Fizičko-geografski čimbenici terenske prohodnosti vozila na kontaktnom prostoru Đakovačke lesne zaravni i pobrđa Dilj gore

Heštera, Hrvoje

Doctoral thesis / Disertacija

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Science / Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:217:163430

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-25**

Repository / Repozitorij:

Repository of the Faculty of Science - University of Zagreb

SVEUČILIŠTE U ZAGREBU

PRIRODOSLOVNO-MATEMATIČKI FAKULTET

GEOGRAFSKI ODSJEK

Hrvoje Heštera

FIZIČKO-GEOGRAFSKI ČIMBENICI TERENSKE PROHODNOSTI VOZILA NA KONTAKTNOM PROSTORU ĐAKOVAČKE LESNE ZARAVNI I POBRĐA DILJ GORE

DOKTORSKI RAD

Zagreb, 2021.

UNIVERSITY OF ZAGREB

FACULTY OF SCIENCE

DEPARTMENT OF GEOGRAPHY

Hrvoje Heštera

PHYSICAL GEOGRAPHICAL FACTORS OF TERRAIN TRAFFICABILITY FOR VEHICLES IN THE CONTACT AREA OF ĐAKOVO LOESS PLATEAU AND DILJ GORA FOOTHILLS

DOCTORAL THESIS

Zagreb, 2021

SVEUČILIŠTE U ZAGREBU

PRIRODOSLOVNO-MATEMATIČKI FAKULTET

GEOGRAFSKI ODSJEK

Hrvoje Heštera

FIZIČKO-GEOGRAFSKI ČIMBENICI TERENSKE PROHODNOSTI VOZILA NA KONTAKTNOM PROSTORU ĐAKOVAČKE LESNE ZARAVNI I POBRĐA DILJ GORE

DOKTORSKI RAD

Mentori:

izv. prof. dr. sc. Neven Bočić

izv. prof. dr. sc. Mladen Pahernik

Zagreb, 2021.

ŽIVOTOPISI MENTORA

Neven Bočić rođen je 1972. godine u Zagrebu, a živi u Karlovcu. Studij geologije i geografije završio je na PMF-u 1999. godine. Od 2002. je zaposlen kao asistent na Geografskom odsjeku PMF-a. Doktorat znanosti stekao je 2009., 2011. godine postaje docent, a 2017. izvanredni profesor. Glavni znanstveni interesi usmjereni su mu na geomorfologiju i to posebno na geomorfologiju krša, speleologiju, glacijalnu geomorfologiju, strukturnu geomorfologiju i geomorfološko kartiranje. Najviše se bavi istraživanjem uvjeta i procesa morfogeneze površinskih i podzemnih krških oblika. Radio je na više znanstvenih projekata od koji su najvažniji: Geomorfološko kartiranje RH, Geomorfološka i geoekološka istraživanja krša RH, Istraživanje krške denudacije i zaštita krškog krajolika, Istraživanje regionalnih promjena okoliša na krškim lokalitetima s posebnim naglaskom na recentne procese i dr. Glavni je urednik znanstvenog časopisa Acta Geographica Croatica, član je uredničkog odbora znanstvenog časopisa Land, te je član uredništva stručnog časopisa Subterranea Croatica. Nositelj je kolegija Geomorfologija i hidrografija krša, Primijenjena geomorfologija, Speleologija te Terenske nastave iz fizičke geografije na Geografskom odsjeku PMF-a. Član je Radne grupe za topografiju i kartiranje Međunarodne speleološke unije (UIS). Član je više strukovnih udruga. Od 2010. do 2013. bio je predsjednik Hrvatskog speleološkog saveza. Trenutno je predsjednik Hrvatskog geomorfološkog društva i član upravnog odbora Hrvatskog geografskog društva. Pripadnik je Hrvatske gorske službe spašavanja.

Mladen Pahernik rođen je 03. rujna 1966. godine u Zagrebu gdje je završio osnovnu i srednju školu. Diplomirano je na Prirodoslovno-matematičkom fakultetu 1993. godine na temu „Geomorfološke karakteristike krša Bijelih i Samarskih stijena“, te stekao zvanje profesora geografije. Na istom fakultetu upisao je Poslijediplomski studij kojeg je završio 1997. godine obranom magistarskog rada „recentni krški procesi i njihov utjecaj na oblikovanje reljefa gorske skupne Velike Kapele“. Doktorsku disertaciju pod naslovom „Geomorfologija Gorskog kotara – primjena GIS-a u istraživanju reljefa“ obranio je 11. svibnja 2005. godine. Od sredine kolovoza 1991. godine sudionik je Domovinskog rata, a od 1993. godine postaje i zaposlenik Ministarstva obrane. Većinu radnog vijeka proveo je kao djelatnik Hrvatskog vojnog učilišta „dr. Franjo Tuđman“ kao nastavnik vojne topografije, vojne geografije i GIS-a. U svom znanstvenom radu izv. prof. dr. sc. Mladen Pahernik primarno se bavi geomorfološkom problematikom s naglaskom na primjenu GIS analiza u geomorfologiji, vojnoj geografiji i kartografiji.

ZAHVALA

Zahvaljujem mentoru izv.prof.dr.sc. Mladenu Paherniku, ujedno i dugogodišnjem stručnom i znanstvenom voditelju i savjetniku, na provedenom vremenu i razumijevanju tijekom svih zajedničkih aktivnosti na terenu, u učionici ili uredu.

Zahvaljujem mentoru izv.prof.dr.sc. Nevenu Bočiću na pruženim savjetima i podršci tijekom doktorskog studija.

Zahvaljujem sadašnjem zapovjedniku Hrvatskog vojnog učilišta "Dr. Franjo Tuđman" general-pukovniku Mati Pađenu i bivšem zapovjedniku general-pukovniku doc.dr.sc. Slavku Bariću na podršci i pruženim logističkim i financijskim sredstvima prilikom terenskih i laboratorijskih istraživanja.

Zahvaljujem bojniku Zoranu Kelavi, operativnom časniku na Vojnom poligonu „Gašinci“, na razumijevanju i koordinaciji aktivnosti tijekom provedbe terenskih mjerenja na području vojnog vježbališta.

Zahvaljujem prof.dr.sc. Biljani Kovačević Zelić na pruženim savjetima tijekom izrade disertacije, koordinaciji provedbe laboratorijskih analiza na Odjelu za mehaniku tla, Geomehaničkog laboratorija, Rudarsko-geološko-naftnog fakulteta u Zagrebu., te posudbi krilne sonde i opreme potrebne za terensko uzorkovanje tla.

Zahvaljujem gospođi Evelini Oršulić, dipl. ing. geot. na provedenim laboratorijskim analizama i susretljivosti tijekom provedbe terenskih uzorkovanja tla.

Zahvaljujem doc.dr.sc. Ivanu Čanjevcu na posudbi laserskog daljinomjera.

Zahvaljujem prof.dr.sc. Stjepanu Husnjaku s Agronomskog fakulteta, Sveučilišta u Zagrebu, na savjetima tijekom izrade doktorske disertacije i ustupljenim izvornim pedološkim podacima Osnovnih pedoloških karata i njihovih tumača.

Zahvaljujem gospodinu Davoru Raciću, dipl. ing. šumarstva, zaposleniku informatičke službe Hrvatskih Šuma d.o.o. na pomoći prilikom preuzimanja i strukturiranja prostorne baze podataka s Geoportala Hrvatskih šuma.

Zahvaljujem djelatnicima DHMZ-a na ustupljenim podacima klimatoloških i kišomjernih postaja na području istraživanja.

Zahvaljujem djelatnicima Agencije za plaćanja u poljoprivredi, ribarstvu i ruralnom razvoju (APPRRR) na ustupljenim podacima uzgajanih poljoprivrednih kultura na području istraživanja.

Zahvaljujem satniku dr.sc. Dejanu Barešiću na pomoći i savjetima oko tehnoloških pitanja vezanih uz vozila.

Zahvaljujem satniku dr.sc. Tomislavu Kovačeviću na pomoći i savjetima tijekom statističke obrade podataka.

Zahvaljujem satniku Daliboru Gernhardtu, mag. ing. el. na raspravama i savjetima vezanim uz rješenja koje nude geoinformacijske tehnologije.

Zahvaljujem kolegi Mladenu Plantaku, mag. geogr. na kritičkom razmišljanju i vremenu provedenom u brojnim raspravama tijekom doktorskog studija.

Zahvaljujem svim bivšim i sadašnjim djelatnicima VoGIS odjela, te ostalim djelatnicima Centra za obrambene i strateške studije „Janko Bobetko“ na svesrdnoj podršci i razumijevanju tijekom doktorskog studija.

Zahvaljujem obitelji i supruzi Kristini koja je najzaslužnija za ostvarenje ovog rada, jer bez nje ne bi bilo moguće izdvojiti sate i dane utrošene na terenska mjerenja, istraživanje i pisanje.

Hvala!

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište u Zagrebu
Prirodoslovno-matematički fakultet
Geografski odsjek

Doktorski rad

Fizičko-geografski čimbenici terenske prohodnosti vozila na kontaktnom prostoru Đakovačke lesne zaravni i pobrđa Dilj gore

Hrvoje Heštera

Doktorski studij geografije: prostor, regija, okoliš, pejzaž

Izvadak: U ovoj disertaciji je prostornom analizom i kvantitativnim vrednovanjem fizičko-geografskih čimbenika uspostavljen GIS model terenske prohodnosti vozila za kontaktni prostor Đakovačke lesne zaravni i pobrđa Dilj gore. Istraživanje fizičko-geografskih čimbenika (reljefa, tla, meteo-klimatskih uvjeta, voda i vegetacije) provedeno je koristeći holistički multidisciplinarni pristup na postojećim i prikupljenim prostornim podatcima temeljem rezultata vlastitih istraživanja, laboratorijskih analiza uzoraka tla (USCS), literaturnih izvora, terenskih mjerenja (digitalni konusni penetrometar) i terenskog kartiranja. Kvaliteta i točnost izvora i rezultata vlastitih istraživanja omogućila je formiranje ulaznih parametara, koji su nakon provedenih analiza strukturirani kroz GIS model koristeći principe neizrazite logike u rasterskoj rezoluciji ćelija 1x1m. Rezultati su omogućili kartografski prikaz i analize dostupnosti područja za 6 različitih tipova vozila kroz scenarije „ljeto/jesen – suho“ i „zima/proljeće – mokro“. Zaključeno je da dominante ograničavajuće čimbenike prohodnosti čine vode (jezera) i vinogradi, dok u periodu „zima/proljeće – mokro“ promjenom meteoroloških uvjeta tlo postaje prevladavajući faktor mobilnosti vozila.

212 stranica, 103 grafička priloga, 20 tablica, 169 bibliografskih referenci; izvornik na hrvatskom jeziku

Ključne riječi: les, konusni penetrometar, neizrazita logika, terenska prohodnost vozila, terenska mobilnost vozila, USCS

Mentori: izv. prof. dr. sc. Neven Bočić
izv. prof. dr. sc. Mladen Pahernik

Povjerenstvo: prof. dr. sc. Danijel Orešić
prof. dr. sc. Nenad Buzjak
prof. dr. sc. Biljana Kovačević Zelić

Tema prihvaćena: 14. ožujka 2017.

Rad prihvaćen: 11. ožujka 2021.

Datum i vrijeme obrane: 1. travnja 2021.

Rad je pohranjen u Središnjoj geografskoj knjižnici Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu, Marulićev trg 19, Zagreb, Hrvatska, u Nacionalnoj i sveučilišnoj knjižnici u Zagrebu, Hrvatska te na Sveučilištu u Zagrebu, Hrvatska.

BASIC DOCUMENTATION CARD

University of Zagreb
Faculty of Science
Department of Geography

Doctoral Thesis

Physical geographical factors of terrain trafficability for vehicles in the contact area of Đakovo loess plateau and Dilj gora foothills

Hrvoje Heštera

The Doctoral study in geography: space, region, environment, landscape

Abstract: In this thesis a GIS model of terrain trafficability of vehicles for the contact area of the Đakovo loess plateau and the Dilj gora foothills promontory was created by spatial analysis and quantitative evaluation of physical-geographical factors. The study of physical-geographical factors (relief, soil, meteo-climatic conditions, water and vegetation) was carried out using a holistic multidisciplinary approach based on existing and collected spatial data, which were based on research results, laboratory analysis of soil samples (USCS), literature sources, field measurements (digital cone penetrometer) and field mapping. The quality and accuracy of the data sources and research results allowed the formation of input parameters, which were structured after analysis by a GIS model using the principles of fuzzy logic in the grid resolution of 1x1m cells. The results provided a "speed made good" mapping and analysis of the availability of the area for 6 different vehicle types through the scenarios "summer/autumn - dry" and "winter/spring - wet". It was concluded that the predominant limiting factors of trafficability are water bodies (lakes) and vineyards, whereas in the "winter/spring - wet" period with the change of meteorological conditions, the soil becomes the predominant factor of vehicle mobility.

212 pages; 103 figures; 20 tables; 169 references; original in Croatian

Keywords: cone penetrometer, cross-country mobility, fuzzy logic, loess, terrain traficability, USCS

Supervisors: Neven Bočić, PhD, Associate Professor
Mladen Pahernik, PhD, Associate Professor

Reviewers: Danijel Orešić, PhD, Professor
Nenad Buzjak, PhD, Professor
Biljana Kovačević Zelić, PhD, Professor

Thesis submitted: March 14, 2017

Thesis accepted: March 11, 2021

Thesis defense: April 1, 2021

Thesis deposited in Central Geographic Library, Faculty of Science, University of Zagreb, Marulićev trg 19, Zagreb, Croatia, in National and University Library in Zagreb, Croatia and at the University of Zagreb, Croatia.

SADRŽAJ

1. UVOD 1

1.1. Svrha i namjena istraživanja terenske prohodnosti vozila 1

1.2. Objekt istraživanja 4

1.3. Područje istraživanja 6

1.3.1. Osnovna fizičko-geografska obilježja područja istraživanja 6

1.3.1.1. Geologija 7

1.3.1.2. Reljef 9

1.3.1.3. Tlo 10

1.3.1.4. Vode 12

1.3.1.5. Vegetacija 15

1.3.1.6. Klima 16

1.4. Cilj i hipoteze istraživanja 19

2. PREGLED DOSADAŠNJIH ISTRAŽIVANJA 20

2.1. Metodološki pristupi istraživanja fizičko-geografskih čimbenika terenske prohodnosti vozila 20

2.1.1. Reljef 24

2.1.2. Tlo 26

2.1.3. Meteo-klimatski uvjeti 33

2.1.4. Hidrografija 35

2.1.5. Vegetacija 36

2.2. Izvori i točnost podataka 36

2.3. Strukturiranje i modeliranje parametara fizičko-geografskih čimbenika terenske prohodnosti vozila 39

2.4. Interpretacija rezultata 41

3. METODOLOGIJA ISTRAŽIVANJA 47

3.1. Tehničko-operativna obilježja vozila korištenih u istraživanju 47

3.2. Izvori i metode istraživanja fizičko-geografskih čimbenika 51
3.2.1. Reljef 52
3.2.1.1. Nagib reljefa 52
3.2.1.2. Topografski indeks vlaženja 55
3.2.1.3. Hrapavost površine 56
3.2.2. Tlo 56
3.2.2.1. Terensko uzorkovanje i laboratorijska analiza prema USCS 58
3.2.2.2. Kartografska obrada rezultata laboratorijskih analiza 65
3.2.2.3. Modeliranje odnosa vozilo-kotač-tlo prema WES metodi 66
3.2.2.4. *In situ* mjerenja 71
3.2.2.4.1. Mjerenje nosivosti tla digitalnim konusnim penetrometrom 74
3.2.2.4.2. Mjerenja vlažnosti tla sondom 77
3.2.2.4.3. Mjerenja temperature tla 80
3.2.2.4.4. Mjerenja posmične čvrstoće tla 80
3.2.2.5. Analiza utjecaja meteoroloških uvjeta na prohodnost tla 81
3.2.3. Vode 84
3.2.3.1. Morfometrija poprečnih profila vodotoka 84
3.2.3.2. Prohodnost dna stalnih vodotoka 88
3.2.4. Vegetacija 90
3.2.4.1. Šume 90
3.2.4.2. Ostala vegetacija 92
3.2.5. Antropogeni čimbenici 94

3.3. GIS modeliranje pomoću neizrazite logike 94
3.3.1. Strukturiranje čimbenika unutar skupa 95
3.3.1.1. Faktor nagiba reljefa 96
3.3.1.2. Faktor hrapavosti površine 99
3.3.1.3. Faktor tla 100
3.3.1.3.1. Prohodnost tla 100
3.3.1.3.2. Klizanje vozila i ljepljivost tla 101
3.3.1.4. Hidrološki faktor 102
3.3.1.5. Vegetacijski faktor 102
3.3.1.5.1. Prohodnost šuma 102

3.3.1.5.2. Ostala vegetacija 105
3.3.1.6. Antropogeni faktor 108
3.3.2. Analiza usporenja vozila 109

4. REZULTATI ISTRAŽIVANJA 112

4.1. Faktor nagiba reljefa 112

4.2. Faktor hrapavosti površine 114

4.3. Faktor tla 116
4.3.1. Analiza uzoraka tla prema USCS 116
4.3.2. Prohodnost tla 120
4.3.2.1. Konusni indeks tla 121
4.3.2.2. Vlažnost tla 125
4.3.2.3. Temperatura tla 128
4.3.2.4. Posmična čvrstoća tla 130
4.3.2.5. Padaline 133
4.3.2.6. GIS analiza prohodnosti tla 136
4.3.3. Klizanje vozila i ljepljivost tla 142

4.4. Hidrološki faktor 144
4.4.1. Analiza točnosti DMR-a na linijskim hidrografskim objektima 145
4.4.2. Prohodnost dna stalnih vodotoka 151

4.5. Vegetacijski faktor 152
4.5.1. Prohodnost šumske vegetacije 152
4.5.2. Prohodnost ostale vegetacije 155

4.6. Antropogeni faktor 157

4.7. Vizualizacija i interpretacija rezultata 158
4.7.1. Karta terenske prohodnosti vozila 159
4.7.1.1. Karta terenske prohodnosti vozila (ljeto/jesen – suho) 162
4.7.1.2. Karta terenske prohodnosti vozila (zima/proljeće – mokro) 171
4.7.2. Optimalna ruta kretanja 180
4.7.3. Statistički pokazatelji terenske prohodnosti vozila 182

5. RASPRAVA **187**

6. ZAKLJUČAK **195**

LITERATURA **197**

IZVORI **211**

PRILOG **213**

POPIS TABLICA **243**

POPIS SLIKA **244**

POPIS PRILOGA **249**

KRATICE **251**

SAŽETAK **252**

SUMMARY **255**

ŽIVOTOPIS **258**

1. Uvod

1.1. Svrha i namjena istraživanja terenske prohodnosti vozila

Tehnološkom razvoju i napretku prethodila je čovjekova želja za unaprjeđenjem kvalitete života. Tehnološka ostvarenja inicirana razvojem parnog stroja, a potom i motora s unutarnjim izgaranjem omogućila su brže i efikasnije načine putovanja i upotrebe strojeva. Slijedno tome razvijala se i cestovna infrastruktura bez koje transport robe i ljudi ne bi bio brz i kvalitetan. Osim konvencionalnih motornih vozila namijenjenih vožnji prometnicama, strojevi i vozila se počinju koristiti i izvan izgrađene cestovne mreže u različite svrhe. Pokretljivost vozila izvan cestovne infrastrukture kao istraživački predmet interesa prepoznat je u agronomiji (obrada tla), šumarstvu (izvlačenje drvne mase), humanitarnom razminiravanju i vojsci (provedba vojnih operacija).

U poljoprivredne svrhe Walter Hancock je 1834. godine predstavio parni traktor, a zatim je 1892. godine John Froelich dizajnirao traktor s benzinskim motorom. Ovi strojevi su sve do 1920-ih imali iznimno malu pokretljivost i ograničene mogućnosti kretanja. Poljoprivredne aktivnosti vezane su uz obradu i pripremu tla za sadnju i kultiviranje usjeva. Šumarski traktori počinju se proizvoditi 1925. godine u Švedskoj, a napredak tehnologije ostvaren je završetkom Drugog svjetskog rata, kada se počinju proizvoditi zglobni traktori (skideri), te potom i specijalizirana vozila forvarderi. Njihova osnovna namjena je ekonomsko iskorištavanje šumske drvne sastojine. Obradi tla u agronomiji i šumarskim radovima zajedničko je njihovo uniformno okruženje i kontrolirani uvjeti rada. Stoga ako promatramo okoliš kao cjelinu poljoprivrednom aktivnošću zahvaćene su samo obradive poljoprivredne površine, dok je šumarstvo usmjereno isključivo na šumske površine.

Strojno uklanjanje mina prvi je put upotrijebljeno u vojne svrhe tijekom Prvog svjetskog rata. Pri razminiranju koriste se strojevi raznih veličina koji koriste razne montirane alate poput mlatilica, freza ili valjaka kako bi što efikasnije istražili i „očistili“ tlo od ubojitih sredstava. Humanitarno razminiravanje podrazumijeva provedbu aktivnosti u kontroliranim uvjetima na terenima koji ne ograničavaju upotrebu strojeva. Ograničavajući operativni faktori specijaliziranih vozila mogu biti nagib terena, stjenovitost, nosivost tla i dr. Teren koji nije obuhvaćen strojnom obradom razminirava se ručno ili uz pomoć pasa tragača (Mikulić, 2013).

U vojne svrhe paralelno s tehnološkim dostignućima razvijana su i vojna vozila specijalnih namjena. Najkarakterističnije vojno vozilo, tenk, svoju „premijeru“ imalo je 1916. godine u Prvom svjetskom ratu kada je „Mark I“ upotrijebljen od strane Ujedinjenog Kraljevstva u bitci na Somi. Osim tenkova vojske svijeta imaju u praktičnoj primjeni široki spektar raznih tipova lakih terenskih vozila, kamiona, oklopnih vozila i radnih strojeva. Za razliku od poljoprivrednih i šumarskih, vojna vozila namijenjena su upotrebi na globalnoj razini i u svim vremenskim i klimatskim uvjetima sukladno potrebitim specifičnostima vojnih operacija i podneblja.

Svim strukama zajednički istraživački interes je utvrđivanje sposobnosti i ograničenja sa svrhom upotrebe vozila u praksi. Uzimajući u obzir razinu kompleksnosti operativnog okruženja koje obuhvaća sve prirodne i umjetne (antropogene) čimbenike prostora najveći udio istraživanja usmjeren je prema vojnim istraživanjima (*List of Publications*, 1993). Utvrđivanje terenske prohodnosti vozila (TPV) potrebno je kako bi se zapovjednicima vojnih snaga omogućio uvid u ograničenja pokretljivosti vozila i stvorile pretpostavke o mogućim smjerovima kretanja vlastitih i protivničkih snaga. Implementiranjem iskustvenih i znanstvenih metoda, analiza zemljišta postaje integralni dio obavještajne pripreme bojišta, te je ključni element pripreme svake vojne operacije (Loomer, 1987; Wawer i dr., 2003).

„Definiranje TPV u sklopu vojne analize zemljišta kompleksan je analitički proces koji zahtijeva sveobuhvatan multidisciplinaran pristup (Sl. 1.) (*Military Geographic Intelligence*, 1972). Primarni je cilj pri utvrđivanju TPV utvrditi u kojoj mjeri pojedini čimbenik i/ili kombinacija čimbenika usporavaju vozilo prilikom kretanja u odnosu na njegovu maksimalnu moguću brzinu kretanja. Čimbenici koji definiraju pokretljivost vozila na zemljištu su postojeća mreža prometnica, izgrađeni objekti, morfološka, hidrološka i pedološka obilježja zemljišta, vegetacija i meteorološki uvjeti. Vojno-geografska analiza zemljišta dio je OAKOC[1] procedure unutar procesa donošenja vojnih odluka (*Military Geographic Intelligence*, 1972; *Terrain Analysis*, 1990). Osnovni preduvjet uspješnog planiranja i provedbe pokreta vojnih snaga je prikupljanje, obrada i analiza podataka o zemljištu i nadolazećim meteorološkim prilikama kroz strukturiranu bazu podataka (Bruzese, 1989; Mintzer i Messmore, 1984). TPV se istražuje u svrhu definiranja mogućih ruta i smjerova kretanja vozila, odnosno kako bi se definirali koridori

[1] OAKOC (engl. *Observation/fields of fire, Avenues of approach, Key terrain, Obstructions, Cover and concealment)* je kratica za proces korišten od strane zemalja članica Sjevernoatlantskog saveza (NATO), tijekom kojeg se analizira zemljište u svrhu obavještajne pripreme bojnog polja tijekom procesa planiranja vojnih operacija, gdje se utvrđuju sposobnost motrenja i polja vatri, avenije prilaza-koridori mobilnosti, ključni tereni, prepreke, te zaštita i prikrivanje vojnih snaga.

mobilnosti i avenije prilaza[2]. Krajnji cilj vojnih analitičara je stvaranje karte prohodnosti vozila, temeljem koje se potom može planirati kretanje vozila.“ (Heštera i Pahernik, 2018).

Utvrđivanje mogućnosti TPV prethodi potrebnim saznanjima u sljedećim okolnostima:

- potrebe korisnika za što točnijim modelima TPV kako bi obuka, planiranje i provedba aktivnosti bila što uspješnija,
- poznavanje obilježja terena za kvalitetniji odabir opreme.

Sl. 1. Položaj vojne analize zemljišta unutar ostalih znanosti

Izvor: Heštera i Pahernik (2018)

[2] „Avenija prilaza je zračna ili kopnena ruta smjera napada snaga određene jačine koja vodi ka ključnom terenu na zemljištu. Grupa koridora mobilnosti čini aveniju prilaza.” (*Intelligence preparation*, 1994, 2-18)

1.2. Objekt istraživanja

Kvantificirana evaluacija terenske mobilnosti vozila zasnovana je na analizi pojedinačnih geografskih subjekata i pojava na zemljištu, odnosno sintezi njihovih atributa i parametara vozila i vozačkih sposobnosti.

„Poznavanje graničnih tehničko-taktičkih mogućnosti kretanja vozila na zemljištu kao predmet proučavanja prepoznato je i primijenjeno prvotno u vojnoj znanosti (Johnson, 1921; Malm, 2018). Poznavanje obilježja zemljišta prilikom planiranja vojnih operacija prepoznato je kao odlučujući čimbenik uspješnog ishoda ratnih operacija još od antičkih vremena (Clausewitz, 1997; Jomini, 1838; Tzu, 2009). Do svjetskih ratova vojno-geografska analiza zemljišta bila je usmjerena u većoj mjeri na upotrebu snaga na strateškoj razini, pri čemu je zanemarena upotreba snaga na najnižoj taktičkoj razini ratovanja. Iako je postojala svijest o važnosti poznavanja fizičkih obilježja zemljišta kroz cijelu povijest ratovanja, sistematizirano proučavanje prohodnosti terena u širokoj znanstvenoj zajednici aktualizirano je tek nakon završetka Prvog svjetskog rata (Johnson, 1921; Malm, 2018). Brojne vojne akcije, npr. Treća bitka kod Ypresa 1917. godine, bitka kod Smolenska 1943. godine ili bitka kod Monte Casina 1944. godine, okončane su isključivo zbog nepoznavanja obilježja zemljišta i vremenskih prilika i to isključivo zbog nemogućnosti pokreta i upotrebe vojne tehnike, odnosno vozila. Znanstvena istraživanja obilježja zemljišta s aspekta TPV prvotno je u Sjedinjenim Američkim Državama (SAD) u 1950-ima započeo Waterways Experiment Station-a (WES)[3]. Tijekom 1970-ih godina analiza prohodnosti zemljišta u vojsci SAD-a postaje sastavni dio procesa planiranja vojnih operacija izdavanjem sljedećih proceduralnih i doktrinarnih vodiča (Bruzese, 1989): *Military Geographic Intelligence (Terrain)* (1972), *Terrain Analysis* (1978) i serijom Terrain Analysis Procedural Guides (počevši od 1979. godine). Tome je prethodio razvitak i masovna upotreba širokog spektra vrsta vozila koja koji su trenutno u operativnoj uporabi. Danas se istraživanja TPV provode od najviših razina u vidu multinacionalnih suradnj. pa sve do razine studentskih završnih radova.“ (Heštera i Pahernik, 2018)

U predmetnoj tematici koja se odnosi na utvrđivanje pokretljivosti, mobilnosti i općenito ograničavajućih voznih osobina vozila prilikom njihove upotrebe izvan cestovne infrastrukture postoji nekoliko sličnih pojmova koji opisuju svojstva zemljišta ili tehničke mogućnosti vozila

[3] US Army Engineer Waterways Experiment Station, Vicksburg, Mississippi.

gdje se u literaturi navode nekoliko istoznačnica i pojmova bliskoga značenja (Heštera i Pahernik, 2018). Autori koriste pojmove kao što su:

- terenska prohodnost (engl. *terrain trafficability*) (Birkel, 2003; Donlon i Forbus, 1999; Đuka, 2014; Grabau, 1964; Gumoś, 2005; Hofmann, i dr. 2013; Hohmann, i dr. , 2013; Kourdian, 2009; *Military Geographic Intelligence*, 1972; *Production of Cross-Country*, 1959; Rybansky, 2003; Saarilahti, 2002; Sadiya i dr., 2017; Schreier i Lavkulich, 1978; Shoop i dr., 2005; Suvinen, 2006; Wong, 2001),
- terenska mobilnost (engl. *cross-country mobility* – CCM) (Bruzese, 1989; Grogan, 2009; Hetherington i Smith, 1986; Jurkat, i dr., 1975a; Mintzer i Messmore, 1984; Planning and design, 1994; Pearson i Wright, 1980; Rybansky, 2014; Shoop i dr., 2006; Talhofer i dr., 2015),
- terenska pokretljivost (engl. *cross-country movement*) (Ahlvin i Haley, 1992; Donlon i Forbus, 1999; Haley i dr., 1979a; Jurkat i dr., 1975; Pahernik i dr., 2006; Pearson i Wright, 1980; *Production of Cross-Country*, 1959; Rybansky, 2014; *Terrain Analysis*, 1990; Wynn, 1985),
- terenska prometnost (engl. *cross-country trafficability*) (Donlon i Forbus, 1999; Gumoś, 2005),
- manevarska sposobnost vozila (engl. *vehicle maneuverability*) (Bozdech, 2012; Dawkins, 2011; Gumoś, 2005; Mason, i dr., 2001; Shoop i dr., 2005).

Pojam „prohodnost terena“ upotrebljava se pri određivanju ograničavajućih čimbenika koji utječu na pokretljivost vozila izvan cestovne infrastrukture. Iako ovaj rad svojim multidisciplinarnim pristupom zahtijeva obuhvaćanje brojnih struka i područja znanosti, u radu će se upotrebljavati uglavnom pojam „terenska prohodnost vozila“ jer je on pojmovno najuže vezan uz geografiju. „Pojam sadržava opis morfometrije, struktura i pojava na zemljištu koje definiraju mogućnost pokreta vozila. Pojmovi mobilnost, pokretljivost, prometnost i manevarska sposobnost vozila se prije svega koriste prilikom opisivanja tehničko-taktičkih sposobnosti vozila za kretanje po zemljištu van cestovne infrastrukture“ (Heštera i Pahernik, 2018).

Terenska mobilnost vozila uvjetovana je prisutnošću izgrađene infrastrukture, fizičko-geografskih struktura, oblika i pojava, iskustvom vozača i tehničko-taktičkim obilježjima vozila. Utvrđivanje prisutnosti i strukture fizičko-geografskih čimbenika, od kojih zavisi prohodnost vozila, osnovni je preduvjet predviđanja TPV. Fizičko-geografski elementi koji

uvjetuju pokretljivost vozila na zemljištu su reljef, vode, tlo, vegetacija i klimatsko-meteorološke prilike (Birkel, 2003; Borisov i dr., 2010; Grabau, 1964; Grogan, 2009; Gustafsson i Hägerstrand, 2005; Mohamad Rabab, 2002; Pearson i Wright, 1980; Pimpa i dr., 2014; *Production of Cross-Country*, 1959; Rybanský, 2003; Rybanský i dr., 2015; Schreier i Lavkulich, 1978).

1.3. Područje istraživanja

1.3.1. Osnovna fizičko-geografska obilježja područja istraživanja

Područje istraživanja je omeđeno s 45°24' i 45°15' sjeverne geografske širine, te 18°28' i 18°10' istočne geografske dužine (Sl. 2.). Područje istraživanja zahvaća 394.3 km². Područje istraživanja nalazi se u istočnom dijelu Hrvatske u središnjem dijelu Slavonije, odnosno na dodiru istočnog ravničarskog i zapadnog gorskog prostora. U užem geografskom smislu, sukladno geomorfološkoj klasifikaciji, prostor u suštini predstavlja kontaktni prostor dviju mikrogeomorfoloških regija: Đakovačke lesne zaravni i pobrđa Dilj gore, prema Bognaru (1999). Đakovačka lesna zaravan nastavlja se na istok gdje se spaja s Vukovarskom lesnom zaravni. Dilj gora predstavlja samostalno pobrđe koje svojim sjeveroistočnim padinama dodiruje krajnje jugoistočne obronke Krndije. Jasne i koncizne granice ovih dviju izdvojenih uzvišenja Zapadne Slavonije nisu oštro i od akademske zajednice strogo definirane, s obzirom na to da se u geološkoj literaturi kao granica može pronaći potok Breznica, dok u geografskoj rijeka Lonđa. Budući da je ovaj rad prvotno geografske tematike, naslov rada, odnosno područje istraživanja definirano je sukladno geomorfološkim načelima prema Bognaru (1999). U sklopu područja istraživanja nalazi se i vojni vježbališni poligon „Gašinci“ na kojem su rađena neka detaljnija istraživanja s ciljem daljnjeg razvoja istraživanja TPV.

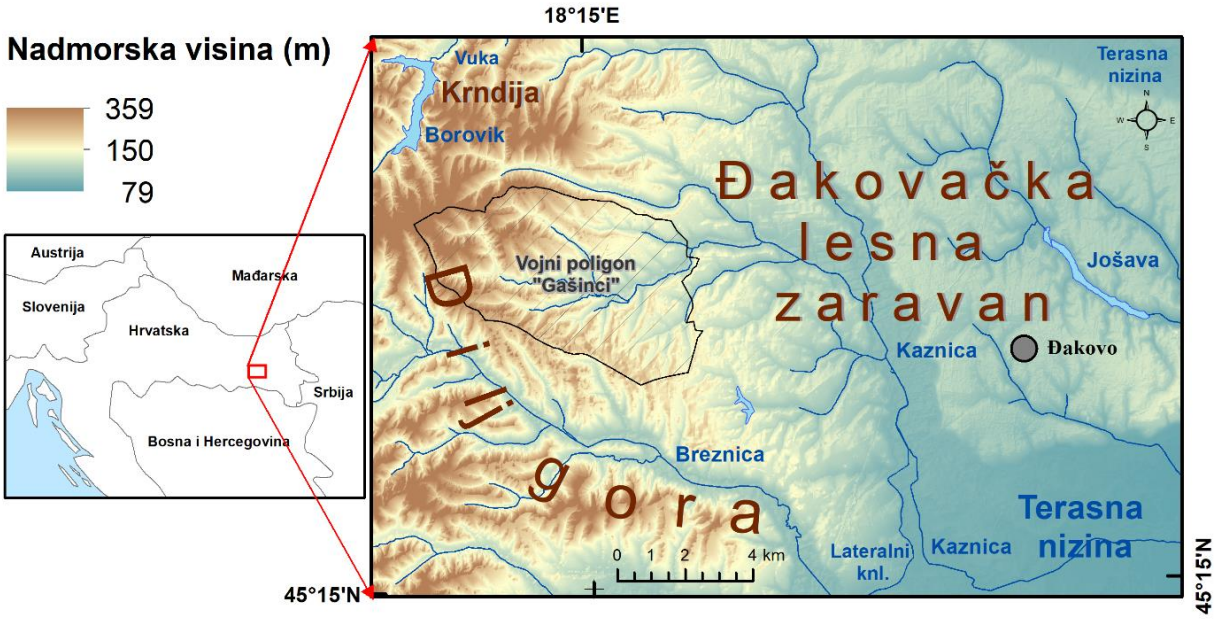

Sl. 2. Prostor istraživanja – fizičko-geografska karta

1.3.1.1. Geologija

Središnjim i istočnim dijelom područja u površinskom sloju dominiraju kvartarne naslage (les) pleistocenske starosti i mlade naplavine holocenske starosti (Sl. 3.). Ranije su ove naslage pokrivale i dijelove na zapadu, međutim one su ogoljene intenzivnom erozijom. U sastavu naslaga na uzvišenijim dijelovima dominira les i lesu slični sedimenti, dok u dijelovima zahvaćeni akumulacijskim procesima jezersko-barski i barski sedimenti (Korolija i Jamičić, 1989). Prisutne lesne naslage sežu od 15 do 30 metara dubine u kojima postoje humusni proslojci nastali u humidnim i toplijim razdobljima procesom truljenja vegetacije. Prisutni lesni sedimenti ispunili su paleoreljefne površine, a na sadašnji prostor transportirani su eolskim procesima za vrijeme virmske glacijacije. Akumulirani les je potom bio pod konstantnim utjecajem klimatskih promjena (izmjena smrzavanja i odmrzavanja), što je manifestirano brojnim pukotinama koje su stvorile uvjete za cirkulaciju kapilarne i atmosferske vode. Prisutni les se razvijao u uvjetima veće vlažnosti i reljefne dinamike, stoga je karbonatiziran i oglinjen. Prema granulometrijskom sastavu sedimenti spadaju u sitnozrnate čestice. Praporni pijesci taloženi su na rubnim područjima Dilj gore. Aluvijalni nanosi potoka ispunjavaju njihove šire

doline, sastav litološke građe je heterogen, jer ovisi o okolnom izvorišnom području s kojeg je transportiran (Korolija i Jamičić, 1989).

U zapadnom dijelu dominiraju nešto starije naslage miocenske i pliocenske starosti. Slojevi pijeska, šljunaka, siltova i glina gornjeg ponta dominiraju velikim područjem Dilj gore. Opća značajka ovih sedimenata je odlična sortiranost zrna. Prisutni su lesni pijesci pleistocenske starosti za koje je karakteristično da je njihov litološki sastav vrlo promjenjiv, a ovisi prije svega o litološkom sastavu podloge. Debljina ovih slojeva iznosi do 20 metara i nije točno utvrđena (Šparica i dr., 1986b).

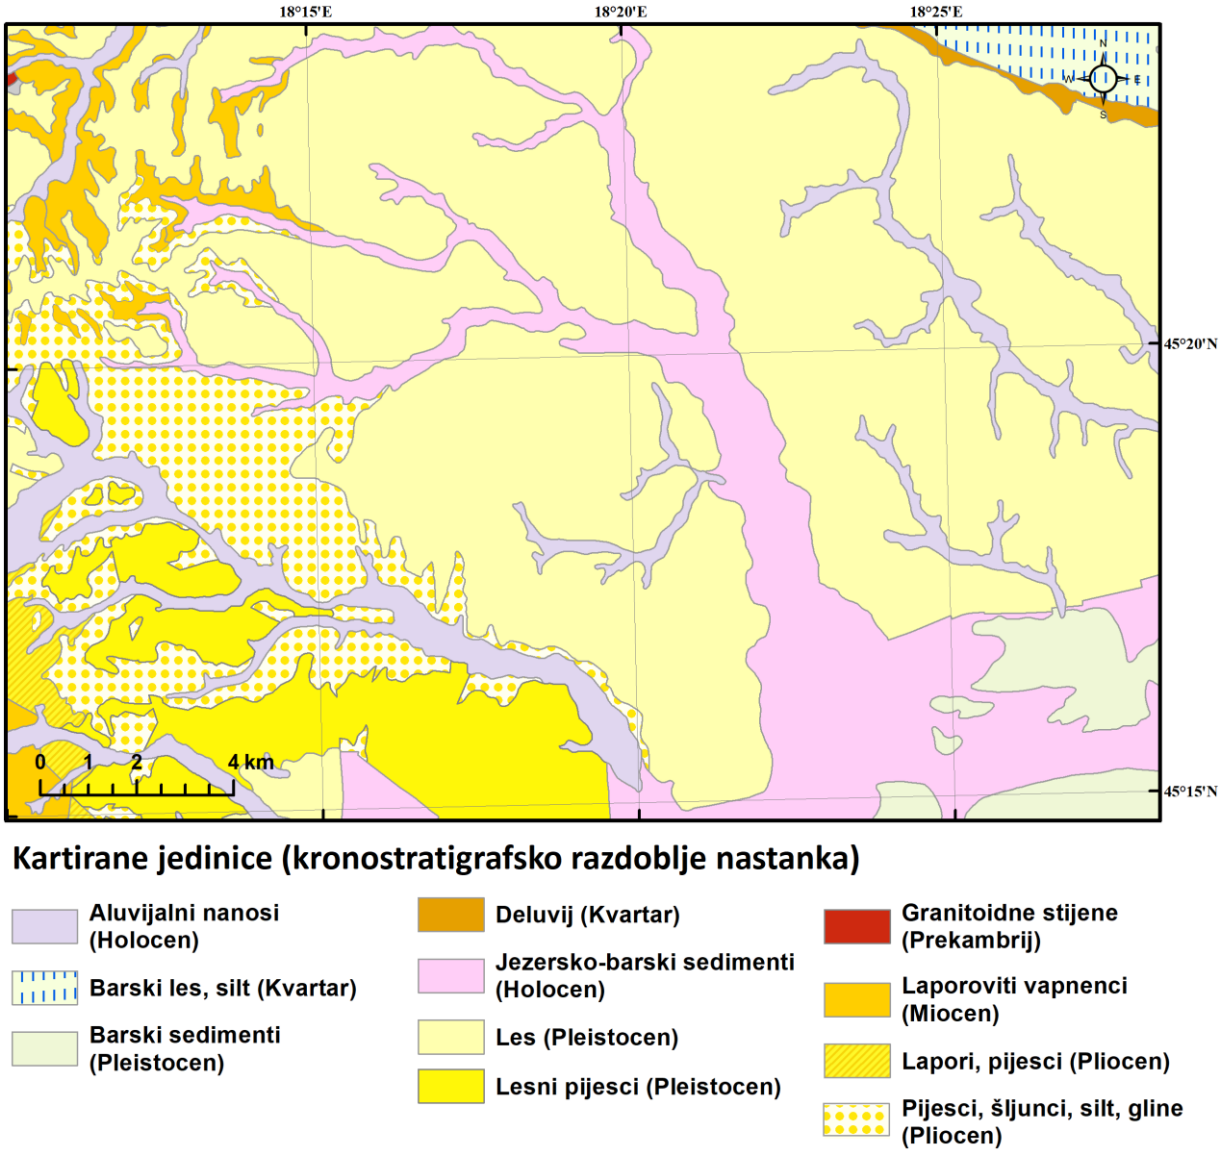

Sl. 3. Osnovna geološka karta

Izvor: Dijelovi listova L 34-97 Slavonski Brod (Šparica i dr., 1986a) i L 34-85 Našice (Korolija i Jamičić, 1989a)

1.3.1.2. Reljef

U geomorfološkom smislu prostor možemo raščlaniti u tri jedinstvene cjeline, a to su lesna zaravan, pobrđa i terasne nizine (Sl. 2.).

Zapadni dio istraživanog područja spada u istočne dijelove pobrđa Dilj gore, te vrlo malim dijelom na sjeverozapadu - istočnim obroncima Krndije. Obzirom na svoj izgled pobrđa spadaju u kategoriju brežuljkastog tipa reljefa. Iako svojom apsolutnom visinom na prelazi 500 metara, zbog pošumljenosti i izraženih nagiba, prostoru Dilj gore narod je pridao naziv „gora“. Dilj gora čini samostalnu cjelinu i nije vezana uz više predjele Papuka. Područjem istraživanja obuhvaćeni su istočni dijelovi pobrđa. Područje istraživanja u svojem sjeverozapadnom dijelu zahvaća i krajnje istočne padine Krndije.

Istočni dio čini dio Đakovačke lesne zaravni, gdje se ona na sjeveru i jugu preko Đakovačke grede spušta (nagibima do 12°) prema naplavnim nizinama porječja rijeka Save i Biđa na jugu i Vuke na sjeveru (Sl. 4.). Zaravni brežuljkastog područja izgrađene su većim dijelom od pleistocenskog eolskog sedimenta – lesa, s ilovastim i glinastim sedimentima. Prema geomorfološkoj klasifikaciji (Bognar, 1978) uz eolski les imamo i derazijski, fluvijalni i epigenetski les. Na nestabilnoj i mladoj podlozi, zadržavanjem lesnog sedimenta tekućice su oblikovale blago valovitu uzvisinu. Đakovačka lesna zaravan je ostatak lesnog pokrova koji nije recentnim kvartarnim klimatskim promjenama erodiran i pretaložen, stoga lesna greda od 10 do 20 metara nadvisuje okolne nizine. Debljina naslaga ovisi o nagibu i snazi destrukcijskih procesa. Lesne naslage su porozne i nisu uslojene pri čemu se voda lako procjeđuje. U modeliranju reljefa dominiraju fluvijalni i padinski procesi uz sufozijske procese na lesu. Intenzivnim jaružnim erozivnim procesima na rahloj lesnoj podlozi u donjoj trećini padina dolazi do intenzivnog udubljivanja tla, stoga je prisutna gusta mreža vododerina. Na izrazito zaravnjenim mikro lokacijama moguće je duže zadržavanje površinske vode u plitkim ponikvama (pseudokrški oblici).

Terasne nizine nalaze se jugoistočno i manjim dijelom sjeveroistočno od lesne zaravni. One predstavljaju nekadašnje poloje riječnih tokova, što se može vidjeti u unakrsnoj slojevitosti naslaga. Na jugoistoku ju čine zapravo naplavine tokova (Kaznice, Jošave i Breznice) koji su akumulirali materijal fluvijalnim procesima s prostora pobrđa Dilja i lesne zaravni. Sjeveroistočni dio nizine spada u porječje Vuke, koja transportira materijal s obronaka Krndije.

Terasne nizine nalaze se na nešto višoj relativnoj visini (2-5m) od poloja te na njima više nisu prisutne poplave.

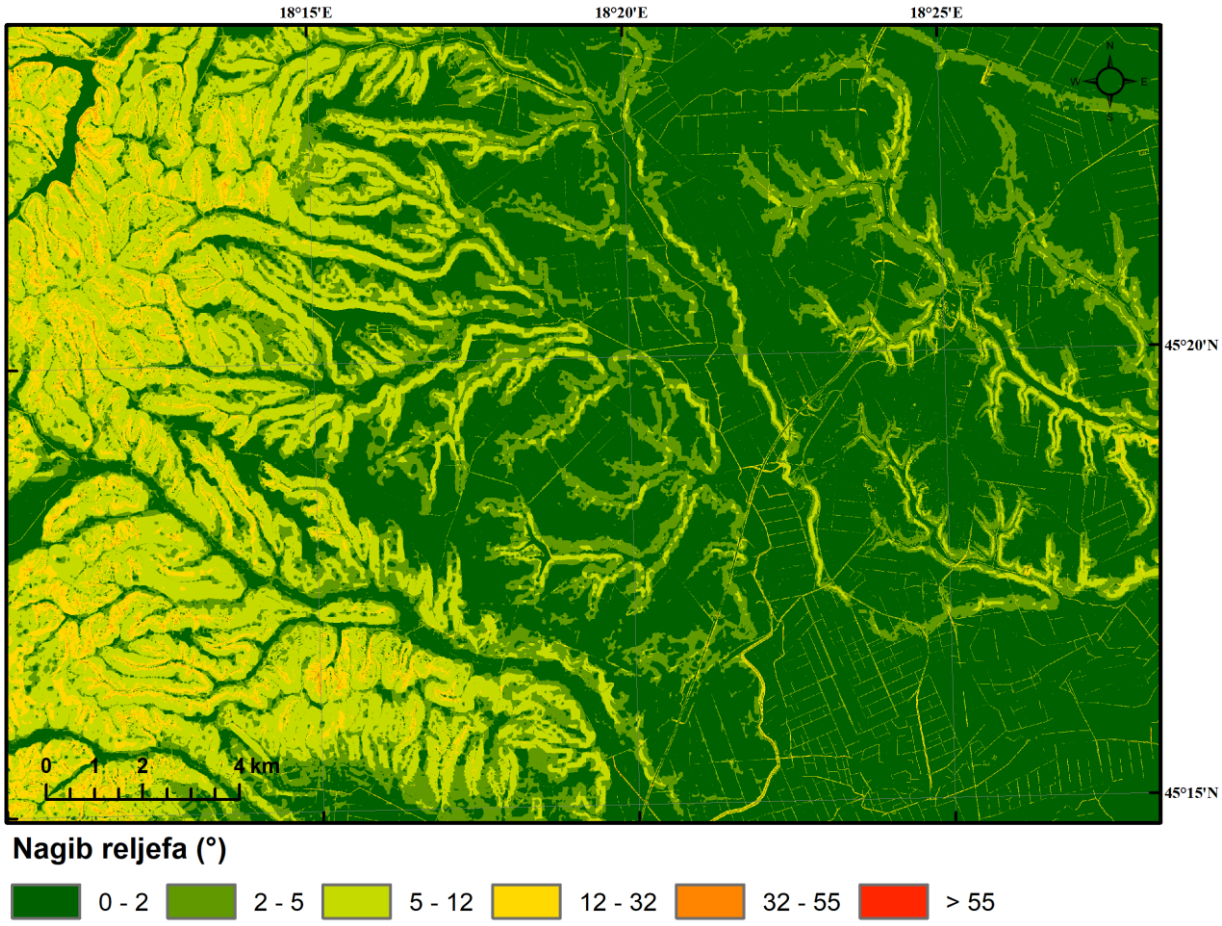

Sl. 4. Nagib padina istraživanog područja

1.3.1.3. Tlo

U skladu s korištenom sistematizacijom na osnovu načina vlaženja tla (Husnjak, 2014) na ovom području nalazimo automorfna (vlaženje oborinskom vodom) i hidromorfna tla (povremeno ili stalno prekomjerno vlaženje stagnirajućom površinskom, te dodatno površinskom i podzemnom vodom). U nastavku će biti opisani prisutni glavni tipovi tala (Sl. 5.) i njihova glavna obilježja, dok će se opis podtipova i njihovih varijeteta izostaviti (detaljnije u: Bogunović, 1973a; Husnjak, 2014; Vidaček, 1973a).

Automorfna tla su ujedno i najzastupljenija na području istraživanja (točni površinski udjeli prema tipovima tla, vidi Tab. 2.). Najzastupljeniji tip tla je lesivirano tlo, uz moguće kombinacije s prisutnim sirozemom i eutrično smeđim tlom. Lesivirano tlo nastalo je akumulacijom matičnom supstrata – lesa u vrijeme trećeg virmskog stadijala. Za ova tla je karakterističan proces oglejavanja eluvijalnog i iluvijalnog Bt horizonta. Sirozem možemo pronaći na erodiranim tjemenima diseciranih formi reljefa, te na donjim trećinama padinama, gdje matični supstrat izbija na površinu zbog prevelike erozije. Sirozemi su i antropogeno predisponirani zbog prekomjernog krečenja šuma, što je dovelo do ubrzanja erozivnih procesa. Rendzine su se razvile na laporovitoj i vapnenačkoj podlozi. Nastanak i razvoj tla uvjetovan je litološkom podlogom, vegetacijom i klimom. Možemo ih pronaći u kombinaciji sa sirozemima u području Dilj gore. Distrično smeđe ili kiselo smeđe tlo se razvilo na jače ocjeditim područjima beskarbonatnih ilovina, a ponegdje i glinama. Ono se nalazi na nešto ocjeditijim gornjim trećinama padina, dok pesudooglejena tla nalazimo na zaravnjenijim predjelima i vršnim dijelovima pobrđa. Ovom stadiju površinskog oglejavanja prethodila je faza lesivaže, odnosno premještanja gline u dublje slojeve – ispiranje površinskog sloja. Sadnjom vinograda oko Mandićeva i Trnave stvoren je zaseban tip tla rigosol koji je nastao dubokim (do 1 metar dubine) oranjem – rigolanjem tla.

Hidromorfna tla nalazimo na blago nagnutim terenima, nizinama i polojima većih vodotoka. Pseudoglej nalazimo na mezouzvisinama nizina i zaravnima pobrđa. Karakterizira ga stagniranje površinske vode (do 70 cm) na slabo propusnim ili nepropusnim horizontima. Fluvijalno tlo (fluvisol) definirano je prisustvom humusnog horizonta terestričkog tipa, a ovdje je izgrađeno od lesa kao matičnog supstrata. Njegova geneza određena je prisustvom i izmjenom podzemne vode na dubinama od 1 do 2 metra. Amfiglejna tla nalazimo najčešće u kombinaciji s koluvijem u mezodepresijama nizinskih predjela, te u srednjim i donjim dijelovima potočnih dolina. Karakterizira ih prisustvo hidromorfizma do 1 metra dubine, a vlaženje se odvija površinskom, slivnom, poplavnom i podzemnom vodom. Većina ovih tala zahvaćena je hidromelioracijskim zahvatima, stoga je prirodno predisponiran proces razvoja tla zaustavljen pa se može reći da ovaj tip polako preuzima svojstva hipoglejnih tala. Ritsku crnicu karakterizira topografska uvjetovanost, a njihova pojavnost vezana je uz negativne (akumulativne) forme reljefa. Cijelim dubinskim profilom zahvaćena je djelovanjem podzemne vode, što istovremeno otežava odvodnju, pa uslijed većih padalina dolazi do dužeg zadržavanja površinske vode (Bogunović, 1973a; Vidaček, 1973a).

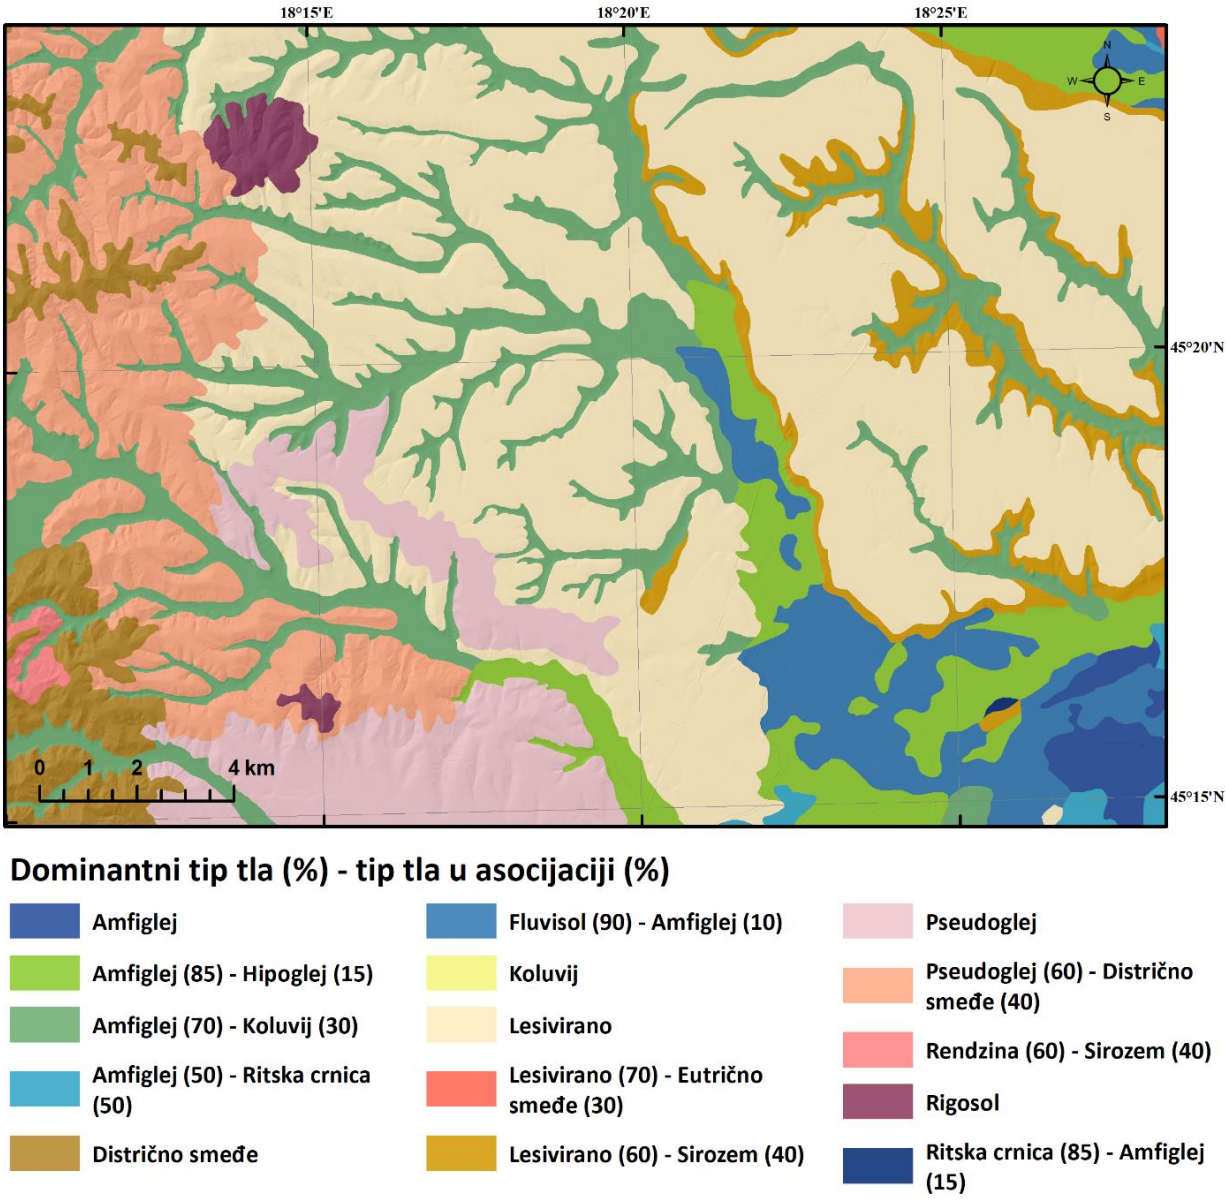

Sl. 5. Osnovna pedološka karta

Izvor: Dijelovi listova Osnovne pedološke karte (1:50 000) Slavonski Brod 2 (Vidaček, 1973b) i Vinkovci 1 (Bogunović, 1973b)

1.3.1.4. Vode

Ovaj prostor odvodnjavaju vodotoci porječja Dunava i Save (Sl. 6.). Dunavskom slijevu pripada rijeka Vuka s pritocima koja protječe sjeverozapadnim dijelom i područjem sjeverno od ruba Đakovačke grede. Na ovom području nalazi se i akumulacija Borovik (1.13 km^2) koja

ujedno čini i izvorišni dio rijeke Vuke. Središnjim i južnim dijelom protječu Breznica i Kaznica (pritoke Save), te Jošava (pritok Biđa). Područje je ispresijecano brojnim dolinama rijeka Kaznice i Jošave sa pritocima koje ujedno čine vododjelnicu između Dravsko-Dunavskog i Savskog sliva. Mnogobrojni manji ili veći potoci i rijeke izviru i teku blago usječenim dolinama brežuljkasto-brdovitog područja i slijevaju se u nizinsko područje.

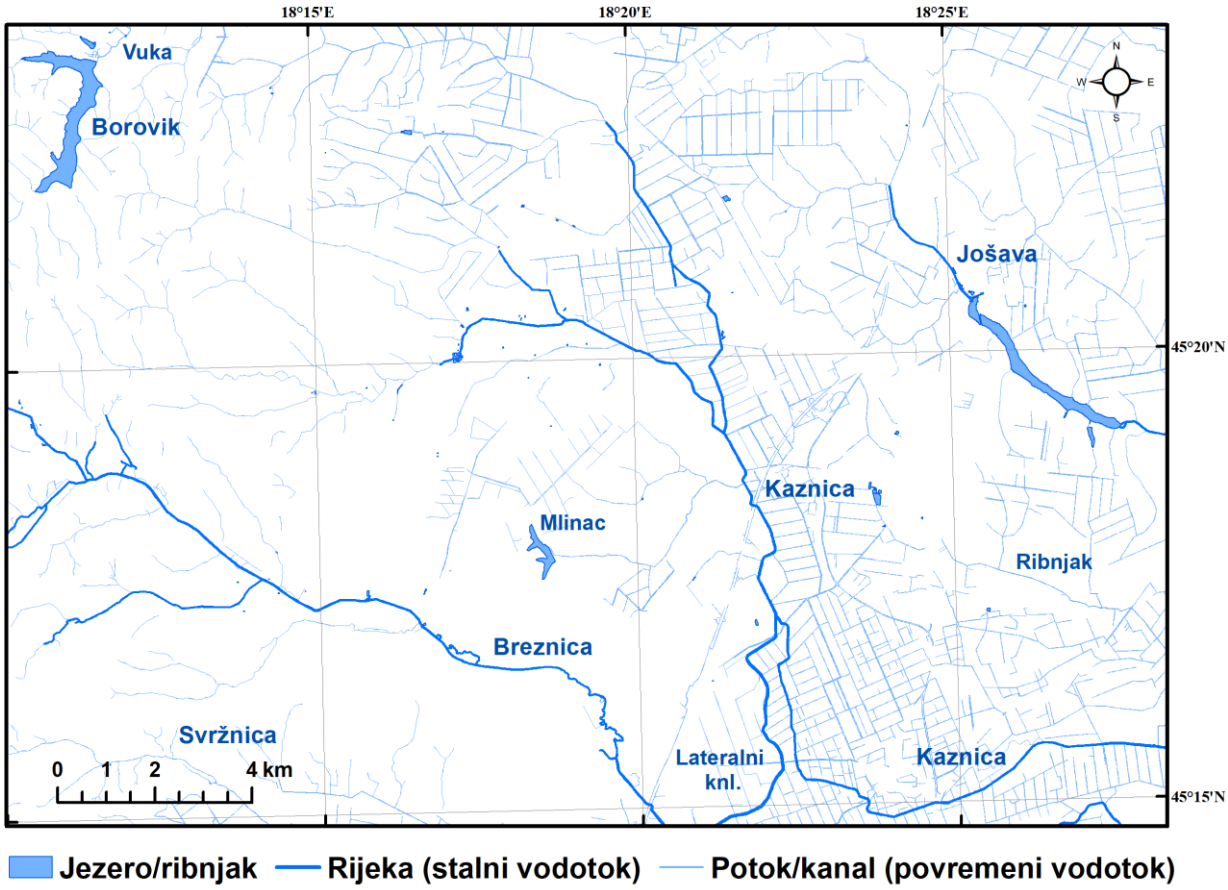

Sl. 6. Vodene površine

Izvor: CROTIS[4]

Vodotoke na lesnoj zaravni karakterizira mnoštvo dužih i kraćih potočnih dolina povremenog toka erozijsko-derazijskog tipa koji nemaju stalne izvore, pa stoga tijekom

[4] CROTIS – Hrvatski topografski informacijski sustav (*Državna geodetska uprava*, 2014), stanje podataka CROTIS baze odgovara situaciji na terenu iz 2017. godine

dijelova godine presušuju. S druge strane, doline stalnog toka, koje imaju razgranatu mrežu pritoka su Kaznica, Jošava i Breznica (Sl. 6.).

Na dijelovima istraživanog područja provedene su hidromelioracijske mjere, kako bi se postigli povoljniji uvjeti za poljoprivrednu proizvodnju (Sl. 7.).

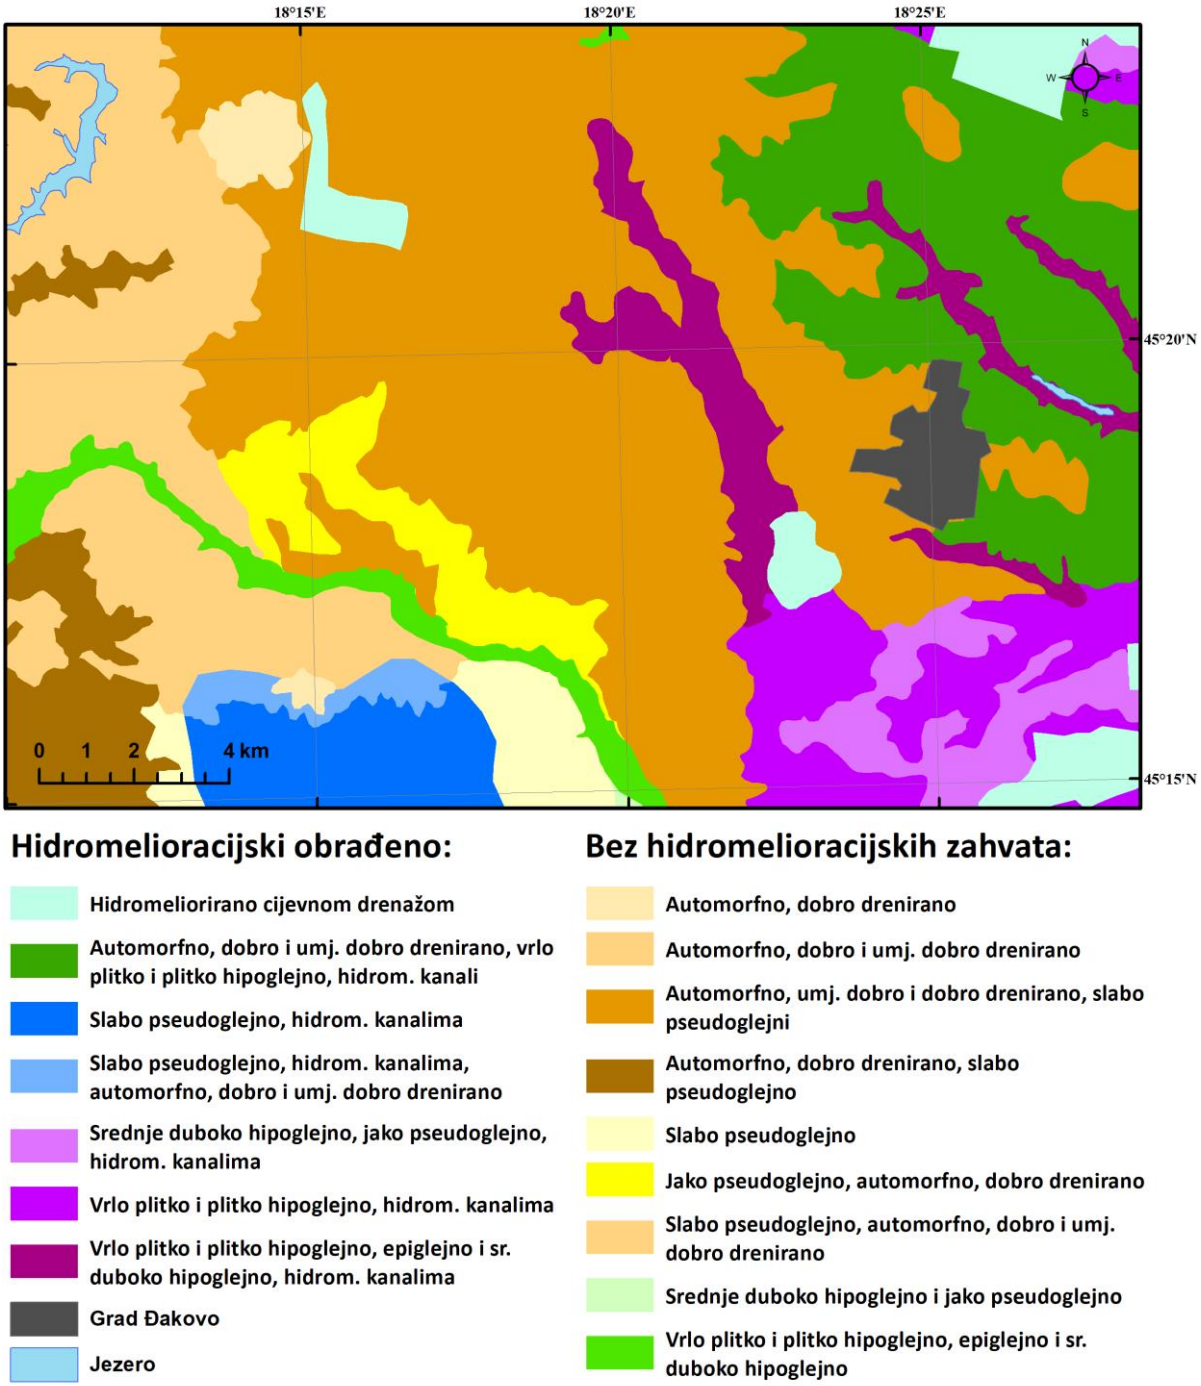

Sl. 7. Hidropedološka karta - načini vlaženja i osnovni tipovi tla

Modificirano prema: *Zavod za pedologiju* (2004)

Hidromelioracijskim zahvatima spriječene su poplave od vanjskih i unutarnjih voda. Na ovim prvotno močvarnim područjima, melioracijski zahvati su započeti još u vrijeme antike (Bojanovski, 1993), a u tu svrhu su u drugoj polovini 1980-ih godina iskopani brojni duboki kanali i ugrađena cijevna drenaža koja je ubrzala otjecanje oborinskih voda i zaustavila zadržavanje vode na oranicama.

1.3.1.5. Vegetacija

Recentna vegetacija ne odgovara autohtonoj vegetaciji koja je postojala na ovim područjima do Srednjeg vijeka. Do tada je cjelokupno područje bilo pod šumom, nakon čega su krčenjem šuma stvarane poljoprivredne površine (Vlašić, 2019). Na najnižim i najvlažnijim dijelovima aluvijalne ravni rasle su šume hrasta lužnjaka, u nešto višoj lesnoj zaravni šume hrasta kitnjaka, dok u pobrđu šume bukve i graba. Najmanje izmjene autohtonog pejzaža doživljavaju brdski predjeli, pri čemu je nekoliko gajeva opstalo i danas na lesnoj zaravni, dok je aluvijalna ravan u potpunosti transformirana u oranice. Današnja vegetacija je usko vezana s geomorfologijom područja. Brdska područja obrasla su šumskom vegetacijom koja sprječava proces spiranja, dok je lesna zaravan uglavnom kultivirana (Sl. 8.). Prvobitnu vegetaciju čitavog područja činile su šume hrasta, graba i brijesta. Danas se mogu pronaći šumske sastojine hrasta kitnjaka, bukve, graba, crnog jasena i bagrema. Eksploatacijom šumskog pokrova u ravničarskim predjelima stvorene su velike obradive površine koje se trenutno intenzivno obrađuju (Bogunović, 1973a). Ova nekada poplavna područja, hidromelioracijskim zahvatima postala su krâj intenzivne ratarske proizvodnje. Od uzgajanih kultura najzastupljeniji su kukuruz, pšenica, uljana repica i suncokret. Danas je na zaravni i nizinskom dijelu ostalo samo nekoliko usamljenih gajeva. Istočnim dijelom dominira agrarni pejzaž zasijan žitaricama, dok se na prisojnim stranama oko Mandićevca i Trnave kultiviraju vinogradi. Diljsko i krndijsko pobrđe je šumovito s malim poljoprivrednim površinama.

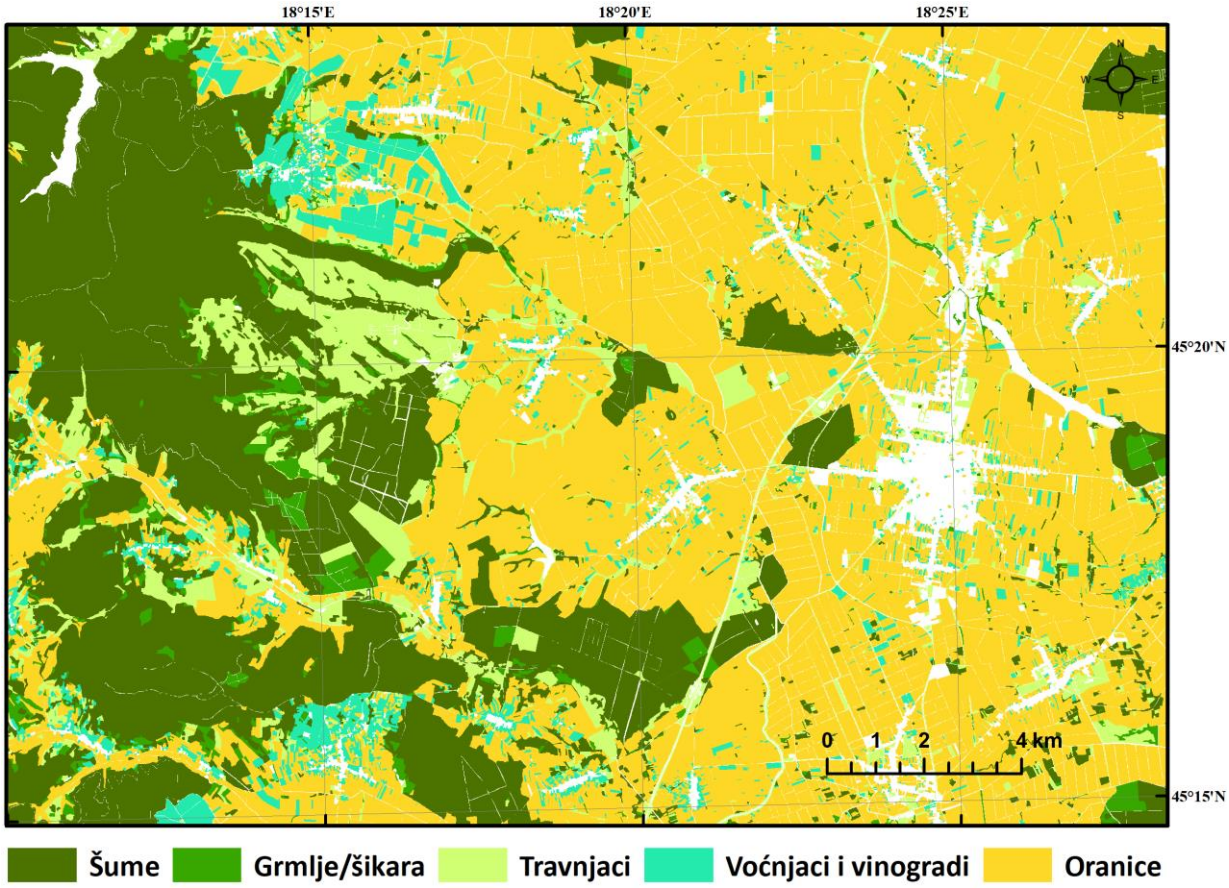

Sl. 8. Vegetacija

Izvor: CROTIS[5]

1.3.1.6. Klima

Istraživano područje je pod izrazitim utjecajem kontinentalnih klimatskih obilježja. Ovaj prostor se nalazi na prijelaznom području između vlažnih krajeva na zapadu i suhih krajeva na istoku. Na ovim prostorima izraženo je nekoliko pravilnosti u pogledu temperature, koja u prosjeku raste u smjeru od zapada prema istoku. Količina padalina je predefinirana dvama faktorima. Količina padalina opada prema istoku zbog: orografskog efekta Slavonskog gorja, te zbog gubitka vlage zračnih masa (iz smjera jugozapada i zapada) na putu prema unutrašnjosti kontinenta (Sl. 9.) (Zaninović i dr., 2008).

[5] CROTIS – Hrvatski topografski informacijski sustav (*Državna geodetska uprava*, 2014), stanje podataka CROTIS baze odgovara situaciji na terenu iz 2017. godine

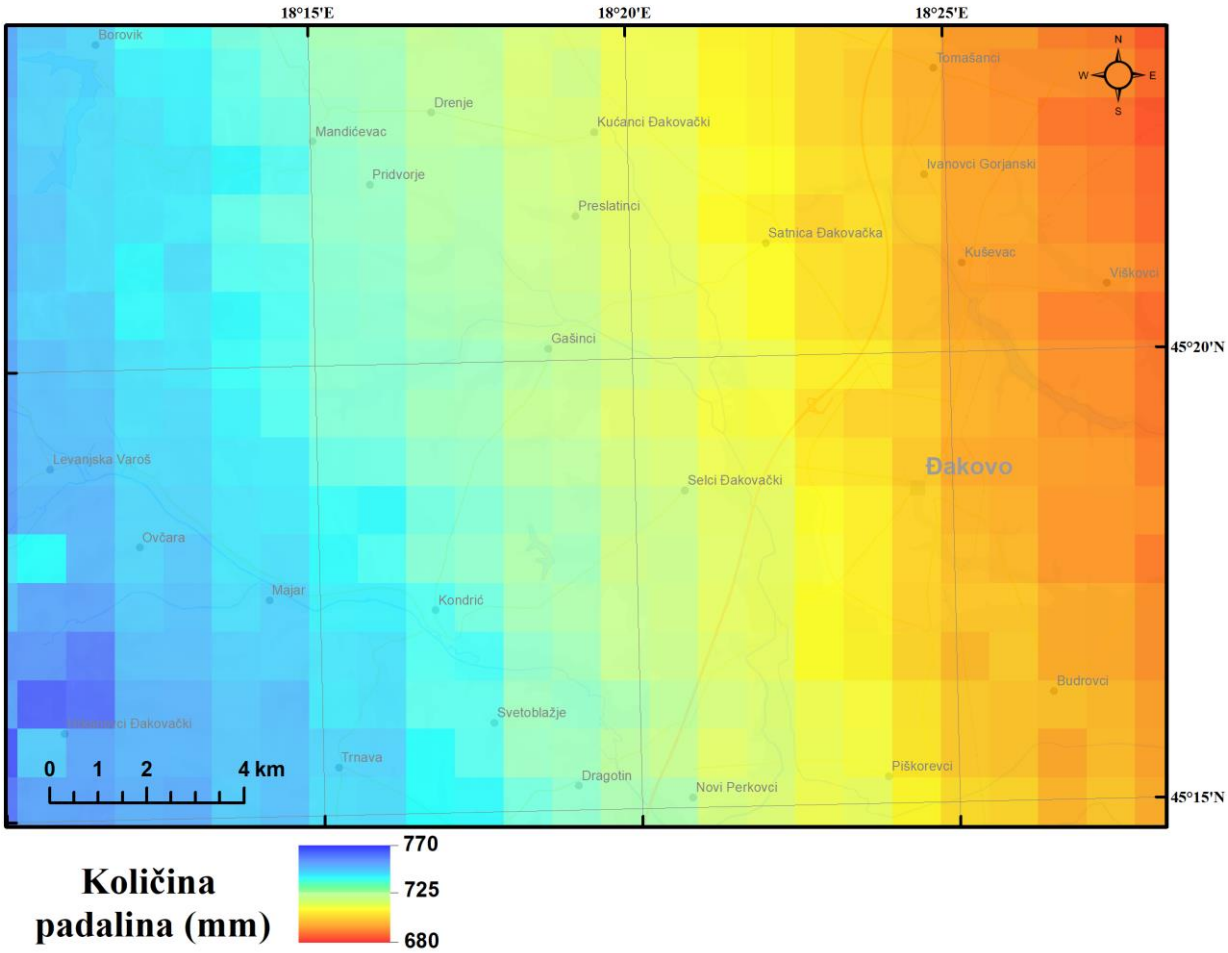

Sl. 9. Prosječne godišnje padaline za klimatsko razdoblje 1960 – 1990

Prema podacima: Zaninović i dr. (2008)

Padaline odlikuje izraziti kontinentalni godišnji režim, odnosno više padalina ima u toplijem nego u hladnijem dijelu godine (Sl. 10.). Ističu se ljetni i manji proljetni maksimum padalina. Ovaj prostor prema Thornthwaiteovoj klasifikaciji spada u subhumidnu klimu (Zaninović i dr., 2008), dok prema Köppenovoj klasifikaciji klima prostor se nalazi pod utjecajem umjereno vlažne kontinentalne klime s toplim ljetima (Cfb). Detaljnije prema Köppenovoj klasifikaciji klima prostor je obilježen formulom Cfwbx", budući da se nalazi u nizinskom kontinentalnom dijelu Hrvatske. Prema Zaninović i dr., (2008) uz spomenute temperaturne karakteristike (oznake C i b), tijekom godine nema izrazito suhih mjeseci, a mjesec s najmanje padalina u hladnom je dijelu godine (fw). U godišnjem hodu padalina ističu se dva maksimuma (x").

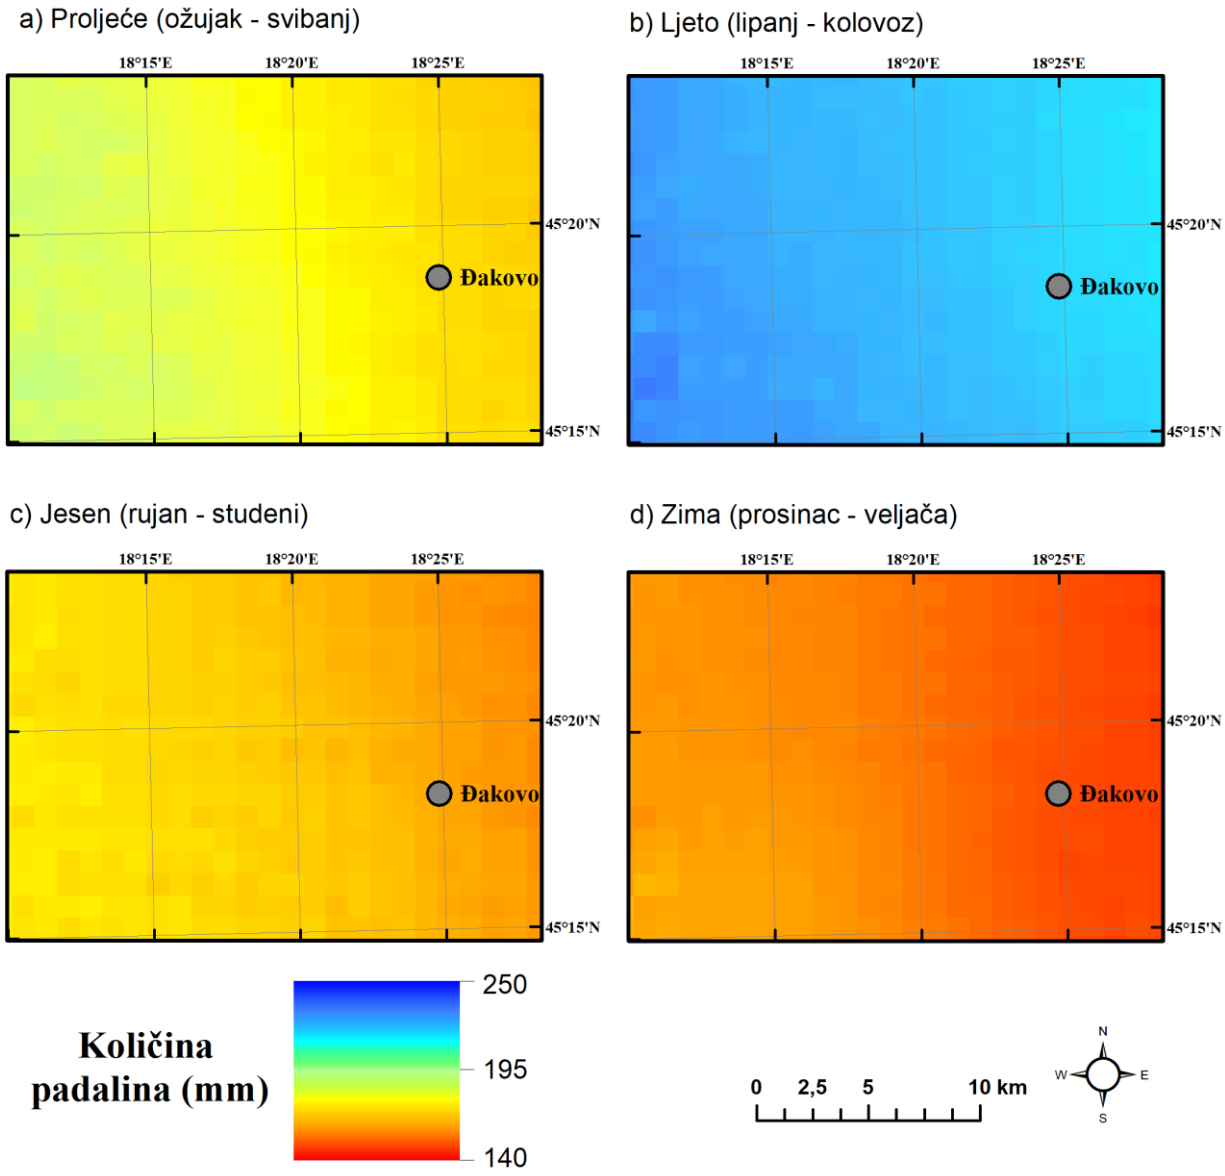

Sl. 10. Prosječne padaline prema godišnjim dobima za klimatsko razdoblje 1960 – 1990

Prema podacima: Zaninović i dr. (2008)

1.4. Cilj i hipoteze istraživanja

Cilj ovog rada je prostornom analizom i kvantitativnim vrednovanjem fizičko-geografskih čimbenika uspostaviti GIS model TPV za kontaktni prostor Đakovačke lesne zaravni i pobrđa Dilj gore. To će se postići analitičkim pristupom prema svakom pojedinačnom fizičko-geografskom čimbeniku. Pri tome će važnu ulogu imati terenski rad u istraživanom prostoru, laboratorijska obrada preuzetih uzoraka s terena i uredska obrada dostupnih prostornih podataka.

Hipoteze na kojima se temelji ovo istraživanje su:

A Iz stvorenog modela terenske prohodnosti, bit će moguće načiniti karte prohodnosti za više vrsta vozila u više različitih mjerila.

B Prevladavajući čimbenik mobilnosti vozila su sastav i struktura pedološke podloge.

C Postoji prostorna korelacija između podjele tla prema USCS klasifikaciji i USDA klasifikaciji na istraživanom području.

D Postoji prostorna korelacija između podjele tla prema USCS klasifikaciji i litostratigrafskih jedinica na istraživanom području.

E Prohodnost terena podliježe promjenama u skladu sa promjenama meteoroloških uvjeta.

2. Pregled dosadašnjih istraživanja

2.1. Metodološki pristupi istraživanja fizičko-geografskih čimbenika terenske prohodnosti vozila

Važno je istaknuti da su istraživanja i cjelokupan rad temeljeni na dostupnim izvorima i spoznajama istraživača koji su svoje rezultate javno objavili. Naime zbog same prirode zatvorenosti pojedinih društvenih sistema (Rusija, Iran, Kina i dr.) koji svoja vojna dostignuća o modelima prohodnosti ne iznose u javnost, njihovi rezultati nisu dostupni globalnoj znanstvenoj zajednici. Stoga su dosadašnja istraživanja ograničena na saznanja i rezultate znanstvenika koji spadaju u kulturni krug zemalja Zapadnog svijeta.

U nastavku će biti opisane metode definiranja morfometrijskih i tehničkih sposobnosti vozila pri kretanju van cestovne infrastrukture, istraživani čimbenici, načini prikupljanja i strukturiranja podataka, njihovo strukturiranje i modeliranje, te završno - načini interpretacije rezultata. Za uspješno utvrđivanje TPV određenog područja i tipa vozila potrebno je provesti nekoliko radnji:

- prikupiti i analizirati dostupne prostorne podatke,
- klasificirati i kvantificirati geografske faktore o kojima ovisi TPV, temeljene na poznavanju tehničko – operativnih mogućnosti promatranih tipova i vrsta vozila,
- utvrditi međusobne veze i ovisnost pojedinih geografskih parametara,
- sintezom prisutnih geografskih pojava i objekata provesti modeliranje i testiranje TPV na specifičnim tipovima i vrstama vozila,
- grafički i numerički interpretirati TPV,
- evaluirati rezultate.

Svi prisutni čimbenici na zemljištu u nekoj mjeri ograničavaju mobilnost vozila. Svaki tip i model vozila sa svojim tehničkim svojstvima omogućava kretanje vozila. Prilikom utvrđivanja TPV primarni cilj istraživanja je utvrđivanje mjere usporavanja svakog pojedinog čimbenika. Osnovna obilježja vozila koja definiraju njegovu pokretljivost su oblik, veličina, težina, broj osovina i osovinski razmak, broj pokretačkih osovina, snaga motora, način prijenosa brzina, način pokretanja (kotači i/ili gusjenice).

Terenska pokretljivost vozila ovisi o prisutnosti svakoga pojedinog fizičko-geografskog čimbenika na zemljištu, te njihovoj konačnoj međusobnoj interakciji (Birkel, 2003; Earl, 1997; Hofmann i dr., 2015; Pearson i Wright, 1980). Na usporenje vozila svaki od navedenih čimbenika djeluje pojedinačno i u međuovisnosti s ostalim čimbenicima (Sl. 11.) (Heštera i Pahernik, 2018).

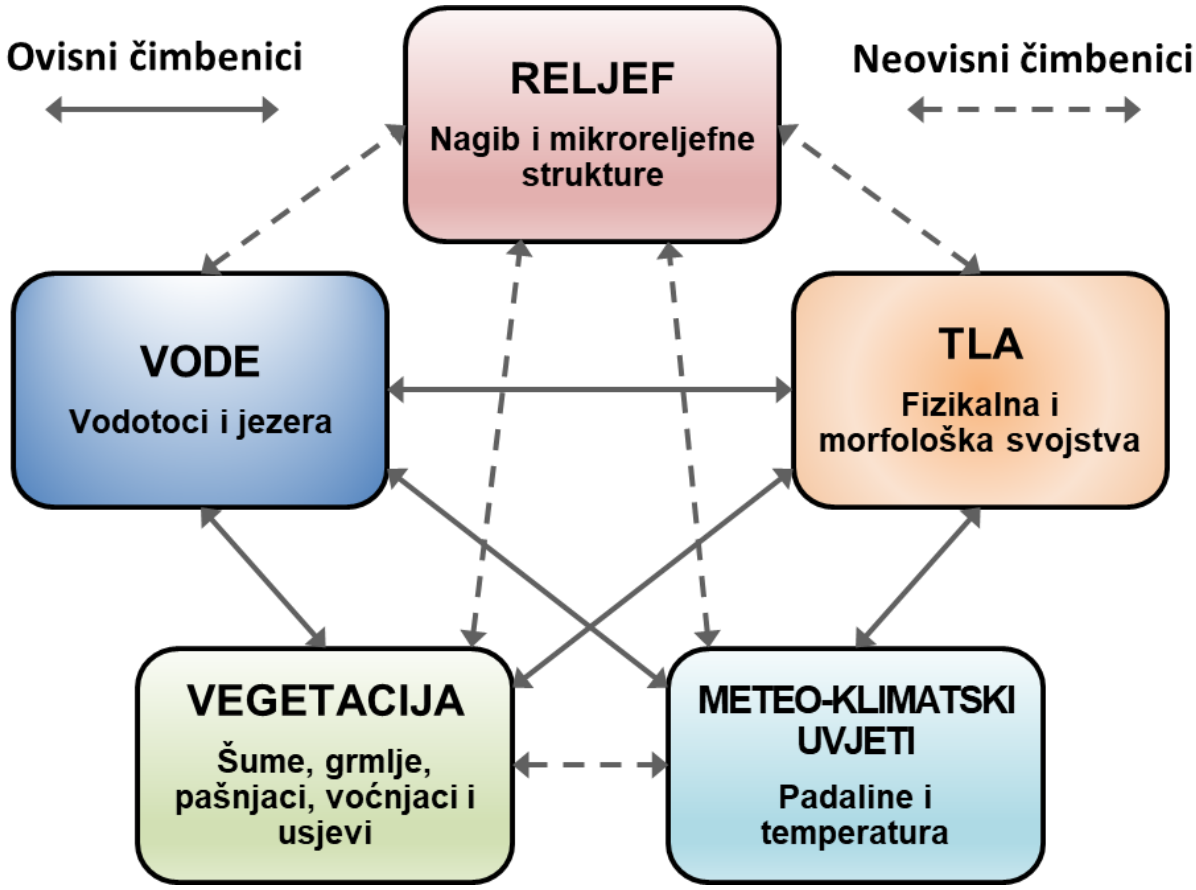

Sl. 11. Međusobni odnosi osnovnih značajki fizičko-geografskih čimbenika TPV

Izvor: Heštera i Pahernik (2018), modificirano prema Rybansky (2009, 17)

Najveći je istraživački izazov utvrđivanje konačnoga stanja prohodnosti zemljišta zbog mnoštva mogućih kombinacija međudjelovanja među čimbenicima. Modeliranje je glavni metodološki pristup, pri čemu prilikom definiranja stanja prohodnosti zemljišta autori uspostavljaju brojne modele koristeći različite metodološke osnove. U Heštera i Pahernik (2018) dosadašnja istraživanja prisutnih fizičko-geografskih elementa koji utječu na TPV podijeljena su u pet osnovnih skupina (Sl. 12.). Svaka od pojedinih skupina u sebi sadržava

čimbenike koji ovisno o prisutnosti i intenzitetu izravno utječu na TPV. Istraživani autori u svojim modelima prilikom modeliranja koriste različite izvore prostornih podataka (više u Poglavlju 2.2) pri čemu kvaliteta i raznovrsnost korištenih izvora podataka doprinosi i točnosti izračuna modela. Prilikom modeliranja koriste se različiti metodološki i matematički pristupi predikcije rezultata (više u Poglavlju 2.3). Heštera i Pahernik (2018) istražili su dvadeset i pet različitih modela koji se razlikuju prema metodološkim pristupima i izvorima podataka, a korišteni parametri unutar pet osnovnih skupina iskazani su postotnim udjelima unutar sveukupnog broja modela obuhvaćenih analizom. Nastavno u sljedećim poglavljima svaka od zasebnih skupina biti će detaljnije analizirana i obrađena.

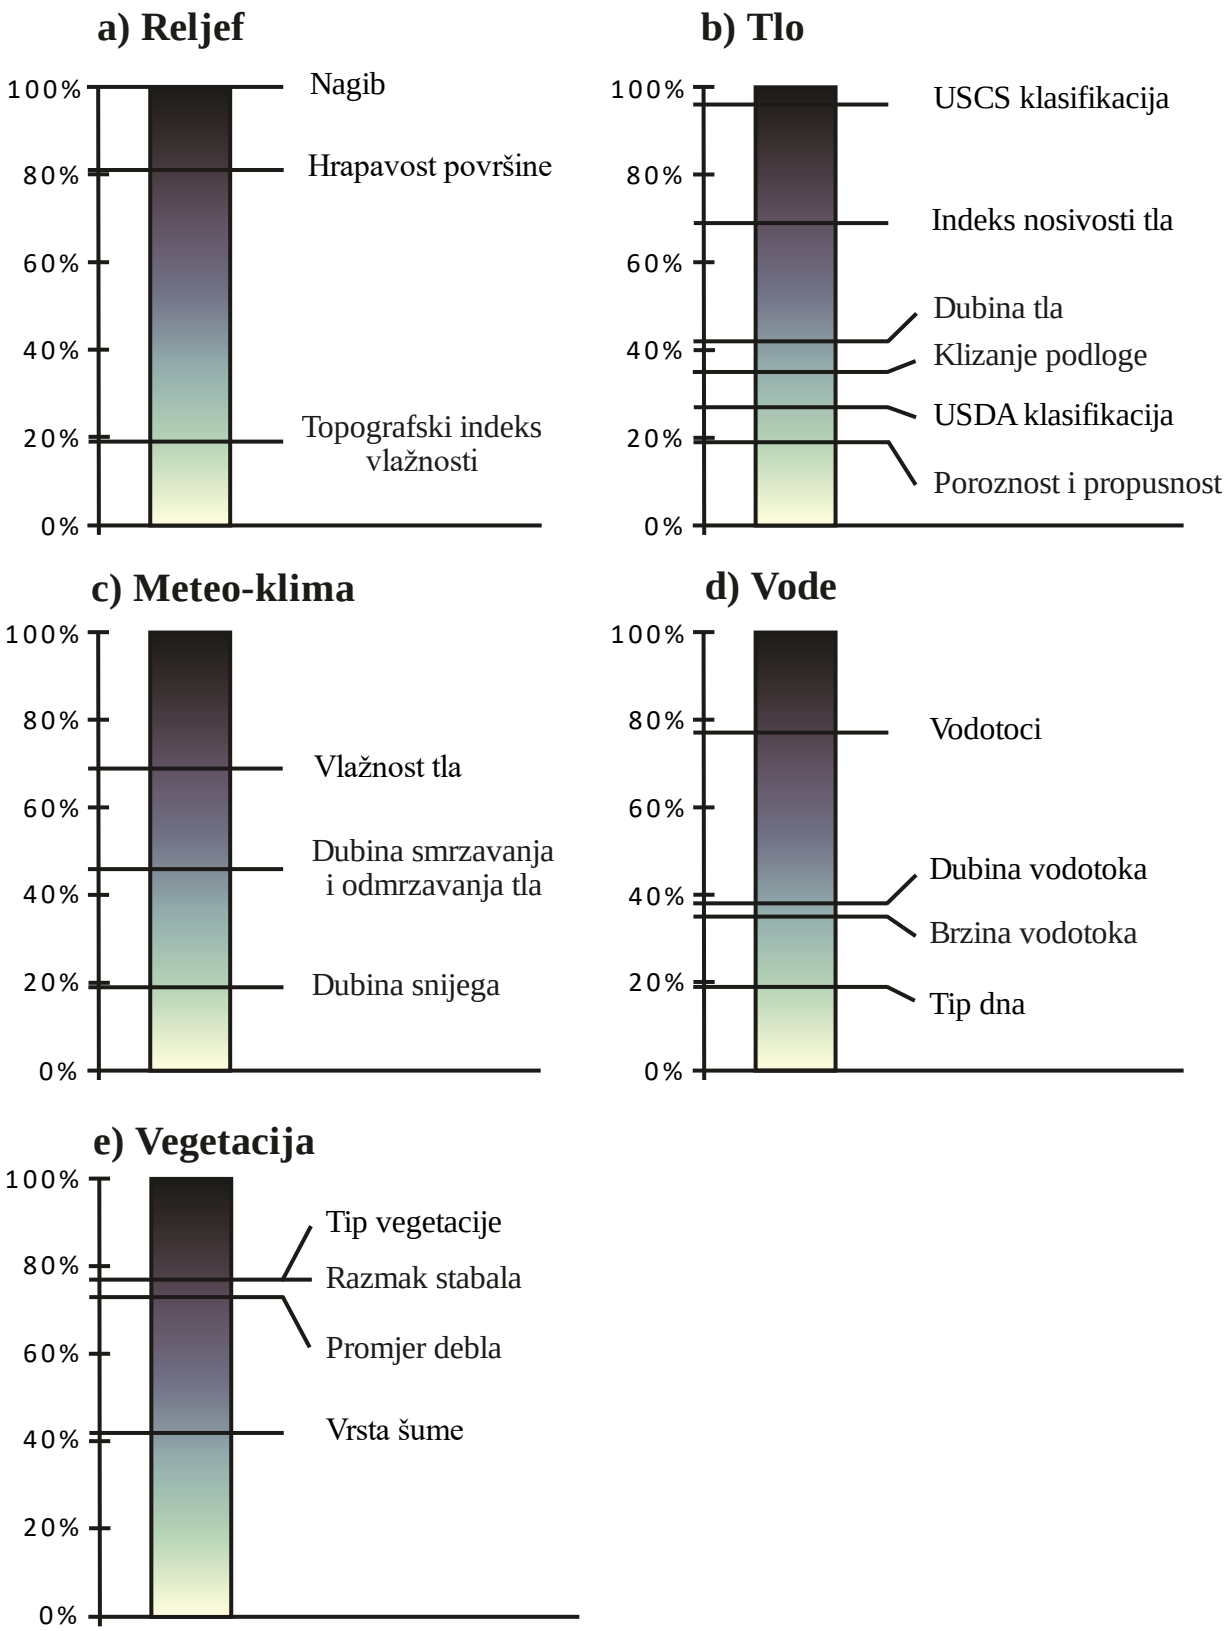

Sl. 12. Postotni udio uključenih faktora u modelima TPV, grupiranih prema čimbenicima: a) Reljef, b) Tlo, c) Meteo-klima, d) Vode, e) Vegetacija

Izvor: Heštera i Pahernik (2018)

2.1.1. Reljef

Struktura mezoreljefnih i mikroreljefnih forma temeljni je determinirajući čimbenik pokretljivosti vozila na terenu. Nagib zemljišta je osnovna forma i morfometrijski čimbenik koji utječe na TPV. Svi modeli koriste nagib terena kao parametar TPV (Sl. 12. a). Mobilnost vozila ograničavaju vertikalni i bočni nagib zemljišta (Saarilahti, 2002). Prohodnost terena ogleda se u sposobnosti vozila da savlada maksimalni vršni nagib, koji ovisi o tehničko-taktičkim obilježjima svakoga pojedinog vozila (Ahlvin i Haley, 1992; Pahernik i dr., 2006; Pearson i Wright, 1980; *Terrain Analysis*, 1990; Wong, 2001). Nagib zemljišta kao parametar posredno je integriran u hidrografske modele predviđanja vlažnosti tla, stoga nagib determinira topografski indeks vlaženja (TIV) (engl. *Topographic Wetness Index*) te u kombinaciji s ekspozicijom padine utječe i na klimatske elemente. Mikroreljefne forme na površini svojim devijacijama definiraju stupanj pokretljivosti vozila i prohodnost terena (vidi Sl. 13.) (Baylot i dr., 2005; Mintzer i Messmore, 1984; Pahernik i dr., 2006; Weiss, 1981).

Naziv	Oblik objekta	Evaluacijski parametri
Nasip	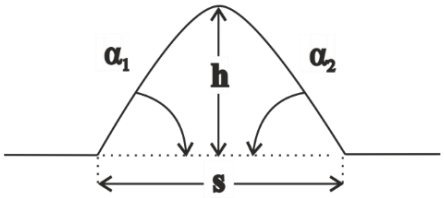	- nagib (α_1, α_2) - visina nasipa (h) - širina nasipa (s)
Kanal, iskop	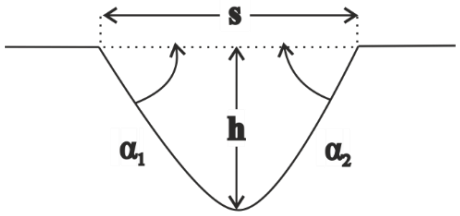	- nagib (α_1, α_2) - dubina kanala (h) - širina kanala (s)
Usjek (uspon)	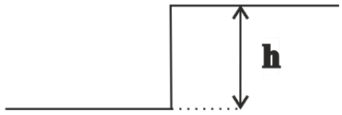	- visina usjeka (h)
Usjek (silazak)	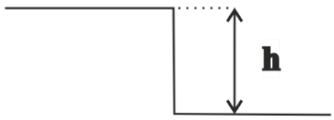	- visina usjeka (h)
Rov (prijelaz)	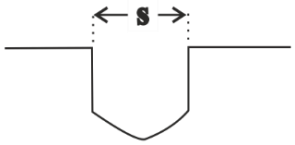	- širina rova (s)

Sl. 13. Evaluacijski parametri osnovnih mikroreljefnih formi

Modificirano prema: Rybansky i dr. (2020)

Mikroreljefne forme i pojave koje utječu na hrapavost površine su kanali, nasipi, vododerine, jaruge, kamenitost površine, stjenovitost površine i klizišta (Heštera i Pahernik, 2018). „Zajedničko obilježje mikroreljefnih formi i pojava je da ne utječu na vozilo u cjelini, već na svaki kotač ili gusjenicu posebno" (Saarilahti, 2002, 44), odnosno na dinamiku vožnje (Becker i Els, 2014; Birkel, 2003). Hrapavost površine izražava se pomoću kvadratne sredine razlika visine površine (engl. *root-mean square*) profiliranjem terena (Dawkins, 2011; Jurkat i dr., 1975).

2.1.2. Tlo

Najviše dosadašnjih istraživanja mobilnosti vozila i TPV usmjereno je prema definiranju geotehničkih svojstava tla. Tlo predstavlja najdinamičniju komponentu prostora, ako ga promatramo s aspekta mobilnosti i prohodnosti za bilo koju vrstu vozila. Čimbenici koji utječu na pokretljivost vozila su posmična čvrstoća tla, nosivost, klizanje i ljepljivost tla, te vučna sila vozila (*Military Geographic Intelligence*, 1972). Proučavanje mehanike tla s ciljem utvrđivanja mobilnosti vozila (engl. *Terramechanics*) je područje mehanike tla koje se bavi mehaničkim gibanjem strojeva (kotača i gusjenica) po tlu, odnosno interakcijom između tla i vozila (Wong, 2001). Ovo relativno novo polje istraživanja zasnovano je na znanstvenim spoznajama Terzaghija, (1943), a počelo se razvijati krajem pedesetih godina 20. stoljeća kada je započeto istraživanje upotrebe strojeva popraćeno opsežnim kvantitativnim mjerenjima tla (Drescher i Hambleton, 2010). Kao posebno polje inženjerstva *Terramehanika* prepoznato je od strane široke znanstvene zajednice početkom 1964. godine izdavanjem časopisa „*Journal of Terramechanics*".

U začecima istraživanja prohodnosti tla upotrebljavani su tzv. „*black box*" empirijski modeli koji su jednostavni u primjeni. Ovi opisni modeli su ograničeni na upotrebu iste ili vrlo slične vrste vozila i tipove tla. Pomoću njih nije moguće dovesti u vezu niz promjenjivih parametar kod vozila i raznih vrsta tala. Za točnije definiranje mobilnosti vozila i prohodnosti tla razvijene su sofisticiranije skupine metode modeliranja odnosa kotač-tlo (Sl. 14.). „Prilikom modeliranja mobilnosti vozila postoje tri metodološka okvira u mehanici tla:

- WES – metoda, zasnovana na poluemprijskom modeliranju performansi kotača i mjerenju otpora tla penetracijskim pokusom,
- Bekker-ova metoda, zasnovana na teoriji elastičnosti tla i mjerenjima bevametrom,
- matematička metoda, zasnovana na teoriji plastičnosti tla i mehaničkim svojstvima čvrstoće tla." (Saarilahti, 2002, 15).

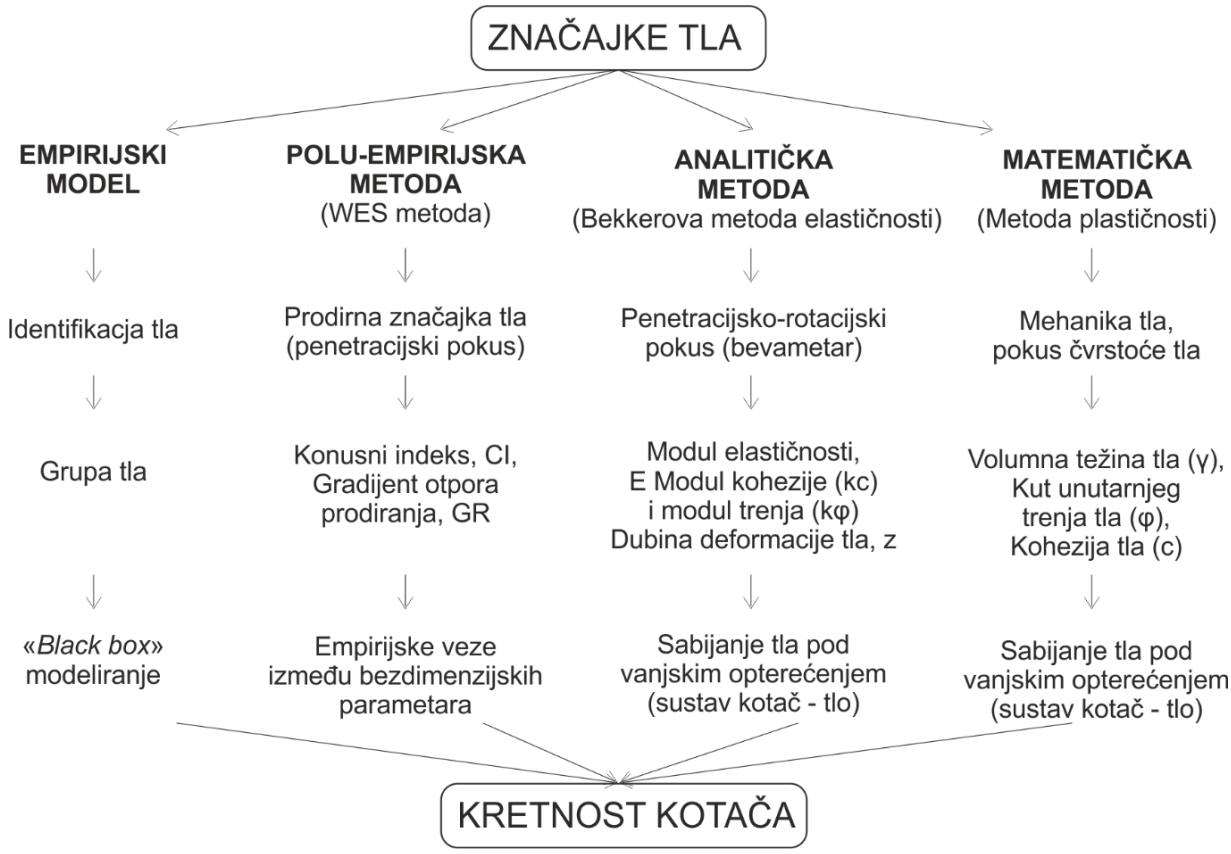

Sl. 14. Shema različitih pristupa problematici mobilnosti vozila u odnosu na tlo

Modificirano prema: Đuka (2014) i Saarilahti (2002)

Primjena WES metode zahtijeva poznavanje granulometrijskog sastava tla i performansi vozila. Nosivost tla i stabilnost tla su u izravnoj ovisnosti s čvrstoćom tla. Pomoću konusnog penetrometra (Sl. 15. a) se mjeri čvrstoća tla i iskazuje putem konusnog indeksa (KI). Mjerenja se vrše uz pomoć kompleta za mjerenje (Sl. 15.) prohodnosti tla. Penetrometar se utiskuje u tlo, a pokazivač/kazaljka prikazuje silu (MPa) koja je upotrijebljena prilikom prodiranja konusa u tlo. Zbog toga što čvrstoća sitnozrnatih tala varira prilikom opterećenja i uslijed poremećenosti prirodnog stanja tla, potrebno je provesti mjerenja i u poremećenom tlu. Konačni indeks nosivosti tla (INT) za prohodnost vozila je produkt KI i remoduliranog indeksa (RI), odnosno korigirane vrijednosti nakon mjerenja u poremećenom tlu (Jednadžba 1.) (FM 5-430-00-1, 1994).

$$\boldsymbol{INT = KI \; x \; RI}$$ **Jednadžba 1**

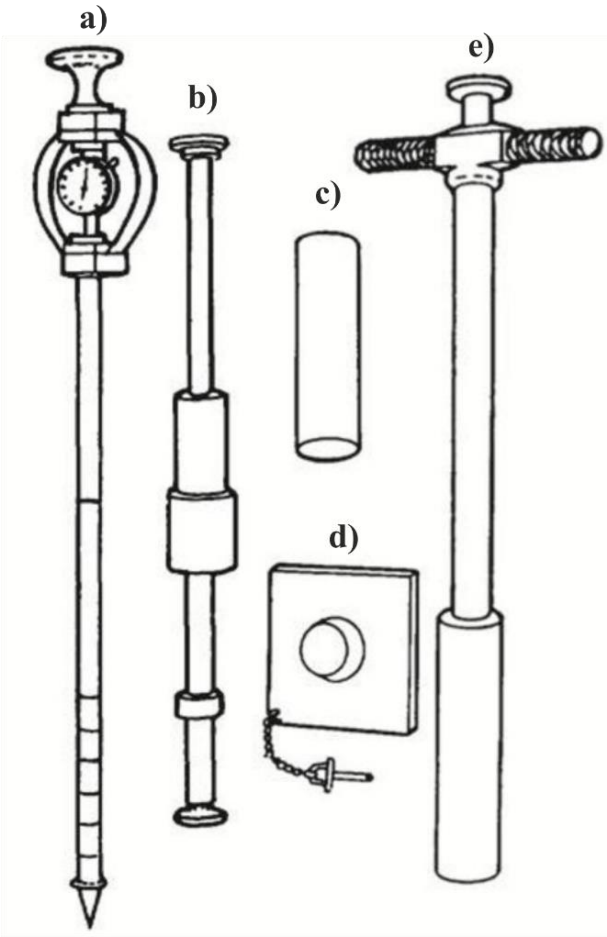

Sl. 15. Komplet za ispitivanje prohodnosti tla. Dijelovi kompleta: a) Konusni penetrometar, b) Čekić za zbijanje tla, c) Cilindar, d) Baza, e) Uzorkivač tla

Modificirano prema: Mason i dr. (2015)

Oba indeksa prohodnosti tla se računaju uz pomoć alata u sklopu kompleta za ispitivanje prohodnosti tla. Vrijednost KI dobiva se mjerenjem otpora tla koje je neporemećeno u svojem prirodnom okruženju (*in situ*), a postupci prilikom mjerenja su definirani ASAE[6] normama. Drugi indeks, RI predstavlja rezultat mjerenja otpora konusa prilikom utiskivanja u poremećeno tlo. U svrhu simuliranja stanja tla prilikom prelaska više vozila (kolone) preko tla potrebno je prvo uzeti uzorak tla uzorkivačem (Sl. 15. e). Uzorak tla se ubacuje u cilindar (Sl. 15. c) koji se pričvršćuje na metalnu bazu (Sl. 15. d). Postupak se nastavlja provedbom 50 udaraca čekićem (Sl. 15. b) mase 1.13 kg (2.5 lb) ispuštanog s visine od 30 cm (12 inča). Broj udaraca predstavlja

[6] ASAE – American Society of Agricultural Engineers

ukupan broj vozila unutar kolone. Postupak izračuna RI završava utiskivanjem konusnog penetrometra u poremećeno tlo (FM 5-430-00-1, 1994; Mason i dr., 2015).

Pokretljivost vozila opisuje se Konusnim indeksom vozila (KIV) (engl. *Vehicle Cone Index*). Radi što vjernije interpretacije stvarnih vojnih situacija na terenu se koriste dva KIV, odnosno za jedan prolazak vozila (KIV_1) i/ili 50 prolazaka (KIV_{50}). Informacija koju pruža KIV_{50} prvenstveno se odnosi na mogućnost višestrukog (50) prolaska po istom tragu, što isto tako simulira kretanje više vozila u koloni. Budući da se tla u mehanici tla dijele na sitnozrnata, krupnozrnata i močvarna tla (treset), za svaku pojedinu grupu tala postoje i zasebne polu-empirijski izvedene formule. Treba napomenuti da ova metoda nije primjenjiva za krupno zrnata tla, pri čemu se izračuni mogu koristiti jedino u svrhu komparacije. Metoda konusnoga indeksa najviše je u upotrebi zbog svoje praktičnost u primjeni na samom terenu, jer korisnik može izravno provjeriti prohodnost tla uz pomoć praktičnoga ručnog alata (konusni penetrometar), te nisu potrebni neki ostali parametri (Heštera i Pahernik, 2018).

Analitička metoda razvijena od strane Bekkera (1962) poznatija je pod nazivom „bevametar metoda“. Uređaj – bevametar (Sl. 16.) penetracijsko-rotacijskim pokusom provodi dvije grupe pokusa.

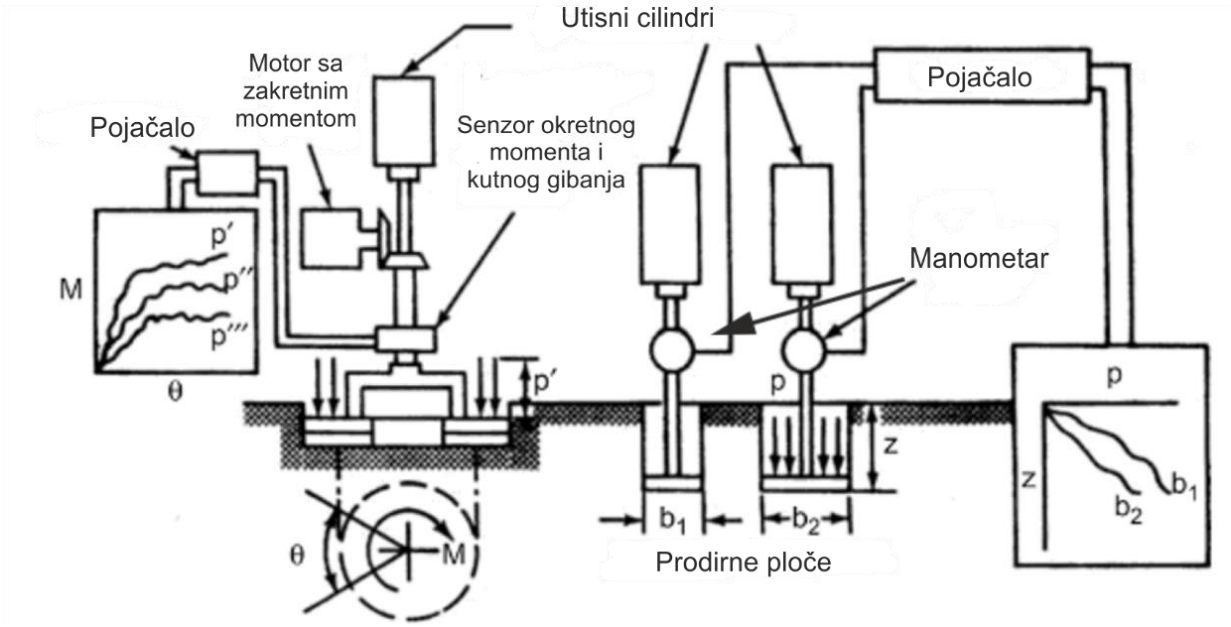

Sl. 16. Shematski prikaz bevametra

U prvom pokusu koriste se ploče čija veličina treba odgovarati površini nalijeganja kotača ili gusjenice. Uređaj utiskivanjem ploča u tlo simulira pritisak kotača ili gusjenice na tlo, te manometrom mjeri distribuciju pritiska i ukupnu dubinu ulijeganja tla. Drugim pokusom mjeri se smicanje tla rotirajućom prstenastom pločom čiji pokret simulira okretanje kotača ili gusjenice pri vožnji. Mjerenjem se utvrđuje odnos pokreta vozila i tla, odnos koliku vučnu silu i klizanje tlo može podnijeti prilikom prolaska vozila (Bekker, 1962; Shoop, 1993; Wong, 2001). Za izračun prohodnosti potrebno je izračunati kut trenja tla (φ), koheziju tla (c), kohezijski modul deformacije tla (kc), modul trenja deformacije tla ($k\varphi$) i dubinu deformacije tla (z). Detaljan opis metode i načina izračuna nalazi se u Bekker (1962), Senatore (2010), Shoop (1993) i Wong (2001). Uređaj može mjeriti fizikalna svojstva tla u laboratoriju ili može montiran na vozilo mjeriti prohodnost tla na terenu (Sl. 17.).

Sl. 17. Terensko mjerenje bevametrom montiranim na buldožer

Izvor: *Next Generation NATO Reference Mobility Model* (22.10.2020.)

Matematička metoda zasnovana je na Metodi konačnih elemenata (engl. *finite element method* (FEM)), ujedno je najkompleksnija od svih navedenih metoda pomoću kojih se želi modelirati sustav odnosa kotač-tlo. Ova numerička metoda pruža mogućnost pouzdane i precizne teorijske analize u trodimenzionalnom okruženju u kojem se zbivaju deformacije prilikom kotrljanja kotača uslijed prelaska preko tla. Između mnoštva modela koji opisuju prirodu plastičnosti tla ova metoda koristi model idealne elasto- plastičnosti. Za provedbu ove metode potrebno je poznavanje pet parametara: Youngov modul elastičnosti i Poissonov koeficijent, kohezija, kut trenja i kut dilatancije (Drescher i Hambleton, 2010). U svrhu istraživanja prohodnosti tla za vozila ovu metodu u svojim radovima koriste Chiroux, i dr., (2005), Schmid (1995), Shoop i dr. (2006) i Wong (1991).

Sve navedene metode izračuna prohodnosti tla koriste informacije o geotehničkim svojstvima tla koja su strukturirana i definirana pomoću Jedinstvene klasifikacije tla (USCS[7]), (Sl. 12. b). USCS (detaljan opis načina klasifikacije tla u Prilog 1.) sadržava u sebi opise mehaničkih svojstava svih tipova tala koja su opisana u normi ASTM D2487, a zasnovana je na granulometrijskom sastavu tla i Atterbergovim granicama. Geotehnička obilježja koja utječu na pokretljivost vozila, a mogu se korelirati s USCS su posmična čvrstoća tla, nosivost i vučne sile, klizanje i ljepljivost tla (*Military Geographic Intelligence*, 1972). Kod upotrebe ovih metoda koristi se USCS klasifikacija, jer sadržava opise fizikalnih svojstava svih grupa tala. U svrhe kartiranja mobilnosti vozila WES metodom, za svaku od sveukupno 16 grupa tala USCS klasifikacije, koriste se INT. INT utvrđeni su empirijskim i laboratorijskim istraživanjima od strane NATO zemalja članica. Ključni faktor terenske mobilnosti vozila je nosivost tla, koja utječe na performanse vozila u terenskim uvjetima, što je bitno prilikom izgradnje prometnica, u poljoprivredi, rudarstvu, šumarstvu i vojnim operacijama. USCS klasifikacija također koristi distribuciji veličine čestica prilikom klasifikacije, ali također koristi i Atterbegove granice plastičnosti za definiranje prahova i glina. Atterbergove granice vrlo dobro opisuju ponašanje tla prilikom promjene vlažnosti tla, što je iznimno važno, jer se promjene stanja plastičnosti tla direktno reflektiraju na mobilnost vozila. Osnovna problematika istraživanja prohodnosti tla proizlazi iz toga što postoji mnoštvo podataka granulometrijske razdiobe čestica tla, prema

[7] Početni pokušaji klasifikacije tla bili su zasnovani samo na veličini čestica tla, dok je 1911. godine švedski znanstvenik Atterberg prepoznao i definirao i dodatne faktore klasifikacije, tada prvenstveno u poljoprivredne svrhe. Za potrebe projektiranja zračnih luka u SAD tijekom Drugog svjetskog rata Arthur Casagrande razvio je klasifikaciju ACS (engl. *Airfield Classification System*) koja je uključivala granulometrijski sastav i granice konzistencije koherentnog tla (Casagrande, 1948). Modificiranjem ACS klasifikacije nastala je 1952. godine USCS (engl. *Unified Soil Classification System*) klasifikacija tla, koja je sastavni dio američkih normi ASTM D 2487-11.

raznim klasifikacijama i granicama veličine čestica, ali ne postoje izvori podataka za USCS klasifikaciju (Heštera, 2020). Problem upotrebe navedenih metoda koje koriste USCS je što izrada kartografskih podloga zahtijeva laboratorijske analize uzoraka tla s terena. Prilikom izrade karata geotehničkih svojstava tla upotrebljavaju se prethodni geološki i pedološki izvori u svrhu koreliranja i predikcije svojstava tla prema USCS. Najšire dostupni izvor pedoloških podataka je granulometrijska klasifikacija tla prema USDA klasifikaciji koja je temeljna na razdiobi veličine čestica unutar trokuta granulometrijske veličine čestica (vidi Sl. 63.). USDA i ostale granulometrijske klasifikacije unutar sebe ne sadržavaju informacije o graničnim vrijednostima fizikalnih stanja tla koje su opisane indeksima plastičnosti i granicama tečenja kod USCS. Osnovni problem upotrebe USDA klasifikacije je što do sada ne postoe jasno definirani parametri transformacije iz sustava u sustav (García-Gaines i Frankenstein, 2015; Knob, 2010; Kourdian, 2009; Wawer i dr., 2003). Mnoštvo istraživanja i modela je uspostavljeno kako bi se ustvrdila korelacija između USDA i USCS klasifikacijskog sistema (Sl. 18.), što su García-Gaines & Frankenstein (2015) u svom radu objedinjeno prikazali. García-Gaines i Frankenstein (2015) u svom preglednom radu zaključno naglašavaju da treba sa zadrškom uzimati korelacije dvaju klasifikacijskih sistema, odnosno da su za potpunu točnost kartiranja prema USCS klasifikaciji potrebni laboratorijski pokusi (Heštera, 2020). Prema tome, mnoga dosadašnja istraživanja usmjerena su ka koreliranju i modeliranju s ciljem predikcije i definiranja grupa tala prema USCS klasifikaciji (Frankenstein, 2008; Gambill, i dr., 2016). Prilikom koreliranja i modeliranja predikcije USCS grupe tla uz granulometrijski sastav koriste se svi dostupni podatci vezani uz svojstva tla, kao što su: sadržaj organske tvari, propusnost, gustoća tla, vodni kapacitet, i dr. (Gambill i dr., 2016).

Dubina tla determinira mogućnost prolaska vozila određenim područjem. Ukoliko je dubina tla manja od klirensa vozila, za vozilo nema zapreke prolaska, s obzirom da čvrsta podloga (stijena) omogućava direktan kontakt s kotačem ili gusjenicom. Kao izvor informacija o dubini tla koriste se pedološke i geološke karte.

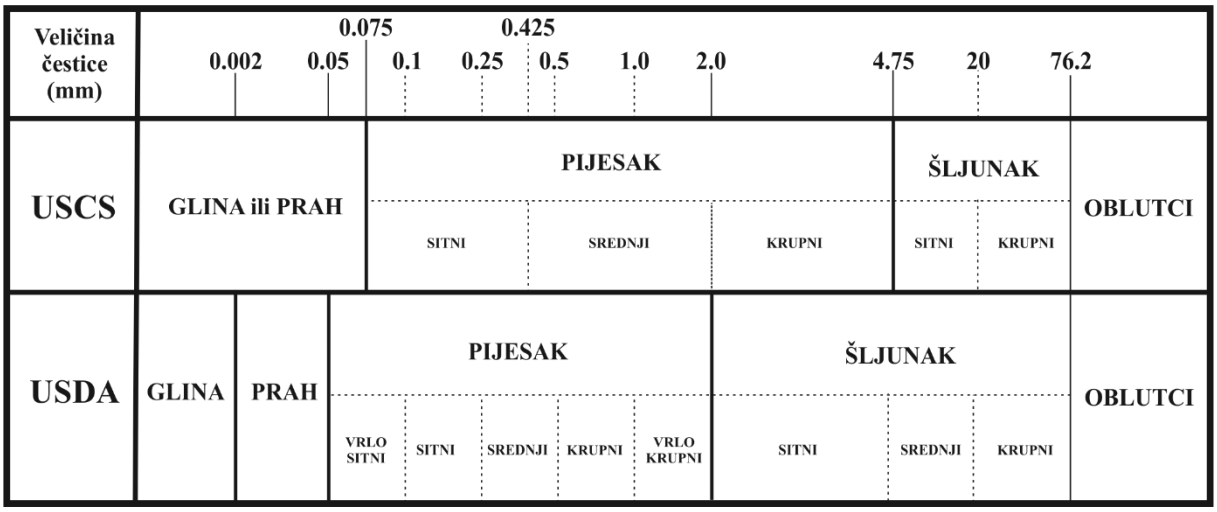

Sl. 18. Usporedba graničnih vrijednosti veličina čestica USCS i USDA klasifikacijskih sustava

2.1.3. Meteo-klimatski uvjeti

Meteorološki uvjeti predstavljaju dinamičku komponentu čimbenika. Padaline – kiša i snijeg u interakciji s tlom imaju izravan utjecaj na mobilnost vozila. Vlažnost tla (Sl. 12. c) je temeljna odrednica pri utvrđivanju prohodnosti tla (Wawer i dr., 2003). Nosivost i čvrstoća sitnozrnatih tala u izravnoj je korelaciji s tipom tla i udjelom vlažnosti. Porastom vlažnosti tla kod sitnozrnatih tala opada nosivost tla, čime se ujedno smanjuje mobilnost vozila. Vlažnost tla izravno utječe na sposobnost tla da podnese težinu i pokret vozila, jer vlažnost definira stanje tla (Heštera i Pahernik, 2018).

U kontekstu mobilnosti vozila u prostoru pokrivenom snježnim pokrivačem empirijskim istraživanjima (Wong, 2009) dokazano je da prohodnost vozila ovisi o klirensu vozila i dubini snijega. Nepokretljivost vozila dolazi pri niskom klirensu kada duboki snijeg onemogućava izravan kontakt s podlogom, a istovremeno dolazi do izravnog doticaja snježne površine s podvozjem. U područjima pokrivenim dubokim snijegom u pravilu se koriste vozila pokretana gusjenicama. Prilikom terenskih istraživanja duboki snijeg se definira kao sitnozrnato tlo, odnosno njegova nosivost se mjeri konusnim penetrometrom (*Production of Cross-Country*, 1959; Suvinen, 2006; Vega-Nieva i dr., 2009). Posebna pozornost usmjerena je procesu

topljenja i ponovnog zamrzavanja snijega s ciljem definiranja vlažnosti tla i otjecanja vode (Frankenstein i Koenig, 2004b; NCAR, 2007).

Na TPV temperatura zraka može utjecati pozitivno i negativno. Dugotrajne niske temperature ispod 0°C mogu do tada neprohodnu vodenu površinu (rijeku ili jezero) zamrznuti, te područje učiniti prohodnim. Za utvrđivanje prohodnosti potrebno je znati do kojih dubina tla je stvoren led. Negativan utjecaj na TPV događa se pri obrnutim procesima od prethodno navedenih, kada prilikom dugotrajnih temperatura iznad 0°C dolazi do topljenja snijega ili leda, odnosno vlaženja tla. Općenito - pozitivne temperature doprinose isparavanju tla, pri čemu dolazi do gubitka vlažnosti tla, a samim time i povećanju njegove nosivosti i čvrstoće.

Modeli prohodnosti vozila sadržavaju informacije o meteorološkim pojavama nakon modeliranja stanja vlažnosti tla putem strukturiranih podataka meteoroloških prognoza (Frankenstein, 2008; Frankenstein i Koenig, 2004a, 2004b; Smith i Meyer, 1973). Meteorološke prognoze koriste se za kratkoročna (do 72 sata unaprijed) predviđanja TPV zbog nemogućnosti točnoga predviđanja vremena za dulja razdoblja (Heštera i Pahernik, 2018).

Važnost klimatskih elemenata je indirektna te oni posredno utječu na ostale čimbenike prohodnosti terena jer o njima ovisi prosječan broj snježnih dana u godini, prosječna količina padalina, a niske prosječne temperature uvjetuju trajno smrznuto tlo (permafrost) (Heštera i Pahernik, 2018). Podaci o klimatskim elementima, u vidu mjesečnih i godišnjih statističkih podataka, uglavnom su integrirani u kartografske proizvode krupnijih mjerila (Sl. 19.) i u izravnoj su vezi s tipom tla (Hintze, 1991).

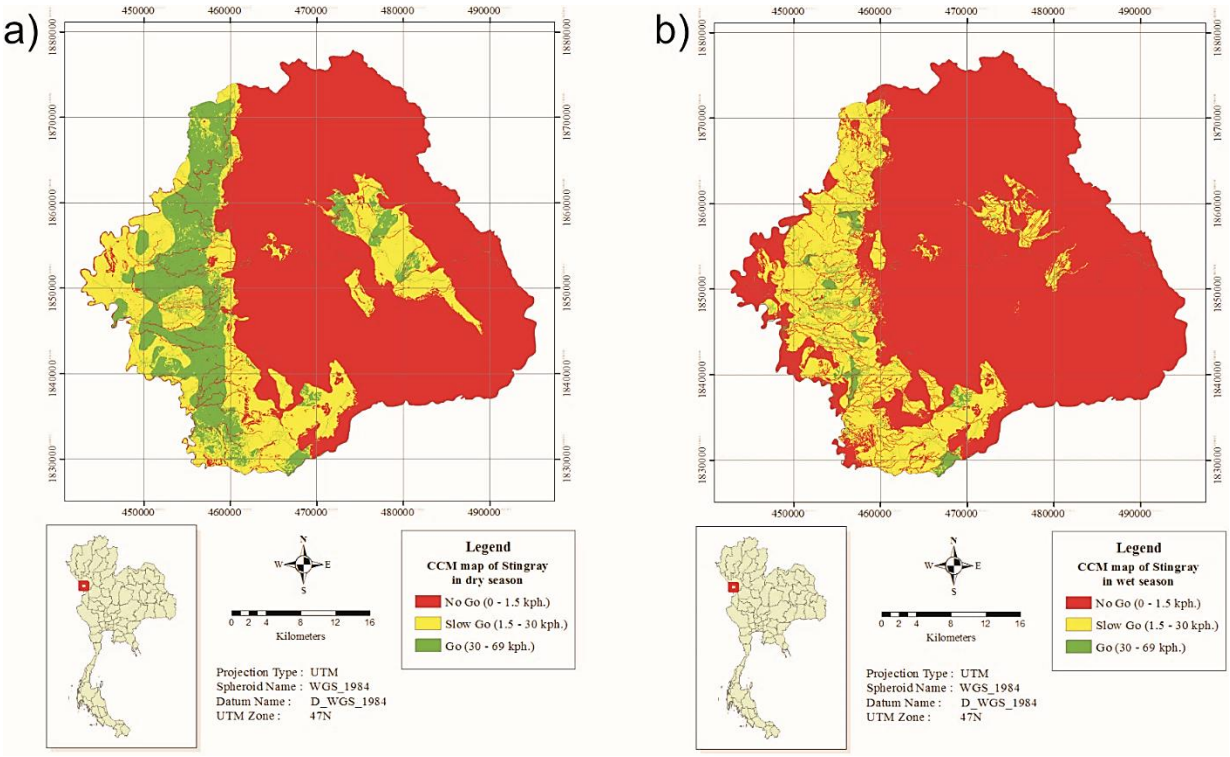

Sl. 19. Primjer karte terenske mobilnosti tenka (Stingray) u: a) sušnom periodu i b) kišnom periodu

Izvor: Pimpa (2012, 118-119)

2.1.4. Hidrografija

Rijeke, potoci i kanali predstavljaju linijske hidrografske objekte koji u većini slučajeva čine izdužene linijske prepreke slobodnom pokretu vozila na zemljištu. Istraživanje vodenih objekata (Sl. 12. d) sadržava prikupljanje i strukturiranje podataka o morfološkim obilježjima obale (uključujući jezera i mora) koja čine: širinu vodotoka, nagib i visinu obala. Za vodotoke čija dubina omogućava prijelaz rijeke prikupljaju se podaci o sastavnom materijalu koji tvori dno korita tekućice. Za uspješnu upotrebu amfibijskih vozila prikupljaju se podaci o brzini i dubini vodotoka. (Messmore, 1982).

2.1.5. Vegetacija

Vegetacija ili biljni pokrov zemljišta svojom prisutnošću usporava pokret vozila, dok šumska vegetacija može i u potpunosti onemogućiti pokret svih vrsta vozila. Osnovni fokus istraživanja šumskoga pokrova obuhvaća atribute vezane uz promjer stabala na prsnoj visini (1.35 m) i njihov međusobni razmak (Leighty, 1965; Messmore i dr., 1981) (Sl. 12. d). Prilikom modeliranja TPV prvotno se razmatra mogućnost manevriranja između stabala, a uslijed prevelike gustoće stabala mogućnost njihova rušenja vozilom (Ahlvin i Haley, 1992; Haley i dr., 1979b; Mason i dr., 2012; Pearson i Wright, 1980; *Terrain Analysis*, 1990). Hubacek i dr. (2015) istraživali su i utjecaj korijenskoga sustava različitih vrsta drveća na mogućnost rušenja stabala (Heštera i Pahernik, 2018).

Treba naglasiti da tijekom vegetacijskog razdoblja biljni pokrov svojom prisutnošću i vizualno ograničava nesmetano kretanje zemljištem. Za razliku od crnogoričnih šuma u listopadnim šumama tijekom zimskog perioda postoje bolji uvjeti vidljivosti što doprinosi boljoj preglednosti i kvalitetnijem donošenju odluka vozača.

2.2. Izvori i točnost podataka

Prema Heštera i Pahernik (2018) u svrhu predviđanja TPV koriste se brojni i različiti prostorni izvori podataka i informacija. Tijekom kreiranja karte prohodnosti vozila potrebno je razmotriti i sistematizirati sve prisutne čimbenike na prostoru planiranih aktivnosti. Izradi karte prohodnosti prethodilo je ručno preklapanje prethodno načinjenih prozirnica koje su svaka zasebno na sebi sadržavale tematsku cjelinu čimbenika prohodnosti vozila. Prije pojave GIS računalnih sustava ovaj sveobuhvatni analitički proces zahtijevao je visoku kvalificiranost analitičara i iskustvo iz područja kartografije, topografije i geodezije (analiza aerofotogrametrijskih i satelitskih snimaka). Interpretacija rezultata zahtijevala je multidisciplinarni tim stručnjaka sa znanjima iz područja geodezije, topografije, geologije, hidrologije, mehanike tla, šumarstva i ekologije (Leighty, 1965; *Production of Cross-Country*, 1959). Prije pojave računalnih sustava osnovni ulazni podaci bile su analogne topografske karte, geološke karte, pedološke karte te aerofotogrametrijske snimke. Razvoj računalnih sustava

1970-ih godina zamjenjuje ručni proces te se razvija novi pristup u kojem je cjelokupni proces integriran u matematički model koji se izvršava na programskim kalkulatorima, gdje je korišten HP-97 i njemu slični (Pearson i Wright, 1980). Današnji GIS sustavi i alati omogućavaju manji utrošak vremena potrebnog za provedbu analiza na način da ubrzavaju proces pripreme, obrade, analize, vizualizacije i distribucije velike količine podataka koji slijedno tomu doprinose većoj pouzdanosti i produktivnosti cjelokupnoga procesa (Pimpa, 2012). Stoga je potrebno istraživanje TPV promatrati i iz aspekta kvalitete ulaznih prostornih podataka. Do pojave računalnih sustava i digitalizacije prostornih podataka upotrebljavani analogni izvori podataka nisu bili posve točni i detaljni s obzirom na to da su se koristile karte mjerila manjega od 1:50 000 te aerofotogrametrijske snimke mjerila manjega od 1:40 000. Kao ulazni prostorni podaci koristile su se karte velikoga mjerila (1 : 50 000 i manjeg), stoga je i preciznost i točnost podataka bila veoma niska. Podaci o reljefu bili su iznimno niske točnosti jer su informacije o nagibu terena derivirane interpolacijom intervala susjednih izohipsa, a cjelokupni proces rađen je ručno, što je dodatno povećavalo mogućnost pogreške pri interpretaciji. Velik napredak u istraživanju utjecaja nagiba terena nastaje razvojem GIS-a zbog pojave mnoštva izvora prostornih podataka uz pomoć kojih je moguće stvoriti vrlo točne i precizne digitalne modele reljefa (DMR). Trenutno se autori koriste svim dostupnim izvorima podataka, koji služe kao primarni izvori prostornih podataka za strukturiranje i kreiranje prostorne baze podataka za daljnje analize i kreiranje informacija o prohodnosti vozila na željenom području. Metodologijom istraživanja u kojoj su primijenjeni opće dostupni *open source* podaci koristio se Kourdian (2009). Proveo je sintezu multispektralnih podataka dobivenih radarom sa sintetičkom antenom (TerraSAR-X) i *open source* podataka, gdje je uz pomoć daljinskih istraživanja i GIS-a čimbenike strukturirao u slojeve prohodnosti vozila. Identičan pristup u kojem su istraživanje terenske prohodnosti proveli isključivo uz pomoć daljinskih istraživanja prikazali su i Bacon i dr. (2008), Kruse i dr., (2000) i Sadiya i dr., (2017). Korištenjem satelitskih snimaka visoke rezolucije i LIDAR (engl. *Light Detection and Ranging*) snimaka u istraživanjima Campbell (2012), Dawkins (2011), Gustafsson i Hägerstrand (2005), Kirkland (1981), Kristalova (2015), Mohamad Rabab (2002), Mohtashami i dr., (2012), Rybansky i dr., (2015) implementirali su podatke visoke točnosti i preciznosti, čija je upotreba doprinijela većoj točnosti podataka DMR-a i vegetacijskoga pokrova zemljišta (Andersen i dr., 2003). Potrebno je naglasiti da se daljinskim istraživanjima ne može postići detaljnost i potpuna pouzdanost podataka (Leighty, 1965; Kruse i dr. 2000; Wawer i dr., 2003), dok podatke o vegetaciji i pedološkim svojstvima tla nije moguće prikupiti bez izravne provjere na samom terenu (Laskey i dr., 2010). Rezultate daljinskih istraživanja ostali autori koriste većinom kao sekundarne

izvore podataka, pri čemu oni doprinose vjerodostojnosti izvornih podataka koji su dobiveni laboratorijskim analizama ili mjerenjima na terenu. Prisutnost detaljnih prostornih podataka nekoga područja ovisi ponajprije o svjetskim organizacijama i državnim institucijama koje su ujedno najčešći naručitelji i vlasnici geoprostornih podataka za konkretno područje (Heštera i Pahernik, 2018).

S druge strane najviše dostupnih podataka i istraživanja oko procesa nastanka i ostalih fizikalno-kemijskih procesa vezanih uz tlo posjeduju agronomi. Prilikom istraživanja pedoloških svojstava tla koriste se svi dostupni izvori prostornih informacija. Daljinske metode su popularne, jer su jeftinije, one spadaju pristupu znanom kao „Digital soil mapping“, prilikom kojeg se koriste metode kao što su višestruka linearna regresija, neuronske mreže, slučajna šuma (engl. *random forest*), neizrazita logika, kokriging (engl. *cokriging*), regresijski kriging (engl. *regresion kriging*) i dr. (Hengl i Reuter, 2009; Lagacherie, 2007; McBratney i dr., 2003; Zhu i dr., 2001). Zatim postoje metode aerofotointerpretacije (Soil Science Division Staff, 2017), geomorfometrijski pristup (engl. *terrain based*) (McKenzie i Ryan, 1999) i geopedološki pristup kartiranja tla (Zinck i dr., 2016). Jedini točni i čvrsto utemeljeni podaci dolaze jedino iz terenskih istraživanja i laboratorijskih analiza. Za područje Republike Hrvatske OPK trenutno predstavlja jedini relevantni kartografski izvor pedoloških svojstava, sa time da kartiranje cjelokupnog područja nije do kraja provedeno u cijelosti (rukopisne karte i nekoliko nedovršenih listova) (Bogunović i Rapaić, 1993). OPK je nastala aerofotointerpretacijom, terenskim istraživanjem i laboratorijskim analizama, sa zadaćom unaprijeđena poljoprivredne proizvodnje. Kartografske jedinice ove karte definirane su temeljem nekoliko glavnih kriterija: načina vlaženja, evolucijskog stadija tla, tipske građe profila, redoslijeda horizonata, procesa transformacije i migracije mineralnih i organskih tvari, sličnostima u fizikalno-kemijskim obilježjima horizonata, te su zaključno raspoređene u eventualne podtipove, varijete i forme (Husnjak, 2014). S obzirom na njenu sistematičnost i visoku vrijednost podataka OPK predstavlja krucijalan primarni izvor podataka za sva istraživanja pedosfere na području Republike Hrvatske (Heštera i Pahernik, 2018).

Hoškova-Mayerova i dr., (2010), Laskey i dr. (2010) i Kristalova (2015) posebice naglašavaju da je poznavanje kvalitete ulaznih prostornih podataka ključno kako bi se mogla utvrditi vjerojatnost odstupanja rezultata prilikom modeliranja TPV. Naglašavaju da cjelokupni proces kontrole kvalitete podataka treba sistematizirati te da on treba sadržavati procjenu i opis kvalitete kroz metapodatke. Waldock i Corne (2011) istražili su mogućnosti predviđanja TPV na nestrukturiranim *open source* prostornim podacima koristeći se metodom višekriterijske

optimizacije. Horttanainen i Virrantaus (2004) zaključuju da nesigurnost u točnosti podataka treba biti sadržana u cijelom procesu modeliranja te krajnjega korisnika kao donositelja odluka treba upoznati s razinom netočnosti podataka (Heštera i Pahernik, 2018).

2.3. Strukturiranje i modeliranje parametara fizičko-geografskih čimbenika terenske prohodnosti vozila

Modeliranje TPV započelo je 1970-ih i 1980-ih godina u vojsci SAD-a. Svi modeli TPV na različite načine žele prikazati u kojoj mjeri sveukupne pojave na zemljištu usporavaju vozilo u odnosu na maksimalnu predviđenu brzinu kretanja vozila (Ahlvin i Haley, 1992). Heuristički pristup (Waldock i Corne, 2011) modeliranja prohodnosti baziran na dinamičkim matematičkim modelima Army Material Command Mobility Model (AMC) i NATO Reference Mobility Model (NRMM) (Hohmann i dr., 2013) bio je ograničen sa svojim brojnim ulaznim parametrima i mnoštvom matematičkih formulacija, što je otežavalo upotrebu kod krajnjih korisnika. Pojavom i razvojem računalnih tehnologija krajem 1980-ih godina stvorila se mogućnost implementacije matematičkih modela u GIS sustav (Heštera i Pahernik, 2018).

Heštera i Pahernik (2018) navode da računalna tehnologija tada još nije bila na dovoljnoj razini razvoja te i dalje nije omogućavala obradu, izračune i vizualizaciju prostornih podataka na mjerilu većem od lokalne razine (Loomer, 1987). Nasuprot matematički orijentiranim modelima, kao što je NRMM, pojavili su se i modeli sa stohastičkim pristupom (Lessem i dr., 1996). Birkel (2003) preporučuje reviziju modela korištenih u vojne svrhe gdje je analizirao mogući razvojni potencijal Modular Semi-Automated Forces (MoDSAF), Close Combat Tactical Trainer (CCTT), Warfightering Simulation (WARSIM), NRMM I i NRMM II (Hohmann i dr., 2013). Njihova je osnovna namjena osposobljavanje vozača uz pomoć računalnih simulacija kako bi se stvorila što vjernija slika stvarnosti vozačima vozila (Affleck i dr., 2009). Analizu, kvalitetu podataka i modeliranje čimbenika TPV zasnovanu na probabilističkim i statističkim teorijama koristeći se Bayesovim teoremom primijenili su u svom radu Laskey i dr. (2010). Modeliranje uz neizrazitu (engl. *fuzzy*) logiku[8] pri modeliranju i analizi čimbenika TPV primjenjuju Atkinson i dr., (2005), George i dr., (2017), Hofmann i dr., (2013; 2015), Slocum (2003) i Talhofer i dr., (2015) gdje je nadograđena jednostavna Jasna

[8] Koristiti će se prijevod značenja riječi *Fuzzy* s engleskog jezika temeljem izvora: Tehničke znanosti (2001)

tradicionalna logika - Booleova logika[9] primjenom teorije skupova u rasterskoj analizi. Poseban pristup baziran na teoriji grafova i isključivo vektorskoj analizi organiziranoj na osnovi mrežnoga modela podataka primijenili su Gustafsson i Hägerstrand (2005). Grandjean i dr., (2009) i Hohmann i dr., (2013) u sklopu projekta ECORS[10] razvijaju model koji uključuje mehanička i taktička obilježja vozila, matematičke i fizičke zakonitosti i rezultate empirijskih istraživanja. Model je pretočen u svojevrsni sustav za pomoć pri prostornom odlučivanju koji pruža krajnjemu korisniku mogućnost prilagodbe izlaznih kartografskih proizvoda prema njegovim potrebama (Densham, 1991; Lubello, 2008). Od kraja 1990-ih godina autori se počinju koristiti multifunkcionalnim obilježjima GIS-a unutar kojega su integrirani i objedinjeni svi potrebni procesi organizacije, strukturiranja, modeliranja, procesiranja, analize, evaluacije i vizualizacije TPV. GIS je na taj način postao osnovni alat za utvrđivanje TPV. ArcGIS platformom koriste se Eichrodt (2003), Handke i Butikofer (1994), Pahernik i dr., (2006), Sadiya i dr., (2017) i Vrščaj i Godeša (2010), a modulom *Model Builder* za formuliranje i vizualno programiranje procesa koriste se Grogan (2009), Hofmann i dr. (2015), Hohmann i dr. (2013), Lubello (2008), Mohtashami i dr. (2012). Osnovna prednost GIS-a je u integriranim procesima na jedinstvenoj platformi koja zaokružuje procese od prikupljanja podataka do vizualizacije rezultata. U upotrebi još uvijek postoje modeli temeljeni isključivo na grafičkim programskim jezicima među kojima je najpoznatiji NRMM. Recentnim istraživanjima i razvojem NRMM-a u NRMM – Next Generation (2019) integriran je GIS modul. Heštera i Pahernik (2018) navode da GIS svakako nije jedina korištena metoda pri modeliranju i prostornoj analizi, stoga se koriste matematički modeli, statistički programi, meteorološki modeli i hidrološki modeli (Gumoś, 2005). Kao rezultat kontinuiranih istraživanja upotrebom složenih algoritama razvijeni su modeli FASST[11], SMSP[12] i SOFT[13] kojima je glavni cilj ustvrditi dinamičke procese koji se odvijaju na zemljištu, a uvjetovani su meteorološkim prilikama. Modeli simuliraju hidrogeomorfološke procese kako bi se utvrdila fluktuacija vlažnosti u tlu, odnosno predvidjela razina vlažnosti tla temeljem poznatih podataka (Albert i dr., 2000; Frankenstein i Koenig, 2004b; Mason i dr., 2003).

Prema Heštera i Pahernik (2018), nakon izrađenoga modela i provedenih računalnih kalkulacija neki su autori proveli i empirijska istraživanja točnosti modela na samom terenu u

[9] Booleova algebra je dio matematičke logike u kojoj su vrijednosti varijabli definirane logičkim operatorima „istina" i „laž", koji se obično označavaju vrijednostima 1 i 0.
[10] Etude Continentale et Océanique par Réflexion et Réfraction Sismiques
[11] Fast All-season Soil STrength
[12] Soil moisture-strength prediction
[13] Short Term Operational Forecasts of Trafficability

stvarnim situacijama (Hohmann i dr., 2013), a to je ujedno i jedina vjerodostojna metoda provjere točnosti i pouzdanosti modela. Stoga su Lessem i dr. (1992), Li i dr., (2007), Murphy i Randolph (1994), Rybansky i dr. (2015) i Talhofer i dr. (2015) svoje modele testirali na terenu služeći se GPS prijamnicima. Najprimjenjivaniji i najčešće korišteni parametri pri kalkulacijama unutar svojih modela autori koriste rezultate implementirane u NRMM modelu. NRMM model je kombinacija empirijskih istraživanja i teorijskih predviđanja, a parametri definirani u ovom modelu rezultat su više desetljeća sustavnoga testiranja i primjene dobivenih rezultata (*List of Publications*, 1993). Testiranja modela provode se na način da unaprijed definiranu rutu izračuna model, a potom po istoj ruti prolazi vozilo u stvarnim uvjetima. Općeniti zaključci testiranja odnosne se na statističku značajnost odstupanja stvarnih rezultata nasuprot modelom predviđenih rezultata. Proces utvrđivanja uzroka odstupanja je najkompleksniji i najdugotrajniji jer je vrlo teško izolirati svaki čimbenik zasebno zbog njihove međuovisnosti (vidi Sl. 11.). Krajnji rezultati iznimno ovise i o vozačima jer oni svojim iskustvom, načinom vožnje i poznavanjem prostora testiranja generiraju odstupanja i definiraju točnost rezultata testnih vožnja (Talhofer i dr., 2015).

2.4. Interpretacija rezultata

Karta TPV je svojevrsna sinteza interakcije svih čimbenika koji su prisutni u prostoru. Karte općenito sadržavaju tri kategorije prohodnosti vozila i opisuju teren kao prohodan, teško prohodan ili neprohodan (Grogan, 2009; Hohmann i dr., 2013; Kourdian, 2009; Pearson i Wright, 1980; Pimpa i dr., 2014; Rybansky i dr., 2015; *Terrain Analysis*, 1990; Wynn, 1985). Svrha izrade tematskih kartografskih proizvoda i interaktivnih aplikacija jest pomoć pri kvalitetnijem donošenju odluka za provedbu širokoga spektra aktivnosti (Hohmann i dr., 2013; Kourdian, 2009). Tematska karta prohodnosti donositeljima vojnih odluka doprinosi boljemu razumijevanju zemljišta, temeljem koje korisnik bira vrstu i veličinu postrojbe s kojom će provesti aktivnosti na terenu (*Military Geographic Intelligence*, 1972; Pearson i Wright, 1980). Uobičajena je praksa za sve geografske širine da se na temelju velike razlike u količini padalina i razlikama u temperaturama kroz godinu, odnosno snježnim ili kišnim i sušnim periodima, napravi više verzija karata prohodnosti (Affleck i dr., 2009; Baylot i dr., 2005; Pimpa, 2012). Karte prohodnosti prema godišnjim dobima prikazuju zimski period sa zaleđenim stanjem površine tla, ljetni period u sušnom razdoblju te vlažne periode u proljeće i jesen (Schreier i

Lavkulich, 1978). Zavisnost o dinamičkim čimbenicima u kartografskom obliku prikazuju se u obliku dvaju scenarija, za mokro i suho stanje podloge, odnosno nakon obilnih padalina i bez padalina (Sl. 19.).

Prema Heštera i Pahernik (2018) krajnji kartografski proizvod koji predstavlja kartu TPV plod je procesa prikupljanja, strukturiranja, evaluacije, modeliranja, standardizacije i generalizacije prostornih podataka. Svaki od navedenih procesa u sebi generira određeni stupanj pogreške, odnosno svakim korakom povećava se vjerojatnost pogreške modela. U skladu s potrebnom detaljnosti i kvalitetom ulaznih podataka, koji deriviraju i samu točnost modela (Grogan, 2009; Laskey i dr., 2010; Lessem i dr., 1996) postoji i nekoliko vrsta izlaznih kartografskih proizvoda različitih mjerila. Hohmann i dr. (2013, 90) navode: „Prilikom stvaranja tematskih kartografskih proizvoda sa svrhom prikaza TPV treba imati u vidu namjenu i potrebnu točnost u prostoru i vremenu, stoga možemo karte prohodnosti vozila kategorizirati prema tri razine vojnoga odlučivanja i provedbe operacija:

- Strategijska ili regionalna razina: odluke se donose nekoliko mjeseci unaprijed, karte su sitnoga mjerila i meteorološke promjene planiraju se na osnovi promjena godišnjih doba (primjer Sl. 20.),
- Operativna ili srednja razina: odluke se donose nekoliko tjedana unaprijed, karte su srednjega mjerila, analize meteoroloških promjena planiraju se na mjesečnoj razini (primjer Sl. 21.),
- Taktička ili lokalna razina: odluke se donose nekoliko dana unaprijed, karte su krupnoga do srednjega mjerila, analize meteoroloških promjena planiraju se na temelju vremenskih prognoza (primjer Sl. 22.).“

Tematske karte TPV pružaju općenitu informaciju za široki prostor koji prikazuju. Za planiranje mogućega pokreta većega broja vozila kroz određeno područje potreban je široki prostor koji je u skladu s veličinom snaga kojom se želi kroz njega proći (Intelligence preparation, 1994). Temeljem algoritama i računalno generiranih GIS podloga moguće je kreirati uska i ograničena područja prohodna za veći broj vozila, odnosno avenije i koridore mobilnosti vozila (Laskey i dr., 2010; Pimpa, 2012). Planiranje i odabir konkretne rute kretanja prepuštena je donositelju odluka. Interaktivni GIS sustavi omogućuju planiranje rute kretanja vozila odabirom polazišne i završne točke kretanja. Za razliku od cestovnoga planera putovanja koji je zasnovan na kvantitativnim metodama na postojećoj mreži prometnica (vektorski oblik podataka), planiranje rute kretanja vozila u terenskim uvjetima mnogo je kompleksnije (Donlon

i Forbus, 1999). Usloženost problema veća je zbog brojnih čimbenika koji su dionici procesa kalkulacije rute kretanja. Al-Hasan i Vachtsevanos (2002), Atkinson i dr., (2005), Grandjean i dr., (2009), Gumoś (2005), Lantzi dr., (2005), Laskey i dr., (2010), Mohtashami i dr., (2012), Pahernik i dr., (2006), Prato (2009), Rybansky (2014), Suvinen i Saarilahti (2006), Talhofer i dr., (2015), i Tarapata (2003) za izračune optimalne, najbrže ili najkraće rute kretanja u rasterskom formatu podataka u računalnim i GIS sustavima koriste *costpath* funkciju. Metodologiju izračuna rute kretanja zasnovanu na teoriji grafova, koja također koristi Dijkstra i A* algoritme istražili su Gustafsson i Hägerstrand (2005), Han i dr., (2014) i Stahl (2005). Interaktivne aplikacije omogućuju i integraciju dinamičnih čimbenika u realnom vremenu, kao što je npr. količina padalina predviđena vremenskom prognozom (Grogan, 2009; Schreier i Lavkulich, 1978; Wawer i dr., 2003). Sukladno dinamici, odnosno potrebama modernih vojnih snaga za dobivanjem informacija u realnom vremenu, interaktivne aplikacije u većoj su upotrebi na taktičkoj razini operacija, dok kartografski proizvodi prevladavaju na operativnoj i strateškoj razini upravljanja (Heštera i Pahernik, 2018).

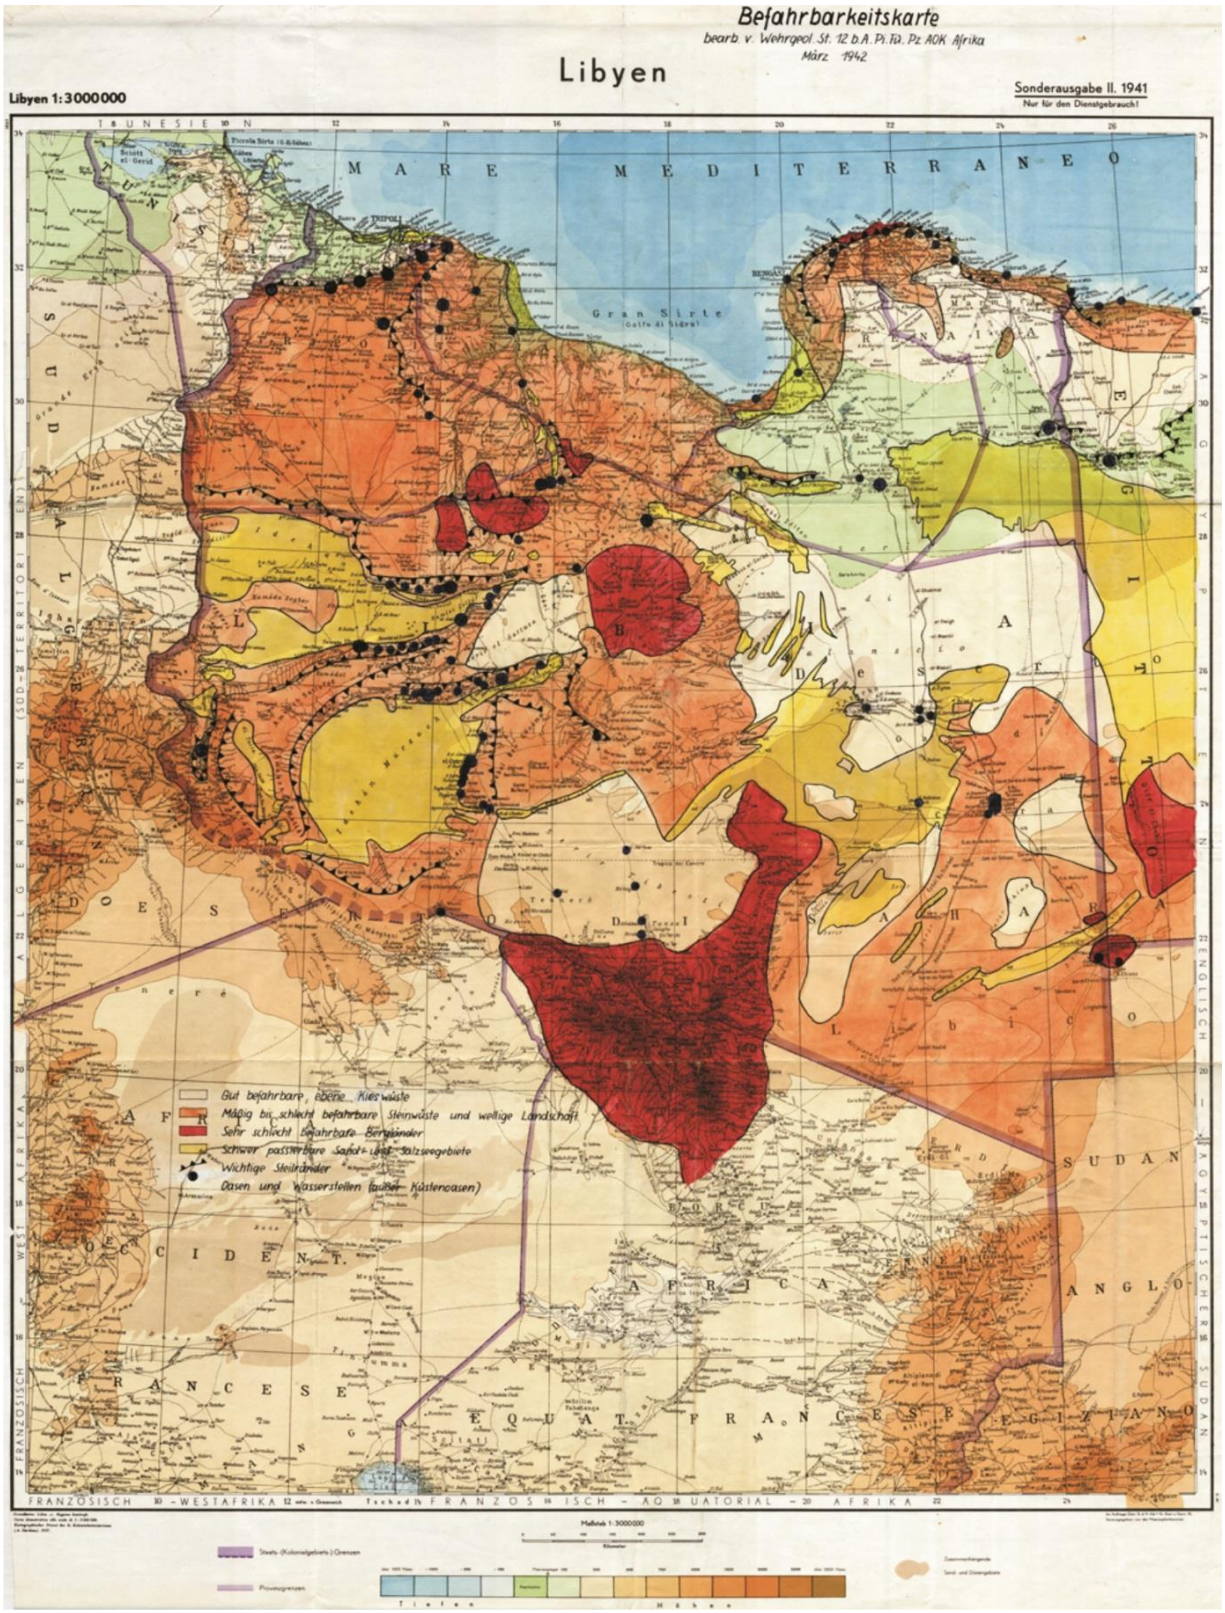

Sl. 20. Primjer karte prohodnosti vozila na strateškoj razini odlučivanja. Njemačka karta prohodnosti vozila za područje Libije (1941).

Izvor: Kuckelkorn (1942)

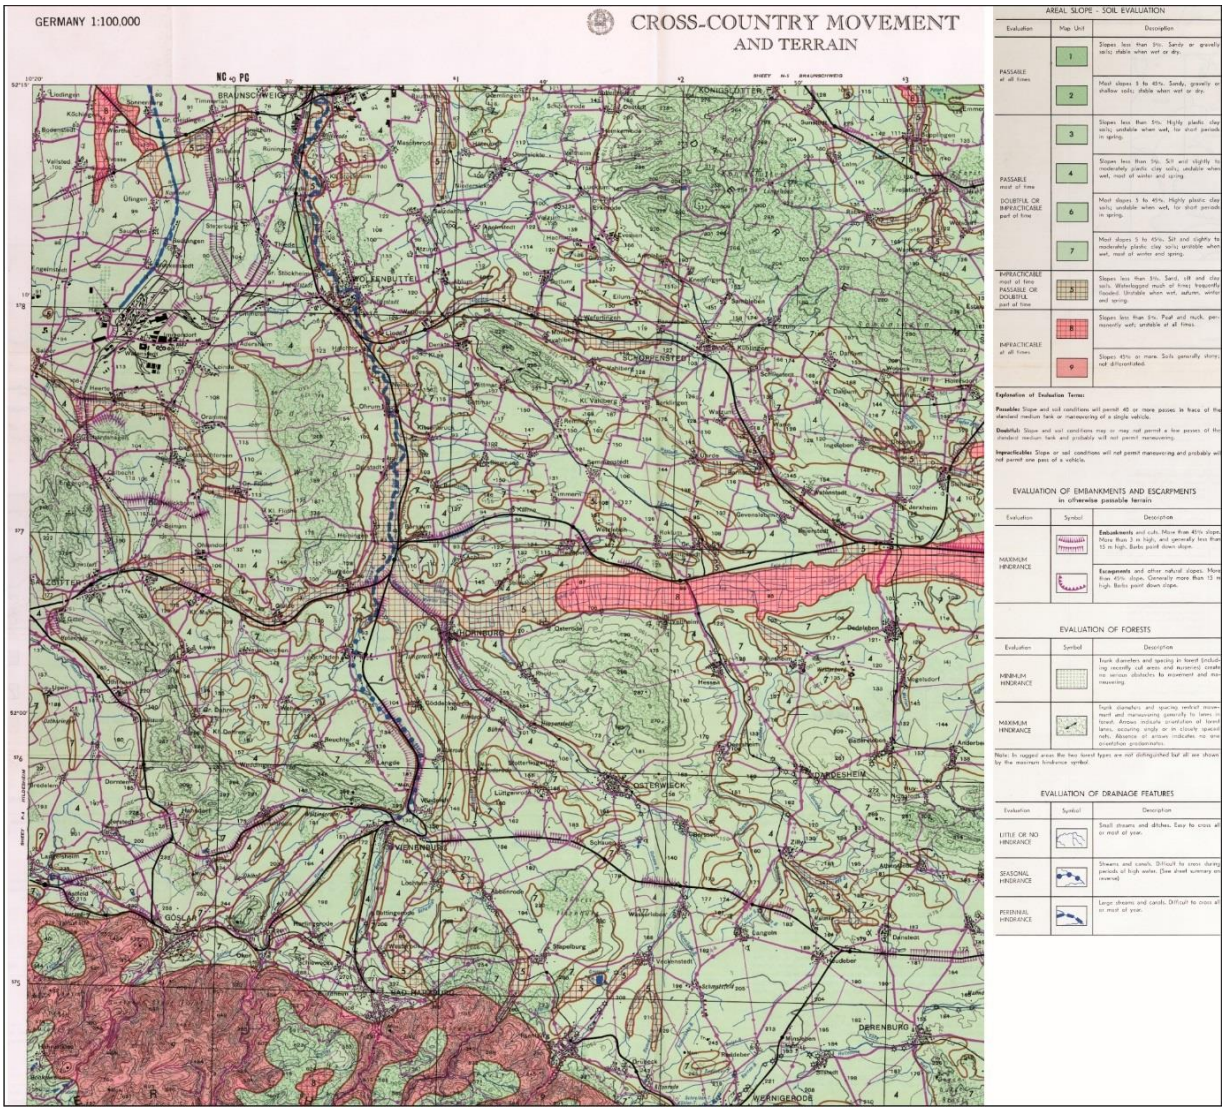

Sl. 21. Primjer karte prohodnosti vozila na operativnoj razini odlučivanja. Dio lista P 5 Serija M641 (CCM), Terenska pokretljivost vozila i karta zemljišta, Halberstadt, Njemačka, 1958, izrađena od strane vojske SAD-a.

Izvor: *Production of Cross-Country* (1959, Appendix I)

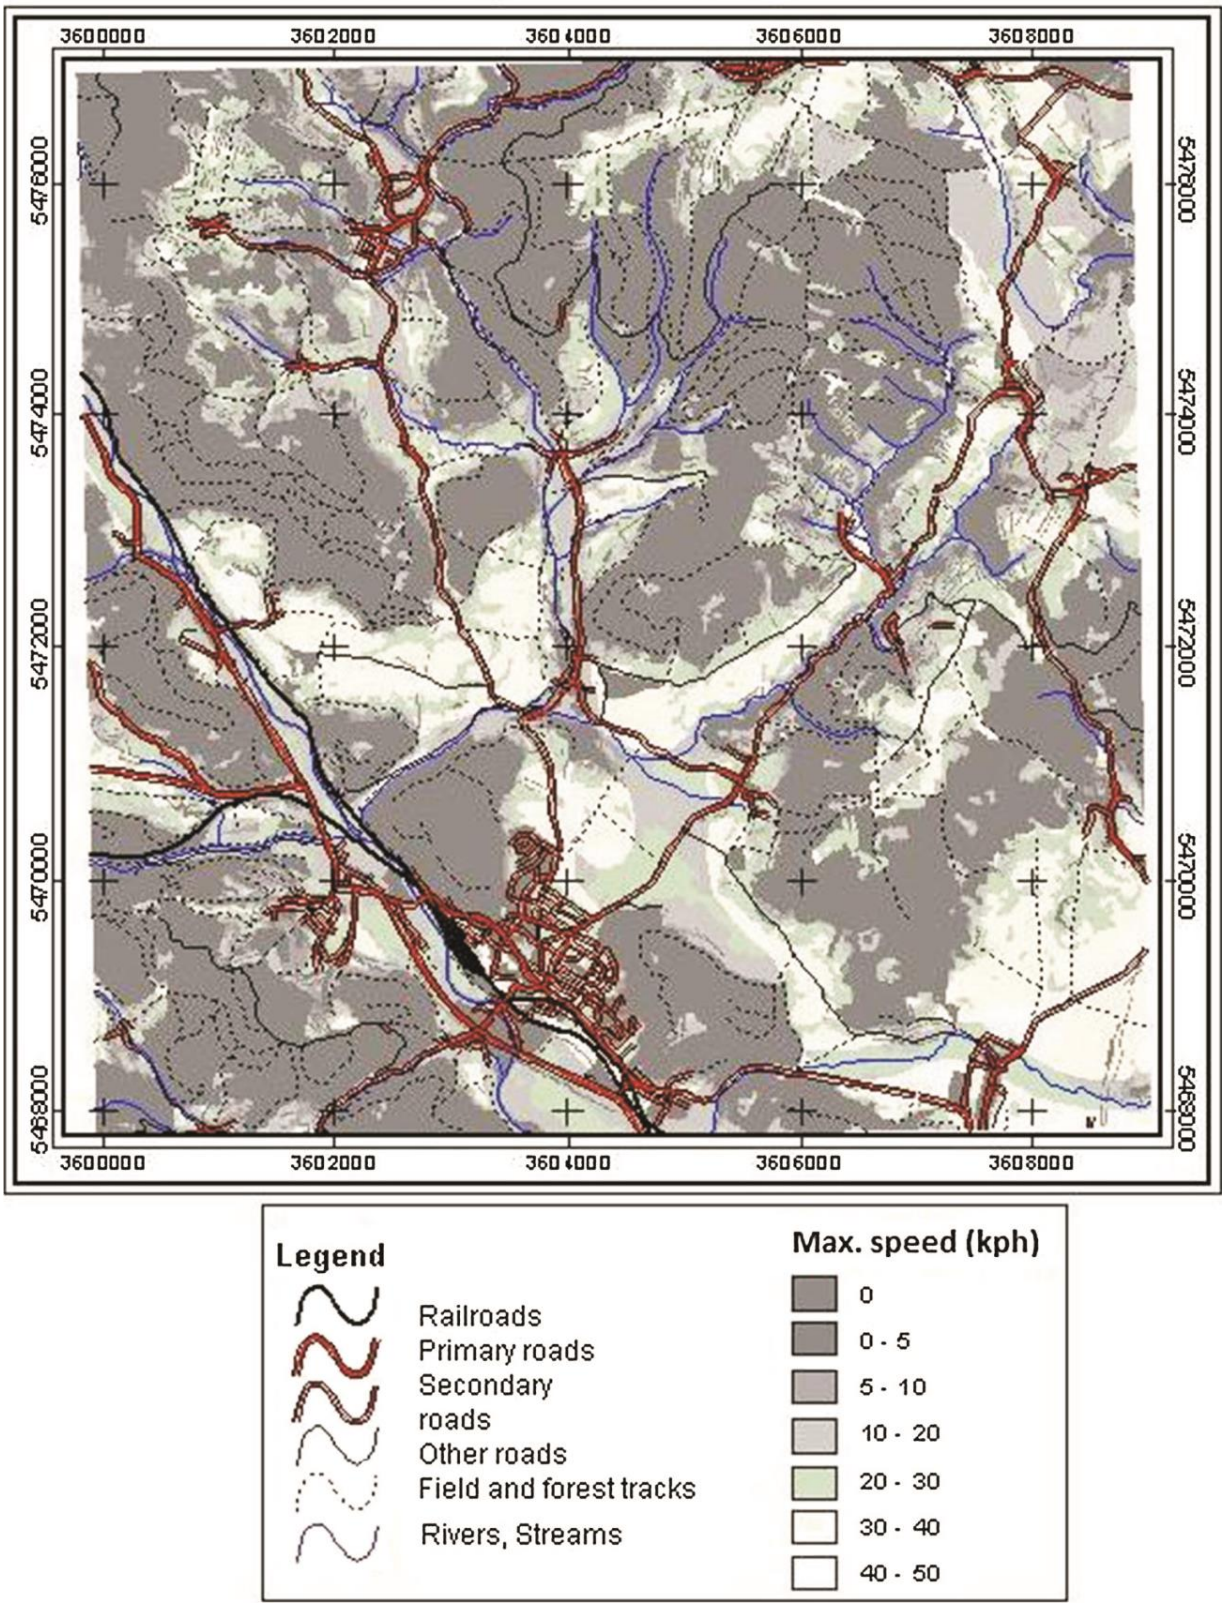

Sl. 22. Primjer karte prohodnosti vozila na taktičkoj razini odlučivanja. Karta terenske mobilnosti vozila u mjerilu 1:25 000 za područje Tišnova (Češka).

Izvor: Rybansky i dr. (2015, 7055)

3. Metodologija istraživanja

3.1. Tehničko-operativna obilježja vozila korištenih u istraživanju

Tehnička obilježja vozila određuju pokretljivost i manevarske sposobnosti vozila. Vozila se razlikuju prema namjeni korištenja. Namjena definira obilježja prema kojima se konstruira vozilo. Za provedbu analiza odabrani su različiti tipovi vozila koji se po svojim obilježjima jasno razlikuju, odnosno ona spadaju u zasebne kategorije mobilnosti i namjene. Vozila korištena u analizama i modeliranju su:

a) četverokotač, vozilo za sve terene, (*quad*, ATV (engl. *all terrain vehicle*)): Kawasaki B-Force 750 4x4i (Sl. 23.),
b) lako terensko vozilo (4x4): Land Rover Defender 110 (Sl. 24.),
c) višenamjensko oklopno vozilo na kotačima (8x8): BOV Patria (Sl. 25.),
d) cestovni transportni kamion: Iveco Eurocargo ML 100 E21 4x4 (Sl. 26.),
e) laki oklopni transporter, gusjeničar: BTR-50 (Sl. 27.),
f) srednji borbeni tenk: M-84 (Sl. 28.).

U Tab. 1. se nalaze svi parametri i tehnička obilježja vozila koji su upotrijebljeni u istraživanju. Svaki pojedini parametar korišten je za definiranje jednog ili više čimbenika usporenja vozila. Pomoću prikazanih parametara provedeni su svi izračuni opisani u metodologiji istraživanja.

Sl. 23. Kawasaki B-Force 750 4x4i

Izvor: https://www.kawasaki.com/products/2021-brute-force-750-4x4i?cm_re=MPP-_-PRODUCTTRIMLIST-_-VEHICLEDETAILS#gallery-photos-studio-6 (7.10.2020.)

Sl. 24 Land Rover Defender 110

Izvor: Hrvoje Heštera (17.11.2019.)

Sl. 25. BOV Patria

Izvor: https://www.feral.news/dan-otvorenih-vrata-povodom-dana-gardijske-mehanizirane-brigade-hv-q/ (7.10.2020.)

Sl. 26. Iveco Eurocargo ML 100 E21

Izvor: https://www.truck1-hr.com/img/Kamion_Dropside_kamion_sa_spustivim_stranicama_Iveco_Eurocargo_ML100E21_4x4_Singlebereift_Expedition-xxl-9041/9041_9438723237990.jpg (7.10.2020.)

Sl. 27. BTR-50

Izvor: https://www.pinterest.com/pin/445223113143311587/ (8.10.2020.)

Sl. 28. Tenk M-84

Izvor: http://www.balkanwarhistory.com/2016/04/yugoslav-tank-m-84.html (8.10.2020.)

Tab. 1. Glavna tehnička obilježja vozila korištenih u istraživanju

Osnovni podaci	Kawasaki B-Force 750i E	Land Rover Defender 110	BOV Patria	Iveco Eurocargo ML 100 E21	BTR-50	Tenk M-84
Težina (kg)	320	1950	26000	16000	14200	41500
Visina (m)	1.22	2	2.65	2.6	2	2.2
Dužina (m)	2.20	4.6	8	8.52	7.1	9.5
Širina (m)	1.18	1.8	2.83	2.2	3.1	3.6
Širina pneumatika (m)	0.22	0.2	0.39	0.36	-	-
Visina pneumatika (m)	0.65	0.73	1.24	1.08	-	-
Razmak između krajnjih osovina (m)	1.3	3	4.5	4.8	-	-
Širina gusjenice (m)	-	-	-	-	0.36	0.58
Dužina nalijeganja gusjenice (m)	-	-	-	-	4.4	4.27
Broj osovina	2	2	4	2	-	-
Broj kotača gusjeničara	-	-	-	-	12	14
Klirens (m)	0.24	0.25	0.43	0.35	0.37	0.43
Maksimalni nagib (°)	45	45	35	31	38	30
Indeks Mobilnosti (IM)	18	94	133	450	48	79
Konusni Indeks Vozila 1 (MPa)	0.092	0.2	0.25	0.43	0.11	0.15
Kritični nosivi sloj tla (cm)	15	15	30	30	30	30
Radijus okretanja (m)	3.2	5.7	11	11	9.5	9.5

3.2. Izvori i metode istraživanja fizičko-geografskih čimbenika

Svi prikupljeni i obrađeni prostorni podaci u vektorskom ili rasterskom obliku zapisa, ukoliko je to bilo potrebno, transformirani su u referentni projekcijski koordinatni sustav

Republike Hrvatske – HTRS96/TM[14]. Svi ulazni podaci u vektorskom obliku zapisa u svrhu provedbe prostornih analiza i izračuna pretvoreni su u rasterski oblik zapisa. Krajnji kartografski proizvodi i svi slojevi uključeni u završne izračune finalnih digitalnih kartografskih proizvoda provedeni su na veličini ćelija prostorne rezolucije 1x1 m.

U obradi, analizi i vizualizaciji prostornih podataka korištene su aplikacije tvrtke ESRI – ArcGIS, verzije 10.5.1 i ArcGIS Pro, verzije 2.4.3, zatim *opensource* aplikacija OpenJUMP, verzije 1.10. Statistička obrada dijela podataka rađena je u programu Excel tvrtke Microsoft. Grafička izrada i obrada grafičkih priloga provedena je programom CorelDRAW Graphics SuiteX7 tvrtke Corel Corporation.

3.2.1. Reljef

3.2.1.1. Nagib reljefa

Kreiranju sloja nagiba padina prethodila je izrada DMR-a. Prilikom izrade DMR-a korišteni su podaci projekta CRONO GIP[15], čiji su ulazni visinski podaci prikupljeni pomoću zračnih snimaka u mjerilu 1:20000 i drugih izvornika. Detaljan opis specifikacija izrade, metoda, točnosti i dozvoljenih odstupanja prilikom kreiranja digitalnog modela visina (DMV) nalazi se u *Državna geodetska uprava* (2004). Na osnovu izvornih vektorskih podataka DMV stvoren je *Terrain* (engl. *terrain dataset*). On predstavlja višerezolucijski zapis u prostornoj bazi podataka gdje prikaz morfologije površine zasnovan na nepravilnoj mreži trokuta (engl. *Triangular irregular network* - TIN). Prilikom izrade *Terraina*-a definirani su sljedeći parametri na ulaznim visinskim podacima:

- kao *mass points*: trigonometri, kote i visinske točke,
- kao *hard lines*: ceste, putevi, željeznice, nadzemni objekti, propusti, obalne linije, uske rijeke, uski kanali, potoci i vododerine, linijski objekti vodotoka, nasipi i zidovi,
- kao *soft lines*: izohipse, grebeni i doline,
- kao *soft clip*: granica područja istraživanja.

[14] Hrvatski Terestrički Referentni Sustav za epohu 1995.55, poprečne Mercatorove (Gauss-Krügerove) projekcije
[15] Hrvatsko-norveški geoinformacijski projekt

Pomoću *Terrain*-a kreirani su rasterski DMR-ovi različitih prostornih rezolucija ćelija.

Rasterski slojevi nagiba padina izrađeni su provedbom prostorne analize u programu ArcMap - verzija 10.5. U analizi je korišten alat *Slope* kojim je u stupnjevima izražena maksimalna promjena u visini između 8 susjednih ćelija (Pahernik i dr., 2006). U svrhu preliminarnih istraživanja načinjeni su slojevi nagiba padina u više različitih prostornih rezolucija (25x25 m, 10x10 m, 5x5 m, 3x3 m, 1x1 m i 0.5x0.5 m). Kao referentna rezolucija sloja nagiba padina korištena je prostorna rezolucija 1x1 m.

Prilikom modeliranja utjecaja vertikalnog nagiba na pokret vozila treba uzeti u obzir niz čimbenika, odnosno sila koje interaktivno definiraju smjer i brzinu gibanja vozila. Pojednostavljeni prikaz osnovnih sila koje djeluje prilikom pokreta vozila vidljiv je na Sl. 29.

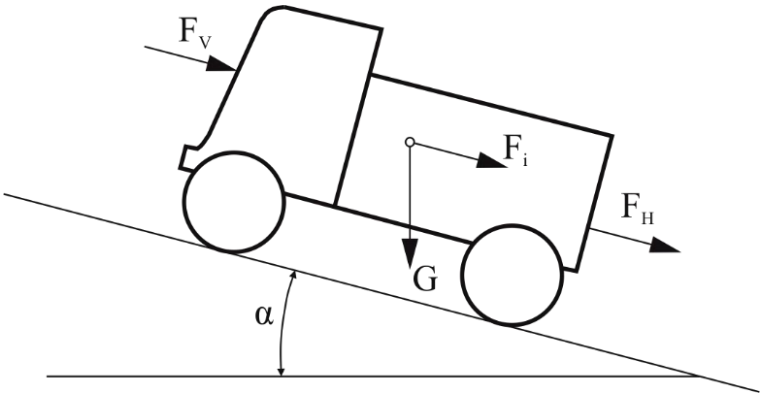

Sl. 29. Pojednostavljeni prikaz sila koje djeluju na vozilo u pokretu na vertikalnom nagibu

Sile koje djeluju na vozilo su:

- G *sin* α (otpor uspona),
- F_H (vuča priključka),
- F_i (inercijska sila),
- F_V (aerodinamički otpor).

Prema Ahlvin i Haley (1992) i Wong (2001) sile koje također utječu na vozilo u pokretu su: otpor zraka, otpor kotrljanja kotača (klizanje), sustav kočenja i upravljački sklop vozila.

U svrhu modeliranja odnosa nagiba padina i maksimalne moguće brzine kretanja vozila upotrjebljen je uopćeni odnos sila i pokretačkih mogućnosti vozila prikazan na Sl. 30. Dinamika pokreta vozila ovisi o ravnoteži odnosa sila koje djeluju na vozilo i pokretačke snage vozila. Uslijed uravnoteženog pokreta vozila odnosi između snage motora, brzine vrtnje motora, brzine vozila i nagiba terena prikazani su grafički na Sl. 30. Vučna sila (Ft) ovisi o okretnom momentu motora i stupnju prijenosa brzine. Krivulje otpora okreta kotača pri specifičnoj brzini prikazane su uz odgovarajući nagib terena. Ispod apscise grafikona prikazane su brzine vrtnje motora iz kojih iščitavamo okretni moment u određenom stupnju prijenosa (Wong, 2001). Rezultantu odnosa vučne sile i brzine predstavlja hiperbola koja je definirana točkama dodira tangencijalnih krivulja vučne sile pojedinog prijenosa brzine.

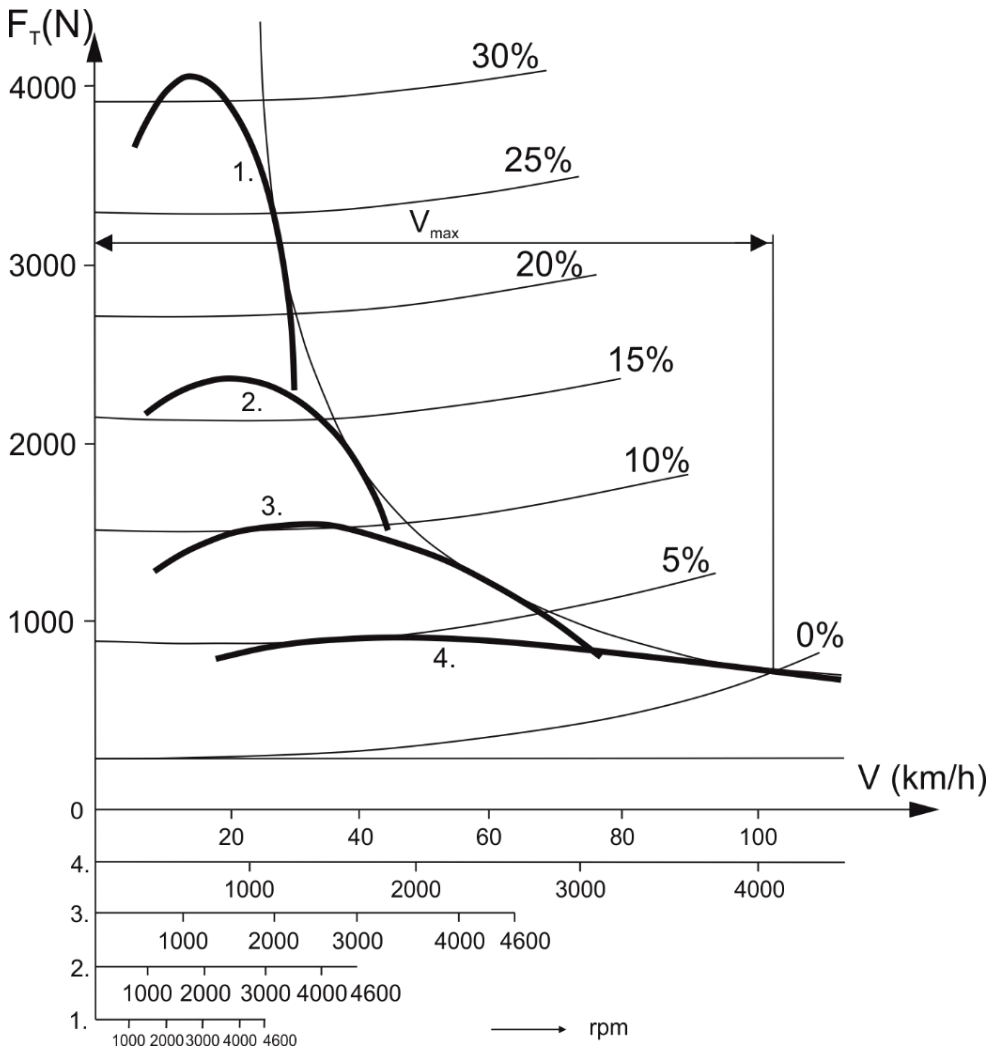

Sl. 30. Grafikon vučnih sila cestovnog vozila s četiri stupnja prijenosa brzine

Modificirano prema: Rybansky (2009, 29)

Pomoću grafikona vučnih sila moguće je steći uvid u:

- maksimalnu brzinu kretanja vozila,
- sposobnost uspona u pojedinim stupnjevima prijenosa brzine,
- koji je optimalni stupanj prijenosa za određeni nagib terena,
- koja je maksimalna brzina na određenom nagibu terena (Rybansky, 2009).

3.2.1.2. Topografski indeks vlaženja

TIV je upotrijebljen u svrhu utvrđivanja nosivosti tla cjelokupnog područja istraživanja temeljem poznatih odnosa ovisnosti vlažnosti i nosivosti tla (Hohmann i dr., 2013; Wawer i dr., 2003). TIV je statički hidrološki model zasnovan isključivo na topografiji terena. Prema Jednadžbi 2. TIV opisuje koliko svaka pojedina ćelija ima slijevno područje (A_{sp}) temeljem izračuna konvergentnih i divergentnih smjerova otjecanja ($\tan\beta$) niz padinu (Pahernik i dr., 2006).

$$\boldsymbol{TIV = ln\frac{A_{sp}}{\tan\beta}} \qquad \textbf{Jednadžba 2}$$

Sukladno istraživanjima (Ågren i dr., 2014) TIV je kreiran na DMR-u manje rezolucije (25x25 m) u svrhu dobivanja boljih rezultata. Prvotno je na podacima DMR-a provedena prostorna analiza pri kojoj su alatom *Fill* ispunjene i „poravnate“ nepravilnosti u podacima, pri čemu je korištena vertikalna granica (engl. *z-limit*) od 1 m. Potom je kreiran TIV prema Jednadžbi 2., pri čemu je korištena *D-Infinity* (DINF) metoda određivanja smjera otjecanja (Environmental Systems Research Institute, 2020), a dobiveni rezultati su pretvoreni u raster rezolucije ćelija 1x1 m. S ciljem dobivanja „blažih“ prijelaza između vrijednosti u posljednjem koraku analize korišten je alat *Focal statistics* kojim su uprosječene vrijednosti ćelija u okruženju od 12 m.

3.2.1.3. Hrapavost površine

Ovim zasebnim čimbenikom usporenja obuhvaćeni su nasipi, povremeni vodotoci i obale vodotoka. Hrapavost površine je izdvojena kao posebna skupina usporenja vozila zato što DMR-ovi imaju ograničene mogućnosti prikaza zemljine površine. DMR-om rezolucije 1x1m nije moguće prikazati nagle promjene u nagibu pojedinih objekata u prostoru. Ova skupina čimbenika ne čini teren neprohodnim, već svojim prisustvom ograničava kretanje vozila jer djeluje na svaki kotač ili gusjenicu zasebno (ovisno o smjeru prilaza). Njihove lokacije su kartirane pomoću vektorske baze visinskih podatka CRONO GIP-a. Prije transformacije u rasterski oblik zapisa pretvarani su u poligonalne objekte. Pretvorba je rađena alatom *Buffer* gdje je srednja linija objekta proširena za 0.75 m (ukupne širine poprečnog presjeka 1.5 m). Ova širina zoniranja određena je zbog ostvarivanja kontinuiteta podataka u rasterskom obliku zapisa, zbog uklanjanja tzv. „procjepa“ između ćelija.

3.2.2. Tlo

U svrhu planiranja terenskih istraživanja i daljnjih prostornih analiza kao temeljni pedološki podaci o pedološkim jedinicama i pedološkim profilima korišteni su podaci s listova Slavonski Brod 2 i Vinkovci 1 Osnovne pedološke karte (OPK) Republike Hrvatske (vidi Sl. 33.). Prilikom vektorizacije podataka OPK uočeno je nekoliko problema koji su zajednički za sve listove OPK (Bogunović i Rapaić, 1993), odnosno: „Topološka nekonzistentnost proizlazi iz razloga što je OPK rađena na topografskoj podlozi u mjerilu 1:100 000 izdanja Vojno geografskog instituta u Beogradu od 1923. do 1934. godine u poliedarskoj projekciji, na Besselovom elipsoidu i s Parizom kao početnim meridijanom. Glavni problem vezan je tako uz poliedarsku projekciju, odnosno svaki list je posebna projekcijska cjelina (Frančula, 2004, 135-137), te ih nije moguće praktično i automatiziranim procesom spojiti u jedinstven koordinatni sustav“ (Heštera i dr., 2019) (Sl. 31.). Kako bi se dobila odgovarajuća konzistentnost vektorskih podataka i zadržali topološki odnosi prethodno vektoriziranih podataka korištena je metoda „savijanja“ engl. *warp*. „Pomoću programa OpenJUMP i integriranog alata Warp koji se pokazao kao jedini prikladan za „savijanje“ vektora, provedena je korekcija digitalnih podataka pedoloških jedinica OPK, a da se pri tome nisu narušili njihovi topološki odnosi“ (Heštera i dr.,

2019). Rad na topološkom ujednačavanju izvornih podataka započeo je njihovom transformacijom u projekciju HTRS96TM. Položaji pedoloških poligona korigirani su prema sadržaju na Topografskoj karti 1:25000 i karti nagiba reljefa. Usklađivanje nazivlja pedoloških jedinica izvornih podataka i ostale terminologije provedeno je koristeći suvremenu metodologiju sistematike pedoloških jedinica prema Husnjaku (2014).

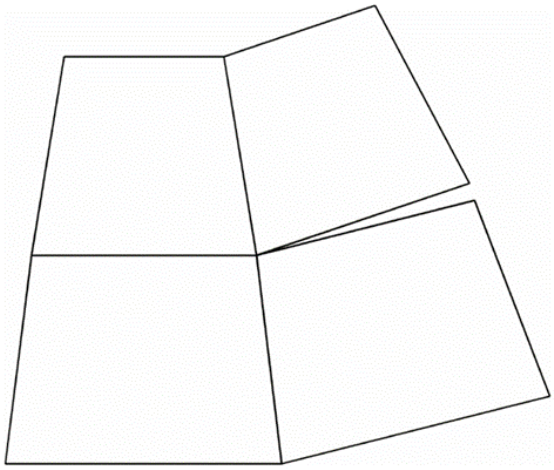

Sl. 31. Spajanje više listova u poliedarskoj projekciji

Izvor: Frančula (2004)

Prilikom izrade OPK mehanička analiza profila tla provedena je pipet metodom uz pripremu Na-pirofosfatom i teksturnom klasifikacijom prema Soil Survey Staff (1951). Frakcije tla su podijeljene prema veličinama: 2-0.2mm, 0.2-0.05mm, 0.05-0.02mm, 0.02-0.002mm i manje od 0.002mm. Teksturna klasifikacija izvornih podataka unutar profila rađena je na različitim dubinama, odnosno prema pripadajućim osnovnim pedogenetskim horizontima. Postoje mnoge teksturne klasifikacije koje su zavisne o udjelima pojedinih frakcija (pijesak, prah i glina) i granicama veličinskih razreda pojedinih frakcija. Prilikom ovog istraživanja frakcije čestica su klasificirane prema USDA klasifikaciji zbog usporedivosti brojnih radova koji su rađeni na temu mobilnosti vozila i svojstava tla, a koristili su upravo USDA klasifikaciju (García-Gaines i Frankenstein, 2015). Prilikom klasificiranja tla prema USDA klasifikaciji u obzir je uzeta dubina do 50 cm, jer je to referentna dubina do koje se mjeri nosivost tla prema WES metodi.

Teksturna obilježja unutar prisutnih pedogenetskih horizonata do 50 cm dubine klasificirana su proporcionalno s udjelom dubine (Heštera, 2020).

Od ostalih rezultata analiza koje bi se mogle upotrijebiti u istraživanju (sadržaj organske tvari, porozitet, kapacitet za vodu, kapacitet za zrak, specifična težina volumena i specifična težina tla), dobivenih prilikom izrade OPK, jedino su podaci za sadržaj organske tvari konzistentni za čitavo područje istraživanja. Ostali podaci fizikalnih svojstava tla nisu upotrijebljeni za prostorne analize zbog nepotpunosti podataka (Heštera, 2020).

3.2.2.1. Terensko uzorkovanje i laboratorijska analiza prema USCS

Broj uzorkovanja na terenu (72) za provedbu analiza tla prema USCS klasifikaciji određen je na osnovu prisutnih izvornih podataka pedoloških profila (77) istraženih u sklopu izrade OPK. Odabir mjesta uzorkovanja tla za provedbu laboratorijske analize definirana su u dva koraka:

- prvotno je svakoj od prisutnih pedoloških jedinica dodijeljen broj uzoraka sukladno njihovoj prostornoj zastupljenosti unutar cjelokupnog područja istraživanja (Tab. 2.),
- lokacije uzorkovanja unutar pedoloških jedinica predefinirane su prema istraženim profilima analiziranim prema USDA klasifikaciji (50 lokacija). Ukoliko nije postojao istraženi USDA profil na području interesa, lokacije (22 lokacije) su definirane slučajnim odabirom unutar pedološke jedinice. Treba napomenuti da su favorizirani pedološki poligoni koji se nalaze unutar vojnog poligona „Gašinci“ (Sl. 32. i Sl. 33.), s obzirom na cilj i svrhu predmetnog i daljnjih mogućnosti istraživanja TPV u budućnosti (Heštera, 2020).

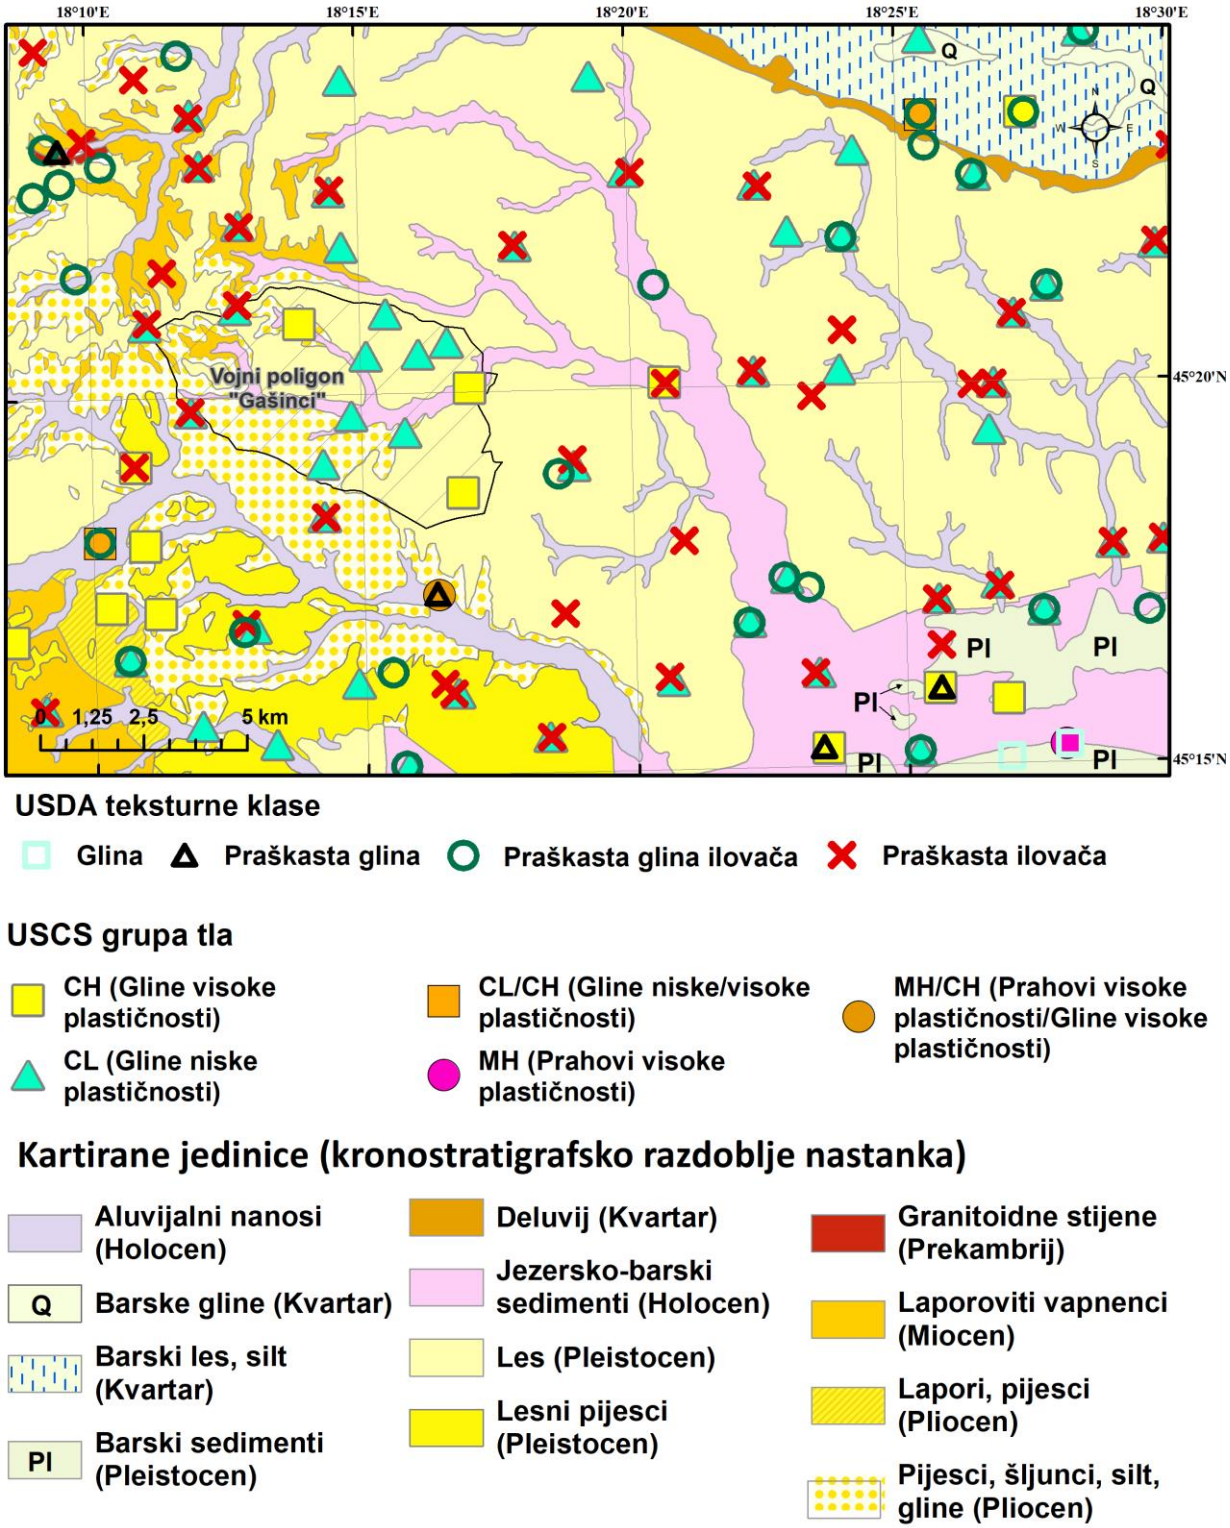

Sl. 32. Osnovna geološka karta s lokacijama USDA profila i uzorka prema USCS

Izvor: Dijelovi listova L 34-97 Slavonski Brod (Šparica i dr., 1986a) i L 34-85 Našice (Korolija i Jamičić, 1989a)

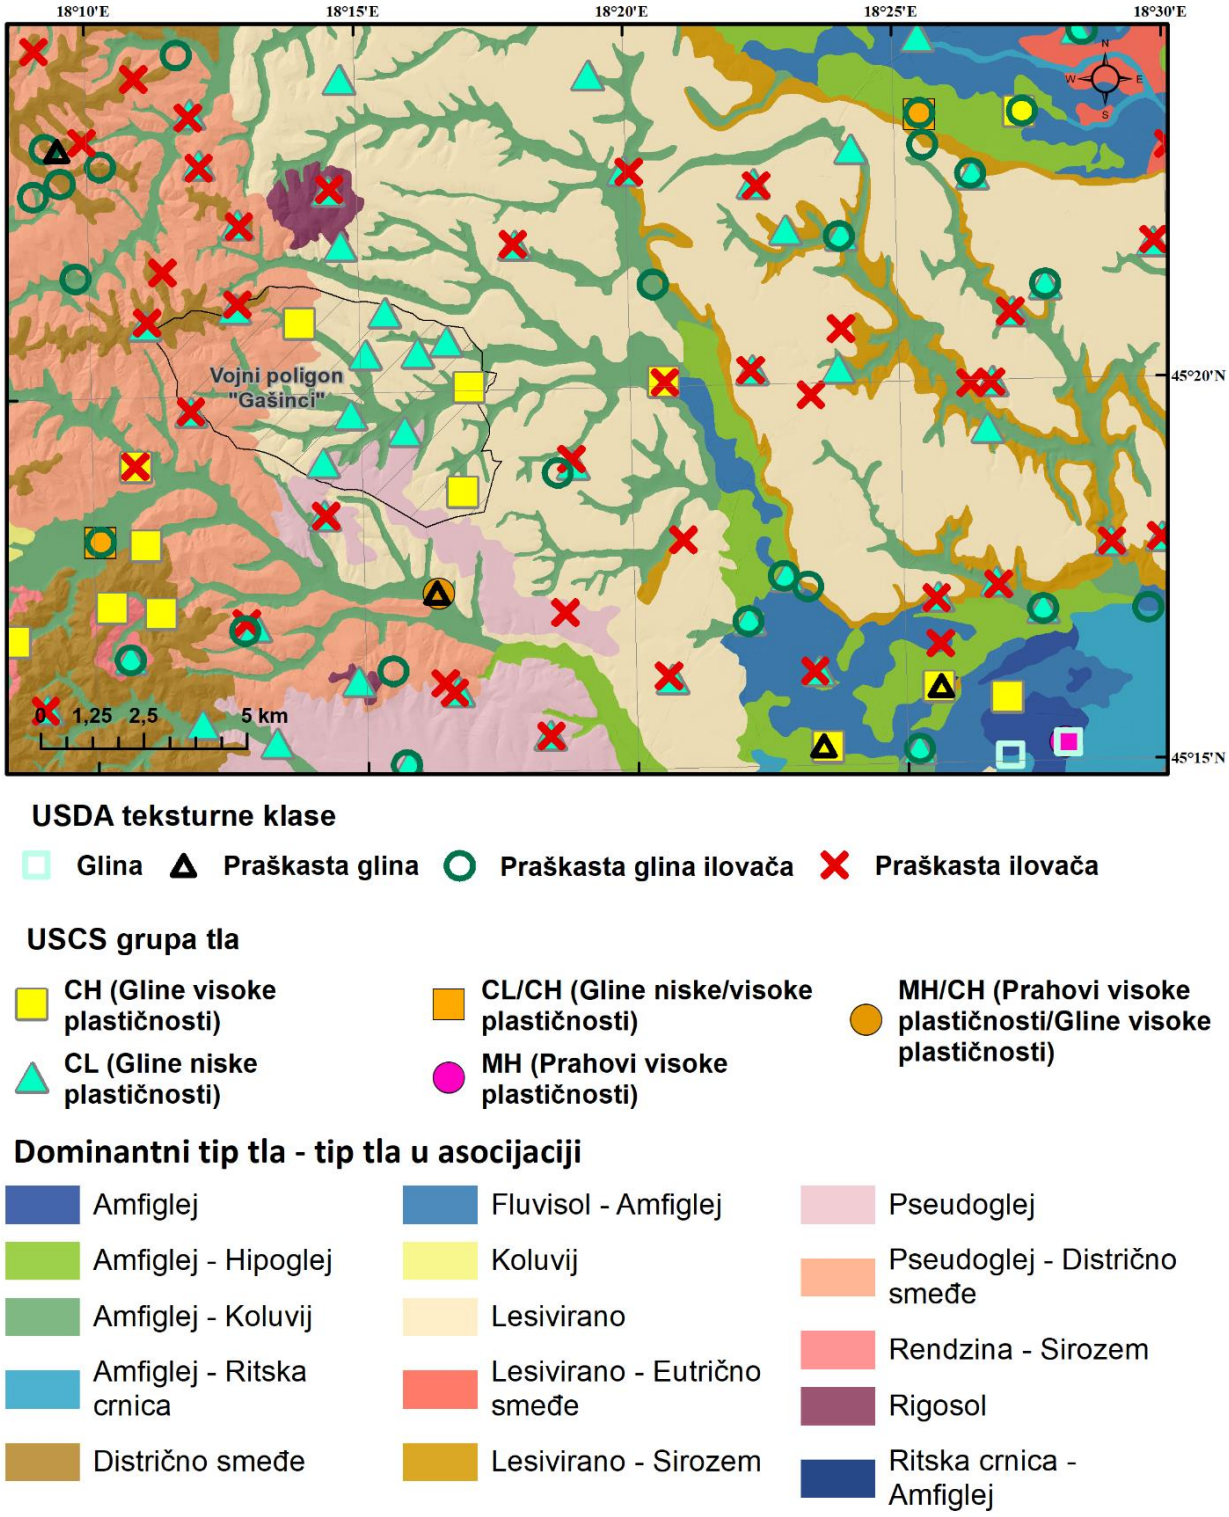

Sl. 33. Osnovna pedološka karta s lokacijama USDA profila i uzorka prema USCS

Izvor: Dijelovi listova Osnovne pedološke karte (1:50 000) Slavonski Brod 2 (Vidaček, 1973b) i Vinkovci 1 (Bogunović, 1973b)

Tab. 2. Odnos površinskog udjela pedoloških jedinica i preuzetih uzoraka za laboratorijsku analizu prema USCS

Kartirana pedološka jedinica	Površina (km²)	Udio u ukupnoj površini (%)	Broj uzoraka za klasifikaciju prema USCS	Udio u ukupnom broju uzoraka (%)
Pseudoglej	27.8	5.4	5	6.9
Pseudoglej - Distrično smeđe	68.6	13.4	4	5.6
Rigosol	3.9	0.8	2	2.8
Distrično smeđe	30.1	5.9	5	6.9
Fluvisol - Amfiglej	33.0	6.5	5	6.9
Rendzina - Sirozem	2.4	0.5	1	1.4
Lesivirano	193.6	38.0	15	20.8
Lesivirano - Sirozem	25.8	5.1	5	6.9
Koluvij	0.4	0.1	0	0.0
Amfiglej	4.8	0.9	2	2.8
Amfiglej - Hipoglej	31.1	6.1	6	8.3
Amfiglej - Koluvij	80.5	15.8	20	27.8
Amfiglej - Ritska crnica	7.8	1.5	1	1.4
Ritska crnica - Amfiglej	0.1	0.0	1	1.4
Σ	509.9	100.0	72	100.0

Uzorkovanja tla na terenu provedena su vremenskom razdoblju od 25. rujna do 24. listopada 2017. godine terenskim uzorkivačem tvrtke Eijkelkamp oznake 04.15.SB foil sampler (Sl. 34.). Prilikom planiranja uzorkovanja, odnosno za izradu pedološkog sloja za istraživano područje uzet je nešto veći prostor od osnovnog prostora istraživanja kako bi krajnji rezultat više odgovarao stvarnosti. Prikupljeno je 72 uzorka na području istraživanja koje zahvaća 510 km², a gustoća uzorkovanja iznosila je 1 uzorak na 7 km². Na svakoj lokaciji ekstrahirano je po dva uzorka duljine 30 cm i promjera 5 cm (Sl. 35.), čime je ukupna dubina uzorkovanja dosezala 60 cm. Uzorci su u zaštitnoj foliji dopremani u geotehnički laboratorij (Heštera, 2020). Laboratorijskom analizom su zahvaćene dubine do 50 cm, imajući na umu referentnu dubinu

tla prema WES metodi. Na uzorcima u laboratoriju (Sl. 36.) je obavljeno ispitivanje fizičkih i indeksnih svojstava što je obuhvaćalo određivanje:

- vlažnosti u prirodnom stanju prema normi ASTM D2216-10 (2010),
- Atterbergovih granica (granica plastičnosti, granica tečenja i indeks plastičnosti) prema normi ASTM D4318-17e1 (2017),
- granulometrijskog sastava tla prema normi ASTM D422-63(2007)e2 (2007).

Za određivanje granice tečenja korišten je Casagrandeov uređaj tvrtke Controls, model 22-T0031/F. Za određivanje granulometrijskog sastava tla metodom sijanja korišten je standardni set sita tvrtke ELE (sita broj 4, 10, 20, 40, 60 i 200) s dimenzijama otvora sita: 4.75 mm, 2.00 mm, 0.85 mm, 0.425 mm, 0.25 mm i 0.075 mm. Za određivanje granulometrijskog sastava sitnozrnate frakcije tla korišten je areometar oznake ASTM-E100/151H-62. Temeljem sumarnih rezultata ispitivanja i podataka o prirodnoj vlažnosti tla određen je još indeks tečenja i indeks konzistencije odnosno stanje konzistencije tla. Sumarni rezultati omogućili su naknadnu provedbu klasifikacije tla prema normi ASTM D2487-17 (2017) (Heštera, 2020). Laboratorijske analize i klasifikacija tla su provedene od strane djelatnika Geomehaničkog laboratorija - Odjela za mehaniku tla, Rudarsko-geološko-naftnog fakulteta u Zagrebu.

Sl. 34. Uzorkovanje tla uzorkivačem „Foil sampler“ na lokaciji Lapovci

Autor: Mladen Pahernik (18.09.2017.)

Sl. 35. Ekstrahirani uzorak tla na lokaciji Široko Polje - sjever

Autor: Hrvoje Heštera (11.10.2017.)

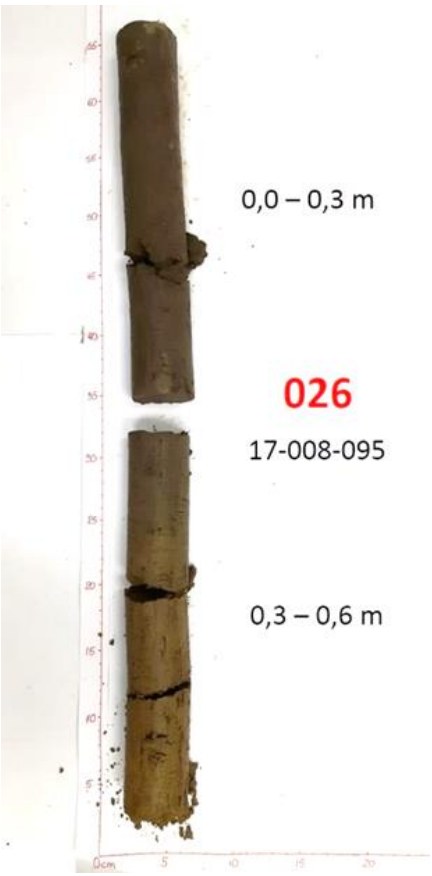

Sl. 36. Uzorak tla s lokacije Široko Polje – sjever (prije laboratorijske obrade)

Autor: Evelina Oršulić (17.10.2017.)

3.2.2.2. Kartografska obrada rezultata laboratorijskih analiza

Prilikom kartografske obrade krajnjih rezultata laboratorijskih analiza tla korišten je vizualni programski jezik *Model Builder* koji je dio ArcGIS platforme. Za inicijalnu kartografsku interpretaciju rezultata korišten je princip neizrazite logike na način da su objedinjeni poligoni istovjetnih pedoloških grupa tala prema INT (Tab. 3.) WES metode (*Defense Mapping Agency*, 1982; Hofmann i dr., 2013). Na poligonima je učinjeno unutrašnje zoniranje (engl. *inner buffer zone*) od 30 m, koji su potom uz pomoć *Euclidean distance* alata produženi za dvostruko veću udaljenost (60 m). Prije završnog objedinjenja poligona, *Fuzzy membership* alatom koristeći linearnu funkciju, dodijeljene su krajnje vrijednosti INT za svaku grupu tala (Heštera, 2020). Ovaj proces je proveden u svrhu preliminarnog uvida i vizualizacije prohodnosti tla, nakon čega su uslijedila *in situ* mjerenja na terenu.

Tab. 3. Prosječne vrijednosti INT za tri uobičajena stanja vlažnosti tla

Izvor: *Defense Mapping Agency* (1982, str. 29)

Simbol grupe	Tipičan naziv	Vrijednosti INT		
		Suho	Vlažno	Mokro
GW	Dobro graduirani šljunak	163	123	83
GP	Slabo graduirani šljunak	160	120	81
GM	Prašinasti šljunak	120	76	32
GC	Glinoviti šljunak	130	91	52
SW	Dobro graduirani pijesak	155	116	78
SP	Slabo graduirani pijesak	145	109	73
SM	Prašinasti pijesak	119	72	25
SC	Glinoviti pijesak	126	86	46
CL	Glina niske plastičnosti	118	69	20
ML	Prah niske plastičnosti	123	81	40
OL	Organska glina ili prah niske plastičnosti	111	57	3
MH	Prah visoke plastičnosti	114	61	8
CH	Glina visoke plastičnosti	136	99	62
OH	Organska glina ili prah visoke plastičnosti	107	54	1

3.2.2.3. Modeliranje odnosa vozilo-kotač-tlo prema WES metodi

Prema Ahlvin i Haley (1992) i Haley i dr. (1979b) parametar kojim se objedinjuju sva tehnička obilježja i koji se koristi za predviđanje sposobnosti vozila za vožnju po određenom tipu tla u terenskim uvjetima izražava se putem indeksa mobilnosti (IM). Metodologija izračuna razvijena je pod vodstvom WES laboratorija oružanih snaga SAD-a i stručnjaka iz ostalih zemalja članica NATO saveza. Prilikom računanja IM, vozila se dijele u dvije osnovne skupine, odnosno na kotačna vozila i vozila pokretana gusjenicama. U nastavku teksta će mehanička svojstva tla biti detaljnije opisana. Formule uz pomoć kojih se računa IM za vozila su:

$$IM = \left(\frac{K_{KP}\ x\ K_T}{K_G\ x\ K_L} + K_{OK} - K_{CL}\right) \text{ x } K_M \text{ x } K_{MJ}$$ **Jednadžba 3**

Za gusjeničare se koriste ovi elementi prilikom izračuna:

K_{KP} – faktor dodirnog pritiska na tlo,

$$\boldsymbol{K_{KP} = \frac{w}{2lb}}$$ **Jednadžba 4**

w – ukupna težina vozila

l – dužina gusjenice u kontaktu sa podlogom (jedna strana)

b – širina gusjenice u kontaktu sa podlogom (jedna strana)

K_T – faktor osovinskog opterećenja vozila (vidi Tab. 4.),

K_G – faktor širine gusjenice

$$\boldsymbol{K_G = \frac{b}{100}}$$ **Jednadžba 5**

K_L – faktor visine gusjenice (1 ako < 1.5; 1.5 ako ≥ 1.5)

K_{OK} – faktor opterećenja kotača

$$\boldsymbol{K_{OK} = \frac{\frac{w}{10}}{pn}}$$ **Jednadžba 6**

p – površina kojom naliježe jedna gusjenica na tlo

n – broj kotača koji su u kontaktu sa tlom (ukupno)

K_{CL} – faktor udaljenosti šasije od tla

$$\boldsymbol{K_{CL} = \frac{H}{10}}$$ **Jednadžba 7**

H – klirens

K_M – faktor specifične snage vozila (> 7.36 kW/t = 1; < 7.36 kW/t = 1.05)

K_{MJ} – faktor mjenjača (automatski = 1.0; ručni = 1.05)

Tab. 4. Faktor osovinskog opterećenja za gusjeničare

K_T =	1.00	ako	0	≤	w	<	50 000 lb (22680 kg)
K_T =	1.20	ako	50 000 lb (22680 kg)	≤	w	<	70 000 lb (31751 kg)
K_T =	1.40	ako	70 000 lb (31751 kg)	≤	w	<	100 000 lb (45359 kg)
K_T =	1.80	ako	100 000 lb (45359 kg)	≤	w		

Za kotačna vozila računa se opterećenje za svaku osovinu u sklopu vozila prilikom kojih se koriste ovi elementi za izračun:

K_{KP} – faktor dodirnog pritiska na tlo

$$\boldsymbol{K_{KP} = \frac{w}{0.5\ nbd}}$$ **Jednadžba 8**

w – opterećenje po osovini

n – broj kotača po osovini

b – širina pneumatika (neopterećen kotač)

d – promjer pneumatika (neopterećen kotač)

K_T – faktor osovinskog opterećenja vozila (vidi Tab. 5.)

K_G – faktor širine pneumatika

$$\boldsymbol{K_G = \frac{100+b}{100}}$$ **Jednadžba 9**

K_L – faktor grebena lanca (1= bez lanaca, 1.5= s lancima)

K_{OK} – faktor opterećenja kotača

$$\boldsymbol{K_{OK} = \frac{w}{2000}}$$ **Jednadžba 10**

K_{CL}– faktor klirensa

$$\boldsymbol{K_{CL} = \frac{H}{10}}$$ **Jednadžba 11**

H – klirens

K_M – faktor specifične snage vozila (> 7.36 kW/t = 1; < 7.36 kW/t = 1.05)

K_{MJ} – faktor mjenjača (automatski = 1.0; ručni = 1.05)

Tab. 5. Faktor osovinskog opterećenja za kotačna vozila

K_T =	0.553 w/1000	ako	0	≤	w	<	2 000 lb (907 kg)
K_T =	0.033 w/1000 + 1.050	ako	2 000 lb (907 kg)	≤	w	<	13 500 lb (6123 kg)
K_T =	0.142 w/1000 – 0.42	ako	13 500 lb (6123 kg)	≤	w	<	20 000 lb (9070 kg)
K_T =	0.278 w/1000 – 3.115	ako	20 000 lb (9070 kg)	≤	w		

Izračunom IM moguće je definirati Konusni indeks vozila (KIV) (Pahernik i Tuta, 2010). KIV predstavlja numerički indeks za neko vozilo koji se koristi prilikom modeliranja mogućnosti prolaska vozila u odnosu na minimalnu nosivosti tla.

Izračun KIV za prolazak vozila računa se putem empirijskih formula (Ahlvin i Haley, 1992; Ciobotaru, 2009):

Za sitnozrnata tla:

Gusjeničari:

$$\text{KIV} = 7.0 + 0.2\ \text{IM} - \left(\frac{\mathbf{39.2}}{\boldsymbol{IM}+\mathbf{5.6}}\right)$$ **Jednadžba 12**

Kotačna vozila:

(Ako je IM ≤ 110): $$\text{KIV} = 11.48 + 0.2\ \text{IM} - \left(\frac{39.2}{IM+3.74}\right)(K_F)$$ **Jednadžba 13**

(Ako je IM > 110): $$\text{KIV} = 4.1\ \text{IM}^{0.446}\ (K_F)$$ **Jednadžba 14**

K_F = Faktor korekcije za ispuštenost pneumatika (Sl. 37.) (on se dodaje po potrebi na prethodne formule)

$$\boldsymbol{K_F} = \left(\frac{\mathbf{0.15}}{\boldsymbol{\delta}/\mathbf{h}}\right)^{\mathbf{0.25}}$$ **Jednadžba 15**

δ – ispuštenost pneumatika za određeni scenarij

h – nominalna visina pneumatika

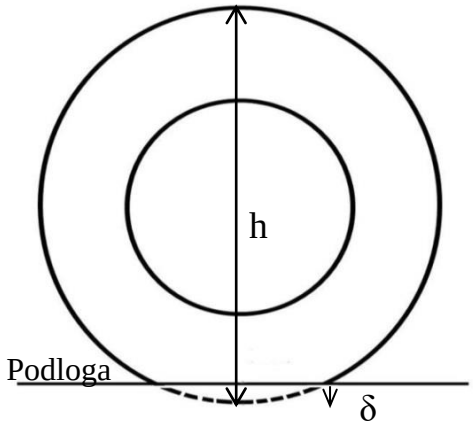

Sl. 37. Parametri za računanje ispuštenosti pneumatika

Mobilnost vozila ovisi o nosivosti tla (KI) na pritisak od strane vozila (KIV), odnosno sposobnosti tla da podnese težinu vozila koje se po njemu kreće. KI tla predstavlja jediničnu vrijednost sile (MPa) koja je rezultat stvaranja otpora prilikom prodiranja konusa u tlo. Mjerenja KI indeksa provode se ručnim uređajem – penetrometrom. Budući da nije mjerena nosivost tla u poremećenom stanju tla (simulacija prolaska više vozila u koloni), već samo KI – za utvrđivanje prohodnosti tla (jednog prolaska vozila) uspoređivane su vrijednosti KI i KIV (Pahernik i Tuta, 2010; Stevens i dr., 2013). Ukoliko je KIV veći od KI tlo je neprohodno, a u slučaju kada je KIV manji od KI – tlo je prohodno. Ova metoda je odabrana zbog praktičnosti i brzine mjerenja, obzirom na veliki broj repeticija i ograničeni vremenski period mjerenja. Drugi razlog zbog čega nije odabrana cjelokupna metoda ispitivanja INT (opisana u poglavlju 2.1.2) je nedostatak instrumenata za provedbu mjerenja.

3.2.2.4. *In situ* mjerenja

U svrhu provedbe mjerenja prohodnosti tla za istraživano područje odabrano je 12 lokacija na vojnom poligonu „Gašinci“ (Sl. 38.). Mjerenja su zasnovana na ideji da se odabrane lokacije iskoriste kao reprezentativni uzorak čitavog područja istraživanja. U tu svrhu odabrane su lokacije sa heterogenim fizičko-geografskim obilježjima (Sl. 39. i Tab. 6.). Prilikom izbora lokacija postojali su neki ograničavajući i uvjetovani faktori:

- lokacije nisu smjele biti na privatnom posjedu,
- lokacije su trebale biti osigurane od „vanjskih“ utjecaja,
- lokacije su se trebale nalaziti unutar granica vojnog poligona „Gašinci“,
- provedba mjerenja na lokacijama nije smjela ometati druge aktivnosti na vojnom vježbalištu, stoga su odabrane lokacije na rubnim dijelovima vježbališta.

Provedeno je ukupno 7 petodnevnih mjerenja (35 dana) tijekom 2019. godine. Odabir termina referiran je prema reprezentativnim klimatskim razdobljima tijekom godine (Jones i dr., 2005). Provedene su po dvije grupe petodnevnih mjerenja tijekom klimatološke zime (25. veljače - 1. ožujka i 16. prosinca – 20. prosinca), proljeća (11. – 15. ožujka i 30. travnja – 4. svibnja) i jeseni (15. – 19. studenog i 25. – 29. studenog), te jedno petodnevno mjerenje tijekom ljeta (26. – 30. kolovoza). Lokacije su podijeljene u grupe „Bakunovac“ i „Kućište“. Provedba mjerenja na svakoj od grupa (po 6 lokacija) trajala je između 2.5 do 3 sata. Dnevna dinamika provedbe mjerenja koncipirana je na način da su mjerenja na grupi „Bakunovac“ započinjana u 8:00 sati, a na grupi „Kućište“ u 15:00 sati. Na svakoj od lokacija mjerena su četiri parametra: konusni indeks tla, vlažnost tla, temperatura tla, te posmična nedrenirana i rezidualna čvrstoća tla. Metodologije provedbe mjerenja navedenih parametra zasebno su opisane u sljedećim potpoglavljima.

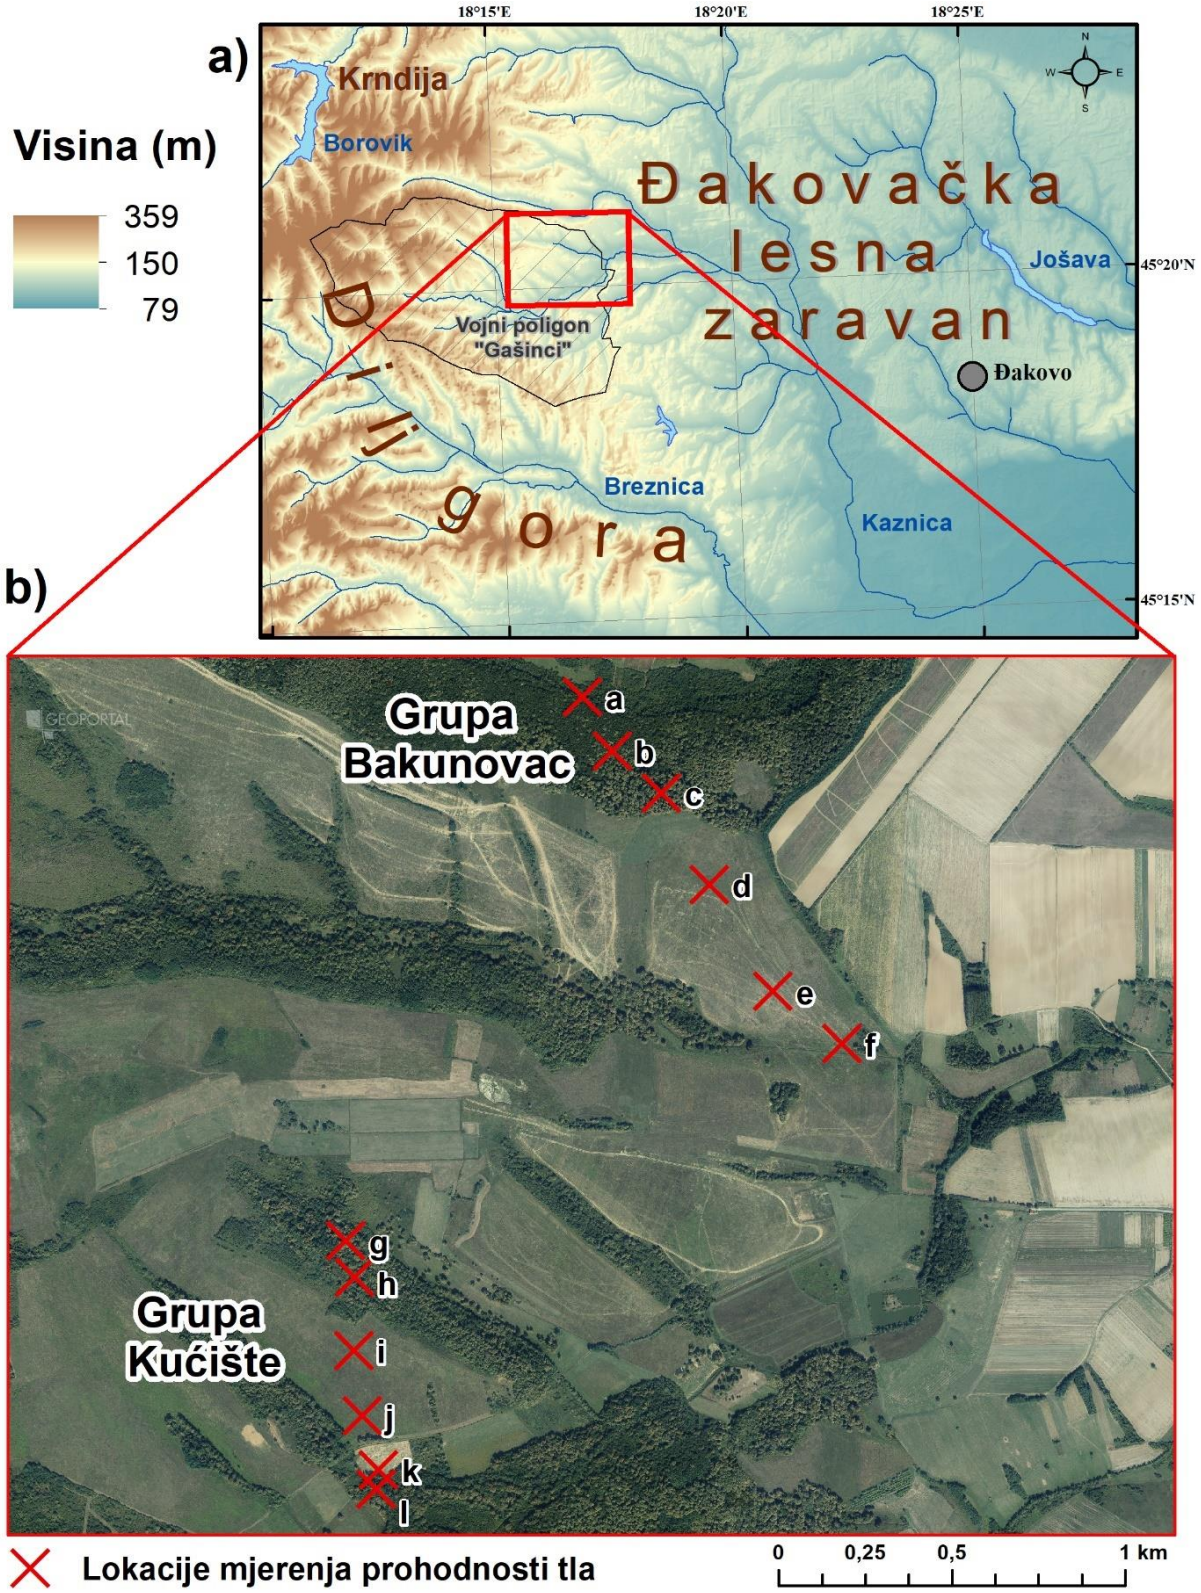

Sl. 38. a) Pregledna fizička karta odabranih lokacija, b) Digitalni ortofoto snimak s lokacijama mjerenja na lokaciji VP „Gašinci“

Izvor ortofoto snimka: https://geoportal.dgu.hr/services/inspire/orthophoto_2017/wms? (20.02.2020.)

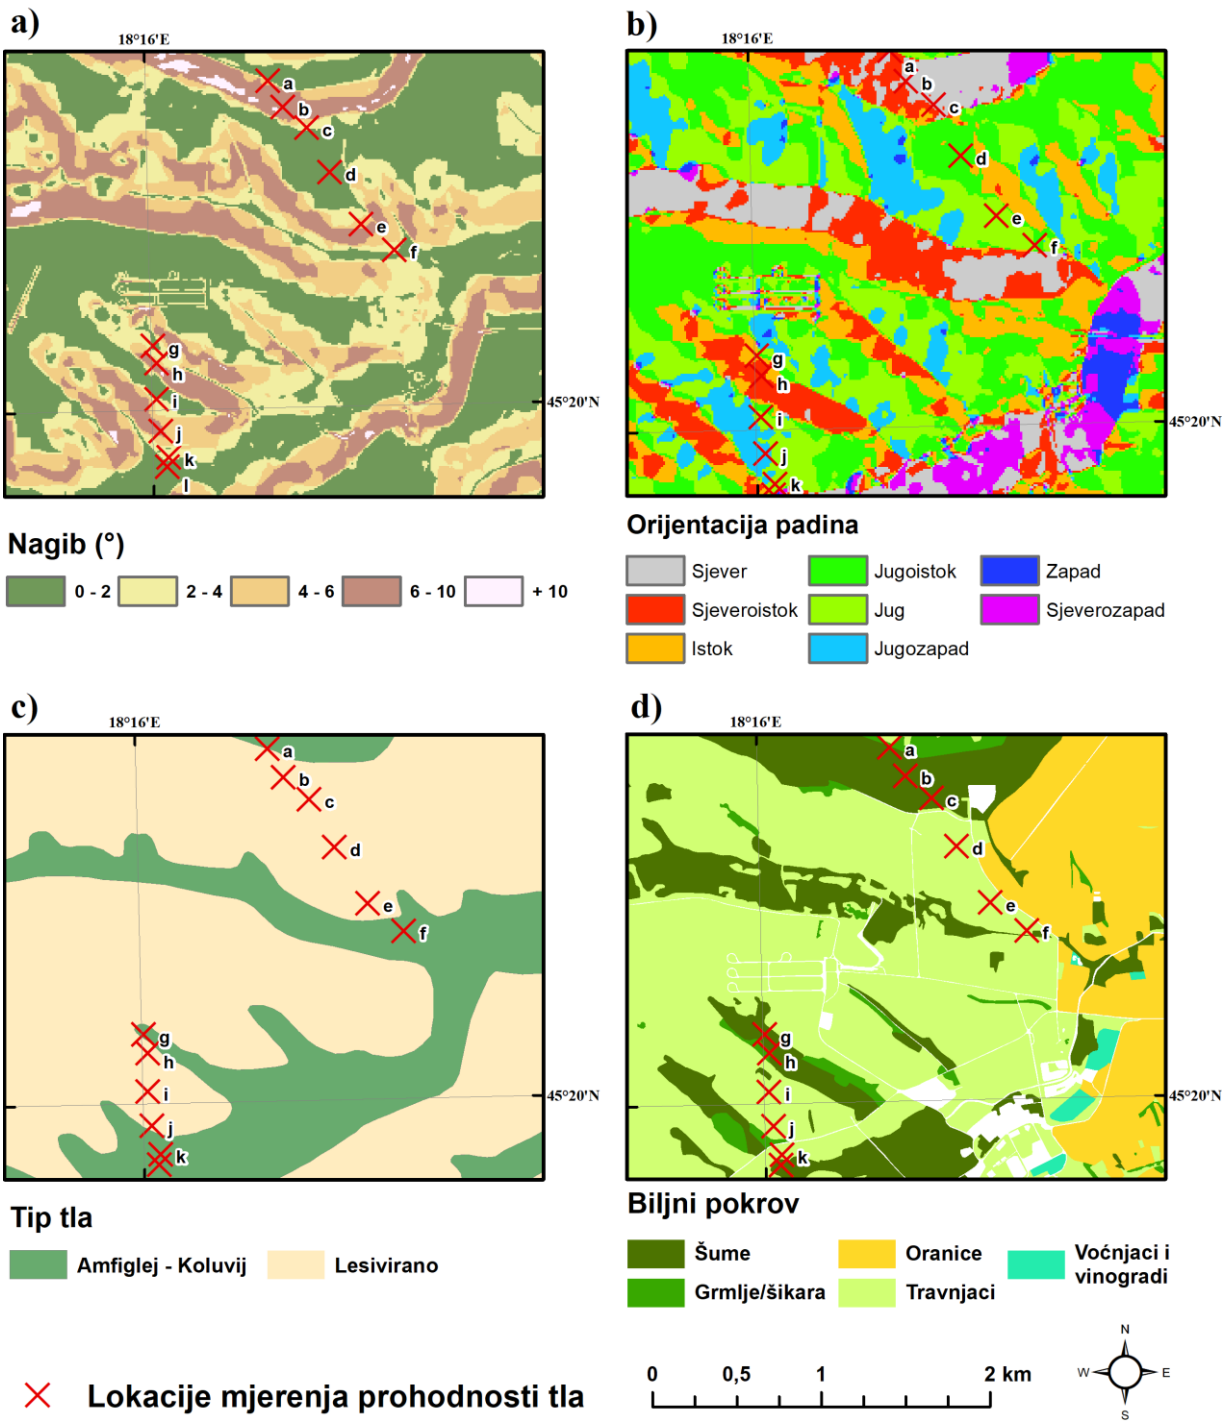

Sl. 39. Lokacije mjerenja prohodnosti tla prema: a) nagibu, b) orijentaciji padina, c) tipu tla i d) biljnom pokrovu

Tab. 6. Lokacije mjerenja prohodnosti tla prema nagibu i orijentaciji padina, tipu tla i grupi tla prema USCS, TIV i biljnom pokrovu

	ID lokacije	Nagib (°)	Orijentacija padine	Tip tla	Grupa tla prema USCS	TIV	Biljni pokrov
Grupa Bakunovac	**a**	5.7	SI (24°)	Lesivirano	CL	7.1	Šuma
	b	8.2	S (20°)	Lesivirano	CL	7.3	Šuma
	c	2	SI (41°)	Lesivirano	CL	6.8	Šuma
	d	1.3	JI (120°)	Lesivirano	CL	8.9	Travnjak
	e	4	J (175°)	Lesivirano	CL	8.1	Travnjak
	f	2	JI (157°)	Amfiglej	CH	7.2	Travnjak
Grupa Kućište	**g**	2	I (78°)	Amfiglej	CH	8.6	Šuma
	h	5.6	SI (46°)	Lesivirano	CL	7.1	Grmlje/šikara
	i	2.7	J (182°)	Lesivirano	CL	7.5	Travnjak
	j	6.4	JZ (211°)	Lesivirano	CL	10.5	Travnjak
	k	2.5	J (188°)	Amfiglej	CH	11	Travnjak
	l	0.8	Z (262°)	Amfiglej	CH	14.8	Šuma

3.2.2.4.1. Mjerenje nosivosti tla digitalnim konusnim penetrometrom

Tijekom 35 dana na odabranim lokacijama u navedenim razdobljima provedena su mjerenja nosivosti tla digitalnim konusnim penetrometrom (DKP). Za provedbu mjerenja nosivosti tla odabran je DKP - „Penetrologger“ tvrtke Eijkelkamp (Sl. 40. i Sl. 41.). DKP-om se mjere prodirne značajke tla tijekom utiskivanja konusa u tlo (sila u MPa), čime se može utvrditi kapacitet nosivosti tla za prolazak vozila. Rezultat mjerenja je KI tla do dubine 80 cm. Instrument mjeri silu otpora prilikom prodiranja konusa pri rezoluciji dubine od 1 cm pri točnosti od $1x10^{-6}$ MPa. Vršna vrijednost koju instrument može izmjeriti iznosi 5 MPa. Mjerenje je provedeno tipom konusa sa površinom baze od 2 cm^2 i kutem vrha konusa 30° (sukladno ASAE S 313.1). Nominalna brzina utiskivanja konusa u tlo iznosila je 2 cm/sec. Na

svakoj lokaciji pri jednom mjerenju izvršeno je pet ponavljanja (*Penetrologger*, 2013). Kao referenta vrijednost za pojedinu lokaciju uzeta je prosječna vrijednost dobivenih rezultata. Prostorni obuhvat same lokacije mjerenja zahvaćao je prostor površine 20 m^2, što odgovara polumjeru od oko 2.5 m od točno definirane lokacije. Sveukupno za potrebe izrade doktorske disertacije izvršeno je 2100 ispravnih mjerenja (po 5 mjerenja na 12 lokacija provedenih sveukupno u 35 dana).

Prije same provedbe *in situ* mjerenja (Sl. 42.) na uređaj je pomoću pripadajućeg računalnog programa „PenetroViewer 6.08“ unesen plan mjerenja s definiranim lokacijama mjerenja. Nakon završetka mjerenja spajanjem na stolno računalo podaci mjerenja su učitani u „PenetroViewer 6.08“, te radi daljnje statističke obrade i analize izvezeni u Microsoft Excel program.

DKP zajedno sa standardnim setom za ispitivanje tla sadržava (vidi Sl. 40.):

1. Vodootporno kućište
2. Ublaživač udaraca
3. Dvodijelnu šipku
4. Konus
5. Ploču za referenciranje dubine mjerenja (Sl. 41.)
6. Komunikacijski priključak
7. GPS antenu
8. LCD zaslon
9. Upravljačku ploču
10. Libelu
11. Električki izolirane ručke
12. Baždar konusa (Sl. 41.)

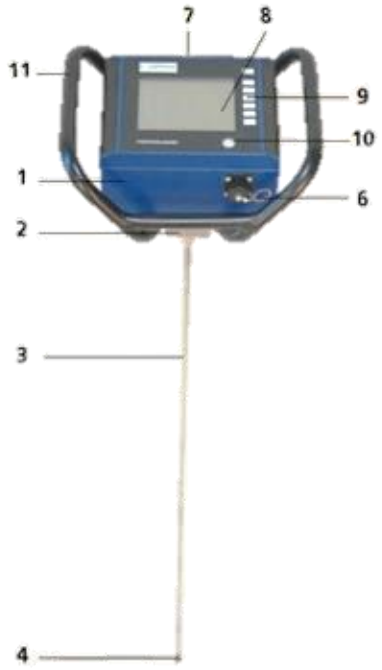

Sl. 40. Digitalni konusni penetrometar

Izvor: *Penetrologger* (2013)

Sl. 41. Digitalni konusni penetrometar s popratnom opremom

Izvor: *Penetrologger* (2013)

Sl. 42. *In situ* mjerenje digitalnim konusnim penetrometrom

Autor: Hrvoje Heštera (27.02.2019.)

3.2.2.4.2. Mjerenja vlažnosti tla sondom

Tijekom 35 dana na odabranim lokacijama u navedenim razdobljima provedena su mjerenja vlažnosti tla sondom za mjerenje vlažnosti tla „ML3 ThetaProbe“(Sl. 43.).

Sl. 43. Sonda za mjerenje vlažnosti tla ML3 Theta Probe

Izvor: *Delta-T Devices* (30.10.2020.)

Za rad u terenskim uvjetima sonda se spaja na kućište DKP-a koji zapisuje rezultate mjerenja. Udio vlažnosti tla sonda mjeri na osnovu provodljivosti struje između četiri metalne igle koje se utiskuju u tlo. Rezultati mjerenja vlažnosti su unutar rezolucije od ±1 % volumnog udjela vode u tlu (*User Manual for the ML3 ThetaProbe*, 2013). Mjerenja vlažnosti tla provedena su na dubinama od 1 cm, 15 cm, 30 cm i 45 cm (Sl. 44.). Za provedbu mjerenja vlažnosti tla bušene su rupe ručnim alatom – svrdlom (Sl. 45.) do navedenih referentnih dubina. Kao i kod mjerenja KI prostorni obuhvat same lokacije mjerenja zahvaćao je prostor površine 20 m^2, što odgovara polumjeru od oko 2.5 m od točno definirane lokacije.

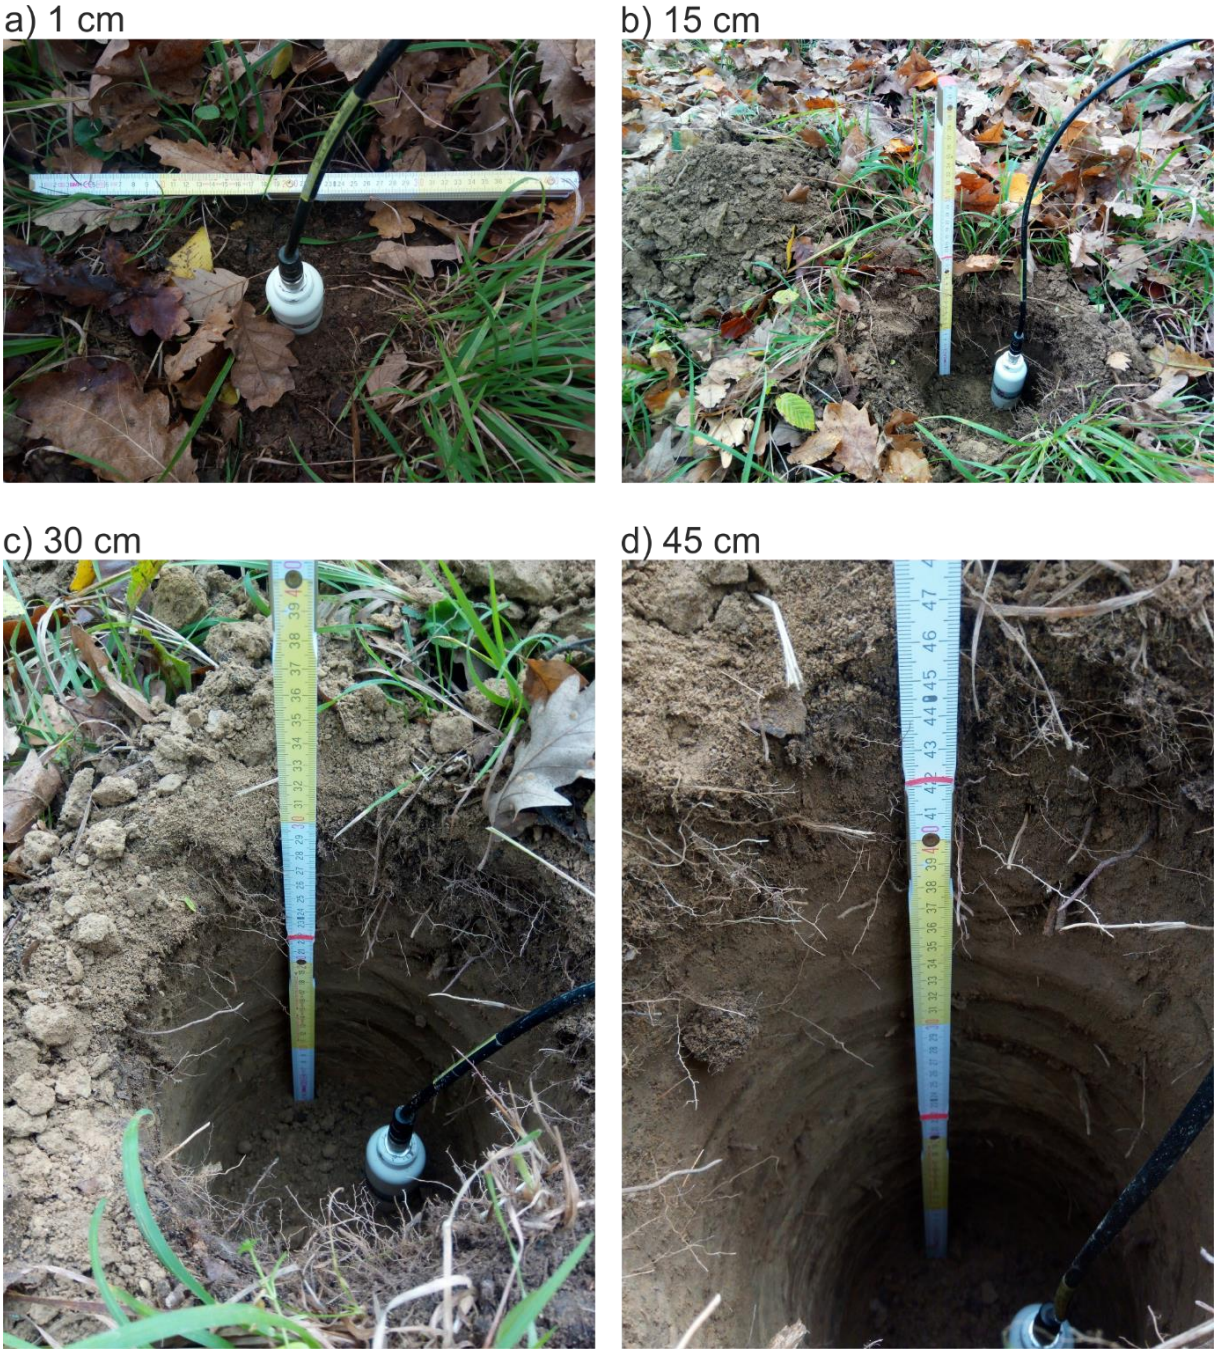

Sl. 44. Mjerenja vlažnosti tla na različitim dubinama tla sondom ML3 ThetaProbe

Autor: Hrvoje Heštera (16.11.2019.)

Sl. 45. Svrdlo za bušenje tla

Autor: Hrvoje Heštera (16.11.2019.)

3.2.2.4.3. Mjerenja temperature tla

Tijekom 35 dana na odabranim lokacijama u navedenim razdobljima provedena su mjerenja temperature tla. Mjerenja temperature tla provedena su na dubinama od 1 cm, 15 cm, 30 cm i 45 cm (Sl. 44.), odnosno zajedno sa mjerenjima vlažnosti tla. Mjerenje je provedeno beskontaktnim ručnim infracrvenim termometrom verzije 320-EN-00 (*Infrared thermometer*, 2020). Prilikom svakog mjerenja na navedenim lokacijama i pripadajućim dubinama provedeno je pet ponavljajućih mjerenja, a zabilježen je srednji rezultat ukupnih mjerenja.

3.2.2.4.4. Mjerenja posmične čvrstoće tla

Za mjerenje nedrenirane posmične čvrstoće tla korištena je krilna sonda tvrtke Eijkelkamp (Sl. 46.), prema normi ASTM 2573. Veličina korištenih krilaca je 20x40 mm. Utiskivanjem sonde u tlo i zakretanjem u smjeru kazaljke na satu pokreću se gornji i donji dio sonde, mjerenje se zaustavlja kada dođe do „sloma“ tla. Očitavanjem vrijednosti na kružnoj skali dobiva se vršna čvrstoća tla. U sljedećem koraku za dobivanje vrijednosti rezidualne čvrstoće tla, na istoj dubini nakon očitanja vrijednosti vršne čvrstoće sonda se polagano zakreće 10 puta i skala se postavlja u nulti položaj. Ponovnim zakretanjem do trenutka sloma dobiva se vrijednost rezidualne čvrstoće tla. Maksimalna vrijednost koju sonda mjeri je 130 kPa. Sondom su mjerene vršna i rezidualna čvrstoća tla na dubinama od 15 cm i 30 cm.

Sl. 46. Krilna sonda marke Eijkelkamp

Autor: Hrvoje Heštera (16.10.2019.)

3.2.2.5. Analiza utjecaja meteoroloških uvjeta na prohodnost tla

Prilikom provedbe analiza utjecaja meteoroloških uvjeta na prohodnost zemljišta korišteni su službeni podaci dobiveni od strane Državnog hidrometeorološkog zavoda za stanje u 2019. godini. U analize su uključeni podaci prikupljeni s osam kišomjernih postaja. Prostorni obuhvat kišomjernih postaja proširen je i izvan područja istraživanja, radi dobivanja točnijih podataka o kretanju količina padalina (Sl. 47.).

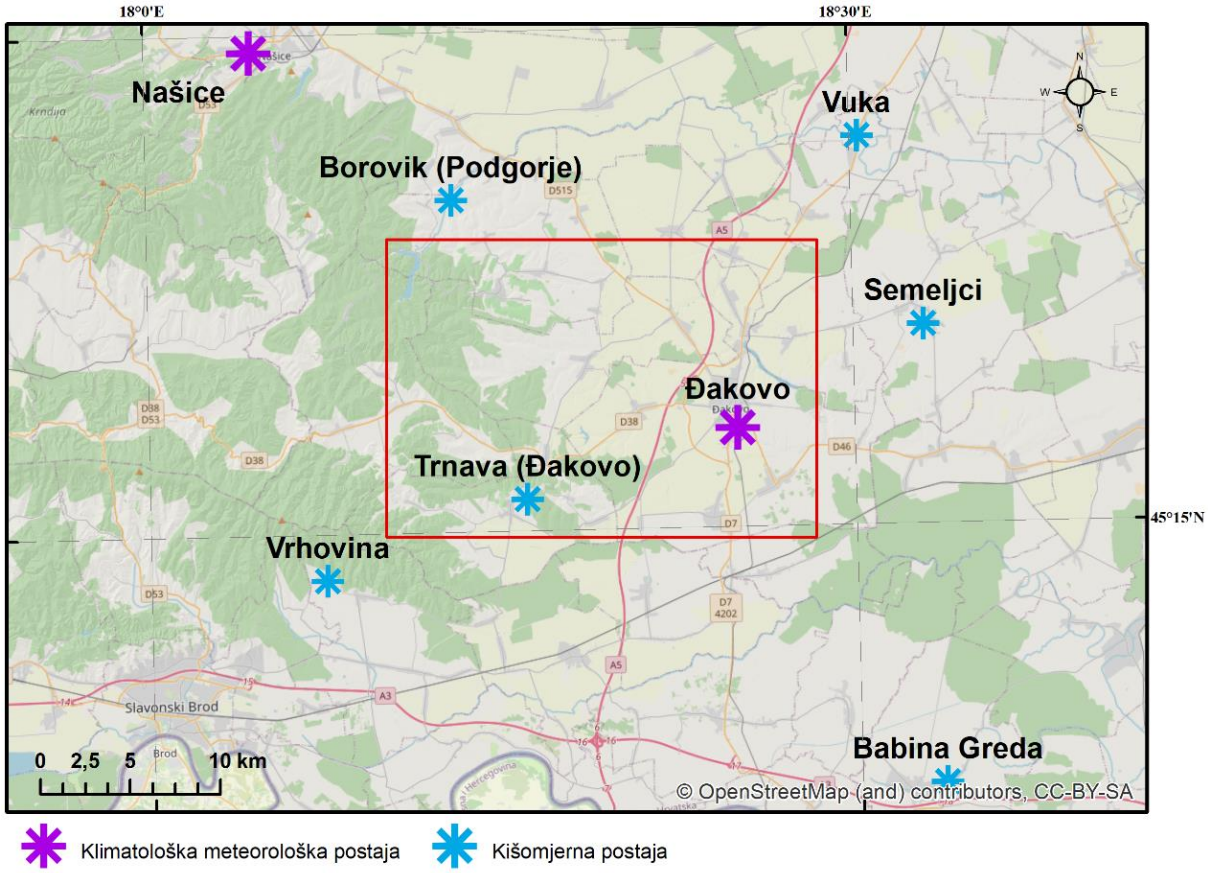

Sl. 47. Klimatološke i kišomjerne postaje DHMZ-a na širem području istraživanja

Izvor kartografske podloge: http://www.OpenStreetMap.org. (preuzeto 2.11.2020.)

Unutar prostora istraživanja nalaze se kišomjerne postaje Đakovo i Trnava, dok su izvan granica istraživanja kišomjerne postaje Babina Greda, Borovik (Podgorje), Našice, Semeljci, Vrhovina i Vuka. Drugi meteo-klimatski podaci nisu uključeni u analize obzirom da na prostoru istraživanja postoji samo jedna klimatološka postaja – Đakovo. Klimatološka postaja Našice je na prevelikom udaljenosti od ruba prostora istraživa (13 km). Jedino se na postaji Đakovo osim padalina prikuplja širi spektar konkretnih meteoroloških mjerenja i zapažanja kao što su: temperatura zraka (3 puta dnevno, maksimalna vrijednost i minimalna vrijednost), relativna vlažnost, smjer vjetra, jačina vjetra, naoblaka i snijeg. Obzirom na veličinu područja istraživanja, orografsku heterogenost prostora i blagi rubni položaj ostali podaci klimatološke postaje korišteni su samo u deskriptivne svrhe.

Podaci o količini padalina korišteni su u svrhu analize prohodnosti tla. Podaci o količinama padalina s kišomjernih postaja interpolirani su pomoću metode inverzne udaljenosti (engl.

inverse distance weighting – IDW). Ova interpolacijska metoda pridaje vrijednosti nekoj lokaciji na način da vrijednost pojedinih točaka na mjerenu vrijednost ima utjecaj obrnuto proporcionalan njihovoj udaljenosti (Environmental Systems Research Institute, 2020). U analizi je korištena potencija 3 reda s veličinom ćelije 66x66 metara. Kreirani su slojevi sa ukupnom dnevnom količinom padalina. Podaci su kumulirani prema klimatološkim godišnjim dobima i na godišnjoj razini. U svrhu korekcije vlažnosti tla na temelju vrijednosti dobivenih terenskim mjerenjima iskorišteni su podaci o količinama padalina unazad 30 dana od datuma *in situ* mjerenja. Normalizacija vlažnosti tla pomoću padalina provedena je putem jednadžbe:

$$\boldsymbol{Vlažnost\ tla}\ (\boldsymbol{vol}\ \%) = \mathbf{1} + \left[\frac{\frac{\mathbf{1}+(\boldsymbol{xy}-\mathbf{107.5}^{*})}{(\boldsymbol{P}\ \mathbf{max} - \boldsymbol{P\ min})}}{(\boldsymbol{P}\ \mathbf{max} - \boldsymbol{P\ min})}\right] \qquad \textbf{Jednadžba 16}$$

Pmax = maksimalna izmjerena količina padalina (mm) na području istraživanja,

Pmin= minimalna izmjerena količina padalina (mm) na području istraživanja,

xy= količina padalina (mm) pripadajuće lokacije dobivena putem izračuna IDW-a,

* srednja količina padalina (mm) na području između grupa „Bakunovac“ i „Kućište“.

U komparativne svrhe tijekom analize temperature tla upotrijebljena je srednja vrijednost temperature zraka izmjerena na klimatološkoj postaji Đakovo. Srednja dnevna temperatura na meteorološkoj postaji je računata prema formuli:

$$\boldsymbol{T_D} = (\boldsymbol{T_7} + \boldsymbol{T_{14}} + \mathbf{2} * \boldsymbol{T_{21}})/\mathbf{4} \qquad \textbf{Jednadžba 17}$$

T_D = srednja dnevna temperatura zraka,

T_7 = temperatura zraka u 7 sati,

T_{14} = temperatura zraka u 14 sati,

T_{21} = temperatura zraka u 21 sat.

3.2.3. Vode

Vektorski podaci o hidrografskim objektima prikupljeni su iz CROTIS baze podataka. Podaci su strukturirani u tri kategorije: vode stajaćice (jezera i ribnjaci), stalne vodotoke i povremene vodotoke, te transformirani u rasterski oblik zapisa. Vodeni objekti koji su izvorno prikupljani u linijskom vektorskom obliku, prije transformacije u rasterski oblik zapisa pretvarani su u poligonalne objekte. Pretvorba je rađena alatom *Buffer* gdje je srednja linija objekta proširena za 0.75 m (ukupne širine poprečnog presjeka 1.5 m). Ova širina zoniranja određena je zbog ostvarivanja kontinuiteta podataka u rasterskom obliku zapisa, kako ne bi dolazilo do tzv. „procjepa“ između ćelija. Svrha ovog proširenja je stvaranje kontinuiteta rasterskog zapisa s ciljem dobivanja realnih rezultata optimalnih ruta kretanja vozila (Stahl, 2005). Terenskim kartiranjem tijekom ljetnog perioda za najnižih vodostaja vodotoka definirane su ishodišne lokacije stalne prisutnosti vode u koritima vodotoka (Sl. 6.). Prisutnost vode u vodotocima tijekom zimskog i proljetnog razdoblja definirana je u skladu s bazom podataka CROTIS baze.

Slijedeća dva poglavlja vezana uz istraživanja hidrografskih pojava i objekata mogla su svojim metodološkim pristupima biti uključena u druge dijelove rada. Budući da su predmetna istraživanja i stanje u prirodi definirani fluvijalnim procesima, metodologije nisu opisane u sklopu poglavlja 3.2.1. Reljef i 3.2.2. Tlo.

3.2.3.1. Morfometrija poprečnih profila vodotoka

Na području terasne nizine i lesne zaravni prisutna je gusta mreža drenažnih kanala. Umjetno prokopane kanale obilježavaju pravolinijski smjerovi pružanja, pri čemu njihova širina većinom ne prelazi 3 metra, a dubina 1 metar. Preliminarnim analizama nagiba reljefa u ravničarskim područjima utvrđen je izostanak informacija sadržanih u izvornim visinskim podacima DMV-a prilikom smanjivanja rezolucije rasterskih podataka. Cilj terenskih mjerenja poprečnih profila vodotoka bio je utvrditi optimalnu rezoluciju rasterskih podataka DMR-a koji će se koristiti prilikom modeliranja terenske prohodnosti.

Terenska mjerenja na 51 lokaciji (Sl. 48.) provedena su uz pomoć laserskog daljinomjera TruPulse 360°R (Sl. 49.) koji je zbog veće stabilnosti montiran na tripod (Sl. 50.). Laser ima mogućnost mjerenja udaljenosti, inklinacije i azimuta. Točnost mjerenja udaljenosti ovim uređajem iznosi ±0.2 m, dok točnost mjerenja kutova iznosi ±0.25° (*TruPulse 360R Specifications*). Izmjera poprečnih profila vodotoka provedena je u periodu između 24. veljače i 28. veljače 2019. godine. Ovaj period je odabran s ciljem dobivanja točnijih rezultata mjerenja uslijed izostanka guste i visoke vegetacije, radi dobivanja što točnijih mjerenja morfometrije objekata. Uređaj je spajan *bluetooth* vezom s pametnim telefonom Doogee S60 Lite, a prilikom mjerenja korištena je Android mobilna aplikacija „LaserSoft MapSmart App“ pomoću koje su pohranjivani podaci mjerenja.

Lokacije mjerenja podijeljene su u dvije grupe. Prva grupa (28 lokacija) je ciljano odabrana na mjestima velikog nagiba terena (više od 25°), što se smatra kritičnim vrijednostima za prohodnost terena. Mjesta mjerenja druge grupe (23 lokacije) definirane su slučajnim odabirom. Na svakom pojedinom mjestu mjerenja dobiven je poprečni profil terena na način da su mjerene prijelomne točke terena. Profili terena sadržavali su od 4 do 8 prijelomnih točaka.

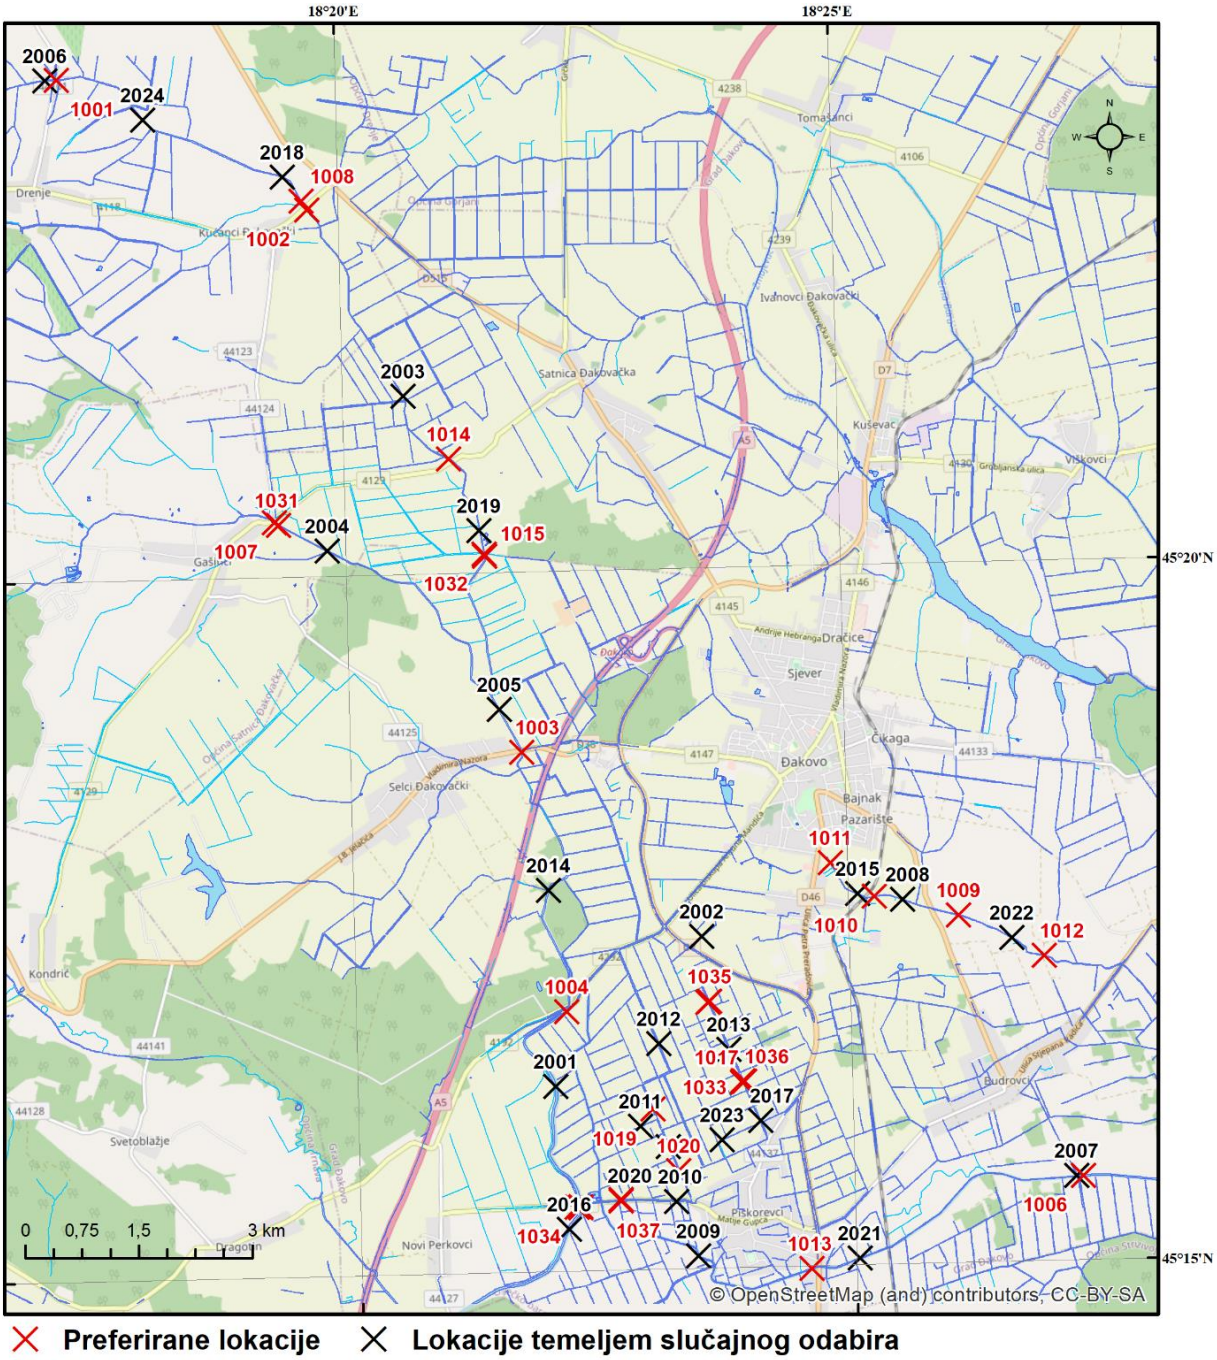

Sl. 48. Lokacije mjerenja poprečnih profila vodotoka laserskim daljinomjerom

Izvor kartografske podloge: http://www.OpenStreetMap.org. (29.09.2020.)

Sl. 49. Laserski daljinomjer TruPulse 360°R

Izvor: https://www.lasertech.com/TruPulse-360-R-Laser-Rangefinder.aspx (19.02.2020.)

Sl. 50. Terensko mjerenje poprečnog profila vodotoka uređajem TruPulse 360°R (lokacija 1014)

Autor: Hrvoje Heštera (26.2.2019.)

Završetkom terenskih mjerenja podaci terenskih mjerenja analizirani su zajedno s podacima prostorne analize u programu ArcMap - verzija 10.5. Kreirani su DMR-ovi u više rezolucija. Iz izvornih podataka DMV (*Državna geodetska uprava*, 2004) stvoren je *Terrain* (engl. *terrain dataset*). Pomoću *Terrain*-a kreirani su rasterski podaci DMR-ova u više rezolucija s ćelijama veličina 10x10, 5x5, 3x3, 1x1 i 0.5x0.5 metara rezolucije. Dobiveni podaci pretvoreni su u poligone. Zatim su stvorene linije poprečnih profila na istovjetnim mjestima gdje su provedena i terenska mjerenja. Analiza je provedena alatom *Intersect* čime su preuzete vrijednosti nagiba terena na mjestima profila zapisane u DMR-ovima.

Prilikom statističke obrade dobivenih vrijednosti nagiba terena dobivene terenskim mjerenjima i prostornim analizama uspoređene su maksimalne apsolutne vrijednosti nagiba lomnih točaka poprečnih profila. Usporedbom mjerenih profila s rezultatima prostornih analiza svih DMR-ova provedena je statistička analiza srednjih odstupanja nagiba na svim rezolucija DMR-a.

3.2.3.2. Prohodnost dna stalnih vodotoka

Mjerenju nosivosti dna vodotoka pristupilo se zbog pretpostavke da vozila uslijed niskog vodostaja mogu prijeći vodotok krećući se okomitom putanjom u odnosu na smjer pružanja vodotoka. Stalne vodotoke na području istraživanja u velikom dijelu godine obilježavaju niske razine vodostaja (do 20 cm), te su slijedno tome i slabog protoka. Morfologija svih stalnih vodotoka rezultat je direktnih antropogenih hidromelioracijskih zahvata. Hidromeliracijskim zahvatima su izvorna dna korita odstranjena, stoga vodotoci teku na podlozi usječenoj u dublje horizonte matičnog pedološkog supstrata. Metodologija provedbe mjerenja nosivosti dna vodotoka istovjetna je metodologiji opisanoj u Poglavlju 3.2.2.4.1 (Sl. 51.). Za razdoblje provedbe mjerenja odabran je ljetni period tijekom kojeg su najniži vodostaji i najmanji protoci vode. Ljetni period je odabran s pretpostavkom da bi tada prelazak vodotoka bi najlakše ostvariv s obzirom da je nosivost tla proporcionalna udjelu vlažnosti u tlu. Mjerenjima na 9 lokacija obuhvaćeni su svi stalni vodotoci prisutni na području istraživanja (Sl. 52.). Na svakoj od lokacija provedeno je pet uzastopnih mjerenja, dok je za rezultat uzeta prosječna vrijednost mjerenja.

Sl. 51. Mjerenje nosivosti dna vodotoka na lokaciji "V"

Autor: Mladen Pahernik (1.7.2019.)

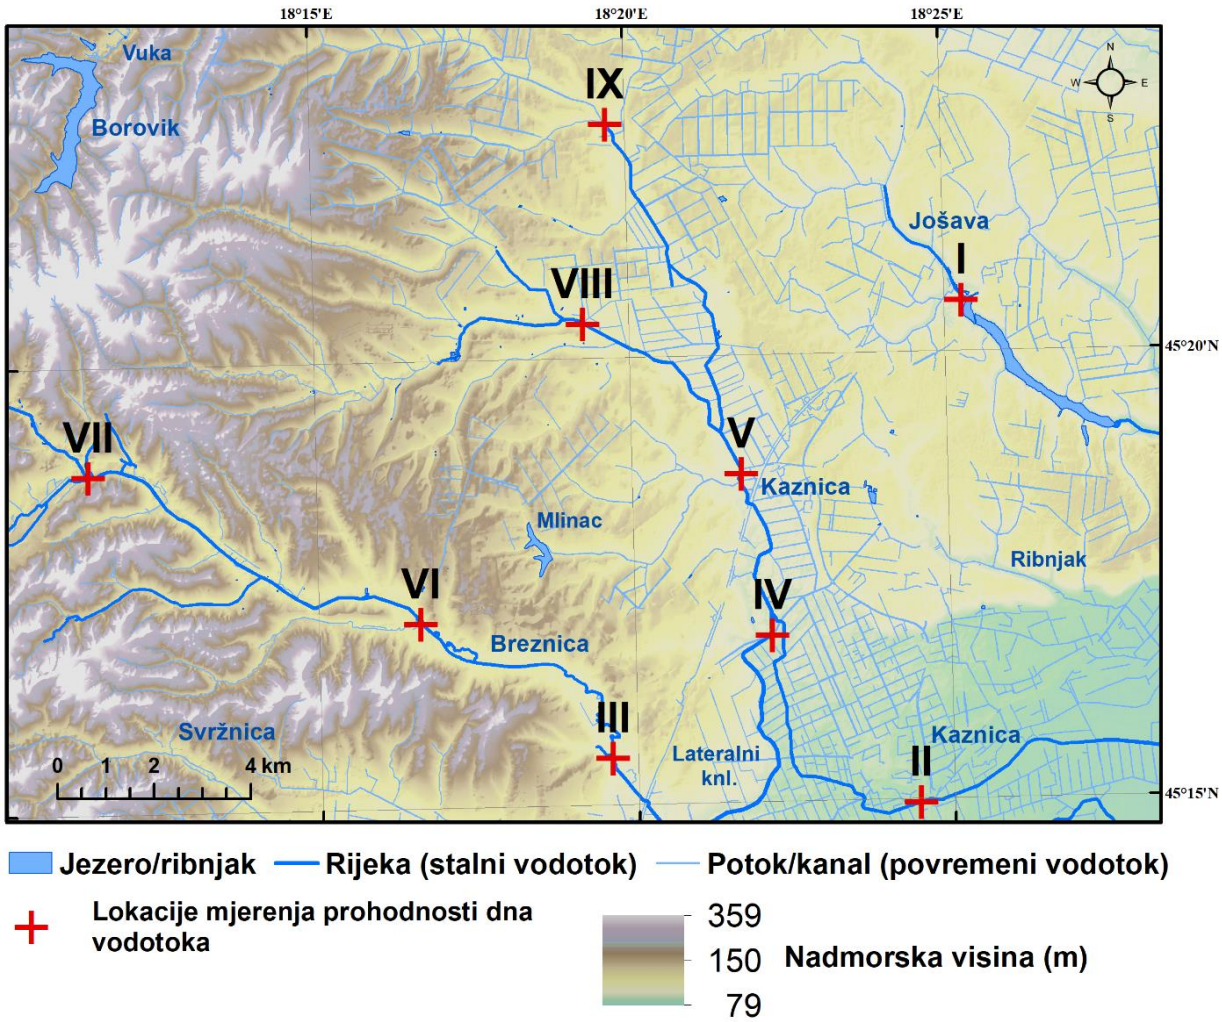

Sl. 52. Lokacije (I - IX) mjerenja prohodnosti dna stalnih vodotoka

3.2.4. Vegetacija

3.2.4.1. Šume

Topološku osnovu prostornih podataka o šumskom pokrovu čini CROTIS baza podataka u vektorskom obliku zapisa. Uporabljeni atributni podaci o šumskim sastojinama dio su evidencije i statistike javnog poduzeća Hrvatske šume d.o.o. (HŠ), zaduženog za gospodarenje šumskim zemljištem i šumama koje su u državnom ili privatnom vlasništvu. Vektorski podaci su preuzeti putem WFS (engl. *Web Feature Service*) servisa sa internog GIS Geoportala HŠ. Strukturiranjem i analizom evidentiranih podataka dobivenih terenskim kartiranjem od strane stručnjaka HŠ kreiran je GIS sloj prohodnosti.

Podaci o šumskoj sastojini unutar baze Geoportala HŠ strukturirani su prema odsjecima. Odsjek je najmanja osnovna površina gospodarskog razdjeljenja šuma unutar veće gospodarske jedinice – odjela. Odsjek se izdvaja prema sastojini koja je dio šume koji ga izdvaja po vrsti, dobi, stadiju razvitka, načinu postanka, uzgojnom obliku i načinu gospodarenja (*Šumarski rječnik*, 27.5.2020.).

Osnovni ograničavajući faktor mobilnosti vozila unutar šume je gustoća stabala, odnosno razmak između stabala. Raspored stabala prilikom definiranja razmaka kreiran je prema najgušćem mogućem rasporedu na jedinici površine, prema shemi trokuta (Rybansky, 2014). Dodatni parametri koji također utječu na definiranje razmaka stabala su: korijenski sustav, srušena stabla, visina grana u odnosu na tlo, nagib reljefa i visina vozila (Capek i dr., 2019). Modeliranje u ovom radu je uopćeno u skladu s dostupnim podacima o šumskoj sastojini. Kako bi se dobila informacija o razmaku stabala na osnovu dostupnih podataka, prvotno je bilo potrebno utvrditi prosječni promjer stabala unutar jednog odsjeka. Prosječni promjer stabala na prsnoj visini (1.35 m iznad tla) izračunat je prema formuli:

$$\boldsymbol{ds = \sqrt{\left(\frac{T}{n}\right)\left(\frac{40000}{\pi}\right)}} \qquad \textbf{Jednadžba 18}$$

ds – srednji promjer stabala (cm),
T – temeljnica (m^2),

n – broj stabala.

Polazišni parametar za izračun srednjeg promjera stabala je temeljnica. Temeljnica je površina poprečnog presjeka u prsnoj visini nekog stabla, dok temeljnica sastojine čini ukupan zbroj površina poprečnih presjeka stabala u m^2 na površini jednog hektara (*Šumarski rječnik*, 27.5.2020.). Temeljnica se računa prema formuli:

$$\boldsymbol{T = \frac{d^2 * \pi}{40000}} \qquad \textbf{Jednadžba 19}$$

d – prsni promjer stabla (cm).

Informacija o prosječnom razmaku stabala unutar jednog odjela izračunata je prema formuli navedenoj u Jednadžbi 20., odnosno prema prikazu na Sl. 53.

$$\boldsymbol{r = \sqrt{\left(\frac{p}{n}\right)} - ds} \qquad \textbf{Jednadžba 20}$$

r – razmak između stabala (m)

p – površina plohe (m^2)

Sl. 53. Shematski prikaz izračuna razmaka stabala u šumama

3.2.4.2. Ostala vegetacija

Ostali tipovi vegetacije unutar GIS modela klasificirani su u sljedeće slojeve: grmlje, živice, oranice, livade, vinograde i voćnjake. Atributno i topološko uređenje baze podataka ostalih tipova vegetacije definirano je upotrebom dvaju izvora podatka. Kao referentna ulazna prostorna i topološka baza podataka korištena je baza podataka pokrova zemljišta prikupljena kroz CROTIS bazu podataka. Podaci o površinama koje pokrivaju grmlje i živice zadržane su u izvornom obliku CROTIS baze. U sljedećem koraku, površine pokrivene oranicama, livadama, voćnjacima i vinogradima unutar CROTIS baze atributno su nadopunjene i topološke korigirane podacima ARKOD[16] sustava. Prostorni podaci načina obrade poljoprivrednih parcela u 2019. godini preuzeti su s mrežnih stranica Agencije za plaćanja u poljoprivredi, ribarstvu i ruralnom razvoju (APPRRR). Temeljem poslanog zahtjeva s popisom identifikacijskih oznakama parcela prema „Službi za identifikaciju zemljišnih parcela ARKOD“ APPRRR-a dobivene su informacije obrađivanih kultura tijekom 2019. godine (Sl. 54.). Prostornom analizom i pridruživanjem podataka o zasađenim kulturama, podacima iz ARKOD sustava površine pod oranicama popunjene su 80 %, livadama 7.8 %, voćnjacima 54.9 % i vinogradima 79.1 %. Površine pod oranicama za koje nisu preuzeti podaci iz ARKOD sustava definirane su kao ozime kulture. Površine pod voćnjacima izvan ARKOD sustava označene su kao nasadi voćnih kultura koje imaju stablo. Livade i vinogradi imaju jednoznačne atributne opise u obje baze podataka, te nisu provedene izmjene.

[16] „ARKOD“ je evidencija uporabe poljoprivrednog zemljišta na području Republike Hrvatske koju u digitalnom grafičkom obliku vodi Agencija za plaćanja u poljoprivredi, ribarstvu i ruralnom razvoju u skladu s člankom 70. Uredbe (EU) br. 1306/2013 Europskog parlamenta i Vijeća (*Pravilnik o evidenciji uporabe poljoprivrednog zemljišta*, 16. str.).

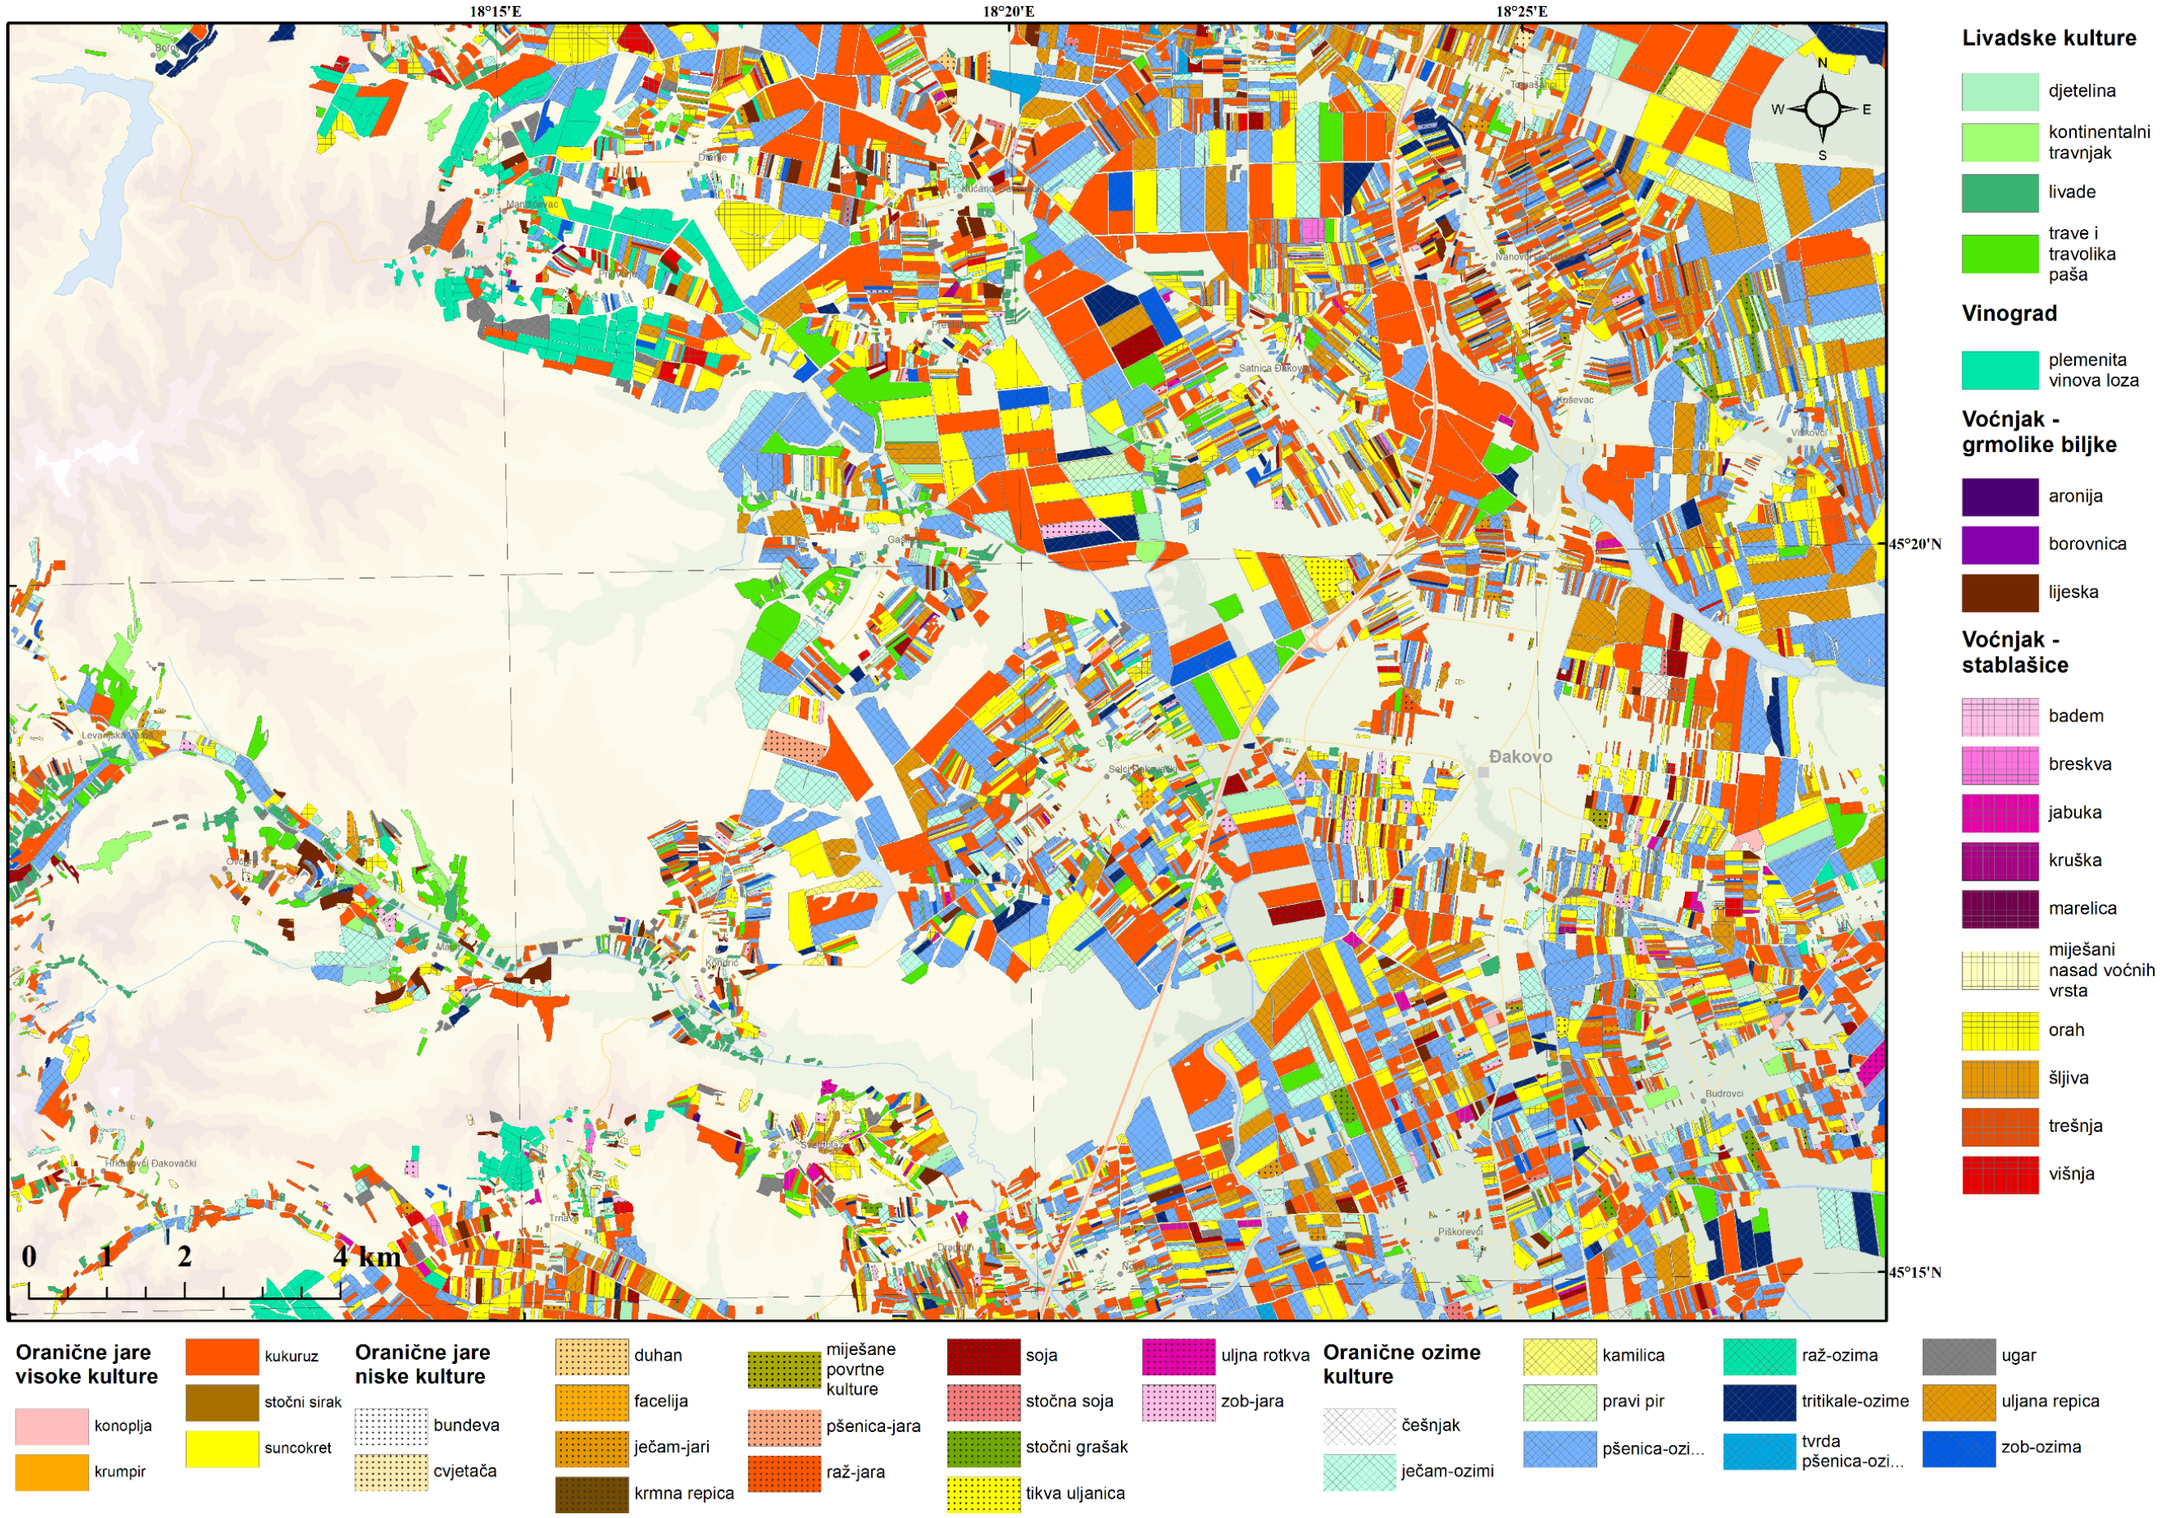

Sl. 54. Kultivirane biljne kulture prema ARKOD-u u 2019. godini

3.2.5. Antropogeni čimbenici

Iako je rad orijentiran na istraživanje fizičko-geografskih čimbenika terenske prohodnosti u krajnje proizvode interpretacije rezultata uključeni su i ostali prisutni objekti na zemljištu kako bi se stvorila realna slika situacije na terenu. Antropogeni objekti u vektorskom obliku zapisa preuzeti su iz CROTIS baze podataka, te transformirani u rasterski oblik zapisa. Ti objekti se odnose na antropogene strukture koje ograničavaju, onemogućavaju ili pospješuju pokret vozila. Kao ograničavajuće antropogene strukture u model su uključena uža područja naselja, odnosno seoske okućnice, urbana stambena okruženja, proizvodna industrijska područja, te odlagališta otpada. Neprohodne prostore čine objekti izgrađeni od čvrstih materijala (kamena, cigle, betona, i dr.). Svim čvrstim objektima prije pretvorbe u rasterski oblik podataka povećana je vanjska tlocrtna površina. Površina poligona je uvećana GIS alatom *Buffer* za vrijednost zone koja je ekvivalentna polovici širine vozila (vidi Tab. 1.) za koje provođena analiza. U model je uključena i postojeća prometna infrastruktura – ceste i željeznice.

3.3. GIS modeliranje pomoću neizrazite logike

Fizičko-geografska obilježja terena i način na koji oni utječu na mobilnost vozila je nemoguće detaljno prikazati (Lessem i dr., 1996). Tradicionalni načini modeliranja koriste jasne, precizne i determinirane pojmove za pojave i fenomene okruženja koje modelima predviđaju. Booleanova logika npr. temelji se na razlikovanju samo dviju vrijednosti – istine (1) ili laži (0) (Sl. 55. a). Takvim načinom modeliranja stvarnost se uokviruje u stroge klase kojima je lako manipulirati, ali je nepreciznost takvih modela značajna (Jiang i Eastman, 2000). Nepreciznost je uzrokovana generalizacijom i umjetnom kategorizacijom vrijednosti (Zimmermann, 1985). Stoga tradicionalno modeliranje nije pogodno za prikaz kontinuiranih vrijednosti gdje ne postoje jasne granice između pojava, ali je očito da one postoje.

Teoriju nejasnih skupova prvi put je uveo Zadeh (1965) gdje je opisao primjenu neizrazite logike u iskazivanju klasičnih tvrdnji. Od vremena objave ovog rada objavljeno je niz knjiga i članaka na temu neizrazite logike koji razvijaju i primjenjuju neizrazitu logiku u raznim znanstvenim područjima (Di Martino i Sessa, 2011; Kainz, 2001; Sousa i Kaymak, 2002; Zhu

i dr., 2001). Neizrazita logika je dio teorije skupova koja je utemeljena na strogim matematičkim načelima i omogućava precizno iskazivanje nejasnih i neizrazito definiranih pojava i fenomena. Pomoću neizrazite logike definiraju se mogućnosti, a ne vjerojatnosti. Pomoću nje se definira mjera pripadnosti određene pojave u skupu podataka. Neizrazljivošću (engl. *fuzzification*) se pretvaraju izvorne vrijednosti pojava i dodjeljuju vrijednosti unutar definiranog skupa. Kod neizrazite logike uvijek je taj skup definiran krajnjim vrijednostima 1 i 0 (Sl. 55. b). Vrijednost 1 predstavlja punu pripadnost neizrazitom skupu, dok pripadnost može opadati sve do 0, kada vrijednost više nije pripadnik neizrazitog skupa (Environmental Systems Research Institute, 2020).

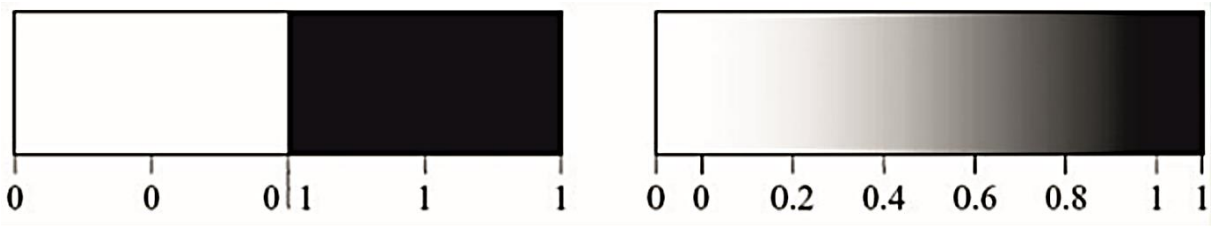

a) Jasna tradicionalna logika *b) Više vrijednosna neizrazita logika*

Sl. 55. Usporedba funkcionalnih principa Jasne tradicionalne logike i neizrazite logike

Prikaz geografskih objekata kao što su prometnice ili građevine koji imaju jasno definirane granice pogoduje primjena tradicionalne Booleanove logike. Nasuprot tome, tlo je tipičan primjer pojave čija svojstva u prirodi nije moguće striktno razgraničiti. Stoga je neizrazita logika moćan alat za modeliranje pojava čija svojstva nije moguće jasno definirati (Zimmermann, 1985).

3.3.1. Strukturiranje čimbenika unutar skupa

Provedba svih operacija strukturiranja čimbenika provedena je aplikacijom ArcGIS Pro, verzije 2.4.3., unutar koje je za automatizaciju i povezivanje procesa alatnih funkcija upotrijebljen vizualni programski jezik *Model Builder*. Za strukturiranje čimbenika usporenja unutar pojedinog skupa prema načelima neizrazite logike korišten je *Fuzzy Membership* alat

(Atkinson i dr., 2005; Eastman, 1999; Talhofer i dr., 2015) ArcGIS Pro aplikacije. *Fuzzy Membership* funkcijom transformirani su izvorni rasterski podaci u rasponu vrijednosti između 0 i 1. Ovisno o scenariju i pojedinom čimbeniku intenzitet pripadnosti skupu definiran je algoritmima ili je jednoznačno dodijeljen alatom *Reclassify*. Pripadnost vrijednosti rasterskih podataka provedene su procesom neizrazljivosti (engl. *fuzzification*). U kontekstu TPV čimbeniku kojem je dodijeljen koeficijent usporenja 1, znači da na tom prostoru ništa ne ograničava pokret vozila i ne dolazi do usporenja. U suprotnom scenariju, kada je nekom čimbeniku dodijeljen koeficijent 0, znači da pokret nije moguć i da je teren neprohodan za vozila. Zaključno – dodijeljene vrijednosti koeficijenata raspona od 1 do 0, ekvivalentne su postotku usporenja u odnosu na maksimalnu moguću brzinu kretanja vozila. Npr. ukoliko neki čimbenik ima koeficijent usporenja 0.2, a maksimalna brzina kretanja vozila je 40 km/h, znači da se vozilo tim prostorom može kretati maksimalnom brzinom od 8 km/h (40*0.2).

3.3.1.1. Faktor nagiba reljefa

Koeficijent usporenja uslijed nagiba terena definiran je unutar GIS sučelja pomoću neizrazite logike. Raspon usporenja korespondira s kutom nagiba reljefa koji je naveden u Tab. 7. Prvi broj označava kut nagiba pri kojemu počinje usporavanje vozila, dok drugi broj označava vršni kut nagiba pri kojemu bi došlo do prevrtanja vozila (koeficijent 0). Začetak usporenja vozila indicira s kutom nagiba od 5° (Suvinen, 2006), dok kod Kawasaki B-Force 750i E započinje na 7°. Vršni nagib ovisi od tehničkih obilježja vozila. Temeljem konstrukcije i provedenih tvorničkih testiranja istraženo je i definirano koji je maksimalni nagib koji je vozilo sposobno prijeći. Krajnji ili vršni nagib na zemljištu koje vozilo može svladati, a da pri tome ne dođe do prevrtanja (vertikalnog ili bočnog), uvjetovano je nizom parametara kao što su: osovinski razmak, razmak između kotača i/ili gusjenica, ukupna dužina vozila, centar ravnoteže vozila, brzina kretanja i dr. (Ahlvin i Haley, 1992; Wong, 2001).

Tab. 7. Koeficijenti i parametri usporenja vozila uslijed vertikalne nagnutosti terena

ČIMBENIK USPORENJA – NAGIB TERENA	**Kawasaki B-Force 750i E**	**Land Rover Defender 110**	**BOV Patria**	**Iveco Eurocargo ML 100 E21**	**BTR-50**	**Tenk M-84**
Raspon usporenja (1-0) u odnosu na nagib (°)	**7 - 45**	**5 - 45**	**5 - 35**	**5 - 31**	**5 - 38**	**5 - 30**
DODATNI PARAMETRI DEFINIRANJA USPORENJA USLIJED NAGIBA TERENA						
Prijelomna točka distribucije funkcije grafa usporenja	27	26	21	19	22	19
Raspon agregacije maksimalnih vrijednosti susjednih ćelija	0	1x1	2x2	2x2	2x2	2x2

Stupanj usporenja između kuta nagiba početnog usporenja i vršnog kuta nagiba prevrtanja definiran je korištenjem načelima neizrazite logike kako je prikazano na Sl. 56. Funkcija prikazana linijom grafa opisuje dinamiku vučnih sila uslijed vertikalnog uspona vozila (vidi Sl. 30.).

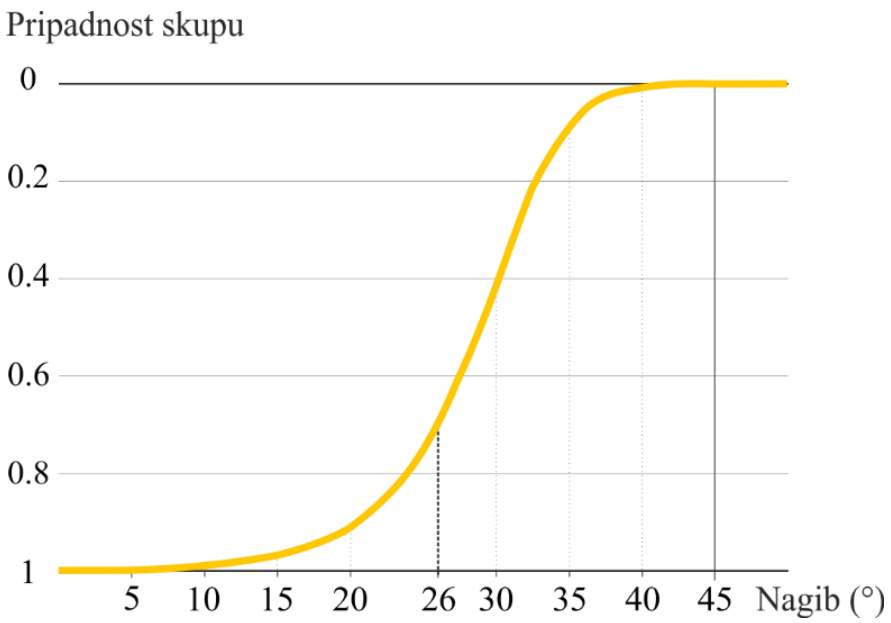

Sl. 56. Prikaz grafa funkcije usporenja Land Rover Defendera 110 u odnosu na nagib terena

Linija koeficijenata usporenja prikazana na Sl. 56. korespondira raspodjeli koeficijenta usporenja uslijed nagiba reljefa unutar GIS modela. Usporenje je definirano upotrebom *Fuzzy Membership* funkcije (prikaz tijeka procesa na Sl. 57.).

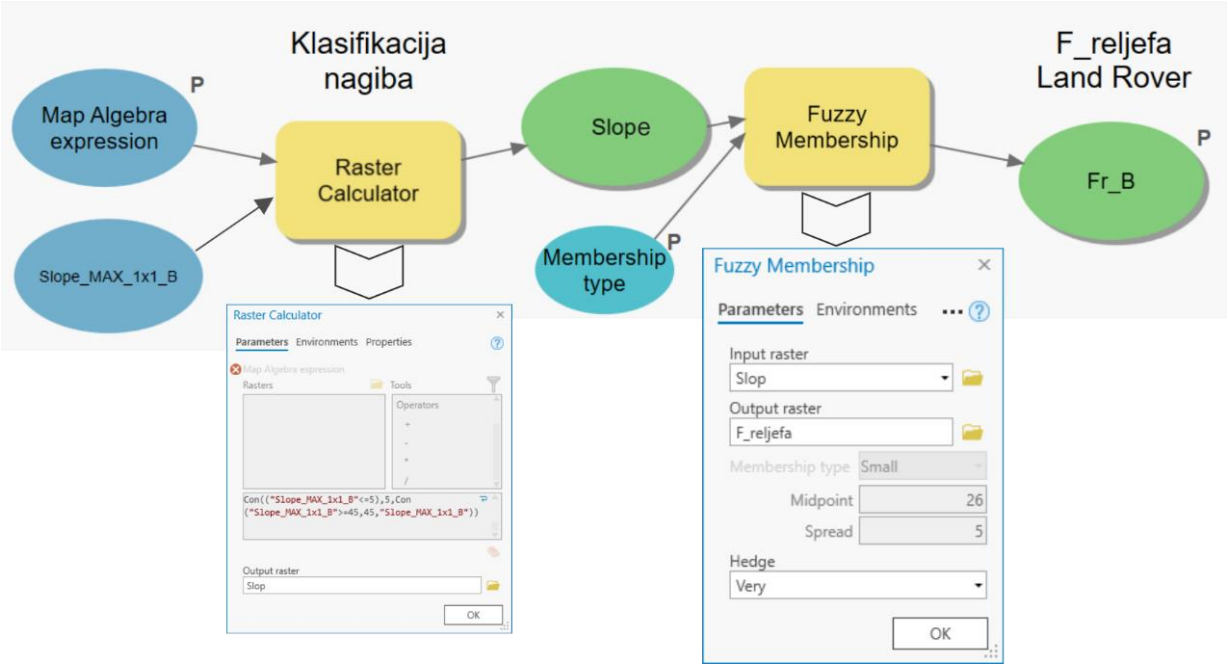

Sl. 57. Prikaz tijeka procesa definiranja stupnja usporenja uslijed nagiba reljefa (za vozilo Land Rover Defender 110) unutar vizualnog programskog jezika *Model Builder* (ArcGIS Pro, verzija 2.4.3)

Fuzzy Membership pretvara ulazne vrijednosti rasterskog podatka unutar raspona vrijednosti od 0 do 1 koje indiciraju jačinu pripadnosti unutar skupa. Pri čemu vrijednost 1 predstavlja punu pripadnost skupu (potpuno prohodno), pripadnost ostalih vrijednosti opadaju do nule (0), pri čemu nula (0) označava da vrijednosti nisu dio skupa (neprohodno) (*ArcGIS 10.5 help*). Prilikom konstruiranja algoritma raspodjele pripadnosti skupu unutar funkcije *Fuzzy Membership*, odabran je tip raspodjele *FuzzySmall*, koji niže vrijednosti dodjeljuje bliže vrijednosti jedan (1). Ovaj tip raspodjele nudi i opciju odabira prijelomne točke linije grafa (*midpoint*) pri čemu je odabrana srednja vrijednost (Sl. 56.) raspona između kuta početnog usporenja i vršnog kuta. Završno – odabirnom prijelomne točke skupa vrijednostima je dodana *hedge* funkcija *Very* kojom su vrijednosti koncentrirane (kvadrirane), a pripadnosti skupu umanjene, odnosno krivulja usporenja je ovom dodatnom modifikacijom strmija.

Prije kreiranja završnog sloja Faktora nagiba reljefa (Fn) provedena je agregacija vrijednosti koeficijenata usporenja. Alatom za prostornu rastersku analizu *Focal Statistics* prikupljene su maksimalne vrijednosti susjednih ćelija. Raspon agregacije maksimalnih vrijednosti zahvaćenih susjednih ćelija (Tab. 7.) definiran je polumjerom kruga čiji je promjer u skladu s razmakom između krajnjih osovina, odnosno u skladu s dužinom nalijeganja gusjenice na podlogu (Tab. 1.). Ovom korekcijom iskorištena je maksimalna preciznost podataka DMR-a i stvarnog utjecaja terena na vozilo u cjelini.

3.3.1.2. Faktor hrapavosti površine

Ova kategorija je izdvojena kao posebna temeljem morfometrije konkretnih geomorfoloških i hidroloških objekta (Tab. 8.). Hrapavost površine utječe na kvalitetu i sigurnost vožnje jer prisutne neravnine utječu na svaki kotač ili gusjenicu zasebno, a ne samo na vozilo u cjelini (Saarilahti, 2002). Neravnine na površini utječu na dinamiku pokreta vozila, te stvaraju vibracije ovjesa vozila (Shoop i dr., 2005). Stoga je hrapavost površine izdvojena kao zasebna kategoriju faktora uslijed kojih dolazi do usporenja vozila i zbog ograničenja koja postoje uslijed digitalnog modeliranja nagiba reljefa. Hrapavost se kvantificirana pomoću odnosa vertikalnih devijacija u odnosu na ravnu površinu pri određenoj udaljenosti. Ukoliko su devijacije velike, površina je neravna, dok su male devijacije znak uravnjenosti površine (Murphy i Randolph,1994).

Povremeni vodotoci (usječeni u lesnu podlogu), obale vodotoka, te nasipi izdvajaju se po svojim oštrim promjenama nagiba (u poprečnom profilu), visine ili dubine. Vozilo prilikom prelaska preko navedenih objekata treba usporiti zbog sigurnosnih razloga, odnosno tehničkih ograničenja koja su determinirana razmakom kotača ili gusjenica, brojem pokretačkih osovina, međuosovinskim razmakom, dužini vozila i klirensom (Dohnal i dr., 2019). Povremeni vodotoci kategorizirani su prema dva scenarija koji odgovaraju prosječnoj razini vodostaja odnosno njihovom isušivanju. Protjecanje i zadržavanje oborinskih voda u povremenim vodotocima tijekom zime i proljeća dodatno otežava prijelaz vodotoka, stoga su ovom periodu pridruženi veći koeficijenti usporenja nego tijekom ljetnog i jesenskog perioda kada dolazi do presušivanja vodnih tokova.

Tab. 8. Koeficijenti usporenja uslijed hrapavosti terena

ČIMBENIK USPORENJA	Kawasaki B-Force 750i E	Land Rover Defender 110	BOV Patria	Iveco Eurocargo ML 100 E21	BTR-50	Tenk M-84
Povremeni vodotok – (ljeto/jesen)	0.2	0.2	0.5	0.1	0.8	0.8
Povremeni vodotok – (zima/proljeće)	0.1	0.05	0.1	0.05	0.2	0.2
Nasip	0.8	0.5	0.5	0.1	0.5	0.5
Obala vodotoka	0.2	0.1	0.2	0.1	0.2	0.2

3.3.1.3. Faktor tla

3.3.1.3.1. Prohodnost tla

Prohodnost tla, odnosno nosivost tla je definirana na sljedeći način: ukoliko je KI manji od KIV (Tab. 1.) tada je tlo neprohodno i dodijeljen je koeficijent usporenja 0, u drugom slučaju ukoliko je KI veći od KIV, tada tlo podržava prelazak vozila i nema usporenja vozila – koeficijent 1. Kod svakog vozila prema FM 5-430-00-1 (1994) postoji u tlu „kritični“ sloj koja predstavlja referentnu dubinu koja podržava prelazak vozila preko tla. Kritični sloj referiran je na osnovu težine vozila i načina pokretanja vozila (Tab. 1.).

Za potrebe kartografskog prikaza definirane su dvije skupine podataka. One odgovaraju krajnjim vrijednostima mjerenja nosivosti tla tijekom godine. Maksimalne izmjerene vrijednosti nosivosti tla odnose se na ljetni i jesenski period, dok minimalne na zimu i proljeće. Provedena mjerenja odnose se na neporemećeno stanje tla. Takvo stanje nosivosti tla odgovara jednom prolasku vozila preko terena (KIV). Obzirom na postojeću korelaciju između nosivosti tla i udjela vlažnosti za kartografski prikaz i optimalne rute kretanja kreiran je sloj prohodnosti tla. Prvotno je izračunat TIV veličine ćelija 25x25 m. Vrijednostima TIV-a pridružene su vrijednosti nosivosti tla dobivene terenskim mjerenjima na referentnim dubinama (15 cm ili 30 cm) nosivosti tla, ovisno o tipu vozila (FM 5-430-00-1, 1994).

3.3.1.3.2. Klizanje vozila i ljepljivost tla

Osim nosivosti tla faktori koji utječu na prohodnost tla i mobilnost vozila na tlu su klizanje i ljepljivost tla (Priddy, 1995; Stevens i dr., 2016; *Terrain Analysis*, 1990). Klizanje kao parametar modela odnosi se samo na kotačna vozila (bez dodatno postavljenih lanaca). Klizanje ne utječe na gusjeničare zbog dobrog prianjanja i dubokog prodiranja gusjenica. Uz poznavanje mehaničkih svojstava tla na klizanje i ljepljivost tla utječe i topografski položaj, te na taj način mogu generalizirati odnosi između udjela vlažnosti tla i njegove pogodnosti za prolazak vozila. Stoga su klizanje i ljepljivost tla podijeljeni prema dubini vodnog lica na visoku topografiju (ispod 120 cm dubine) i nisku topografiju (iznad 120 cm dubine) (FM 5-430-00-1, 1994). U skupinu tala visoke topografije spadaju tla terestričkog i semiterestričkog reda tla te sva hidromeliorirana tla. Karakterizira ih neprisutnost podzemne vode unutar 120 cm dubine tokom cijele godine. To su područja na padinama i vršnim dijelovima grebena. Ovdje nisu prisutni nepropusni slojevi tla, a drenaža je dobra i vrlo dobra (Daigle i dr. 2005). U skupinu tla na područjima niske topografije tla ulaze tla hidromorfnog reda. To su područja depresija, riječnih terasa, donjih dijelova padina i zaravni. U tim područjima prevladavaju uvjeti loše ili vrlo loše odvodnje, te vrlo loše i iznimno loše dreniranosti.

Koeficijenti usporenja kretanja vozila uslijed klizanja i ljepljivosti tla referirani su prema Daigle i dr. (2005). Interpretativni podaci klizavosti i ljepljivosti tla strukturirani su pomoću neizrazite logike prema Tab. 9. Koeficijenti usporenja za klizanje i ljepljivost tla ovise o kombinaciji dviju grupa čimbenika. Prva grupa se odnosi na razinu podzemne vode, odnosno na režimu vlaženja tla, pa prostor možemo podijeliti na visoku i nisku topografiju terena. Podaci su usklađeni prema hidropedološkim podacima prikazanim na Sl. 7. Druga grupa čimbenika odnosi se na USCS grupu tala, jer intenzitet klizanja i ljepljivosti ovisi o plastičnim svojstvima tla. Kombinacijom dvaju čimbenika izraženi su rasponi usporenja.

Tab. 9. Koeficijenti usporenja vozila uslijed mokrog stanja tla

ČIMBENIK USPORENJA (USCS grupa tla) **VOZILA**	**Kawasaki B-Force 750i E** **Land Rover Defender 110** **BOV Patria** **Iveco Eurocargo ML 100 E21**	**BTR-50** **Tenk M-84**
Visoka topografija – KLIZANJE (CL, MH/CH, CH)	0.9	1
Visoka topografija – LJEPLJIVOST (CH - CL/CH, MH/CH - CL)	0.7 - 0.8 - 0.9	0.7 - 0.8 - 0.9
Niska topografija – KLIZANJE (CH - CL/CH, MH/CH - CL)	0.5 - 0.6 - 0.7	1
Niska topografija – LJEPLJIVOST (CH - CL/CH, MH/CH - CL)	0.5 - 0.6 - 0.7	0.5 - 0.6 - 0.7

3.3.1.4. Hidrološki faktor

Svim jezerima, ribnjacima i stalnim vodotocima koji svojom širinom ne omogućavaju prelazak vozila dodijeljen je faktor prohodnosti nula (0). Prohodnost vodotoka uvjetovana je horizontalnim razmakom između obala vodotoka i tehničkim svojstvima vozila. Sva navedena vodena tijela definirana su kao neprohodna za vozila, zbog toga što amfibijske sposobnosti vozila nisu uzimane u obzir. Potrebno je napomenuti da na nekim od promatranih vozila (BOV Patria, BTR-50 i Tenk M-84) postoje izvedbene inačice vozila koje imaju amfibijska svojstva i omogućavaju plovidbu.

3.3.1.5. Vegetacijski faktor

3.3.1.5.1. Prohodnost šuma

Brzina i smjer kretanja vozila po raznim tipovima biljnog pokrova uvjetovana je širinom i dužinom vozila, klirensom i pokretačkom snagom motora. Šumska vegetacija svojom

prisutnošću i morfometrijom predstavlja glavni ograničavajući faktor pokreta vozila po pitanju vegetacije. Determinirajući faktor mobilnosti vozila unutar šume je razmak između stabala (*Terrain Analysis*, 1990). Strukturiranje koeficijenata usporenja zahtijevalo je definiranje dviju graničnih vrijednosti. Neprohodnost (koeficijent 0) i maksimalna ostvariva brzina (koeficijent 1) kretanja šumom definirane su minimalnim razmakom i razmakom uslijed kojeg gustoća stabala više nije faktor za usporavanjem vozila. Rasponi graničnih vrijednosti usporenja navedeni su u Tab. 10.

Tab. 10. Prikaz raspona razmaka stabala unutar koeficijenata usporenja (0-1)

	Kawasaki B-Force 750i E	**Land Rover Defender 110**	**BOV Patria**	**Iveco Eurocargo ML 100 E21**	**BTR-50**	**Tenk M-84**
Razmak stabala (m) unutar raspona usporenja (0-1)	**1.8 - 4.8**	**3 - 7.2**	**5.7 - 11.3**	**5.7 - 11**	**5 - 12.4**	**5 - 14.4**

Prema Tab. 10. donja vrijednost razmaka stabala definirana je formulom:

$$\boldsymbol{R_{min} = ds + \frac{ro}{2}}$$ **Jednadžba 21**

R_{min} - minimalni prohodan razmak stabala za vozilo,

ds – srednji promjer debla na prsnoj visini,

ro – minimalni radijus okretanja vozila.

Minimalni razmak (R_{min}) predstavlja minimalni razmak između stabala koji je potreban da bi se vozilo moglo kretati šumom. Raspored stabala definiran je srednjom gustoćom stabala po jedinici površine, prema idealnom rasporedu stabala u prostoru (shema trokuta) sukladno Rybansky (2014). Manevarske sposobnosti vozila ograničava potrebiti minimalni radijus okretanja (*ro*), na čiju polovinu vrijednosti je dodana srednja vrijednost srednjeg promjera stabala na prsnoj visini (*ds*). Druga granična vrijednost razmaka stabala, nakon koje vozilu stabala ne predstavljaju ograničavajući faktor kretanja, određena je četverostrukom vrijednošću širine vozila (Jednadžba 22.).

$$R_{max} = 4 * \check{s}v$$ **Jednadžba 22**

R_{max} – minimalni razmak stabala potreban za postizanje maksimalne brzine vozila,

$\check{s}v$ – širina vozila.

Četverostruki razmak stabala u odnosu na širinu vozila uslijed idealnog rasporeda stabala po jedinici površine definiran je kao minimalni prostor koji je potreban vozilu da postigne maksimalnu brzinom kretanja u terenskim uvjetima.

Nakon definiranja dviju krajnjih vrijednosti primjenom načela neizrazite logike uslijedila je konstrukcija usporenja vozila pri razmaku stabala unutar raspona donjih i gornjih graničnih vrijednosti prohodnosti. Usporenje unutar raspona koeficijenata 0 i 1 strukturirano je pomoću alata *Fuzzy Membership*, pri čemu je raspodjela pripadnosti unutar skupa definirana linearnom funkcijom (Sl. 58.). Proces obrade i pripreme sloja prohodnosti šumske vegetacije proveden je kroz vizualni programski jezik *Model Builder* (Sl. 59.).

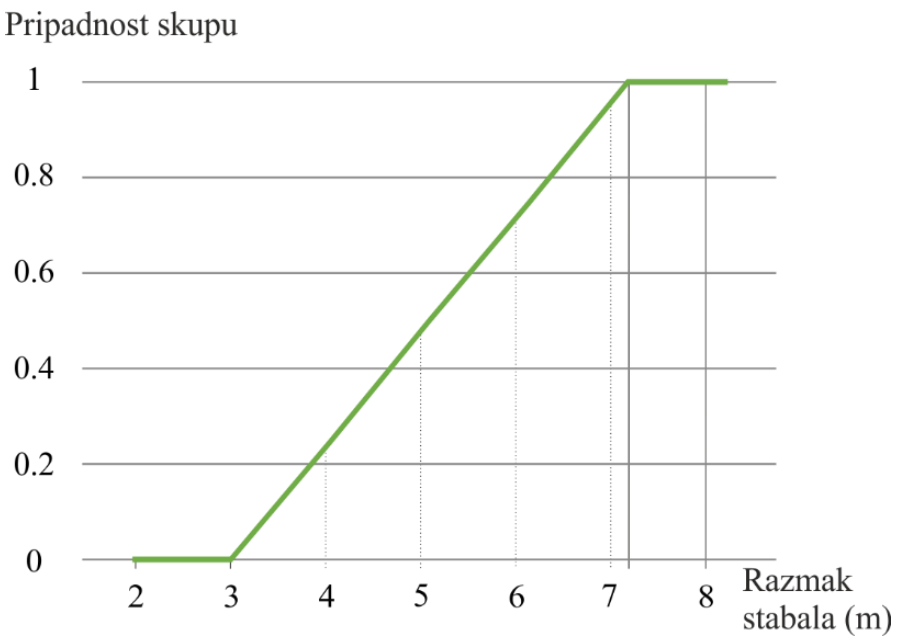

Sl. 58. Prikaz linearne funkcije usporenja Land Rover Defendera 110 u odnosu na razmak stabala

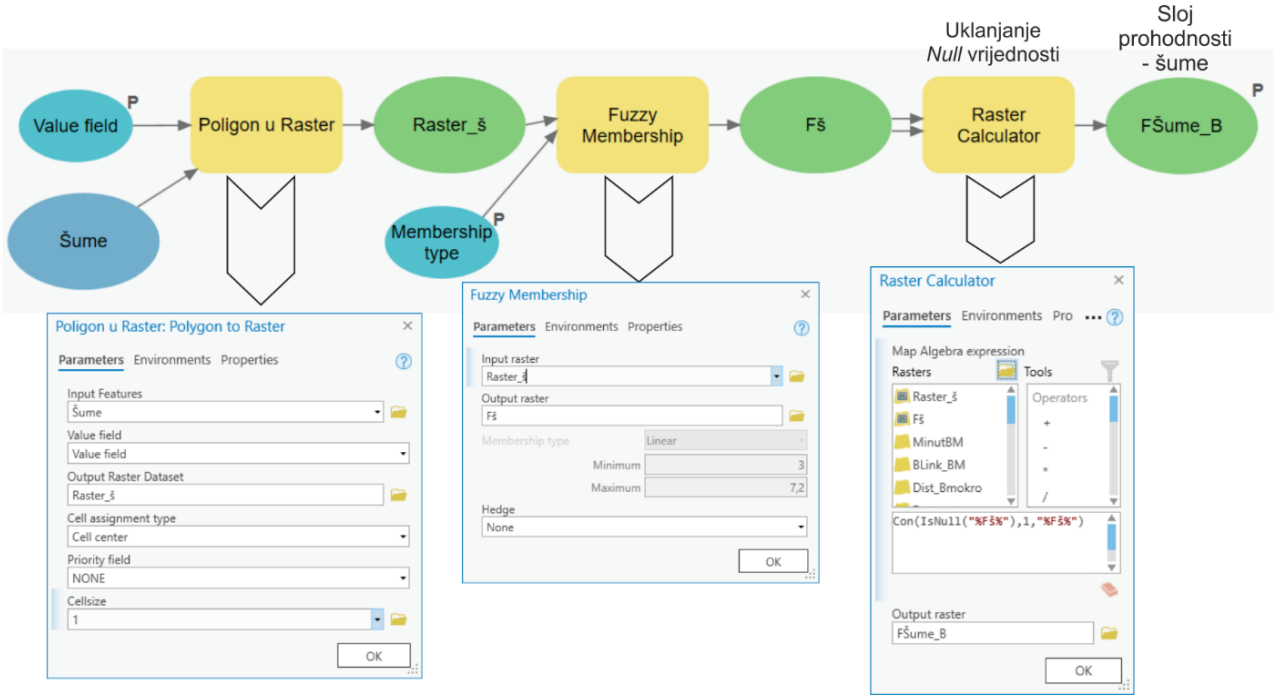

Sl. 59. Definiranje usporenja vozila unutar šumske vegetacije pomoću alata neizrazite logike korištenjem vizualnog programskog jezika *Model Builder*

Prilikom utvrđivanja TPV u šumskoj vegetaciji prohodnost je definirana uz iznimku za vozilo Tenk-84. Modelom je definirano da (ukoliko postoji mogućnost) vozilo manevrira između stabala, te da uslijed nedovoljnog razmaka vozilo može proći šumom na način da ruši stabala (Ahlvin i Haley, 1992; Rybansky, 2020). Sukladno svojoj namjeni i tehničkim obilježjima ova inačica tenka ima i sposobnost rušenja stabala do promjera 60 cm na prsnoj visini (*Tenk M-84*, 1988). Iteracijom opisanih scenarija, neprohodnom šumom za Tenk M-84 definirana je ona koja ima razmak stabala manji od 5 m i čija stabla imaju srednji prosječni prsni promjer veći od 60 cm.

3.3.1.5.2. Ostala vegetacija

Prilikom modeliranja usporenja vozila uslijed prisustva ostalih tipova vegetacije nisu korištene egzaktne metode, već je pri definiranju koeficijenta korišten empirijski pristup dosadašnjih istraživanja. Drugi tipovi vegetacijskog pokrova ne čine značajne zapreke za

prolazak svih tipova vozila, pri čemu su izuzetak vinogradi (BOV Patria, BTR-50, Tenk M-84) i živice (Kawasaki B-Force 750i E) (vidi Tab. 11.). Vegetacija neće onemogućiti pokret vozila, već može:

- vizualno ograničavati vozača prilikom odabira željene putanje gibanja (grmlje, voćnjaci, živice i visoke oranične kulture),
- ograničavati pokret vozila uslijed manevriranja između biljaka (grmlje, vinogradi i voćnjaci),
- pokrivati eventualne neravnine na tlu uslijed kojih dolazi do narušavanja sigurnosti i kvalitete vožnje (livade i oranične kulture).

Oranične kulture su podijeljene obzirom na vegetacijske periode, odnosno vremena obrade i pripreme tla. Koeficijenti usporenja za oranične kulture grupirani su u dva razdoblja, koji odgovaraju stanju vegetacije i tla u periodima zima/proljeće i ljeto/jesen. Jarim usjevima koji se siju potkraj zime i u proljeće dodijeljeni su veći koeficijenti usporenja u periodu zima/proljeće zbog pripremnih radova sadnje (prije svega oranja). Osim navedenog jare kulture dodatno su raspodijeljene u *niske* (maksimalni rast do 1.5 m visine) i *visoke* (preko 1.5 m visine). Visokim kulturama dodani su veći koeficijenti usporenja zbog visine stabljika koje npr. kod kukuruza dosežu i do 4 metra. Krumpir je ubačen u kategoriju *visokih* kultura zbog specifičnog načina kultivacije, kojeg čine pravilne redove humaka tla visine 20-30 cm, stoga mogu narušavati kvalitetu i dinamiku vožnje. Kod ozimih kultura nije rađena distinkcija u vegetacijskim razdobljima. Razlog tome je duži period rasta tih jednogodišnjih kultura, što podrazumijeva duge periode izostanka poljoprivrednih aktivnosti na zemljištu. Prostorni raspored i dodijeljene kategorije po kulturama vidljivi su na Sl. 54.

Od ostale vegetacije, vinogradi su definirani kao neprohodni za određene tipove vozila (Tab. 11.). Vinogradi predstavljaju najznačajniju zapreku za prohodnost širokih vozila obzirom na svoja infrastruktura obilježja (*Military Geographic Intelligence*, 1972; *Terrain Analysis*, 1990). Na prostoru istraživanja kultivirani vinogradi sade se u redove do 2.5 metra razmaka u kojima su postavljeni metalni ili betonski stupovi kroz koje je provedena metalna žica. Ulaskom u vinograd vozilo šire od samih redova sadnje trebalo bi rušiti čvrsto utemeljene stupce. Dodatni problem čine metalne žice u redovima, postavljene u nekoliko nivoa koje bi svojim zaplitanjem u kotače ili gusjenice zaustavile i onesposobile vozilo.

Kao neprohodna vegetacija definirane su i živice, ali samo za vozilo *quad* Kawasaki B-Force 750i E. Jedino ovim tipom vozila ne bi bilo moguće proći kroz gusto raslinje koje čine živice, jer vozač sjedi na vozilu bez zaštite od vanjskih utjecaja.

Tab. 11. Koeficijenti usporenja prema tipu biljnog pokrova i vegetacijskom razdoblju

ČIMBENIK USPORENJA	Kawasaki B-Force 750i E	Land Rover Defender 110	BOV Patria	Iveco Eurocargo ML 100 E21	BTR-50	Tenk M-84
Grmlje	0.2	0.5	0.8	0.3	0.9	0.9
Livada (zima/proljeće)	0.85	0.85	0.85	0.7	0.95	0.95
Livada (ljeto/jesen)	1	1	1	1	1	1
Oranica - ozime kulture (zima/proljeće)	0.9	0.9	0.9	0.8	1	1
Oranica - ozime kulture (ljeto/jesen)	0.9	0.9	0.9	0.8	1	1
Oranica - jare kulture (zima/proljeće)	0.75	0.3	0.75	0.3	0.9	0.9
Oranica - jare kulture (ljeto/jesen)	0.9	0.6	0.9	0.6	1	1
Oranica - jare visoke kulture (zima/proljeće)	0.75	0.3	0.75	0.3	0.9	0.9
Oranica - jare visoke kulture (ljeto/jesen)	0.25	0.2	0.6	0.5	0.75	0.75
Vinograd	0.5	0.3	0	0.2	0	0
Voćnjak - stablašice	0.8	0.5	0.5	0.2	0.8	0.8
Voćnjak - grmolike biljke	0.9	0.8	1	0.8	1	1
Živica	0	0.25	0.5	0.25	0.9	0.9

3.3.1.6. Antropogeni faktor

Svi čvrsto građeni antropogeni objekti koji svojom morfologijom (visina, dužina, širina ili volumen) ograničavaju pokret vozila definirani su kao neprohodno područje. Groblja čine izuzetak od ovog pravila, ali su iz moralno etičkih razloga svrstana kao neprohodno područje (Tab. 12.).

Tab. 12. Koeficijenti usporenja antropogenih objekata i područja

ČIMBENIK USPORENJA	Kawasaki B-Force 750i E	Land Rover Defender 110	BOV Patria	Iveco Eurocargo ML 100 E21	BTR-50	Tenk M-84
Objekti (bazen, el. stupac, groblje, silos, trafostanica, zgrada)	0	0	0	0	0	0
Naselje - urbano područje	0.5	0.25	0.5	0.25	0.6	0.6
Naselje - ruralno područje	0.2	0.5	0.75	0.5	0.85	0.85
Proizvodno područje	0.25	0.25	0.5	0.25	0.5	0.5
Smetlište (odlagalište otpada)	0.1	0.1	0.5	0.1	0.75	0.75
Prometnica (cesta i željeznica)	1	1	1	1	1	1

Faktori usporenja dodijeljeni su i širim stambenim područjima koji čine kontinuirane cjeline između stambenih objekata (Rybansky, 2009). Unutar naseljenih područja izdvojena su ruralna i urbana područja. Urbanim područjima (odnosno gradu Đakovu kao jedinom gradskom naselju u području istraživanja) dodijeljeni su koeficijenti usporenja na temelju prisutnih objekata unutar naselja. U urbanom području pokret vozila mogu ograničavati: ograde raznih vrsta, klupe, spomenici, parkirana vozila, rubnjaci prometnica, kanalizacijski kanali, javna rasvjeta, drvoredi i dr. Seoskim naseljima dodijeljeni su manji koeficijenti usporenja zbog manje gustoće

objekata i sadržaja. Seoska naselja ovog kraja tradicionalno imaju prisutne visoke ograde oko domaćinstava, odvodne kanale (jarke), javnu rasvjetu, pomoćne stambene objekte i dr.

Prometnicama, u koje su uključene sve asfaltirane i makadamske ceste svih širina i kategorija, te željeznicama – dodijeljen je koeficijent usporenja 1, odnosno one čine prohodna područja maksimalne moguće brzine kretanja vozila.

3.3.2. Analiza usporenja vozila

Završetkom definiranja pripadnosti skupu, svakog pojedinog čimbenika uslijedila je završna prostorna analiza u kojoj su pripadajući čimbenici stavljeni u međuodnos. Analizom strukturiranih rasterskih slojeva u GIS analizi korišten je alat *Fuzzy Overlay* (Hofmann i dr., 2013; Kourdian, 2009; Rybansky i dr., 2015; Talhofer i dr., 2015) kojim se izračunava sveukupno usporenje vozila (Jednadžba 23.).

$$\textbf{Usporenje vozila} = [(\boldsymbol{Fn} * \boldsymbol{Fhp} * \boldsymbol{Ft} * \boldsymbol{Fh} * \boldsymbol{Fv} * \boldsymbol{Fa}) + \boldsymbol{Fp}] * \boldsymbol{V_{max}} \qquad \textbf{Jednadžba 23}$$

- Fn – Faktor nagiba terena
- Fhp – Faktor hrapavosti površine
- Ft – Faktor tla
- Fh – Hidrološki faktor
- Fv – Vegetacijski faktor
- Fa – Antropogeni faktor
- Fp – Prometna infrastruktura
- V_{max} – Maksimalna brzina kretanja vozila (40 km/h)

Unutar alata *Fuzzy Overlay* svi čimbenici (unutar oble zagrade Jednadžba 23.) su dovedeni u međuodnos koristeći *Fuzzy Product* funkciju. *Fuzzy Product* je multiplicirajuća padajuća funkcija, odnosno konačni rezultat u slučaju preklopa predstavlja umnožak prisutnih koeficijenata usporenja. U sljedećem koraku izračuna alatom *Raster Calculator* dodan je sloj Fp (koeficijenta 1). Sloj „prometnica“ je dodan neovisno povrh svih slojeva koji su dobiveni

izračunom kako bi se uspostavili topološki odnosi istovjetni onima koji odgovaraju stanju na zemljištu. Završno u sklopu istog izračuna sveukupni dotadašnji izračun pomnožen je pretpostavljenom maksimalnom brzinom kretanja vozila od 40 km/h. Drugi autori koriste različite maksimalne brzine u rasponu od 40 km/h do 90 km/h. Maksimalna brzina kretanja razlikuje se od vozila do vozila i ovisi o tipu vozila (kotačno vozilo ili gusjeničar), odnosno tehničkim specifičnostima izvedbe cjelokupnog pogonskog sklopa, te snage i izvedbe pogonskog motora. U ovom modelu je upotrijebljena relativno niska maksimalna brzina kretanja vozila, čime je istaknut sigurnosni aspekt prilikom terenske vožnje. Sve analize su provedene u vizualnom programskom sučelju *Model builder* (Sl. 60.)

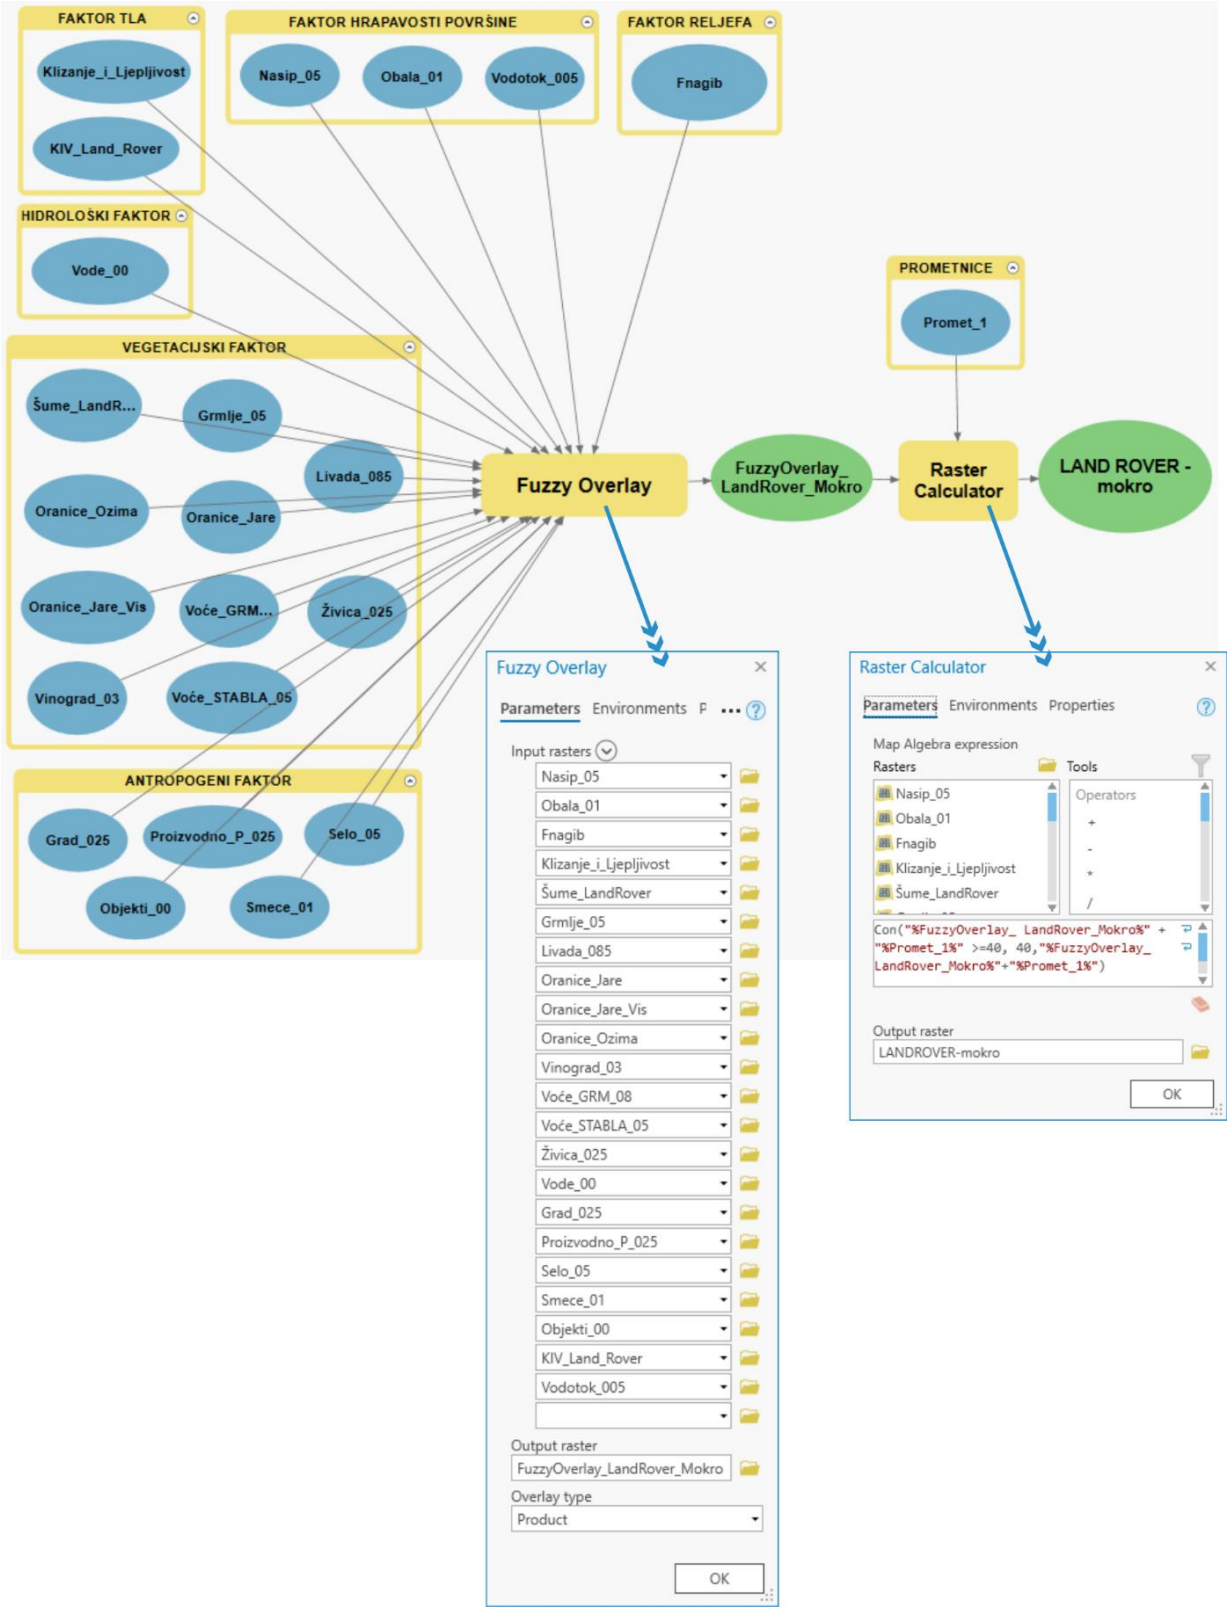

Sl. 60. Programski tijek završne analize usporenja vozila u vizualnom programskom jeziku *Model Builder* (primjer izračuna za vozilo Land Rover Defender 110, scenarij: zima/proljeće – mokro)

4. Rezultati istraživanja

4.1. Faktor nagiba reljefa

Prohodnost uvjetovanu reljefom možemo opisati na osnovu rezultata prostorne analize na sloju nagiba reljefa prikazanih u Tab. 13. Nagibi reljefa raščlanjeni su prema graničnim vrijednostima mobilnosti vozila i dominantnih morfoloških procesa. Područje je dominantno ravničarski kraj, koji s blago nagnutim padinama čini preko 70 % područja. Sukladno navedenom (ovisno o vrsti vozila) ovi prostori predstavljaju minimalno ograničenje mobilnosti vozila. U slučaju vozila Kawasaki B-Force 750 4x4i taj prostor (do 7° nagiba) zahvaća 80.71 % ukupne površine istraživanja. Druga vozila nagib reljefa također ne ograničava na velikom dijelu površine koja obuhvaća između 70.34 % i 71.11 % površine (do 5° nagiba). Usporenja započinju na nagnutom terenu (5° - 12°) koji (ovisno o vozilu) obuhvaća između 22.1 % do 22.2 % površine. Jako nagnuti teren (12°- 32°) koji za većinu vozila predstavlja i krajnje savladive nagibe prohodnosti, varira između 5.75 % i 6.96 % ukupne površine. Vrlo strm teren (32°- 55°), odnosno neprohodan teren (osim od 45° za Kawasaki B-Force 750 4x4i i Land Rover Defender 110) zauzima samo od 0.17 % do 0.32 %, dok strmaca (+55°) ima u statistički zanemarivom iznosu.

Prema Sl. 61. na primjeru vozila Iveco Eurocargo ML 100 E21 4x4 vidljiv je i prostorni položaj glavnih reljefnih prepreka prohodnosti vozila. Najveća područja neprohodnosti (koeficijent 0) čine donje trećine padina u kontaktnim dijelovima s uskim dolinama zapadnih dijelova pobrđa. Osim zapadnih dijelova pobrđa, prohodnost ometaju i onemogućuju brojni umjetni kanali središnjeg i istočnog dijela lesne zaravni te u područjima terasnih nizina. Strmi odsjeci guste mreže umjetnih vodotoka onemogućavaju eventualni poprečni prelazak gotovo svih vozila, a ne samo teškog kamiona koji je prikazan primjerom na karti.

Tab. 13. Razdioba rezultata sloja Faktor nagib reljefa (F_n)

Nagib°	Površina (km^2)[a]	Udio (%) ukupne površine[a]	Površina max 1x1m (km^2)[b]	Udio (%) ukupne površine[b]	Površina max 2x2 m (km^2)[c,d,e,f]	Udio (%) ukupne površine[c,d,e,f]
< 2	207.98	53.12	207.98	53.11	201.26	51.39
< 5[b,c,d,e,f]	281.89	71.99	278.50	71.11	275.48	70.34
< 7[a]	316.02	80.71	312.61	79.82	309.57	79.05
< 12	368.35	94.08	365.57	93.34	363.09	92.71
< 30[f]	390.59	99.76	390.27	99.65	389.84	99.54
< 31[d]	390.77	99.80	390.49	99.71	390.12	99.61
< 32	390.90	99.83	390.68	99.76	390.36	99.67
< 35[c]	391.18	99.91	391.07	99.86	390.86	99.80
< 38[e]	391.26	99.95	391.31	99.92	391.17	99.88
< 45[a,b]	391.34	99.99	391.54	99.98	391.50	99.97
< 55	391.49	100.00	391.62	100.00	391.61	99.99
< 76	391.63	100.00	391.63	100.00	391.63	100.00
Σ*	391.63	100.00	391.63	100.00	391.63	100.00

[a] Kawasaki B-Force 750 4x4i

[b] Land Rover Defender 110

[c] BOV Patria

[d] Iveco Eurocargo ML 100 E21 4x4

[e] BTR-50

[f] Tenk M-84

* Od ukupne površine izuzete su vodene površine

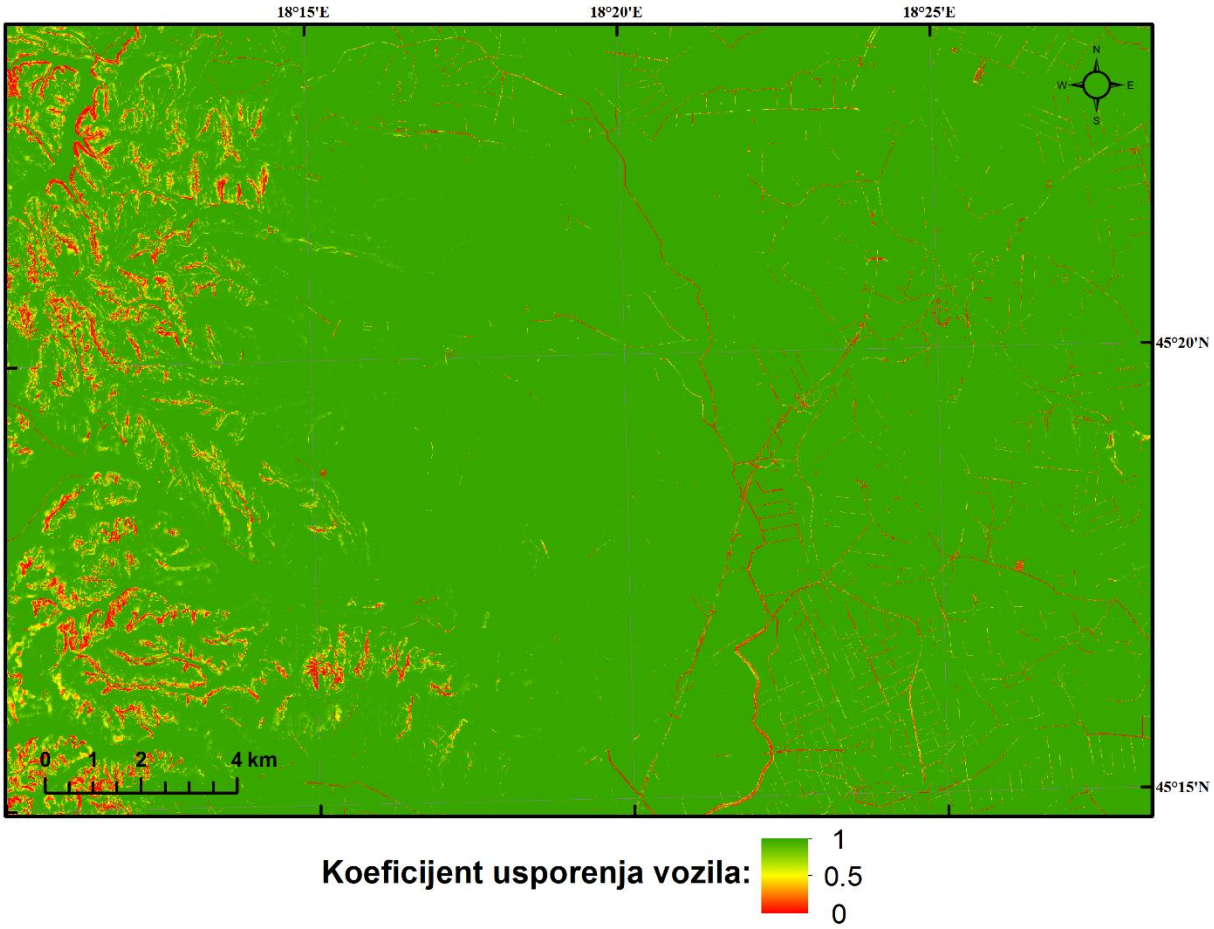

Sl. 61. Koeficijenti usporenja Faktora nagiba reljefa za vozilo Iveco Eurocargo ML 100 E21 4x4

4.2. Faktor hrapavosti površine

Hrapavost površine je faktor kojim je iskazano u kojoj mjeri vozilo usporava zbog neravnina podloge po kojoj se vozilo treba kretati. Ovim faktorom su obuhvaćeni prisutni povremeni vodotoci, obale stalnih vodotoka i jezera, te nasipi (Sl. 62.). Zajedničko obilježje ovih čimbenika je linijska, većinom pravolinijska, izduženost pri čemu svojom prisutnošću ograničavaju pokret vozila, ukoliko bio on bio okomit na smjer pružanja objekta. Kretanje usporedno sa smjerom pružanja (osim kod povremenih vodotoka) ne bi ograničavalo pokret vozila.

Na području se nalazi ukupno 972 km povremenih tokova, od kojih većina (78 % ili 758 km) otpada na umjetno prokopane drenažne kanale u području lesne zaravni i terasnih nizina.

Njihova najveća koncentracija prisutna je na ravničarskom području porječja rijeke Kaznice i nekadašnjeg poplavnog područja sliva rijeke Bić na jugoistoku. Drenažni kanali okružuju poljoprivredne parcele, te se u većini njihovih korita prisutni i gusto obrasli živičnjaci. U kombinaciji sa živičnjacima stvaraju pravolinijske ograde koje okružuju prostrane kultivirane površine. Stoga je povezanost kultiviranih površina ograničena na malen broj (od 1 do 4) uskih mostnih prijelaza koji omogućavaju neometan prolaz vozilima. Ostali povremeni vodotoci pobrđa prolaze prirodno usječenim dolinama, te svojom prisutnošću ne ograničavaju mobilnost vozila.

Obale stalnih vodotoka (81 km) od kojih većinu čine Kaznica, Jošava i Breznica, te obale jezera (najveća Borovik i Jošava) i ribnjaka (45 km) ne predstavljaju značajan fizičko-geografski čimbenik prohodnosti ukupnog područja istraživanja.

Na području se nalazi ukupno 127 km izgrađenih nasipa. Najviše izgrađenih nasipa nalazi se u područjima uz autocestu i uz rijeku Kaznicu, te uz Lateralni kanal.

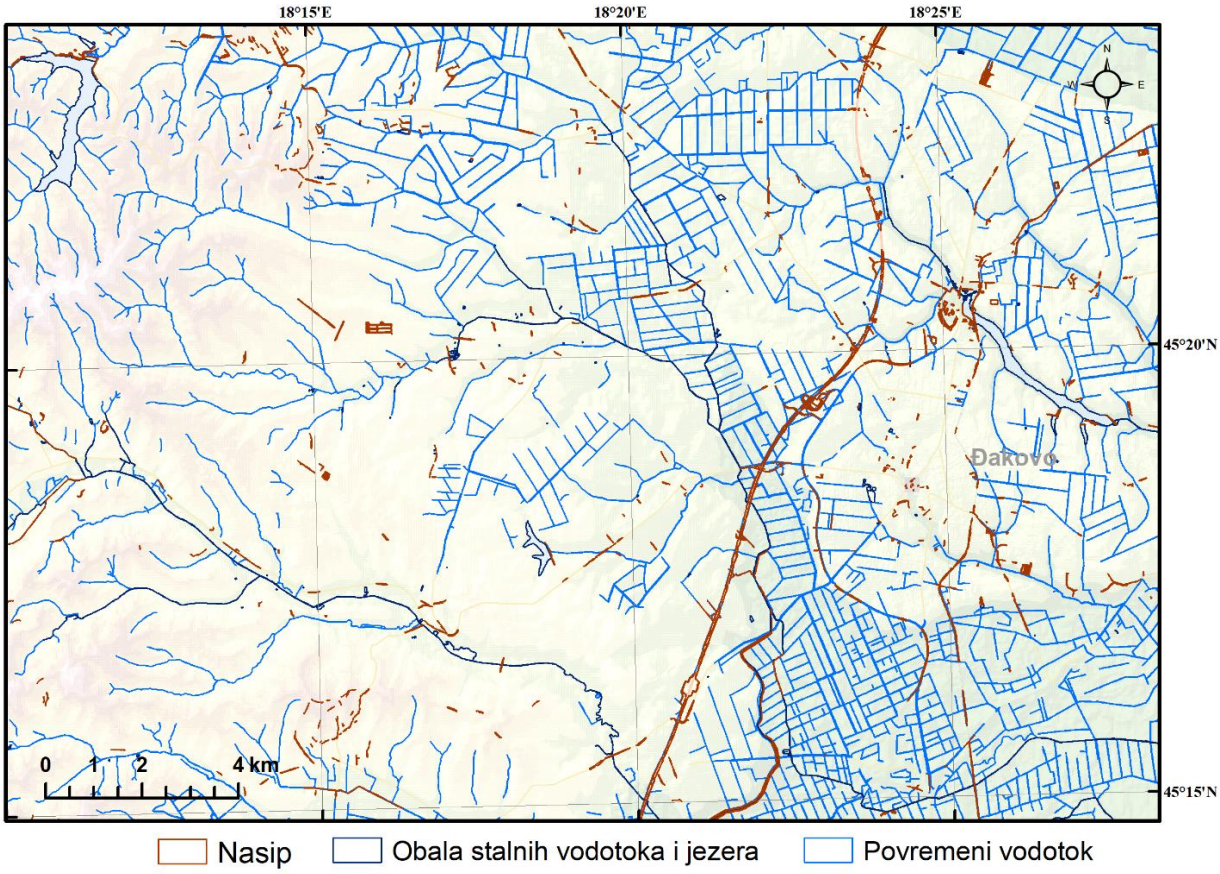

Sl. 62. Objekti obuhvaćeni faktorom prohodnosti – hrapavost površine (F_{hp})

4.3. Faktor tla

4.3.1. Analiza uzoraka tla prema USCS

Osnovna pretpostavka prije provedbe terenskih istraživanja i laboratorijskih analiza bila uvidjeti mogućnost iskorištavanja pedoloških podataka OPK prema USDA klasifikaciji u svrhu izrade karte mobilnosti vozila. Prema rezultatima laboratorijske i prostorne analize iz Tab. 14. je vidljivo da ne postoji jasna veza između dvije klasifikacijske podjele, osim visoke korelacije rezultata između praškaste ilovače (PrI) i gline niske plastičnosti (CL). Razlozi nepoklapanja mogu se tražiti u malom broju uzoraka ili velikoj geološko-pedološkoj heterogenosti prostora (Heštera, 2020).

Tab. 14. Matrica uzoraka (50) preuzetih s istovjetnih lokacija klasificiranih prema USDA teksturnoj klasifikaciji (izvor: OPK) i USCS grupi tla (laboratorijski rezultati)

Izvor: Heštera (2020)

	USDA teksturna grupa (broj i distribucija uzoraka prema USCS)			
USCS grupa tla	G (Glina)	PrG (Praškasta glina)	PrGI (Praškasta glina ilovača)	PrI (Praškasta ilovača)
CL (Glina niske plastičnosti)	1 (50 %)	-	10 (72 %)	29 (91 %)
CH (Glina visoke plastičnosti)	-	1 (50 %)	2 (14 %)	3 (9 %)
CL/CH (Glina niske/visoke plastičnosti)	-	-	2 (14 %)	-
MH/CH (Prah visoke plastičnosti/ Glina visoke plastičnosti)	-	1 (50 %)	-	-
MH (Prah visoke plastičnosti)	1 (50 %)	-	-	-

Zorniji prikaz rezultata analize vidljiv je kada se rezultati postave unutar izvorišnih sustava klasifikacija (Sl. 63. i Sl. 64.). Na Sl. 63. je vidljivo da se gline niske plastičnosti (CL) i gline visoke plastičnosti (CH) prema USCS klasifikaciji rasprostiru preko tri USDA teksturne klase tla. S druge pak strane na Sl. 64. je vidljivo da su svi rezultati USCS klasificiranja smješteni u dvije grupe tala koje spadaju u sitnozrnata tla.

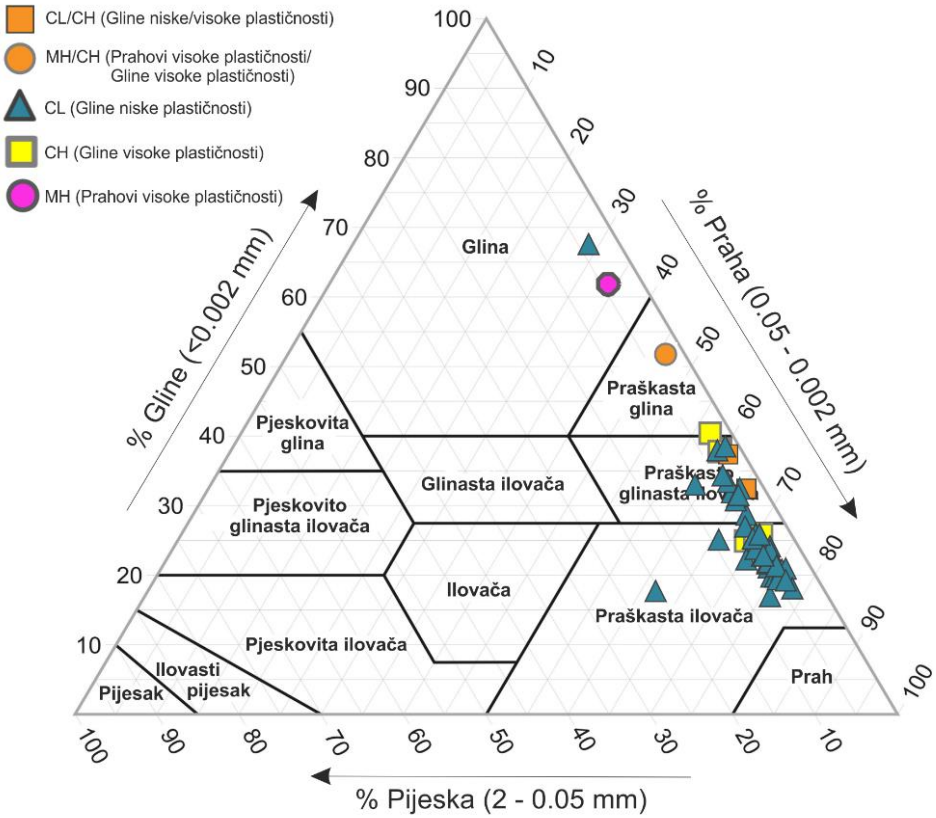

Sl. 63. Distribucija USCS uzoraka nakon prostorne analize prema USDA teksturnom trokutu

Izvor: Heštera (2020)

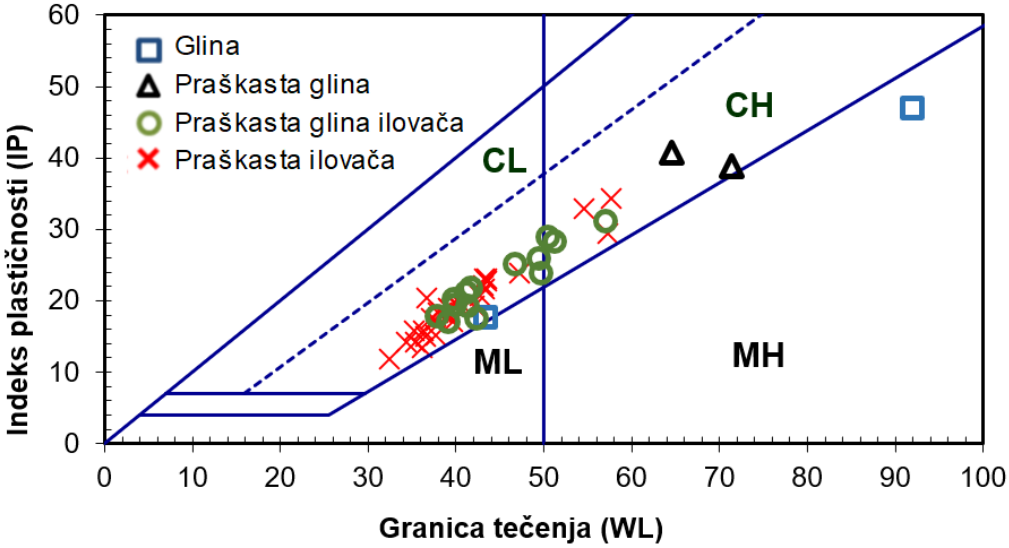

Sl. 64. Distribucija rezultata prostorne analize USDA uzoraka na dijagramu plastičnosti

Izvor: Heštera (2020)

Prema dijagramu plastičnosti sva tla su anorganske gline. Samo je jedan uzorak iznimka – prah visoke plastičnosti (MH) koji je uzet sa ritske crnice – amfigleja (vidi Tab. 14.). Uz navedenu iznimku, možemo reći da su rezultati iznimno jednolični, odnosno spadaju u dvije grupe anorganskih glina.

Uslijed uočenih nepoklapanja dviju klasifikacijskih podjela, nastavljene su prostorne analize uzoraka preko pedoloških jedinica OPK. U rezultatima prostorne analize prikazane preko dijagrama plastičnosti na Sl. 65. možemo vidjeti određene pravilnosti; da su gline niske plastičnosti (CL) zastupljene na svim pedoloških jedinica, te da su rezultati dobro grupirani kod svih pedoloških jedinica, osim kod pedoloških jedinica gdje su amfigleji prevladavajući tip tla (Heštera, 2020).

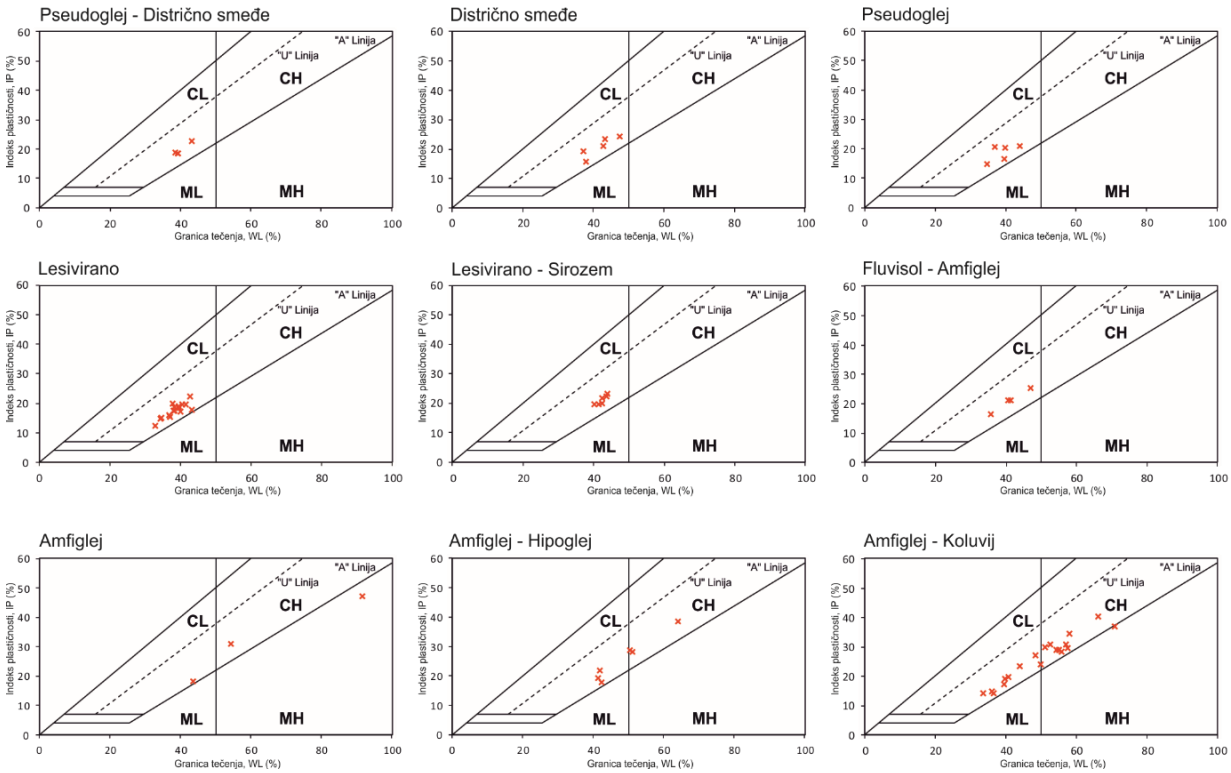

Sl. 65. Dijagrami plastičnosti uzoraka tla prema USCS na kartiranim pedološkim jedinicama

Izvor: Heštera (2020)

Prostorna analiza uzoraka koji se nalaze na aluvijalnim naslagama i amfiglejnim tlima: amfiglej, amfiglej – hipoglej, amfiglej – ritska crnica, i ritska crnica – amfiglej upućuje na najveće rasipanje rezultata prema USCS klasifikaciji tla. Ovi tipovi tla zastupljeni su s glinama niske plastičnosti (CL) i glinama visoke plastičnosti (CH), te na temelju podataka s pedološke karte nije moguće jasno definirati grupu tla prema USCS klasifikaciji. Slijedno tome, daljnjom analizom utvrđeno je da postoji pravilnost i grupiranje uzoraka obzirom na kronostratigrafska obilježja matičnog materijala koji se nalazi u podlozi (Sl. 66.). Zapadnim dijelom područja istraživanja dominiraju procesi odnošenja sedimenata fluvijalnim putem, dok u jugoistočnom i sjeveroistočnim dijelovima dominira procesi akumulacije sedimenata donesenih iz zapadnog dijela. Čestice tla uz vodotoke na zapadnom dijelu područja istraživanja (desna pritoka rijeke Kaznice i potok Breznica) mješavina su porijekla Miocenske i Pliocenske starosti. Tla koja su nastala transportom i taloženjem materijala ovih kronostratigrafskih epoha pripadaju glinama visoke plastičnosti (CH) ili su na samoj granici tečenja (2 uzorka) koja razdvaja grupe tla. Uzrok tome je utvrđeno prisustvo ilita na zapadu, zbog pojave lapora, koji je sastavljen od različitog omjera kalcita i gline, dezintegracijom takvih naslaga nastaje ilitična glina koja je spirana i transportirana prema jugoistoku (Korolija i Jamičić, 1989b).

Ostala aluvijalna tla sjevernog i istočnog dijela područja istraživanja kao matični supstrat imaju lesnu podlogu s prisustvom kaolinitskih glina koje odgovaraju genskom tipu pleistocenskih i holocenskih taložina (Šparica i dr., 1986b). Sva aluvijalna tla s matičnim supstratom tog razdoblja nastanka pripadaju glinama niske plastičnosti (CL) (Heštera, 2020).

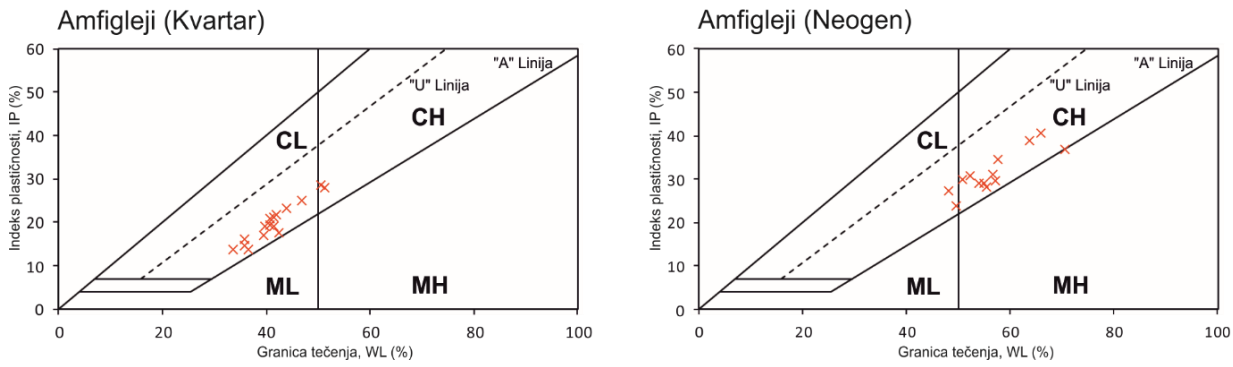

Sl. 66. Dijagram plastičnosti tla uzoraka tla prema USCS na amfiglejnim tipovima tla

Izvor: Heštera (2020)

Od ostalih rezultata analiza (sadržaj organske tvari, porozitet, kapacitet za vodu, kapacitet za zrak, specifična težina volumena i specifična težina tla) dobivenih prilikom izrade OPK, jedino podaci za sadržaj organske tvari su kompletni za čitavo područje istraživanja, ali nije ustvrđena korelacija između udjela sadržaj organske tvari i tipova tla prema USCS klasifikaciji (Heštera, 2020), te se sadržaj organske tvari ne može uzeti kao faktor u svrhu modeliranja i predikcije tipova tla prema USCS klasifikaciji (Gambill i dr., 2016).

4.3.2. Prohodnost tla

Nakon provedene analize načinjena je preliminarna karta prohodnosti tla za vozila (Sl. 67.). Karta je načinjena s ciljem dobivanja općenite slike o mehaničkim svojstvima tla, temeljem koje su planirane daljnja terenska mjerenja i analize. Preliminarna karta prohodnosti tla načinjena je prema rezultatima *Defense Mapping Agency Hydrographic/Topographic Center* (1982) (vidi Tab. 3.). Sukladno provedenoj analizi, poligonima pedoloških jedinica pridodane su pripadajuće prosječne vrijednosti INT za pripadajuće grupe USCS tala. Sl. 67. prikazuje stanje prohodnosti tla u tri različita scenarija za tri različita stanja vlažnosti tla: suho (a), vlažno (b) i mokro (c). Iz karte je vidljivo da u sva tri stanja vlažnosti tla područja pod glinama visoke plastičnosti (CH) imaju najviše vrijednosti nosivosti tla. Područja pod glinama visoke plastičnosti (CH) obuhvaćaju aluvije središnjeg i južnog dijela pobrđa i dijelove terasnih nizina koja u podlozi imaju pleistocenske barske sedimente. Vrlo slična svojstva prohodnosti ima i područje na jugoistoku (ritske crnice) pokriveno mješavinom glina visoke plastičnosti (CH) i praha visoke plastičnosti (MH). Ostala područja pokrivena su glinama niske plastičnosti (CL) i imaju najniže vrijednosti nosivosti tla u sva tri stanja vlažnosti tla. Srednje vrijednosti nosivosti tla, u odnosu na ukupno područje, ima područje zahvaćeno rendzinama i sirozemima (uzorak tla na granici između glina niske plastičnosti (CL) i glina visoke plastičnosti (CH)). Na Sl. 67. (d) je uvećani prikaz karte koji zornije prikazuje primijenjenu kartografsku metodu neizrazite logike. Korištenjem metode neizrazite logike interpretirana je „priroda“ tla, odnosno njegove preklapajuće i neoštre granice između tipova tala.

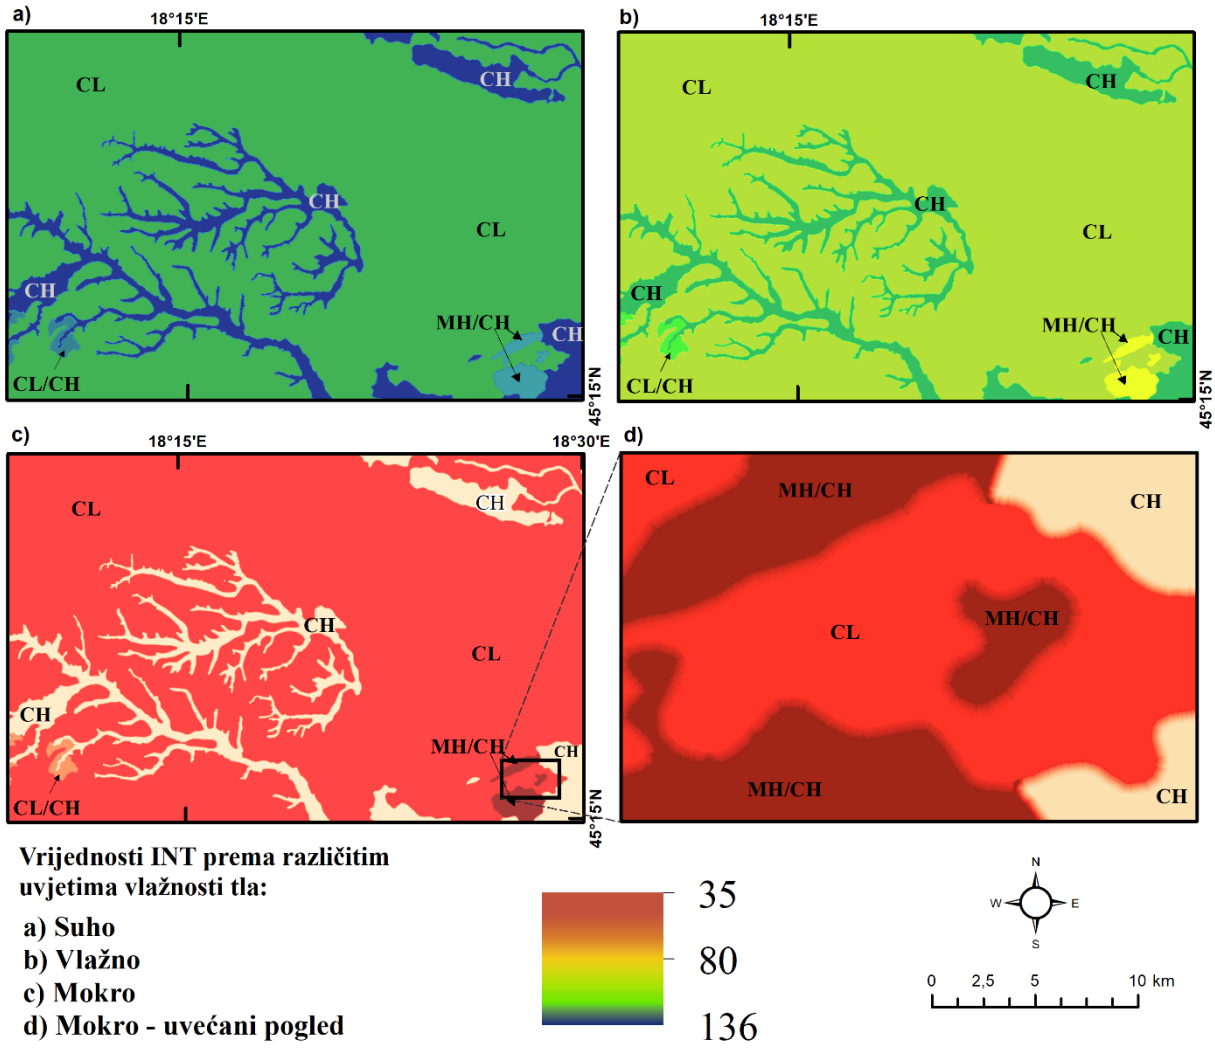

Sl. 67. Karta prohodnosti tla u različitim uvjetima vlažnosti tla izrađena pomoću neizrazite logike

4.3.2.1. Konusni indeks tla

Rezultati mjerenja KI (Sl. 68.) bit će interpretirati i uspoređivani zbirno prema srednjim vrijednostima petodnevnih mjerenja u različitim godišnjim dobima tijekom 2019. godine. Unutar godišnjeg doba uslijedit će interpretacija rezultata po lokacijama koje su razdvojene na osnovu USCS grupe tla, odnosno ovisno o tome da li su u podlozi gline niske plastičnosti (CL) ili gline visoke plastičnosti (CH).

Uvidom u Sl. 68. i usporedbom rezultata dvaju petodnevnih mjerenja KI tijekom **zimskog** perioda[17] razvidna je razlika u iznosima KI krajem zimskog perioda (25. veljače - 1. ožujka) i početkom zimskog perioda (16. – 20. prosinca). Početkom zimskog perioda zabilježeni su viši iznosi KI na svim lokacijama. Očitije razlike u iznosima KI utvrđene su na lesu pokrivenom glinama niske plastičnosti (CL), gdje skokovi KI nastupaju pri dubinama od 20 do 40 cm. Ujednačene vrijednosti KI tijekom zimskog perioda nalazimo u aluvijalnim predjelima glina visoke plastičnosti (CH). Krajem zimskog perioda dnevne promjene KI imale su blagu tendenciju rasta, dok su zamjetne amplitude dnevnih mjerenja zabilježene na lokacijama „e“ i „k“. Početkom zimskog perioda dnevni hod i amplitude nisu bile zamjetne. Sumirajući godišnje rezultate tijekom zimskog perioda vidljivo je da su:

- na glinama niske plastičnosti (CL) zabilježeni rezultatski minimumi KI na „kritičnim“ dubinama tla od 15 cm (lokacije: „b“, „c“, „d“, „e“ i „j“) i na 30 cm dubine (lokacije: „e“, „h“ i „i“),
- na glinama visoke plastičnosti (CH) zabilježeni rezultatski minimumi KI na „kritičnim“ dubinama tla od 15 cm (lokacije: „g“ i „k“) i 30 cm dubine (lokacija: „l“).

Ukupno gledajući, tijekom dva petodnevna mjerenja tijekom **proljeća**[18] zabilježene su najniže razine KI tijekom cijele godine. Od dva navedena mjerenja ističe se mjerenje provedeno u razdoblju između 30. travnja i 4 svibnja kada je KI na gotovo svih lokacijama bio najniži na najvećoj dubini od 80 cm. Početkom proljeća praćenjem dnevnog hoda i amplituda KI jedino su na lokacijama „d“ i „k“ zabilježene značajnije promjene KI, dok su kod ostalih lokacija mjerenja bila poglavito uniformna. Sredinom proljeća, praćenjem dnevnog hoda i amplituda zabilježene su najveće razlike u dnevnim rezultatima, ali samo na lokacijama „d“ i „e“. Dnevne amplitude prilikom mjerenja možemo pripisati poroznosti lesne podloge. Na malim površinama postoje konkavna uleknuća gdje je na nepropusnih proslojcima moguće duže zadržavanje vlažnosti i površinske vode. Sumirajući rezultate na godišnjoj razini vidljivo je da su tijekom proljeća postignute minimalne vrijednosti KI na „kritičnim“ dubinama na svim ostalim lokacijama na kojima nije zabilježen minimalni KI tijekom zime, odnosno:

- na glinama niske plastičnosti (CL) zabilježeni su rezultatski minimumi KI na „kritičnim“ dubinama tla od 15 cm (lokacije: „a“, „h“, i „i“) i na 30 cm dubine (lokacije: „a“, „b“, „c“, „d“, i „j“),

[17] Dnevni rezultati mjerenja Prilog 2 (25. veljače – 1. ožujka) i Prilog 8 (16. – 20. prosinca).
[18] Dnevni rezultati mjerenja Prilog 3. (11. – 15. ožujka) i Prilog 4. (30. travnja – 4. svibnja).

- na glinama visoke plastičnosti (CH) zabilježeni su rezultatski minimumi KI na „kritičnim“ dubinama tla od 15 cm (lokacije: „f“ i „l“) i 30 cm dubine (lokacije: „f“, „g“ i „k“).

Uvidom u Sl. 68. ističu se maksimalne vrijednosti[19] mjerenja zabilježene tijekom **ljeta**[20]. Na svim lokacijama (8) glina niske plastičnosti (CL), vršne vrijednosti KI dostizane su već pri 20-ak cm dubine. Vršne vrijednosti na lokacijama (4) pod glinama visoke plastičnosti (CH) zabilježene su na lokacijama „f“ (na 40-ak cm dubine) i „k“ (na 20-ak cm dubine). Na ostale dvije lokacije „g“ i „l“ KI bio je veoma blizu vršnim vrijednostima, ali se uspjelo provesti mjerenje do 80 cm dubine i vrijednosti KI nisu dosegle 5 MPa. Razlike u vrijednostima dnevnih mjerenja treba pripisati općenito velikoj čvrstoći tla i prolascima konusa kroz mikro pukotine u tlu tijekom mjerenja.

Tijekom dva petodnevna mjerenja provedenih krajem **jeseni**[21] zabilježeni su visoki iznosi KI. Kod glina niske plastičnosti (CL) visoki iznosi očitavani su već pri malim dubinama od 15-ak cm (lokacije „a“, „b“, „c“ i „h“). Kao i ljeti, tijekom jeseni zabilježene su maksimalne vrijednosti mogućeg očitanja DKP-a (5 MPa) i to na svih 8 lokacija. Za razliku od ljeta vršne vrijednosti očitanja KI očitavane su na nešto većim dubina od 40 do 50 cm. Rezultati mjerenja provedenih na lokacijama pokrivenim glinama visoke plastičnosti (CH) nisu bili jednoznačni. Rezultati zabilježeni na lokacijama „f“ i „k“, te na lokaciji „g“ (do dubine od 25 cm) korespondiraju rezultatima mjerenja provedenim tijekom zime i proljeća. Izuzetak čini lokacija „l“ na kojoj su rezultati kontinuirano viši (0.5 - 1.0 MPa) duž cijelog dubinskog profila tla. Tijekom jesenskog perioda zabilježen je nepravilan hod dnevnih vrijednosti mjerenja i značajnije amplitude KI na glinama niske plastičnosti (CL).

[19] DKP ima ograničenje vršne vrijednosti mjerenja do 5 MPa, prilikom pojedinačnih mjerenja – očitanjem vrijednosti od 5 MPa mjerenje je zaustavljeno na dostignutoj dubini, a daljnjim dubinama tla do 80 cm pridodana je vrijednost od 5 MPa.
[20] Dnevni rezultati mjerenja Prilog 5. (26. – 30. kolovoza).
[21] Dnevni rezultati mjerenja Prilog 6. (15. – 19. studenog) i Prilog 7. (25. – 29. studenog).

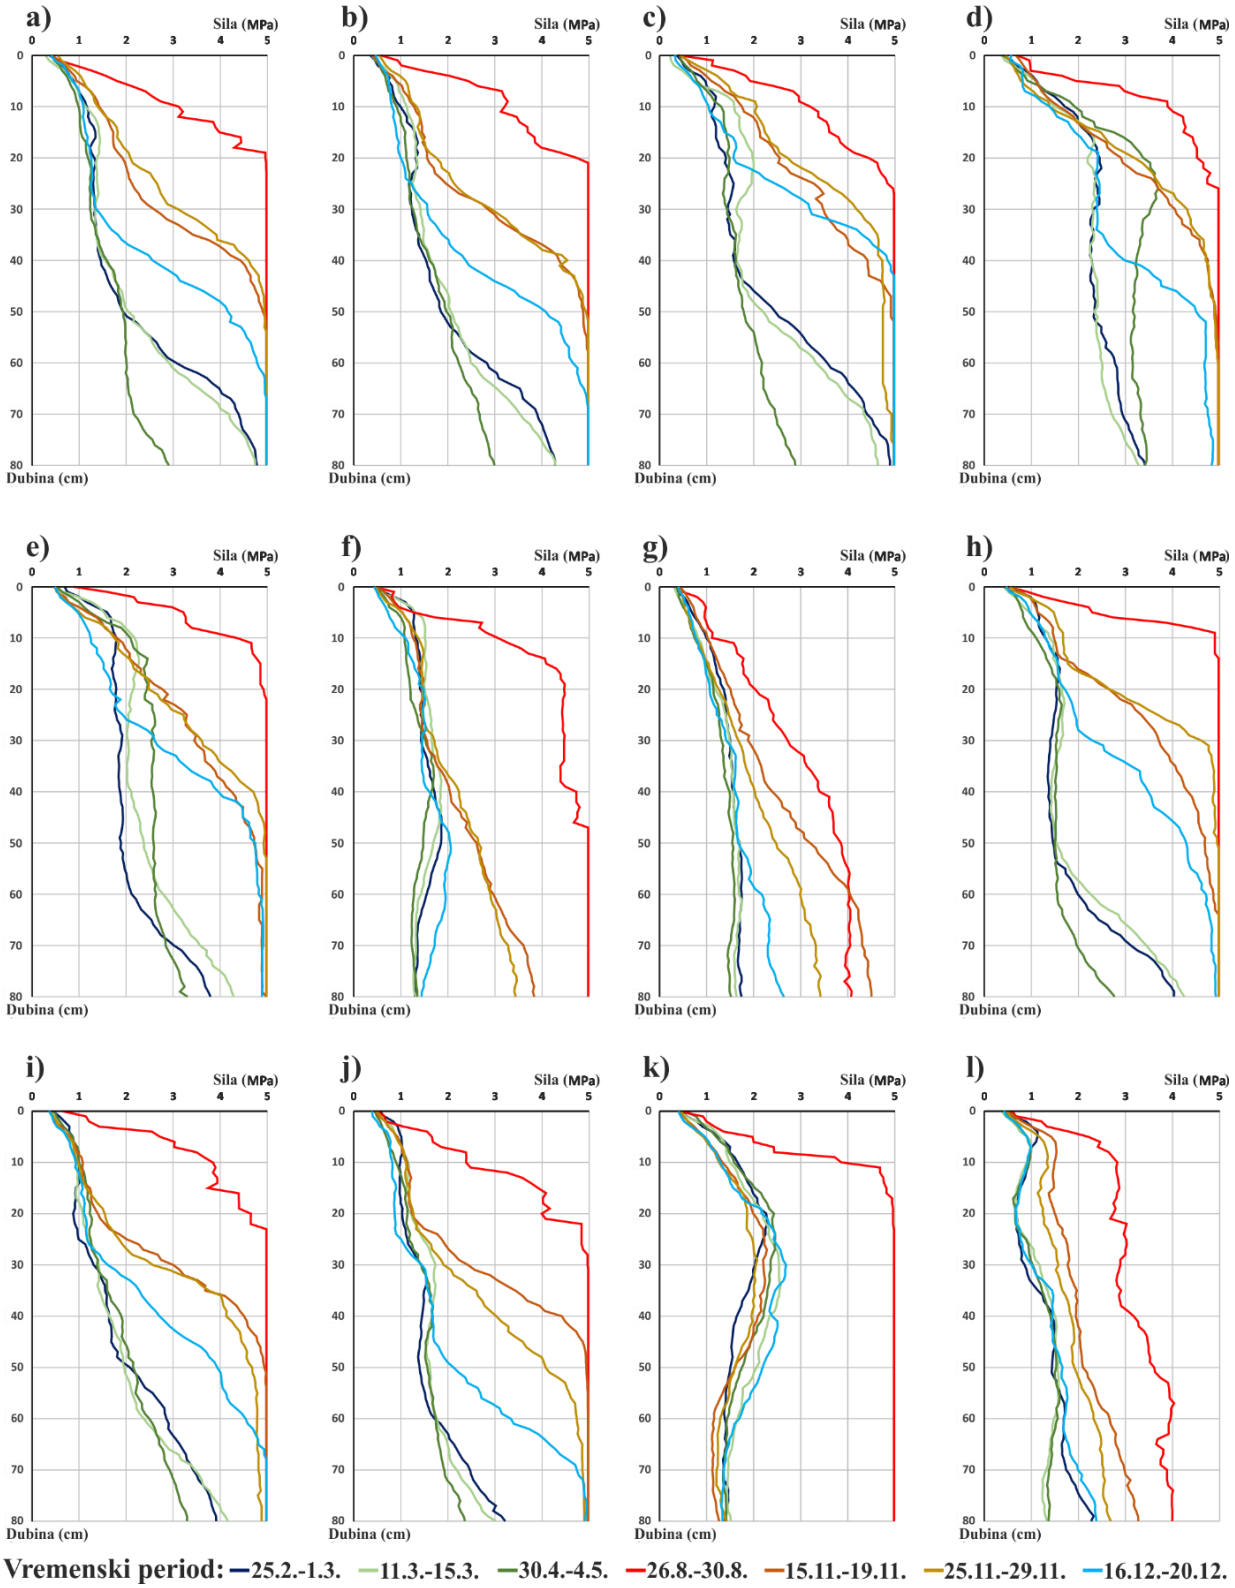

Sl. 68. Srednje vrijednosti dnevnih mjerenja prodirnih značajki tla prema lokacijama (vidi Sl. 38. i Sl. 39.) u odabranim periodima u 2019. godini

4.3.2.2. Vlažnost tla

Kao i kod interpretacije rezultata mjerenja KI, prosječni rezultati petodnevnih mjerenja vlažnosti tla bit će interpretirani i uspoređivani po godišnjim dobima. Nakon interpretacije tijekom godišnjeg doba uslijediti će interpretacija rezultata po lokacijama koje će biti grupirane prema dvjema grupama tala (glinama niske plastičnosti (CL) i glinama visoke plastičnosti (CH)). Prilikom opisa rezultata fokusiranost će biti usmjerena na „kritične“ dubine (15 cm i 30 cm) nosivosti tla.

Zajedničko obilježje gotovo svih dubinskih profila svih lokacija tijekom cijele godine (osim ljeti) je da vrijednosti vlažnosti porastom dubine opadaju, stoga su samim time i linije na grafovima blago nakošene u desno (Sl. 69.).

Razdoblje kasne **zime** (veljača) obilježile su niže vrijednosti u odnosu na ranu zimu (prosinac). U dnevnom hodu[22] vlažnosti tla nisu zabilježene pravilnosti, dok su na pojedinim lokacijama („j“ i „l“) tijekom kasne zime amplitude na istim dubinama mjerenja iznosile i do 10 %. Tijekom prosinca unutar petodnevnih mjerenja također su zabilježene velike amplitude (oko 10 %) na nekim lokacijama („c“, „e“, „h“ i „l“). Lokacije na aluviju (35 % – 40 % vlažnosti) u odnosnu na lesne uzvisine (30 % – 35 % vlažnosti) imale su više vrijednosti vlažnosti tla. Unutar godine općenito, zimi nisu zabilježene najviše vrijednosti vlažnosti tla. Najviše vrijednosti vlažnosti tla na godišnjoj razini tijekom zime zabilježene su samo na nekoliko lokacija („a“, „b“ i „d“) pri 15 cm dubine, te na lokaciji „d“ pri 30 cm dubine.

Mjerenjima provedenim u **proljeće** zabilježene su najviše razine vlažnosti tla. U dnevnom hodu[23] na mjerenim lokacijama nisu uočene pravilnosti. Velikim dnevnim amplitudnim razlikama ističu se jedino lokacije („d“, „e“ i „i“) koje se nalaze na lesnim zaravnjenim područjima. Osim navedenih maksimalnih vrijednosti tijekom zime, u proljeće su zabilježeni maksimumi na svim ostalim lokacijama. Kada se sumiraju rezultati svih petodnevnih srednjih vrijednosti rezultata mjerenja, u razdoblju od 30. travnja do 4. svibnja zabilježene su najviše razine vlažnosti tla. Maksimalne vrijednosti vlažnosti tla pri kritičnim dubinama na lesnim uzvišenjima (osim lokacije „d“) kretale su se između 30 % i 40 %, dok na aluvijima između 34 % i 44 %.

[22] Dnevni rezultati mjerenja Prilog 9. (25. veljače – 1. ožujka) i Prilog 15. (16. – 20. prosinca).
[23] Dnevni rezultati mjerenja Prilog 10. (11. – 15. ožujka) i Prilog 11. (30. travnja – 4. svibnja).

Ljeti su zabilježene minimalne prosječene vrijednosti vlažnosti tla tijekom godine. Na lesnom pokrivenim uzvišenjima vrijednosti su se kretale između 14 % i 21 % udjela vlažnosti u tlu. Na lokacijama unutar aluvija izmjerene vrijednosti bile su nešto više i iznosile su između 21 % i 29 % udjela vlažnosti u tlu. Razlike u vrijednostima dnevnih mjerenja[24] rezultat su niskih udjela vlažnosti tla i nailaska na mikro pukotine u tlu tijekom mjerenja sondom.

Izmjerene vrijednosti vlažnosti tla tijekom kasne **jeseni** bile su niže od onih zabilježenih u proljeće i zimi. Veće razlike u odnosu na proljeće i zimu zamjetnije su na lesnoj podlozi (20 % - 32 %), dok na aluvijalnim područjima vrijednosti ne odstupaju značajno (32 % - 35 %). U odnosu na druga godišnja doba, tijekom jeseni uočljiva je znatna diferencija vlažnosti tla po dubinskom profilu na lesnoj podlozi. Na dubinama od 30 cm i 45 cm udjeli vlažnosti niži su od 5 % – 15 % u odnosu na pliće dubine (1 cm - 15 cm). Niži iznosi udjela vlažnosti tla na većim dubinama rezultat su snažnog isušivanja cijelog dubinskog profila tla tijekom ljeta, uslijed visokih ljetnih temperatura. Drugim riječima, količina padalina tijekom jesenskih mjeseci nije bila dostatna da oborinska voda prodre u veće dubine tla, već je navlažila samo plitak površinski sloj tla. U rezultatima dnevnih mjerenja[25] uočene su izrazite amplitudne promjene samo kod lokacijama na lesnoj podlozi, dok su na aluviju promjene su uniformnije i blaže.

[24] Dnevni rezultati mjerenja Prilog 12. (26. – 30. kolovoza).
[25] Dnevni rezultati mjerenja Prilog 13. (15. – 19. studenog) i Prilog 14. (25. – 29. studenog).

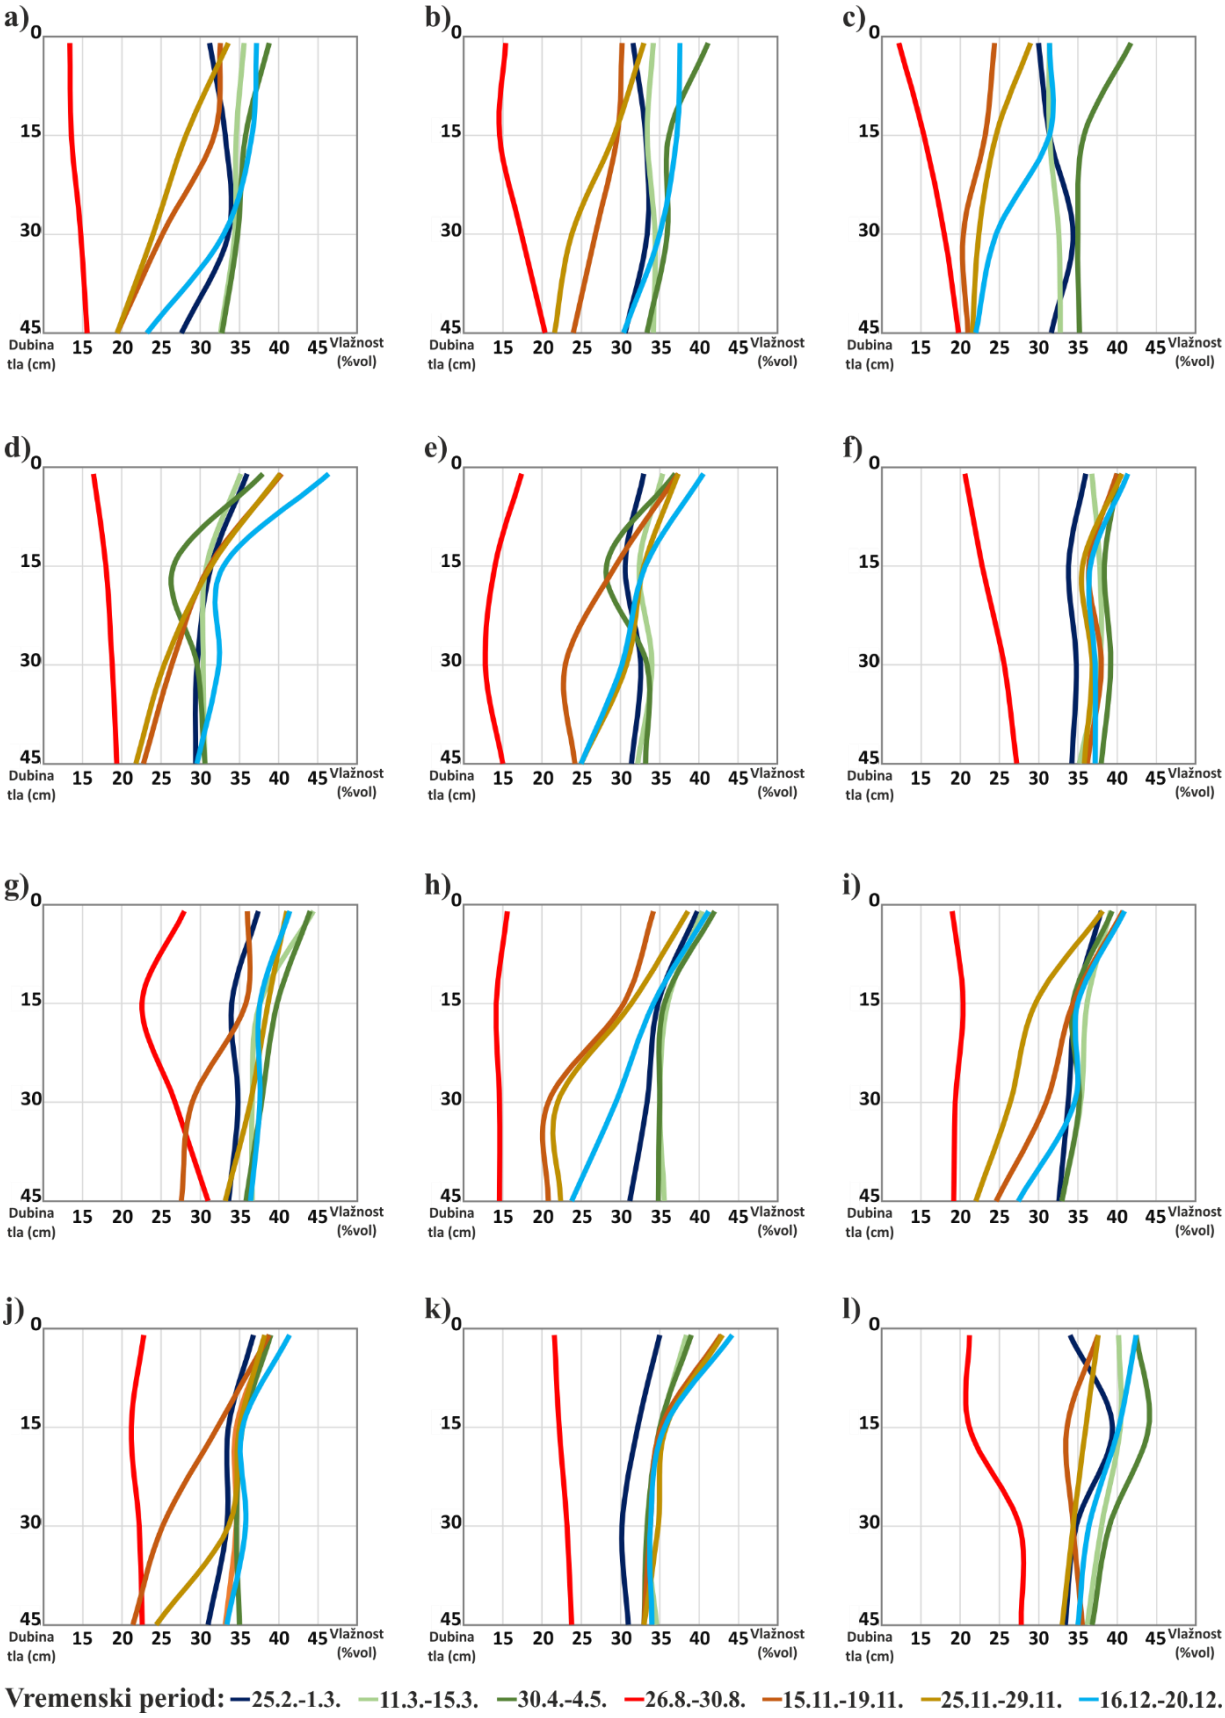

Sl. 69. Srednje vrijednosti dnevnih mjerenja vlažnosti tla prema lokacijama na lokacijama (vidi Sl. 38. i Sl. 39.) u odabranim periodima u 2019. godini

4.3.2.3. Temperatura tla

Uvidom u Sl. 70. maksimalne i minimalne izmjerene vrijednosti temperature tla analogne su temperaturnim obilježjima dvaju godišnjih doba. Krajem zime su izmjerene najniže temperature tla (0°C do 11°C), dok ljeti najviše (22°C do 29°C). Tijekom provedenih mjerenja temperature ispod 0°C zabilježene su samo na lokaciji „a“ do dubine 15 cm (na 1 cm dubine -3°C (27. veljače), dok na 15 cm -1.4°C (26. veljače)). Bez obzira na negativne izmjerene iznose tlo nije bilo zamrznuto. Promatrajući dubinske profile svih lokacija u svim periodima mjerenja, možemo reći da su temperature po dubini skoro istovjetne. Promjene po dubini uočene su na lokacijama pokrivene travnatom vegetacijom, gdje vršni sloj tla ima nekoliko stupnjeva više temperature, pri čemu su te razlike izraženije u ljetnom periodu. Osim izdvojenih minimuma i maksimuma, potrebno je izdvojiti mjerenje provedeno sredinom proljeća (30. travnja – 4. svibnja) kada su temperature bile nešto više na većini lokacija u odnosu na druge periode mjerenja.

U komparativne svrhe pojedinih lokacija mjerenja tla uzeta je temperatura zraka mjerena na klimatološkoj postaji u Đakovu kao referentna vrijednost i pokazatelj „vanjskog“ stanja temperature. Tijekom godine vidljive su određene pravilnosti u razlikama između temperature tla i zraka, pri čemu su na svim lokacijama (osim lokacije „a“) temperature zraka niže u odnosu na temperature tla gornjeg sloja tla (1 cm) tijekom čitave godine. Dubinom, temperature tla opadaju i uravnotežuju se s vrijednostima temperature zraka na svim lokacijama (osim lokacije „a“). Temperaturni minimumi temperature zraka na svim lokacijama su veći od temperature tla (osim lokacije „a“).

Dnevni hod temperature tla[26] bio je u skladu s temperaturama zraka. Amplitudne razlike dnevnog hoda temperature snižavale su se rastom dubine tla, pri čemu je izloženost najvećim promjenama temperature imao vršni sloj tla. Zbog svojih reljefnih ekspozicija i travnatog biljnog pokrova najveće razlike i promjene u dnevnim fluktuacijama temperature tla imale su lokacije „d“, „e“, „f“, „j“ i „i“.

[26] Dnevni rezultati mjerenja zimi: Prilog 16. (25. veljače – 1. ožujka) i Prilog 22. (16. – 20. prosinca), u proljeće: Prilog 17. (11. – 15. ožujka) i Prilog 18. (30. travnja – 4. svibnja), ljeti: Prilog 19. (26. – 30. kolovoza) i u jesen: Prilog 20. (15. – 19. studenog) i Prilog 21. (25. – 29. studenog).

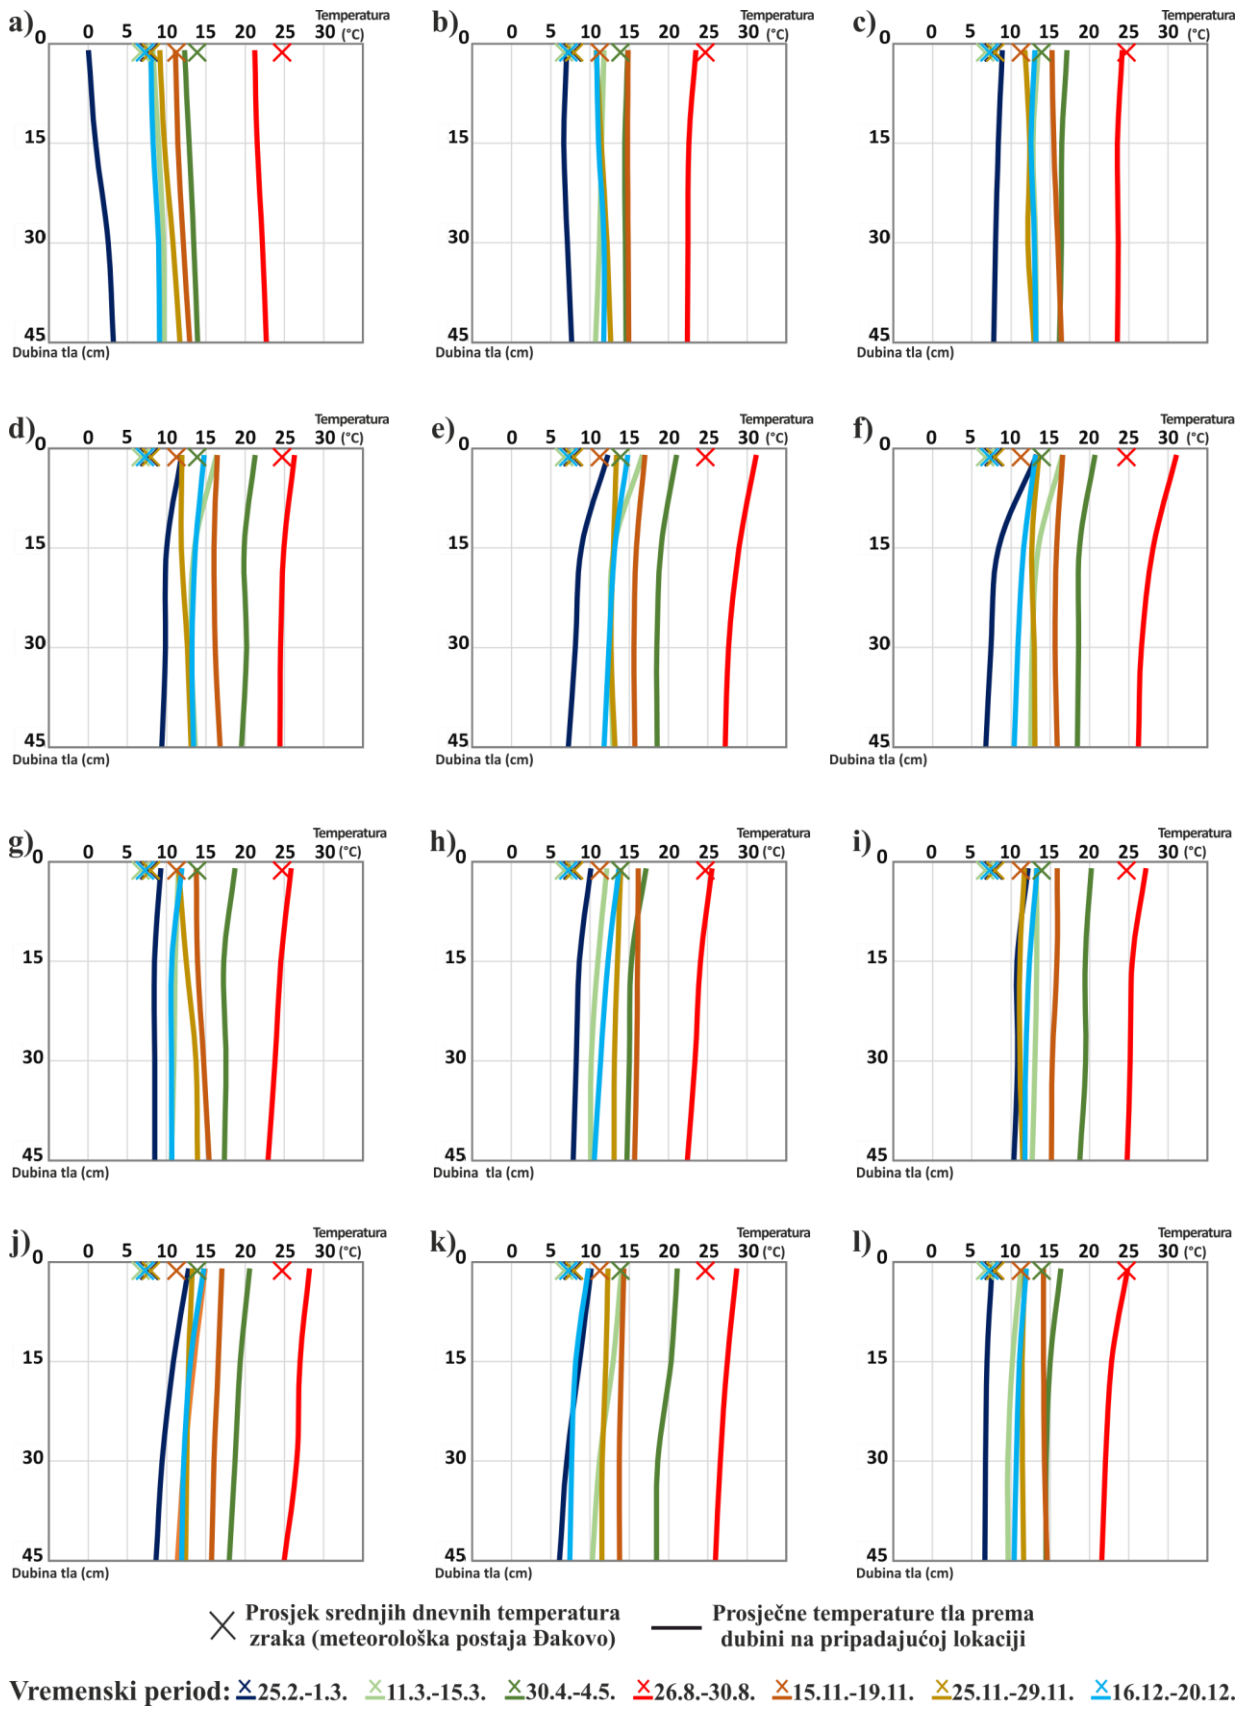

Sl. 70. Prosječne vrijednosti srednjih dnevnih temperatura zraka i prosječne temperature tla na lokacijama (vidi Sl. 38. i Sl. 39.) u odabranim periodima 2019. godine

4.3.2.4. Posmična čvrstoća tla

Vrijednosti očitane vršne posmične čvrstoće možemo promatrati kao relevantnu informaciju za jedan prolazak vozila. Vrijednosti rezidualne posmične čvrstoće mogu poslužiti za određivanje terenske prohodnosti višestrukog prolaska vozila ili kolone vozila.

Prema mjerenjima tijekom sedam petodnevnih perioda vidljivima na Sl. 71. prikazane su prosječne vrijednosti vršne nedrenirane posmične čvrstoće tla (VNPČT) mjerene krilnom sondom. U svrhu interpretacije mjerenja upotrijebiti će se gradacija vrijednosti VNPČT prema Tab. 15. Prilikom utvrđivanja prohodnosti tla za vozila, uvijek se prohodnost tla referira na onaj dubinski sloj koji ima najniža izmjerena svojstva čvrstoće (FM 5-430-00-1, 1994). Prema dobivenim rezultatima uvijek su na dubljem sloju od 30 cm zabilježene više petodnevne prosječne vrijednosti, stoga će samo svojstva sloja tla pri dubini od 15 cm biti opisana prilikom interpretacije. Prije same interpretacije rezultata treba napomenuti da su tijekom godine prilikom svih mjerenja (osim u rano proljeće) vrijednosti prelazile i granicu očitanja (130 kPa) koju omogućava krilna sonda. Stoga su prikazane vrijednosti i iznimno veće od grafom opisanih krivulja mjerenja na Sl. 71.

Na svim lokacijama izmjerena je *visoka* VNPČT sredinom proljeća, ljeti, u jesen i početkom zime. *Visoke* vrijednosti VNPČT izmjerene su i početkom proljeća (11. – 15. ožujka), osim na lokacijama: „a“, „b“, „c“, „d“, „g“, „h“, „i“, „j“ i „l“ gdje su izmjerene *srednje* vrijednosti NPČT.

Krajem zime (25. veljače – 1. ožujka) na svim lokacijama je zabilježena *srednja* vrijednost VNPČT, osim na lokacijama „e“, „f“ i „k“ gdje su zabilježene *visoke* vrijednosti VNPČT, pri čemu se prethodno navedene lokacije jedine imale *visoku* VNPČT tijekom cijele godine. Dnevni hod[27] vrijednosti VNPČT ukazuje da su i na ostalim lokacijama, u četvrtom i petom danu mjerenja dosegle visoke vrijednosti VNPČT na svim lokacijama.

Praćenjem dnevnih mjerenja VNPČT, jedino tijekom zime i proljeća dolazilo je do značajnih promjena u vrijednostima VNPČT, pri čemu su one bile značajnije izražene na glinama niske plastičnosti (CL), odnosno na lesu.

[27] Dnevni rezultati mjerenja zimi: Prilog 23 (25. veljače – 1. ožujka) i Prilog 29 (16. – 20. prosinca), u proljeće: Prilog 24 (11. – 15. ožujka) i Prilog 25, ljeti: Prilog 26 (26. – 30. kolovoza) i u jesen: Prilog 27. (15. – 19. studenog) i Prilog 28. (25. – 29. studenog).

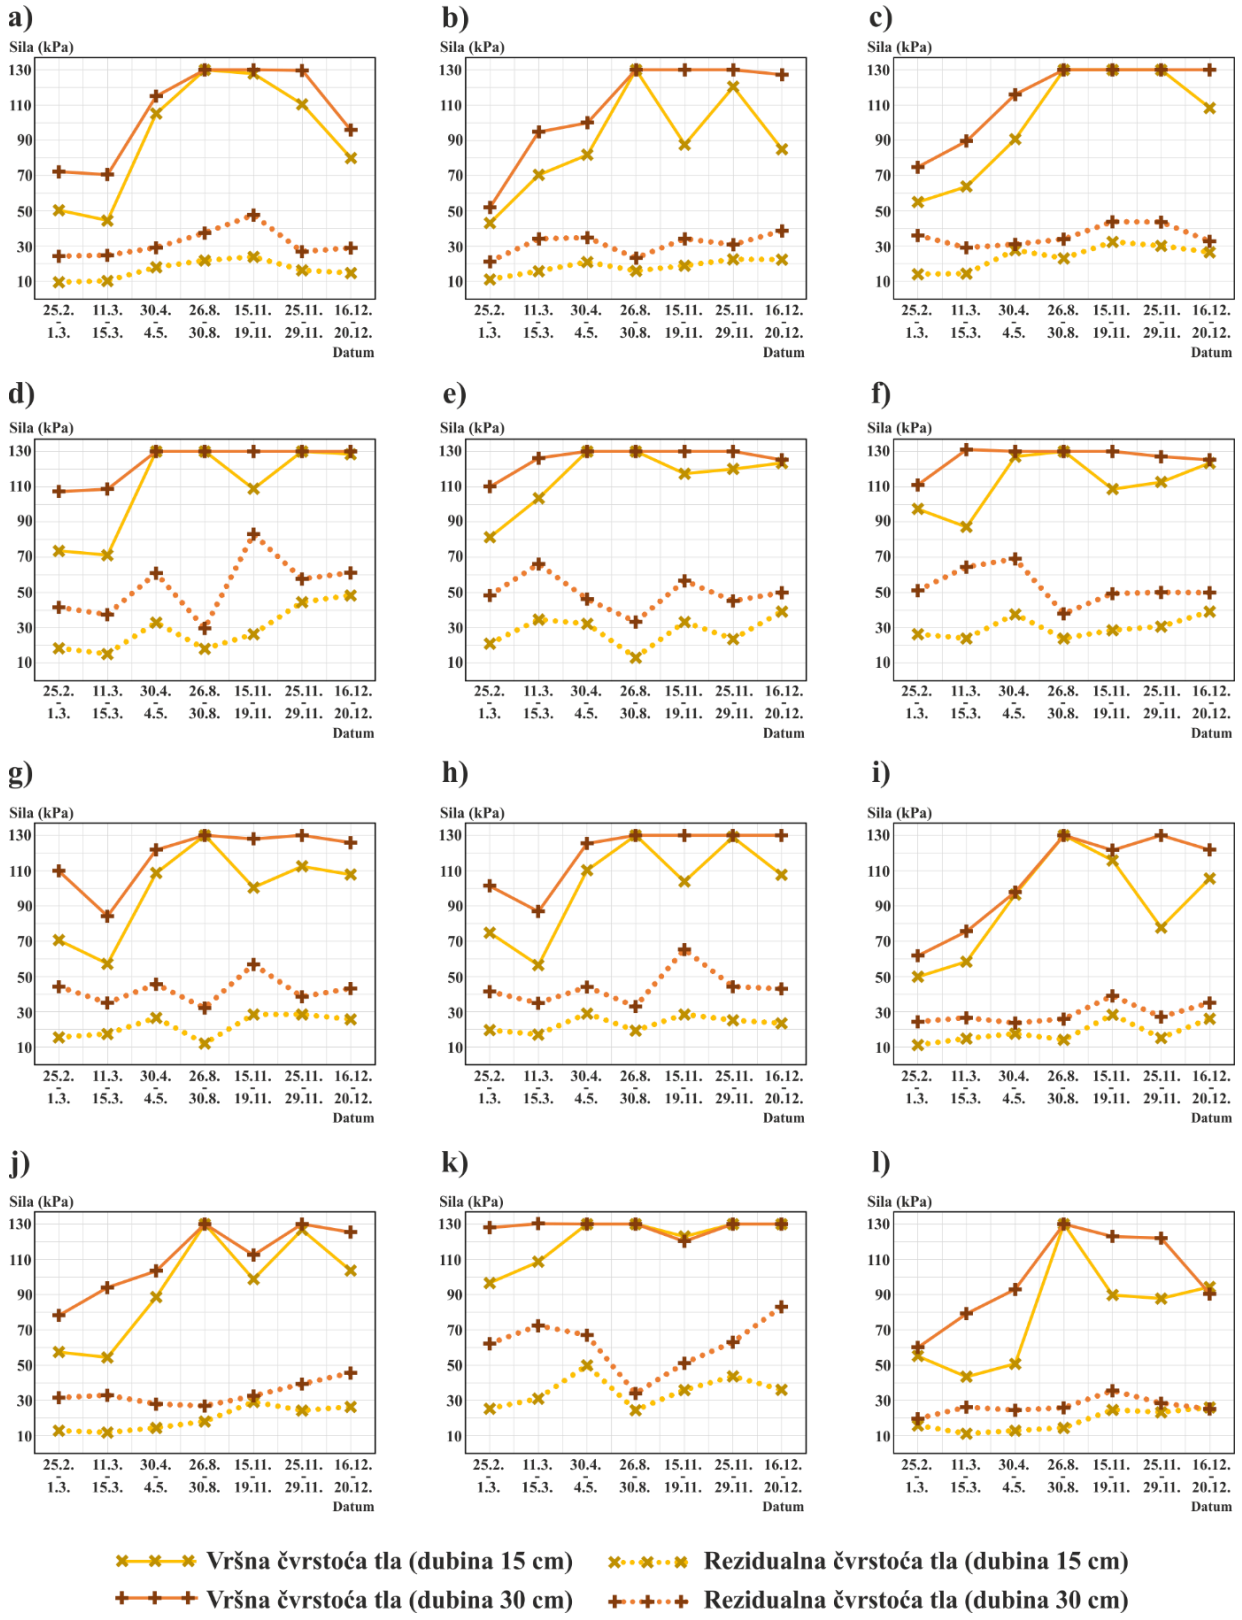

Sl. 71. Srednje vrijednosti dnevnih mjerenja nedrenirane vršne i rezidualne posmične čvrstoće tla prema lokacijama (vidi Sl. 38. i Sl. 39.) u odabranim periodima sondom tvrtke Eijkelkamp

Tab. 15. Nedrenirana posmična čvrstoća glina

Izvor: BS EN ISO 14688-2:2004 (2006)

Nedrenirana posmična čvrstoća glina	Nedrenirana posmična čvrstoća c_u (kPa)
Izrazito niska	< 10
Jako niska	10 - 20
Niska	20 - 40
Srednja	40 - 75
Visoka	75 - 150
Jako visoka	150 - 300
Izrazito visoka*	> 300
* Materijali s nedreniranom posmičnom čvrstoćom većom od 300 kPa mogu se ponašati kao meka stijena i treba ih opisivati prema normi ISO 14689-1.	

Osim VNPČT mjerene su i vrijednosti rezidualne nedrenirane posmične čvrstoće tla (RNPČT). Kao i VNPČT najniže vrijednosti zabilježene su pri dubini od 15 cm na svim lokacijama tijekom godine. Srednje vrijednosti petodnevnih mjerenja na većini lokacija kreću se u rasponu od 10 – 30 kPa, stoga ih prema Tab. 15. možemo svrstati u *jako niske* i *niske* RNPČT. Većim iznosima čvrstoće tla ističu se lokacije „d“, „e“, „f“ i „k“ gdje vrijednosti dosežu i 50 kPa, a zabilježene maksimalne vrijednosti odnose se na sredinu proljeća (30. travnja – 4. svibnja) i početak zime. Četiri navedene lokacije imaju raspon vrijednosti RNPČT između *niskih* i *srednjih*. Iz Prilog 25. je vidljivo da je dnevni hod RNPČT imao iznimno male i nepravilne promjene, te da su i amplitude bile niske – s maksimalnom promjenom do 12 kPa tijekom cijele godine). Treba napomenuti da tijekom mjerenja provedenom na lokaciji „e“ 14. ožujka zabilježen „skok“ od 50 kPa, što se treba pripisati zapinjanju sonde u korijenski sustav biljaka ili nečemu sličnom.

Temeljem poznate zakonitosti da dolazi do promjena posmične čvrstoće glina s povećanjem vlažnosti tla, na Sl. 72. su prikazane vrijednosti VNPČT i dnevne količine padalina. Jedino tijekom ovog perioda mjerenja, u tijeku provedbe mjerenja, pale su značajnije količine padalina u iznosu od 24 mm (30. ožujka – 1. svibnja). Iako je pala značajna količina padalina, ne mogu se donijeti jednoznačni zaključci i definirati jačina i smjer promjene u dnevnom hodu VNPČT ili RNPČT.

Provedenim mjerenjima VNPČT i RNPČT nisu uočene neke zakonitosti povezane s ostalim fizičko-geografskim faktorima u kontekstu prohodnosti tla. Povezanost parametra bi se prije svega trebala tražiti između KI i posmične čvrstoće tla, no Đuka (2014) i Poršinsky i dr. (2006) također nisu uvidjeli korelaciju između KI i posmične čvrstoće tla.

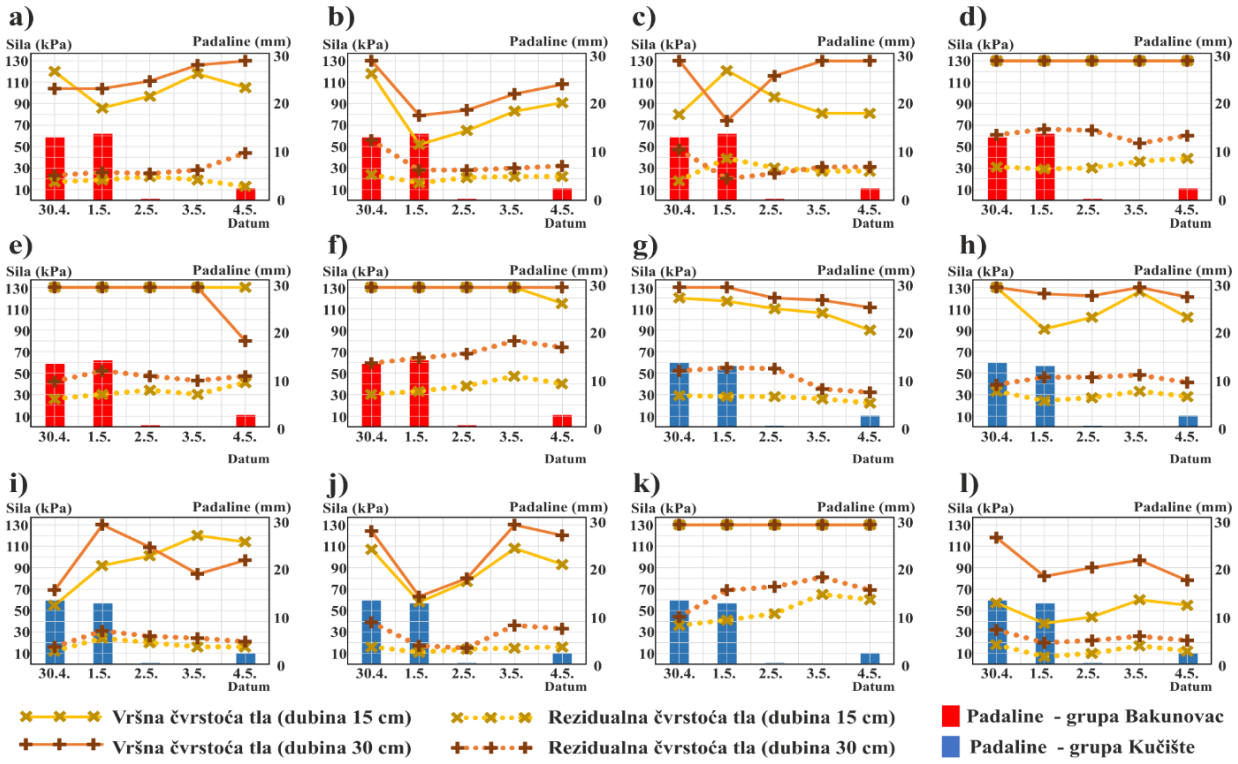

Sl. 72. Posmična čvrstoća tla i količina padalina najvlažnijeg razdoblja tijekom provedenih mjerenja na odabranim lokacijama (vidi Sl. 38. i Sl. 39.)

4.3.2.5. Padaline

Iz prikaza distribucije godišnje količine padalina tijekom 2019. godine prema Sl. 73. vidljivo je da su najmanje količine padalina (720 mm) zabilježene na sjeveroistočnom dijelu područja, dok najveća zabilježena količina padalina (860 mm) obuhvaća sjeverozapadni dio područja. Glavnina područja obuhvaćena je ukupnom količinom padalina između 750 mm i 820 mm kiše. Budući da su zabilježene amplitude relativno niske (140 mm), prostor možemo definirati kao homogeno područje kada se promatra ukupan iznos padalina na godišnjoj razini. Premda treba

naglasiti da zapadni dijelovi, koji su ujedno i orografski (prosječno 300m n/m) predisponiraniji, dobivaju nešto veće količine padalina od nižih istočnijih dijelova (prosječno 100m n/m).

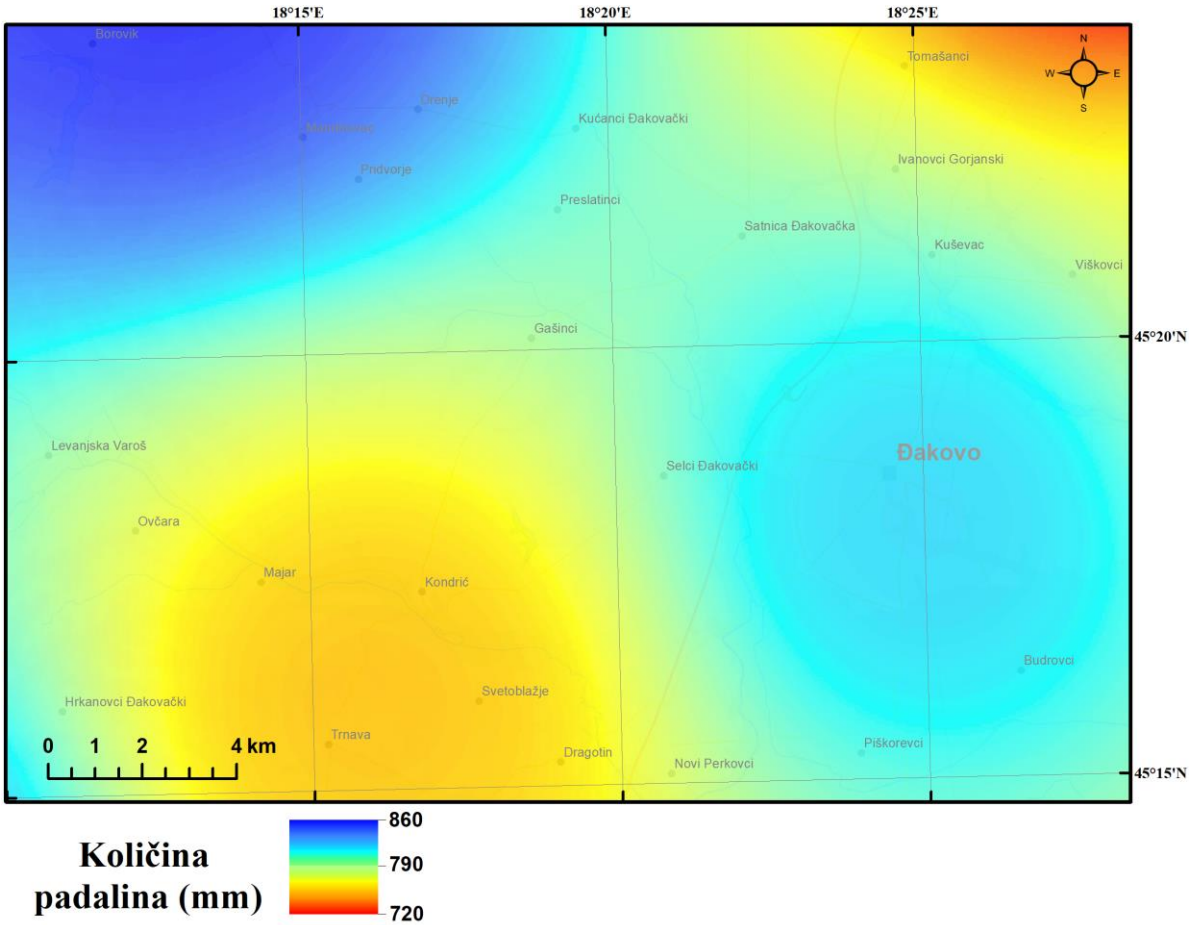

Sl. 73. Padaline u 2019. godini

Raščlambom količine padalina po godišnjim dobima tijekom 2019. godine (Sl. 74.) utvrđeni su sljedeći rezultati:

- proljeće je bilo godišnje doba s najvećom količinom padalina (286 mm – 230 mm),
- zimi je zabilježeno najmanje padalina (153mm – 103 mm),
- ljeti (242 mm – 208 mm) i u jesen (216 mm – 174 mm) su pale podjednake količine padalina.

Raščlambom padalina prema mjesecima potrebno je istaknuti da je u mjesecu svibnju zabilježena najveća količina padalina (179 mm), pri čemu treba istaknuti da je upravo prijelazni period iz proljeća u ljeto predstavlja maksimum količine padalina, odnosno da su svibanj i lipanj

(123 mm) bili najkišovitiji mjeseci. Mjesec s najmanjom zabilježenom količinom padalina bio je ožujak (24 mm).

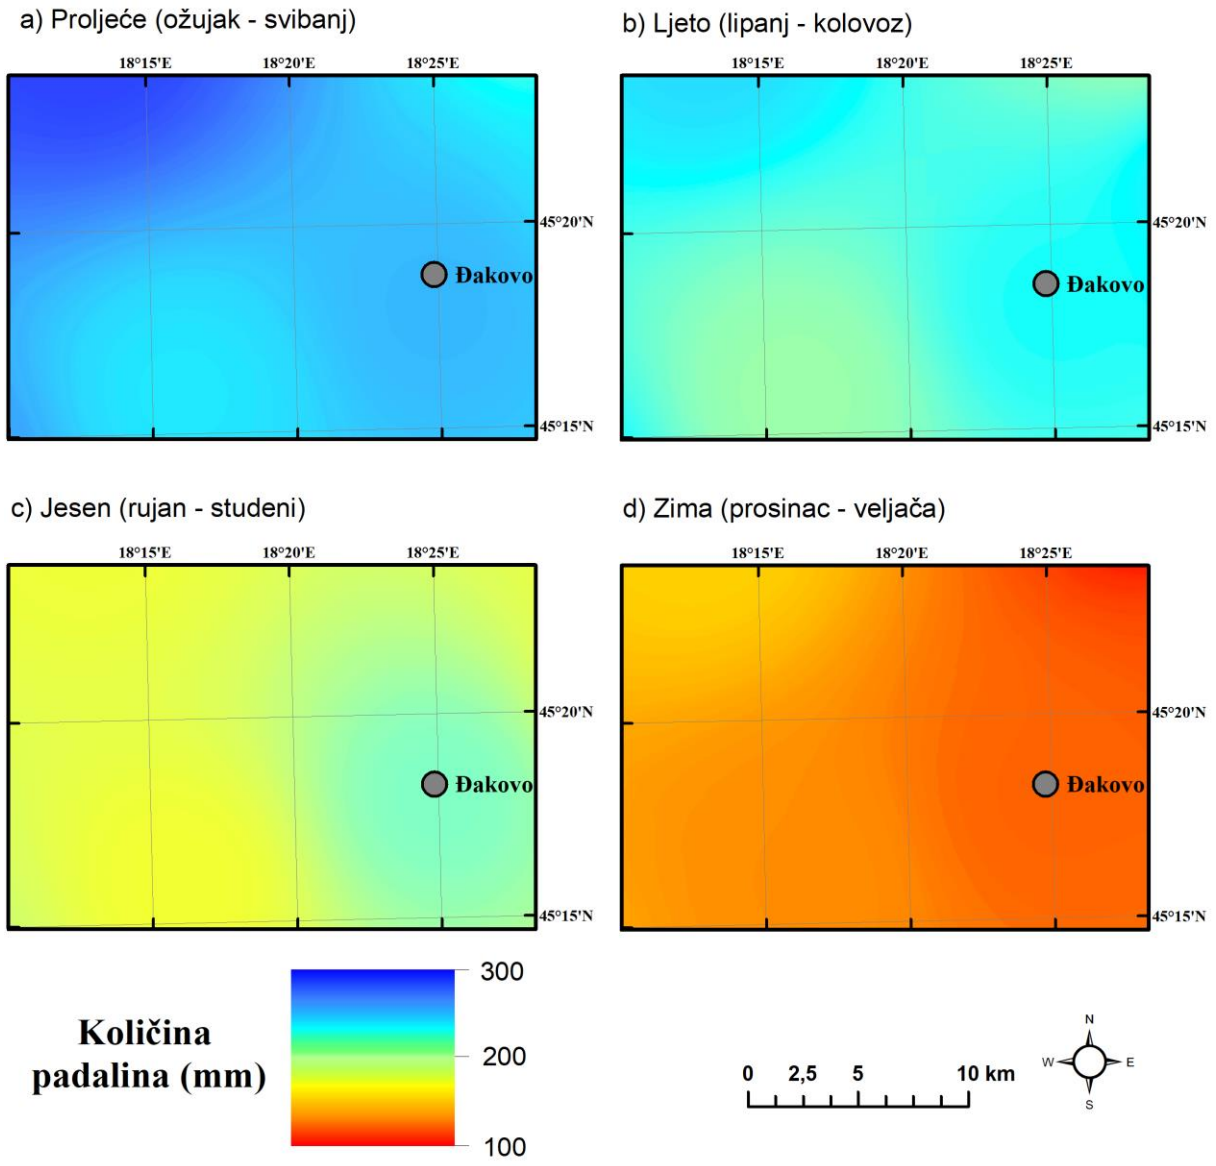

Sl. 74. Padaline po godišnjim dobima 2019. godine

Prema klimatološkoj meteorološkoj stanici Đakovo u 2019. godini u sklopu ukupnih izračunatih padalina palo je i ukupno 23 cm snijega tijekom šest dana (2 cm 6. siječnja. i 21 cm između 22. siječnja. i 26. siječnja), pri čemu je ukupni visinski maksimum zabilježen 25. siječnja koji je iznosio 20 cm. Prema Affleck i dr., (2009) ova maksimalna visina snijega ne bi

utjecala na TPV, jer snijeg utječe na TPV kada je njegova visina veća od 30 cm. Kada visina snijega prijeđe 30 cm, prohodnost snijega mjeri se metodom KI za sitnozrnata tla.

4.3.2.6. GIS analiza prohodnosti tla

Terenska mjerenja KI provedena su na malom površinskom uzorku. Odabirom heterogenih svojstava lokacije postignuta je reprezentativnost na ukupnoj površini prostora istraživanja. Korelacijskom analizom i primjenom stohastičkog pristupa predviđene su vrijednosti nosivosti tla.

Rezultati mjerenja DKP-om tijekom godine prikazali su da nosivost tla možemo grupirati u dvije skupine mjerenja. Skupine su definirane na osnovu zajedničkih obilježja KI, odnosno prohodnosti tla. U skupine su pridržena po dva godišnja doba. Ljeto i jesen su definirane kao scenarij „ljeto/jesen – suho“, dok zima i proljeće kao scenarij „zima/proljeće – mokro“. Scenarijima su pridružene krajnje zabilježene vrijednosti KI, pri čemu „ljeto/jesen – suho“ sadržava maksimalne vrijednosti KI, a „zima/proljeće – mokro“ minimalne. Minimalne vrijednosti KI izmjerene su početkom svibnja (30. travnja – 4. svibnja), dok maksimalne ili vršne vrijednosti krajem kolovoza (26. – 30. kolovoza). Drugim riječima ova dva scenarija odgovaraju najboljim i najlošijim zabilježenim uvjetima prohodnosti tla.

Analiza je započeta scenarijem „zima/proljeće – mokro“ za stanje najlošije prohodnosti tla. Analiza je provedena u skladu s referentnim „kritičnim“ slojem za pojedini tip vozila, pri čemu su uzete prosječne vrijednosti petodnevnih mjerenja DKP-om i udjela vlažnosti. Komparacijom rezultata mjerenja KI i vlažnosti tla, testirane su korelacijske veze između ova dva parametra. Statistički značajne korelacijske veze između parametra utvrđene su tek nakon podjele rezultata prema dvije prisutne USCS grupe tla (Tab. 6.). Na glinama visoke plastičnosti (CH) nalazilo se 4 lokacije, a na glinama niske plastičnosti (CL) 8 lokacija mjerenja. Tijekom procesa istraživanja u grupi glina niske plastičnosti (CL) je uočeno da rezultati mjerenja na lokaciji „d“ imaju velika odstupanja po svim parametrima, stoga su podaci s lokacije „d“ isključeni iz daljnjih procesa analize.

U Tab. 16. prikazani su rezultati korelacijske analize između KI (MPa) i vlažnosti tla (vol %). Prema Pearsonovom koeficijentu korelacije (r_p) dobiveni rezultati koji variraju između

-0.85 i -0.93 ukazuju na *jaku korelaciju* između KI i vlažnosti tla. Ukupno gline niske plastičnosti (CL) imaju nešto viši stupanj jakosti veze od glina visoke plastičnosti (CH). Rezultati ukazuju da s porastom vlažnosti tla opada nosivost tla, čime se ujedno smanjuje i mobilnost vozila.

Budući da je terenskim kartiranjem (Sl. 67.) utvrđeno da prostor dominantno pokrivaju gline niske plastičnosti (CL) i gline visoke plastičnosti (CH), te da postoji jaka veza između KI i vlažnosti tla ostvareni su uvjeti za translaciju dobivenih rezultata terenskih mjerenja na cjelokupni prostor istraživanja.

Tab. 16. Korelacijski parametri (r_p) između vlažnosti tla, sile prodiranja konusnog penetrometra i topografskog indeksa vlaženja (TIV)

a)

Glina visoke plastičnosti (CH), dubina 15cm	Udio vlažnosti (vol%)	Sila (MPa)	TIV
Udio vlažnosti (vol%)	1	-0.89	0.93
Sila (Mpa)	-0.89	1	-0.95
TIV	0.93	-0.95	1

b)

Glina niske plastičnosti (CL), dubina 15cm	Udio vlažnosti (vol%)	Sila (MPa)	TIV
Udio vlažnosti (vol%)	1	-0.93	0.80
Sila (Mpa)	-0.93	1	-0.72
TIV	0.80	-0.72	1

c)

Glina visoke plastičnosti (CH), dubina 30cm	Udio vlažnosti (vol%)	Sila (MPa)	TIV
Udio vlažnosti (vol%)	1	-0.85	0.94
Sila (Mpa)	-0.85	1	-0.92
TIV	0.94	-0.92	1

d)

Glina niske plastičnosti (CL), dubina 30cm	Udio vlažnosti (vol%)	Sila (MPa)	TIV
Udio vlažnosti (vol%)	1	-0.92	0.67
Sila (Mpa)	-0.92	1	-0.82
TIV	0.67	-0.82	1

Terenskim mjerenja na lokaciji koja predstavlja mali, ali reprezentativan uzorak upotrebom TIV uspješno su „prenesena“ obilježja nosivosti tla za cijeli prostor istraživanja. TIV je upotrijebljen kao referentni sloj uz pomoć kojeg je provedeno pridruživanje vrijednosti KI na cjelokupni prostor istraživanja (Sl. 75.). U sljedećem koraku prostorne analize preuzete su

vrijednosti TIV prema pripadajućim lokacijama mjerenja DKP-om. Vrijednosti TIV po lokacijama vidljive su u Tab. 6. Pridruživanju je prethodilo utvrđivanje statističke povezanosti između parametara slojeva.

Iz Tab. 16. je vidljivo da jakosti veza variraju u odnosu na grupu, dubinu i vlažnost tla. Analizirajući KI i vlažnost tla s TIV utvrđene su *jake veze* između pojava. Jedina utvrđena *srednje jaka* veza postoji kod glina niske plastičnosti (CL) između KI i TIV-a (-0.72), te vlažnosti tla i TIV-a (0.67). Dobiveni koeficijenti korelacije potvrdili su mogućnost pridruživanja vrijednosti terenskih mjerenja KI i TIV.

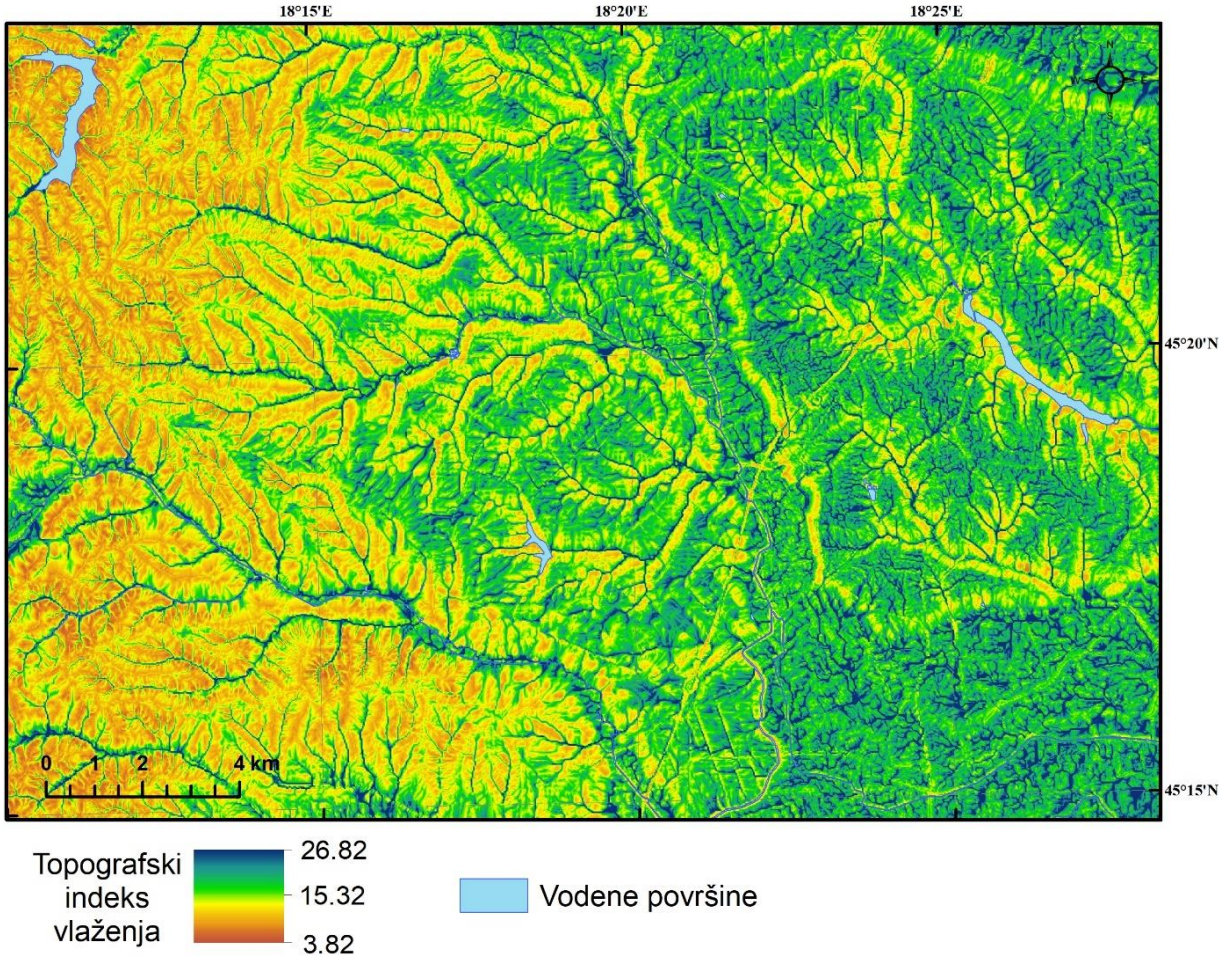

Sl. 75. Topografski indeks vlaženja

Nakon utvrđenih veza korelacijskih odnosa, upotrijebljena je metoda regresijske analize kako bi se izrazila dinamika i smjer promjene odnosa između KI i TIV. Fizikalna svojstva

nosivosti tla modelirana su eksponencijalnim funkcijama. Svaka grupa tla i pripadajuća „kritična“ dubina tla definirana je zasebnim algoritmom. Formulom je opisana promjena KI u odnosu na TIV. Reprezentativnost svakog od modela izražena je koeficijentima determinacije (R^2). Ukoliko znamo da je prema Chadockovoj ljestvici model jači ukoliko mu je vrijednost bliža broju 1, dobiveni modeli imaju različite razine reprezentativnosti. Drugim riječima model korišten pri izračunu nosivosti glina niske plastičnosti (CL) pri „kritičnom“ sloju od 15 cm (Sl. 76. b) ima najniži koeficijent (0.48) determinacije, stoga je najmanje reprezentativan od upotrijebljenih. Ovaj model je jedini s *vezom srednje jakosti*, dok ostala tri prema Chadocku imaju *čvrste veze*.

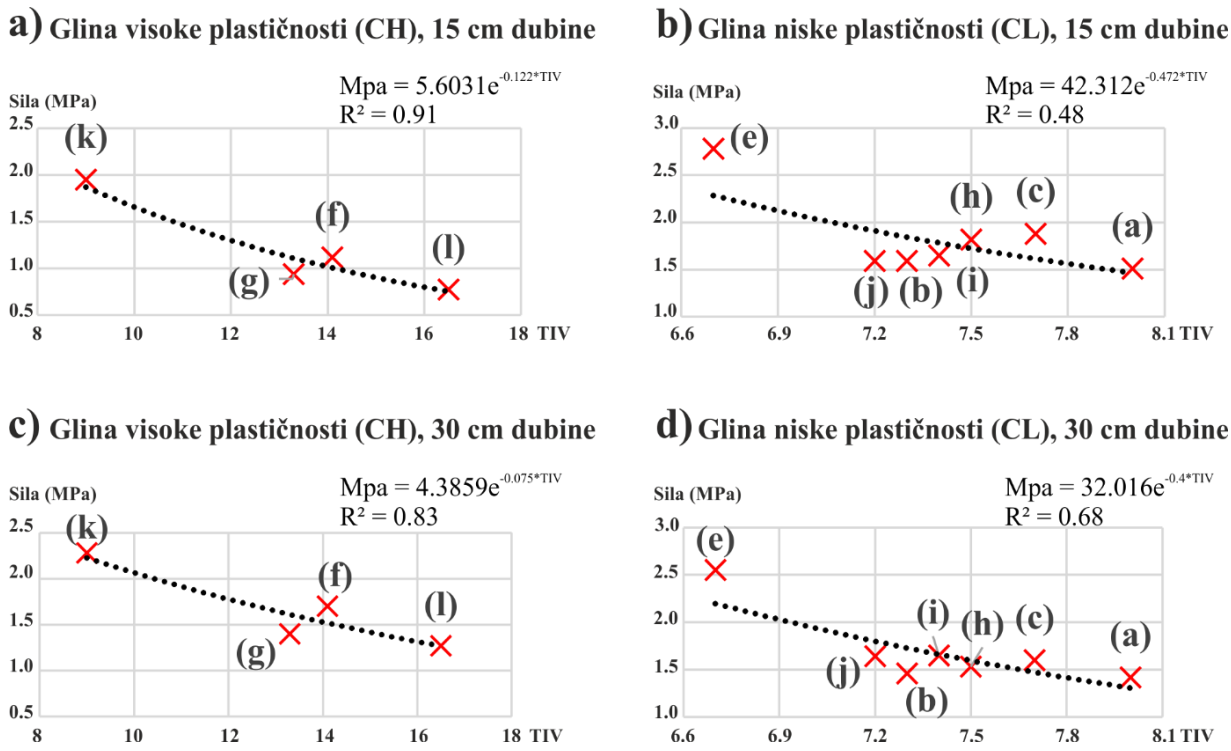

Sl. 76. Odnos nosivosti tla i topografskog indeksa vlaženja (TIV) sa aproksimiranom eksponencijalnom funkcijom

Prije izrade finalnog sloja prohodnosti tla, TIV je normaliziran količinom padalina u posljednjih 30 dana. Prilikom normalizacije TIV korišteni su podaci o ukupnoj količini padalina između 4. travnja i 4. svibnja (30 dana). Izračunati zbroj količine padalina unutar prostora istraživanja iznosio između 114.8 mm i 99.8 mm. Kao referentna vrijednost uzeta je srednja količina padalina (107.5 mm) između grupa lokacija mjerenih DKP-om.

Sl. 77. prikazuje rezultat dobivenih KI za „kritičnu“ dubinu nosivosti tla od 15 cm. Ovaj sloj korišten je za definiranje prohodnosti tla vozila Kawasaki B-Force 750 4x4i (KIV 0.092) i Land Rover Defender 110 (KIV 0.2). U finalnom koraku analize područja s manjim vrijednostima KI od KIV definirana su kao neprohodna. Pomoću dobivenog sloja KI moguće je odrediti prohodnost bilo kojeg vozila temeljem izračuna njegovog KIV, uz uvjet da dubina od 15 cm čini njegov „kritični“ nosivi sloj. Iz dobivenih rezultata je vidljivo da su vrijednosti KI veoma niske na glinama niske plastičnosti (CL) u područjima lesne zaravni i njenih aluvija. Iznimno dobru prohodnost tla pružaju svi dijelovi pobrđa, osim uskih dijelova uz same vodotoke koji u svojoj podlozi imaju gline niske plastičnosti (CL). Područja koja u podlozi imaju gline visoke plastičnosti (CH) ili u kojima su gline visoke plastičnosti (CH) prisutne, prohodna su za oba tipa vozila korištena prilikom analize.

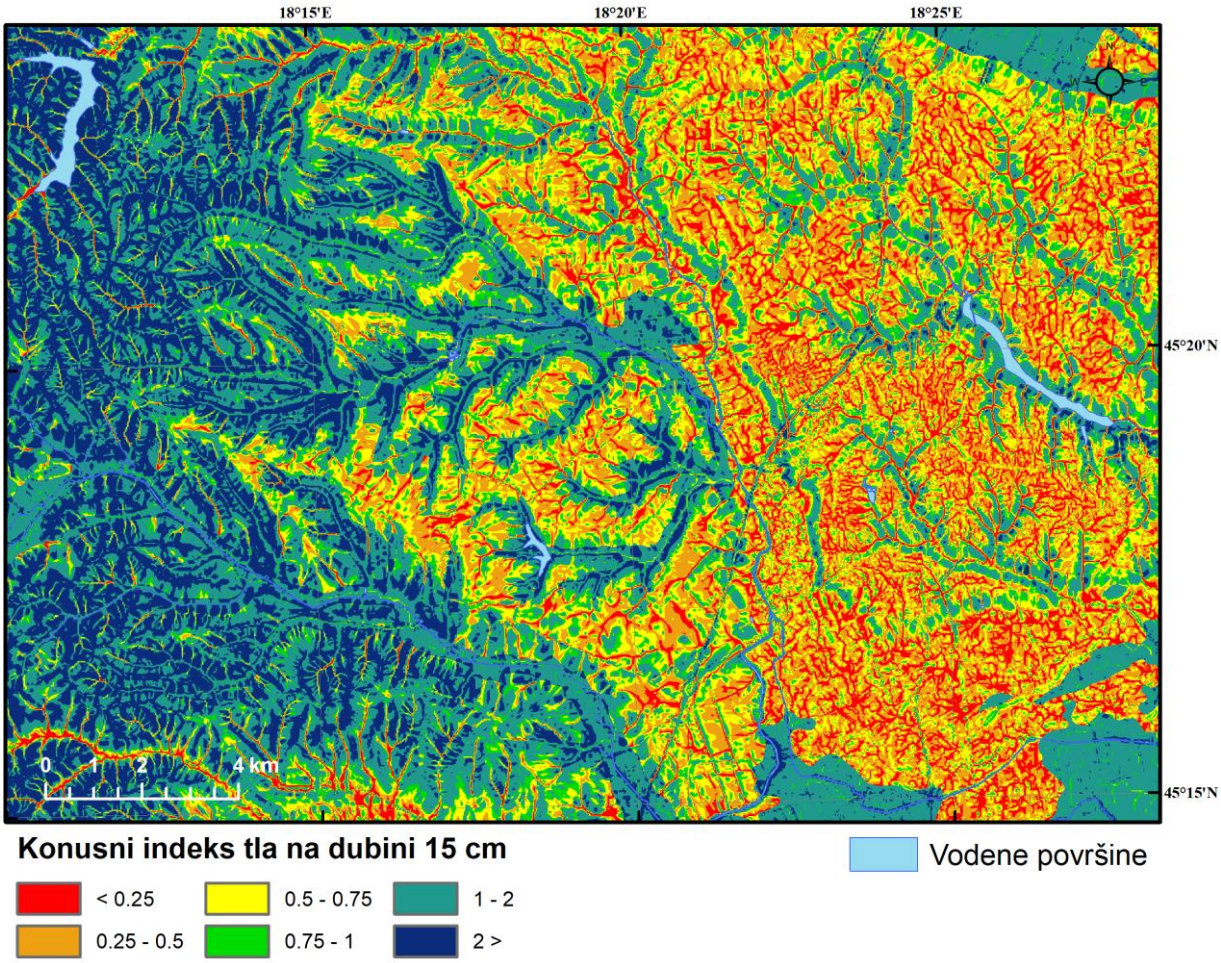

Sl. 77. Konusni indeks nosivosti tla na dubini 15 cm

Sl. 78. prikazuje rezultat dobivenih KI za „kritičnu“ dubinu nosivosti tla od 30 cm. Ovaj sloj korišten je za definiranje prohodnosti tla vozila BOV Patria (KIV 0.25), Iveco Eurocargo ML 100 E21 4x4 (KIV 0.43), BTR-50 (KIV 0.11) i Tenk M-84 (KIV 0.15). U finalnom koraku analize područja s manjim vrijednostima KI od KIV definirana su kao neprohodna. Dobiveni rezultati slični su onima na Sl. 77., samo su ovdje vrijednosti KI općenito više zbog dubljeg referentnog nosivog sloja. Iz dobivenih rezultata je vidljivo da su vrijednosti KI niske na glinama niske plastičnosti (CL) u središnjim i istočnim područjima lesne zaravni i njenih aluvija. Iznimno dobru prohodnost tla pružaju svi dijelovi pobrđa, osim udolina povremenih vodotoka. Područja koja u podlozi imaju gline visoke plastičnosti (CH) ili u kojima su gline visoke plastičnosti (CH) prisutne, prohodna su za sva vozila, osim uskih područja uz same vodotoke koja su ponegdje bila neprohodna za Iveco Eurocargo ML 100 E21 4x4.

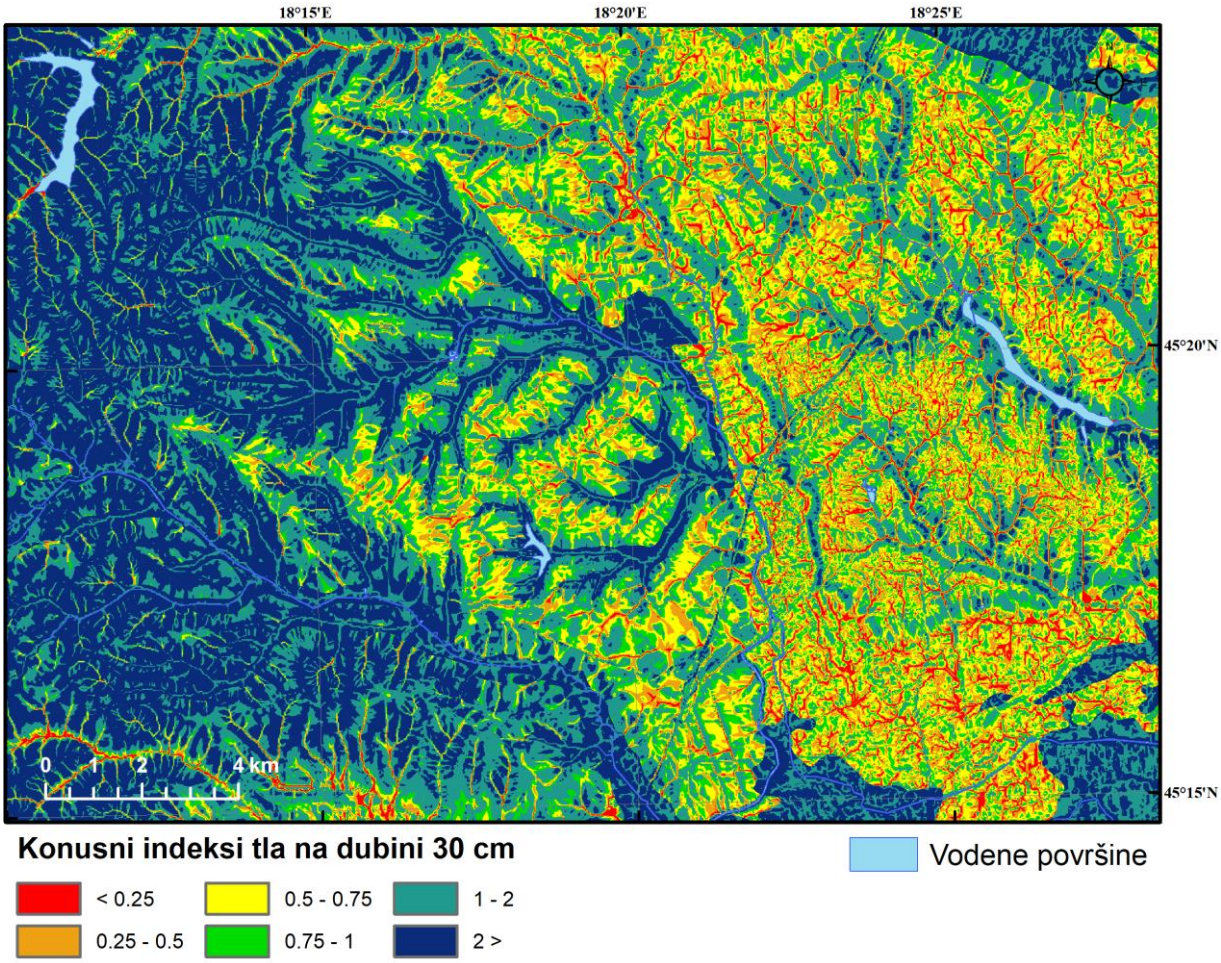

Sl. 78. Konusni indeks nosivosti tla na dubini 30 cm

Za scenarij „ljeto/jesen – suho“ ponovljen je cjelokupni proces izračuna KI opisan za scenarij „zima/proljeće – mokro“. Izračunom korištenih rezultata prilikom mjerenja u mjesecu kolovozu dobiveni su rezultati KI koji omogućavaju prohodnost tla svim vozilima na čitavom području istraživanja.

4.3.3. Klizanje vozila i ljepljivost tla

Klizanje i ljepljivost kao čimbenici usporenja uključeni su u model tijekom izračuna scenarija za period „zima/proljeće – mokro“. Sukladno provedenom pedološkom kartiranju (gline niske plastičnosti (CL), gline visoke plastičnosti (CH) i prahovi visoke plastičnosti (MH)) i razinama prisutne podzemne vode (niska i visoka topografija) kreiran je sloj prohodnosti unutar GIS modela. Koeficijenti su multiplicirani sukladno deskriptivnoj ljestvici usporenja prema Daigle i dr. (2005). Kao kontrolni faktor dobivenih koeficijenata usporenja upotrijebljeni su rezultati mjerenja KI. Prema Sl. 79. je vidljivo da kombinacija dvaju čimbenika različito utječe na usporenje i kontrolu kretanja vozila. Područja najznačajnijih usporenja odnose se na nisku topografiju pokrivenu glinama visoke plastičnosti (CH), sva ostala nedrenirana područja aluvija predstavljaju znakoviti usporavajući element, dok visoka topografija i dobro drenirana područja najmanje otežavaju pokret kotačnih vozila.

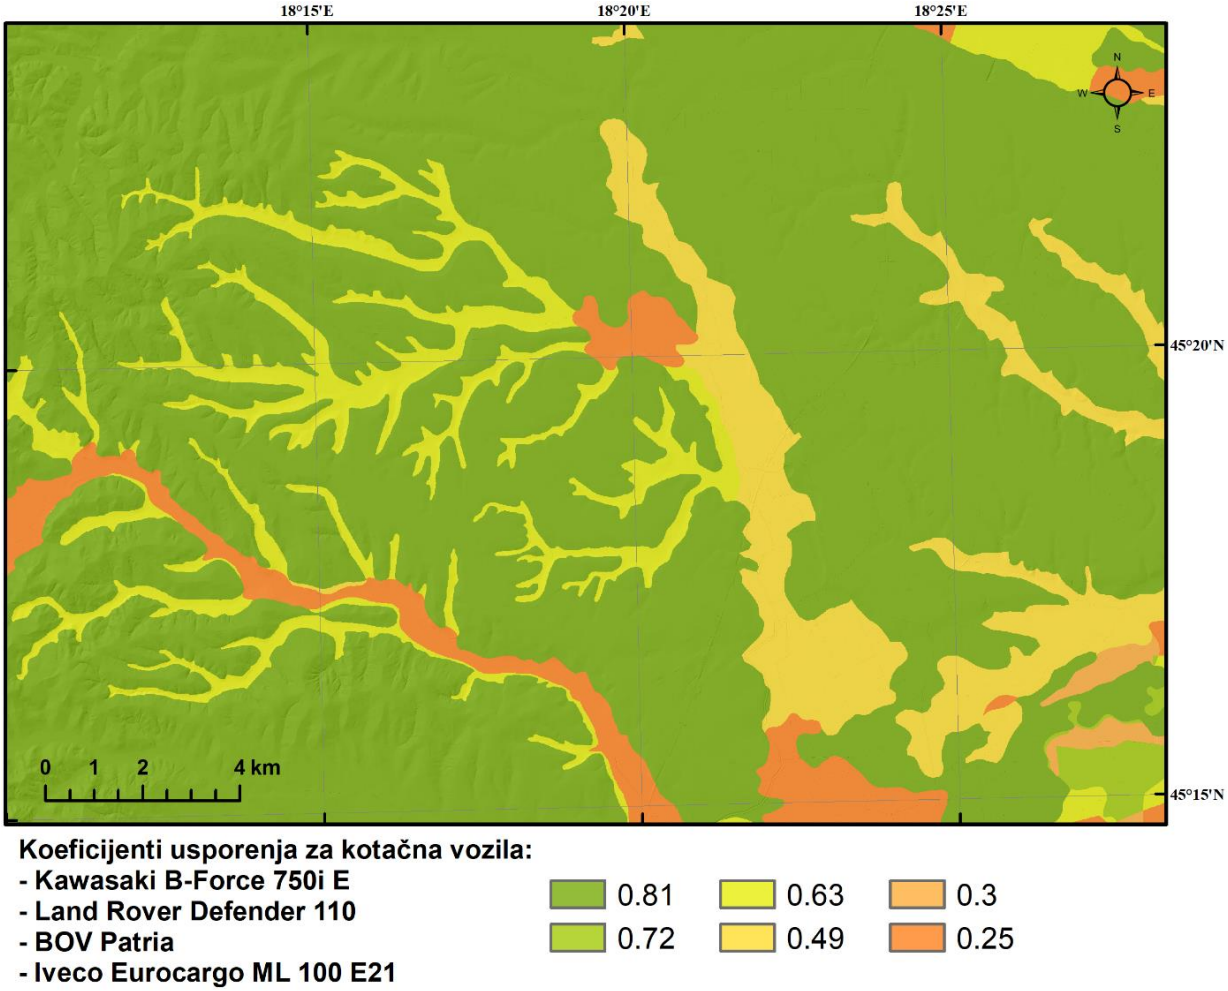

Sl. 79. Koeficijenti usporenja zajedničkog utjecaja klizanja vozila i ljepljivosti tla za kotačna vozila

Za razliku od kotačnih vozila, gusjeničari imaju bolje manevarske sposobnosti, jer njihove gusjenice bolje prianjaju uz tlo. Kod gusjeničara je izostao efekt klizanja vozila uslijed mokre podloge, pa je prema Sl. 80. vidljivo da i kod njih najproblematičnije područje mobilnosti (0.5 koeficijent usporenja) predstavljaju nedrenirani aluviji koji u podlozi imaju gline visoke plastičnosti (CH). Sva ostala područja, osim glina visoke plastičnosti (CH) na aluviju, ne ograničavaju kontrolu vožnje u većoj mjeri.

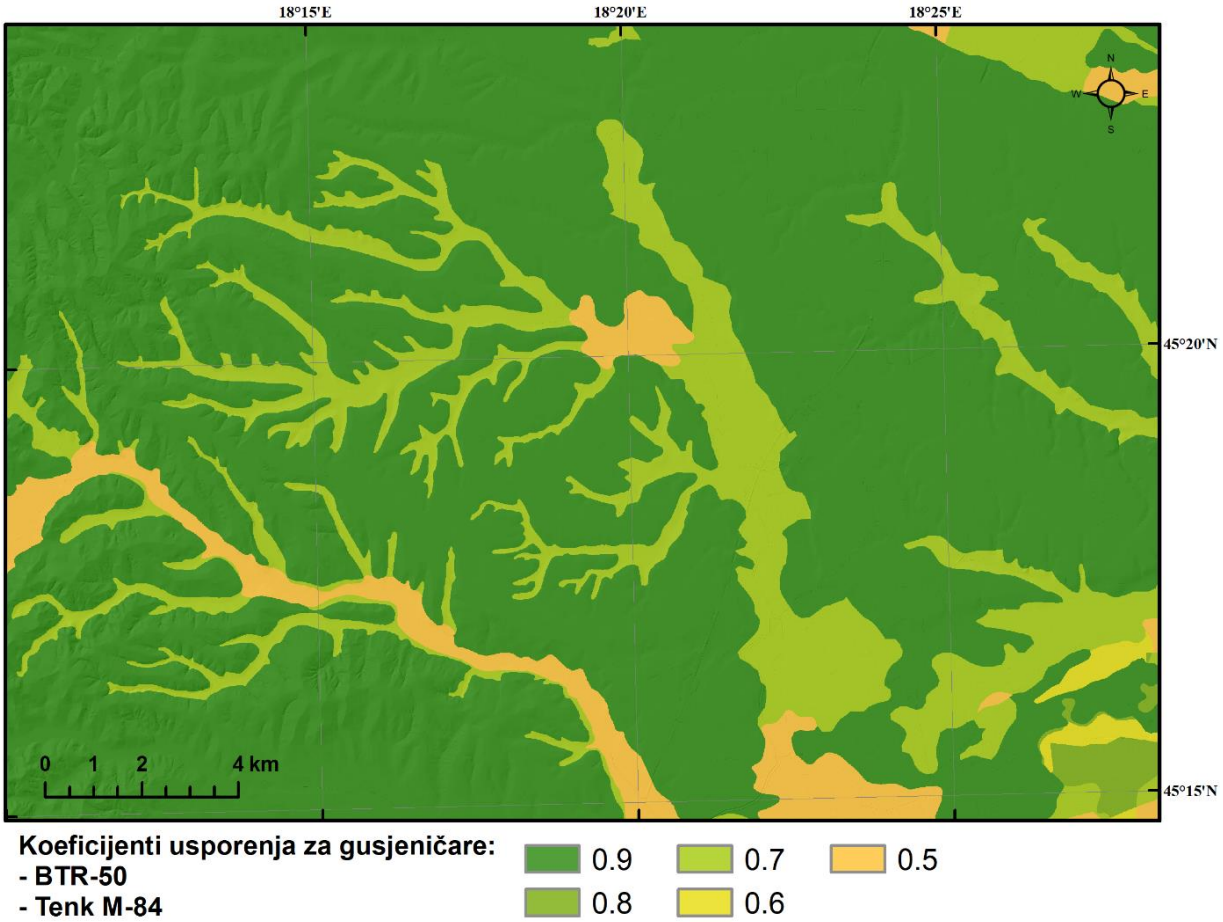

Sl. 80. Koeficijenti usporenja za gusjeničare uslijed ljepljivosti tla

4.4. Hidrološki faktor

Sve vodene površine koja su jezera ili ribnjaci su neprohodne za sva vozila.

Prisutnost stalnih vodotoka također je definirana sukladno scenarijima „ljeto/jesen – suho“ i „zima/proljeće – mokro“. Za scenarij „ljeto/jesen – suho“ dobiveni su rezultati sukladno Sl. 6., dok je prisutnost stalnih vodotoka za scenarij „zima/proljeće – mokro“ komplementarna stanju prikazanom na Sl. 2. Stoga su, ukoliko ne presuše, svi stalni vodotoci neprohodni za sva vozila.

Utjecaj povremenih vodotoka na prohodnost vozila opisan je u Poglavlju 4.2. Hrapavost terena.

4.4.1. Analiza točnosti DMR-a na linijskim hidrografskim objektima

Terenskim mjerenjima i prostornim analizama prethodila je preliminarna premisa o potrebitoj točnosti ulaznih podataka prilikom izrade DMR-a, odnosno njegove upotrebe prilikom izrade sloja nagiba reljefa. Prema primjeru iz Sl. 81. je vidljivo da povećanjem gustoće ulaznih podataka i rezultati DMR-a postaju bliži stvarnoj situaciji na Zemljinoj površini.

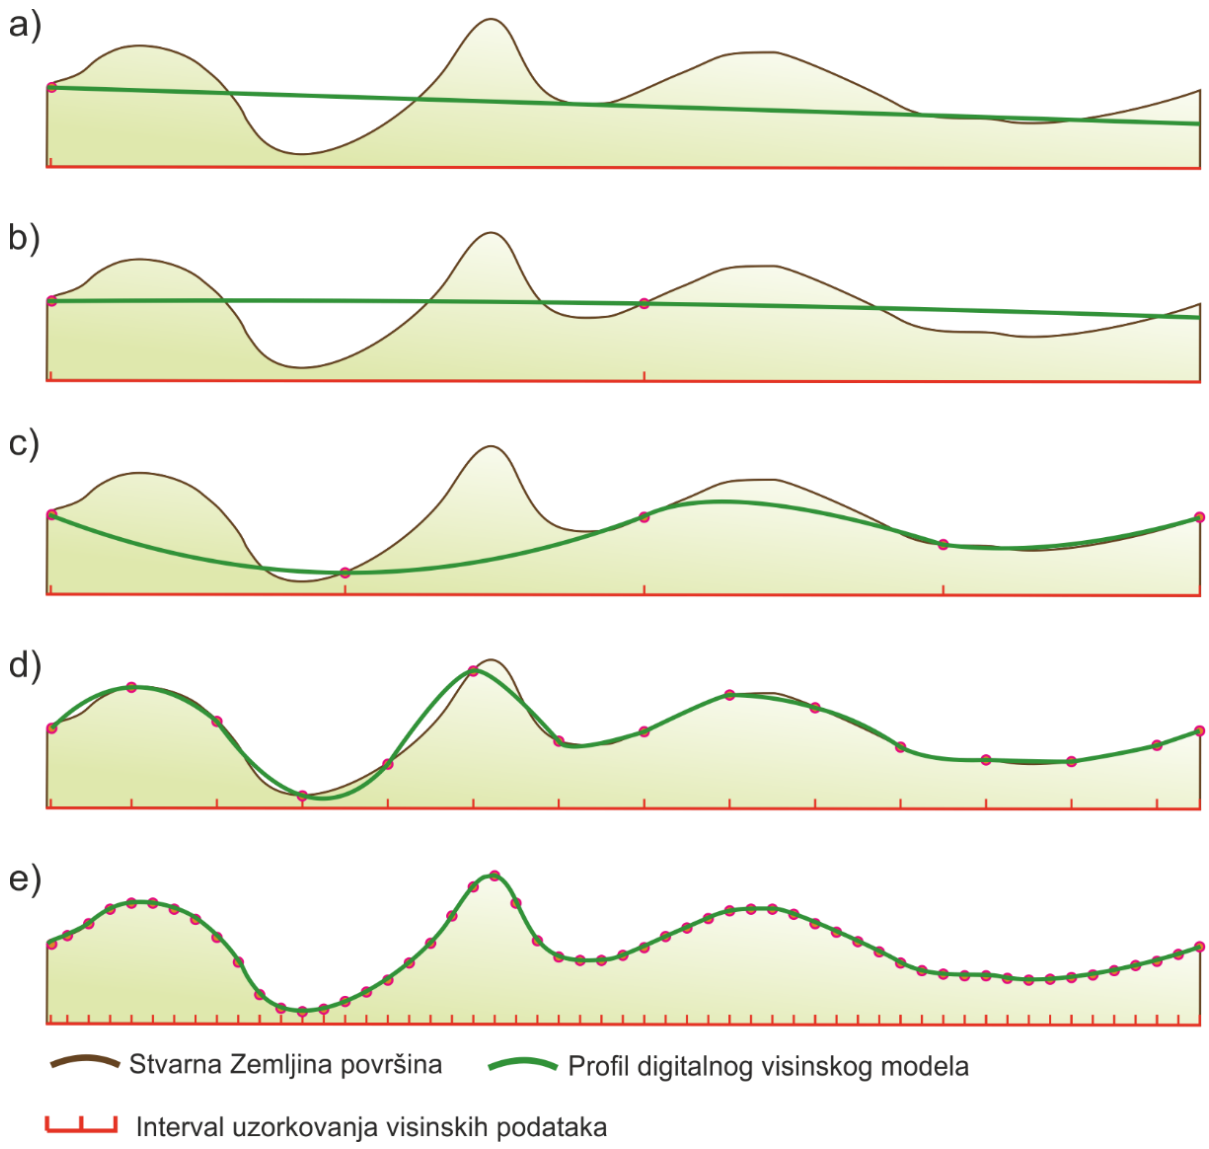

Sl. 81. Shematski prikaz ovisnosti točnosti visinskog prikaza Zemljine površine i gustoće uzorkovanja izvornih visinskih podataka

Prilikom provedbe preliminarnih analiza odabira potrebne prostorne rezolucije rasterskih podataka uočena je nužnost provedbe daljnjih analiza i mjerenja. Predmetna problematika odnosi se na područja izrazito ravničarskih obilježja, odnosno na terasne nizine i značajna dijelove lesne zaravni. Primjer područja sa Sl. 82. ukazao je na nužnost odabira rasterskih podataka visoke rezolucije. Prema Sl. 82. jasno je vidljiv „gubitak“ informacija smanjenjem prostorne rezolucije rasterskih podataka. Sl. 82. (a) rasterskog prikaza rezolucije ćelija 1x1 m sadržava najviše informacija, te je na njoj zabilježen i najveći kut nagiba zemljišta koji iznosi 45.3°. Slijedno padom rezolucije do Sl. 82. (e) pri veličini ćelija 25x25 m maksimalni zabilježeni kut nagiba iznosio je 4.8°.

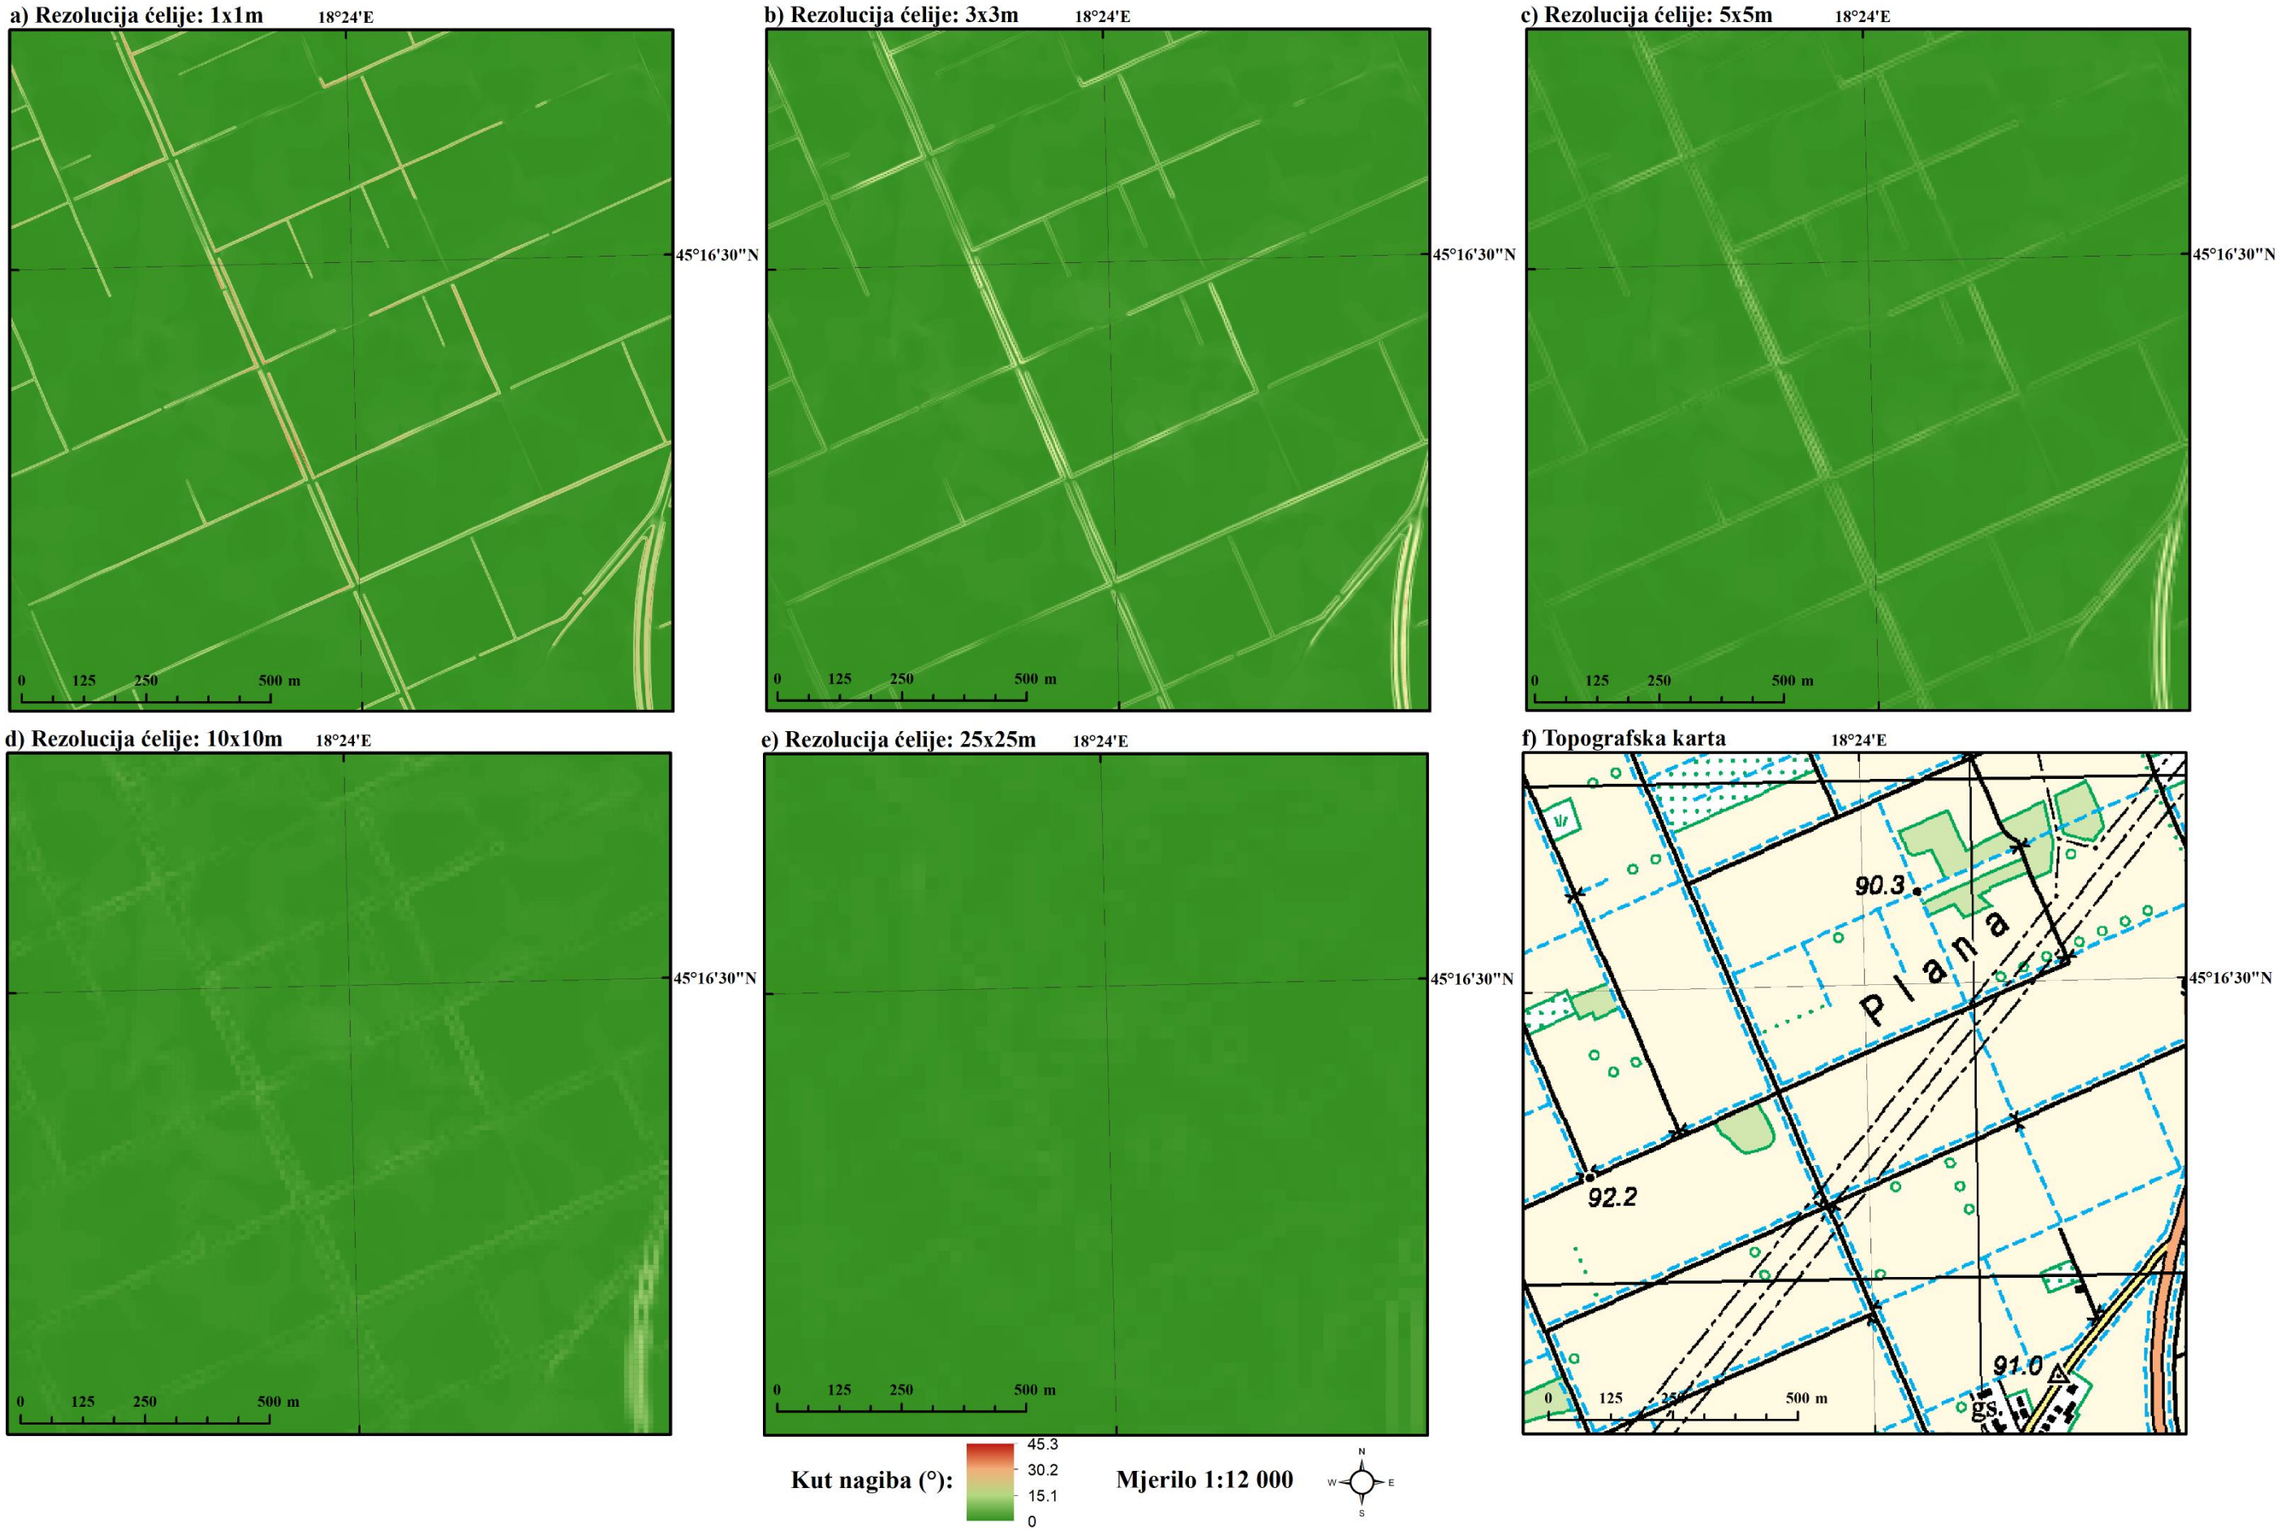

Sl. 82. Prikaz utjecaja različitih rezolucija rasterskih podataka na kvalitetu i detaljnost prikaza nagiba ravničarskog reljefa

Temeljem preliminarnih uvida i spoznaje da različite rezolucije DMR-ova daju različite rezultate pristupilo se terenskim mjerenjima. Provedba terenskih mjerenja poprečnih profila vodotoka laserskim daljinomjerom imala je dva cilja. Prvim se željela utvrditi točnost podataka DMR-a u odnosu na situaciju na zemljištu, a drugim definirati referentnu rastersku rezoluciju ćelija za provedbu analiza na razini čitavog modela. Terenskim mjerenjima i prostornim analizama poprečnih profila vodotoka uspoređene su maksimalne vrijednosti nagiba, jer prisutni maksimalni nagib je ujedno i „kritični moment“ koji determinira način i uvjete prelaska preko nekog linijskog objekta. Provedenim mjerenjima na 51 lokaciji (Sl. 48.) na osnovu analize rezultata dviju grupa podataka prikazanih u Tab. 17. i Tab. 18. dobiveni su sljedeći rezultati:

- Pri većim nagibima terena kod preferirane grupe lokacija (Tab. 17.), najmanja srednja ukupna odstupanja (σ) od 8.7° imao je raster rezolucije 1x1 m. Srednje ukupno odstupanje rastera rezolucije 0.5x0.5 m bilo je gotovo identično (8.9°).
- Na lokacijama temeljenim slučajnim odabirom (Tab. 18.), najmanja srednja ukupna odstupanja (σ) od (9.2°) imao je raster rezolucije 0.5x0.5 m. Srednje ukupno odstupanje rastera rezolucije 1x1 m bilo je također gotovo identično (9.3°).
- U obje grupe lokacija povećanjem rezolucije DMR-a (počevši od rezolucije 1x1 m) odstupanja rastu, a promjene su konstantne.
- Bez obzira na način odabira lokacije mjerenja, odstupanja unutar istovjetnih rasterskih rezolucija DMR-a su vrlo slična.

Tab. 17. Odstupanja vrijednosti nagiba terena na poprečnim profilima dobivenih DMR-ovima i terenskim mjerenjima (preferirane lokacije)

ID lokacije	Mjerenje laserskim daljinomjerom (°)	Odstupanja DMR-a u stupnjevima (°)				
		raster 10x10 m	raster 5x5 m	raster 3x3 m	raster 1x1 m	raster 0.5x0.5 m
1001	21.8	15.8	11.4	1.9	4.6	4.6
1002	34.9	29.0	19.3	8.3	4.3	4.6
1003	37.0	26.3	16.0	9.1	8.0	7.7
1004	31.7	18.2	11.6	3.5	1.7	1.8
1005	26.0	10.2	3.0	0.5	0.4	0.4
1006	39.6	30.2	21.3	10.7	15.0	19.1
1007	33.9	28.8	20.9	15.7	11.3	11.3
1008	27.7	25.0	18.8	11.4	8.2	8.2
1009	56.8	47.4	41.8	35.9	29.9	29.9
1010	48.1	45.9	39.0	32.3	16.1	16.1
1011	42.9	41.2	35.9	26.3	12.7	12.7
1012	56.8	53.6	46.3	39.2	29.8	29.6
1013	41.4	33.2	21.9	14.8	7.4	7.3
1014	37.1	31.3	22.8	14.8	8.0	8.0
1015	26.1	19.6	11.8	3.9	2.7	2.7
1016	36.3	31.7	24.2	17.8	10.9	10.9
1017	27.7	25.6	19.0	13.5	3.7	3.9
1018	30.1	28.9	23.8	15.9	0.6	5.5
1019	34.1	33.5	31.6	28.0	21.0	19.3
1020	29.9	28.6	26.8	24.7	11.7	11.3
1030	34.7	18.5	11.7	8.1	7.8	7.8
1031	39.3	34.8	25.5	18.8	7.6	7.5
1032	27.8	23.3	15.3	5.2	5.7	6.8
1033	26.8	24.8	20.7	13.0	7.2	8.5
1034	27.4	24.8	15.9	14.4	6.1	5.5
1035	24.5	22.7	17.6	11.0	5.0	5.4
1036	26.4	25.7	21.1	13.4	4.0	4.0
1037	34.9	30.5	25.1	19.0	2.6	9.1
$\sum$		**809.0**	**620.0**	**430.9**	**253.9**	**269.5**
σ		**22.5**	**17.9**	**13.5**	**8.7**	**8.9**

Tab. 18. Odstupanja vrijednosti nagiba terena na poprečnim profilima dobivenih DMR-ovima i terenskim mjerenjima (lokacije temeljem slučajnog odabira)

ID lokacije	Mjerenje laserskim daljinomjerom (°)	Odstupanja DMR-a u stupnjevima (°)				
		raster 10x10 m	raster 5x5 m	raster 3x3 m	raster 1x1 m	raster 0.5x0.5 m
2001	27.5	13.0	8.7	4.5	2.7	2.7
2002	34.5	32.7	28.5	26.4	9.0	7.3
2003	34.0	29.1	22.3	13.7	1.8	1.8
2004	34.3	30.5	24.7	20.7	15.3	15.3
2005	29.9	24.2	15.1	10.1	3.6	3.3
2006	44.3	40.2	38.1	32.3	27.6	27.5
2007	46.1	40.3	38.4	30.0	6.0	4.8
2008	65.8	63.0	56.7	50.4	41.8	41.7
2009	32.3	28.8	22.9	16.4	11.1	10.9
2010	40.9	38.7	31.0	25.2	4.7	1.5
2011	28.4	26.5	23.2	20.2	12.3	12.2
2013	29.0	28.0	25.8	23.4	18.3	18.3
2014	33.2	18.9	8.6	0.9	1.5	1.5
2015	38.2	34.3	30.2	22.8	13.1	13.0
2016	20.6	5.0	3.0	6.8	8.1	8.2
2017	27.6	26.3	24.0	18.3	0.3	8.2
2018	28.5	25.7	19.1	11.2	2.1	2.1
2019	40.9	36.0	29.0	22.1	10.6	10.5
2020	30.7	29.1	26.8	23.7	6.9	5.4
2021	34.7	28.6	18.7	7.9	6.0	6.0
2022	43.5	39.7	32.2	22.5	13.6	13.5
2023	36.4	34.9	33.2	30.3	16.9	15.4
2024	25.1	20.7	13.6	6.6	2.2	2.0
∑		**694.3**	**573.7**	**446.4**	**235.3**	**232.9**
σ		**21.6**	**18.4**	**14.9**	**9.3**	**9.2**

Rezultati prostornih analiza istaknuli su dva potencijalna rastera kao adekvatna za korištenje prilikom modeliranja. Rasteri rezolucija 1x1 m i 0.5x0.5 m imaju gotovo identična ukupna odstupanja koja se u zbroju razlikuju samo 0.1° (primjer Sl. 83.). Stoga je za potrebe daljnjih analiza korišten raster rezolucije ćelija 1x1 m. Jedan od razloga odabira rezolucije 1x1m je potreban prostor za pohranu podataka, jer rasteri rezolucije 0.5x0.5 m zauzimaju mnogo memorije. Razlozi odbacivanja rastera rezolucije 0.5x0.5 m su što bi se njegovim korištenjem učetverostručio memorijski prostor potreban za pohranu, a što je još važnije, ne bi došlo do poboljšanja kvalitete rezultata. Zaključeno je da raster DMR rezolucije 1x1 m svojom točnošću

prikaza primjeren za GIS model, te da se njegovim odstupanjima neće narušiti vjerodostojnost daljnjih izračuna modela TPV.

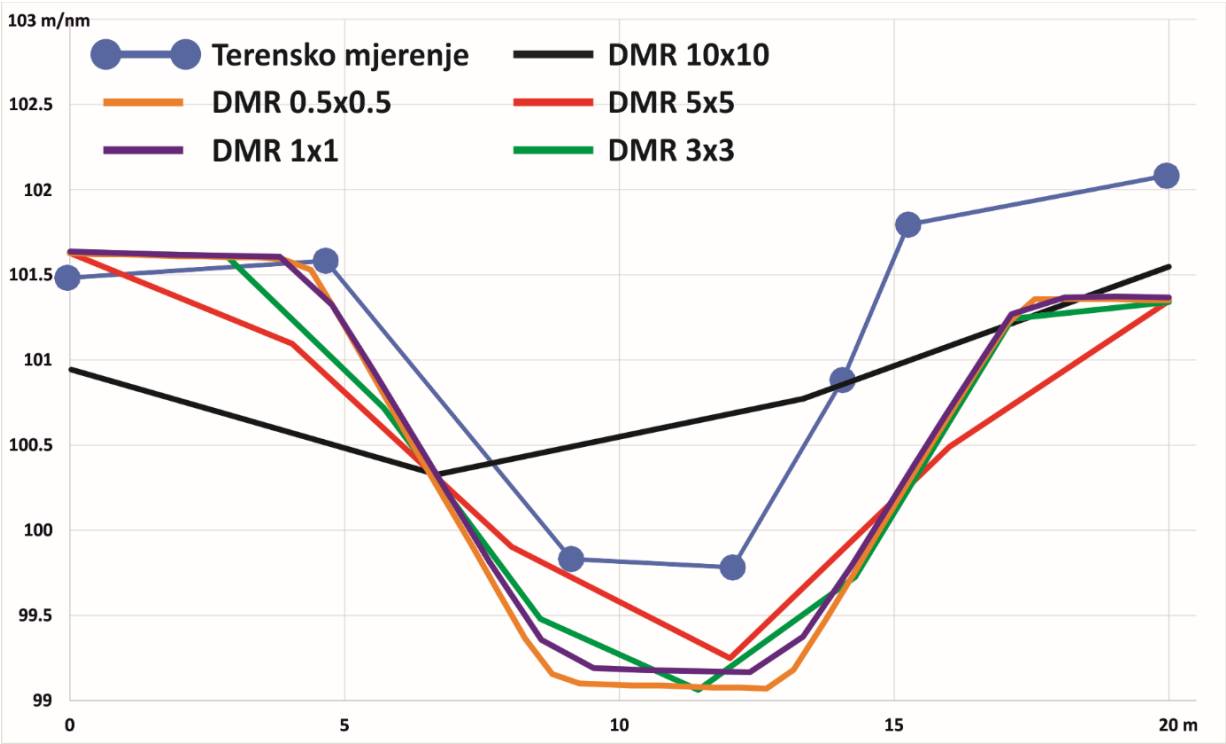

Sl. 83. Usporedba poprečnih profila terena na lokaciji 1014 (Kašnica – Satnica Đakovačka zapad)

4.4.2. Prohodnost dna stalnih vodotoka

Prohodnost dna stalnih vodotoka utvrđena je mjerenjima KI (Sl. 84.). Na svih 9 lokacija izmjereni KI na „kritičnim“ dubinama ne bi omogućio poprečni prelazak vodotoka bilo kojeg tipa vozila. Na nekim lokacijama na kritičnoj dubini od 30 cm vrijednosti KI zadovoljavaju uvjete prolaska vozila, no pri većim dubinama KI ponovno opada ispod razina KIV. Treba napomenuti da bi rezultati mjerenja zasigurno bili i mnogo niži s obzirom da na nekim mjestima zbog dubine vode mjerenje KI nije provedeno na sredini vodotoka, odnosno matici rijeke, već uz rub obale.

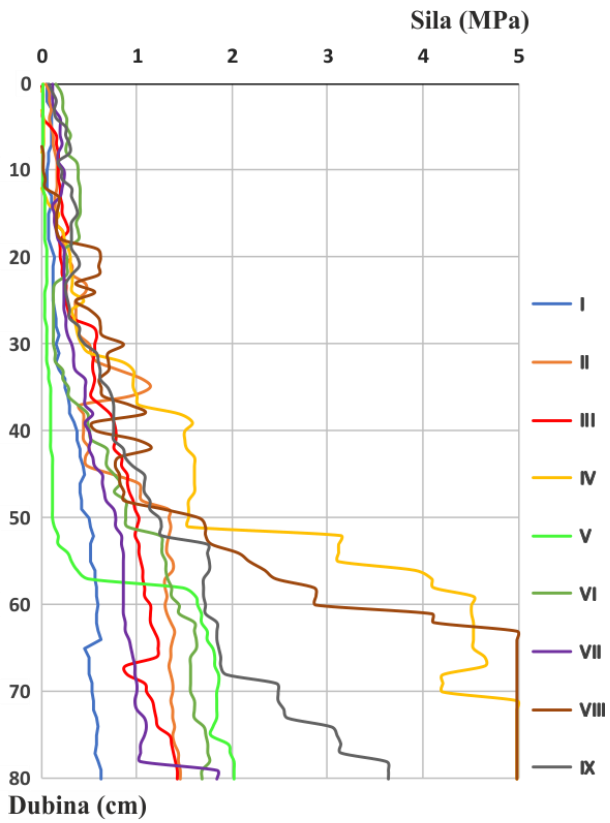

Sl. 84. Prodirne značajke tla na dnu korita stalnih vodotoka (lokacije vidi na Sl. 52.)

4.5. Vegetacijski faktor

4.5.1. Prohodnost šumske vegetacije

Utvrđivanju razmaka između stabala, prethodio je izračun prosječnog promjera stabala na prsnoj visini šumske sastojine. Uvidom u Sl. 85. vidljivo je da glavnina površina pokrivenih šumom ima stabla prosječnog promjera do 40 cm (97.2 %). Temeljem ovog podatka, a obzirom da debljina stabala na prsnoj visini korespondira sa starosti šumske sastojine možemo reći da ovaj prostor zahvaćaju mlade šume i šume srednje starosti.

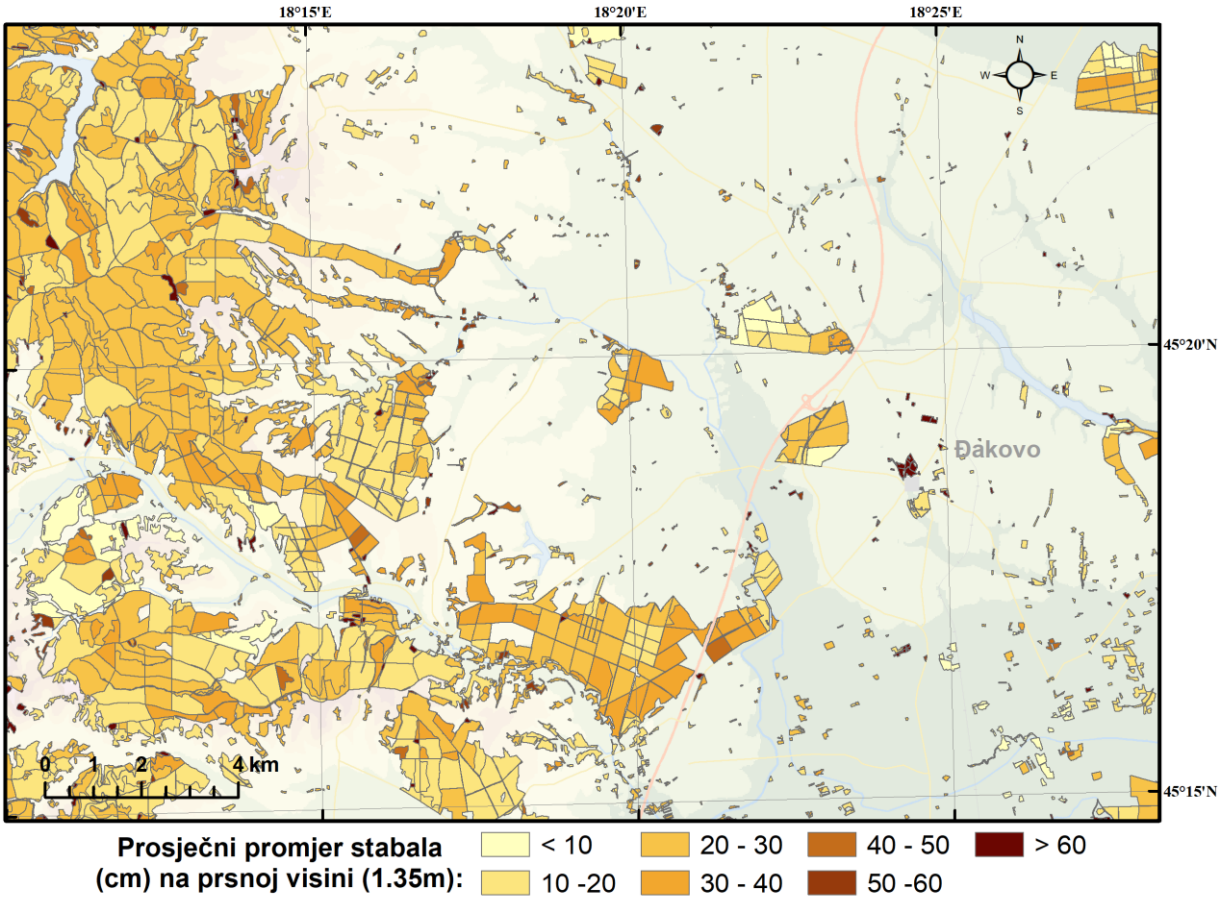

Sl. 85. Prosječni promjer stabala (cm) na prsnoj visini (1.35m)

Sloj prohodnosti šuma dobiven je temeljem prostornih analiza i statističkom obradom podataka koji su prikazani na Sl. 86. i Tab. 19. Gustoća stabala, odnosno razmak u prostoru je heterogen, jer iz kartografskog prikaza nije moguće istaknuti neku prostornu cjelinu koja bi se mogla izdvojiti temeljem nekog jednoznačnog kriterija.

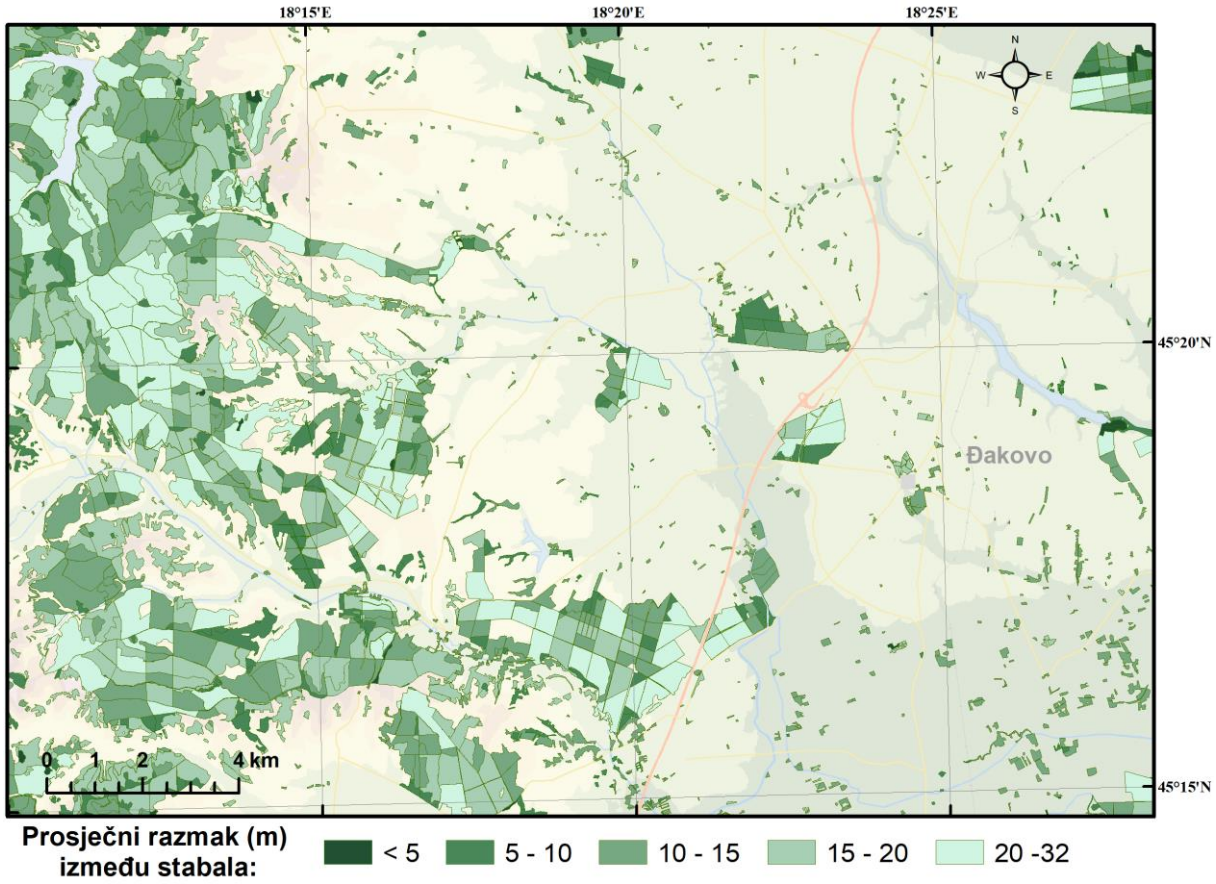

Sl. 86. Prosječni razmak (m) između stabala unutar šumske sastojine

Iz tabličnog prikaza u Tab. 19. statistička obrada podataka ukazuje da je tek 1.23 km^2 ili 1.14 % ukupne površine pod šumom (do 5.7 metara razmaka) neprohodno za sve tipove vozila. Nadalje, uvjetno prohodne šume obuhvaćaju (od 5.7 do 14 metara razmaka) 30.28 km^2 ili 28.02 %. Neometanu prohodnost omogućava 76.56 km^2 ili 70.84 % ukupne površine pod šumskom vegetacijom. Analizom je utvrđeno da na području istraživanja ne postoji šuma čiji je razmak manji od 5 metara, a da pri tome sastojina stabala ima srednji promjer veći od 60 cm. Stoga možemo zaključiti da šumske površine ne ograničavaju pokret za Tenk M-84.

Tab. 19. Površina i udio šumske sastojine prema graničnim vrijednostima razmaka stabala za TPV

Prosječni razmak stabala (m)	Površina (km^2)	Udio ukupne površine pokrivene šumom (%)
< 1.8[a]	0.01	0.01
< 3[b]	0.03	0.02
< 4.8[a]	0.50	0.47
< 5[e,f]	0.64	0.59
< 5.7[c,d]	1.23	1.14
< 7.2[b]	2.87	2.66
< 11[d]	12.86	11.90
< 11.3[c]	14.83	13.72
< 12.4[e]	20.88	19.32
< 14[f]	31.51	29.16
< 20	78.91	73.02
< 32	108.07	100.00
Σ	108.07	

[a] Kawasaki B-Force 750 4x4i

[b] Land Rover Defender 110

[c] BOV Patria

[d] Iveco Eurocargo ML 100 E21 4x4

[e] BTR-50

[f] Tenk M-84

4.5.2. Prohodnost ostale vegetacije

Prisutni tipovi vegetacije prikazani su na Sl. 8., dok je detaljniji prikaz prema načinu kultiviranja vidljiv na Sl. 54. Način obrade zemljišta, odnosno njegov vegetacijski pokrov omogućava izrazito dobru prohodnost zemljišta. Stanje prohodnosti zemljišta u Tab. 20. iskazano je površinskim udjelima pojedinih tipova vegetacije prema kategorijama mobilnosti. Oranice omogućavaju veliku mobilnost vozila i njima je pokriveno 46.71 % ukupne površine.

Oranice dominiraju u području lesne zaravni i terasnih nizina. Značajniji ograničavajući faktor mobilnosti za neka niža vozila (Kawasaki B-Force 750i E i Land Rover Defender 110) predstavljaju jare visoke kulture (16.97 %) u ljetnom i jesenskom periodu. One ne priječe mobilnost samog vozila, već svojom visinom onemogućavaju vizualnu preglednost vozaču kod upravljanja vozilom. Ukoliko oranicama pridružimo i livade (10.98 %) možemo zaključiti da je više od polovine, odnosno 57.97 % područja iznimno pogodno za pokret vozila.

Voćnjaci zauzimaju 4.03 % područja, te svojom prisutnošću uvjetuju mobilnost u smislu kanaliziranja kretanja vozila između zasađenih stabala, jer njihova pravolinijska sadnja i razmak omogućavaju nesmetan prolaz svim tipovima vozila (naročito grmolike kulture).

Grmlje obuhvaća 2.83 % površine i ono je zastupljeno poglavito uz rubove šumskih područja i na manjim zapuštenim, uglavnom nedreniranim površinama uz vodotoke. Grmlje predstavlja značajan problem jedino za Kawasaki B-Force 750i E, jer je narušena sigurnost vozača koji nije zaštićen od vanjskih utjecaja tijekom vožnje.

Tab. 20. Površinski udjeli ostale vegetacije (bez šuma) na području istraživanja

Vegetacija	Površina (km^2)	Udio (%) u ukupnoj površini područja istraživanja
Grmlje	11.16	2.83
Livada	43.30	10.98
Oranica: ozime kulture	72.15	18.30
Oranica: jare - niske kulture	45.10	11.44
Oranica: jare - visoke kulture	66.93	16.97
Vinograd	6.63	1.68
Voćnjak - stablašice	13.69	3.47
Voćnjak - grmolike biljke	2.20	0.56
Živica	0.95	0.24
Σ	262.11	66.47

Neprohodno područje za pojedina vozila čine vinogradi (1.68 %) i živičnjaci (0.24 %). Glavni ograničavajući faktor prohodnosti za BOV Patriu, BTR-50 i Tenk M-84 predstavljaju

površine kultivirane vinovom lozom. Čimbenik neprohodnosti uvjetovan je infrastrukturnim obilježjima (armaturni stupci i metalna žica) uzgajane kulture. Područja kultivirana pod vinogradima odnose se na prisojne padine pobrđa oko naselja Mandićevac na sjeverozapadu i Trnave na jugozapadu.

Živičnjaci su neprohodni za Kawasaki B-Force 750 4x4i. Neprohodnost ovog vozila uvjetovana je nezaštićenošću i izloženosti vozača vanjskim faktorima. Područja prekrivena živičnjacima u pravile se nalaze u koritima povremenih vodotoka koji služe kao odvodni kanali oborinskih voda s oranica koje okružuju. Živičnjaci su prisutni na području lesne zaravni i terasnih nizina.

4.6. Antropogeni faktor

Krajnji utjecaj antropogenih čimbenika na sveukupnu TPV prikazan je na Sl. 87. Područja pod utjecajem antropogenih čimbenika raščlanjena su u tri kategorije prohodnosti vozila, odnosno:

- Neprohodno zemljište – zauzimaju područja naselja (25), gdje prostor neprohodnim čine čvrsti objekti stambene namjene. Najveća koncentracija stambenih objekata nalazi se u jedinom naselju urbanog karaktera – Đakovu. Grad Đakovo smješten je na lesnoj zaravni. Ostala – seoska naselja imaju obilježja niznih naselja gdje su kuće linijski poredane uz prometnice. Na lesnoj zaravni je najveća koncentracija i veličina naselja (Drenje, Đakovačka Satnica, Gašinci, Ivanovci Gorjanski, Kućanci Đakovački, Kuševac, Mandićevac, Selci Đakovački, Preslatinci, Pridvorje, Tomašanci i Viškovci). Terasna nizina ima nekoliko naselja (Budrovci, Novi Perkovci i Piškorevci), dok prostori pobrđa Dilje gore (Dragotin, Harkanci Đakovački, Kondrić, Levanjska Varoš, Majar, Ovčara, Svetoblažje i Trnava) i krajni istočni obronci Krndije (Borovik) imaju vrlo slabu naseljenost.
- Uvjetno prohodno zemljište – obuhvaća komplementaran prostor prethodno opisanih naselja, gdje se dodatno ističu prostori koji obuhvaćaju šire područje Grada Đakova koji je svojim industrijsko – proizvodnim subjektima zahvatio šire urbano područje.
- Prohodno zemljište – čine cestovna mreža i željeznička pruga. Lesna zaravan i terasne nizine imaju dobro razvijenu cestovnu povezanost u svim smjerovima. Cestovna

premreženost pobrđa je slabija, što je uvjetovano energijom reljefa i slabom naseljenošću prostora.

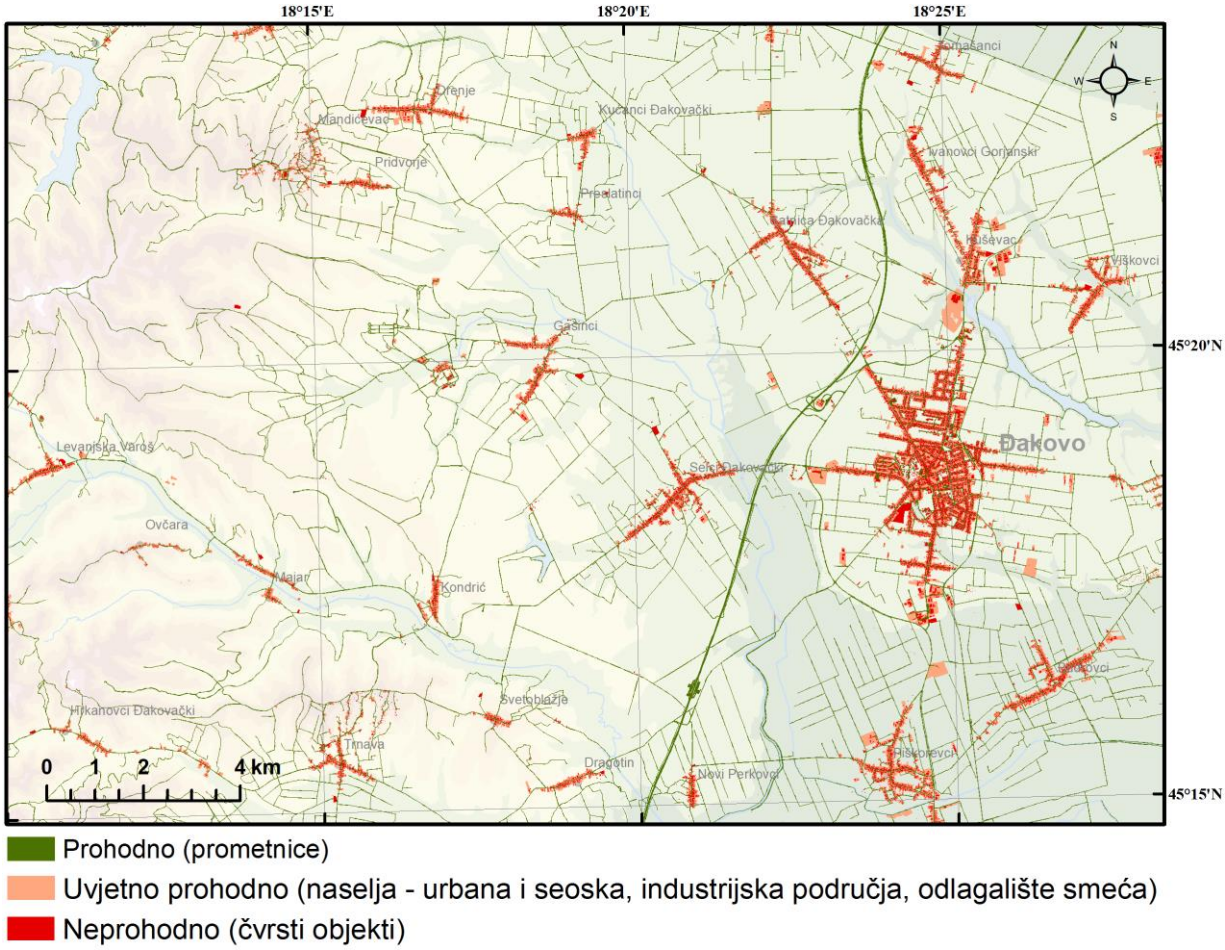

Sl. 87. Utjecaj antropogenih čimbenika na prohodnost vozila

4.7. Vizualizacija i interpretacija rezultata

Završetkom svih analiza i uvidom u rezultate istraživanja uočeno je da se rezultati ne mogu interpretirati uniformno, već da ih treba razdvojiti prema određenim specifičnostima koje ovise isključivo o fizičko-geografskim čimbenicima. Stoga su rezultati prikazani u dva scenarija koje su predodredili faktori tla, vodotoci i vegetacija.

Godišnji ciklus je podijeljen u dva perioda koji su determinirani minimalnim i maksimalnim vrijednostima KI tla. Scenarij „zima/proljeće – mokro“ definiran je na osnovu niskih vrijednosti KI. Prilikom izračuna prohodnosti tla preuzete u najniže izmjerene vrijednosti KI i vlažnosti tla prema referentnom periodu mjerenja provedenom između 30. travnja i 4. svibnja. Sukladno pedološkim obilježjima, u sklopu ovog scenarija uključen je faktor klizanja vozila i ljepljivosti tla. Period „ljeto/jesen – suho“ prezentira polovicu godine kada je nosivost tla prema rezultatima mjerenja KI bila najviša. U izračun su uključene vrijednosti KI i vlažnosti tla prema periodu mjerenom između 26. i 30. kolovoza.

Prilikom izračuna prema scenariju „zima/proljeće – mokro“ preuzete su informacije o izvorišnim mjestima stalnih vodotoka na temelju CROTIS baze. U scenarij „ljeto/jesen – suho“ uključeni su stalni vodotoci određeni terenskim kartiranjem. Terenskim kartiranjem na stalnim vodotocima su određena uzvodna mjesta na kojima postoji prisutnost vodenog toka tijekom ljeta.

Dvjema grupama godišnjih doba pridružene su i vegetacijske faze rasta biljaka, te s njima povezani tipični načini obrade tla kod oranica u ratarstvu. Oraničnim i livadskim kulturama pridružene su vrijednosti usporenja vozila na osnovu stanja pri njihovom vegetacijskom maksimumu. Dok su drugi kriterij dodijele koeficijenata usporenja činile težišne poljoprivredne aktivnosti, odnosno faze stagnacije poljoprivrednih radova na oranicama.

Ostali čimbenici i njihovi faktori usporenja nisu mijenjani u odnosu na scenarij TPV.

4.7.1. Karta terenske prohodnosti vozila

Prikupljanjem, analizom i strukturiranjem prostornih podataka fizičko-geografskih čimbenika stvoren je rasterski sloj rezolucije ćelija 1x1 m koji u sebi sadrži ukupne koeficijente usporenja vozila svih prisutnih čimbenika. Jedan od izlaznih proizvoda analiza čine karte maksimalnih mogućih brzina kretanja vozila (KMMBKV) (Choi, i dr., 2019; Pearson i Wright, 1980). KMMBKV pružaju detaljan uvid u ograničena i preferirana područja kretanja vozila. One su u suštini detaljniji prikaz uvjeta TPV. Ako prohodnost terena raščlanimo u tri osnovne kategorije prohodnosti i usporedimo ih s KMMBKV tada dobivamo informacije o:

- **neprohodnom terenu** – na KMMBKV: brzina kretanja vozila od 0 km/h,
- **uvjetno prohodnom terenu** – na KMMBKV: brzina kretanja vozila od 0.1 – 40 km/h,
- **prohodnom terenu** – na KMMBKV: brzina kretanja vozila 40 km/h.

Strukturiranje i analiza podataka obrađenih GIS modelom omogućila je uvid u rezultate putem tematskih kartografskih proizvoda koji se mogu razmatrati kroz različite stupnjeve detaljnosti. GIS model istovremeno omogućava planiranje aktivnosti i donošenje odluka na najnižim i najvišim razinama odlučivanja. Najviši stupanj detaljnosti prikaza može koristiti vozaču, jer omogućava donošenje odluka na objektnoj razini. Istovremeno, model omogućava prikaz i kartografsku podlogu na razini čitavog područja istraživanja, što je potrebno prilikom planiranja pokreta većeg broja vozila, kao što su vojne operacije ili akcije spašavanja i traganja prilikom prirodnih katastrofa. Kao ogledni primjeri mogućnosti kartografskog prikaza i njihove kvalitete upotrijebljeni su rezultati prohodnosti dobiveni za vozilo Land Rover Defender 110 (prema scenariju za period zima/proljeće – mokro). Na Sl. 88. prikazane su tri KMMBKV različitih mjerila. Na istom području kreirane su karte mjerila 1:1000, 1:3000 i 1:10000. Uvid u najviše detalja omogućava karta mjerila 1: 1000. Ovaj stupanj umanjenja omogućava jasno izdvajanje pojedinih fizičko-geografskih pojava i antropogenih objekata. Pri čemu se npr. mogu jasno izdvojiti kolni putevi opasani usječenim odvodnim kanalima. Umanjenjem mjerila jasno je vidljivo da i detaljnost prikaza informacija opada. Dok npr. na karti mjerila 1:10 000 jasno se mogu izdvojiti blage konkavne udoline (nepravilni izduženi oblici na karti istaknuti crvenom bojom - neprohodno) nastale uslijed derazijskih procesa, koje se izdvajaju svojom većom vlažnosti tla i dužim zadržavanjem oborinskih voda.

U sljedeća dva poglavlja bit će prikazano 12 karata koje opisuju prohodnost vozila za 6 tipova vozila prema dva scenarija: „ljeto/jesen – suho“ (Poglavlje 4.7.1.1) i „zima/proljeće – mokro“ (Poglavlje 4.7.1.2). Sve karte prikazane su u mjerilu 1:156200.

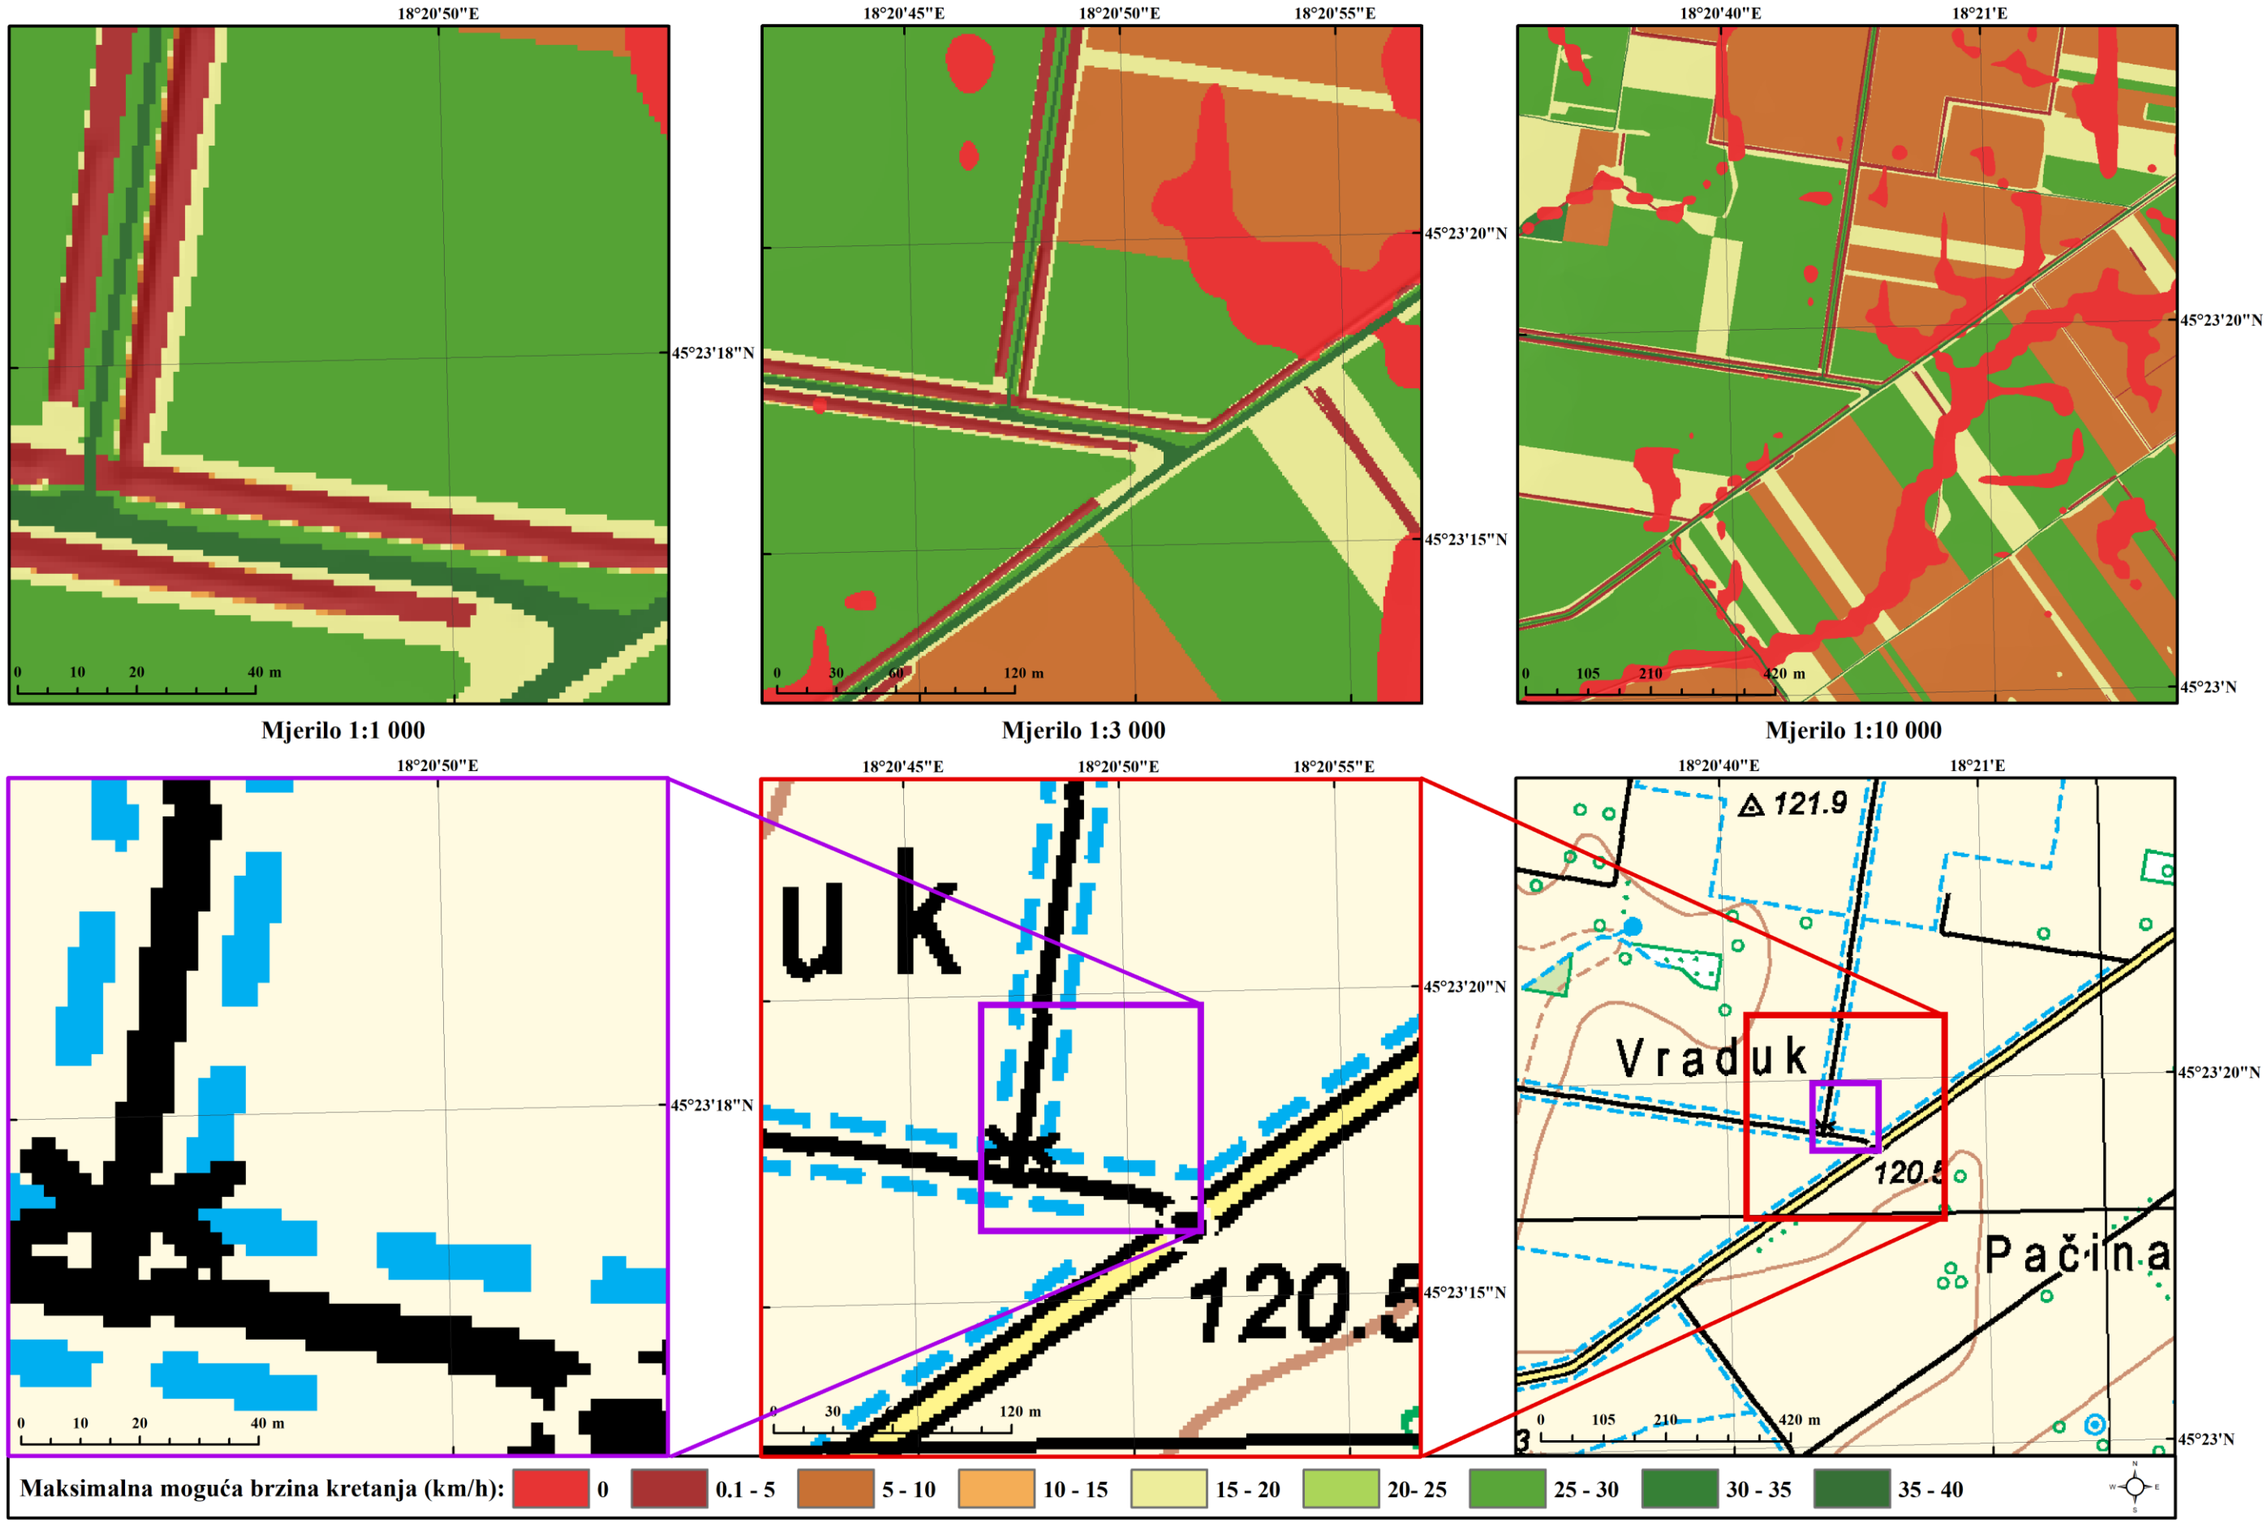

Sl. 88. Karte maksimalne moguće brzine kretanja (km/h) Land Rover Defendera 110 (zima/proljeće - mokro) u više mjerila

4.7.1.1. Karta terenske prohodnosti vozila (ljeto/jesen – suho)

U nastavku će za svako vozilo pomoću karata TPV biti opisani ograničavajući čimbenici TPV sukladno dominantnim fizičko-geografskim čimbenicima.

Prema scenariju ljeto/jesen – suho kod svih vozila antropogeni objekti, stalni vodotoci i vodene površine čine neprohodno zemljište, dok je utjecaj ostalih čimbenika na terensku prohodnost prema vrsti vozila sljedeći:

- Prema Sl. 89. za **Kawasaki B-Force 750 4x4i** osim prethodno navedenih čimbenika, područje neprohodnim čine:
  - živičnjaci uz kanale i kolne puteve koji se većinom nalaze na lesnoj zaravni i terasnim nizinama,
  - strmi odsjeci vodotoka,
  - kontaktna područja donjih dijelova strmih padina i dolina pobrđa na zapadu.

  Uvjetnu prohodnost područja omogućavaju oranične visoke kulture zasađene na lesnoj zaravni i terasnim nizinama, vinogradi na sjeveru i jugu, sporadična šumska područja pobrđa, povremeni vodotoci, kanali i nasipi lesne zaravni i terasnih nizina.

  Neometanu prohodnost pruža gotovo čitavo područje pobrđa i sve ostale oranice, te livade na lesnoj zaravni i terasnim nizinama.

- Prema Sl. 90. za **Land Rover Defender 110** osim prethodno navedenih čimbenika, područje neprohodnim čine:
  - kontaktna područja donjih dijelova strmih padina i dolina pobrđa na zapadu,
  - strmi odsjeci vodotoka.

  Uvjetnu prohodnost područja omogućavaju oranične visoke kulture zasađene na lesnoj zaravni i terasnim nizinama, vinogradi na sjeveru i jugu, sporadična šumska područja pobrđa, povremeni vodotoci, kanali i nasipi lesne zaravni i terasnih nizina.

  Neometanu prohodnost pruža gotovo čitavo područje pobrđa i sve ostale oranice, te livade na lesnoj zaravni i terasnim nizinama.

- Prema Sl. 91. za **BOV Patria** osim prethodno navedenih čimbenika, područje neprohodnim čine:

- kontaktna područja donjih dijelova strmih padina i dolina pobrđa na zapadu,
- strmi odsjeci vodotoka,
- vinogradi na sjeveru i jugu pobrđa,
- sporadična šumska područja pobrđa.

Uvjetnu prohodnost područja omogućavaju oranične visoke kulture zasađene na lesnoj zaravni i terasnim nizinama, sporadična šumska područja pobrđa, povremeni vodotoci, kanali i nasipi lesne zaravni i terasnih nizina.

Neometanu prohodnost pruža istočno područje pobrđa i sve ostale oranice, te livade na lesnoj zaravni i terasnim nizinama.

- Prema Sl. 92. za **Iveco Eurocargo ML 100 E21 4x4** osim prethodno navedenih čimbenika, područje neprohodnim čine:
  - kontaktna područja donjih i srednjih dijelova strmih padina i dolina pobrđa,
  - strmi odsjeci vodotoka,
  - sporadična šumska područja pobrđa.

Uvjetnu prohodnost područja omogućavaju oranične kulture zasađene na lesnoj zaravni i terasnim nizinama, vinogradi na sjeveru i jugu, sporadična šumska područja pobrđa, povremeni vodotoci, kanali i nasipi lesne zaravni i terasnih nizina.

Neometanu prohodnost pruža središnje područje pobrđa i te livade na lesnoj zaravni i terasnim nizinama.

- Prema Sl. 93. za **BTR-50** osim prethodno navedenih čimbenika, područje neprohodnim čine:
  - kontaktna područja donjih i dijelova strmih padina i dolina pobrđa na zapadu i središnjem dijelu,
  - strmi odsjeci vodotoka,
  - vinogradi na sjeveru i jugu pobrđa,
  - sporadična šumska područja pobrđa i lesnih gajeva.

Uvjetnu prohodnost područja omogućavaju sporadična šumska područja i povremeni vodotoci, kanali i nasipi lesne zaravni i terasnih nizina.

Neometanu prohodnost pruža istočno područje pobrđa i sve ostale oranice, te čitavi ostali prostor lesne zaravni i terasnih nizina.

- Prema Sl. 94. za **Tenk M-84** osim prethodno navedenih čimbenika, područje neprohodnim čine:
  - kontaktna područja donjih i srednjih dijelova strmih padina i dolina pobrđa na zapadu i središnjem dijelu,
  - strmi odsjeci vodotoka,
  - vinogradi na sjeveru i jugu pobrđa,
  - sporadična šumska područja pobrđa i lesnih gajeva.

Uvjetnu prohodnost područja omogućavaju sporadična šumska područja i povremeni vodotoci, kanali i nasipi lesne zaravni i terasnih nizina.

Neometanu prohodnost pruža područje istoka pobrđa i sve ostale oranice, te čitavi preostali prostor lesne zaravni i terasnih nizina.

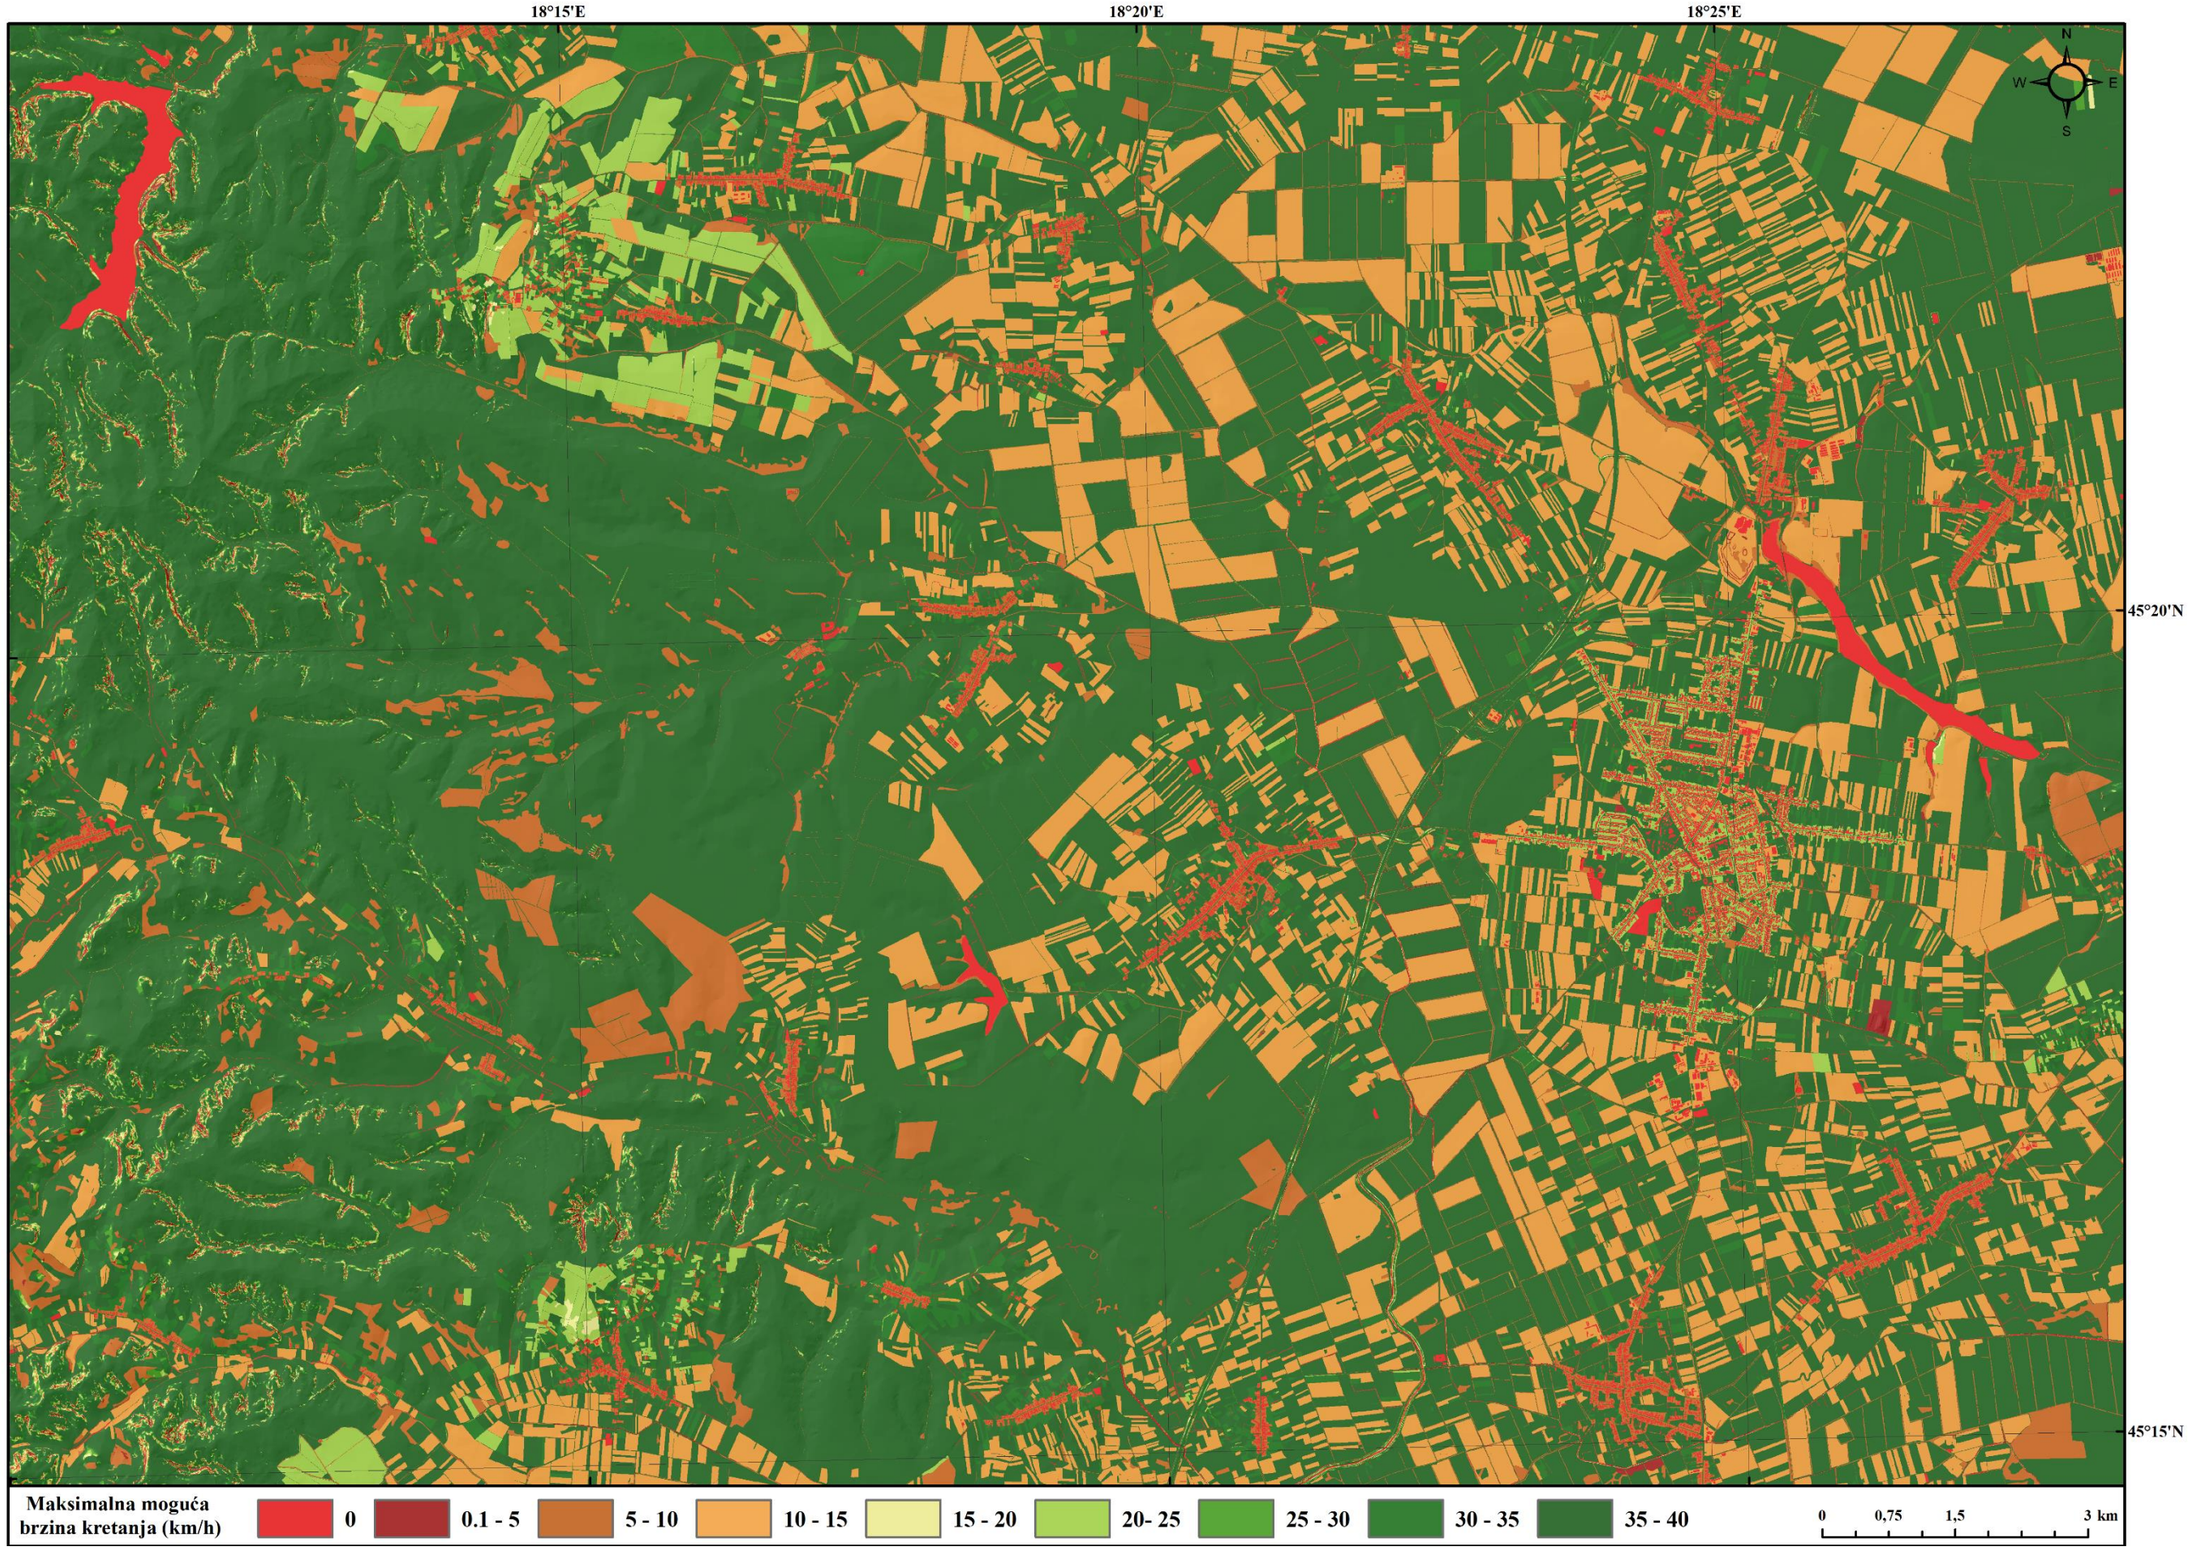

Sl. 89. Karta maksimalne brzine kretanja za Kawasaki B-Force 750 4x4i (ljeto/jesen – suho)

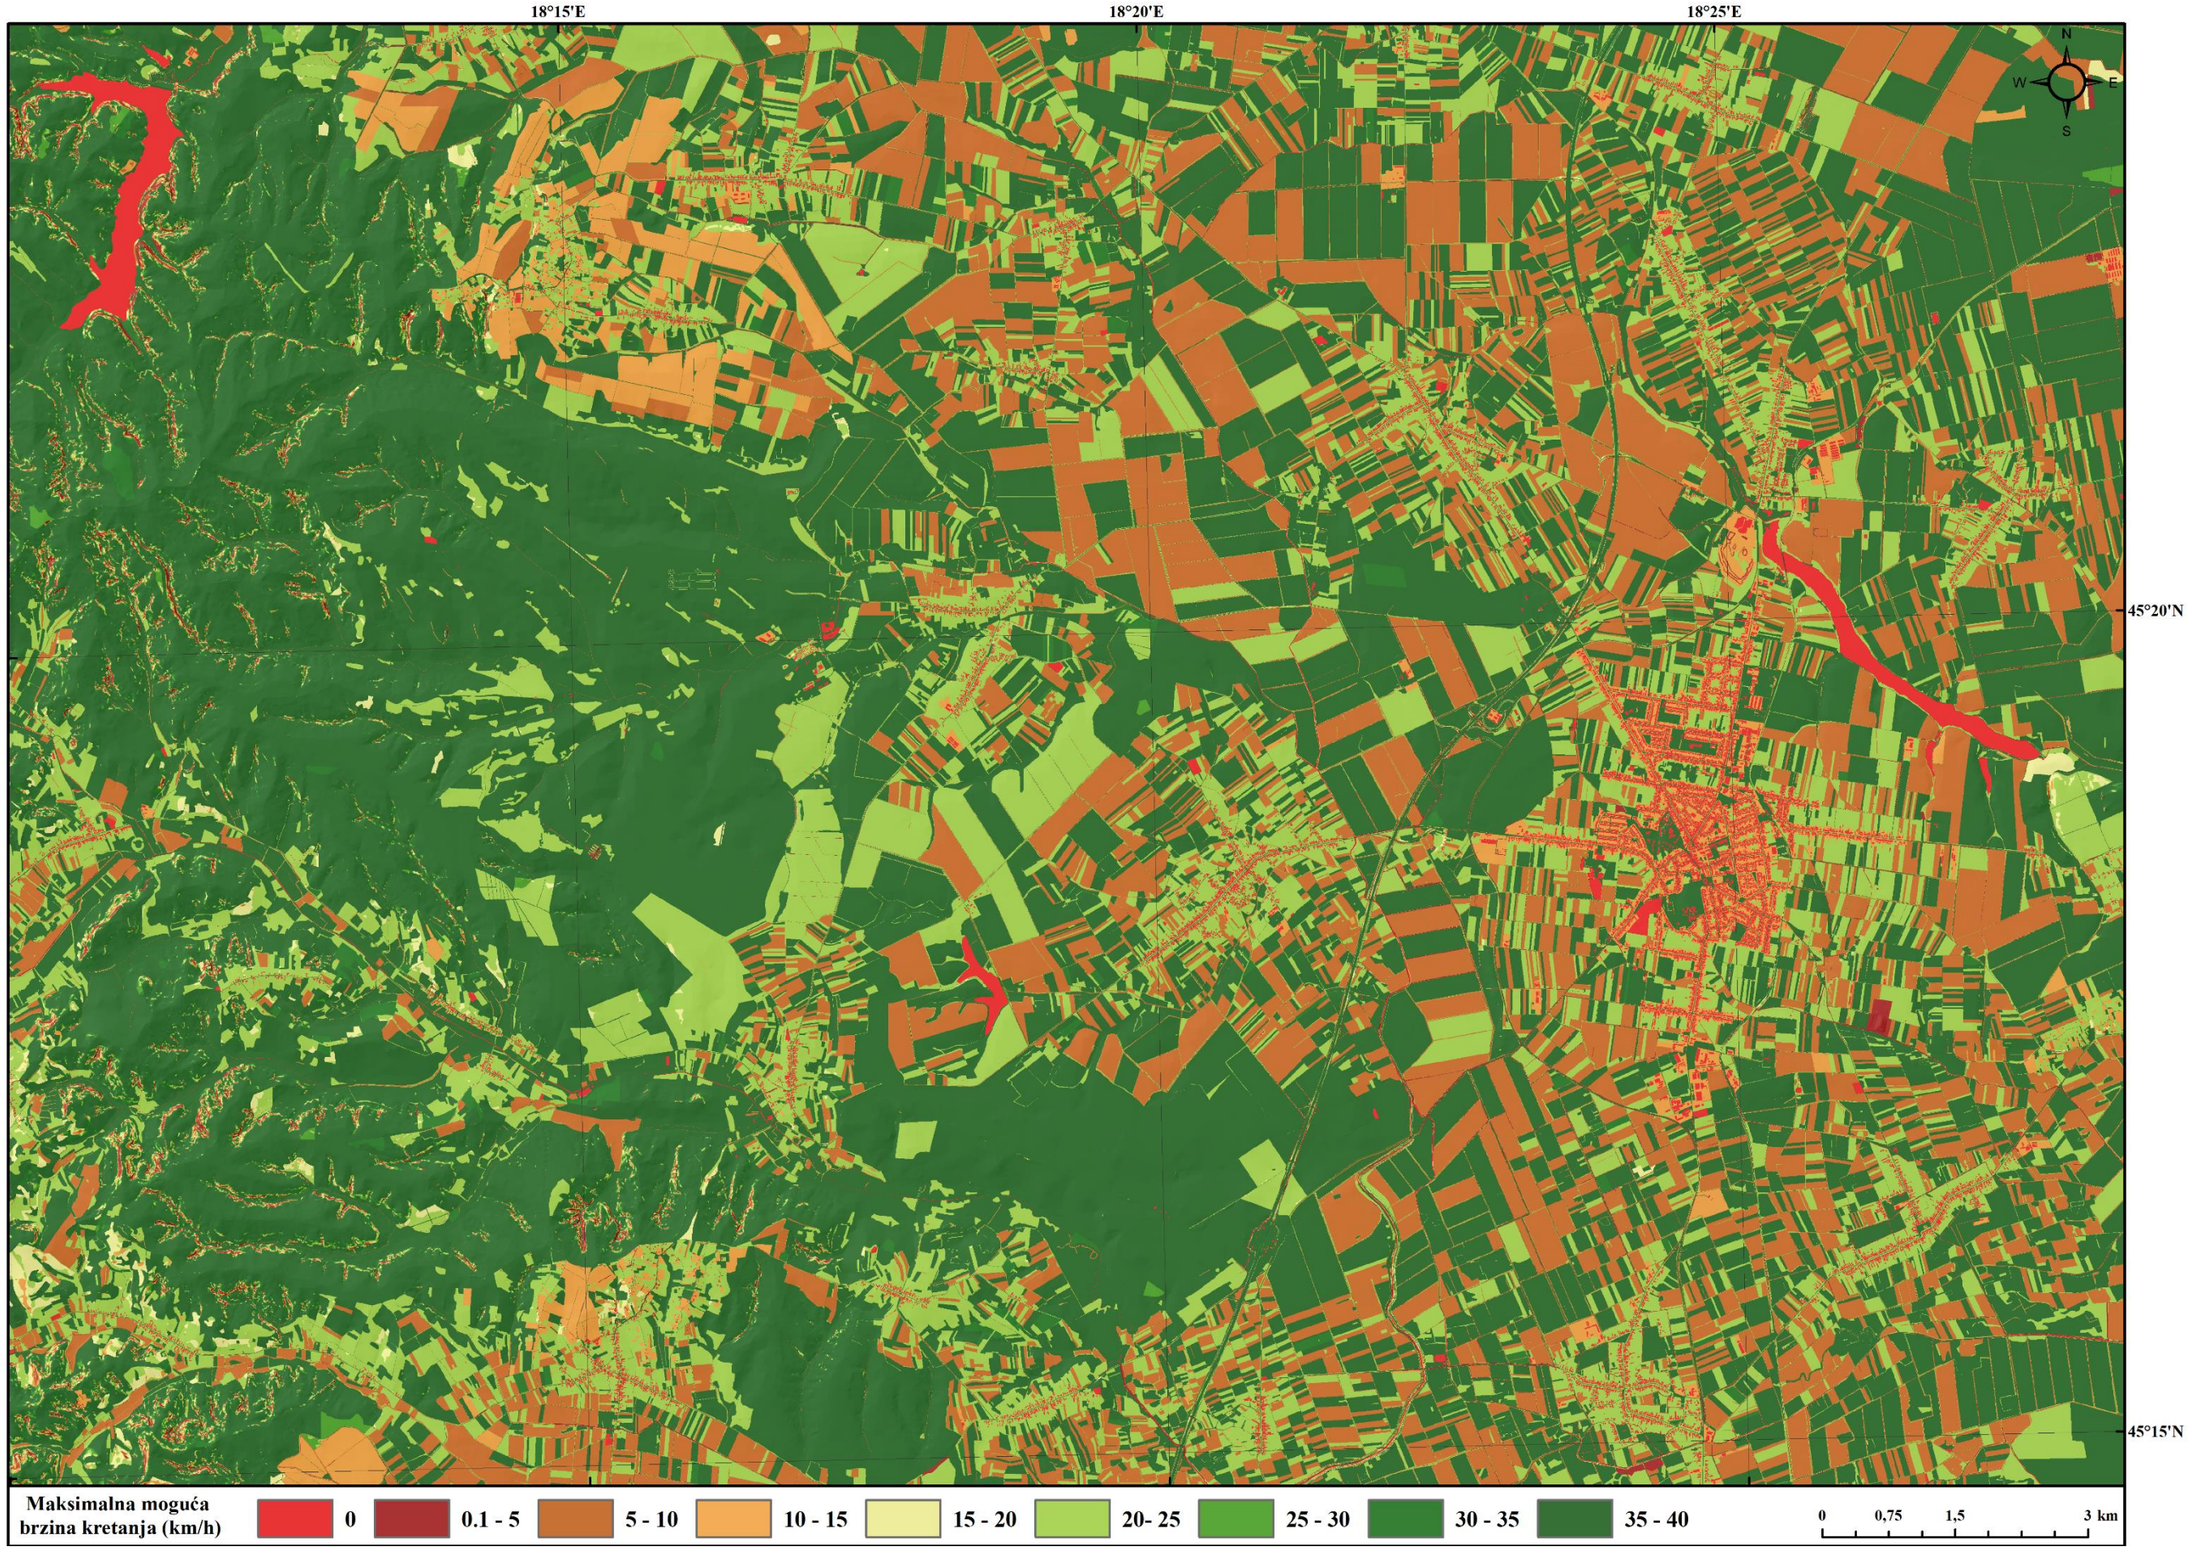

Sl. 90. Karta maksimalne brzine kretanja za Land Rover Defender 110 (ljeto/jesen – suho)

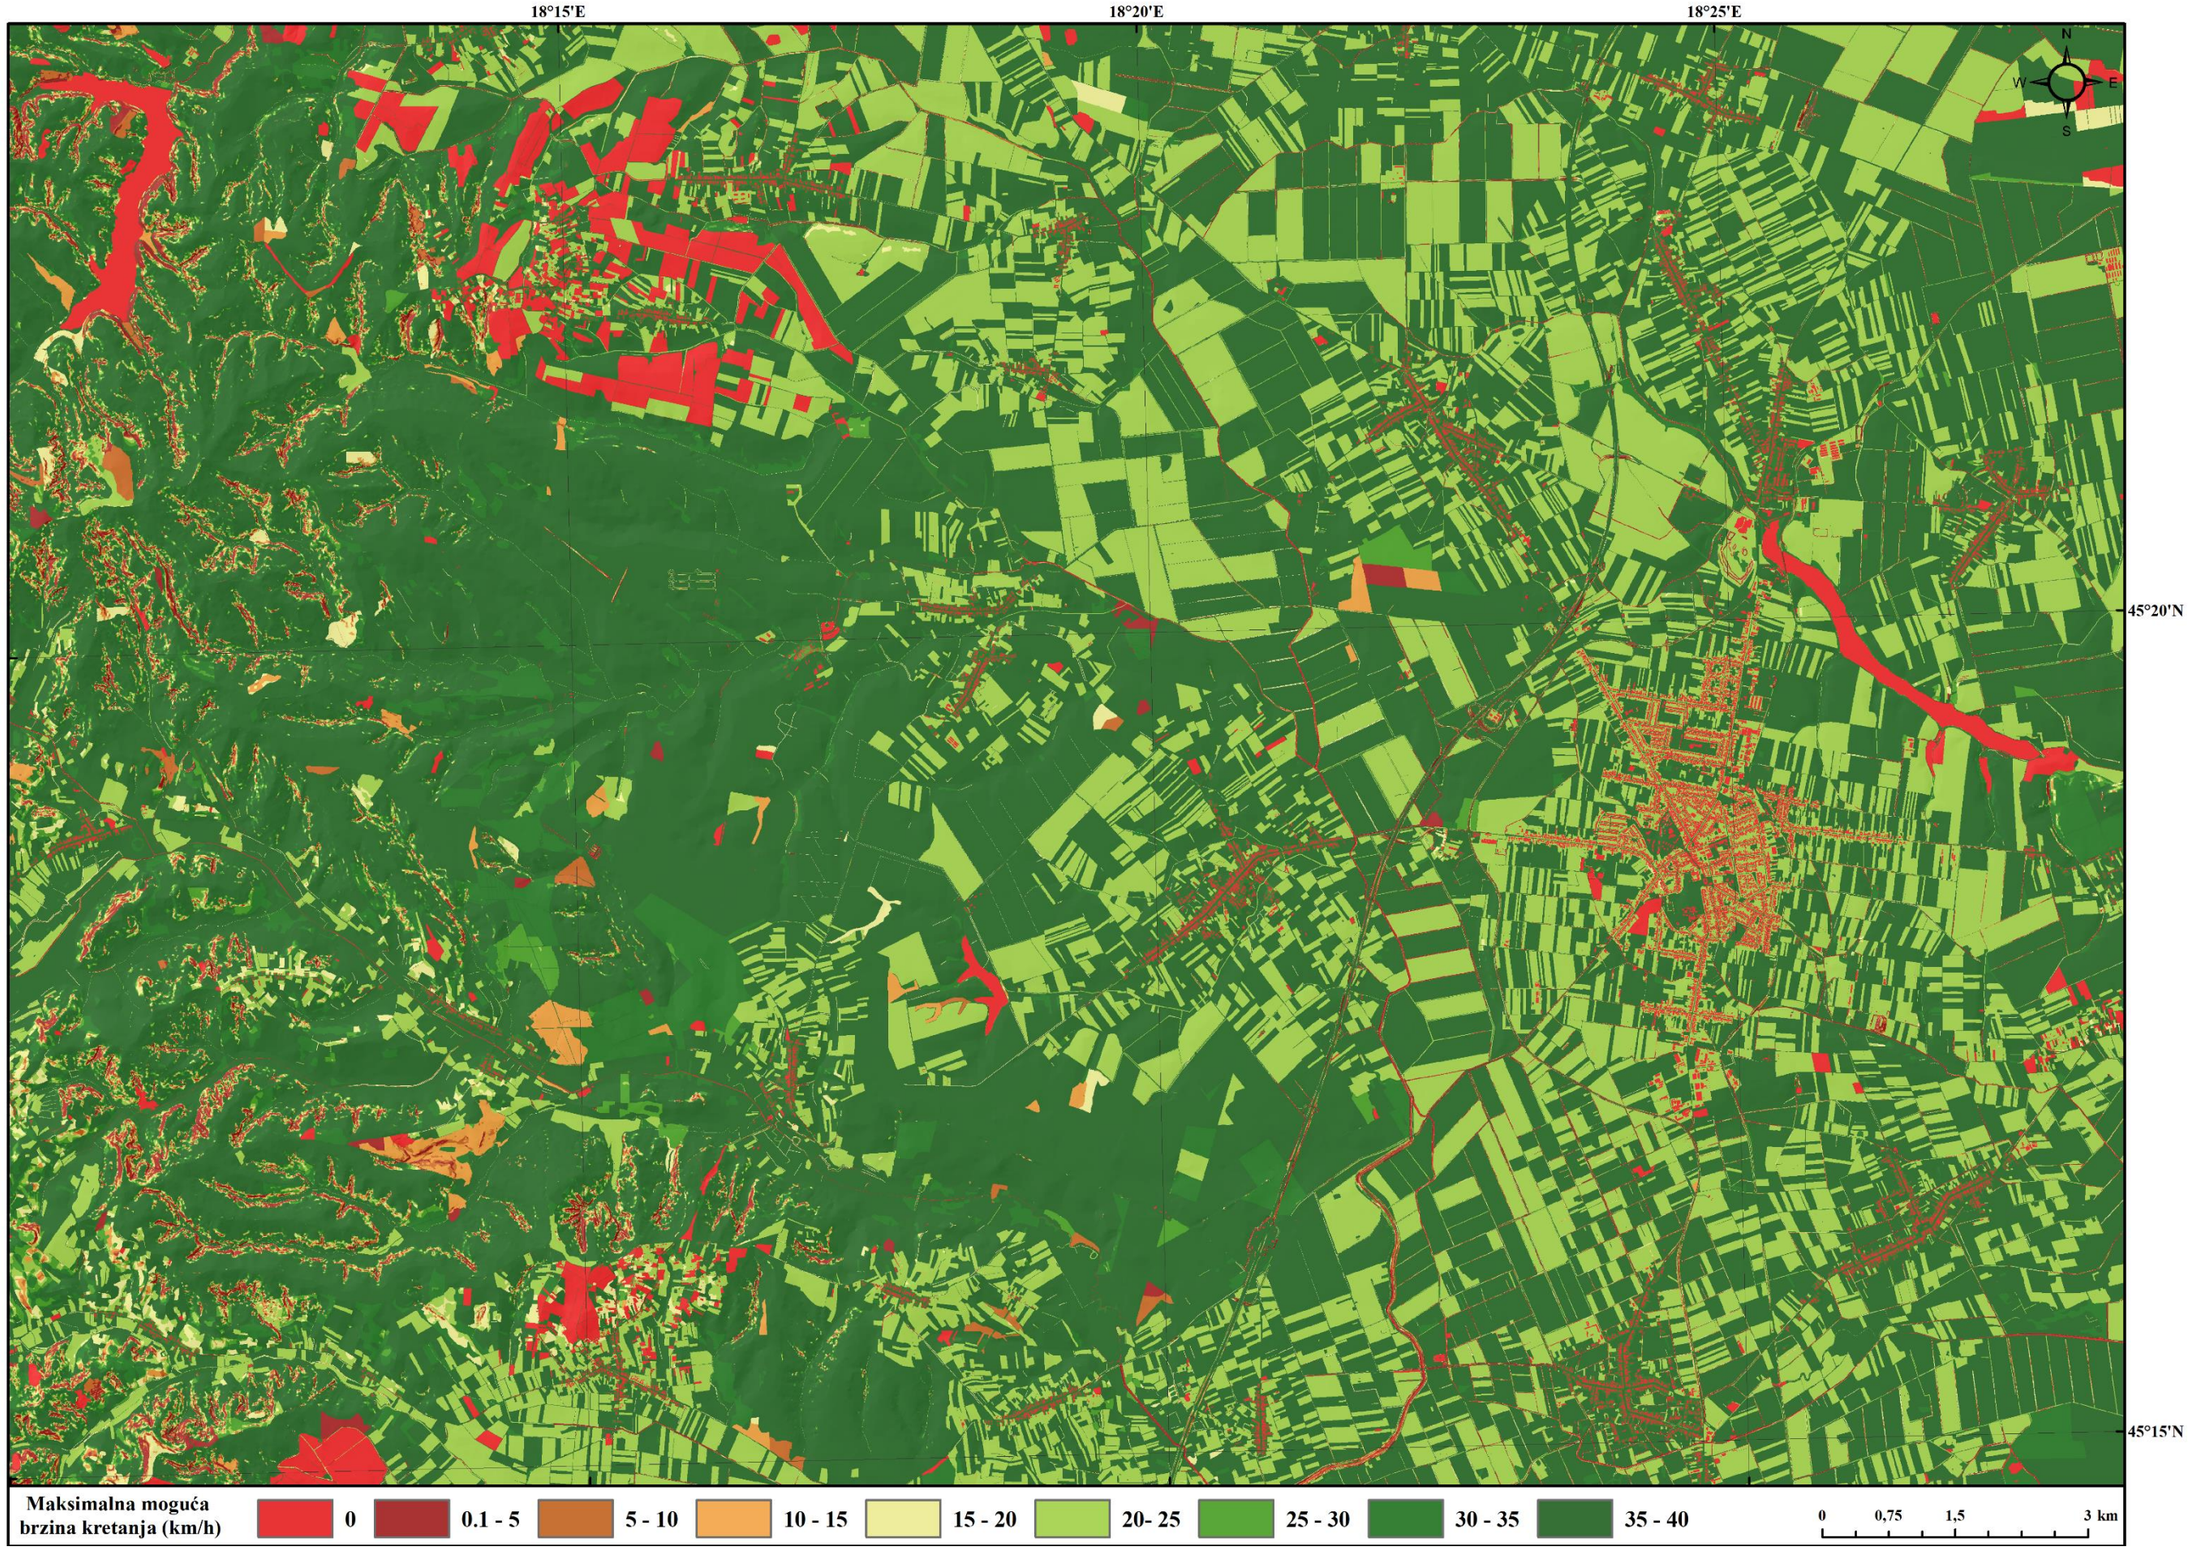

Sl. 91. Karta maksimalne brzine kretanja za BOV Patria (ljeto/jesen – suho)

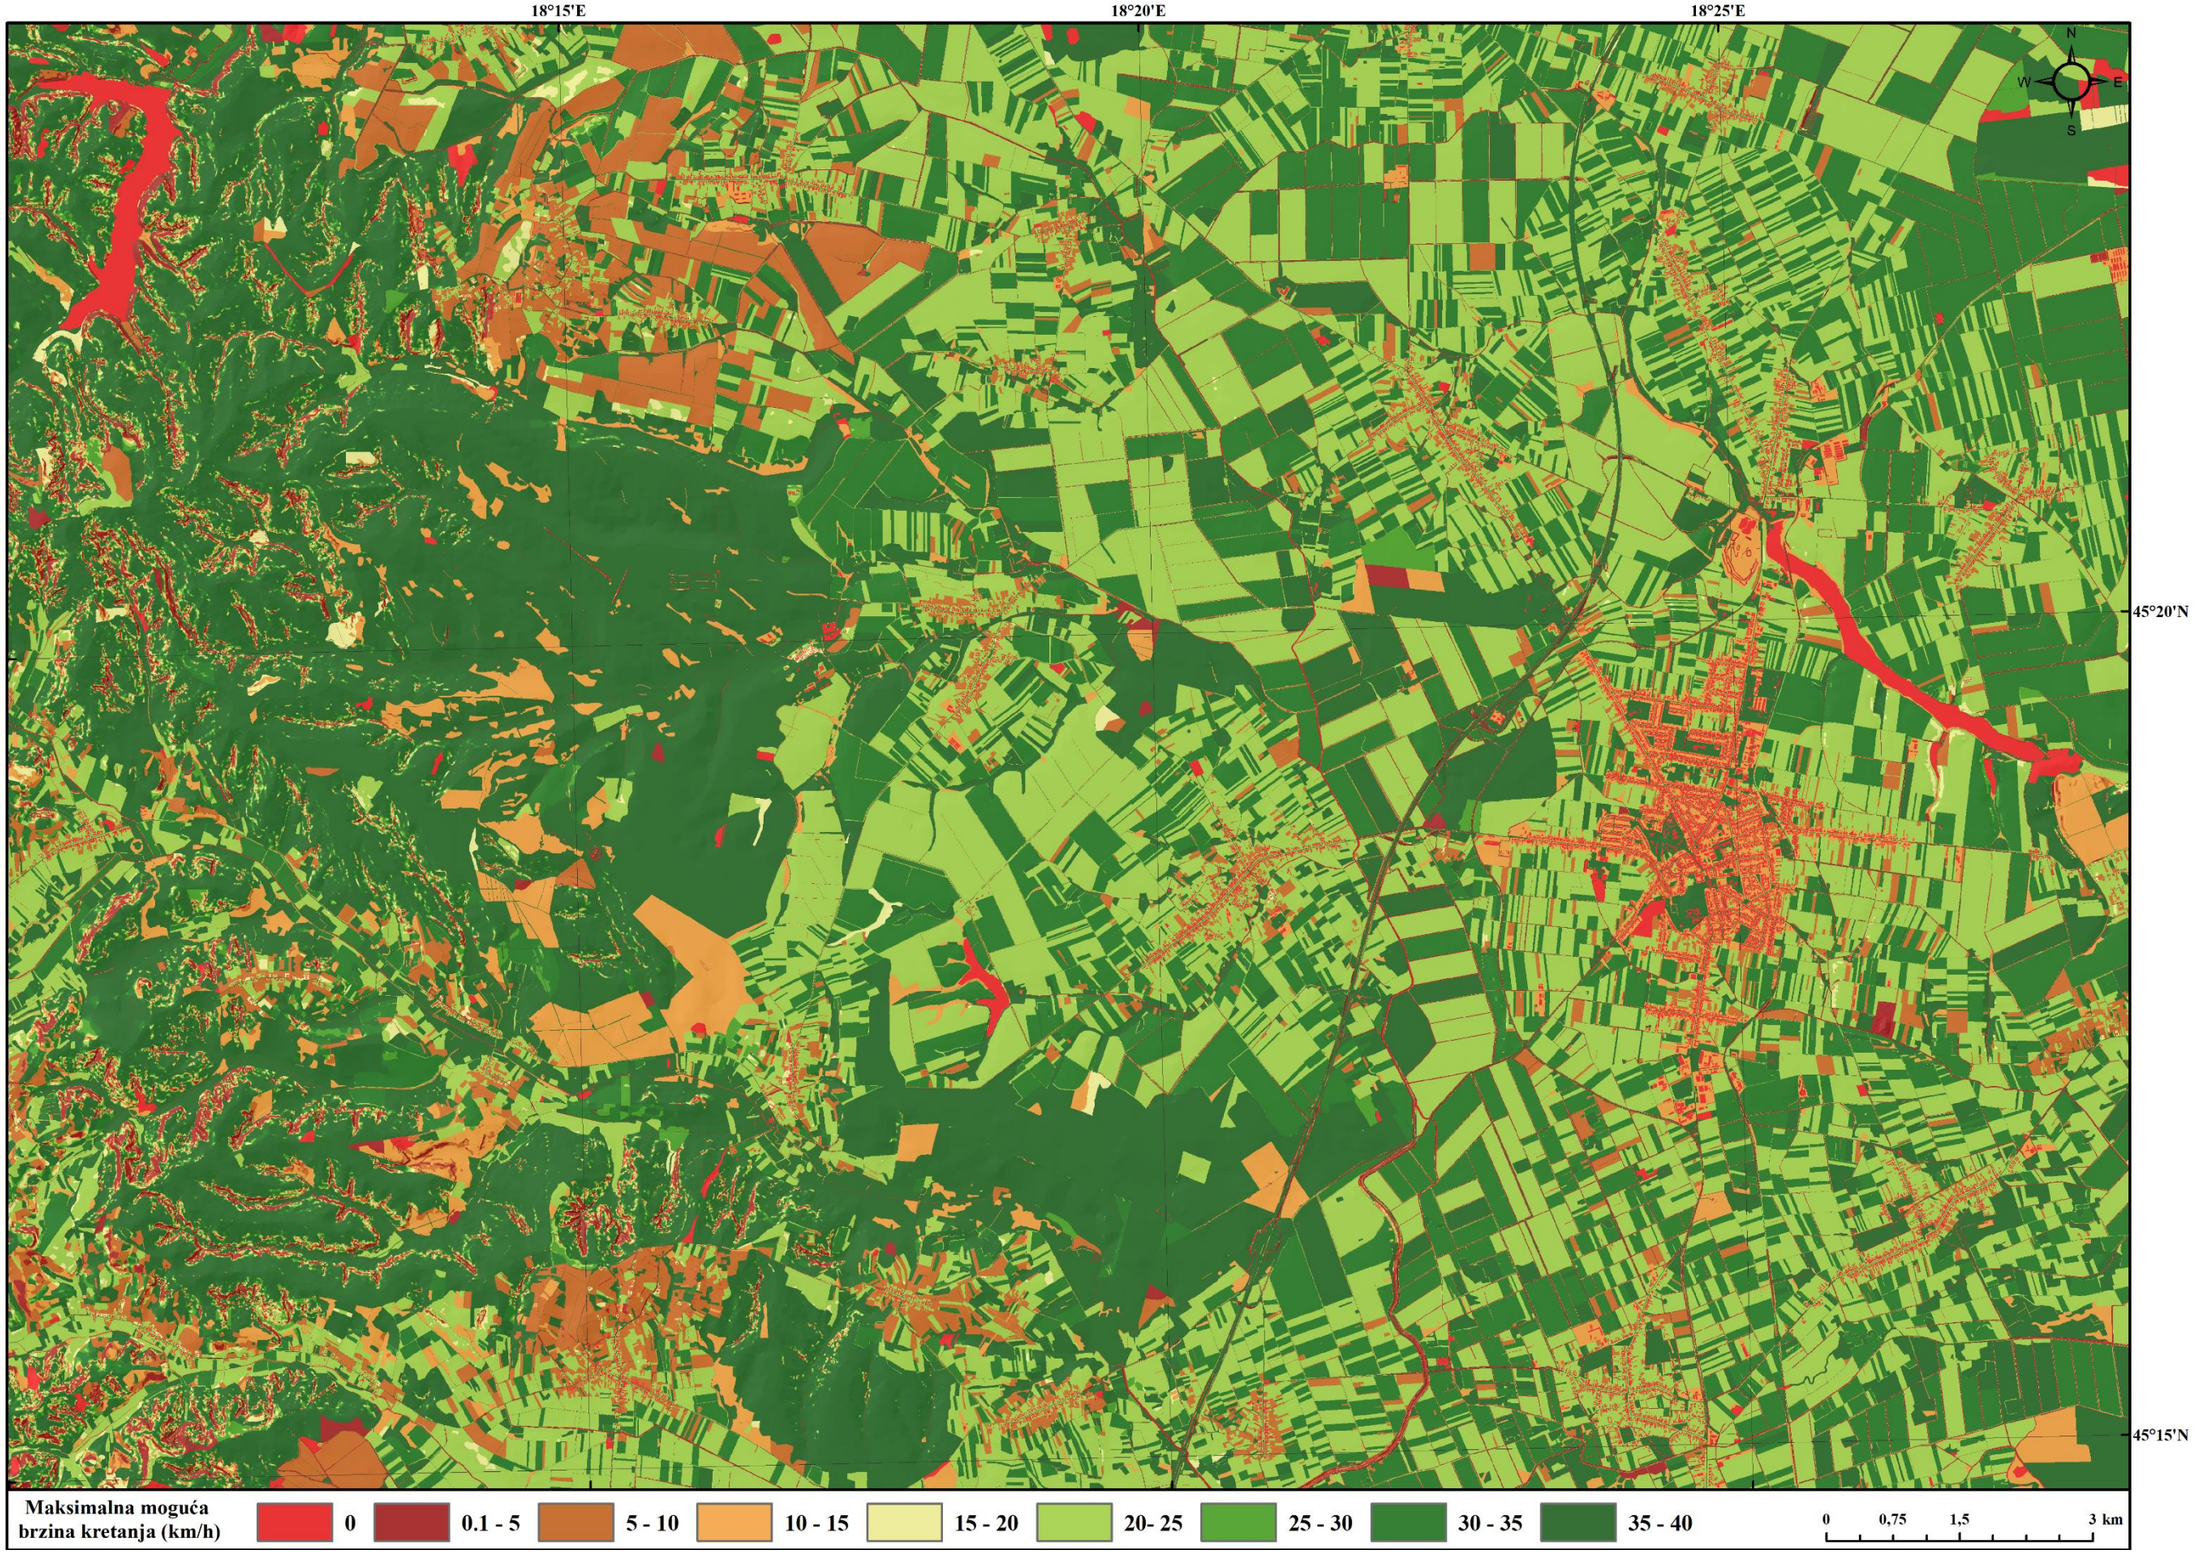

Sl. 92. Karta maksimalne brzine kretanja za Iveco Eurocargo ML 100 E21 4x4 (ljeto/jesen – suho)

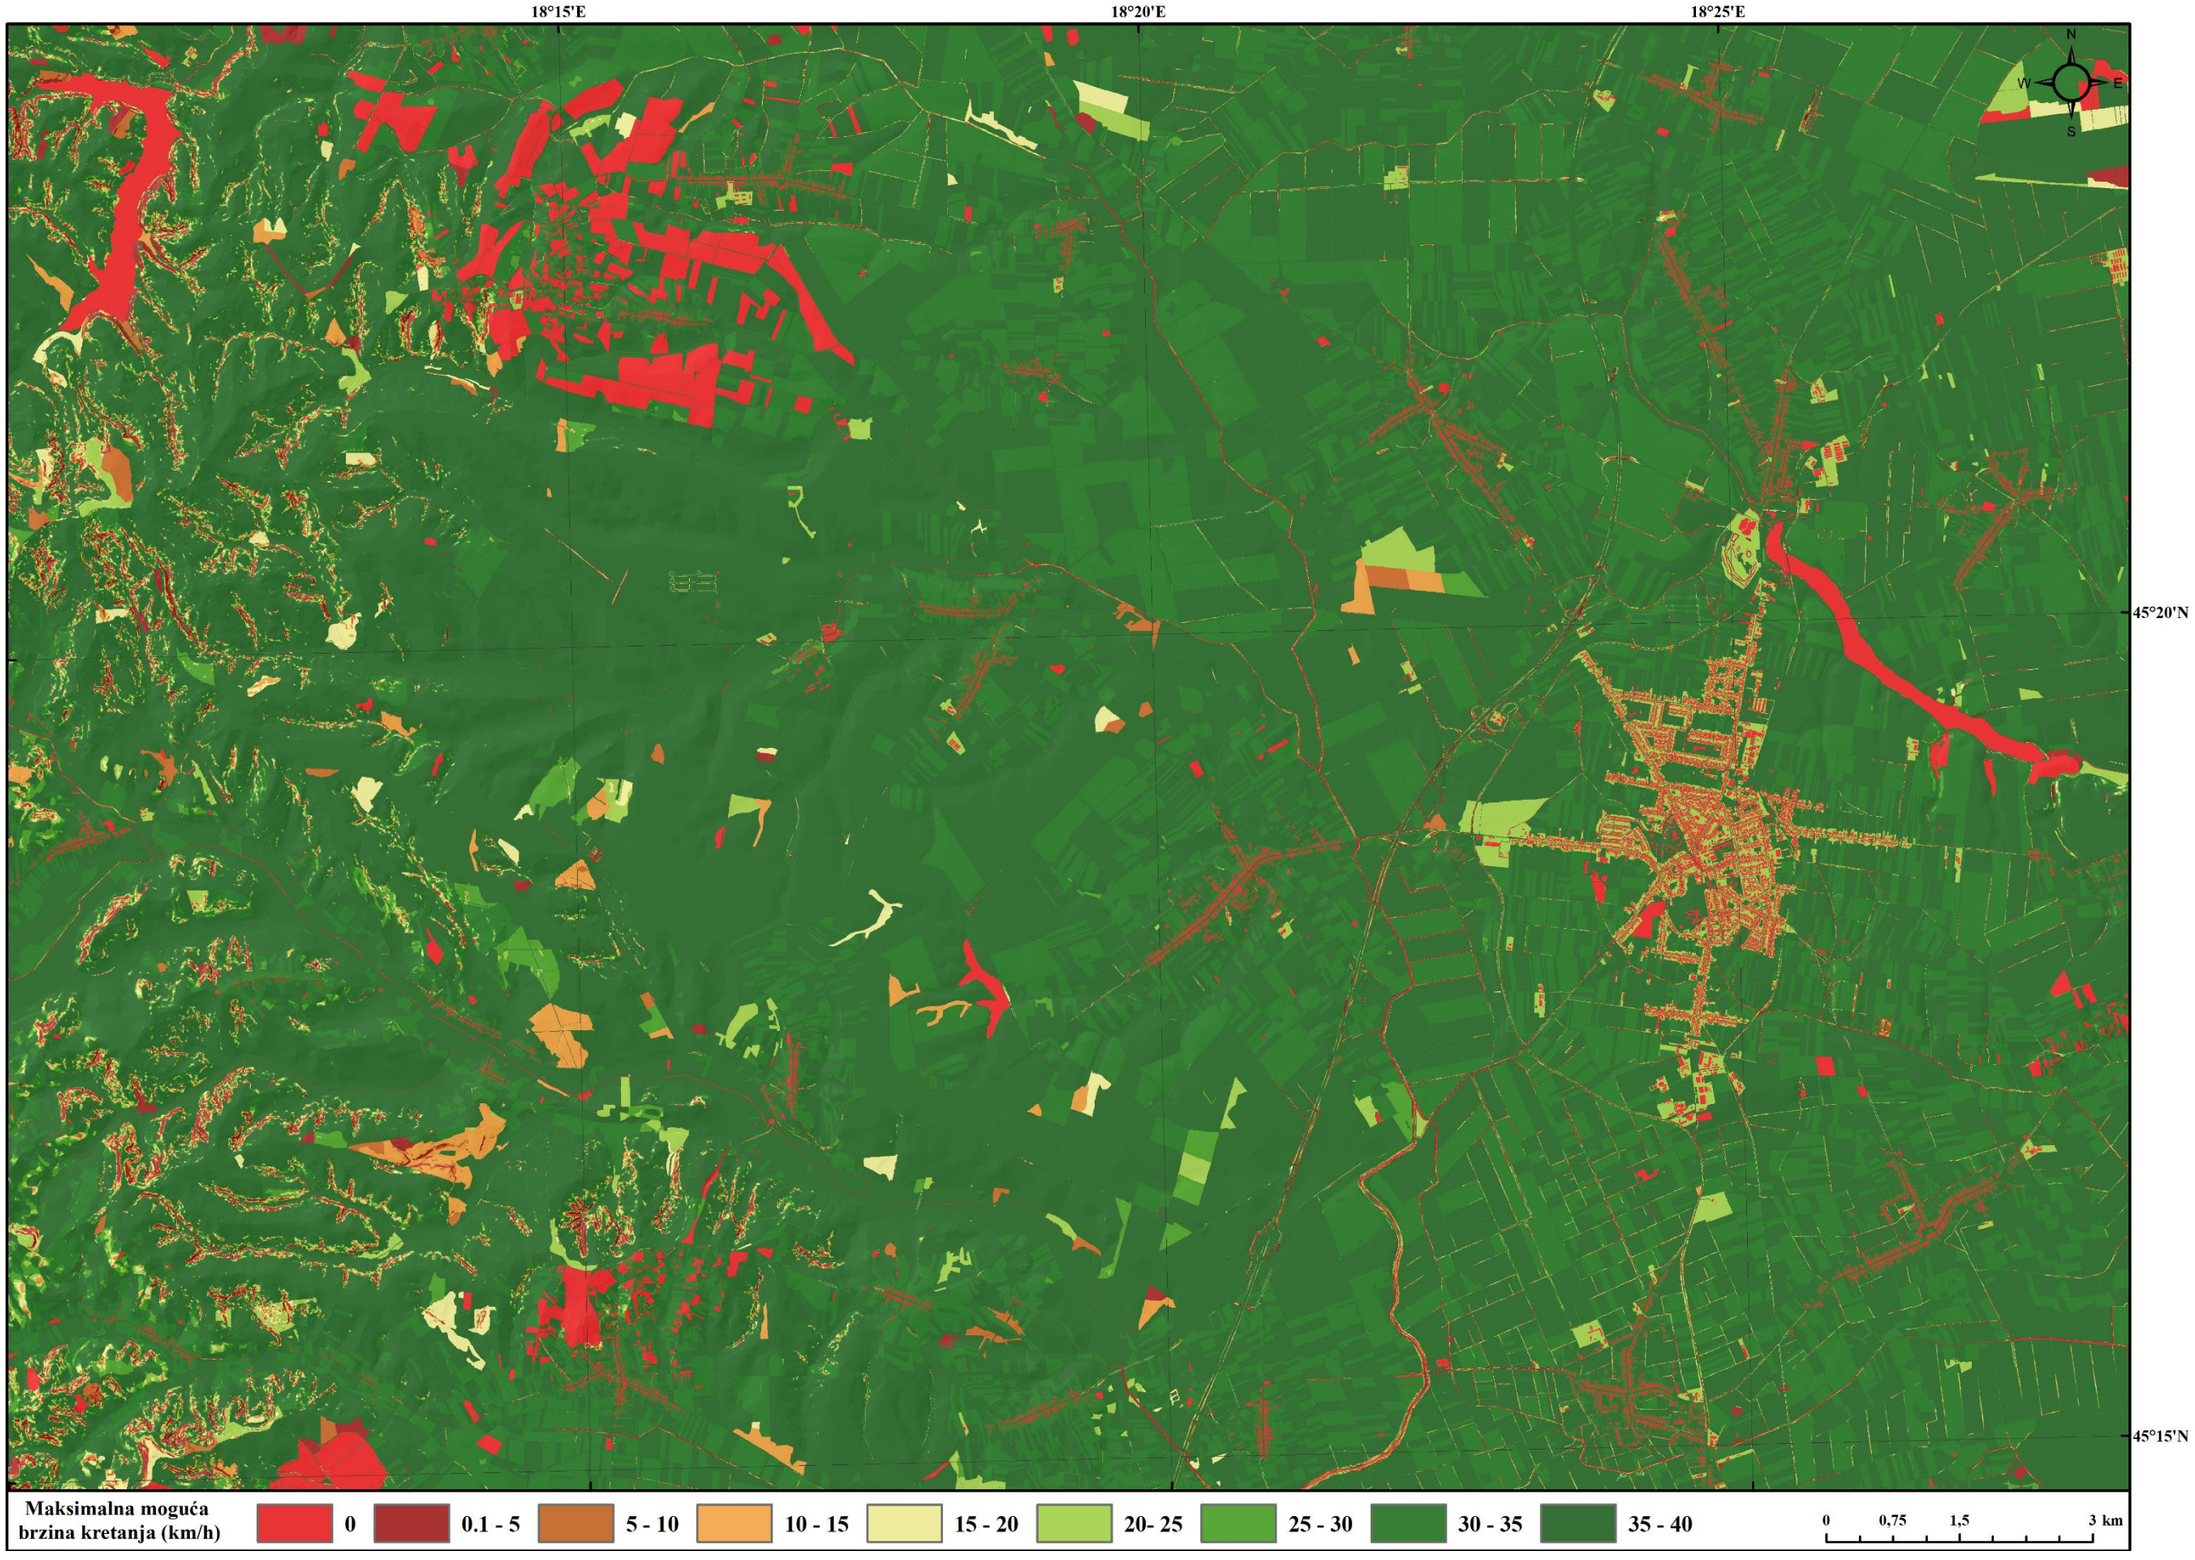

Sl. 93. Karta maksimalne brzine kretanja za BTR-50 (ljeto/jesen – suho)

Sl. 94. Karta maksimalne brzine kretanja za Tenk M-84 (ljeto/jesen – suho)

4.7.1.2. Karta terenske prohodnosti vozila (zima/proljeće – mokro)

U nastavku će za svako vozilo pomoću karata TPV biti opisani ograničavajući čimbenici TPV sukladno dominantnim fizičko-geografskim čimbenicima.

Prema scenariju zima/proljeće – mokro kod svih vozila antropogeni objekti, stalni vodotoci i vodene površine čine neprohodno zemljište, dok je utjecaj ostalih čimbenika na terensku prohodnost prema vrsti vozila sljedeći:

- Prema Sl. 95. za **Kawasaki B-Force 750 4x4i** osim prethodno navedenih čimbenika, područje neprohodnim čine:
  - živičnjaci uz kanale i kolne puteve koji se većinom nalaze na lesnoj zaravni i terasnim nizinama,
  - strmi odsjeci vodotoka,
  - kontaktna područja donjih dijelova strmih padina i dolina pobrđa na zapadu,
  - manje zaravni konkavnih oblika na lesnoj zaravni i tereasnim nizinama, te uska područja udolina u blizini stalnih vodotoka.

  Uvjetnu prohodnost područja omogućavaju oranične kulture, vinogradi na sjeveru i jugu, sporadična šumska područja pobrđa, povremeni vodotoci, kanali i nasipi lesne zaravni i terasnih nizina, te područja niske topografije.

  Neometanu prohodnost pružaju područja visoke topografije pobrđa, te livade i šume na lesnoj zaravni i terasnim nizinama.

- Prema Sl. 96. za **Land Rover Defender 110** osim prethodno navedenih čimbenika, područje neprohodnim čine:
  - kontaktna područja donjih dijelova strmih padina i dolina pobrđa na zapadu,
  - strmi odsjeci vodotoka,
  - zaravni konkavnih oblika na lesnoj zaravni i tereasnim nizinama, te područja udolina u blizini stalnih i povremenih vodotoka.

  Uvjetnu prohodnost područja omogućavaju oranične kulture, vinogradi na sjeveru i jugu, sporadična šumska područja pobrđa, povremeni vodotoci, kanali i nasipi lesne zaravni i terasnih nizina, te područja niske topografije.

Neometanu prohodnost pružaju područja visoke topografije pobrđa, te livade i šume na lesnoj zaravni i terasnim nizinama.

- Prema Sl. 97. za **BOV Patria** osim prethodno navedenih čimbenika, područje neprohodnim čine:
  - kontaktna područja donjih dijelova strmih padina i dolina pobrđa na zapadu,
  - strmi odsjeci vodotoka,
  - vinogradi na sjeveru i jugu pobrđa,
  - sporadična šumska područja pobrđa,
  - manje zaravni konkavnih oblika na lesnoj zaravni i tereasnim nizinama, te područja udolina u blizini stalnih i povremenih vodotoka.

Uvjetnu prohodnost područja omogućavaju oranične kulture, sporadična šumska područja pobrđa, povremeni vodotoci, kanali i nasipi lesne zaravni i terasnih nizina, te područja niske topografije.

Neometanu prohodnost pružaju istočna područja visoke topografije pobrđa, te livade i šume na lesnoj zaravni i terasnim nizinama.

- Prema Sl. 98. za **Iveco Eurocargo ML 100 E21 4x4** osim prethodno navedenih čimbenika, područje neprohodnim čine:
  - kontaktna područja donjih i srednjih dijelova strmih padina i dolina pobrđa,
  - strmi odsjeci vodotoka,
  - sporadična šumska područja pobrđa,
  - šira područja zaravni konkavnih oblika na lesnoj zaravni i terasnim nizinama, te šira područja udolina u blizini stalnih i povremenih vodotoka.

Uvjetnu prohodnost područja omogućavaju oranične kulture, vinogradi na sjeveru i jugu, sporadična šumska područja pobrđa, povremeni vodotoci, kanali i nasipi lesne zaravni i terasnih nizina, te područja niske topografije.

Neometanu prohodnost pruža kontaktni prostor visoke topografija istočnog pobrđa i lesne zaravni pod šumom.

- Prema Sl. 99. za **BTR-50** osim prethodno navedenih čimbenika, područje neprohodnim čine:

- kontaktna područja donjih i dijelova strmih padina i dolina pobrđa na zapadu i središnjem dijelu,
- strmi odsjeci vodotoka,
- vinogradi na sjeveru i jugu pobrđa,
- sporadična šumska područja pobrđa i lesnih gajeva,
- područja udolina u blizini stalnih vodotoka.

Uvjetnu prohodnost područja omogućavaju sporadična šumska područja i povremeni vodotoci, kanali i nasipi lesne zaravni i terasnih nizina, te područja niske topografije.

Neometanu prohodnost pružaju područja visoke topografije pokrivene oranicama, livadama i šumom.

- Prema Sl. 100. za **Tenk M-84** osim prethodno navedenih čimbenika, područje neprohodnim čine:
  - kontaktna područja donjih i srednjih dijelova strmih padina i dolina pobrđa na zapadu i središnjem dijelu,
  - strmi odsjeci vodotoka,
  - vinogradi na sjeveru i jugu pobrđa,
  - sporadična šumska područja pobrđa i lesnih gajeva,
  - područja udolina u blizini stalnih vodotoka.

Uvjetnu prohodnost područja omogućavaju sporadična šumska područja i povremeni vodotoci, kanali i nasipi lesne zaravni i terasnih nizina, te područja niske topografije.

Neometanu prohodnost pružaju područja visoke topografije pokrivene oranicama, livadama i šumom.

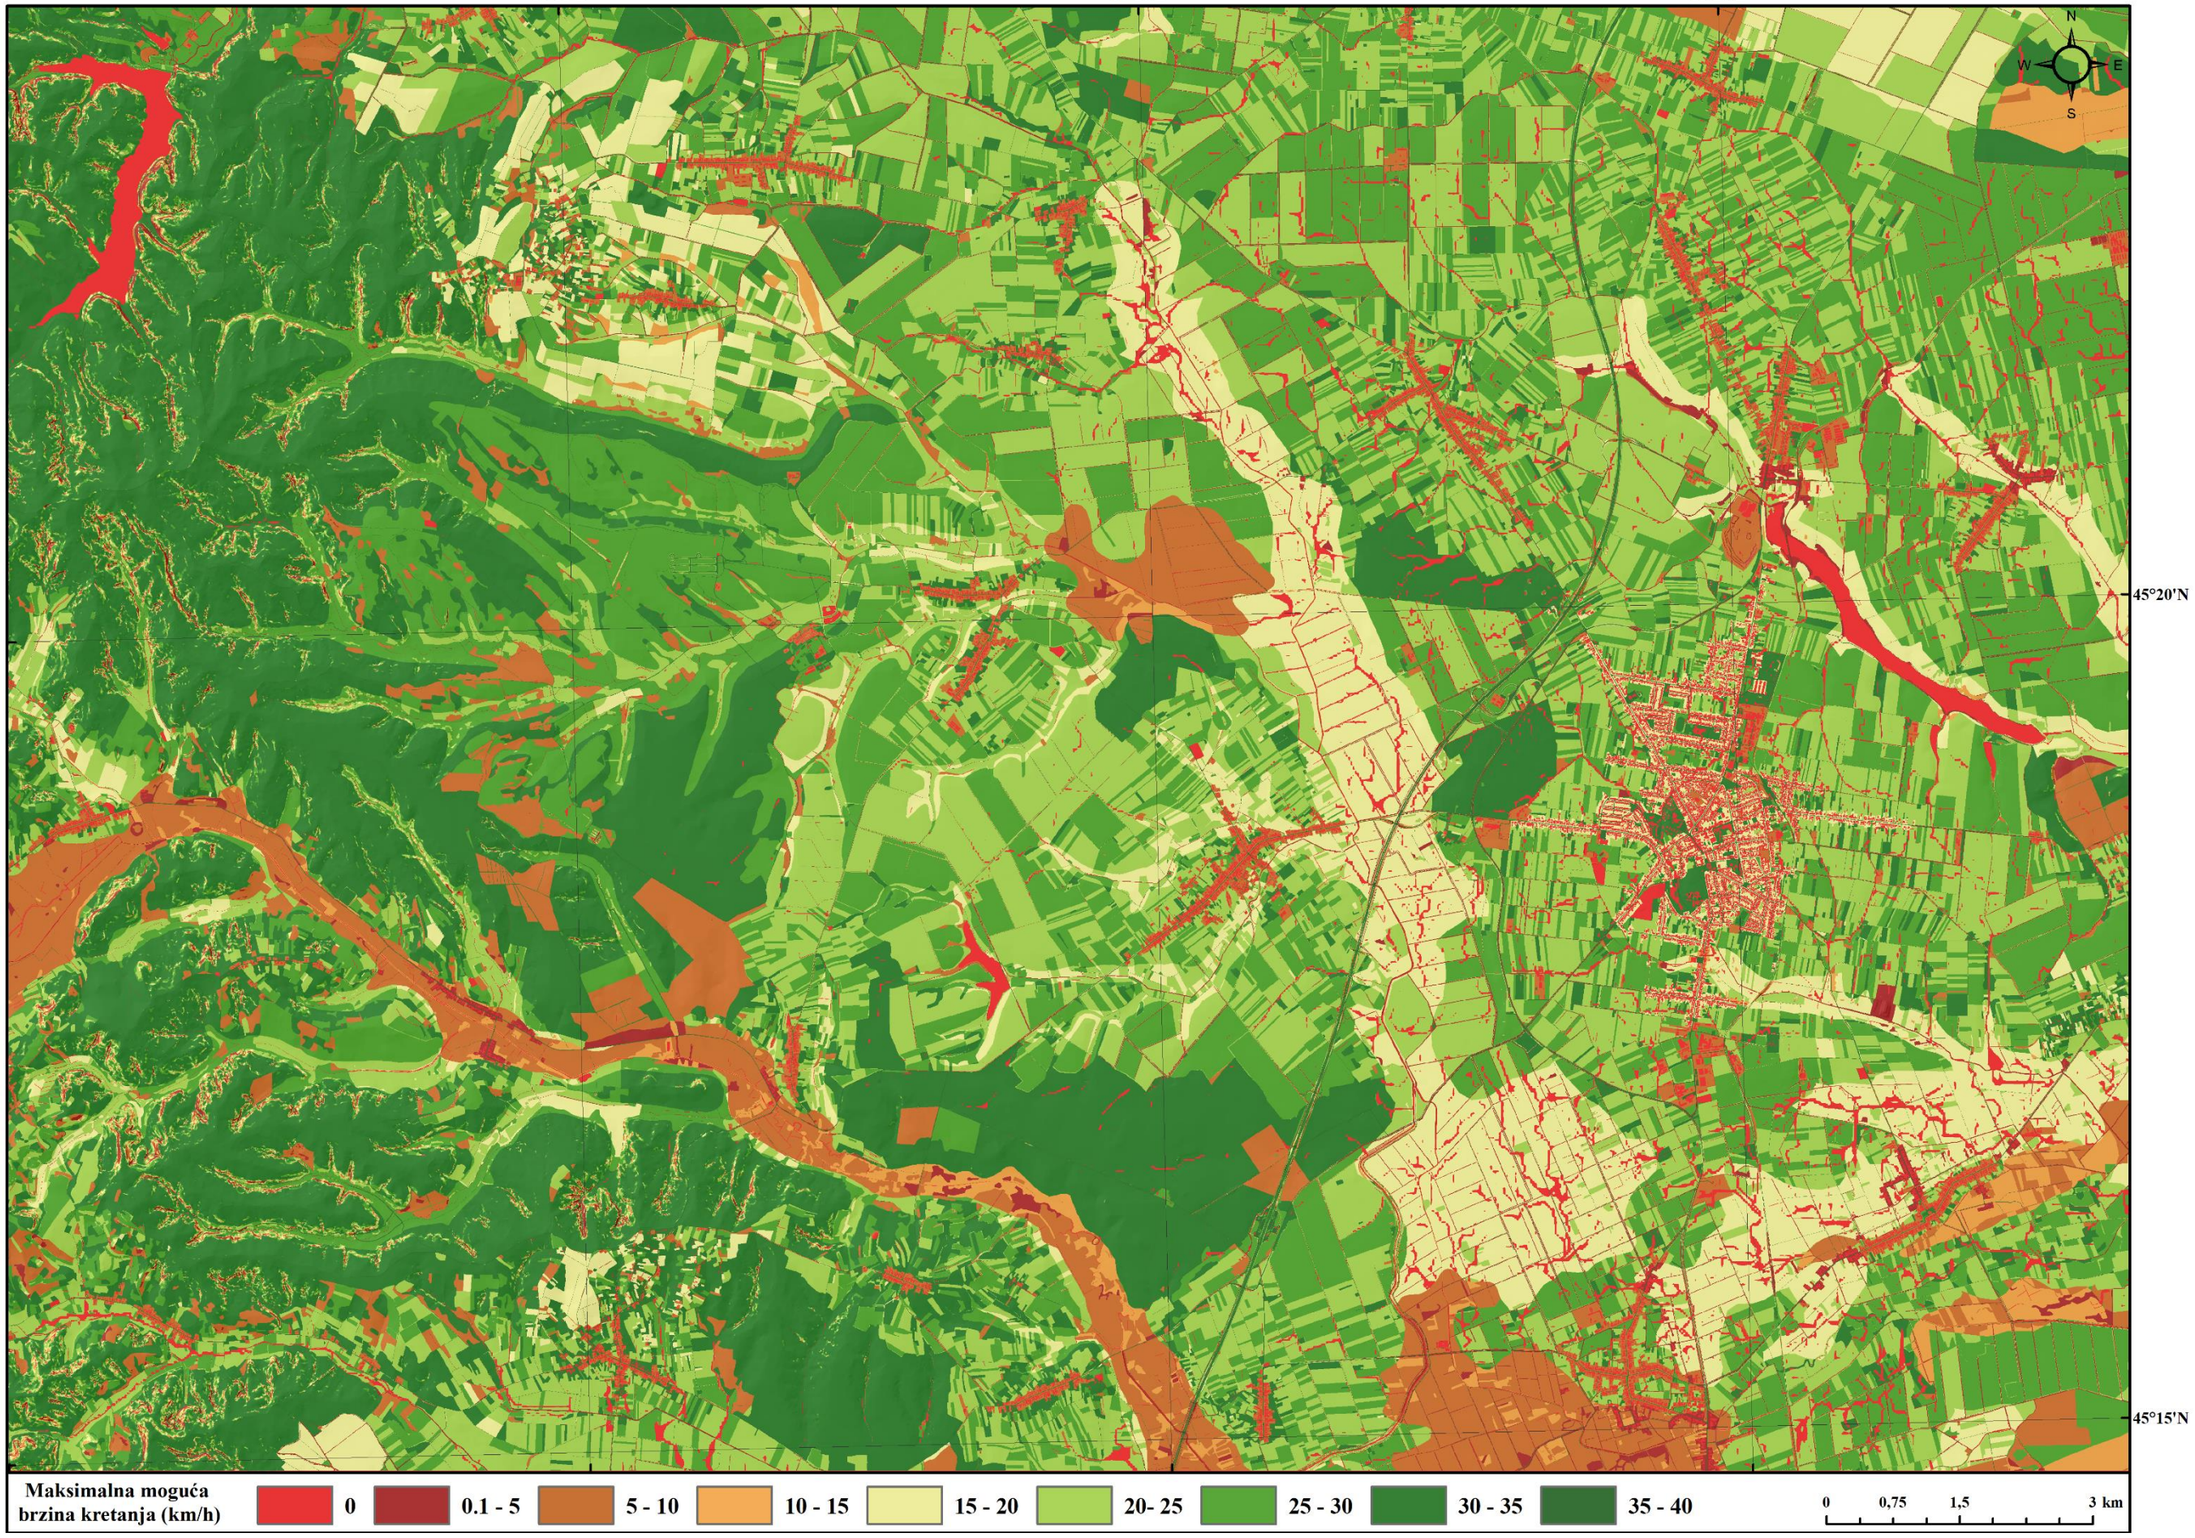

Sl. 95. Karta maksimalne brzine kretanja za Kawasaki B-Force 750 4x4i (zima/proljeće - mokro)

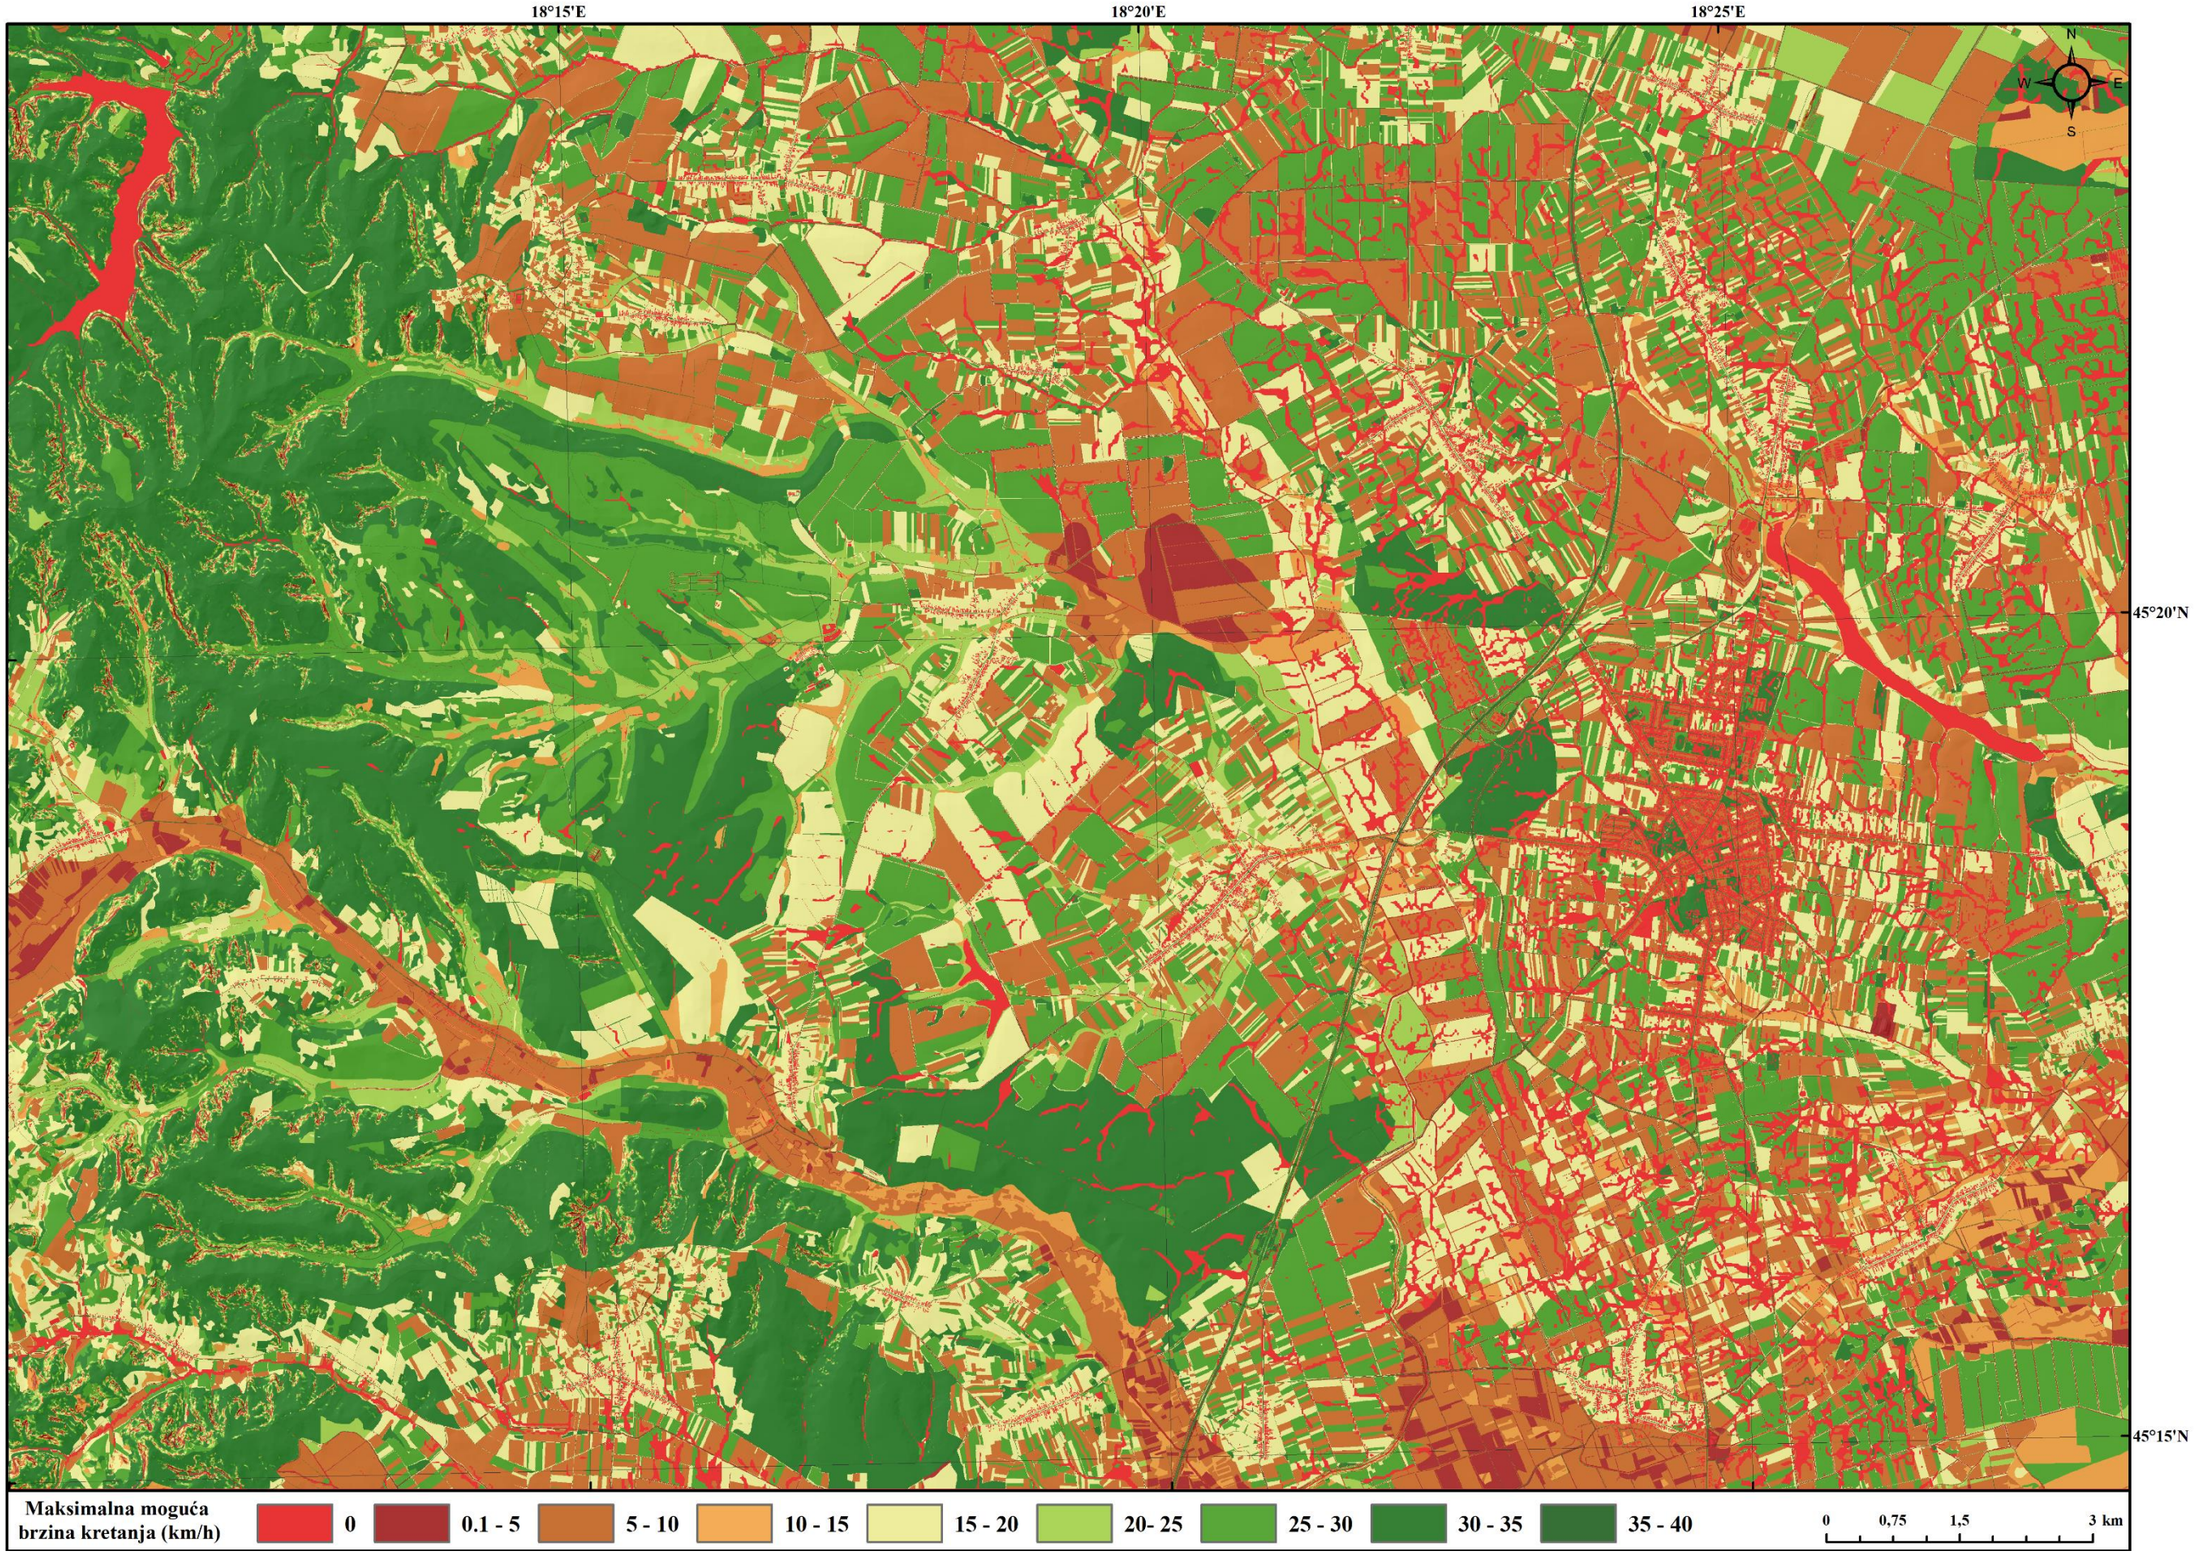

Sl. 96. Karta maksimalne brzine kretanja za Land Rover Defender 110 (zima/proljeće - mokro)

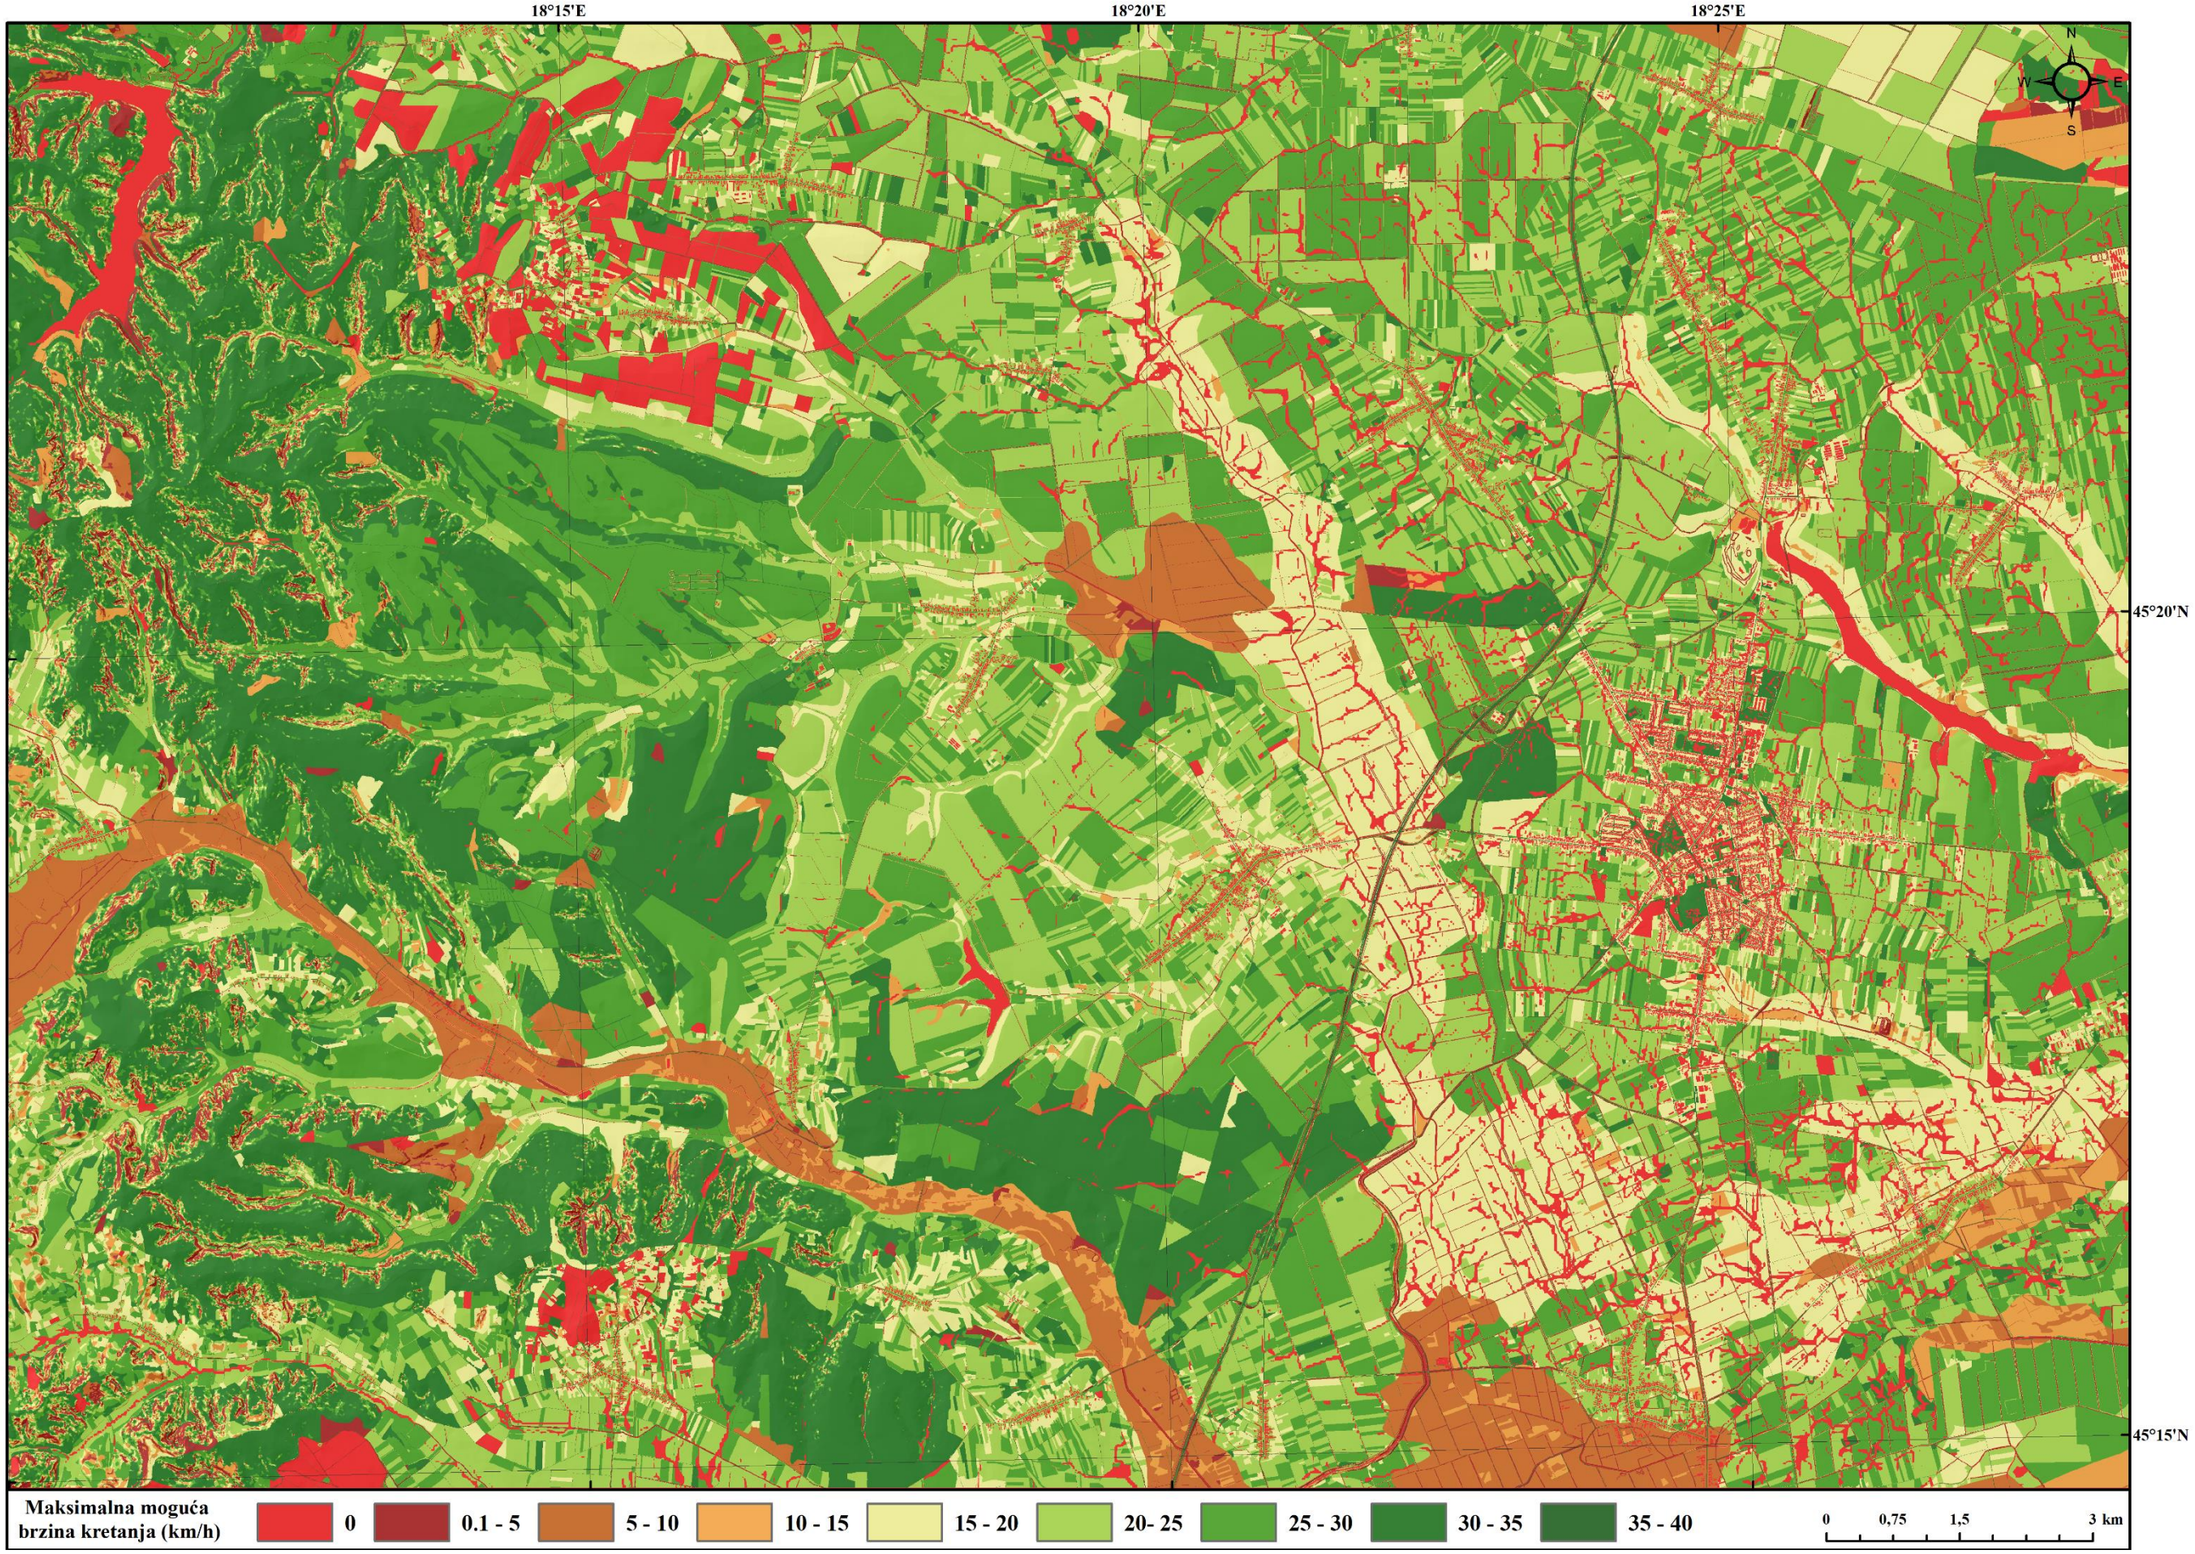

Sl. 97. Karta maksimalne brzine kretanja za BOV Patria (zima/proljeće - mokro)

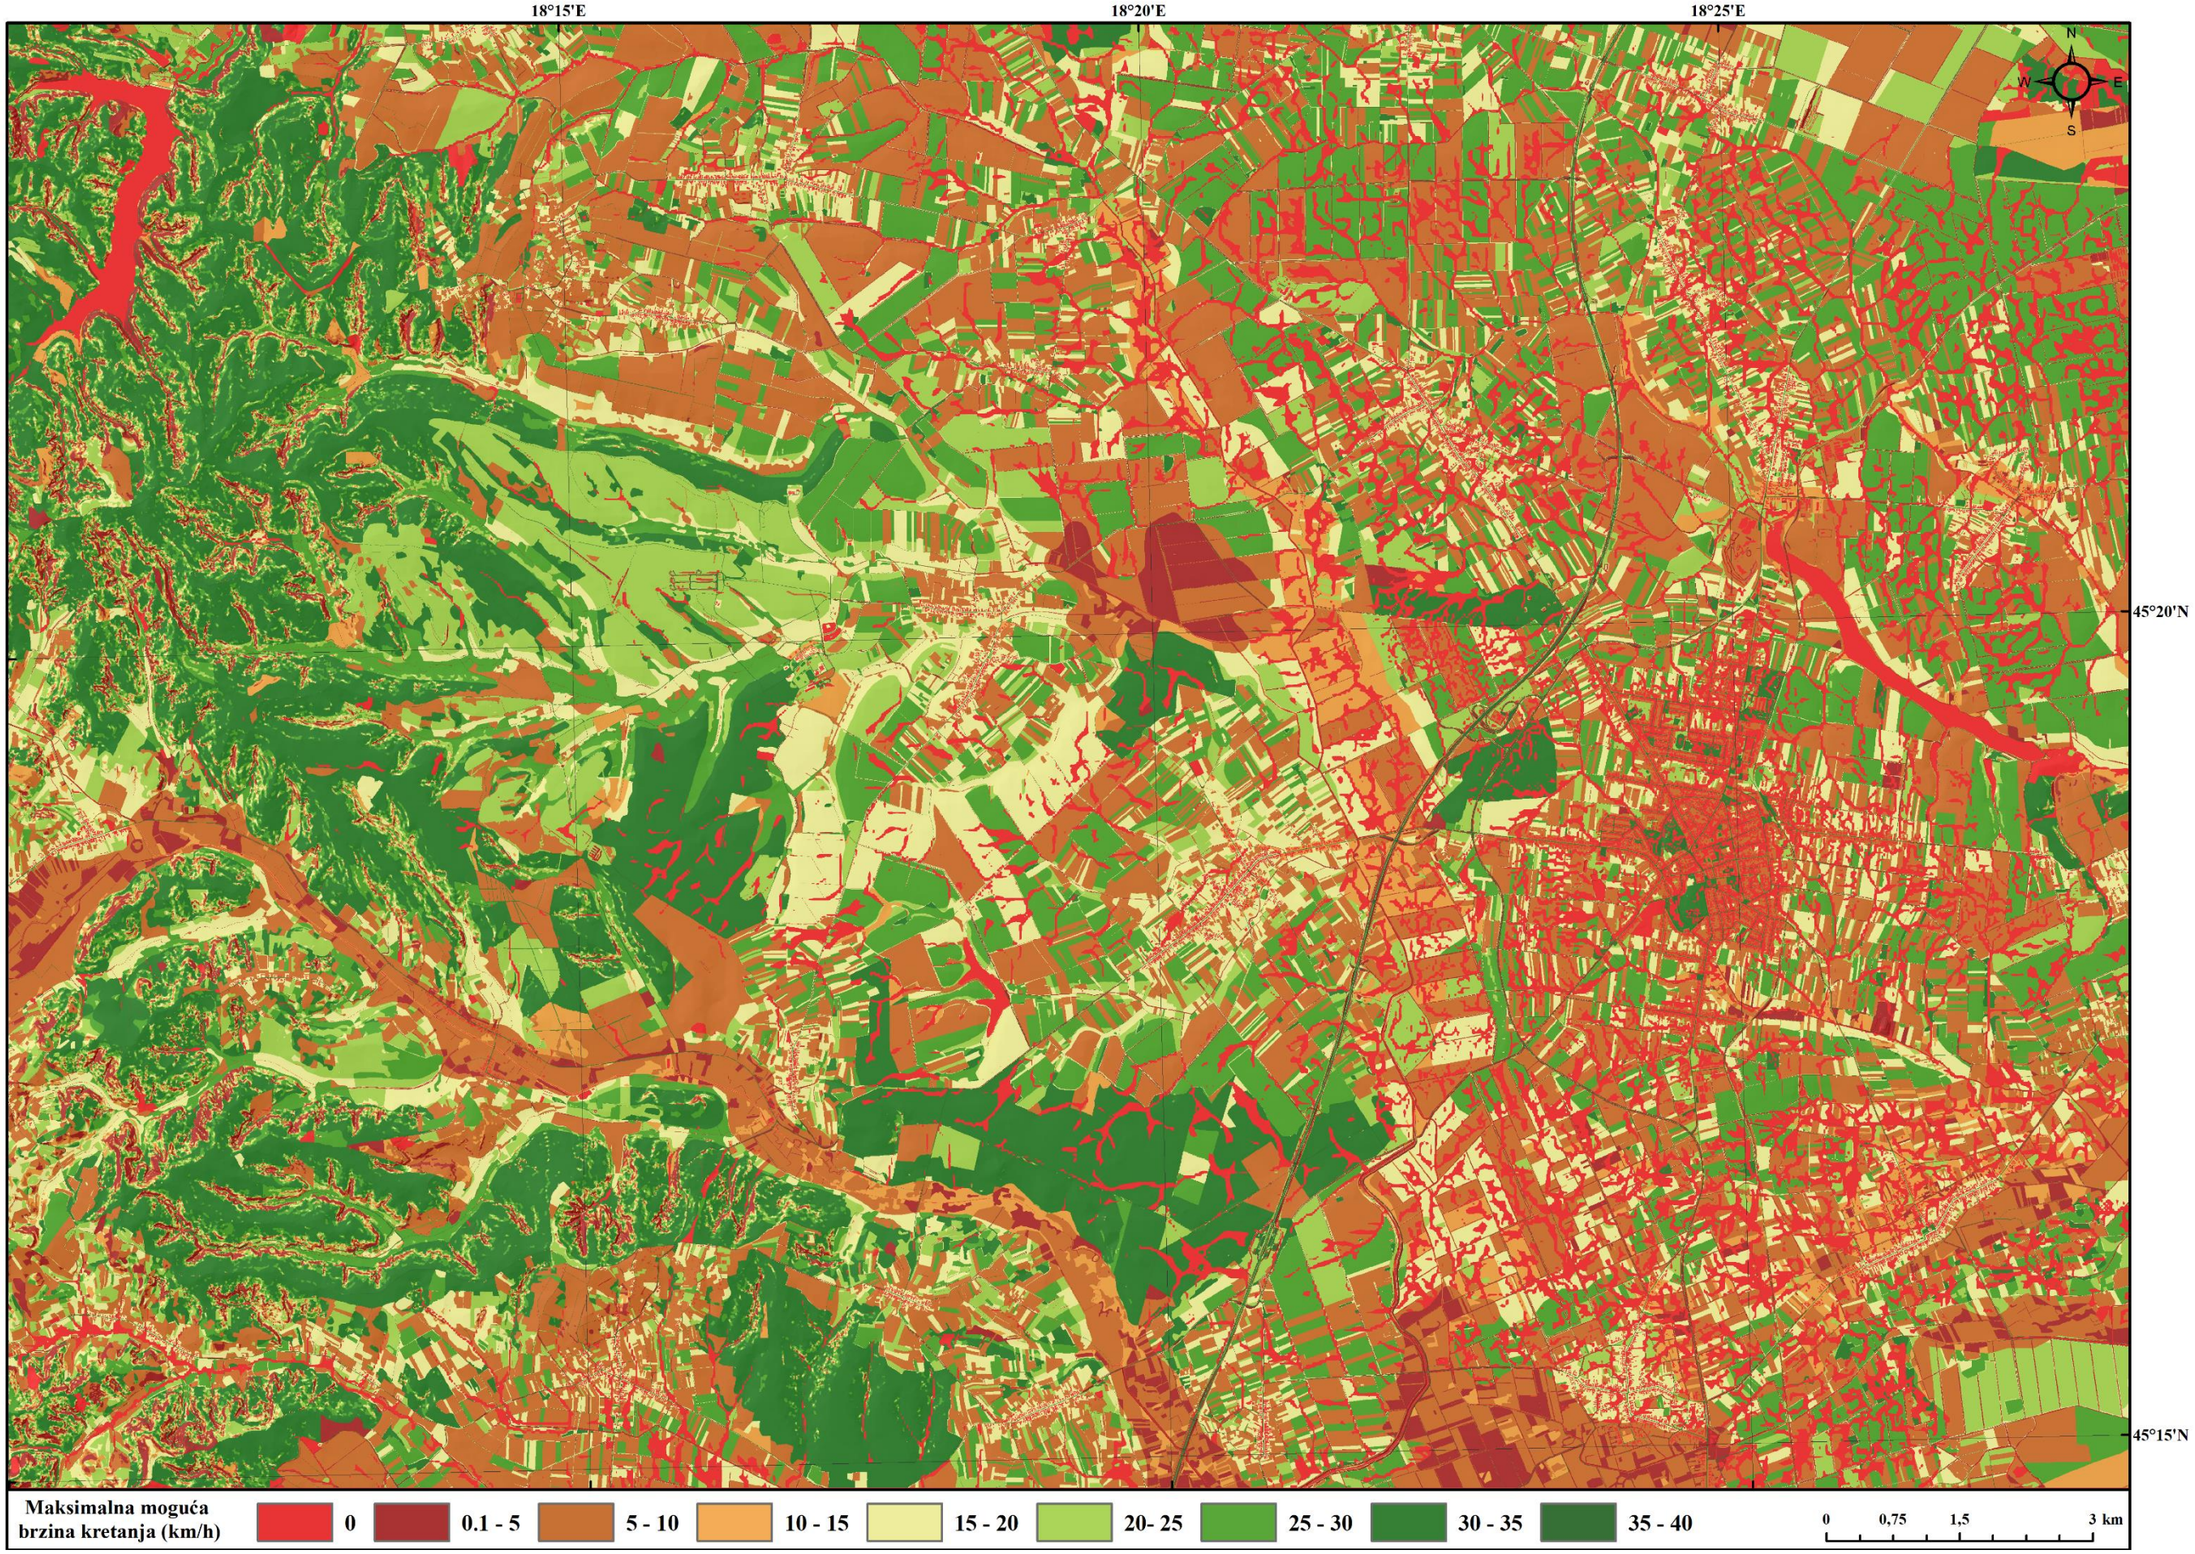

Sl. 98. Karta maksimalne brzine kretanja za Iveco Eurocargo ML 100 E21 4x4 (zima/proljeće - mokro)

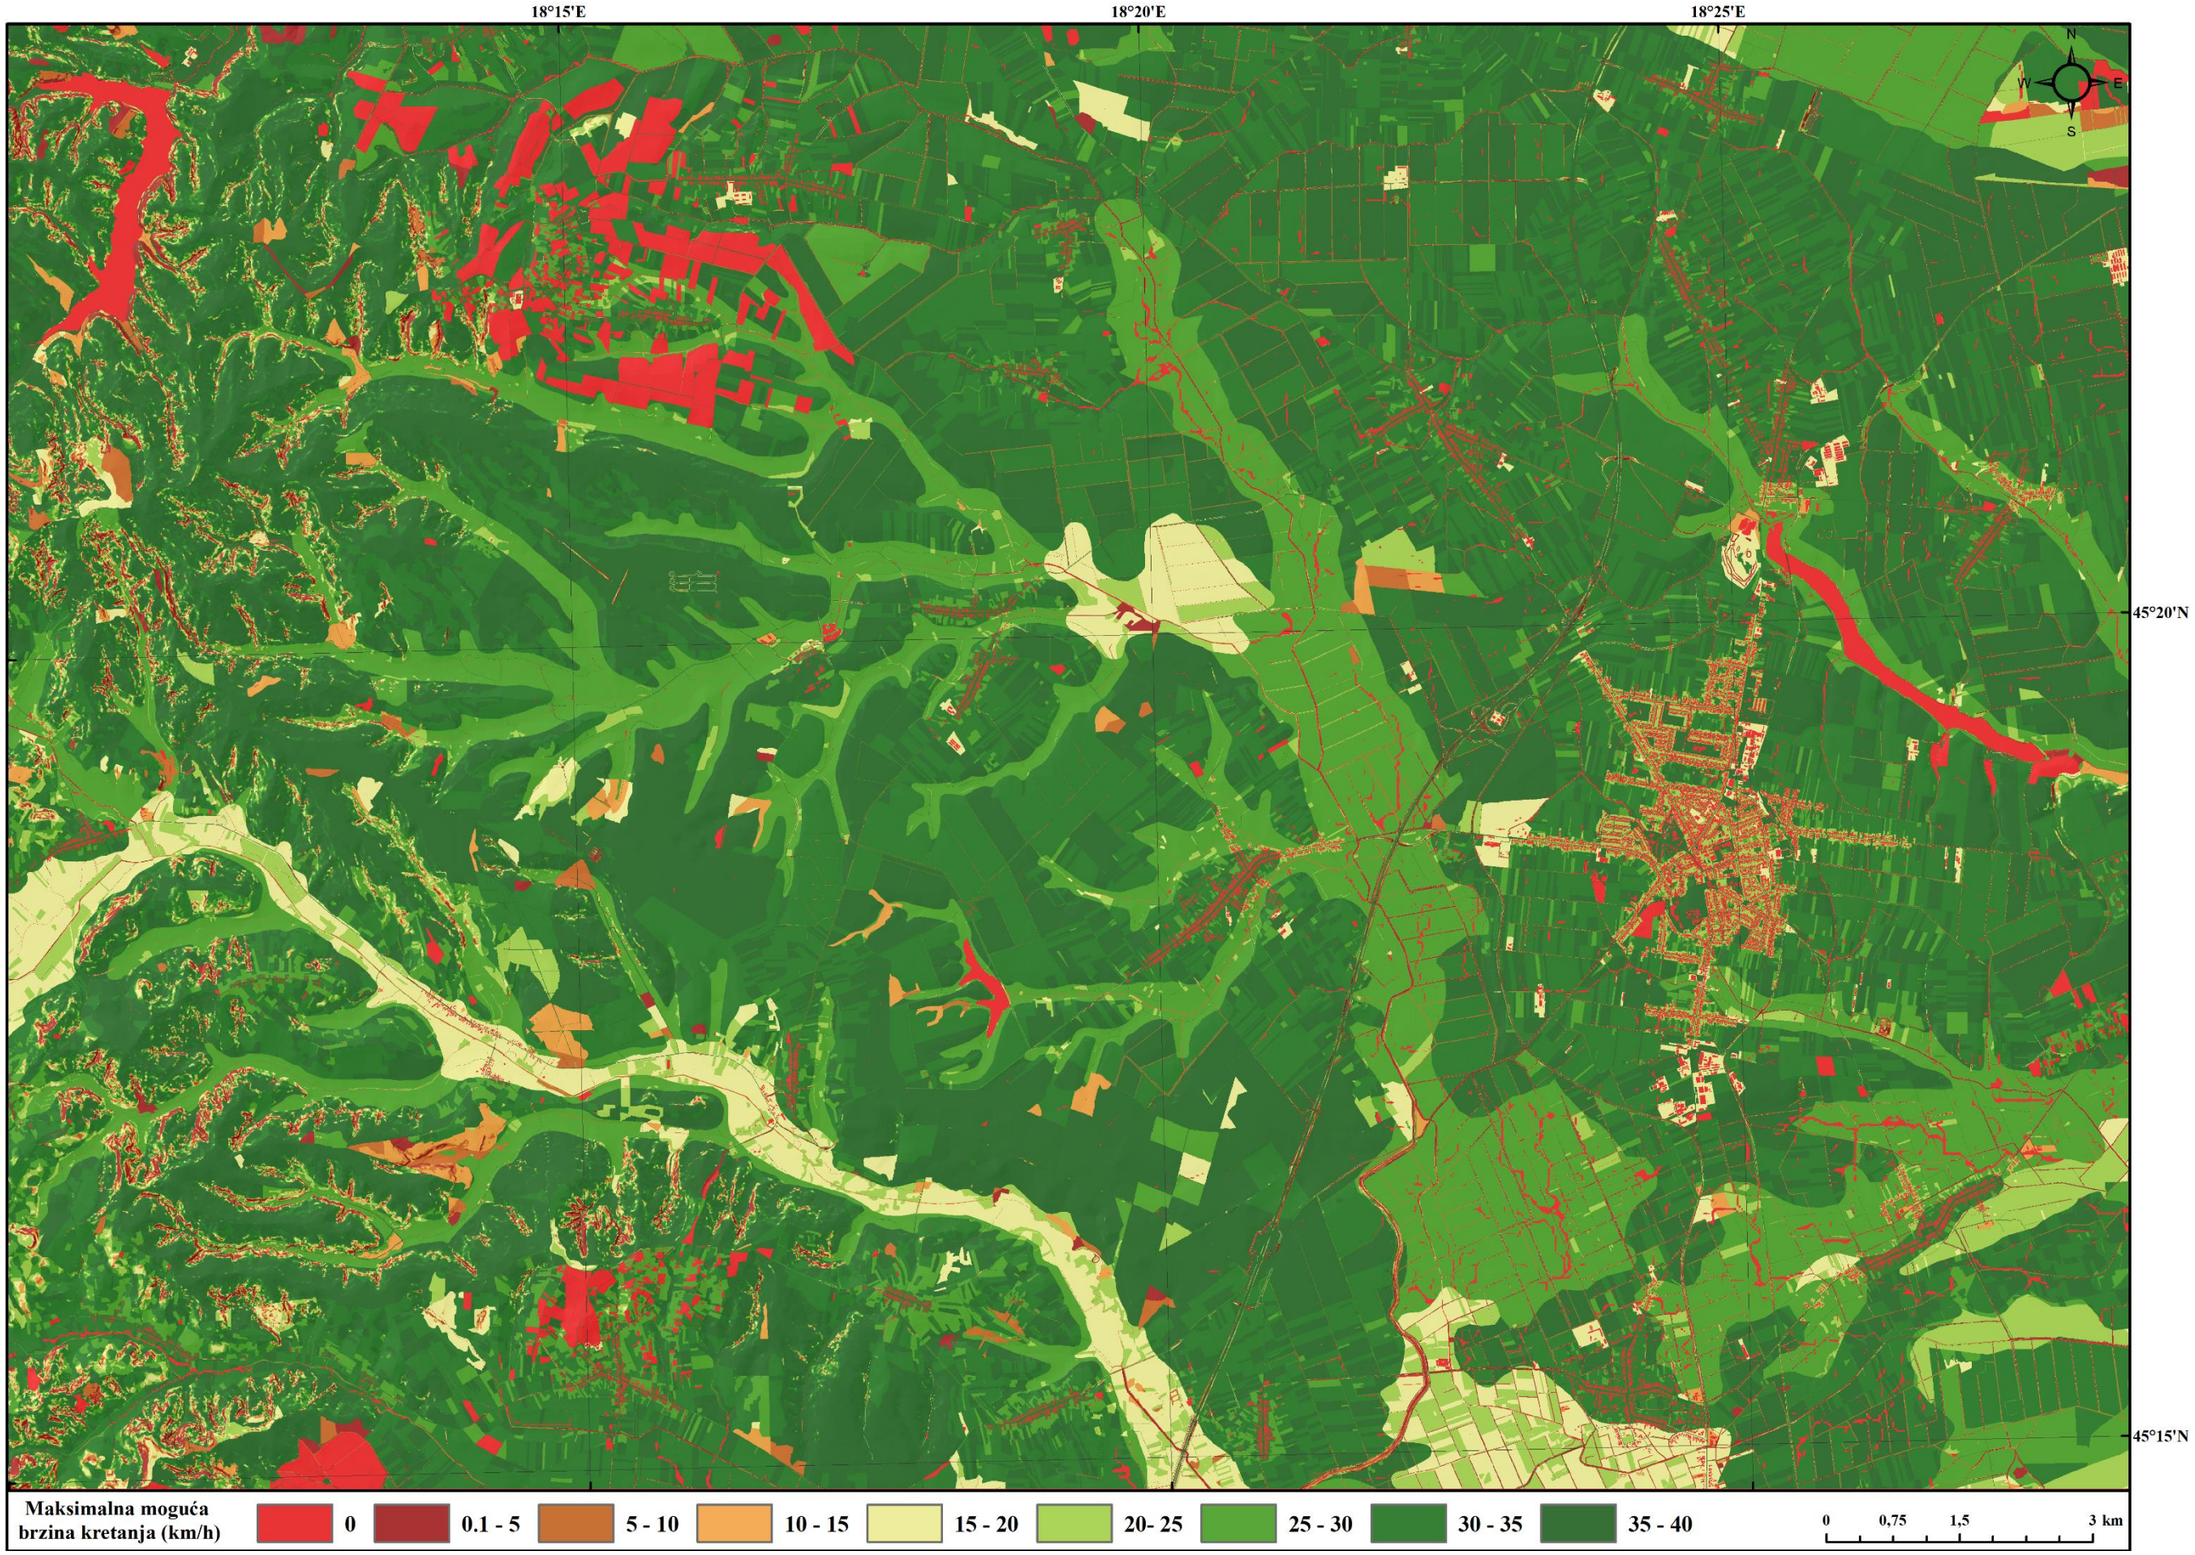

Sl. 99. Karta maksimalne brzine kretanja za BTR-50 (zima/proljeće - mokro)

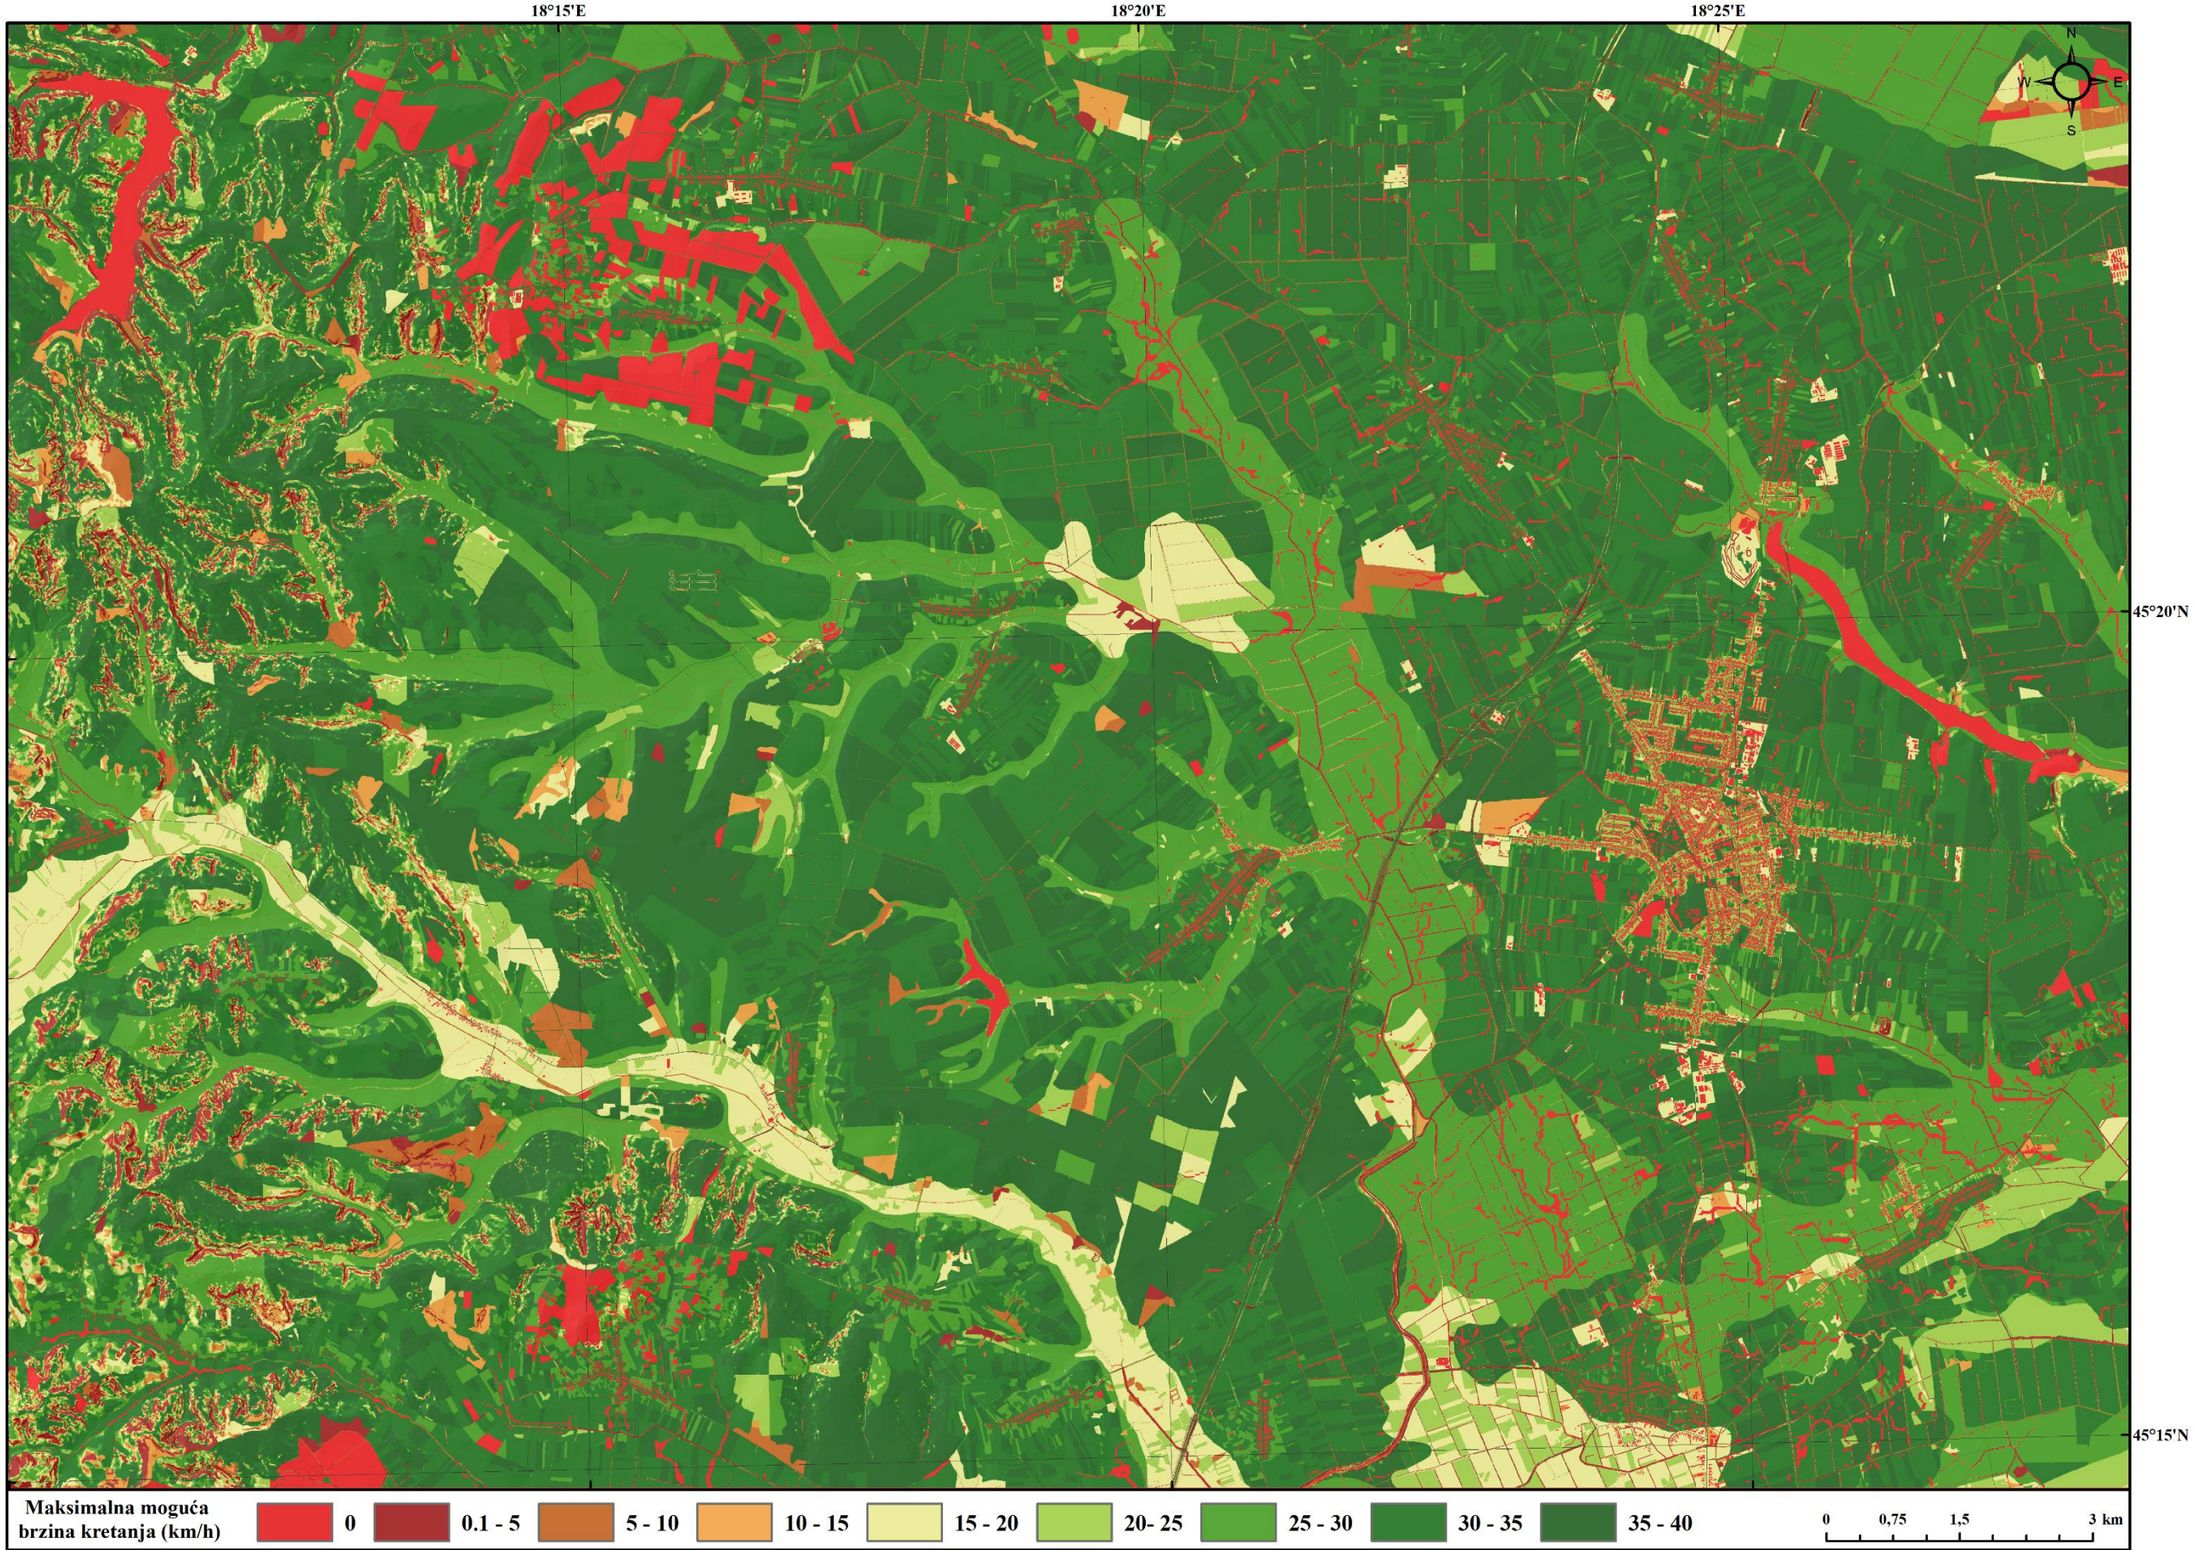

Sl. 100. Karta maksimalne brzine kretanja za Tenk M-84 (zima/proljeće – mokro)

4.7.2. Optimalna ruta kretanja

Na temelju spoznaje o maksimalnoj mogućoj brzini kretanja vozila na terenu načinjena je karta dostupnosti područja s optimalnim rutama kretanja (Sl. 101.). Temeljem modela moguće je načiniti kartu dostupnosti s optimalnim rutama kretanja za sve tipove vozila. Optimalna ruta kretanja načinjena je ArcGIS alatima *Cost Distance* i *Cost Path*. U svrhu vizualizacije i interpretativne svrhe odabrano je vozilo Land Rover Defender 110 na osnovu scenarija koji je postavljen u zimu/proljeće s mokrim uvjetima vlažnosti tla.

Za izračun optimalne rute kretanja postavljen je idealizirani scenarij gdje ishodišna pozicija – „start“ postavljen u geometrijsko središte područja istraživanja. Provedena je kalkulacija prema četiri lokacije – „cilja“ koji su smješteni u krajnje kutove područja istraživanja. Lokacije cilja su postavljene na jednakoj zračnoj udaljenosti od startne pozicije, radi lakše komparacije rezultata. Vozilom se može doći do lokacije „B“ (31 min), iako je do iste i najduži put (20.39 km). Gotovo identični parametri brzine i udaljenosti potrebni su i do lokacije „C“ (31.1 min i 20.31. km). Do lokacija „A“ i „D“ je bio najkraći put (20.06 km i 20.07 km), ali su vremena dolaska bila dulja (33.5 min i 33.6 min). Za sve četiri rute je znakovito da se odabrane putanje kretanja u svim scenarijima preko 90 % vremena odvijaju na prometnicama.

Kartom vremenskih udaljenosti ili dostupnosti zorno se opisuje koliko je vozilu potrebno vremena sa ishodišne pozicije do bilo koje lokacije obuhvaćene prostorom istraživanja. Potrebno je istaknuti da je dostupnost svih područja determinirana mrežom prometnica. Iako je do krajnjih točaka prostora istraživanja vozilu bilo potrebno nešto više od 30 minuta, do nekih prohodnih prostora bilo bi potrebno 150 minuta vožnje. Uz neprohodna područja definirana modelom, na karti je vidljivo i nekoliko „džepova“ neprohodnosti. Ovi „džepovi“ uvjetovani su svojom izoliranošću, odnosno okruženošću neprohodnim područjima. Stoga bez obzira što karta brzina prikazuje mogućnost pokreta, ipak su neka područja u „stvarnosti“ – nedostupna, a samim time i neprohodna. Takav primjer se može vidjeti na Sl. 101. – označen crvenom bojom, ako pogledamo 2.5 km istočno od startne pozicije.

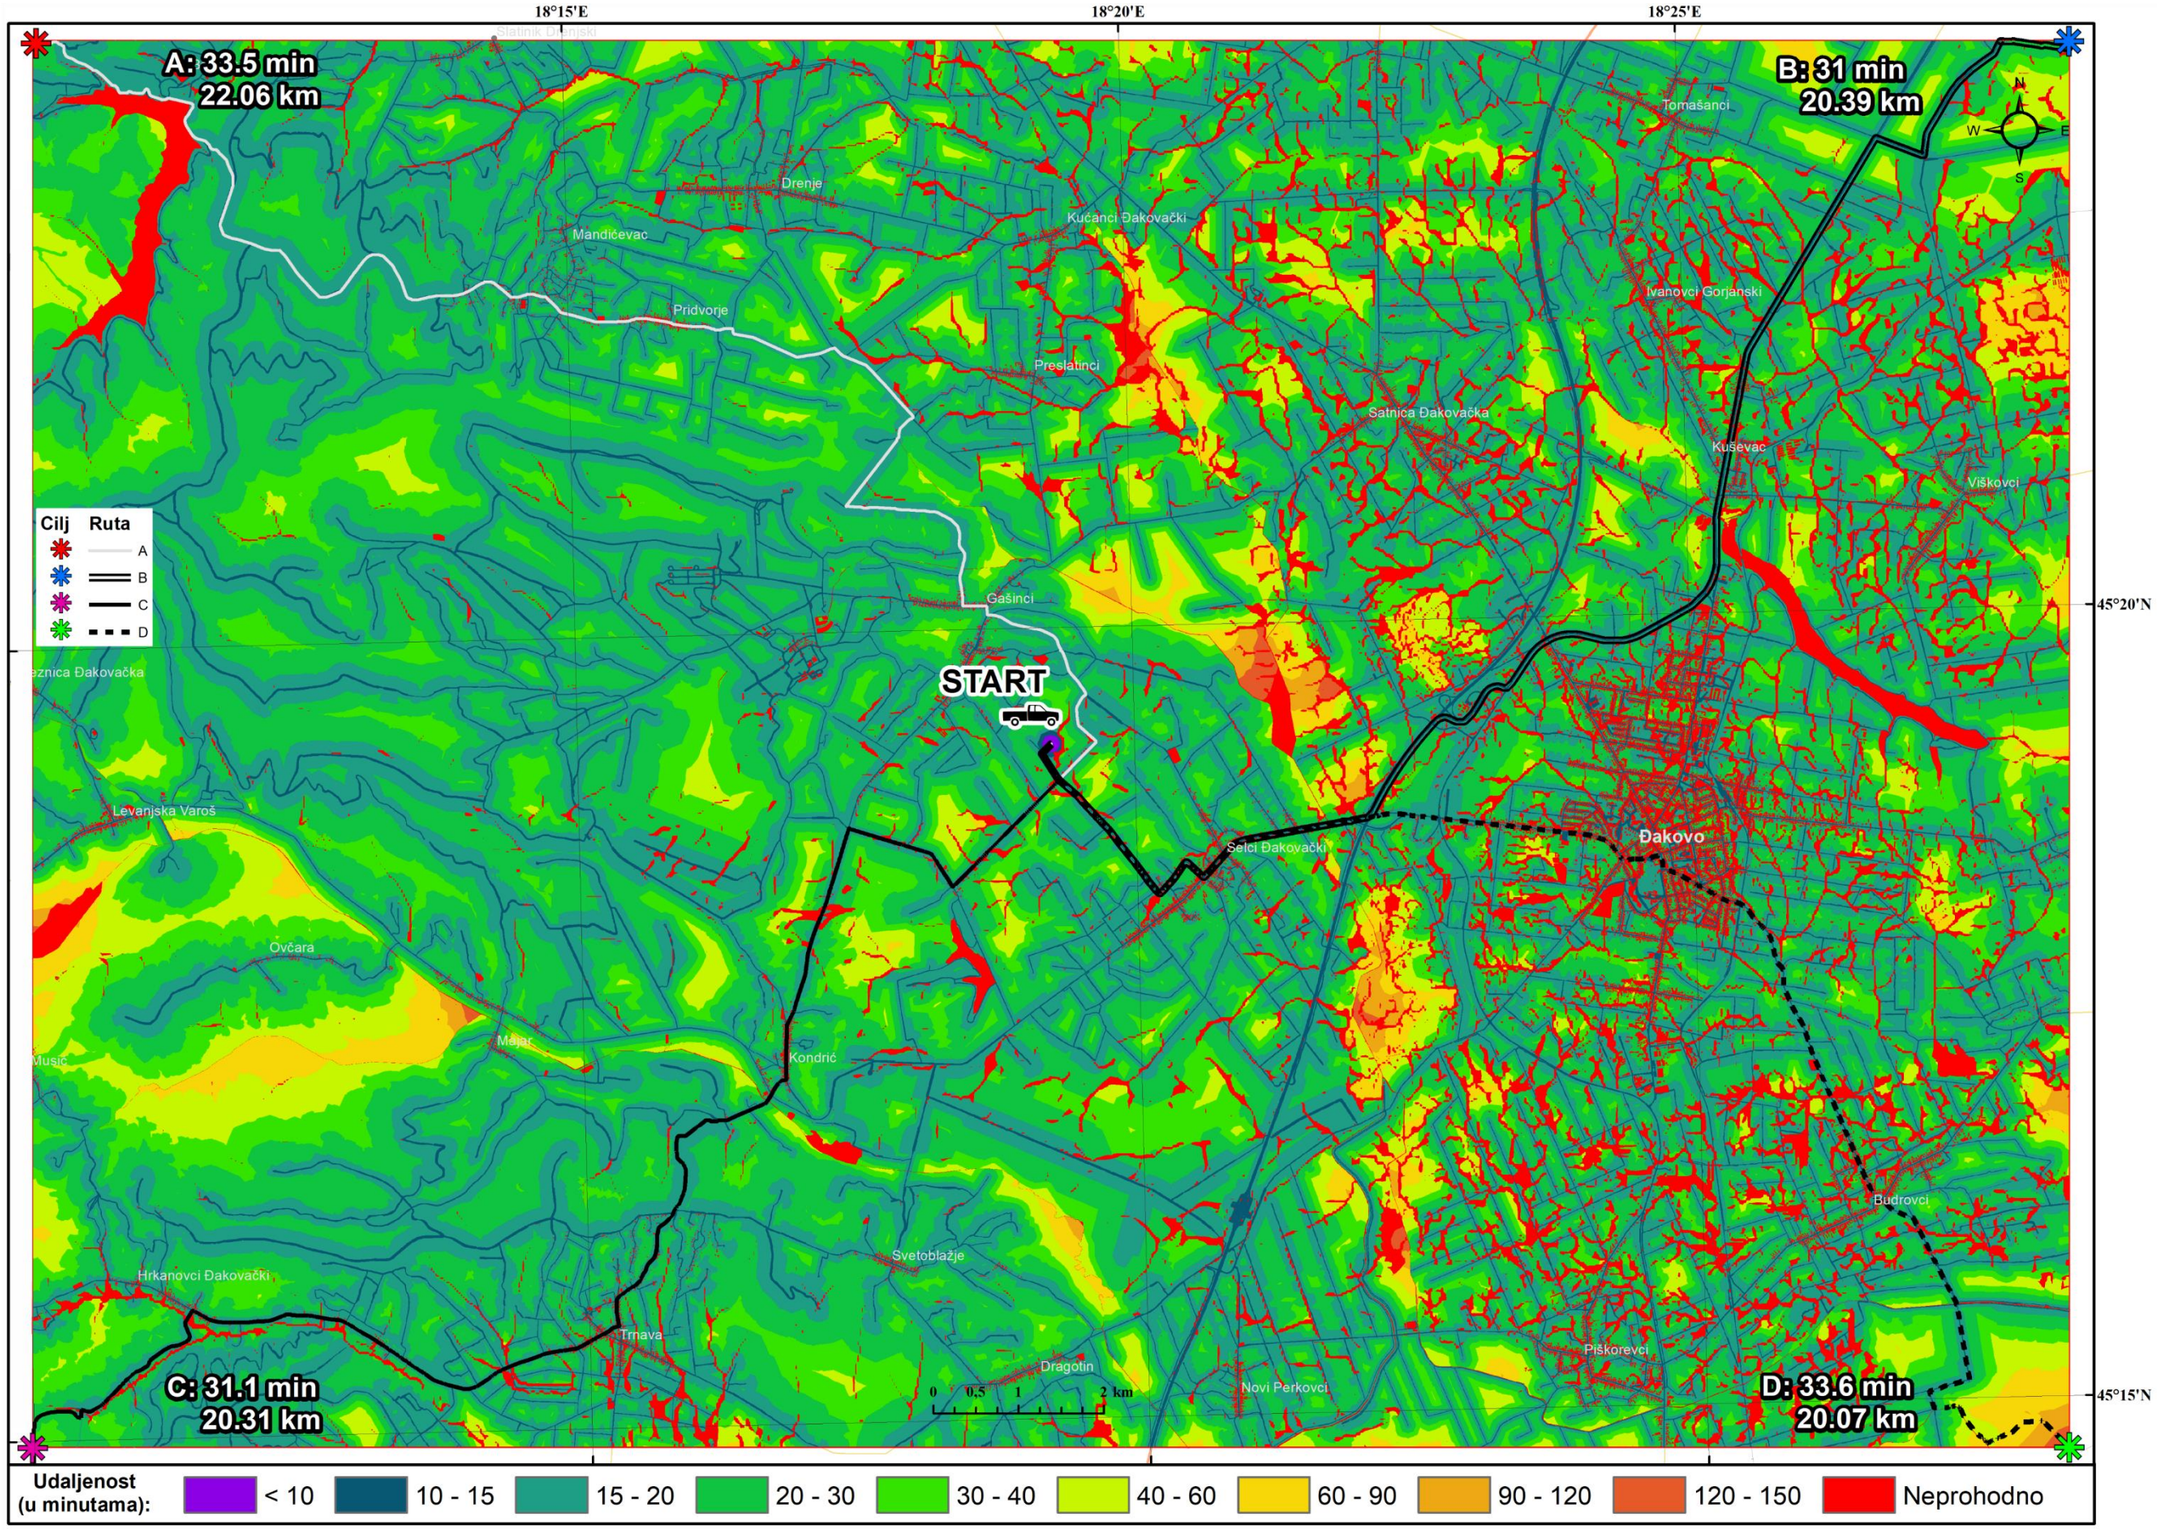

Sl. 101. Karta najbržih ruta kretanja i vremenska udaljenost od polazišta za vozilo Land Rover Defender 110 (zima/proljeće – mokro)

4.7.3. Statistički pokazatelji terenske prohodnosti vozila

U nastavku će biti opisani površinski udjeli neprohodnosti prema pojedinim čimbenicima po vrstama vozila, na osnovu rezultata dobivenih izradom karata TPV kroz dva scenarija: „ljeto/jesen – suho“ i „zima/proljeće – mokro“. Od ukupne površine (394.35 km^2) istraživanja u oba scenarija prisutnost antropogenih objekata činila je neprohodnim 5.22 km^2 ili 1.32 % površine.

Prema podacima vidljivim na Sl. 102., tijekom provedenih izračuna u sklopu scenarija „ljeto/jesen – suho“ po vrstama vozila, udio neprohodnog zemljišta zbog ograničavajućih fizičko-geografskih čimbenika bio je sljedeći:

a) **Kawasaki B-Force 750 4x4i**: 3.86 km^2 ili 0.98 % ukupne površine, pri čemu se najveći udio od 70.51 % (2.72 km^2) odnosi na stalne vodotoke i vodene površine. Sljedeće glavne ograničavajuće čimbenike predstavljali su živičnjaci s 24.69 % (0.95 km^2), nagib reljefa s 4.67 % (0.18 km^2) i na šume je otpalo samo 0.13 % (0.01 km^2).
b) **Land Rover Defender 110**: 3.01 km^2 ili 0.76 % ukupne površine, pri čemu se najveći udio od 89.96 % (2.71 km^2) odnosi na stalne vodotoke i vodene površine. Ograničavajuće čimbenike predstavljali su još nagib reljefa s 9.84 % (0.30 km^2) i šume na koje otpalo samo 0.20 % (0.01 km^2).
c) **BOV Patria**: 12.09 km2 ili 3.07 % ukupne površine, pri čemu se najveći udio od 54.70 % (6.63 km^2) odnosi na vinograde. Stalni vodotoci i vodene površine činili su 22.53 % (2.72 km^2) neprohodnog zemljišta, zatim nagib reljefa 12.24 % (1.48 km^2) i šume s 10.53 % (1.27 km^2).
d) **Iveco Eurocargo ML 100 E21 4x4**: 6.45 km^2 ili 1.64 % ukupne površine, pri čemu se najveći udio od 42.43 % (2.74 km^2) odnosi na stalne vodotoke i vodene površine, potom nešto manji udio 37.61 % (2.43 km^2) ima i nagib reljefa. Ograničavajući čimbenik predstavljaju i šume s 19.96 % (1.29 km^2).
e) **BTR-50**: 11.14 km2 ili 2.82 % ukupne površine, pri čemu se najveći udio od 59.37 % (6.63 km^2) odnosi na vinograde. Stalni vodotoci i vodene površine činili su 24.41 % (2.72 km^2) neprohodnog zemljišta, zatim nagib reljefa 10.32 % (1.15 km^2) i šume s 5.90 % (0.66 km^2).
f) **Tenk M-84**: 12.42 km^2 ili 3.15 % ukupne površine, pri čemu se najveći udio od 53.24 % (6.63 km^2) odnosi na vinograde. Stalni vodotoci i vodene površine činili su 21.92 %

(2.72 km^2) neprohodnog zemljišta, zatim nagib reljefa 19.54 % (2.43 km^2) i uvjetno neprohodne šume s 5.31 % (0.66 km^2).

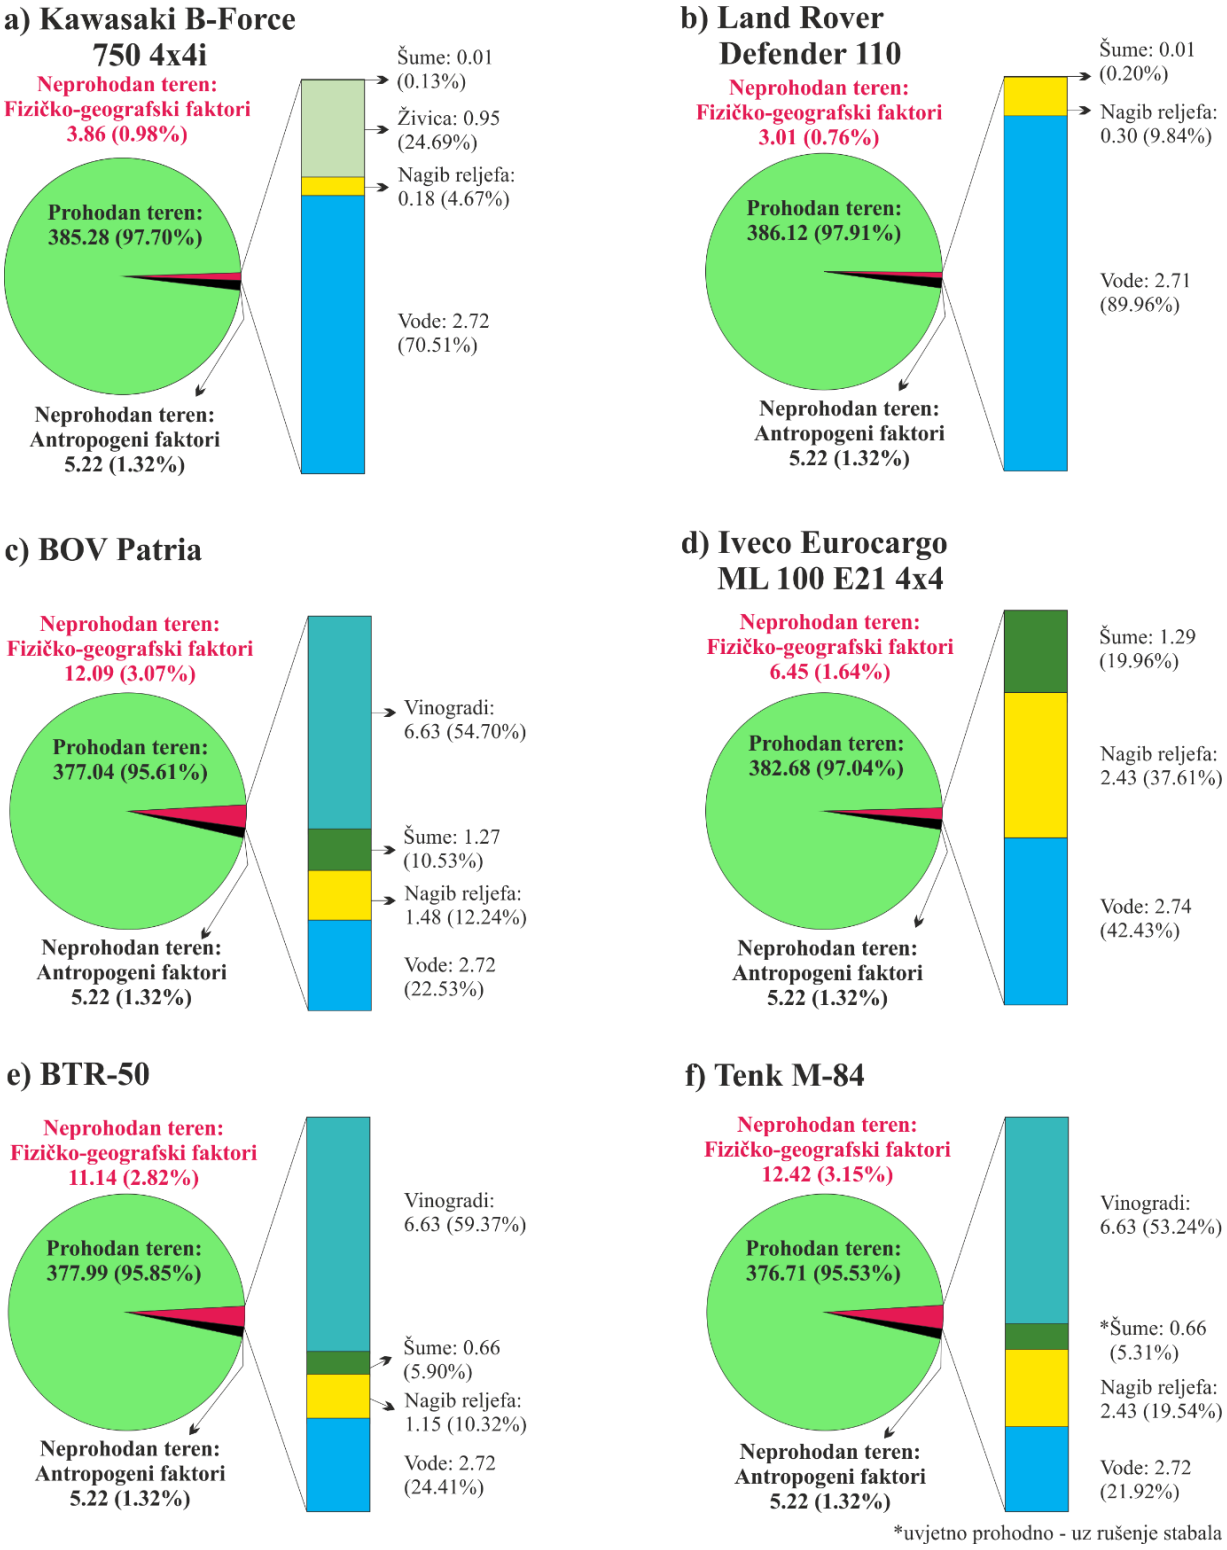

Sl. 102. Statistički prikaz* TPV (km^2), za period: ljeto/jesen – suho

*statističkim prikazom obuhvaćene su površine veće od 0.01 km^2

Prema podacima vidljivim na Sl. 103., tijekom provedenih izračuna u sklopu scenarija „zima/proljeće – mokro“ po vrstama vozila, udio neprohodnog zemljišta zbog ograničavajućih fizičko-geografskih čimbenika bio je sljedeći:

a) **Kawasaki B-Force 750 4x4i**: 12.38 km^2 ili 3.14 %, pri čemu se najveći udio od 68.58 % (8.49 km^2) odnosi na prohodnost tla. Stalni vodotoci i vodene površine čine 22.24 % (2.75 km^2), živičnjaci 7.26 % (0.95 km^2) i nagib reljefa 1.45 % (0.18 km^2). Vrlo male udjele u neprohodnosti imali su i prostori preklopa živica i prohodnosti tla s 0.42 % (0.05km^2), te šume 0.04 % (0.01 km^2).
b) **Land Rover Defender 110**: 30.16 km^2 ili 7.65 %, pri čemu se najveći udio od 89.92 % (27.12 km^2) odnosi na prohodnost tla. Stalni vodotoci i vodene površine zauzimaju 9.08 % (2.74 km^2), nagib reljefa 0.95 % (0.29 km^2). Vrlo male udjele imaju područja obostrane prisutnosti velikog nagiba reljefa i neprohodnog tla koji čine 0.03 % (0.01 km^2), te područja pokrivena šumom preostalih 0.02 % (0.01 km^2).
c) **BOV Patria**: 27.74 km^2 ili 7.04 %, pri čemu se najveći udio od 56.36 % (15.63 km^2) odnosi na tlo. Značajne površine zauzimaju vinogradi s 23.84 % (6.62 km2), stalni vodotoci i vodene površine 9.87 % (2.74 km^2), nagib reljefa 5.19 % (1.44 km^2) i šume s 4.33 % (1.20 km^2). Preostalih 0.41 % (0.11 km^2) odnosi se na područja preklapanja prethodno navedenih čimbenika.
d) **Iveco Eurocargo ML 100 E21 4x4**: 46.34 km^2 ili 11.75 %, pri čemu se najveći udio od 86.19 % (39.94 km^2) odnosi na tlo. U manjem udjelu su prisutni stalni vodotoci i vodene površine s 5.94 % (2.75 km^2), nagib reljefa s 4.91 % (2.27 km^2) i šume s 2.45 % (1.14km^2). Malen, ali zamjetan udio imaju i područja obostrane prisutnosti nagiba reljefa i neprohodnosti tla s 0.33 % (0.15 km^2), nagiba reljefa i šume s 0.19 % (0.09 km^2).
e) **BTR-50**: 14.85 km^2 ili 3.77 %, pri čemu se najveći udio od 44.54 % (6.62 km^2) odnosi na vinograde. Tlo s 24.88 % (3.70 km^2), te stalni vodotoci i vodene površine s 18.41 % (2.73 km^2) činili su zamjetan udio neprohodnog zemljišta. Manjim dijelom prisutni su nagib reljefa 7.67 % (1.14 km^2) i šume s 4.17 % (0.62 km^2). Preostalih 0.33 % (0.05 km^2) odnosi se na područja preklapanja prethodno navedenih čimbenika.
f) **Tenk M-84**: 18.77 km^2 ili 4.76 %, pri čemu se najveći udio od 44.54 % (6.62 km^2) odnosi na vinograde. Bitni čimbenici su i tlo s 33.77 % (6.34 km^2), stalni vodotoci i vodene površine s 14.58 % (2.74 km^2), nagib reljefa 12.72 % (2.39 km^2) i uvjetno neprohodne šume s 3.27 % (0.61 km^2). Preostalih 0.44 % (0.08 km^2) odnosi se na područja preklapanja prethodno navedenih čimbenika.

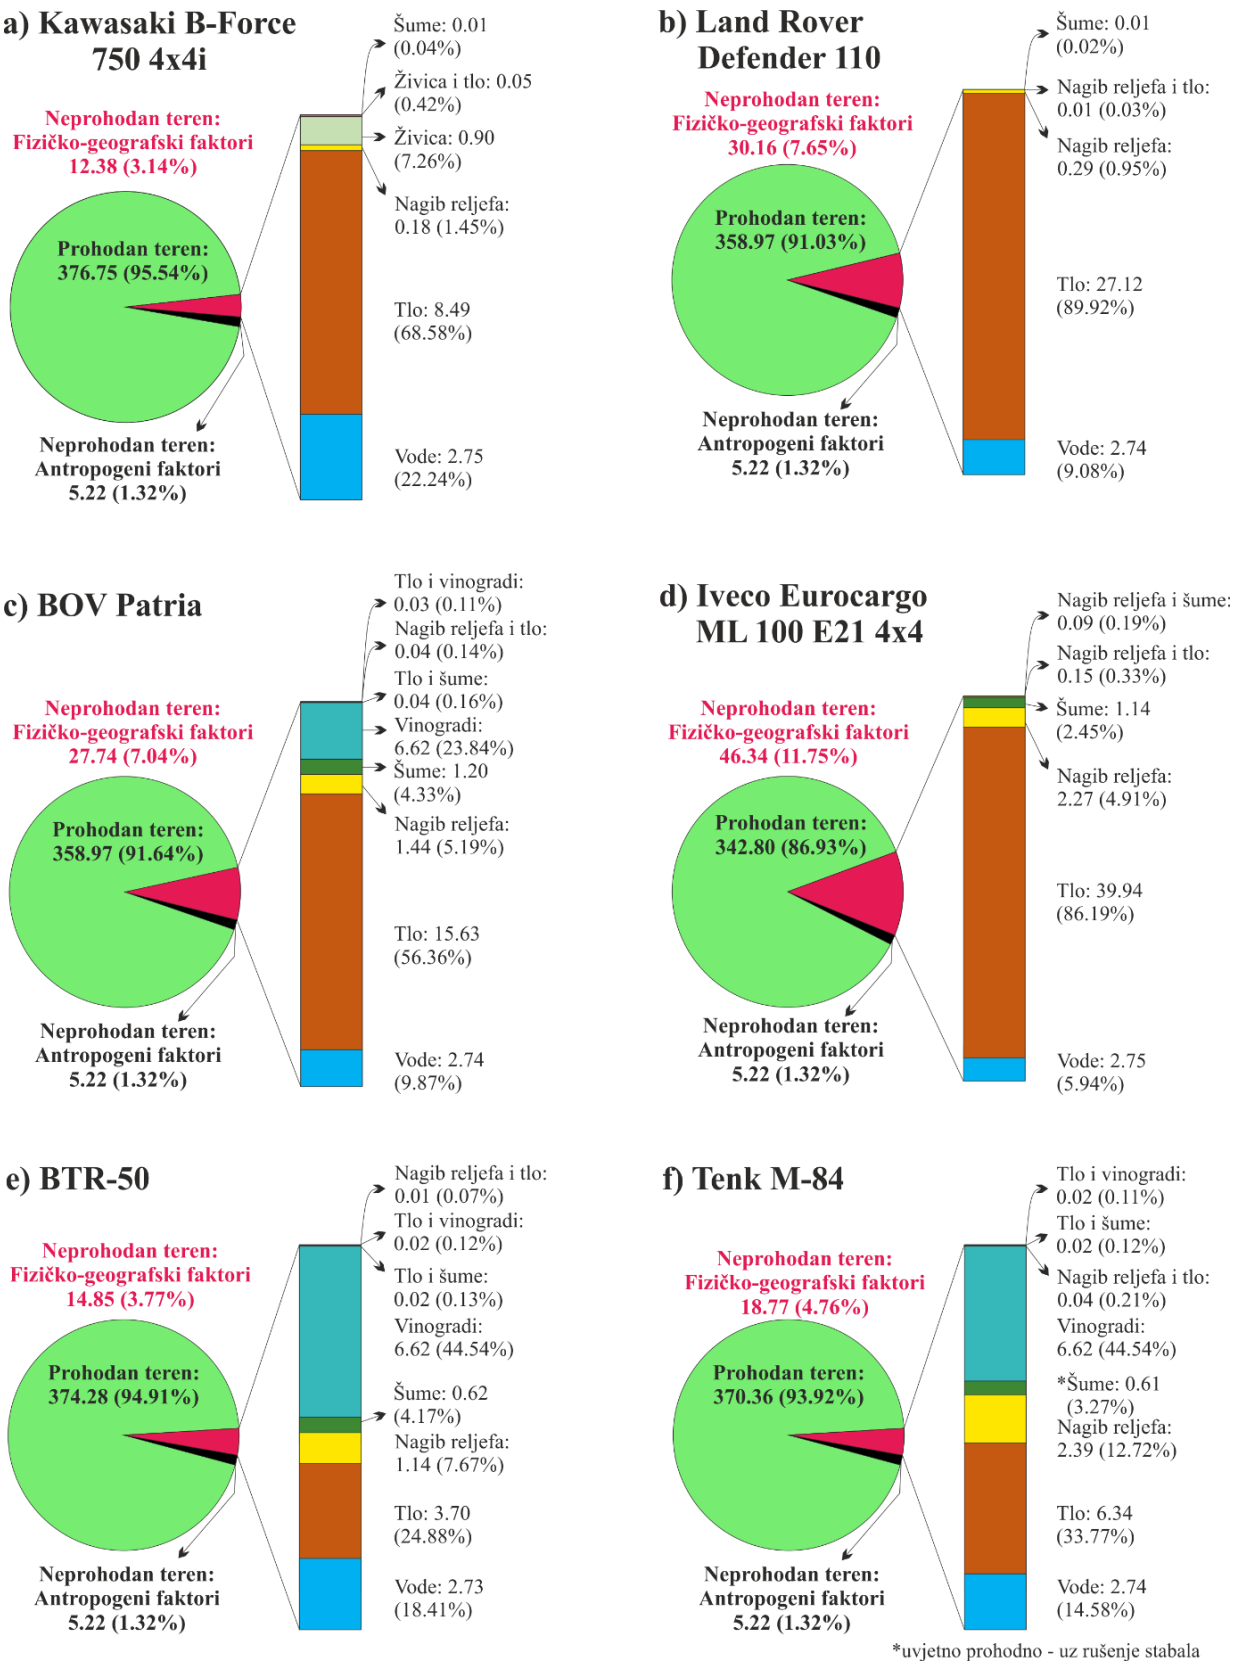

Sl. 103. Statistički prikaz* TPV (km²), za period: zima/proljeće – mokro

*statističkim prikazom obuhvaćene su površine veće od 0.01 km²

Preklop područja nagiba i neprohodnog tla uzrokovan je procesima prostornih analiza prilikom promjena rezolucija ćelija ulaznih i izlaznih parametra prostorne obrade. To se odnosi na TIV čija je „ulazna“ rasterska rezolucija ćelije bila 25x25 metara. Sve navedeno odnosi se samo na statističku obradu podataka i ne utječe na konačne rezultate analize i kartografske proizvode.

5. Rasprava

Cilj ovog rada bio je prostornom analizom i kvantitativnim vrednovanjem fizičko-geografskih čimbenika uspostaviti GIS model TPV za kontaktni prostor Đakovačke lesne zaravni i pobrđa Dilj gore.

Istraživanje je provedeno na temelju podataka iz postojećih prostornih baza koje su prikupile i formirale institucije uspostavljene od strane relevantnih državnih tijela. Osim preuzetih prostornih podataka, podaci su kreirani i terenskim mjerenjima i uzorkovanjima, te laboratorijskim analizama. Postojeći i prikupljeni podaci omogućili su prostornu analizu i kvantitativno vrednovanje fizičko-geografskih čimbenika i njihovih atributa temeljem literaturnih izvora, terenskih mjerenja i rezultata vlastitih istraživanja. Kvaliteta i točnost izvora i rezultata vlastitih istraživanja omogućili su formiranje ulaznih parametara, koji su nakon provedenih analiza strukturirani kroz GIS model.

Uspostava funkcionalnog GIS modela zahtijevala je holistički i multidisciplinarni pristup istraživanja čime je obuhvaćeno niz nužnih procesa. Prostornoj analizi i vrednovanju fizičko-geografskih čimbenika prethodila su istraživanja dostupnih izvora podataka. U sklopu prikupljanja podataka bilo je potrebno utvrditi njihovu točnost, strukturu, konzistentnost, vjerodostojnost, položajnu točnost i topološke odnose. Na temelju rezultata preliminarnih analiza uslijedila su terenska uzorkovanja i mjerenja s ciljem oformljivanja slojeva kojima je moguće kvantitativno izraziti i prostorno prikazati prisutne fizičko-geografske čimbenike. Pojedini čimbenici nisu striktno deterministički valorizirani, već su na osnovu stohastičkih principa upotrijebljene empirijske metode.

Rezultati i kvaliteta istraživanja izravno su ovisni o broju čimbenika te točnosti i preciznosti podataka uključenih u modele. Njihova brojnost i kvaliteta ovisi o provedenim mjerenjima i dostupnosti podataka. U modeliranju nikada nije moguće postići apsolutnu točnost izračuna koji bi u konačnici odgovarali stvarnoj situaciji. Kvaliteta izlazne informacije ovisi o usklađenosti parametara prohodnosti unutar modela s jedne strane i kvalitete ulaznih podataka koje model analizira s druge strane. Brojni autori su proveli istraživanja utjecaja pojedinih čimbenika na kretanje vozila, ali najveći znanstveni izazov predstavlja proces objedinjavanja i definiranja zbirnoga utjecaja svih elemenata prostora na kretanje vozila. Stoga treba napomenuti da svi dosadašnji modeli spadaju u heurističku skupinu modela, gdje nije moguće

jednoznačno i s potpunom sigurnošću jamčiti točan konačni rezultat izračuna modeliranja. GIS osigurava pogodno okruženje za rješavanje problema svih prepoznatih čimbenika TPV (Choi, i dr., 2019; Hohmann i dr., 2013). Na svojoj platformi objedinjuje procese strukturiranja, organizacije, analize i modeliranja podataka te omogućuje evaluaciju, standardizaciju i vizualizaciju TPV.

Modelom su obuhvaćeni svi parametri korišteni u dosadašnjim radovima (Sl. 12.), osim brzine vodotoka. Za razliku od dosadašnjih modela ovim modelom je raščlanjena kultivirana vegetacija obzirom na zasađene vrste i usklađeni su njihovi vegetacijski maksimumi prema godišnjim dobima. Osnovni je problem pri definiranju parametara u modelima u tome što je teško izdvojiti svaki čimbenik zasebno i točno utvrditi koliko on u konačnici usporava vozilo i utječe na njegovu krajnju brzinu u stvarnoj situaciji. Posebice je teško utvrditi usporenje uzrokovano kombinacijom interakcije dvaju ili više čimbenika istodobno, pri čemu se još treba dodati i činjenica da bi sve kombinacije trebalo istražiti i na svakom pojedinom tipu vozila. Prostor za daljnja istraživanja ovog multidisciplinarnog područja i poboljšanja prethodno definiranih parametara moguće je pronaći u primjeni novih:

- izvora podataka kao što su LIDAR (Dawkins, 2011), radarski i multi spektralni snimci (Frankenstein, 2008; Frankenstein i dr., 2015; Kourdian, 2009),
- empirijskih terenskih istraživanja testiranja modela s vozilima u stvarnim uvjetima (George i dr., 2017; Lessem i dr., 1992; Li i dr., 2007; Murphy i Randolph, 1994; Rybansky i dr., 2015; Talhofer i dr., 2015) i
- postavljanju *in situ* senzora za praćenje meteoroloških parametra (Albert i dr., 2000; Frankenstein i Koenig, 2004b; Mason i dr., 2003).

U tekstu koji slijedi bit će testirano 5 postavljenih hipoteza istraživanja, te će se ujedno provesti rasprava o postignutim rezultatima i daljnjim mogućnostima istraživanja.

Hipoteza A je glasila**: „**Iz stvorenog modela terenske prohodnosti, bit će moguće načiniti karte prohodnosti za više vrsta vozila u više različitih mjerila.“

Modelom je stvorena kartografska osnova za prikaz svih mjerila, čime je **Hipoteza A** potvrđena. Uz tematske kartografske proizvode, modelom su kreirane i digitalne podloge koje omogućavaju upotrebu alata za izračun optimalnih ruta kretanja i karata dostupnosti. Model također omogućava brzu izmjenu i korekciju parametara vozila i fizičko-geografskih čimbenika. Modelom je osigurana modularnost i kreiranje kartografskih proizvoda razine

detalja do 1x1 metar prostorne rezolucije rasterskih ćelija. Najviša razina detalja i točnosti potrebna je simulatorima terenske vožnje i interaktivnim aplikacijama za planiranje aktivnosti autonomnih terenskih vozila (Kang i dr., 2011; Pokonieczny i Rybansky, 2018; Richmond i dr., 2009). Postignuti stupanj detaljnosti ne omogućava digitalni prikaz stvarnosti visoke kvalitete. Može se raspravljati i o kvaliteti ulaznih prostornih podataka, jer prije svega o njima i ovisi kvaliteta kreiranih modela (Talhofer i dr., 2015), no povećanje detalja dovodi do problema koji se odnose na pohranu i obradu digitalnih podataka. Dodatnim povećanjem detalja za ovo područje istraživanja porasli bi zahtjevi za računalnim resursima. Veći stupanj detalja zahtijevaju prije svega autonomna vozila, no trendovi idu ka tome da vozila koriste vlastite senzore okoliša s kojima u realnom vremenu mogu skenirati okruženje i automatski odabirati smjer kretanja u realnom vremenu (Al-Hasan i Vachtsevanos, 2002).

Prostorna rezolucija ćelije 1x1 metar omogućila je izdvajanje vertikalnih i horizontalnih objekata čija širina, dubina ili visina prelazi 1 metar. Sve udubine i uzvisine veće od 1 metra determinirane su kutom nagiba većim od 45° što niti jedno od promatranih vozila ne može savladati. Upotrebom rezolucije ove točnosti usklađene su tehničke sposobnosti vozila koje se odnose na savladavanje prepreka.

Mjerenjima poprečnih profila vodotoka zaključeno je da se korišteni ulazni vektorski visinski podaci CRONO GIP-a mogu koristiti za izradu DMR-a čija rezolucija nije manja od 1x1m. Terenskim mjerenjima je dokazano da povećanjem rezolucije ne dolazi i do poboljšanja kvalitete prostornih podataka. Za detaljniji digitalni prikaz modela reljefa u budućnosti potrebniji su točniji i kvalitetniji visinski podaci, pri čemu je LIDAR tehnologija odgovarajuće rješenje.

U komparativne svrhe možemo iskazati proizvedenu količinu podataka i izračunati koliko bi bio velik zapis u računalnoj memoriji kada bi istu metodologiju primijenili na područje Republike Hrvatske. Prostor istraživanja ima 394.3 km^2, jedan rasterski sloj prohodnosti veličine ćelije 1x1 metar zauzima memoriju od 1.47 Gb u nekomprimiranom obliku. Za izradu jednog sloja karte prohodnosti iskorišteno je 24 ulazna sloja strukturirana u 7 faktora. Za izradu jedne karte prohodnosti (za cjelokupni rasterski zapis treba uzeti okvir grube površine od oko 200 000 km^2) Republike Hrvatske u trenutnom formatu trebalo bi osigurati otprilike 20 Tb memorije za pohranu podataka prohodnosti jednog tipa vozila.

Možemo reći da su na kartama maksimalnih mogućih brzina kretanja vozila (KMMBKV) prikazane srednje ili prosječne, odnosno optimalne brzine kretanja vozila. Modeliranjem su

prikazane optimalne brzine kretanja vozila u smislu održavanja sigurnosti vozača, a da pri tome nisu narušene pokretačke sposobnosti vozila. Na kartama su izražene uopćene brzine kretanja vozila, jer treba imati na umu da na njima nije određen točan pravac kretanja i željeni cilj putovanja. Najtočniju kartu pretpostavljenih brzina kretanja vozila bilo bi moguće načiniti tek nakon jasno definiranog smjera ili rute kretanja. Stoga izrađene karte treba promatrati kao proizvode informativnog karaktera koji pružaju općenite informacije o stanju prohodnosti terena, te da stvarno stanje situacije na terenu može odstupati od modelom predviđenih brzina. Za kartografske proizvode krupnijeg mjerila moguće je provesti generalizaciju dobivenih rezultata modela, te na taj način podatke iskoristiti za iskaz stanja prohodnosti terena s ciljem provedbe aktivnosti šireg područja djelovanja.

Hipoteza B je glasila**: „**Prevladavajući čimbenik mobilnosti vozila su sastav i struktura pedološke podloge.“

Prilikom formuliranja ove hipoteze korištena je terminologija opisa fizikalnih svojstava tla koju koriste pedolozi u agronomiji. Za objašnjenje i iznošenje zaključaka potrebne su detaljnije i kvalitetnije strukturirane metode koje koristi mehanika tla. Stoga „sastav i struktura podloge“ trebamo preformulirati kao „svojstva plastičnosti i konzistencija sitnozrnatih tala“ (glina i prahova).

Postavljena **Hipoteza B** može se parcijalno potvrditi ili odbaciti. Budući da su rezultati nosivosti tla formulirani prema krajnjim vrijednostima KI, formirana su i dva scenarijima „ljeto/jesen – suho“ i „zima/proljeće – mokro“. Tijekom perioda godine koji se odnosi na scenarij „ljeto/jesen – suho“ tlo nema nikakav utjecaj na TPV (Sl. 102.), stoga iz te perspektive **Hipotezu B** treba odbaciti.

Promatrajući scenarij „zima/proljeće – mokro“ rezultati TPV otkrivaju da kod 4 od 6 vozila korištenih u analizi, tlo predstavlja prevladavajući ograničavajući faktor prohodnosti. Kod vozila BTR-50 i Tenka M-84 vinogradi čine većinu neprohodnog zemljišta, ali i kod njih je udio neprohodnih područja uzrokovan niskom nosivošću tla velik. Kod BTR-a 50 neprohodno tlo obuhvaća 24.88 %, a kod tenka M-84 33.77 % ukupnih neprohodnih površina uzrokovanih fizičko-geografskim faktorima. Stoga prema scenariju „zima/proljeće – mokro“ ili za jednu polovicu godine, možemo reći da je **Hipoteza B** potvrđena.

Hipoteza C je glasila: „Postoji prostorna korelacija između podjele tla prema USCS klasifikaciji i USDA klasifikaciji na istraživanom području.“

Usporedbom rezultata uzoraka (50) vađenih na istovjetnim lokacijama, utvrđeno je da nema jasne i direktne veze između USCS i USDA klasifikacije tla. Stoga je **Hipoteza C** odbačena. Pretpostavljena gustoća uzimanja uzorkovanja na terenu bila je zadovoljavajuća, što je pokazala uniformnost rezultata laboratorijskih analiza (vidi Sl. 64. i Sl. 65.). U daljnjem radu na nacionalnoj razini može se pretpostaviti da je potrebno provoditi uzorkovanja manje gustoće, osim na aluvijalnim tlima gdje je potrebno provoditi gušća uzorkovanja. Njihova su mehanička svojstva predisponirana matičnim supstratom s mjesta nastanka i doživljavaju najdinamičnije izmjene vlažnih i suhih razdoblja, pa su ujedno i najrizičnija iz aspekata TPV.

Hipoteza D je glasila: „Postoji prostorna korelacija između podjele tla prema USCS klasifikaciji i litostratigrafskih jedinica na istraživanom području."

U detaljnijem i širem kontekstu istraživanja također je bilo potrebno utvrditi postoji li mogućnost upotrebe postojećih pedoloških podataka, čiju izvorišnu osnovu čini OPK, u svrhu predviđanja mehaničkih svojstava i kartiranja terenske prohodnosti tla. Rezultati su pokazali da za 66 % (6 od 9) tipova tala postoji jasna korelacija između tipa tla OPK i tipa tla prema USCS klasifikaciji. Sva tla kod kojih nije utvrđena korelacija odnose se na tla aluvija, odnosno na amfiglej koji je dominantan član. Daljnjom prostornom analizom utvrđeno je da glavna odrednica aluvijalnih tipova tla prema USCS klasifikaciji matični supstrat iz kojeg je tlo nastalo. Jasno je vidljivo da su gline niske plastičnosti (CL) s izvorišta kvartarne starosti, dok su gline visoke plastičnosti (CH) koje su transportirane i taložene uz vodotoke nastale na tlima koja su nastala iz geološke podloge veće starosti, odnosno pliocena i miocena. Sukladno rezultatima, geološka osnova prilikom modeliranja tipova tla prema USCS klasifikaciji ne smije biti izostavljena, odnosno tip tla OPK sam po sebi nije dovoljan za uspješno kartiranje nosivosti tla za vozila. Temeljem iznesenih rezultata **Hipoteza D** je potvrđena. Stoga je zaključeno da je za potrebe kartiranja (svih raspona mjerila karte) nekog područja nužno provesti laboratorijske i terenske pokuse. Isto zaključuju i preporučuju García-Gaines i Frankenstein (2015) i Gambill i dr. (2016). Jedino laboratorijskim pokusima moguće je dobiti pouzdane podatke za pojedinu grupu tla, odnosno na taj način su omogućeni daljnji procesi modeliranja hidroloških procesa i stanja na zemljištu sa svrhom utvrđivanja prohodnosti terena za vozila.

Hipoteza E je glasila: „Prohodnost terena podliježe promjenama u skladu sa promjenama meteoroloških uvjeta."

Istraživanjem je potvrđeno da meteorološki uvjeti izravno određuju mobilnost vozila i prohodnost terena tijekom godine. Promjena meteoroloških uvjeta direktno je utjecala na

prohodnost tla, stanje vodostaja vodotoka i vegetacijske cikluse biljnih kultura. Stoga je **Hipoteza E** potvrđena.

Prohodnost tla određuje nekoliko izravnih i niz posrednih meteoroloških elemenata. Količina padalina određuje stanje vlažnosti tla, ali je iz rezultata raspodjele padalina po godišnjim dobima vidljivo da prohodnost tla ne ovisi samo o njima. Tijekom zime palo je najmanje padalina, a mjerenjima krajem zime utvrđene su niske vrijednosti KI. S druge pak strane, tijekom ljeta pale su značajne količine padalina, ali to se nije odrazilo na prohodnost tla. Vlažnost tla i temperatura tla rezultat su interaktivnog djelovanja vanjskih faktora (Frankenstein, 2008). Temperatura zraka i trajanje insolacije određuje razinu evaporacije, pri čemu vegetacijski pokrov ima također vrlo važnu ulogu uslijed različitih razina evapotranspiracije vode iz tla. Tijekom mjerenja vlažnosti tla tijekom perioda zahvaćenog padalinama (sredina proljeća), zamijećene su velike amplitude u kretanju vlažnosti tla na specifičnim lokacijama („d“, „e“ i „i“). Te lokacije se nalaze na pretežno uravnjenoj (nagib 1.3° - 4°) lesnoj podlozi, s travnatim pokrovom. Istovremeno uslijed intenzivnog kišnog perioda na lokaciji „c“ koja ima ista obilježja kao i prethodno navedene, ali je pokrivena šumom, nisu zabilježene zamjetne amplitude vlažnosti tla. Razlozi manjih amplituda u vrijednostima vlažnosti tla, a samim time i nosivosti tla, proizlaze iz visoke transpiracije šumskih krošnja, te „naknadnog“ smanjenog vlaženja šumskog tla. Zimi naoblaka i magle usporavaju procese isušivanja tla. Temperatura tla ima izravan utjecaj na udio vlažnosti tla, što se poglavito odnosi na temperature oko točke smrzavanja kada nosivost tla može varirati između vrlo velike (temperature ispod -5°C) i niske nosivosti pri temperaturama iznad 0°C. Za vedrih ljetnih dana tlo ovisno o dubini može doseći temperature i do 30°C (Sl. 70.). Za utvrđivanje povezanosti nosivosti tla sa svim referentnim parametrima potrebno je uključiti mnogo različitih senzora koji bi bili u stanju provoditi praćenje promjena svakog zasebnog parametra (Mason i dr., 2003). Osim količine padalina, vrste vegetacijskog pokrova, temperature zraka, temperature tla i vlažnosti tla, u promatranje bilo bi potrebno uključiti i mjerenja koja se odnose na insolaciju, gustoću i tip vegetacije, evaporaciju, evapotranspiraciju, albedo, i dr. Način provedbe praćenja navedenih parametara moguće je provesti daljinskim istraživanjima s ciljem dobivanja informacije o vlažnosti tla (Frankenstein i Koenig, 2004b; Stevens i dr., 2016; Vahedifard i dr. 2017). Područje Republike Hrvatske pokriva SMAP (Soil Moisture Active/Passive) Mission, ali su snimci vrlo male rezolucije (1 x 1 km), što ne bi zadovoljavalo zahtjeve modela. Stoga je osnovna problematika vezana uz dostupnost snimaka željenog područja istraživanja, odnosno ne postoje senzori željene namjene koji imaju globalnu pokrivenost. Mjerenjima provedenim

na malom broju lokacija uspješno je dobivena informacija o prohodnosti tla ukupnog područja istraživanja. Sljedeći korak u istraživanju trebao bi biti usmjeren na uporabu daljinskih istraživanja. Temeljem dobivenih informacija terenskih mjerenja mogli bi se dobiveni podaci upotrijebiti za kontrolu i usporedbu rezultata prohodnosti tla.

Klimatska obilježja godišnjih doba uvjetuju prisutnost vodotoka. Budući da se veliki dio istraživanog područja nalazi na lesnoj poroznoj i propusnoj podlozi razina vodostaja ovisi gotovo isključivo o oborinskim vodama, dok se na kontaktnom području može naći samo nekoliko izvora vode koji u pravilu tijekom ljeta presuše. Poplavljivanje oranica uslijed naglih i velikih količina padalina uzrok su izgradnje guste mreže melioracijskih kanala. Uslijed obilnih proljetnih ili naglih ljetnih pljuskova prije hidroregulacijskih radova vodotoci nisu uspijevali odvodniti sve slivene padaline s oranica, pri čemu su se zbivale poplave. Potrebno je napomenuti da su svim stalnim vodotocima izmijenjeni matični tokovi ili su postojeći izdubljeni hidromelioracijskim zahvatima čime je iznesen matični sedimentacijski sloj koji se taložio tijekom vremena. Hidromelioracijski radovi su provedeni s ciljem obrane od poplava, na način da su iskopani kanali dubina do 10 m. Prilikom obrade ulaznih podataka i terenskim kartiranjem utvrđena je visoka unificiranost oblika poprečnog profila svih stalnih vodotoka. Svojim oblikom nalikuju na obrnuti trapez, što je rezultat težnje u današnjem sustavu upravljanja vodama, u smislu regulacije oborinskih voda i obrane od poplava. Na novonastalim antropogenim vodotocima čija starost nije veća od 60-ak godina stvoreno je novo korito gdje su onemogućeni procesi taloženja materijala. Stalni vodotoci ipak imaju dovoljno dubok sloj nataloženog materijala koji prelazi dubine od 30 cm, pa vodotoke uslijed prisustva visoke razine vlažnosti nije moguće prelaziti i u ljetnim mjesecima kada je protok vode najmanji i vodostaj najniži. Postojeća mreža vodotoka i odvodnih kanala služi za obrane od poplava i oborinske vode vrlo brzo otječu s inicijalnog mjesta pada. Uz sve navedeno treba napomenuti i izostanak prirodne vegetacije (močvarnih biljaka, drveća ili grmlja) zbog konstantnog održavanja velike protočnosti kanala. Svojom manjom širinom (do 2 m) i većom prisutnošću grmlja i manjih stabala razlikuju se jedino gornji dijelovi stalnih vodotoka. Stoga bi sve stalne vodotoke bilo primjernije nazivati „kanalima“, jer su hidromelioracijskim radovima uništeni matični tokovi.

Na rast i vegetacijske cikluse utječe izmjena godišnjih doba. Najnepovoljniji uvjeti prohodnosti terena prisutni su tijekom ljeta kada šume, grmlje, živice, travnjaci i ostale oranične kulture dosežu svoje vegetacijske maksimume i time narušavaju preglednost terena tijekom vožnje. Oranice predstavljaju najdinamičniju vegetacijsku kategoriju mobilnosti vozila. Na području istraživanja uzgajaju se žitarice (kukuruz, pšenica, ječam, soja, zob), suncokret,

krumpir, uljana repica, djetelinsko travne smjese. Svaka kultura zahtjeva različite načine i vremena sadnje i obrade tla, stoga je teško jasno definirati i jednoznačno dodijeliti stupanj usporenja vozila. Izmjene u vezi promjene vegetacijskog pokrova, nasada ili plodoreda i trenutnu situaciju na terenu moguće je detektirati uz pomoć multi spektralnih senzora. Snimke bi trebale biti dostupne u kratkim vremenskim intervalima (najmanje na tjednoj bazi) kako bi se mogla pratiti dinamika rasta vegetacije (Hubacek i dr., 2015; Xie i dr., 2008).

6. Zaključak

U ovom radu je prostornom analizom i kvantitativnim vrednovanjem fizičko-geografskih čimbenika utvrđena prohodnost terena za vozila na kontaktnom prostoru Đakovačke lesne zaravni i pobrđa Dilj gore. Istraživanje fizičko-geografskih čimbenika odnosilo se na utjecaj usporenja vozila uslijed pojavnosti različitih formi i stanja reljefa, tla, meteo-klimatskih uvjeta, voda i vegetacije. U istraživanje su uključeni antropogeni objekti i strukture, kako bi rezultati odgovarali stvarnom odrazu situacije u prostoru.

Analiza usporenja vozila provedena je GIS modelom koji je zasnovan na principima neizrazite logike (engl. *Fuzzy logic*). Model je uspostavljen na postojećim i prikupljenim prostornim podatcima. Provedena je kontrola točnosti prostornih podataka CRONO GIP baze podataka na temelju kojih je izrađen DMR. Usporedbom rezultata prostornih analiza različitih prostornih rezolucija sloja nagiba padina s provedenim terenskim mjerenjima poprečnih profila hidrografskih objekata u zaravnjenim dijelovima područja istraživanja, za referentnu rezoluciju modela odabrana je rezolucija ćelija 1x1m.

Na temelju 50 poznatih lokacija istraženih profila tla prema USDA granulometrijskoj klasifikaciji provedeno je terensko uzorkovanje uzoraka tla (72), te laboratorijska analiza uzoraka tla prema USCS klasifikaciji tla. Kartiranjem nisu utvrđene korelacijske veze između dvaju klasifikacijskih sistema tla.

Uspješno je provedeno kartiranje fizikalnih svojstava tla na osnovu kartografskih jedinica OPK i OGK. Utvrđeno je da su gline niske plastičnosti (CL) nastale na geološkoj podlozi kvartarne starosti, dok su gline visoke plastičnosti (CH) koje su transportirane i taložene uz vodotoke nastale na tlima matičnog supstrata iz perioda pliocena i miocena. Ustanovljena je nužnost laboratorijskih analiza prilikom klasificiranja tla prema USCS u svrhu uspješnog kartiranja mehaničkih svojstava tala.

Provedena su terenska *in situ* mjerenja unutar uskog područja (prostornog obuhvata 3.5 km^2) na 12 lokacija odabranih na temelju njihove geomorfološke, pedološke i vegetacijske heterogenosti. Rezultati *in situ* mjerenja (DKP, sonda za mjerenje vlažnosti, termometar i krilna sonda) uspješno su translatirani na čitavo područje istraživanja koristeći TIV. Korelacijske veze između parametara KI, vlažnosti tla i TIV su bile u rasponu između 0.67-0.95, dok su transformacijski parametri između KI i TIV-a imali koeficijente reprezentativnosti (R^2) između

0.48-0.91. Rezultatima mjerenja KI tijekom svih godišnjih doba (35 dana, odnosno 7 petodnevnih mjerenja), utvrđeno je da se prohodnost tla može raspodijeliti u dva scenarija. Vršne vrijednosti nosivosti tla integrirane su u scenariju „ljeto/jesen – suho“, a minimalne vrijednosti u scenariju „zima/proljeće – mokro“. Tijekom ljeta i jeseni nosivost tla nije ograničavajući čimbenik prohodnosti vozila.

Analizom hoda količine padaline tijekom godine nije utvrđena izravna ovisnost prohodnosti tla i količine padalina, već da na nju utječu i ostali klimatski elementi (temperatura, insolacija, naoblaka i vjetar).

Terenskim kartiranjem i mjerenjima utvrđene su granice isušivanja stalnih vodotoka, dok je uslijed prisutnosti vode u vodotocima utvrđeni KI dna vodotoka prenizak za uspješan prelazak svih tipova vozila.

Kvaliteta i točnost izvora i rezultata vlastitih istraživanja omogućila je formiranje ulaznih parametara, koji su nakon provedenih analiza strukturirani kroz GIS model koristeći principe neizrazite logike.

Pomoću neizrazite logike strukturirani su koeficijenti usporenja svih čimbenika u rasponu vrijednosti: neprohodno (0), uvjetno prohodno (0-1) i prohodno (1). Čimbenici su grupirani u 6 grupa faktora: Faktor nagiba reljefa, Faktor hrapavosti površine, Faktor tla, Hidrološki faktor, Vegetacijski faktor i Antropogeni faktor. Rezultati su omogućili kartografski prikaz i analize dostupnosti područja za 6 različitih tipova vozila kroz scenarije „ljeto/jesen – suho“ i „zima/proljeće – mokro“. Zaključeno je da dominante ograničavajuće čimbenike prohodnosti čine vode (jezera) i vinogradi, dok u razdoblju „zima/proljeće – mokro“ promjenom meteoroloških uvjeta tlo postaje prevladavajući faktor mobilnosti vozila.

Literatura

1. Affleck, R. T., Melloh, R. A., Shoop, S. A., 2009: Cross-country mobility on various snow conditions for validation of a virtual terrain, *Journal of Terramechanics* 46 (4), 203–210, DOI:10.1016/j.jterra.2008.12.005.
2. Ågren, A. M., Lidberg, W., Strömgren, M., Ogilvie, J.,Arp, P. A., 2014: Evaluating digital terrain indices for soil wetness mapping-a Swedish case study, *Hydrology and Earth System Sciences* 18 (9), 3623–3634, DOI: 10.5194/hess-18-3623-2014.
3. Ahlvin, R. B., Haley, P. W., 1992: *NATO Reference Mobility Model Edition II, NRMM II Users's guide*, Wareways Experiment Station, Corps of Engineers, Vicksburg.
4. Al-Hasan, S., Vachtsevanos, G., 2002: Intelligent route planning for fast autonomous vehicles operating in a large natural terrain, *Robotics and Autonomous Systems* 40 (1), 1–24, DOI:10.1016/S0921-8890(02)00208-7.
5. Albert, M., Koenig, G., Mason, G., 2000: Development of a FAST all-seasons model for the state of the ground, in: *Proceedings of the 2000 Winter Simulation Conference* (eds. Joines J. A. et al), IEEE, Orlando, 1010–1019.
6. Andersen, H.-E., McGaughey, R. J., Carson, W. W., Reutebuch, S. E., Mercer, B., Allan, J., 2003: A comparison of forest canopy models derived from LIDAR and INSAR, *ISPRS Archives* 34 (3/W13), 211–217.
7. *ArcGIS Desktop Help 10.5 Spatial analyst toolbox*, Environmental Systems Research Institute (ESRI), https://desktop.arcgis.com/en/arcmap/10.5/tools/spatial-analyst-toolbox/fuzzy-membership.html, (30.10.2020.).
8. Atkinson, D. M., Deadman, P., Dudycha, D., Traynor, S., 2005: Multi-criteria evaluation and least cost path analysis for an arctic all-weather road, *Applied Geography* 25 (4), 287–307, DOI:10.1016/j.apgeog.2005.08.001.
9. Bacon, S. N., McDonald, E. V., Baker, S. E., Caldwell, T. G., Stullenbarger, G., 2008: Desert terrain characterization of landforms and surface materials within vehicle test courses at U.S. Army Yuma Proving Ground, USA, *Journal of Terramechanics* 45 (5), 167–183, DOI:10.1016/j.jterra.2008.09.005.
10. Baylot, E. A., Gates, B. Q., Green, J. G., Richmond, P. W., Goerger, N. C., Mason, G. L., Cummins, C.L, Bunch, L. S., 2005: *Standard for Ground Vehicle Mobility*, U.S. Army Corps of Engineers, Vicksburg.

11. Becker, C. M., Els, P. S., 2014: Profiling of rough terrain, *International Journal of Vehicle Design* 64 (2/3/4), 240, DOI:10.1504/IJVD.2014.058500.
12. Bekker, M. G., 1956: *Theory of Land Locomotion*, University of Michigan Press, Ann Arbor.
13. Birkel, P. A., 2003: Terrain Trafficability in Modeling and Simulation, *Technical paper Sedris* (1), 1–40.
14. Bognar, A., 1978: Les i lesu slični sedimenti Hrvatske, *Geografski glasnik* 40 (1), 21–39.
15. Bognar, A., 1999: Geomorfološka regionalizacija Hrvatske, *Acta Geographica Croatica* 34, 7–29.
16. Bogunović, M., 1973a: *Tla sekcije Vinkovci - 1, u mjerilu 1:50 000 (stručni izvještaj)*, Institut za pedologiju i tehnologiju tla poljoprivrednog fakulteta sveučilišta u Zagrebu, Zagreb, 58.
17. Bogunović, M., Rapaić, M., 1993: Digitalizacija osnovne pedološke karte Republike Hrvatske, *Bilten Savjeta za daljinska istraživanja i fotointerpretaciju* 12, 65–75.
18. Bojanovski, I., 1993: Arheološka istraživanja u Slavonskom Brodu i Brodskom Posavlju, *u: Znanstveni skup: Slavonski Brod, 18.-20. listopada 1988.*, (ur. Čečuk, B.), 59-70.
19. Borisov, M., Banković, R., Drobnjak, S., 2010: Evaluacija morfometrijskih karakteristika zemljišta pri izradi karte tenkoprohodnosti, *Vojnotehnički glasnik* 1 (11), 62–80.
20. Bozdech, G. W., 2012: *A GPS-based Mobility Power Model for Military Vehicle Applications*, University of Tennessee, Knoxville.
21. Bruzese, V. M., 1989: *Terrain analysis and geographic information systems*, Oregon State University, Corvallis.
22. Campbell, D. M. H., 2012: *TRAIL: Optimizing trail locations by terrain conditions and other considerations, at high resolution*, The University of New Brunswick, Fredericton.
23. Capek, J., Zerzán, P., Šimkova, K., 2019: Influence of tree spacing on vehicle manoeuvers in forests, *ICMT 2019 - 7th International Conference on Military Technologies, Proceedings* (June), DOI: 10.1109/MILTECHS.2019.8870092.
24. Casagrande, A., 1948: Classification and Identification of Soils, *Transaction*, ASCE, 113, 901-930.
25. Chiroux, R. C., Foster, W. A., Johnson, C. E., Shoop, S. A., Raper, R. L., 2005: Three-dimensional finite element analysis of soil interaction with a rigid wheel, *Applied Mathematics and Computation* 162 (2), 707–722, DOI: 10.1016/j.amc.2004.01.013.
26. Choi, K. K., Jayakumar, P., Funk, M., Gaul, N., Wasfy, T. M., 2019: Framework of Reliability-Based Stochastic Mobility Map for Next Generation NATO Reference

Mobility Model, *Journal of Computational and Nonlinear Dynamics*, 14 (2), 02101-2, DOI: 10.1115/1.4041350.

27. Ciobotaru, T., 2009: Semi-empiric algorithm for assessment of the vehicle mobility, *Leonardo Electronic Journal of Practices and Technologies* 8 (15), 19–30.
28. Daigle, J. J., Hudnall, W. H., Gabriel, W. J., Mersiovsky, E., Nielson, R. D., 2005: The National Soil Information System (NASIS): Designing soil interpretation classes for military land-use predictions, *Journal of Terramechanics* 42 (3–4), 305–320, DOI: 10.1016/j.jterra.2004.12.002.
29. Dawkins, J. J., 2011: *Terrain Characterization and Roughness Estimation for Simulation and Control of Unmanned Ground Vehicles*, Auburn University, Auburn.
30. *Defense Mapping Agency Procedural Guide for the Proiduction of the Sythesized Cross-Country Movement Compilation Overlay(s), Scale 1:50,000*, Defense Mapping Agency Hydrographic/Topographic Center, Washington D.C., 1982.
31. Densham, P. J., 1991: Spatial decision sup- port systems, u: *Geographical Information Systems: Principles and Applications (*ur. Maguire, D. J. i dr.), Longman Scientific & Techincal, Essex, 403–412.
32. Di Martino, F., Sessa, S., 2011: Spatial analysis and fuzzy relation equations, *Advances in Fuzzy Systems*, 2011 (1), DOI: 10.1155/2011/429498.
33. Dohnal, F., Hubacek, M., Simkova, K., 2019: Detection of Microrelief Objects to Impede the Movement of Vehicles in Terrain, *ISPRS International Journal of Geo-Information*, 8 (3), 101, DOI: 10.3390/ijgi8030101.
34. Donlon, J. J., Forbus, K. D., 1999: Using a Geographic Information System for Qualitative Spatial Reasoning about Trafficability, in: *Proceedings of QR99, The International Workshop on Qualitative Reasoning*, Cognitive Systems Division of the Department of Electrical Engineering and Computer Science, Loch Awe, 1–11.
35. Drescher, A., Hambleton, J. P., 2010: Geotechnics and Terramechanics, *58th Annual Geotechnical Engineering Conference Geotechnics*, St. Paul, (23–31).
36. Đuka, A., 2014: *Razvoj modela prometnosti terena za planiranje privlačenja drva skiderom*, Sveučilište u Zagrebu, Zagreb.
37. Earl, R., 1997*: Prediction of trafficability and workability from soil moisture deficit, Soil and Tillage Research* 40 (3–4), 155–168, DOI:10.1016/S0167-1987(96)01072-0.
38. Eastman, J. R., 1999: Multi-criteria evaluation and GIS, *Geographical information systems*, 493–502.

39. Eichrodt, A.W., 2003: *Development of a spatial trafficability evaluation system*, ETH, Zurich.
40. Frančula, N., 2004: *Kartografske projekcije*, Sveučilište u Zagrebu, Geodetski fakultet, Zagreb.
41. Frankenstein, S., 2008: *FASST Soil Moisture, Soil Temperature: Original Versus New*, Engineer Research and Development Center, Vicksburg.
42. Frankenstein, S., Koenig, G., 2004a: *FASST Vegetation Models*, Cold Regions Research and Engineering Laboratory, Vicksburg.
43. Frankenstein, S., Koenig, G., 2004b: *Fast All-season Soil STrength (FASST)*, Cold Regions Research and Engineering Laboratory, Vicksburg.
44. Frankenstein, S., Stevens, M., Scott, C., 2015: Ingestion of simulated SMAP L3 soil moisture data into military maneuver planning, *Journal of Hydrometeorology*, 16 (1), 427–440, DOI: 10.1175/JHM-D-14-0032.1.
45. García-Gaines, R. A., Frankenstein, S., 2015: *USCS and the USDA Soil Classification System, Development of a Mapping Scheme*, Cold Regions Research and Engineering Laboratory, Vicksburg.
46. Gambill, D. R., Wall, W. A., Fulton, A. J., Howard, H. R., 2016: Predicting USCS soil classification from soil property variables using Random Forest, *Journal of Terramechanics* 65, 85–92, DOI: 10.1016/j.jterra.2016.03.006.
47. George, A. K., Singh, H., Dattathreya, M. S., Meitzler, T. J., 2017: A Fuzzy Simulation Model for Military Vehicle Mobility Assessment, *Advances in Fuzzy Systems* 2017, 1-12, DOI:https://doi.org/10.1155/2017/3982753.
48. Grandjean, G., Angeliaume, S., Hohmann, A., Mardhel, V., Bourguignon, A., Courbouleix, S., Chanteclerc, M., Nouvel, J. F., Grima, M., Saporiti, N., Rousselin, T., Yesou, H., Uribe, C., Schaefer, G., N'Guyen, T., Champigny, P., Vandenberghe, F., 2009: The ECORS system: A mobility decision-making tool based on earth observation data, u*: International Geoscience and Remote Sensing Symposium (IGARSS)*, IEEE, Cape Town, 355–358, DOI:10.1109/IGARSS.2009.5417657.
49. Grogan, A., 2009: Creating a Spatial Analysis Model For Generating Composite Cost Surfaces to Depict Cross Country Mobility In Natural Terrain, u: *ASPRS/MAPPS 2009 Fall Conference*, American Society for Photogrammetry & Remote Sensing, San Antonio, 1–11.
50. Gumoś, A. K., 2005: *Modelling the Cross-Country Trafficability with Geographical Information Systems*, Linköpings universitet, Linköping.

51. Gustafsson, K., Hägerstrand, J., 2005: *Development of a neighbourhood graph for traficability analysis*, FOI - Swedish Defence Research Agency, Linköping.
52. Haley, P. W., Jurkat, P., Brady, P., 1979a: *NATO Reference Mobility Model, Edition I, Users Guidel, Vol 1*, TARADCOM Laboratory, Warren.
53. Haley, P. W., Jurkat, P., Brady, P., 1979b: *NATO Reference Mobility Model, Edition I, Users Guidel, Vol 2*, TARADCOM Laboratory, Warren.
54. Han, D. H., Kim, Y. D., Lee, J. Y., 2014: Multiple-criterion shortest path algorithms for global path planning of unmanned combat vehicles, *Computers and Industrial Engineering* 71 (1), 57–69, DOI:10.1016/j.cie.2014.02.013.
55. Handke, A., Butikofer, M., 1994: Computer-aided Mobility Prognosis of Vehicles in the Field, in: *6th European ISTVS Conference*, ISTVS, Vienna, 135–150.
56. Hengl, T., Reuter, H. I., 2009: *GEOMORPHOMETRY Concepts, Software, Applications, Developments in soil science – Volume 33*, Elsevier, Amsterdam, DOI: 10.1017/CBO9781107415324.004.
57. Heštera, H., 2020: Analysis of pedological factors and USCS in the contact area of Đakovo loess plateau and Dilj gora, Croatia, *The Mining-Geology-Petroleum Engineering Bulletin* 35 (1), 13–23, DOI: 10.17794/rgn.2020.1.2.
58. Heštera, H., Pahernik, M., 2018: Physical-geographic factors of terrain trafficability of military vehicles according to Western World methodologies, *Hrvatski geografski glasnik/Croatian Geographical Bulletin* 80 (2), 5–31, DOI:10.21861/hgg.2018.80.02.01.
59. Heštera, H., Plantak, M., Pahernik, M., 2019: Korekcija digitalizirane Osnovne pedološke karte Republike Hrvatske, (ur. Orešić, D., Lončar, J., i Maradin, M.), *7. hrvatski geografski kongres*, Čakovec, 235–236.
60. Hetherington, J. G., Smith, P. D., 1986: The survivability and mobility of armoured fighting vehicles -Tuition using a simple computer program, *Journal of Terramechanics* 23 (3), 131–140.
61. Hintze, D., 1991: The Prediction of Soil Strength with the Aid of Climatic Data, in: *5th European conference*, ISTVS, Budapest, 17–25.
62. Hofmann, A., Hoskova-Mayerova, S., Talhofer, V., 2013: Usage of fuzzy spatial theory for modelling of terrain passability, *Advances in Fuzzy Systems* 2013, 1–7, DOI:10.1155/2013/506406.
63. Hofmann, A., Hošková-Mayerová, Š., Talhofer, V., Kovařík, V., 2015: Creation of models for calculation of coefficients of terrain passability, *Quality & Quantity* 49 (4), 1679–1691, DOI:10.1007/s11135-014-0072-1.

64. Hohmann, A., Grandjean, G., Mardhel, V., Schaefer, G., Desramaut, N., 2013: A GIS-based Vehicle Mobility Estimator for Operational Contexts, *Transactions in GIS*, 17 (1), 78–95, DOI:10.1111/j.1467-9671.2012.01351.x.
65. Horttanainen, P., Virrantaus, K., 2004: Uncertainty evaluation of terrain analysis results by simulation and visualization, u: *Proc. 12th Int. Conf. on Geoinformatics − Geospatial Information Research: Bridging the Pacific and Atlantic* (ur. Brandt, S.), University of Gävle, Gävle, 473–480.
66. Hoškova-Mayerova, Š., Talhofer, V., Hofmann, A., 2010: Mathematical modell used in decision-making process with respect to the reliability of geo database, *Procedia Social and Behavioral Sciences* 9, 1652–1657, DOI:10.1016/j.sbspro.2010.12.381.
67. Hubacek, M., Ceplova, L., Brenova, M., Mikita, T., Zerzan, P., 2015: Analysis of Vehicle Movement Possibilities in Terrain Covered by Vegetation, u: *International Conference on Military Technologies* (ur. Krivanek, V.), University of Defence, Brno, 301–305.
68. Husnjak, S., 2014: *Sistematika tala Hrvatske*, Hrvatska sveučilišna naklada, Zagreb.
69. *Intelligence preparation of the battlefield*, Field Manual FM 34-130, Headquaters, Department of the Army, Washington D.C., 1994.
70. Jiang, H., Eastman, J. R., 2000: Application of fuzzy measures in multi-criteria evaluation in GIS, *International Journal of Geographical Information Science*, 14 (2), 173–184, DOI: 10.1080/136588100240903.
71. Jones, R., Horner, D., Sullivan, P., Ahlvin, R., 2005: A methodology for quantitatively assessing vehicular rutting on terrains, *Journal of Terramechanics*, 42 (3–4), 245–257, DOI: 10.1016/j.jterra.2004.10.007.
72. Jurkat, M. P., Nuttall, C.J., Haley, P.W., 1975: *The AMC '74 mobility model*, US Army Tank Automotive Command, Warren.
73. Kainz, W., 2001: Fuzzy Logic and GIS, *University of Vienna, Vienna*, 1–21, http://homepage.univie.ac.at/wolfgang.kainz/Lehrveranstaltungen/ESRI_Fuzzy_Logic/File_2_Kainz_Text.pdf.
74. Kang, M.-W., Jha, M. K., Hwong, D., 2011: A GIS-based simulation model for military path planning of unmanned ground robots, *International Journal of Safety and Security Engineering*, 1 (3), 248–264, DOI: 10.2495/SAFE-V1-N3-248-264.
75. Kirkland, J. L., 1981: Remote Sensing of Soil Trafficability Factors, in: *Seventh International Symposium Machine Processing of Remotely Sensed Data* (ur. Burroff, P.G., Morrison, D.B.), Purdue University, West Lafayette, 454–463.

76. Knob, M. J., 2010: *Estudo de trafegabilidade aplicado a veículos de roda em transporte e tração*, Universidade Federal de Santa Maria, Santa Maria.
77. Korolija, B., Jamičić, D., 1989b: *Osnovna geološka karta SFRJ 1:100 000, Tumač za list Našice L 34–85*, Geološki zavod Zagreb (1988.), Savezni geološki zavod, Beograd, 36.
78. Kourdian, R., 2009: *Analyse de la traficabilité en zone tropicale par imagerie spatiale optique et radar. Application au Tchad méridional*, Géosciences et Ressources Naturelles, Paris.
79. Kristalova, D., 2015: Evaluation Of The Data Applicable For Determining The Routes Of Movements Of Military Vehicles In Tactical Operation, in*: International conference KNOWLEDGE-BASED ORGANIZATION*, De Gruyter, Berlin, 699–705, DOI:10.1515/kbo-2015-0118.
80. Kruse, F. A., Boardman, J.W., Lefkoff, A. B., 2000: Extraction of compositional information for trafficability mapping from hyperspectral data, u: *Algorithms for Multispectral, Hyperspectral, and Ultraspectral Imagery VI* (ur. Shen, S.S., Descour M.R.), SPIE 4049, Orlando, 262–273, DOI:10.1117/12.410348.
81. Kuckelkorn, L., 1942: *Befahrbarkeitskarte Libyen 1:3.000.000, Karte der Wehrgeologenstelle (12) vom März 1942*, Heringen Collection Archive, Bundeswehr Geoinformation Center, Euskirchen.
82. Lagacherie, P., McBratney, A.B. i Voltz, M., (ur) 2007: *Digital soil mapping. An introductory perspective*, Developments in soil science, vol 31, Elsevier, Amsterdam.
83. Lal, R., Kimble, J.M., Follett, R.F., Stewart B.A., 1998: *Soil Processes and the Carbon Cycle*, 1st edition, CRC Press, Boca Raton, DOI: https://doi.org/10.1201/9780203739273.
84. Lantz, F., Edlund, S., Jungert, E., 2005: Context Fusion for Driveability Analysis, in: *8th International Conference on Information Fusion*, IEEE, Philadelphia, 1264–1271, DOI:10.1109/ICIF.2005.1592002.
85. Laskey, K. B., Wright, E. J., da Costa, P. C. G., Costa, P. C. G., 2010: Envisioning uncertainty in geospatial information, *International Journal of Approximate Reasoning* 51 (2), 209–223, DOI:10.1016/j.ijar.2009.05.011.
86. Leighty, R. D., 1965: Terrain mapping from aerial photography for purposes of vehicle mobility, *Journal of Terramechanics* 2 (3), 55–67, DOI:10.1016/0022-4898(65)90023-6.
87. Lessem, A., Ahlvin, R., Mason, G., 1996: Stochastic vehicle mobility forecasts using the NATO reference mobility model, *Journal of Terramechanics* 33 (6), 273–280, DOI:10.1016/S0022-4898(97)00010-4.

88. Li, Q., Ayers, P. D., Anderson, A. B., 2007: Modeling of terrain impact caused by tracked vehicles, *Journal of Terramechanics* 44 (6), 395–410, DOI:10.1016/j.jterra.2007.09.001.
89. *List of Publications of the U.S. Army Engineer Waterways Experiment Station*, Volume II (ITL-93-1), US Army Corps of Engineers, Vicksburg, 1993.
90. Loomer, S., 1987: Computer-assisted terrain analysis on a microcomputer, u: *Proceedings of the International Symposium on Computer-Assisted Cartography*, Auto-Carto VIII, Baltimore, 437–444.
91. Lubello, D., 2008: *A Rule-based SDSS for integrated forest harvesting planning*, Universitá degli studi di Padova, Padova.
92. Malm, F., 2018: One hundred years of cross-country mobility prediction in Germany, u: *Military Aspects of Geology: Fortification, Excavation and Terrain Evaluation* (ur. Rose, E.P.F. i dr.), Geological Society, London, https://doi.org/10.1144/SP473.7.
93. Mason, G., Ahlvin, R., Green, J., 2001: *Short-Term Operational Forecasts of Trafficability*, U.S. Army Corps of Engineers, Washington, D.C.
94. Mason, G. L., Gates, B. Q., Moore, V. D., 2012: Determining forces required to override obstacles for ground vehicles, *Journal of Terramechanics* 49 (3–4), 191–196, DOI:10.1016/j.jterra.2012.04.001.
95. Mason, G. L., Moore, D. W., Brandon, G. M., Leese, D. L., 2003: *Data Collection and Analysis of Moisture and Soil Strength Information for Validation of New State-of-the-Ground Models*, Engineer Research and Development Center, Vicksburg.
96. Mason, G., Priddy, J. D., Stevens, M. T., Towne, B. W., Osorio, J. E., 2015: *Test Procedures for the Determination of One-Pass Vehicle Cone Index (VCI)*, Proceedings of the 13th ISTVS European Conference, Rome, 19.
97. McBratney, A. B., Mendonca Santos, M. L., Minasny, B., 2003: On digital soil mapping, *Geoderma* 117 (1-2), 3-52, DOI: 10.1016/S0016-7061(03)00223-4.
98. McKenzie, N. J., Ryan, P. J., 1999: Spatial prediction of soil properties using environmental correlation, *Geoderma* 89 (1–2), 67–94, DOI: 10.1016/S0016-7061(98)00137-2.
99. Messmore, J. A., 1982: *Terrain Analysis Procedural Guide for Drainage and Water Resources*, U.S. Army Corps of Engineers, Fort Belvoir.
100. Messmore, J. A., Vogel, T. C., Pearson, A. R., 1981: *Terrain analysis procedural guide for vegetation*, U.S. Army Corps of Engineers, Fort Belvoir.
101. Mikulić, D., 2013: *Design of demining machinesDesign of Demining Machines*, Springer, London, DOI: 10.1007/978-1-4471-4504-2.

102. *Military Geographic Intelligence (Terrain)*, Field Manual FM 30-10, Headquaters, Department of the Army, Washington D.C., 1972.
103. Mintzer, O., Messmore, J. A., 1984: *Terrain analysis procedural guide for surface configuration*, U.S. Army Corps of Engineers, Fort Belvoir.
104. Mohamad Rabab, M. Z., 2002: *Development of Terrain Analysis Database Using Military Geographic Information System*, Universiti Putra Malaysia, Serdang.
105. Mohtashami, S., Bergkvist, I., Löfgren, B., Berg, S., 2012: A GIS Approach to Analyzing Off-Road Transportation: a Case Study in Sweden, *Croatian journal of forest engineering* 33 (2), 275–284.
106. Murphy, N. R., Randolph, D. D., 1994: *A Limited NRMM Validation Study for ISTVS*, US Army Corps of Engineers, Vicksburg.
107. NCAR (National Center for Atmospheric Research), 2007: *A Comparison of Road Temperature Models : FASST, METRo, and SNTHERM*, Research Applications Laboratory, Boulder.
108. Pahernik, M., Tuta, J., Kovačević, D., 2006: Determination of Terrain Serviceability of Military Vehicles by GIS Relief Analysis, *Promet - Traffic&Transportation* 18 (6), 387–394.
109. Pahernik, M., Tuta, J., 2010: Soil cone index as parameter of military off-road vehicles mobility, *Traffic Engieneering*, 30 (1–2), 142–147.
110. Pearson, A. R., Wright, S. J., 1980: *Synthesis guide for cross-country movement*, U.S. Army Corps of Engineers, Fort Belvoir.
111. Pike, R. J.,1995: *Geomorphometry - progress, practice, and prospect, Zeitschrift fur Geomorphologie*, Suppl., 101, 221–238.
112. Pimpa, W., 2012: *Terrain analysis for path finding of combat cross-country movement*, Suranaree University of Technology, Nakhon Ratchasima.
113. Pimpa, W., Sarapirome, S., Dasananda, S., 2014: GIS application to development of military cross-country movement maps at Mae Sot District, Western Thailand, *Suranaree Journal of Science and Technology* 21 (3), 215–232, DOI:10.14456/sjst.2014.16.
114. *Planning and design of roads, airfields, and heliports in the theater of operations-road design*, Field Manual FM 5-430-00-1, Headquarters, Department of the Army, Washington, D.C., 1994.
115. Pokonieczny, K., Rybansky, M., 2018: Method of developing the maps of passability for unmanned ground vehicles, *IOP Conference Series: Earth and Environmental Science*, 169 (1), 012027, DOI: 10.1088/1755-1315/169/1/012027.

116. Poršinsky, T., Sraka, M., Stankić, I., 2006: Comparison of two approaches to soil strength classifications, *Croatian Journal of Forest Engineering* 27, 17–26.
117. Prato, C. G., 2009: Route choice modeling: Past, present and future research directions, *Journal of Choice Modelling* 2 (1), 65–100, DOI:10.1016/S1755-5345(13)70005-8.
118. Priddy, J. D., 1995: *Stochastic Vehicle Mobility Forecasts Using the NATO Reference Mobility Model*, Waterways Experiment Station, Technical Report GL-95-8, Vicksburg.
119. *Production of Cross-Country Movement Studies*, Engineer Intelligence Guide 31, Chief of Engineers, Department of the Army, Washington D.C., 1959.
120. Richmond, P. W., Mason, G. L., Coutermarsh, B. A., Pusey, J., Moore, V. D., 2009: *Mobility Performance Algorithms for Small Unmanned Ground*, ERDC TR-09-6, Vicksburg.
121. Rybansky, M., 2003: Effect of the Geographic Factors on the Cross Country Movement, in: *Proceedings of the 21st International Cartographic Conference (ICC) 'Cartographic Renaissance'*, The International Cartographic Association (ICA), Durban, 2449–2454.
122. Rybansky, M., 2009: *Cross-country movement the impact and evaluation of geographic factors*, University of defence in Brno, Brno.
123. Rybansky, M., 2014: Modelling of the optimal vehicle route in terrain in emergency situations using GIS data, *IOP Conference Series: Earth and Environmental Science* 18, 1–6, DOI:10.1088/1755-1315/18/1/012131.
124. Rybansky, M., 2020: Determination the ability of military vehicles to override vegetation, *Journal of* Terramechanics, 91, 129–138, DOI: 10.1016/j.jterra.2020.06.004.
125. Rybansky, M., Dohnal, F., Rada, J., 2020: The Impact of Microrelief Forms on Mobility of Terrain Vehicles, *IOP Conf. Ser.: Earth Environmental Science*, DOI: 10.1088/1755-1315/540/1/012083.
126. Rybansky, M., Hofmann, A., Hubacek, M., Kovarik, V., Talhofer, V., 2015: Modelling of cross-country transport in raster format, *Environmental Earth Sciences* 74 (10), 7049–7058, DOI:10.1007/s12665-015-4759-y.
127. Saarilahti, M., 2002: *Soil interaction model*, Development of a protocol for ecoefficient wood harvesting on sensitive sites (ECOWOOD), Helsinki.
128. Sadiya, T. B., Eta, J., Oladiti, I., James, G., Shaba, H. A., Mamfe, V., Muhammad, S.O., Xu, M., Sha, J., Sanusu, M., 2017: Military Terrain Trafficability Analysis for North-East Nigeria: A GIS and Remote Sensing-Based Approach, *IOSR Journal of Mobile Computing & Application* 4 (1), 34–46, DOI:10.9790/0050-04013446.
129. Schmid, I. C., 1995: Interaction of vehicle and terrain results from 10 years research at

IKK, *Journal of Terramechanics* 32 (1), 3–26, DOI: 10.1016/0022-4898(95)00005-L.

130. Schreier, H., Lavkulich, L. M., 1978: A Numerical Terrain Classification Scheme for Off-Road Terrain Trafficability Assessments, *Geoforum* 9, 225–234.
131. Senatore, C., 2010: *Prediction of mobility, handling, and tractive efficiency of wheeled off-road vehicles*, Virginia Polytechnic Institute and State University, Blacksburg.
132. Shoop, S. A., 1993: *Terrain Characterization for Trafficability*, US Army Corps of Engineers, Hanover.
133. Shoop, S. A., Affleck, R., Collins, C., Larsen, G., Barna, L., Sullivan, P., 2005: Maneuver analysis methodology to predict vehicle impacts on training lands, *Journal of Terramechanics* 42 (3–4), 281–303, DOI:10.1016/j.jterra.2004.10.012.
134. Shoop, S. A., Richmond, P. W., Lacombe, J., 2006: Overview of cold regions mobility modeling at CRREL, *Journal of Terramechanics* 43 (1), 1–26, DOI:10.1016/j.jterra.2004.08.004.
135. Slocum, K., Surdu, J. R., Sullivan, J., Rudak, M., Colvin, N., Gates, C., 2003: Trafficability Analysis Engine, *CROSSTALK The Journal of Defense Software Engineering* (June), 28–30.
136. Smith, M. H., Meyer, M. P., 1973: *Automation of a model for predicting soil moisture and soil strenght (SMSP model)*, Army Engineer Waterways Experiment Station, Vicksburg.
137. Soil Science Division Staff, 2017: *Soil Survey Manual*, United States Department of Agriculture, DOI: 10.1097/00010694-195112000-00022.
138. Soil Survey Staff, 1951: *Soil Survey Manual*, U.S. Deptepartment of Agriculture Handbook 18, Government Printing Office, Washington D.C.
139. Sousa, J., Kaymak, U., 2002: *Fuzzy decision making in modeling and control*, World Scientific, New Jersey • London • Singapore • Hong Kong.
140. Stahl, C. W., 2005: *Accumulated Surfaces & Least-Cost Paths: GIS Modeling for Autonomous Ground Vehicle (AGV) Navigation*, Virginia Polytechnic Institute and State University, Blacksburg.
141. Stevens, M. T., McKinley, G. B., Vahedifard, F., 2016: A comparison of ground vehicle mobility analysis based on soil moisture time series datasets from WindSat, LIS, and in situ sensors, *Journal of Terramechanics*, 65 (December), 49–59, DOI: 10.1016/j.jterra.2016.02.002.

142. Stevens, M. T., Towne, B. W., Mason, G. L., Priddy, J. D., Osorio, J. E., Barela, C. A., 2013: *Procedures for One-Pass Vehicle Cone Index (VCI 1) Determination for Acquisition Support*, ERDC, Vicksburg.
143. Sullivan, P.M., C.D. Bullock, N.A. Renfroe, M.R. Albert, G.G. Koenig, L. Peck, O'Neill, K., 1997: *Soil Moisture Strength Prediction Model Version II (SMSP II)*, U.S. Army Corps of Engineers Waterways Experiment Station, Technical Report GL-97-15.
144. Suvinen, A., 2006: A GIS-based simulation model for terrain tractability, *Journal of Terramechanics* 43 (4), 427–449, DOI:10.1016/j.jterra.2005.05.002.
145. Suvinen, A., Saarilahti, M., 2006: Measuring the mobility parameters of forwarders using GPS and CAN bus techniques, *Journal of Terramechanics* 43 (2), 237–252, DOI:10.1016/j.jterra.2005.12.005.
146. Suvinen, A., Saarilahti, M., Tokola, T., 2003: Terrain mobility model and determination of optimal off-road route, u: *The 9th Scandinavian Research Conference on Geographical Information Science* (ur. Virrantaus, K., Tveite, H.), Helsinki University of Technology, Espoo, 251–259.
147. Šparica, M., Buzaljko, R., Pavelić, D., 1986b: *Osnovna geološka karta SFRJ 1:100 000, Tumač za list Slavonski Brod L 34–97*, „Geoinženjering" OOUR institut za geologiju Sarajevo (1986.), Savezni geološki zavod, Beograd.
148. Talhofer, V., Hofmann, A., Kratochvil, V., Hubacek, M., Zerzan, P., 2015: Verification of Digital Analytical Models: Case Study of the Cross-Country Movement, in: *ICMT 2015 - International Conference on Military Technologies 2015* (eds. Krivanek V.), Faculty of Military Technology, Brno, 1–7, DOI:10.1109/MILTECHS.2015.7153664.
149. Tarapata, Z., 2003: Military route planning in battlefield simulation: effectiveness problems and potential solutions, *Journal of Telecommunications and Information Technology* 4, 47-56.
150. *Terrain Analysis*, Field Manual FM 5-33, Headquaters, Department of the Army, Washington D.C., 1990.
151. Terzaghi, K., 1943: *Theoretical soil mechanics*, Géotechnique, John Wiley & Sons, Inc, New York, London, DOI: 10.1680/geot.1964.14.1.1.
152. Vega-Nieva, D. J., Murphy, P. N. C., Castonguay, M., Ogilvie, J., Arp, P. A., 2009: A modular terrain model for daily variations in machine-specific forest soil trafficability, *Canadian Journal of Soil Science* 89 (March 2008), 93–109, DOI: 10.4141/CJSS06033.
153. Vahedifard, F., Stevens, M. T., McKinley, G. B., 2017: Full-featured ground vehicle mobility analysis using different soil moisture sources, *International Journal of Vehicle*

Performance, 3 (1), 19-35, DOI: 10.1504/IJVP.2017.10002319.

154. Vidaček, Ž., 1973a: *Tla sekcije Slavonski Brod 2, u mjerilu 1:50 000 (stručni izvještaj)*, Institut za pedologiju i tehnologiju tla poljoprivrednog fakulteta sveučilišta u Zagrebu, Zagreb.
155. Vlašić, A., 2019. Stanje šuma u Slavoniji za osmanske vladavine (1526.-1691.), u: *Prema povijesti Slavonskih šuma, Prilozi za sintezu* (ur. Skenderović, R. i Župan, D.), HIP Podružnica Slavonski Brod, Slavonski Brod, 70-90.
156. Vrščaj, B., Godeša, T., 2010: Gis modeliranje prehodnosti terena za potrebe slovenske vojske, *GIS v Sloveniji* 2009–2010, 41–53.
157. Waldock, A., Corne, D., 2011: Multiple Objective Optimisation applied to Route Planning, in: *Proceedings of the 13th Annual Genetic and Evolutionary Computation Conference* (ur. Krasnogor, N.), ACM, Dublin, 1827–1834, DOI:10.1145/2001576.2001821.
158. Wawer, R., Nowocien, E., Lopatka, A., 2003: An approach to dynamic trafficability mapping as a component of battle management systems, u: *Soil trafficability – challenges for soil and vehicles* (ur. Reintam, E., Saumets, A.), Estonian National Defence College, Estonian University of Life Sciences, Tartu, 48–56.
159. Weiss, R. A., 1981: Terrain microroughness and the dynamic response of vehicles, in: *Transactions of the twenty -seventh Conference of army mathematicians*, West Point, New York, 448–535.
160. Wong, J. Y., 1991: Some recent developments in vehicle-terrain interaction studies, *Journal of Terramechanics* 28 (4), 269–288, DOI: 10.1016/0022-4898(91)90009-U.
161. Wong, J. Y., 2001: *Theory of ground vehicles, Third Edition*, John Wiley & Sons INC, New York, DOI:10.1017/CBO9781107415324.004.
162. Wong, J. Y. 2009: Development of high-mobility tracked vehicles for over snow operations, *Journal of Terramechanics*, 46 (4), 141–155, DOI: 10.1016/j.jterra.2008.03.002.
163. Wynn, L. K., 1985: *Comparison of Manually Produced and Automated Cross Country Movement Maps Using Digital Image Processing Techniques*, NASA, Pasadena.
164. Xie, Y., Sha, Z., Yu, M., 2008: Remote sensing imagery in vegetation mapping: a review, *Journal of Plant Ecology*, 1 (1), 9–23, DOI: 10.1093/jpe/rtm005.
165. Zadeh, L. A., 1965: Fuzzy Sets, *Information and control* 8, 338–353.

166. Zaninović, K., Gajić-Čapka, M., Perčec Tadić, M., Vučetić, M., Milković, J., Bajić, A., Cindrić, K., Cvitan, L., Katušin, Z., Kaučić, D., Likso, T., Lončar, E., Lončar, Ž., Mihajlović, D., Pandžić, K., Patarčić, M., Srnec, LVučetić, V., 2008: *Klimatski atlas Hrvatske / Climate atlas of Croatia 1961-1990., 1971-2000.*, Zagreb, Državni hidrometeorološki zavod, (http://klima.hr/razno/publikacije/klimatski_atlas_hrvatske.pdf) (14.7.2020.).
167. Zhu, A. X., Hudson, B., Burt, J., Lubich, K., Simonson, D., 2001: Soil Mapping Using GIS, Expert Knowledge, and Fuzzy Logic, *Distribution* 65 (5), 1463–1472, DOI: 10.2136/sssaj2001.6551463x.
168. Zimmermann, H. J., 1985: *Fuzzy Set Theory -- and Its Applications*, Springer Sciecne+Buisness Media, LCC, New York.
169. Zinck, J. A., Metternicht, G., Bocco, G., Del Valle, H. F., 2016: *Geopedology. An Integration of Geomorphology and Pedology for Soil and Landscape Studies*, Springer, New York, DOI: 10.1007/978-3-319-19159-1.

Izvori

1. ASTM D2216-10: *Standard Test Methods for Laboratory Determination of Water (Moisture) Content of Soil and Rock by Mass*, ASTM International, West Conshohocken, PA, 2010.
2. ASTM D2487-06: *Standard Practice for Classification of Soils for Engineering Purposes (Unified Soil Classification System)*, ASTM International, West Conshohocken, PA, 2006. DOI: 10.1520/D2487-11.
3. ASTM D2487-17: *Standard Practice for Classification of Soils for Engineering Purposes (Unified Soil Classification System)*, ASTM International, West Conshohocken, PA, 2017.
4. ASTM D 2 573 - Standard Test Method for Field Vane Shear Test in Cohesive Soil
5. ASTM D422-63(2007)e2: *Standard Test Method for Particle-Size Analysis of Soils (Withdrawn 2016)*, ASTM International, West Conshohocken, PA, 2007.
6. ASTM D4318-17e1: *Standard Test Methods for Liquid Limit, Plastic Limit, and Plasticity Index of Soils*, ASTM International, West Conshohocken, PA, 2017.
7. Bogunović, M., 1973b: *Pedološka karta SFRJ. Vinkovci 1. 1:50000*, Projektni savjet za izradu pedološke karte SRH, Zagreb.
8. BS EN ISO 14688-2:2004, 2006: Geotechnical investigation and testing — Identification and classification of soil — Part 2: Principles for a classification, 11 str.
9. *Delta-T Devices*, https://www.delta-t.co.uk/wp-content/uploads/2016/09/ML3-1.png, (30.10.2020.).
10. *Državna geodetska uprava*, 2004: Specifikacija proizvoda Digitalni model reljefa, CRONO GIP, 1–75.
11. *Državna geodetska uprava*, 2014: Topografski informacijski sustav Republike Hrvatske - CROTIS 2.0, Zagreb.
12. *Infrared thermometer*, https://enimages.ofweek.com/Uploads/20171109/5a03b92d7c9a6.pdf (4.11.2020.).
13. Korolija, B., Jamičić, D., 1989a: *Osnovna geološka karta SFRJ 1:100 000. List Našice L 34–85*, Geološki zavod Zagreb (1988. – 1989.), Savezni geološki zavod, Beograd.
14. *Next Generation NATO Reference Mobility Model*, Development and Demonstration, https://apps.dtic.mil/sti/pdfs/AD1057275.pdf, (22.10.2020.).

15. *Penetrologger, Operating instructions,* Eijkelkamp, Giesbeek, https://www.eijkelkamp.com/download.php?file=M10615SAe_Penetrologger_887e.pdf, (12.10.2020.).
16. *Pravilnik o evidenciji uporabe poljoprivednog zemljišta*, Ministarstvo poljoprivrede, NN 54/2019 (25.9.2019.).
17. Šparica, M., Buzaljko, R., Mojićević, M., 1986a: *Osnovna geološka karta SFRJ 1:100000, List Slavonski Brod L 34–97*, „Geoinženjering“ OOUR institut za geologiju Sarajevo (1986.), Savezni geološki zavod, Beograd.
18. *Šumarski rječnik,* https://www.hrsume.hr/index.php/hr/34-sume/sume1/64-rjecnik, (3.11.2020.).
19. *Tehničke znanosti,* Glasnik akademije tehničkih znanosti Hrvatske, vol. 8 (4), Zagreb, 2001.
20. *Tenk M-84*, 1988: Opis, rukovanje, osnovno i tehničko održavanje, Knjiga 1., Savezni sekretarijat za narodnu odbranu, Tehnička uprava, Beograd.
21. *TruPulse 360R Specifications,* https://www.lasertech.com/TruPulse-360-R-Laser-Rangefinder.aspx#, (31.10.2020.).
22. *User Manual for the ML3 ThetaProbe (*ML3-UM-1.0), Eijkelkamp, 2013.
23. Vidaček, Ž., 1973b: *Pedološka karta SFRJ, Slavonski Brod 2, 1:50000*, Projektni savjet za izradu pedološke karte SRH, Zagreb.
24. *Zavod za pedologiju*, 2004: Hidropedološka karta Republike Hrvatske 1:300000, Agronomski fakultet Sveučilišta u Zagrebu, Zagreb.

PRILOG

Prilog 1. Jedinstvena klasifikacija tla USCS

Kriteriji za dodjeljivanje simbola i naziva pojedinim grupama tla na osnovi laboratorijskih ispitivanja[A]				Klasifikacija tla	
				Simbol	**Naziv grupe[B]**
KRUPNOZRNA TLA (više od 50 % ostaje na situ br. 200 – 0.075 mm)	Šljunak (više od 50 % ostalo je na situ br. 4 – 4.75 mm)	Čisti šljunak (manje od 5% sitnih čestica[E])	$c_u \geq 4$ i $1 \leq c_c \leq 3$[C]	GW	Dobro graduiran šljunak[D]
			$c_u < 4$ i/ili $1 > c_c > 3$[C]	GP	Slabo graduiran šljunak[D]
		Šljunak sa sitnim česticama (više od 12% sitnih čestica[E])	Sitne čestice se klasificiraju kao ML ili MH	GM	Prašinasti šljunak[D,F,G]
			Sitne čestice se klasificiraju kao CL ili CH	GC	Glinoviti šljunak[D,F,G]
	Pijesak (50% ili više prolazi kroz sito br. 4 – 4.75 mm)	Čisti pijesak (manje od 5% sitnih čestica[I])	$c_u \geq 6$ i $1 \leq c_c \leq 3$[C]	SW	Dobro graduiran pijesak[H]
			$c_u < 6$ i/ili $1 > c_c > 3$[C]	SP	Slabo graduiran pijesak[H]
		Pijesak sa sitnim česticama (više od 12% sitnih čestica[I])	Sitne čestice se klasificiraju kao ML ili MH	SM	Prašinasti pijesak[F,G,H]
			Sitne čestice se klasificiraju kao CL ili CH	SC	Glinoviti pijesak[F,G,H]
SITNOZRNA TLA (50 % ili više prolazi kroz sito br. 200 – 0.075 mm)	Prahovi i gline (granica tečenja manja od 50%)	Anorganski	$I_p > 7$ i na ili iznad A-linije[J]	CL	Posna glina[K,L,M]
			$I_p > 7$ i na ili iznad A-linije[J]	ML	Prah niske plastičnosti[K,L,M]
		Organski	(Granica tečenja - sušenje u peći)/ (Granica tečenja - bez sušenja u peći) < 0.75	OL	Organska glina ili prah niske plastičnosti[K,L,M,N]
					Organski prah[K,L,M,O]
	Prahovi i gline veća od	Anorganski	I_p na ili iznad A-linije	CH	Masna glina[K,L,M]
			I_p ispod A-linije	MH	Prah visoke plastičnosti [K,L,M]
		Organski	(Granica tečenja - sušenje u peći)/ (Granica tečenja - bez sušenja u peći) < 0.75	OH	Organska glina ili prah visoke plastičnosti[K,L,M,P]
					Organski prah[K,L,M,Q]
Visoko organsko tlo		Primarno organska materija, tamne boje i organskog mirisa		PT	Treset

[A] Zasnovano na materijalima koji su prošli sito 3-inča, 75 mm.

[B] Ako uzorci tla na terenu sadržavaju komade ili blokove ili oboje nazivu grupe tla treba dodati "s komadima" ili "s blokovima" ili " s komadima i blokovima".

[C] $C_u = D_{60}/D_{10}$; $c_c = (D_{30})^2/(D_{10} x D_{60})$

[D] Ako tlo sadrži ≥ 15% pijeska, nazivu grupe tla treba dodati «s pijeskom».

[E] Šljunci sa 5 do 12 % sitnih čestica dobivaju dvojne simbole:
GW-GM dobro graduirani šljunak s prahom,
GW-GC dobro graduirani šljunak s glinom,
GP-GM slabo graduirani šljunak s prahom,
GP-GC slabo graduirani šljunak s glinom.

[F] Ako se sitne čestice klasificira kao CL-ML, treba koristiti dvojne simbole GC-GM ili SC-SM.

[G] Ako su sitne čestice organske, nazivu grupe tla treba dodati "s organskim sitnim česticama".

[H] Ako tlo sadrži ≥ 15% šljunka, nazivu grupe tla treba dodati "sa šljunkom".

[I] Pijesci sa 5 do 12% sitnih čestica dobivaju dvojne simbole:
SW-SM dobro graduirani pijesak s prahom,
SW-SC dobro graduirani pijesak s glinom,
SP-SM slabo graduirani pijesak s prahom,
SP-SC slabo graduirani pijesak s glinom.

[J] Ako se par vrijednosti (w_L, I_p) u dijagramu plastičnosti nalazi unutar šrafiranog područja ($4 < I_p < 7$), tlo se označava sa CL-ML, kao prašinasta glina.

[K] Ako tlo sadrži 15 do 30% materijala iznad sita br. 200 – 0.075 mm, nazivu grupe tla treba dodati "s pijeskom" ili "sa šljunkom", ovisno o tome koji je od ta dva materijala zastupljeniji.

[L] Ako tlo sadrži ≥ 30% materijala iznad sita br. 200 – 0.075 mm i prevladava li pijesak, nazivu grupe tla treba dodati "pjeskoviti".

[M] Ako tlo sadrži ≥ 30% materijala iznad sita br. 200 – 0.075 mm i prevladava li šljunak, nazivu grupe tla treba dodati "šljunkoviti".

[N] $I_p \geq 4$ i na A-liniji ili iznad nje.

[O] $I_p < 4$ ili ispod A-linije.

[P] I_p na A-liniji ili iznad nje.

[Q] I_p ispod A-linije.

Izvor: ASTM D2487-06 (2006)

Tla se prema USCS dijele u dvije velike skupine:

- krupnozrna tla (više od 50 % čestica je ≥ 0.075 mm) i
- sitnozrna tla (više od 50 % čestica je < 0.075 mm).

Krupnozrna tla se dijele na:

- G – šljunak (engl. *gravel*) – više od 50 % čestica je ≥ 4.75 mm i
- S – pijesak (engl. *sand*) – više od 50 % čestica je < 4.75 mm.

Potom se krupnozrna tla dijele ovisno o sadržaju sitnih čestica (promjera manjeg od 0.075 mm) i karakteristikama granulometrijske krivulje (**Kumulativni graf veličine čestica, Koeficijent jednosličnosti** i **Koeficijent zakrivljenosti**) šljunka na četiri podskupine:

- GW – dobro graduirani šljunak (engl. *well-graded gravel*),
- GP – slabo graduirani šljunak (engl. *poorly graded gravel*),
- GM – prašinasti šljunak (engl. *silty gravel*) i
- GC – glinoviti šljunak (engl. *clayey gravel*).

Pijesak se također dijeli na četiri podskupine:

- SW – dobro graduirani pijesak (engl. *well-graded sand*),
- SP – slabo graduirani pijesak (engl. *poorly graded sand*),
- SM – prašinasti pijesak (engl. *silty sand*) i
- SC – glinoviti pijesak (engl. *clayey sand*).

Sitnozrna tla se dijele prema granici tečenja (W_L) i indeksu plastičnosti (I_P) na sljedeće podskupine:

- CL – glina niske plastičnosti (engl. *lean clay*),
- CH –glina visoke plastičnosti (engl. *fat clay*),
- OL – organska glina ili prah niske plastičnosti (engl. *organic clay or organic silt*),
- OH – organska glina ili prah visoke plastičnosti (engl. *organic clay or organic silt*),
- ML – prah niske plastičnosti (engl. *silt*) i
- MH – prah visoke plastičnosti (engl. *elastic silt*).

Kao posebna skupina tla izdvaja se visoko organsko tla koje nazivamo treset (oznaka Pt) koje posjeduje visoki udio organskih tvari, crne je boje i organskog mirisa.

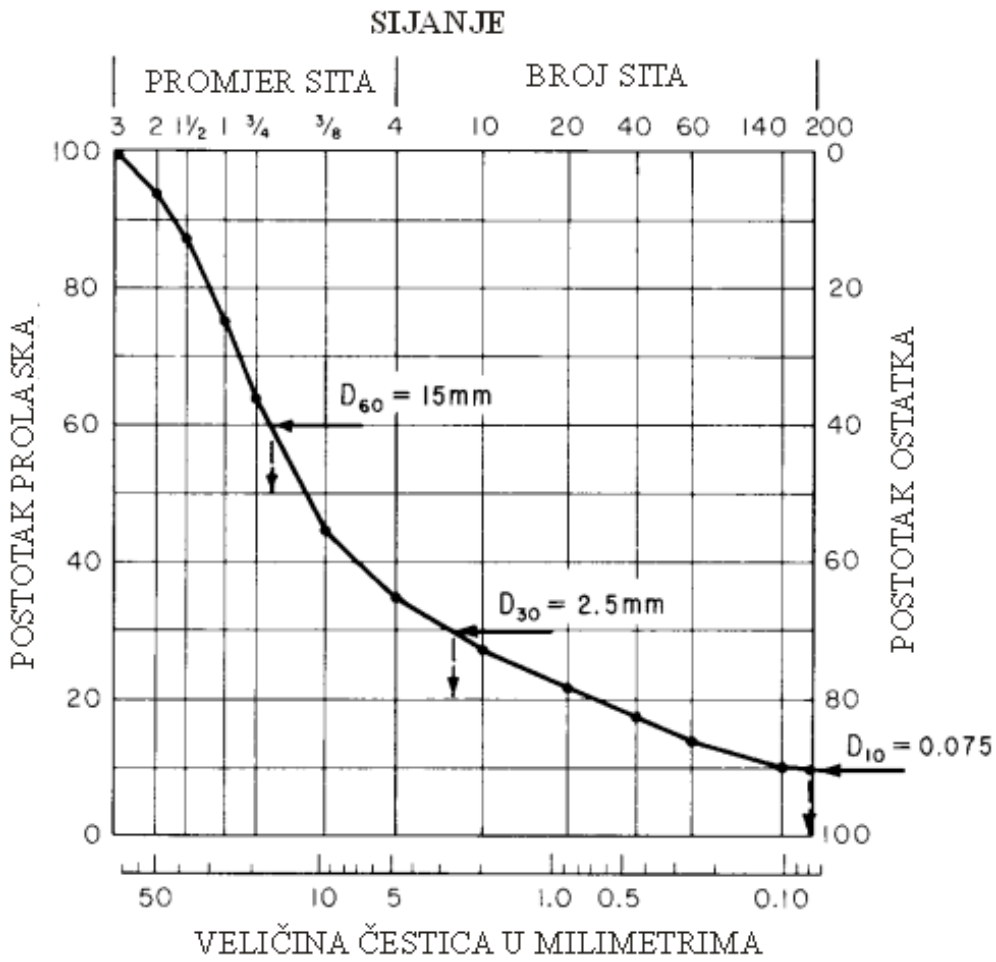

Kumulativni graf veličine čestica

Izvor: ASTM D2487-06, (2006)

Koeficijent jednosličnosti: $\mathrm{Cu} = \frac{D_{60}}{D_{10}} = \frac{15}{0.075} = 200$

Koeficijent zakrivljenosti: $\mathrm{Cc} = \frac{(D_{60})^2}{D_{10}\ x\ D_{60}} = \frac{(2.5)^2}{0.075\ x\ 15} = 5.6$

Kod klasifikacije sitnozrnih tala koristi se dijagram plastičnosti.

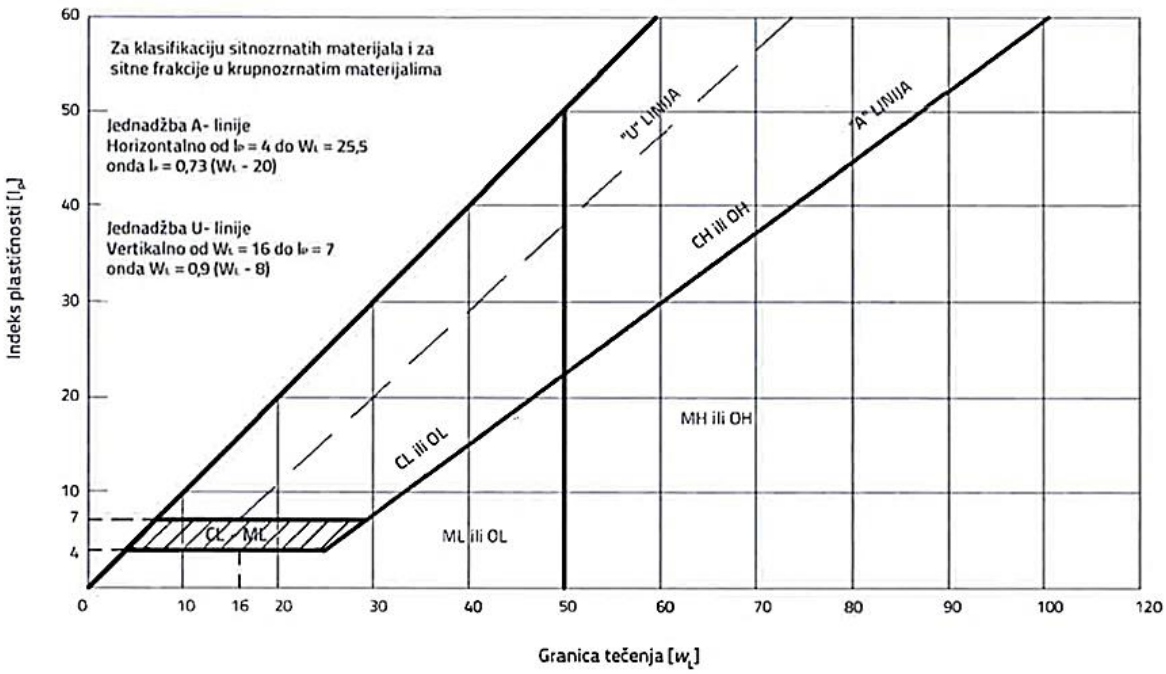

Dijagram plastičnosti

Izvor: ASTM D2487-06, (2006)

Prilog 2. Prodirne značajke tla zimi na lokacijama (vidi Sl. 38. i Sl. 39.) mjerene digitalnim konusnim penetrometrom od 25. veljače do 1. ožujka 2019. godine

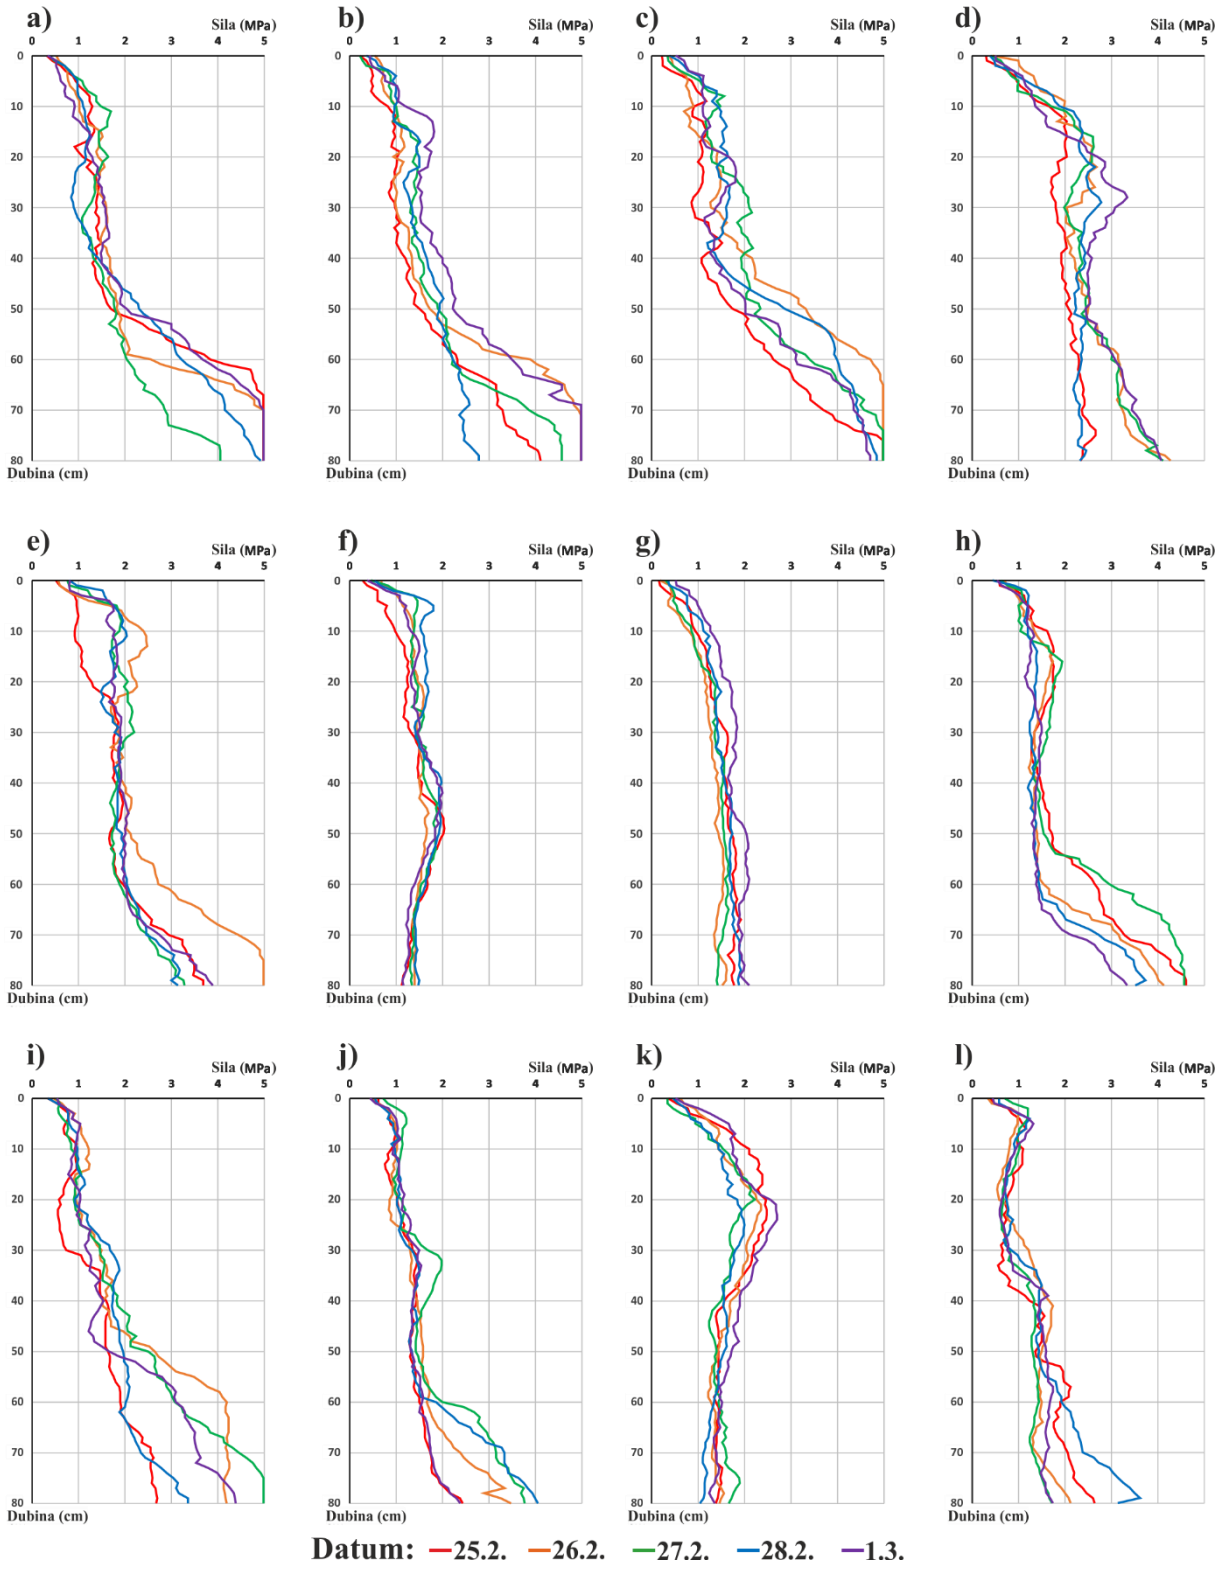

Prilog 3. Prodirne značajke tla u proljeće na lokacijama (vidi Sl. 38. i Sl. 39.) mjerene digitalnim konusnim penetrometrom od 11. do 15. ožujka 2019. godine

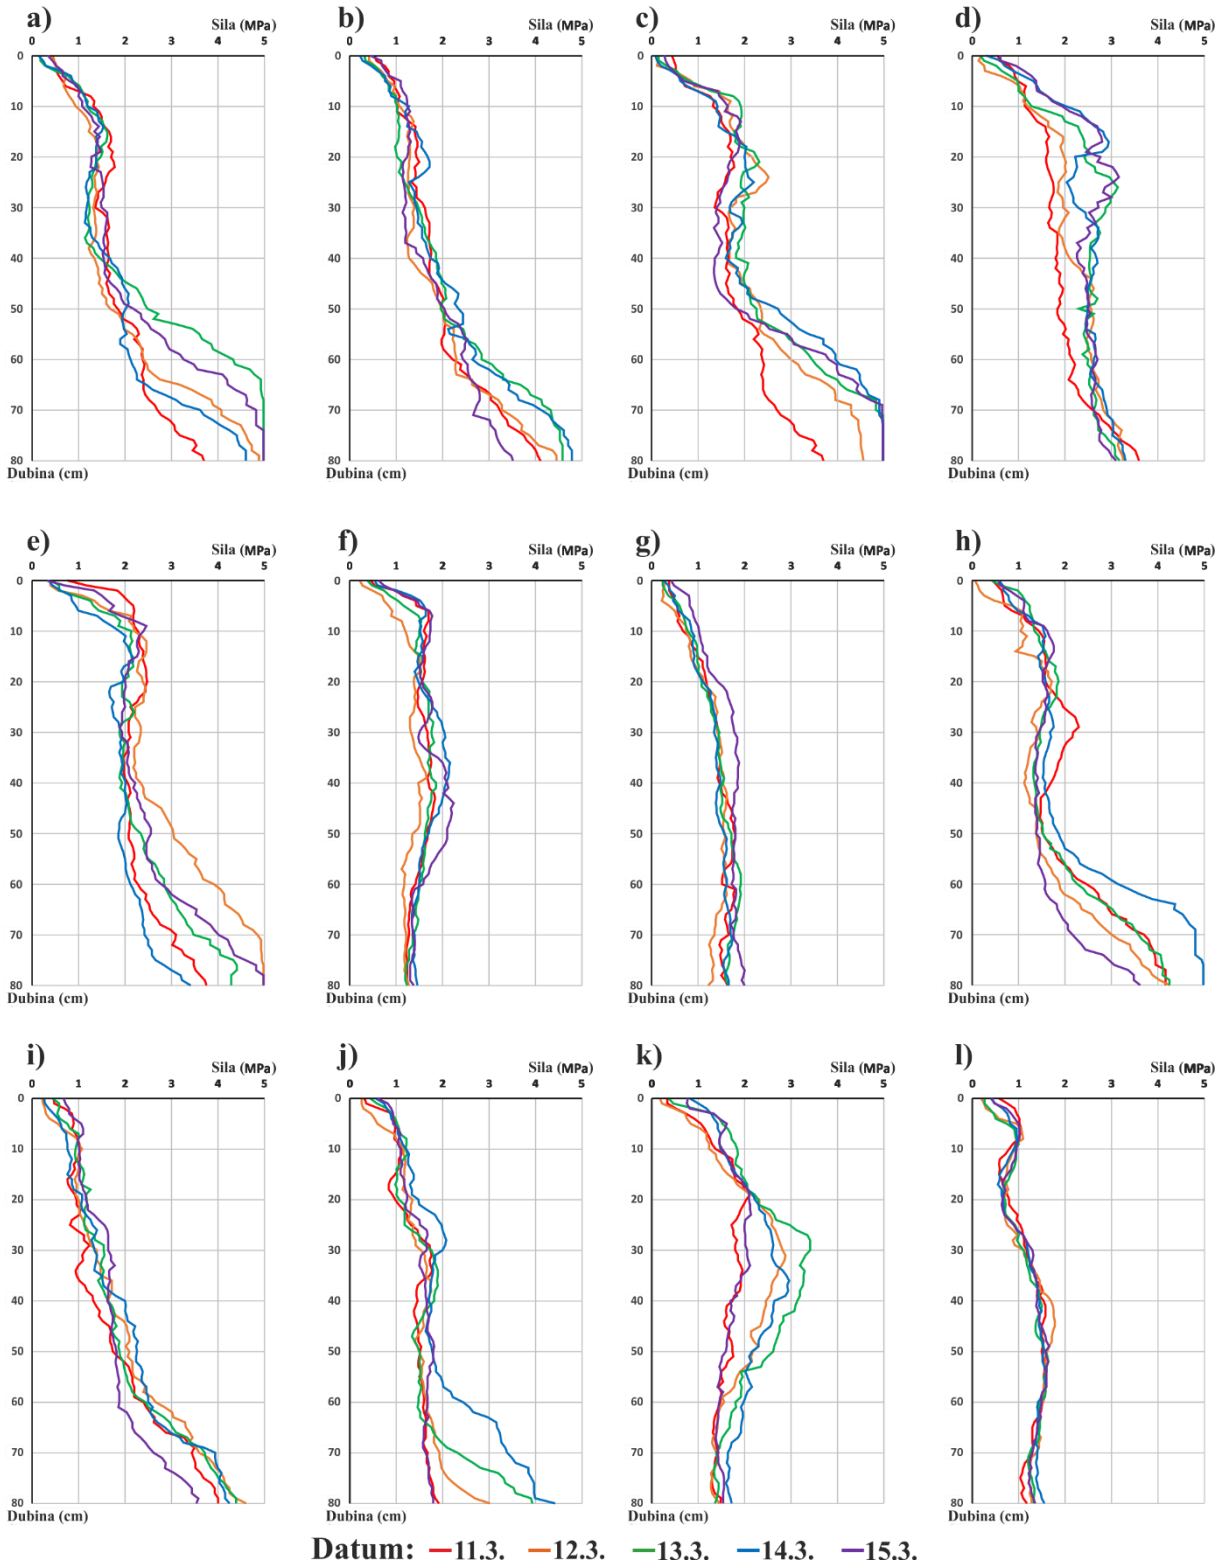

Prilog 4. Prodirne značajke tla u proljeće na lokacijama (vidi Sl. 38. i Sl. 39.) mjerene digitalnim konusnim penetrometrom od 30. travnja do 4. svibnja 2019. godine

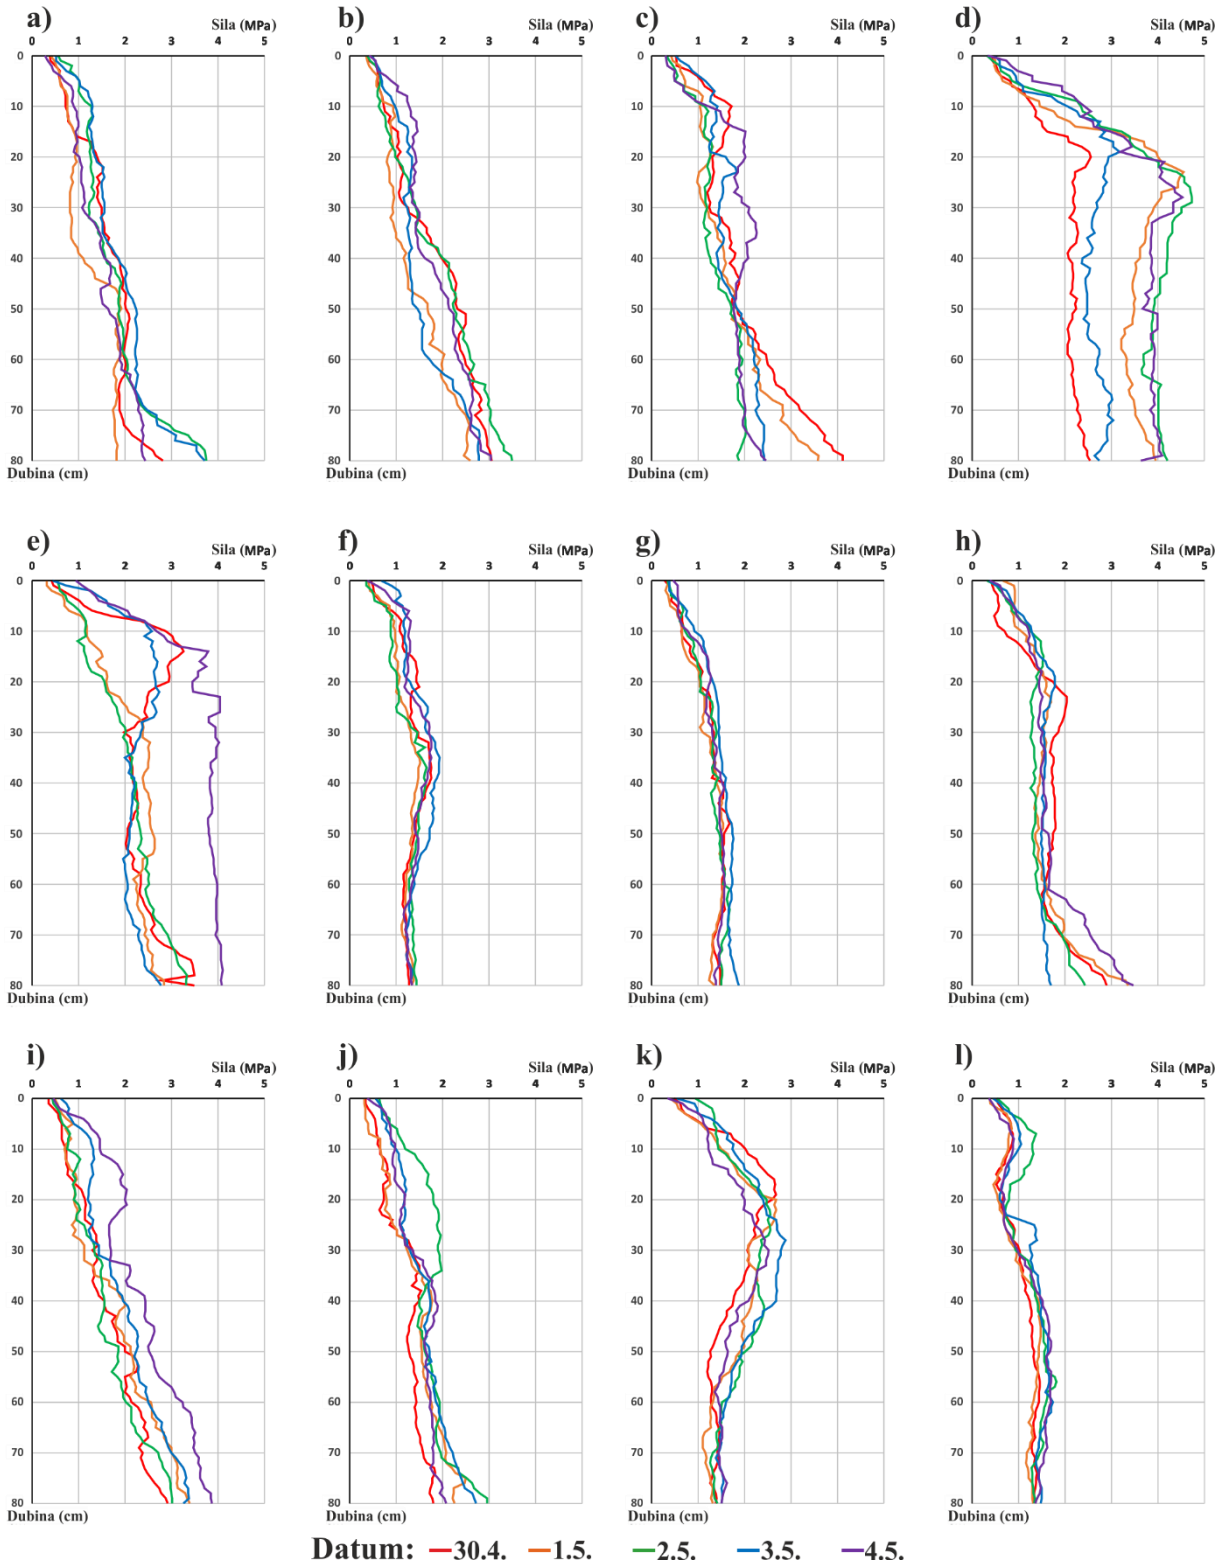

Prilog 5. Prodirne značajke tla ljeti na lokacijama (vidi Sl. 38. i Sl. 39.) mjerene digitalnim konusnim penetrometrom od 26. do 30. kolovoza 2019. godine

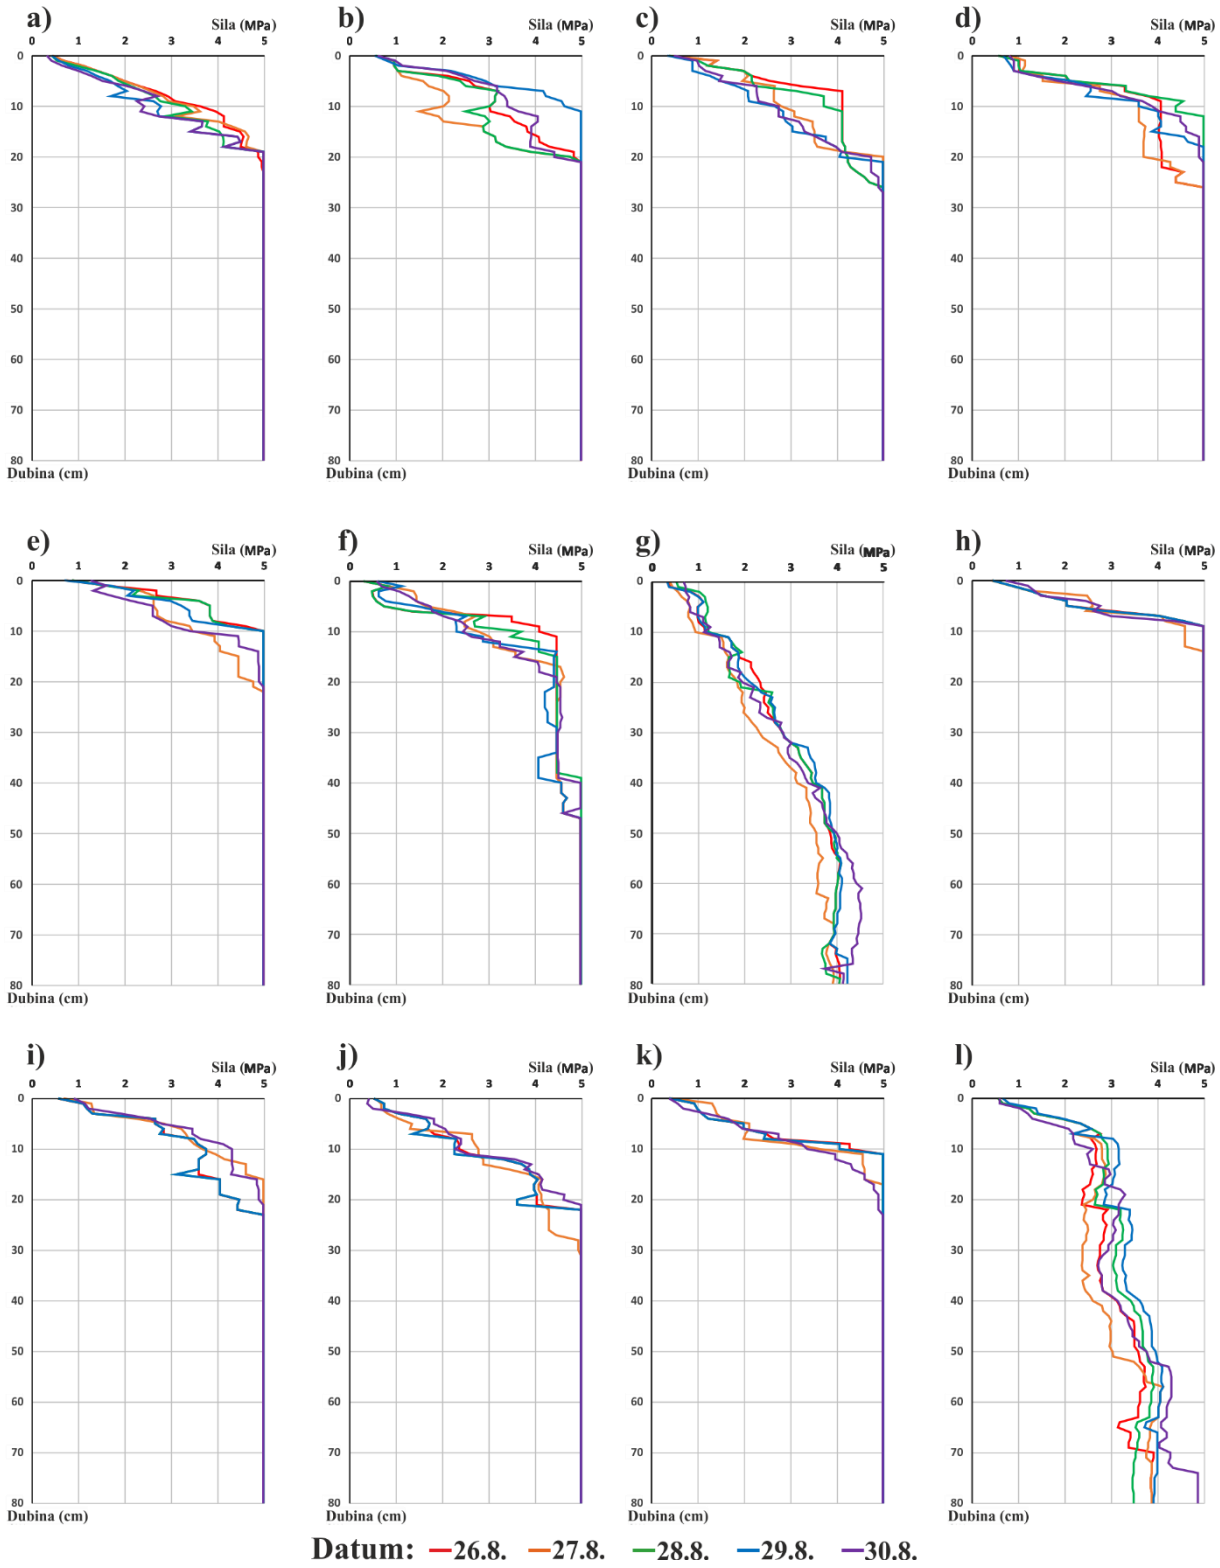

Prilog 6. Prodirne značajke tla u jesen na lokacijama (vidi Sl. 38. i Sl. 39.) mjerene digitalnim konusnim penetrometrom od 15. do 19. studenog 2019. godine

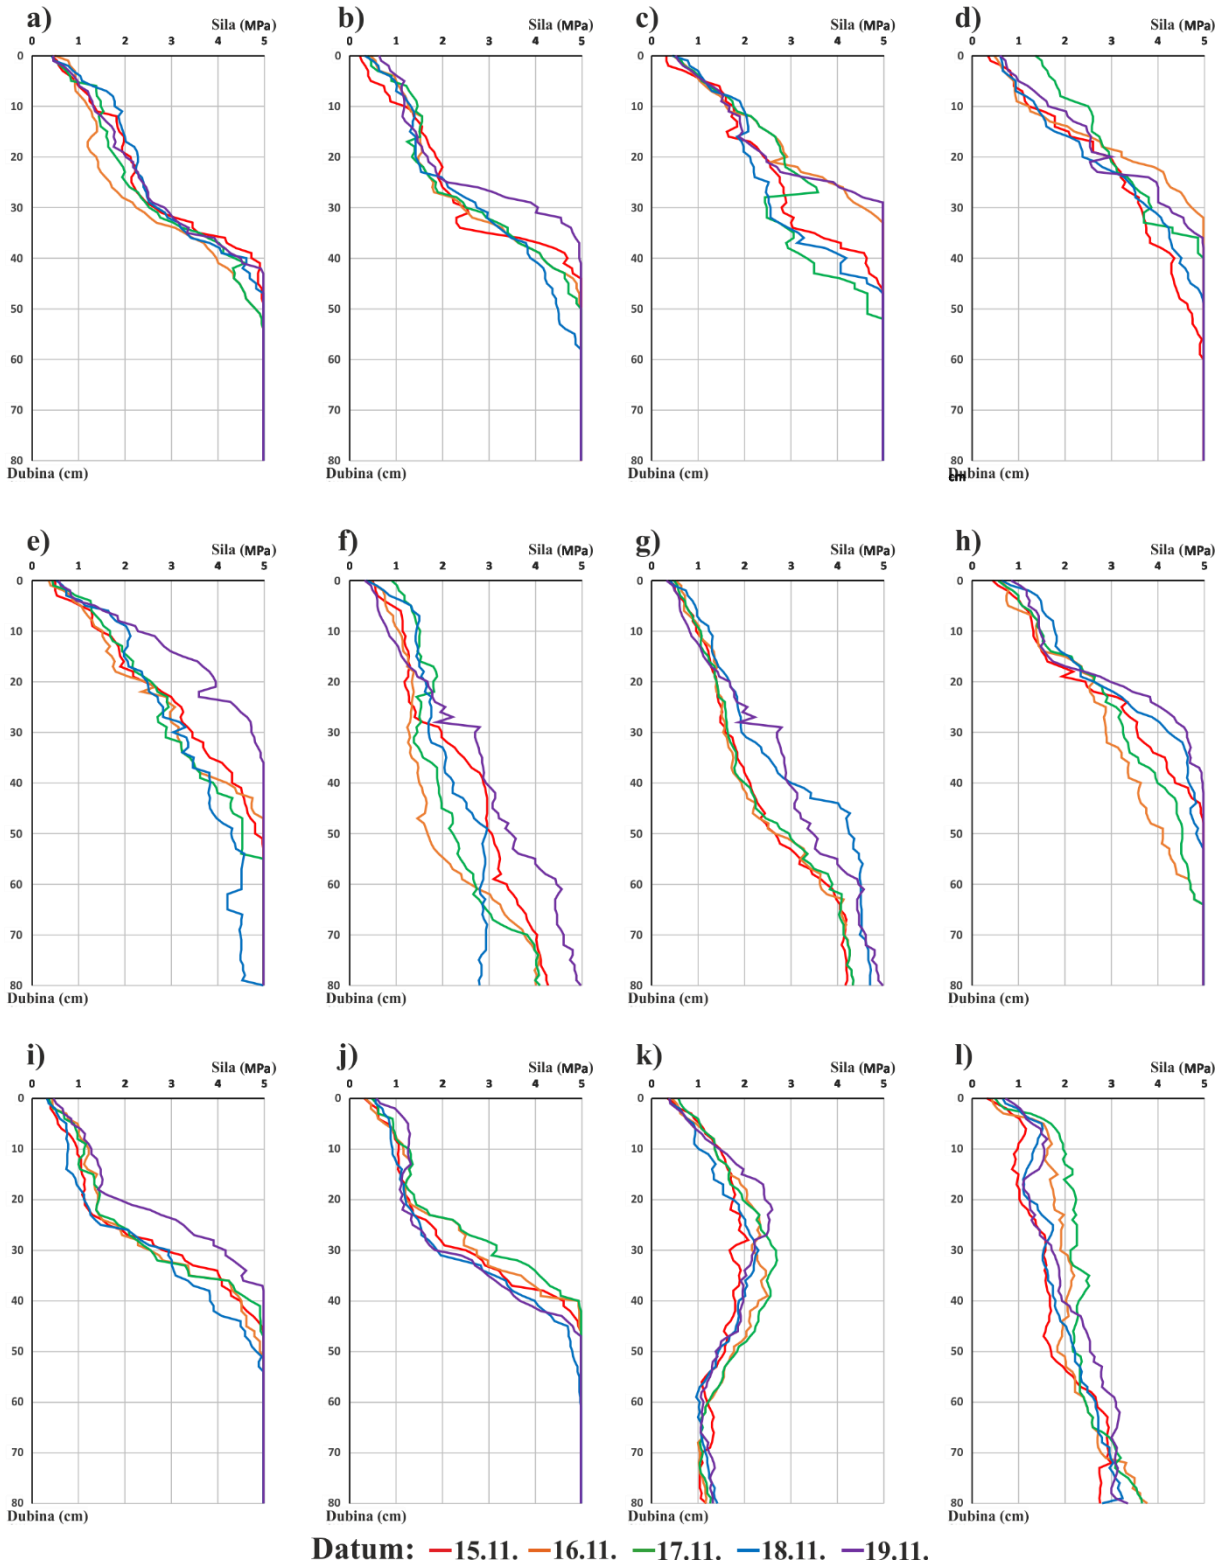

Prilog 7. Prodirne značajke tla u jesen na lokacijama (vidi Sl. 38. i Sl. 39.) mjerene digitalnim konusnim penetrometrom od 25. do 29. studenog 2019. godine

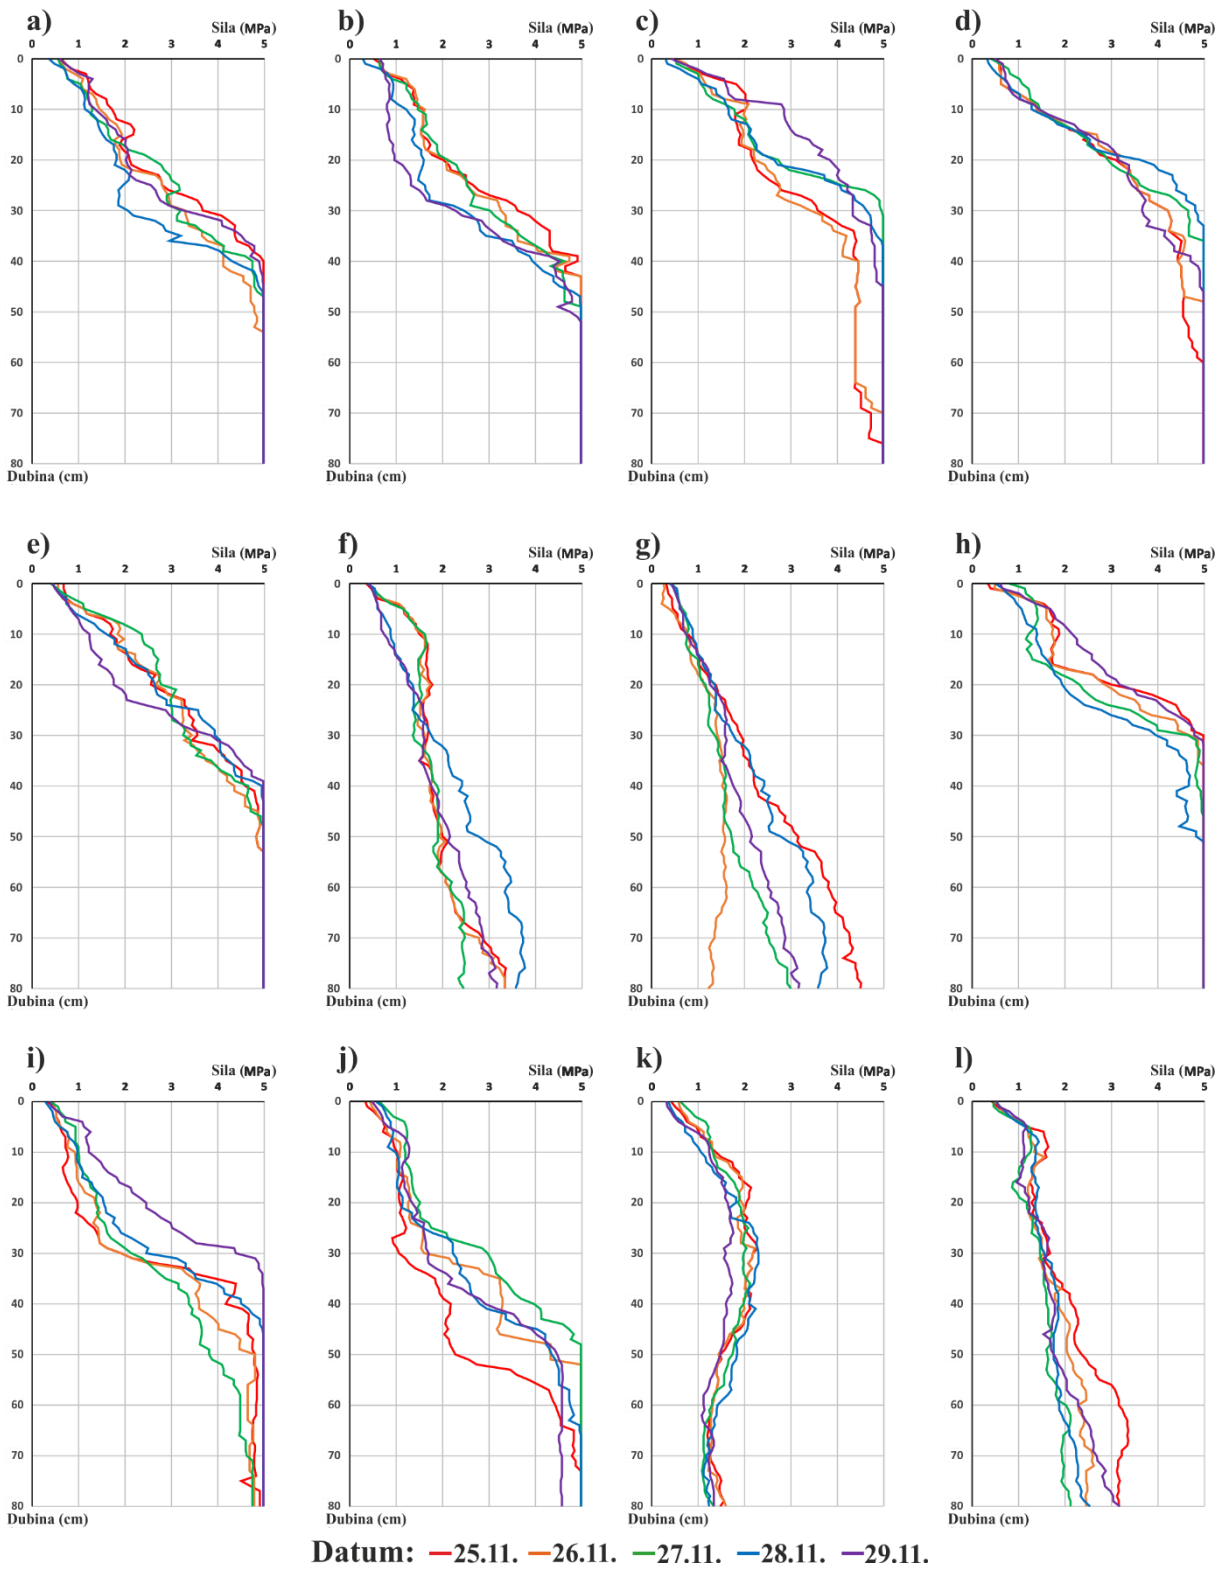

Prilog 8. Prodirne značajke tla zimi na lokacijama (vidi Sl. 38. i Sl. 39.) mjerene digitalnim konusnim penetrometrom od 16. do 20. prosinca 2019. godine

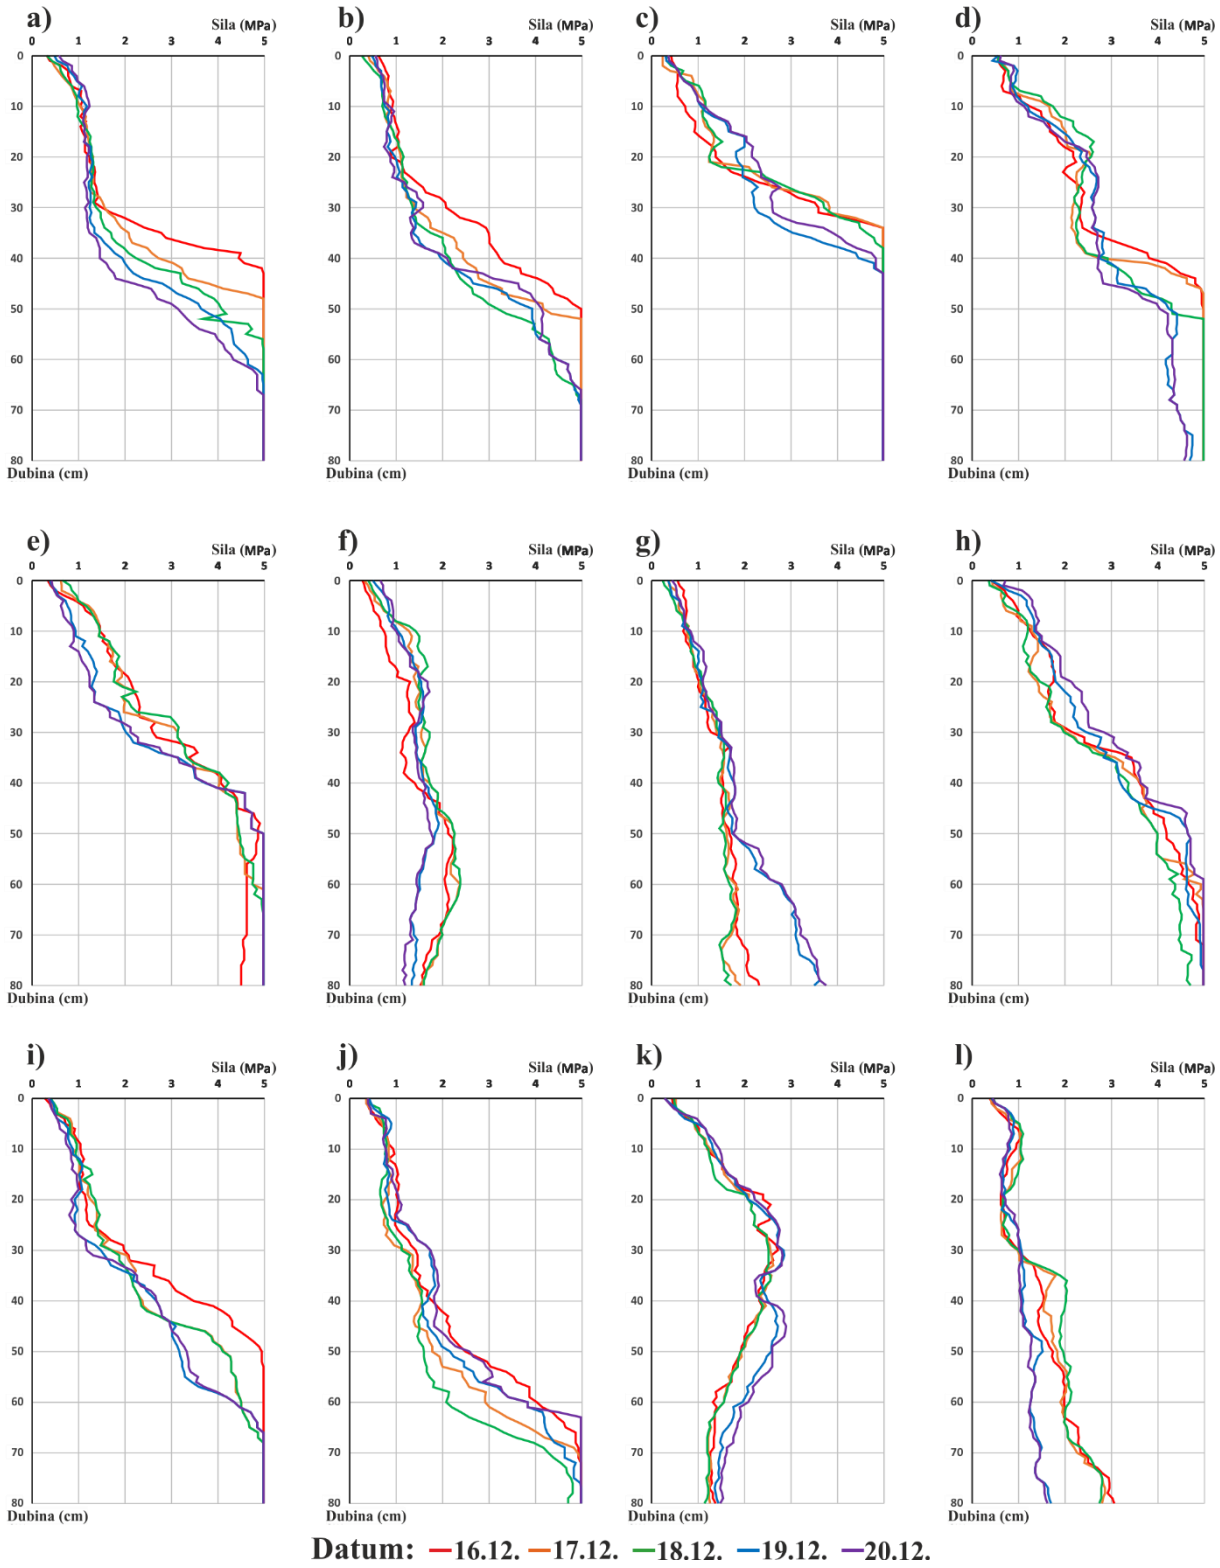

Prilog 9. Vlažnost tla zimi na lokacijama (vidi Sl. 38. i Sl. 39.) mjerena sondom ThetaProbe od 25. veljače do 1. ožujka 2019. godine

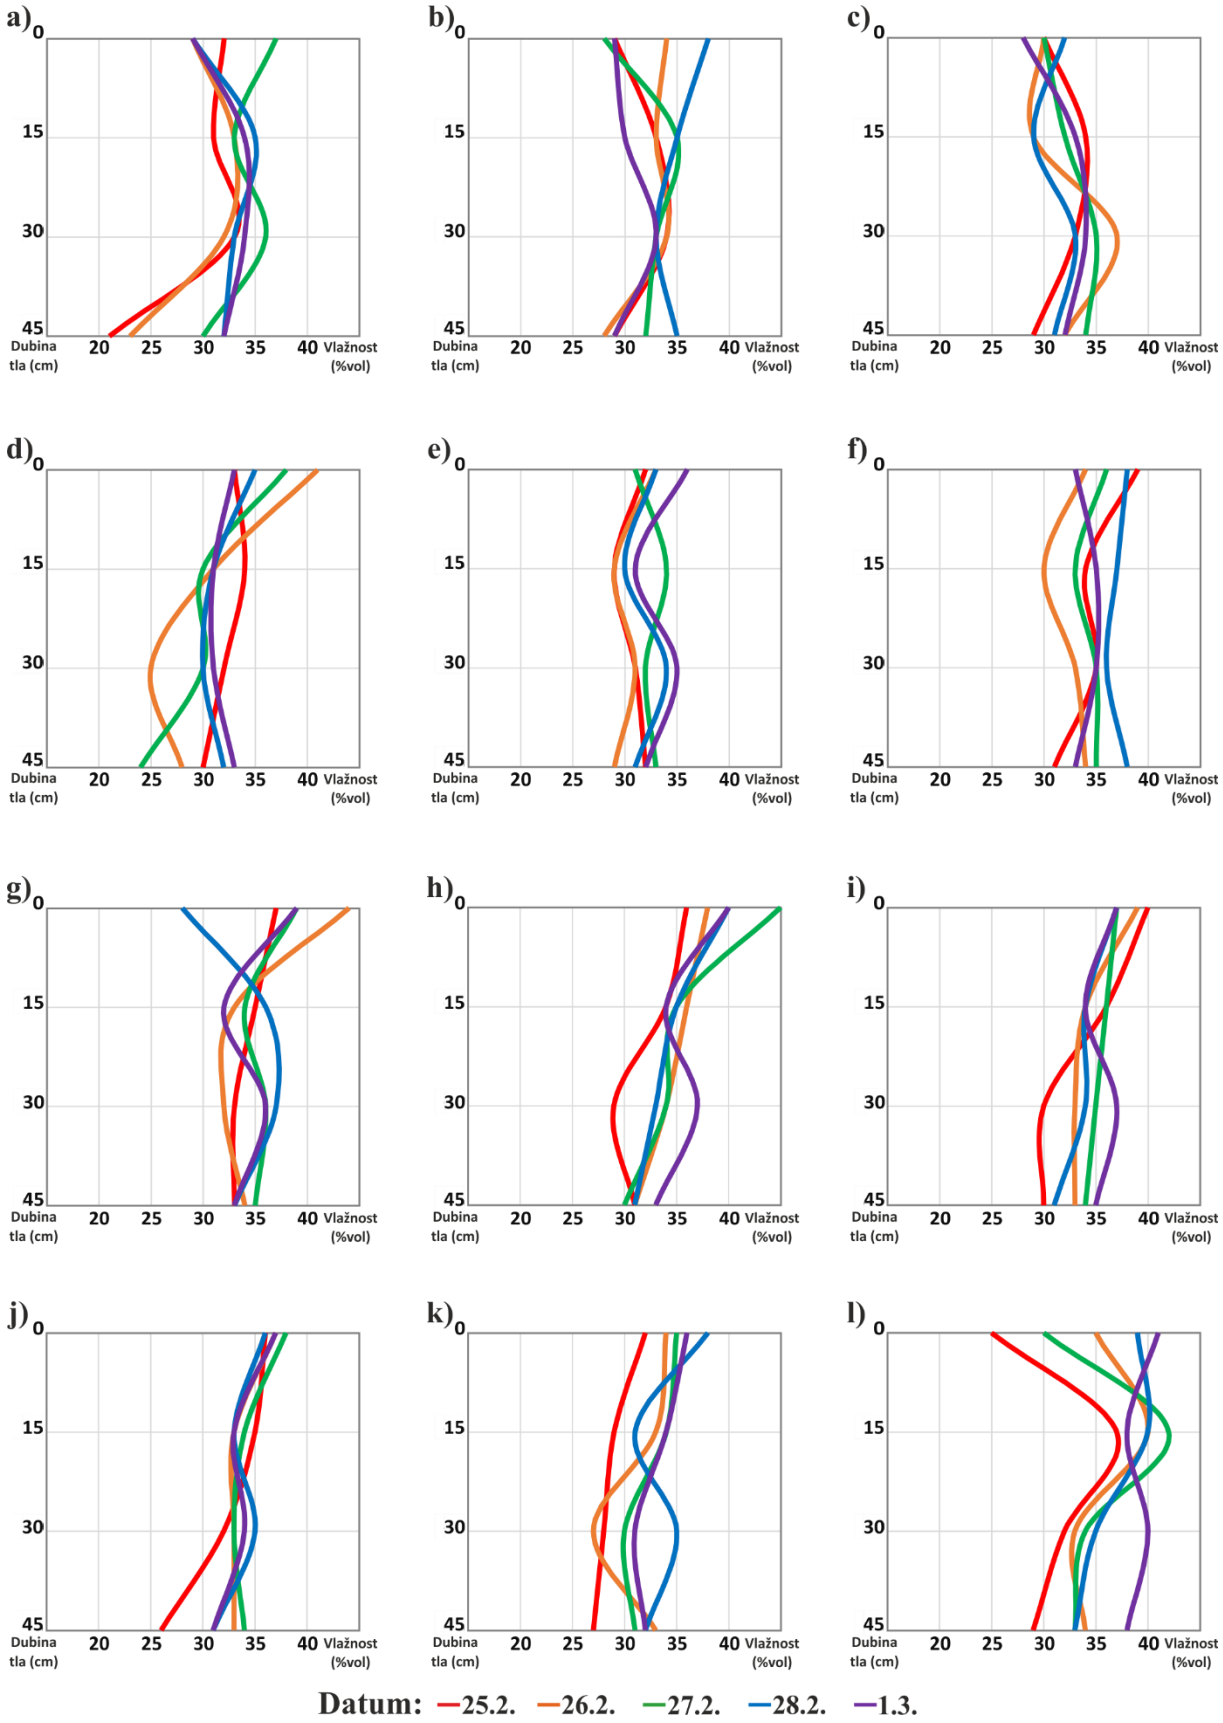

Prilog 10. Vlažnost tla u proljeće na lokacijama (vidi Sl. 38. i Sl. 39.) mjerena sondom ThetaProbe od 11. do 15. ožujka 2019. godine

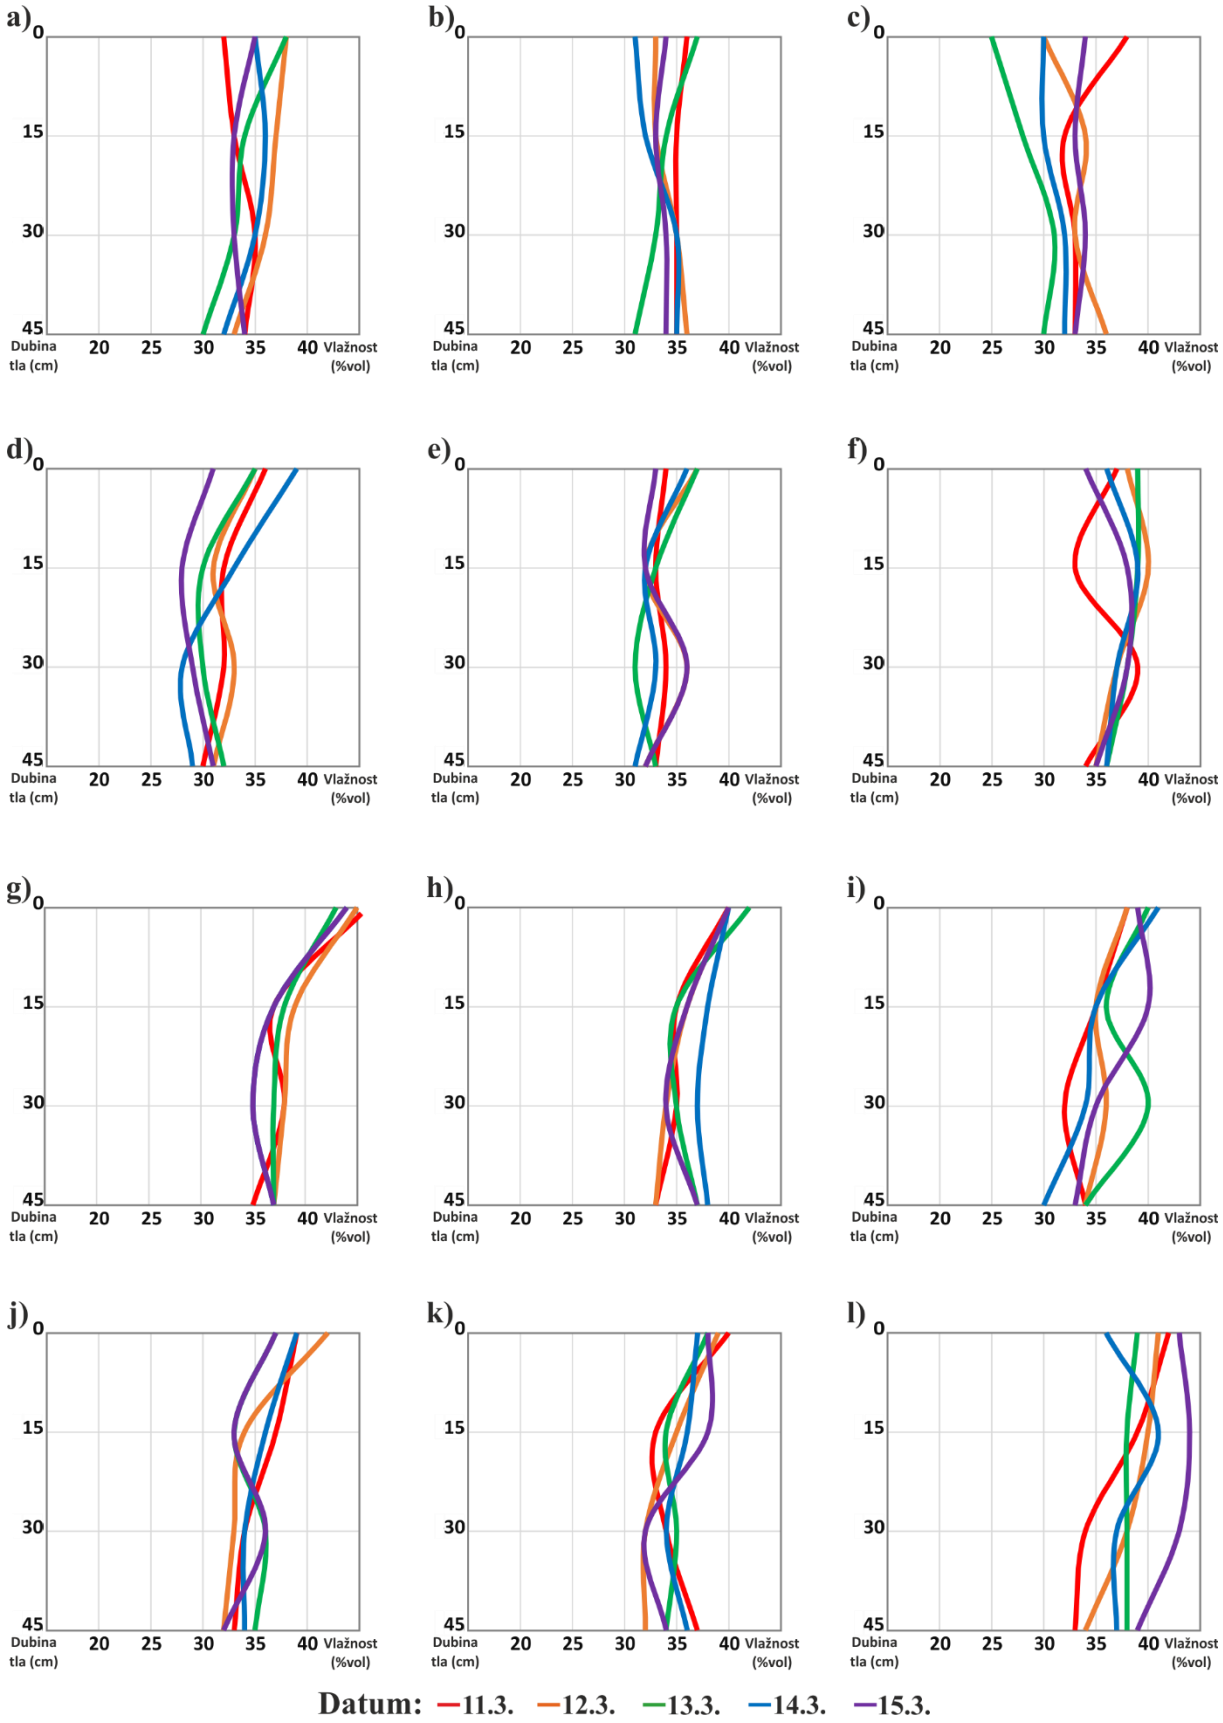

Prilog 11. Vlažnost tla u proljeće na lokacijama (vidi Sl. 38. i Sl. 39.) mjerena sondom ThetaProbe od 30. travnja do 4. svibnja 2019. godine

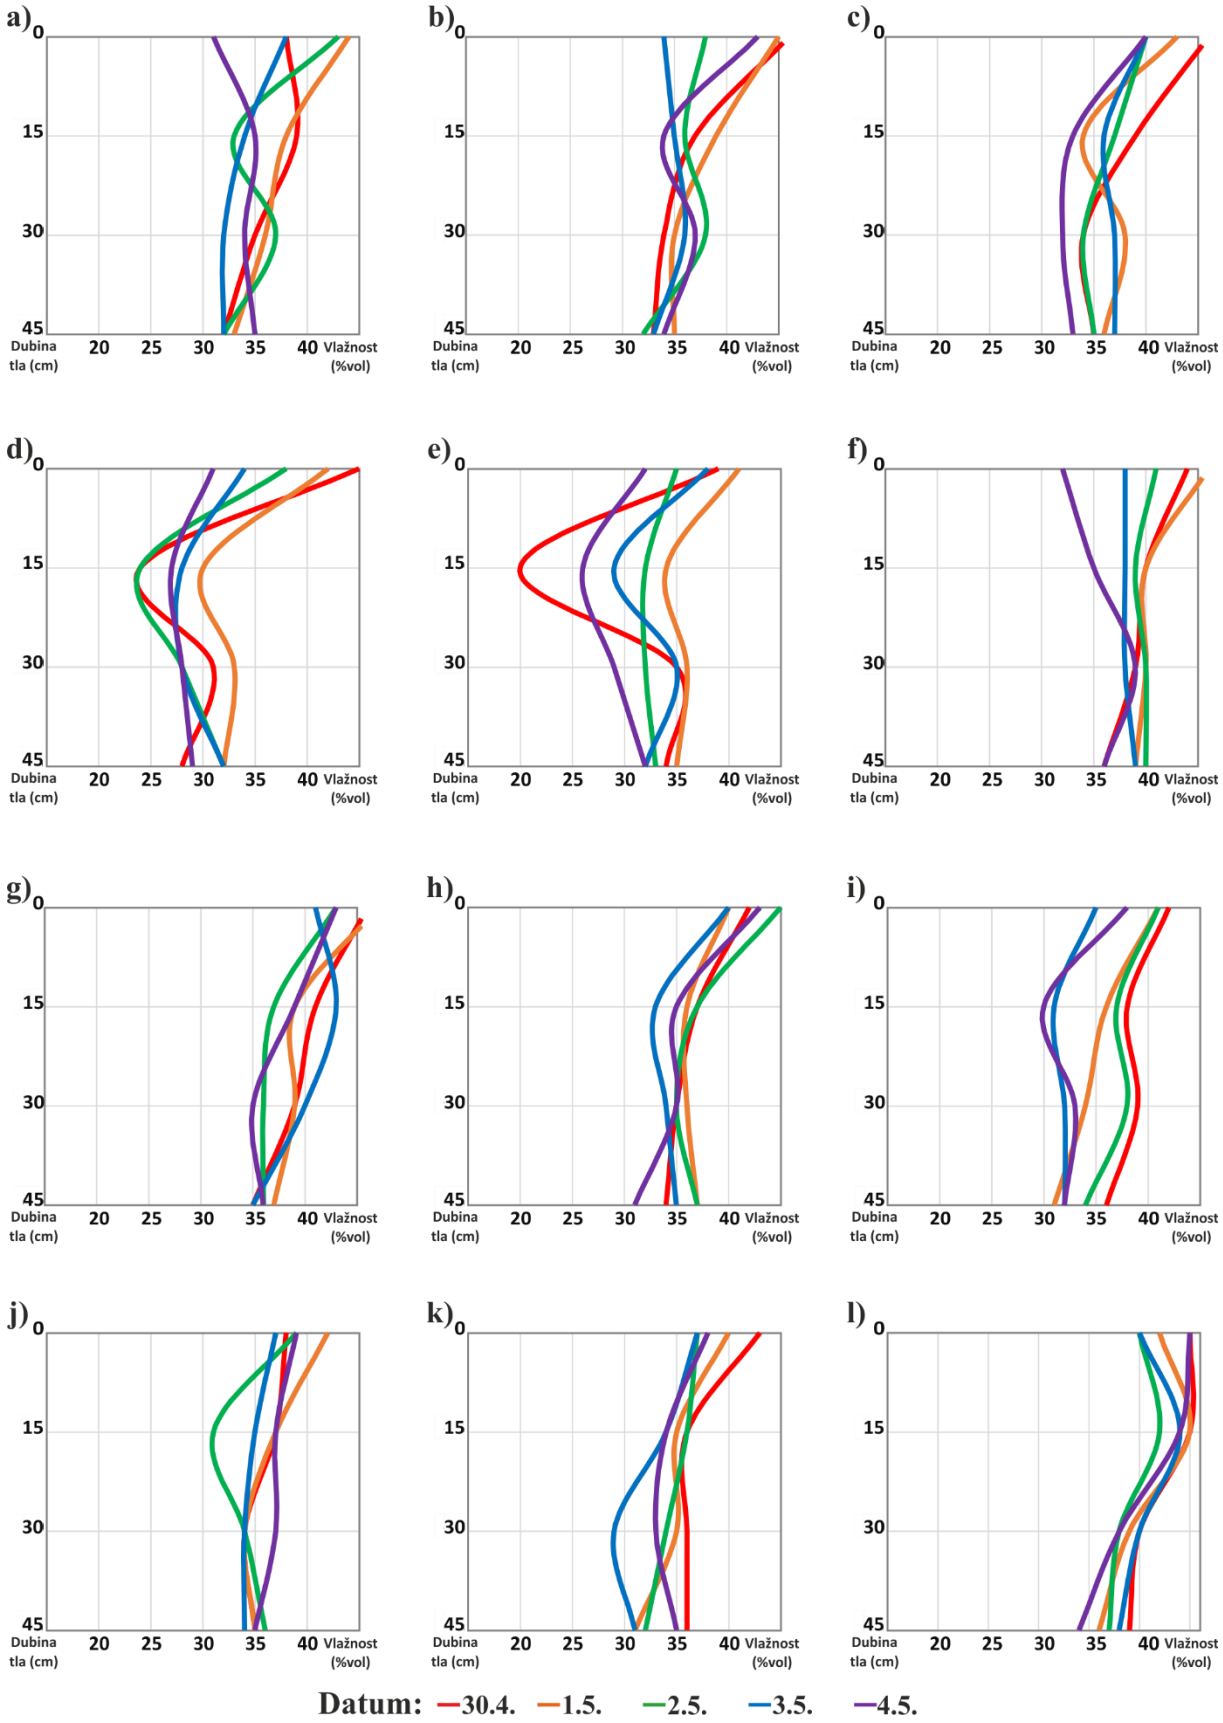

Prilog 12. Vlažnost tla ljeti na lokacijama (vidi Sl. 38. i Sl. 39.) mjerena sondom ThetaProbe od 26. do 30. kolovoza 2019. godine

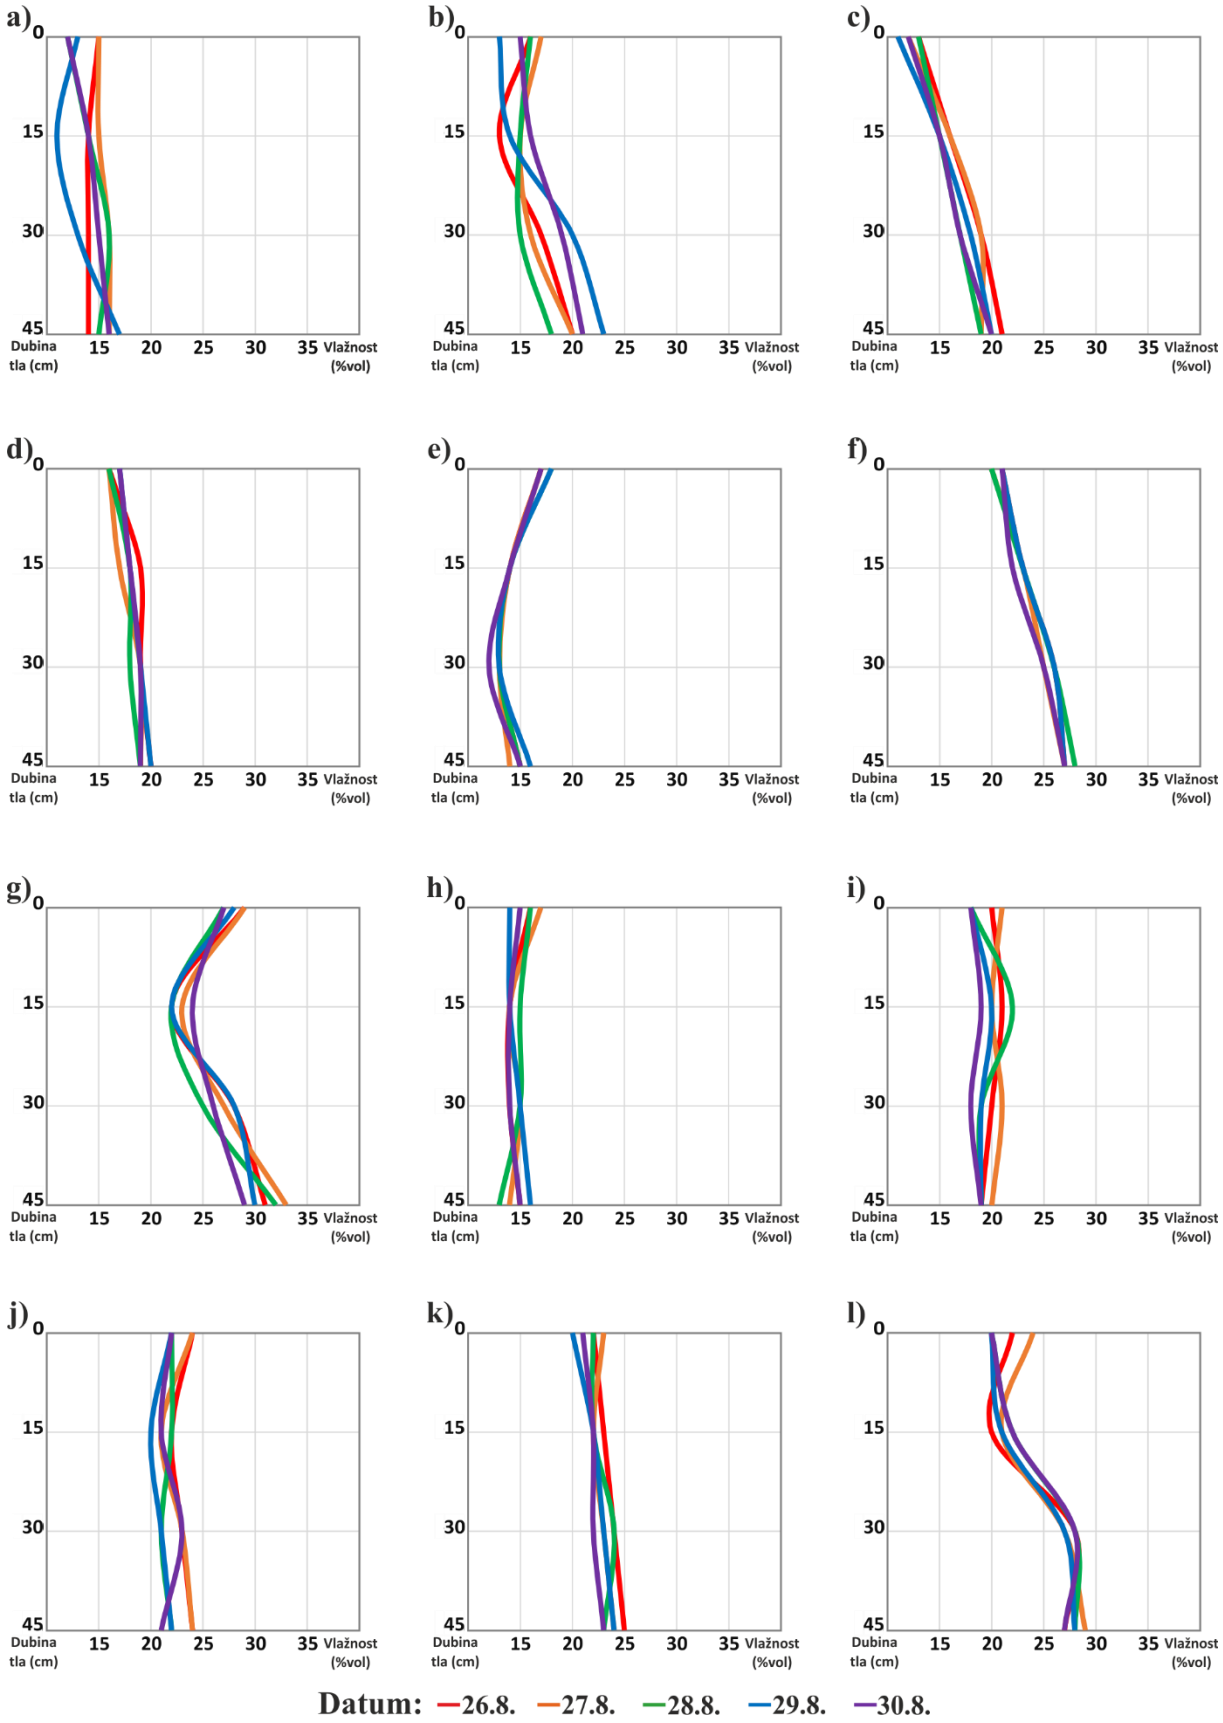

Prilog 13. Vlažnost tla u jesen na lokacijama (vidi Sl. 38. i Sl. 39.) mjerena sondom ThetaProbe od 15. do 19. studenog 2019. godine

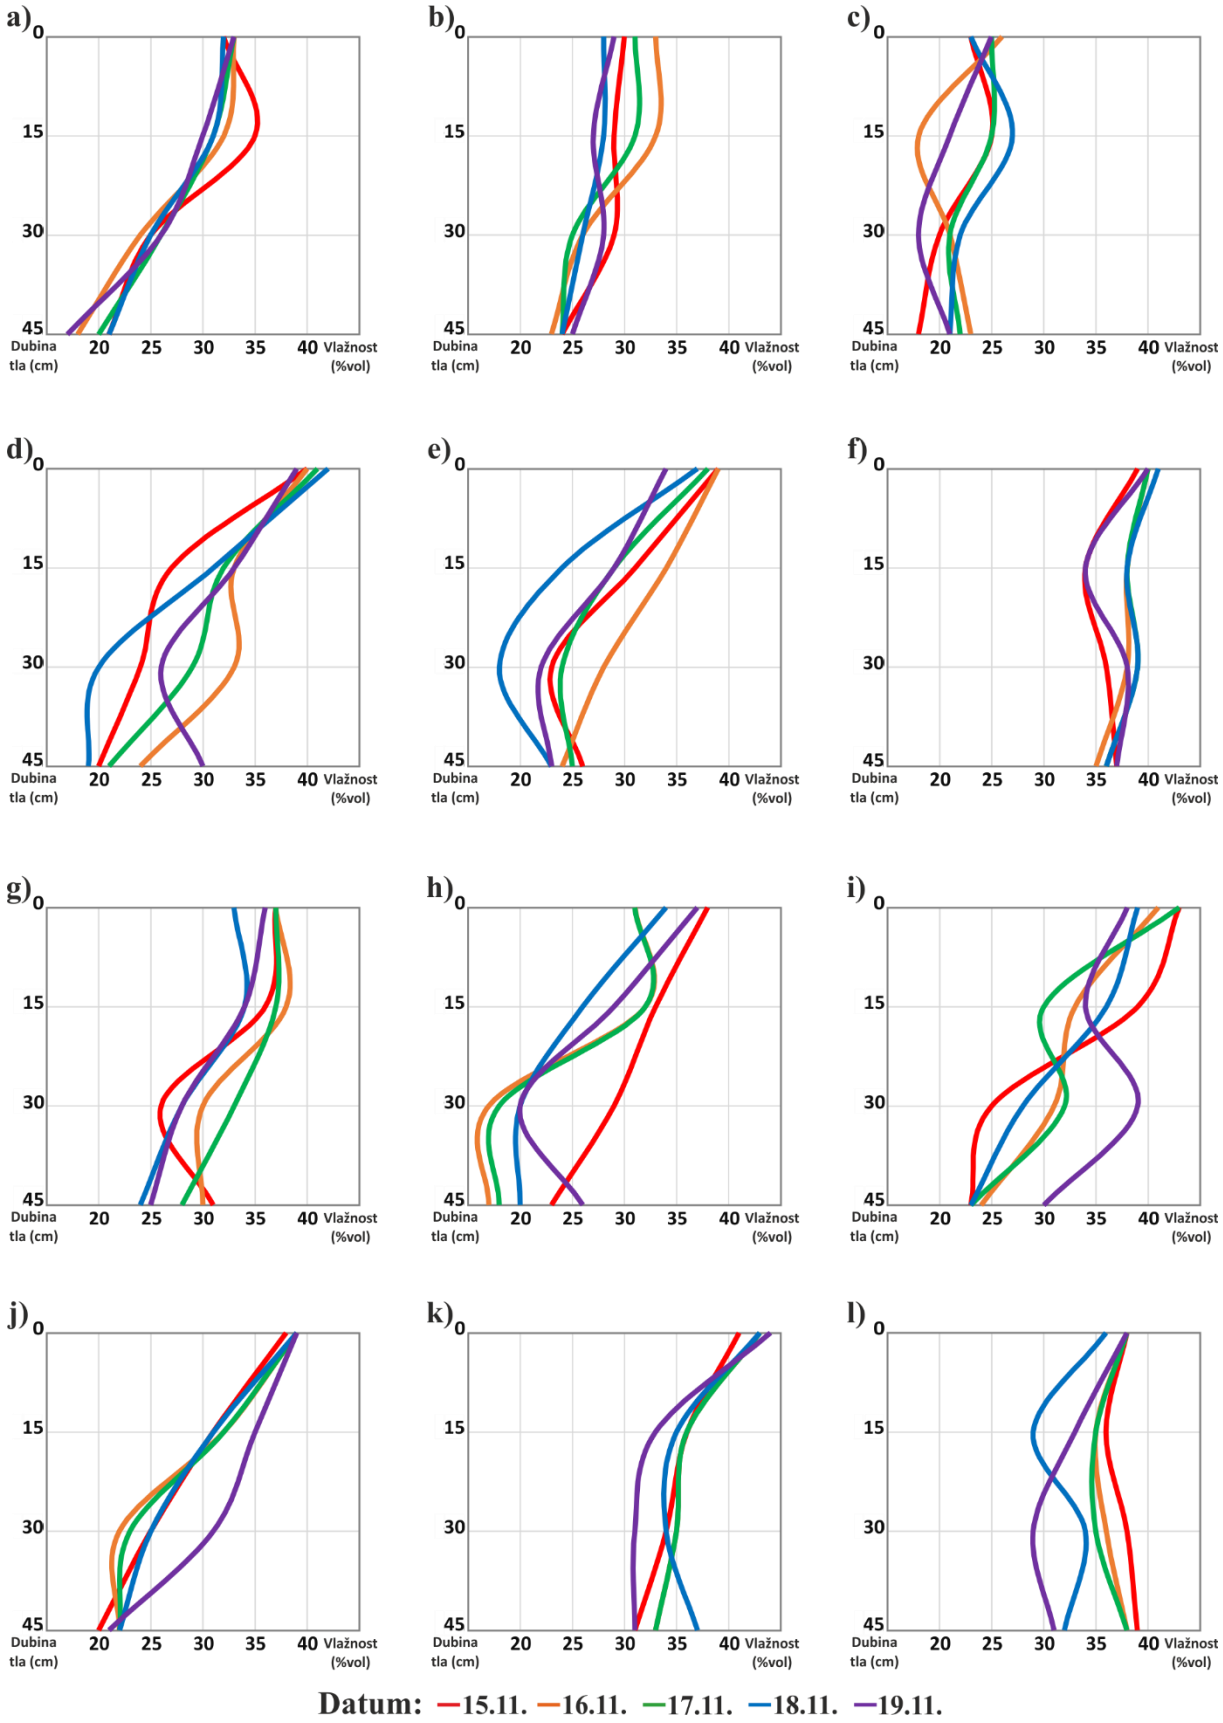

Prilog 14. Vlažnost tla u jesen na lokacijama (vidi Sl. 38. i Sl. 39.) mjerena sondom ThetaProbe od 25. do 29. studenog 2019. godine

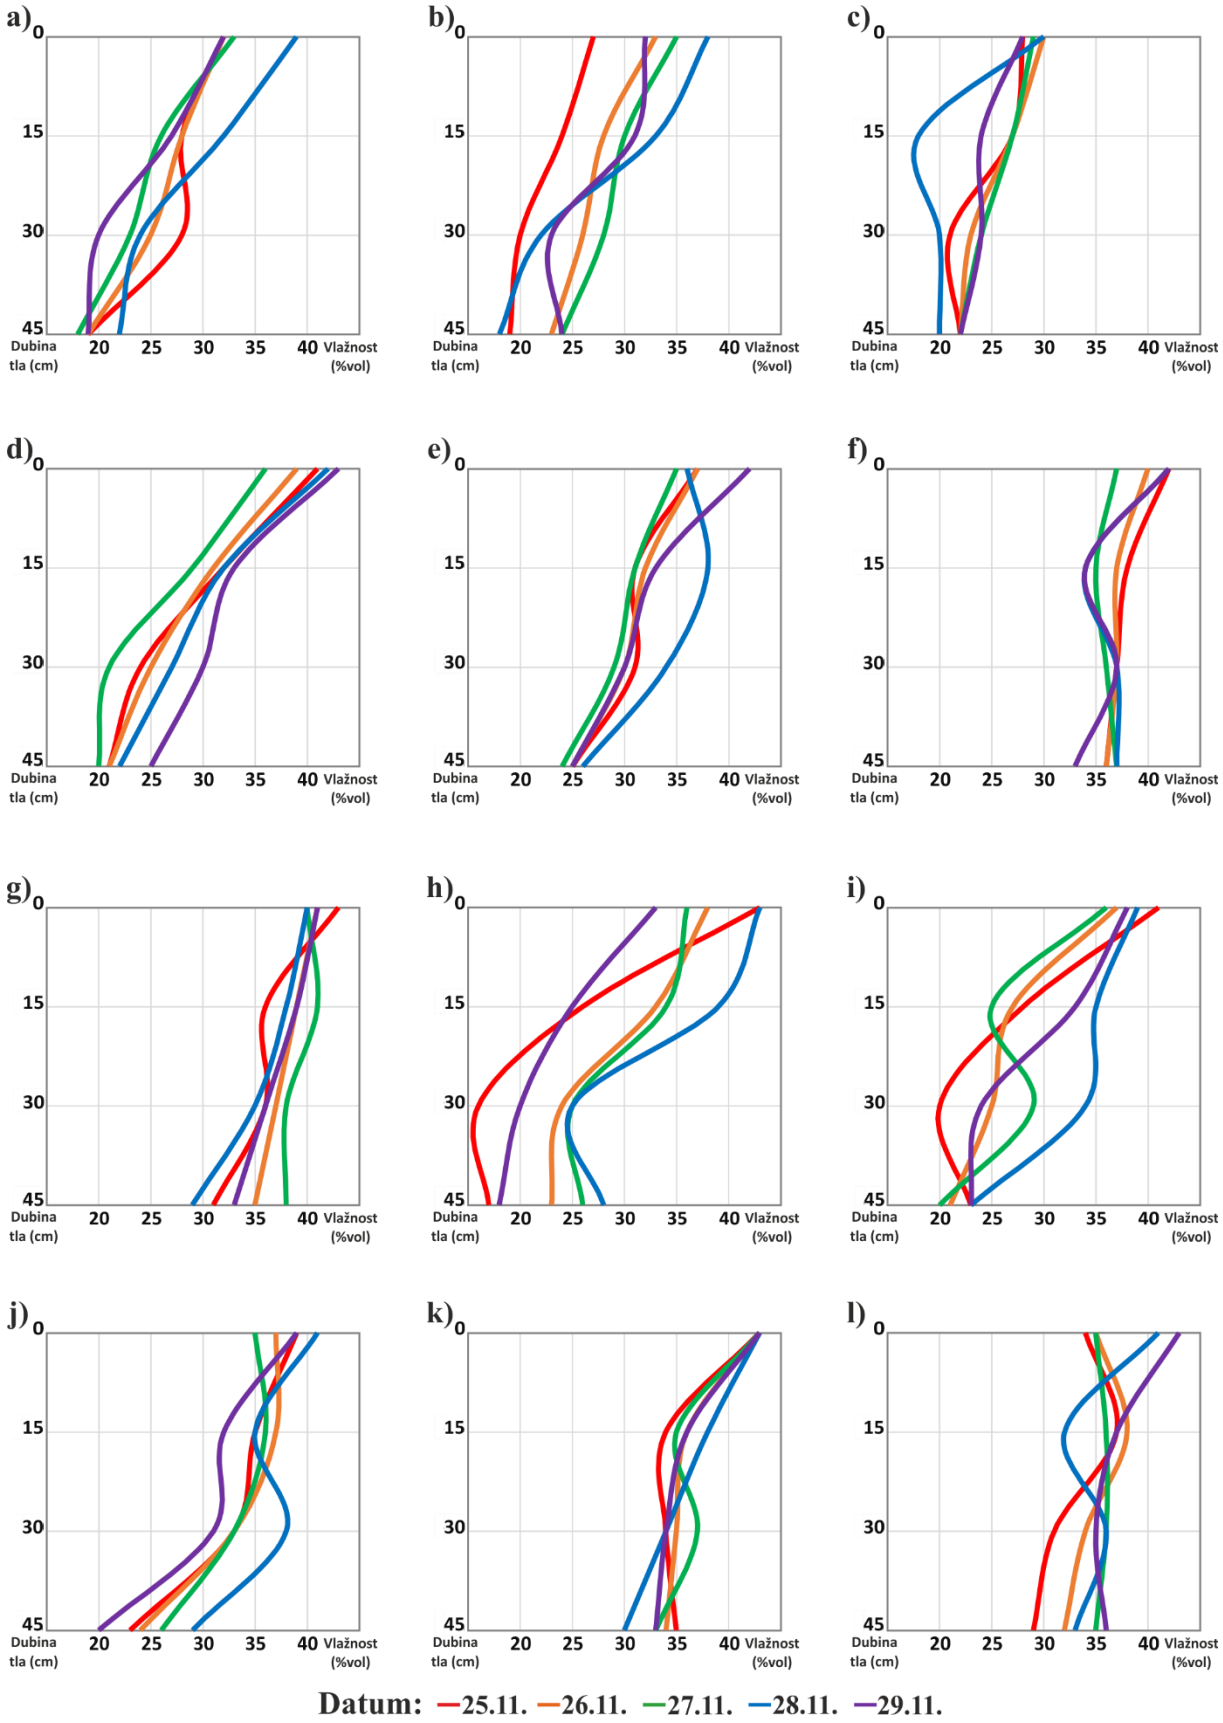

Prilog 15. Vlažnost tla zimi na lokacijama (vidi Sl. 38. i Sl. 39.) mjerena sondom ThetaProbe od 16. do 20. prosinca 2019. godine

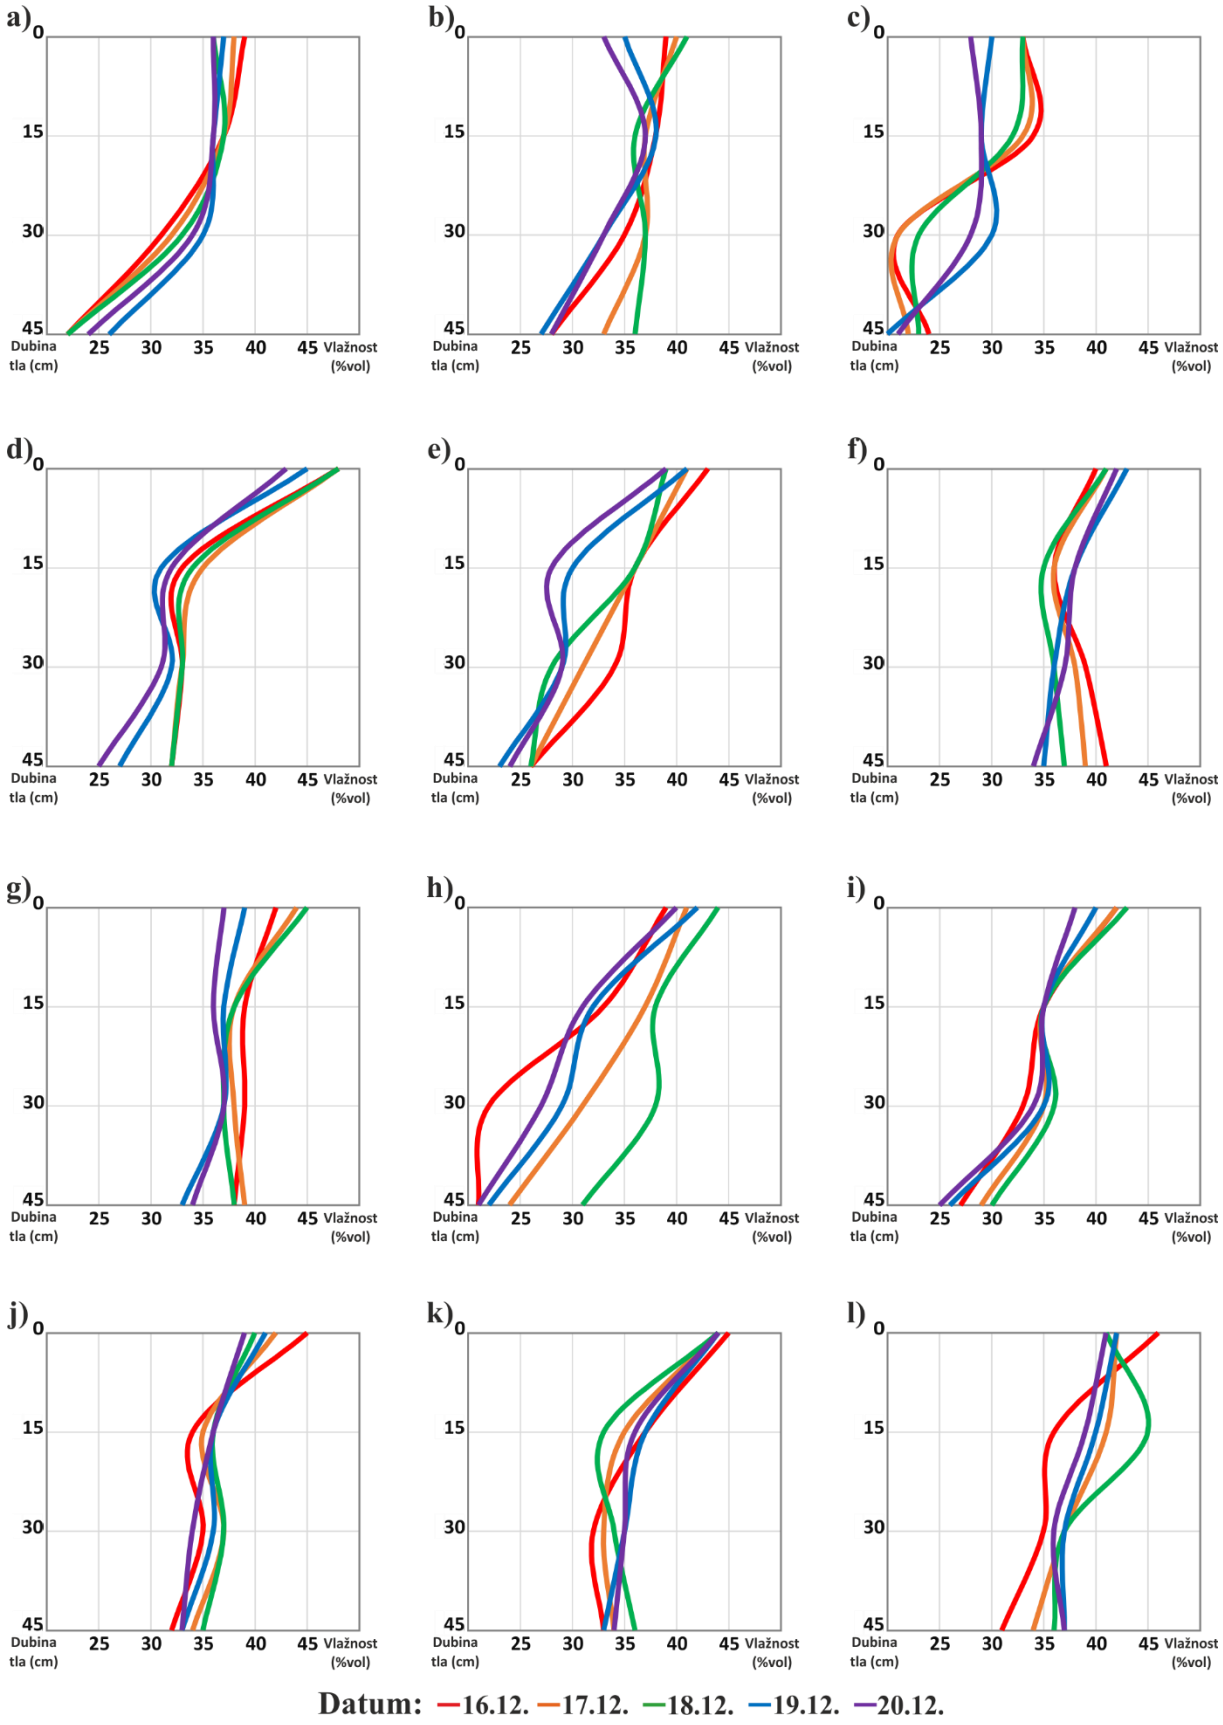

Prilog 16. Temperature zraka i tla zimi od 25. veljače do 1. ožujka 2019. godine

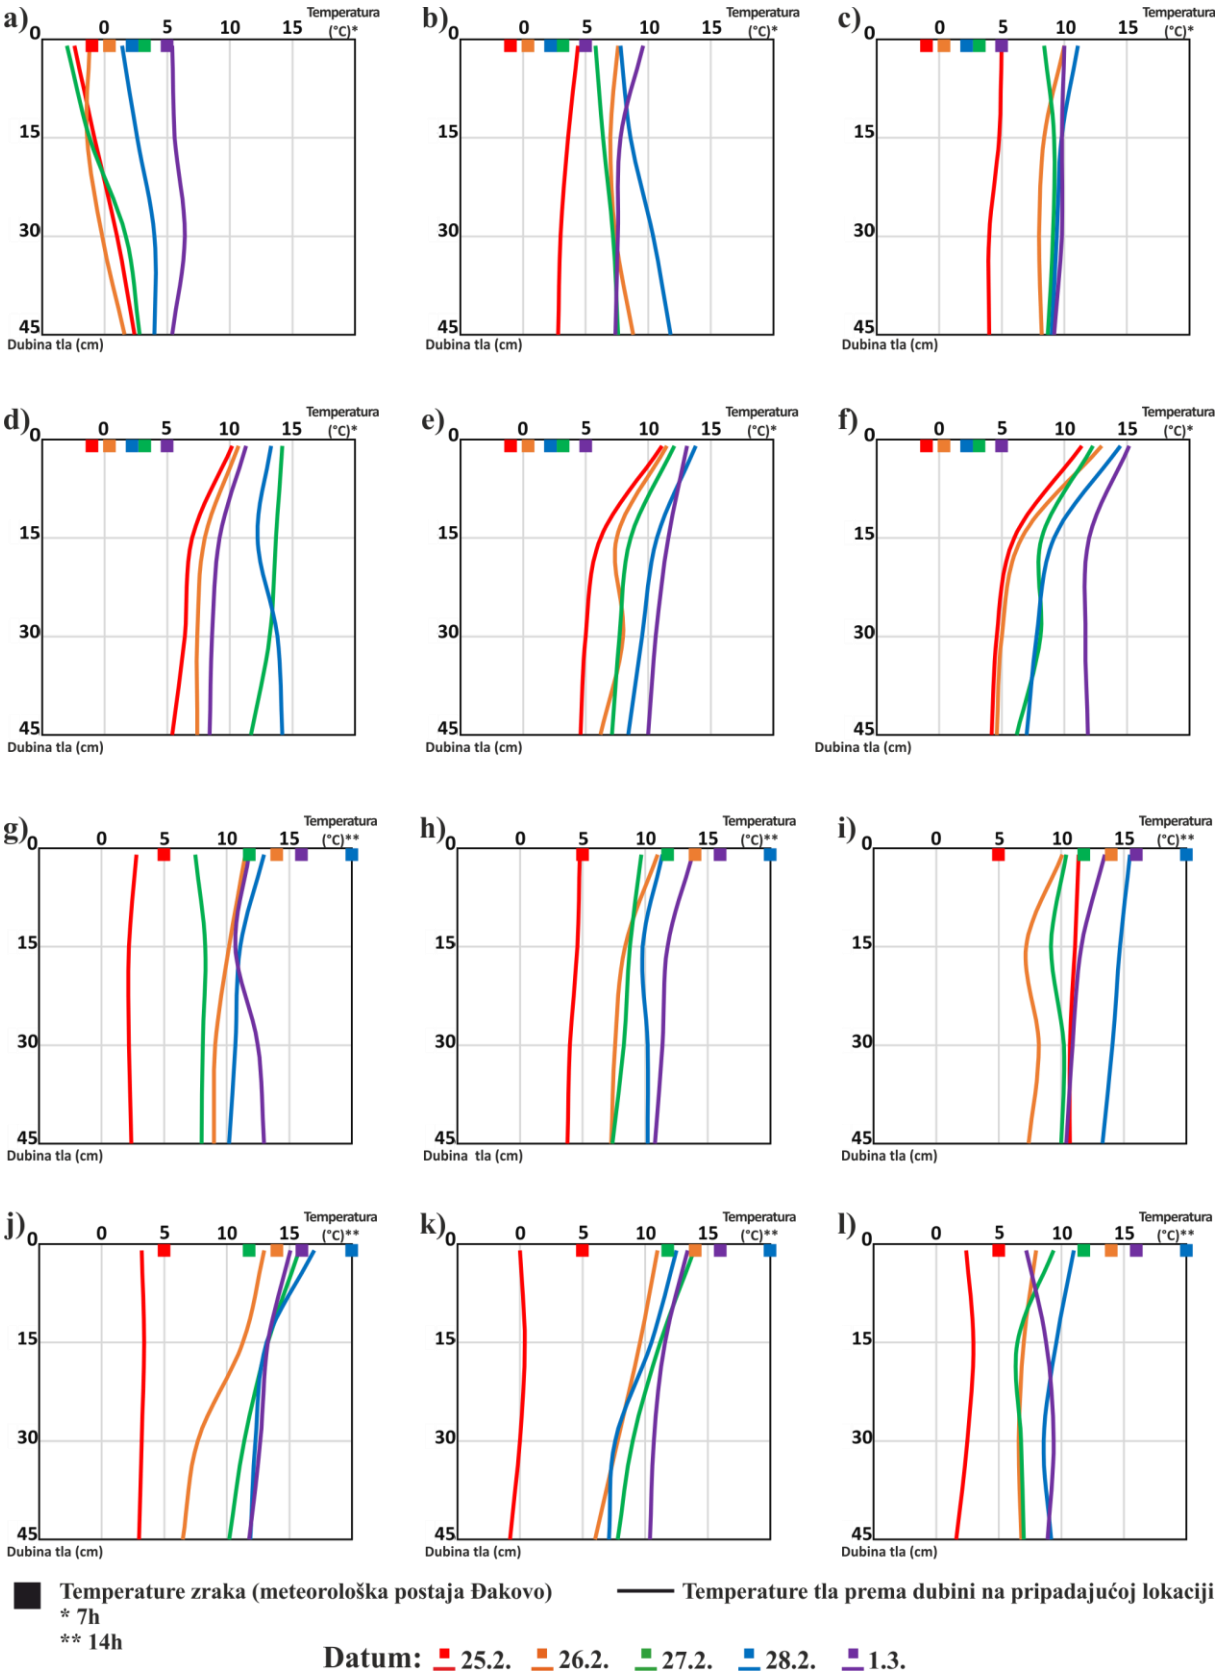

Prilog 17. Temperature zraka i tla u proljeće od 11. do 15. ožujka 2019. godine

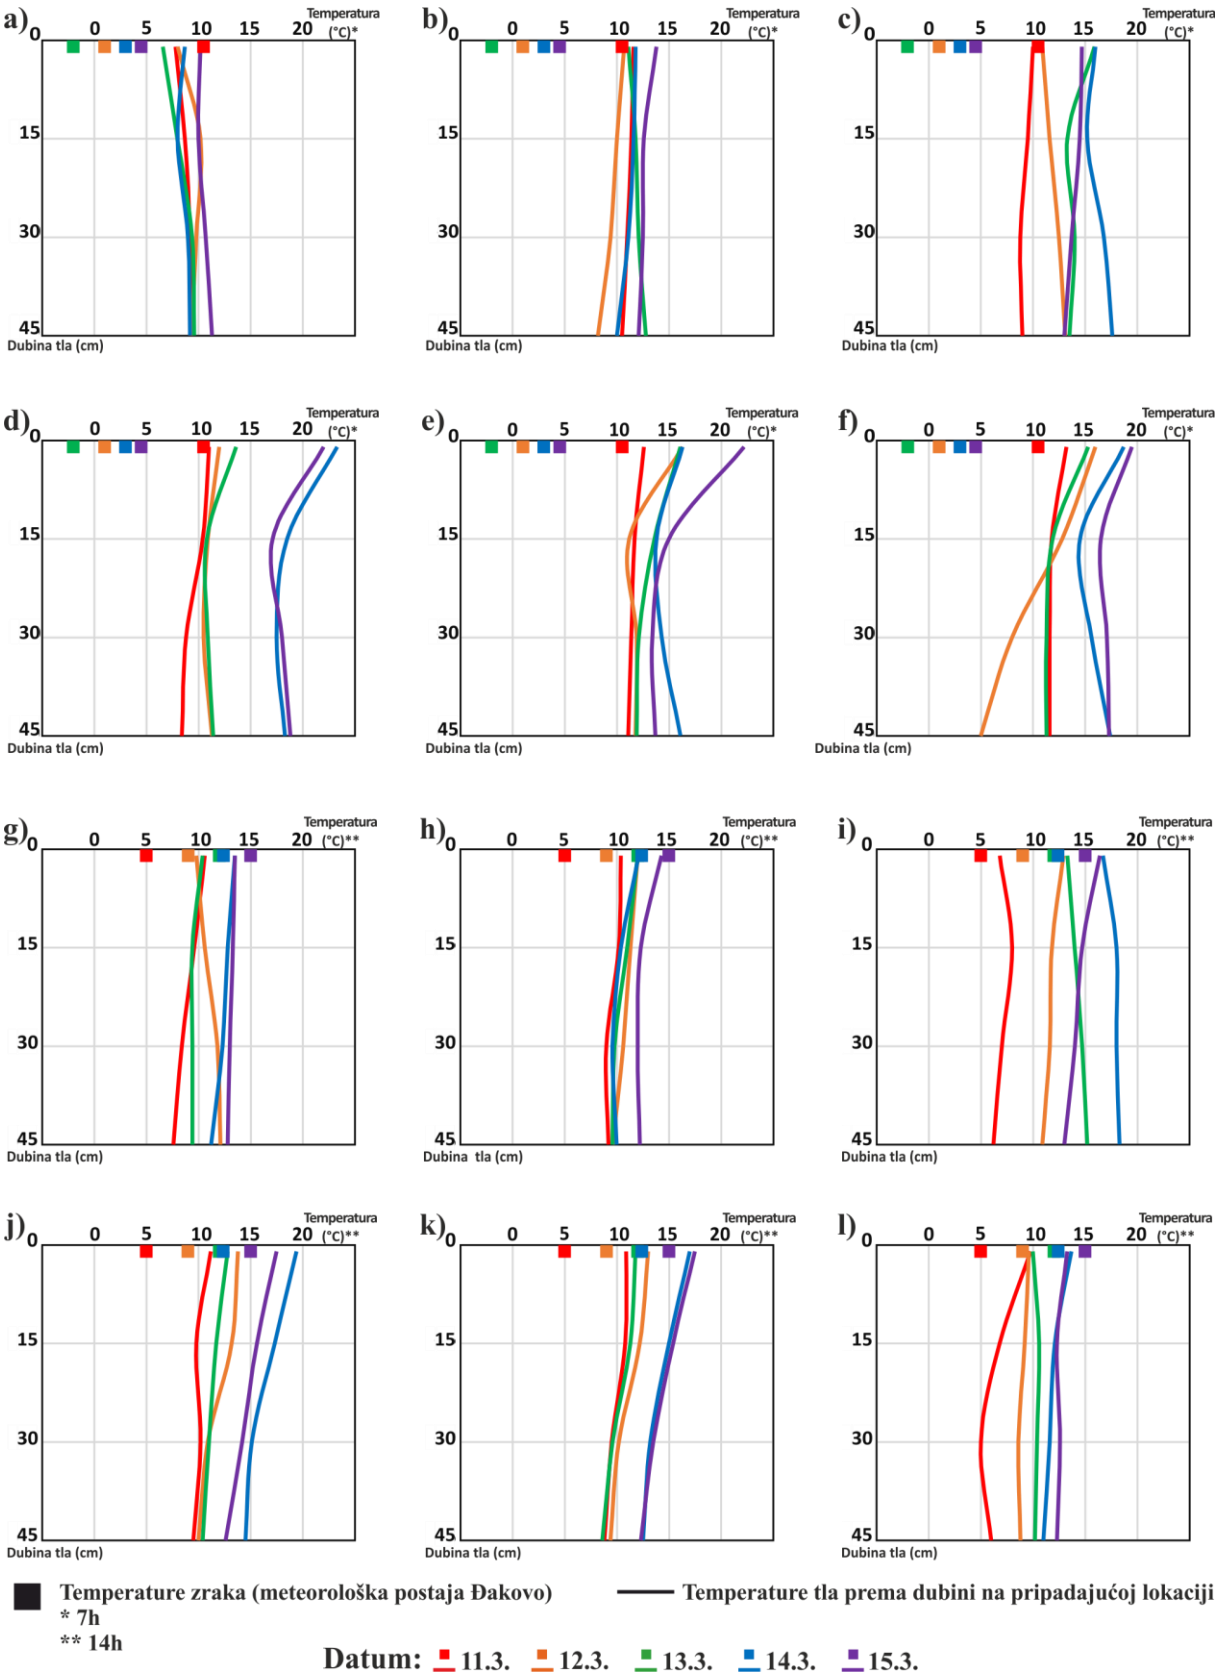

Prilog 18. Temperature zraka i tla u proljeće od 30. travnja do 4. svibnja 2019. godine

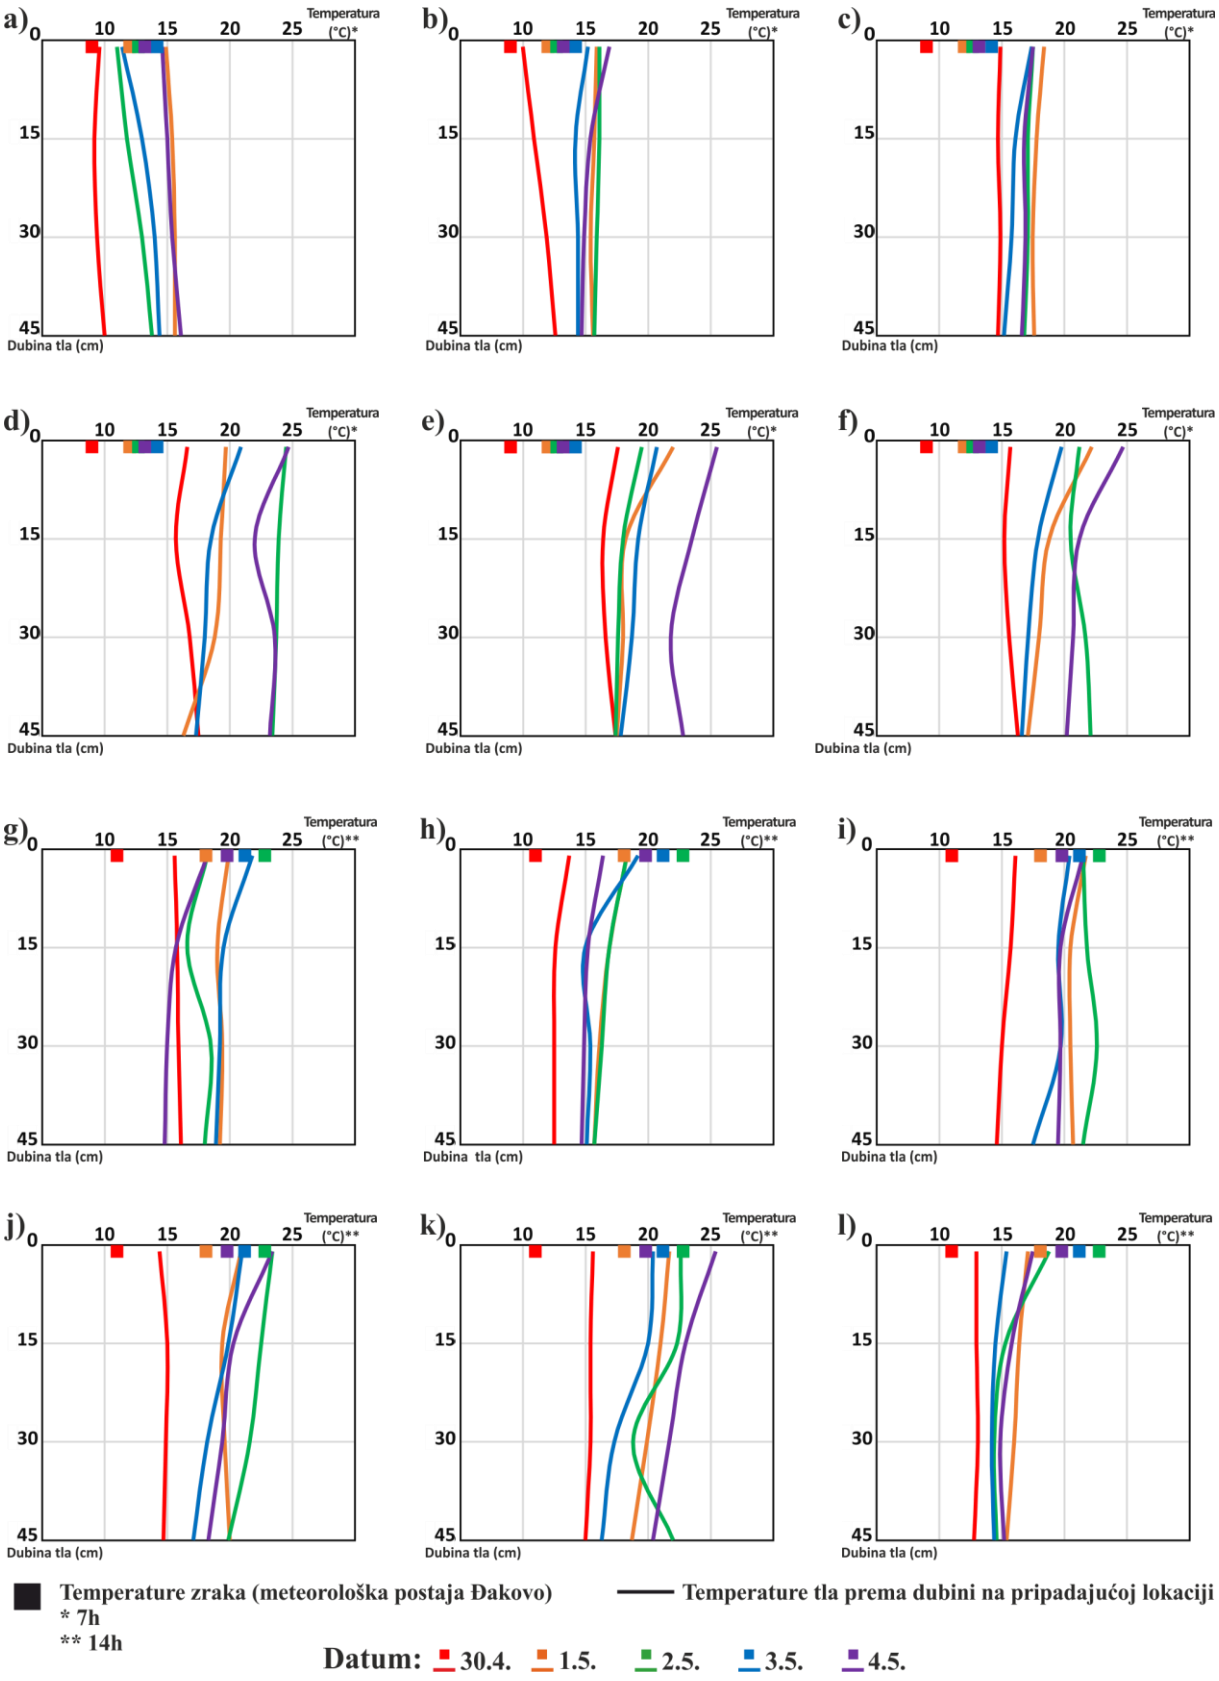

Prilog 19. Temperature zraka i tla ljeti od 26. do 30. kolovoza 2019. godine

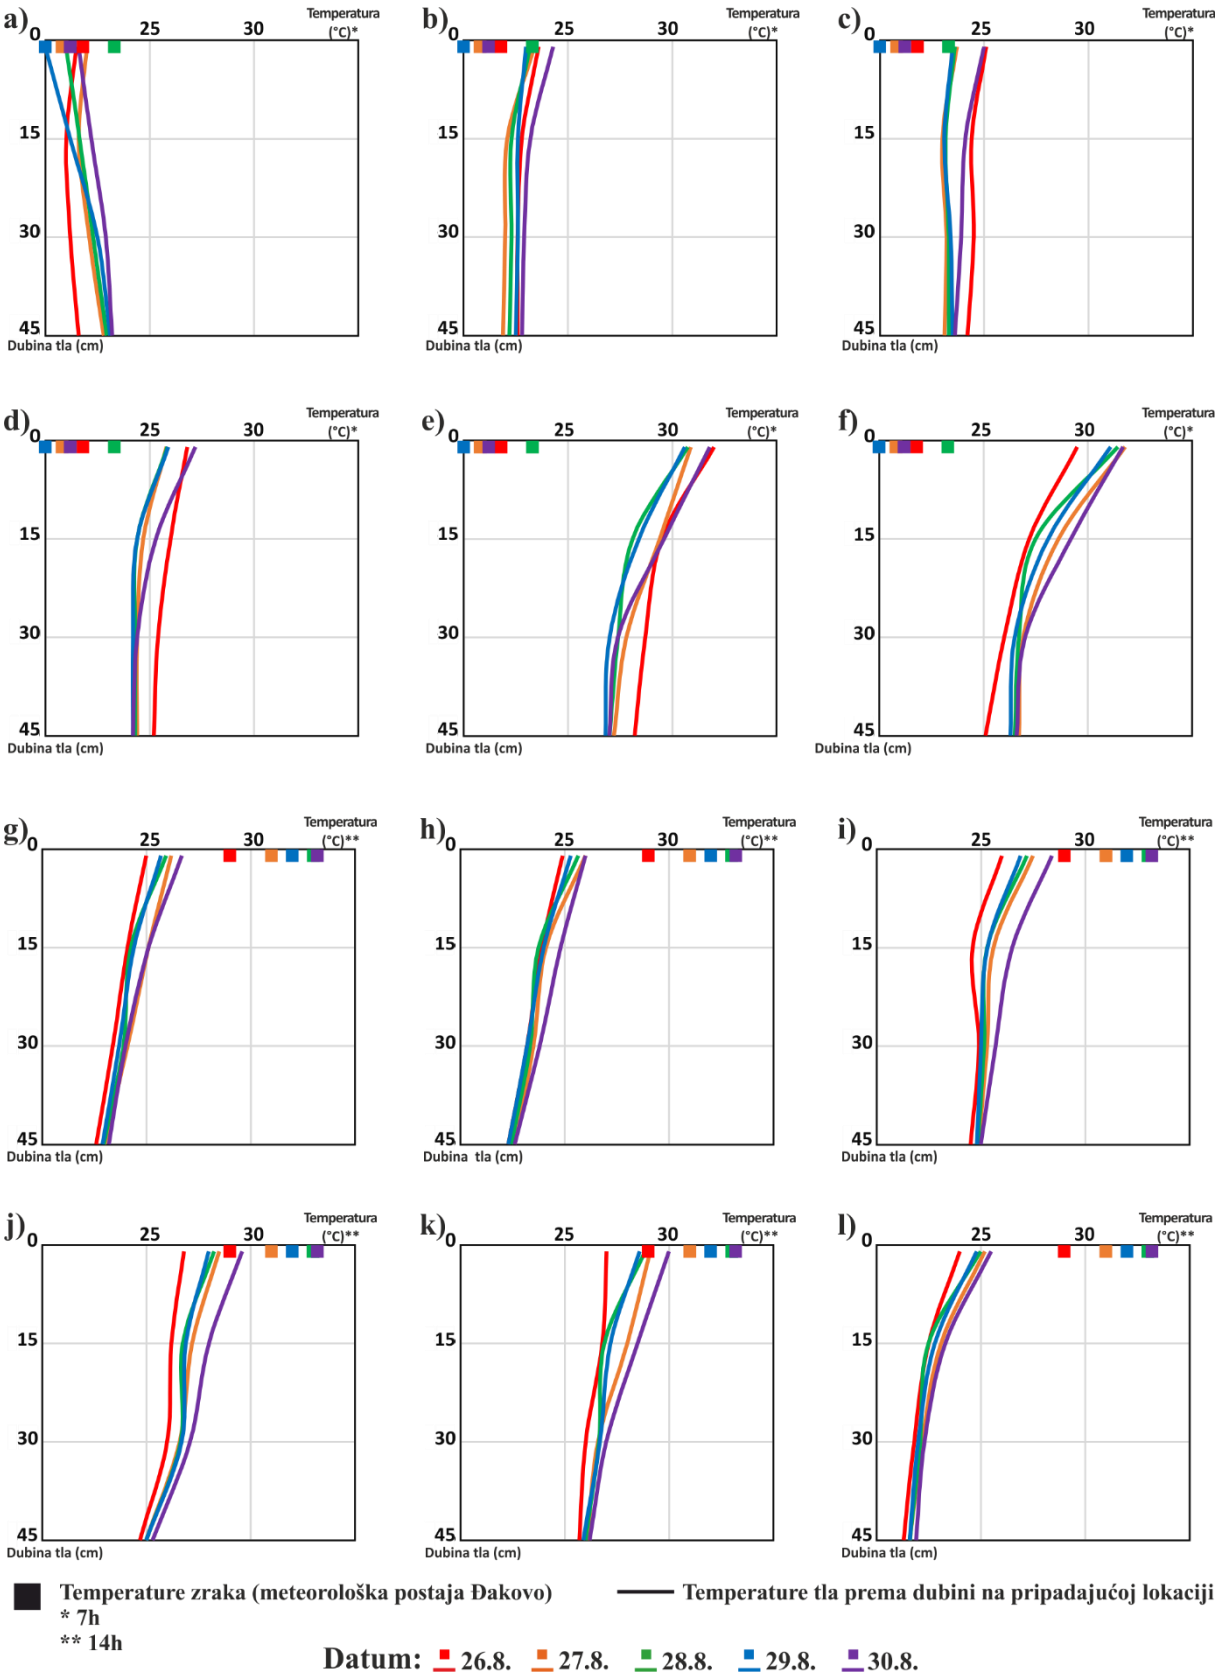

Prilog 20. Temperature zraka i tla u jesen od 15. do 19. studenog 2019. godine

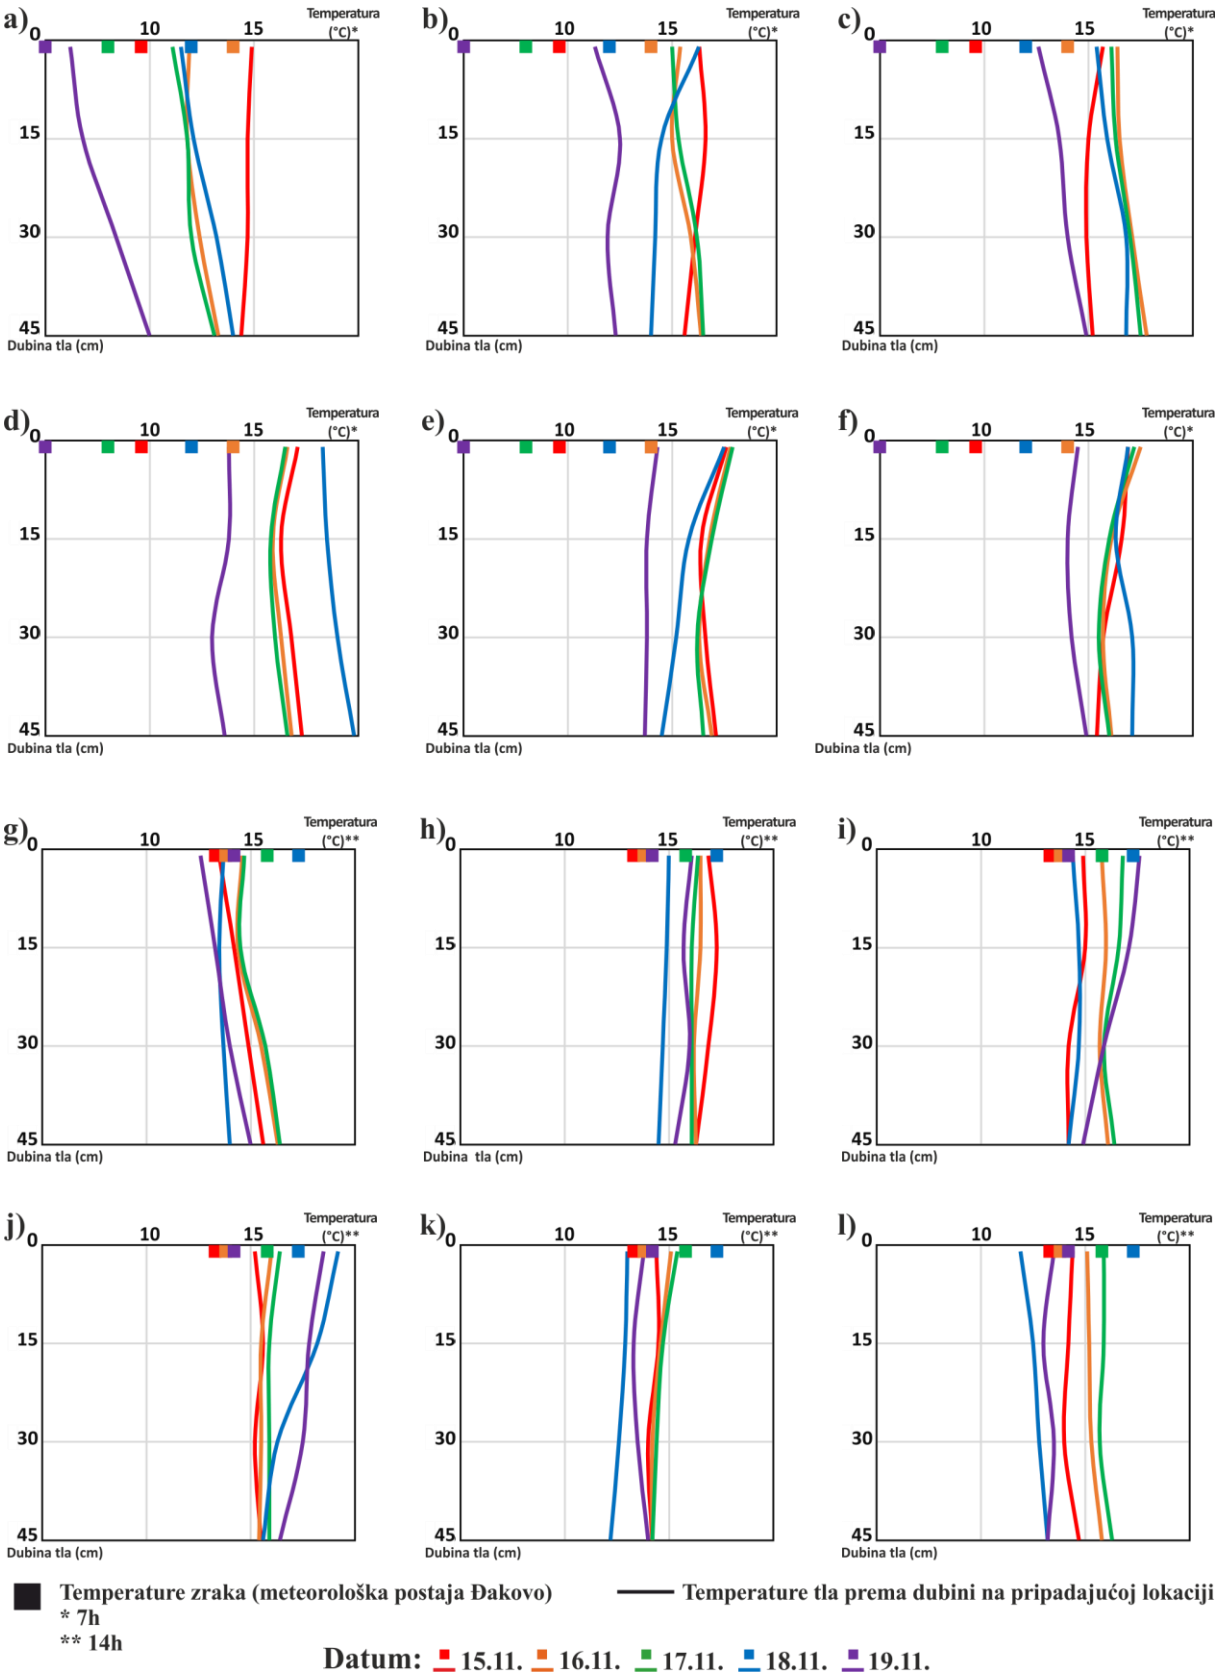

Prilog 21. Temperature zraka i tla u jesen od 25. do 29. studenog 2019. godine

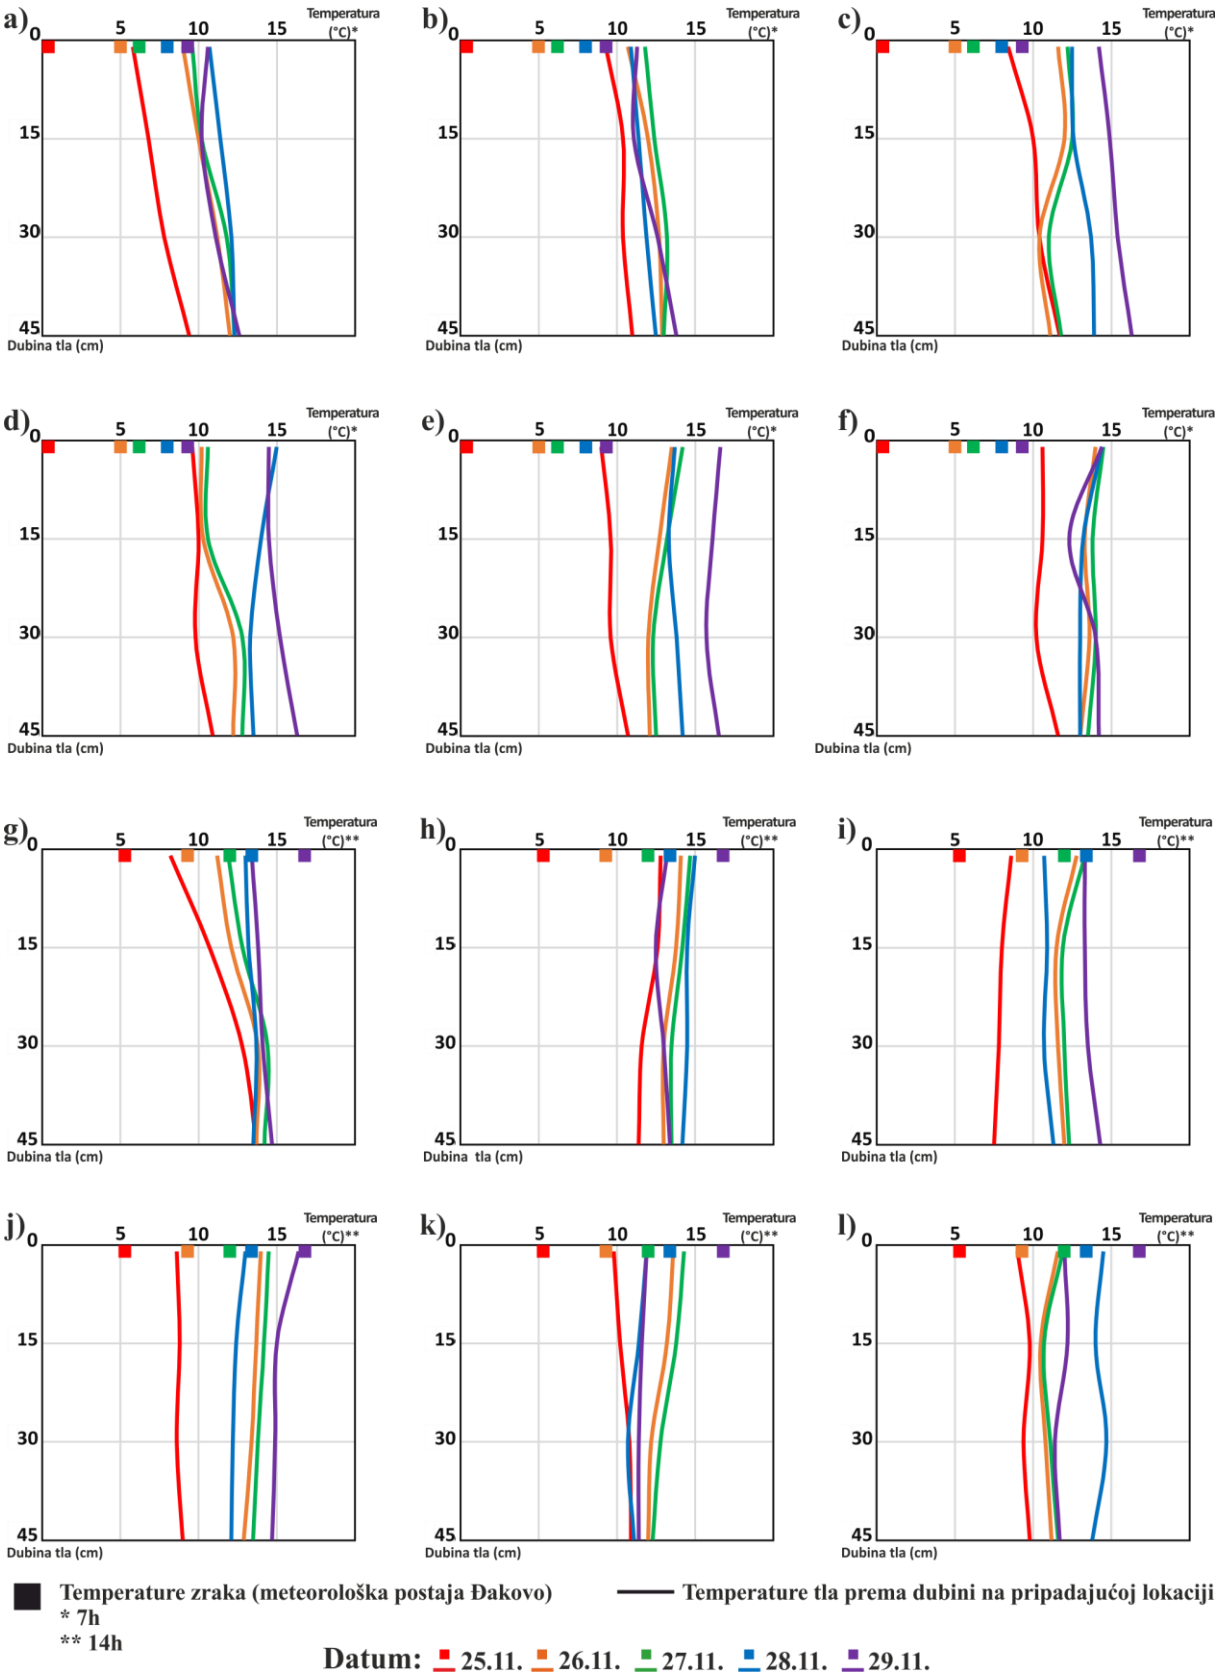

Prilog 22. Temperature zraka i tla zimi od 16. do 20. prosinca 2019. godine

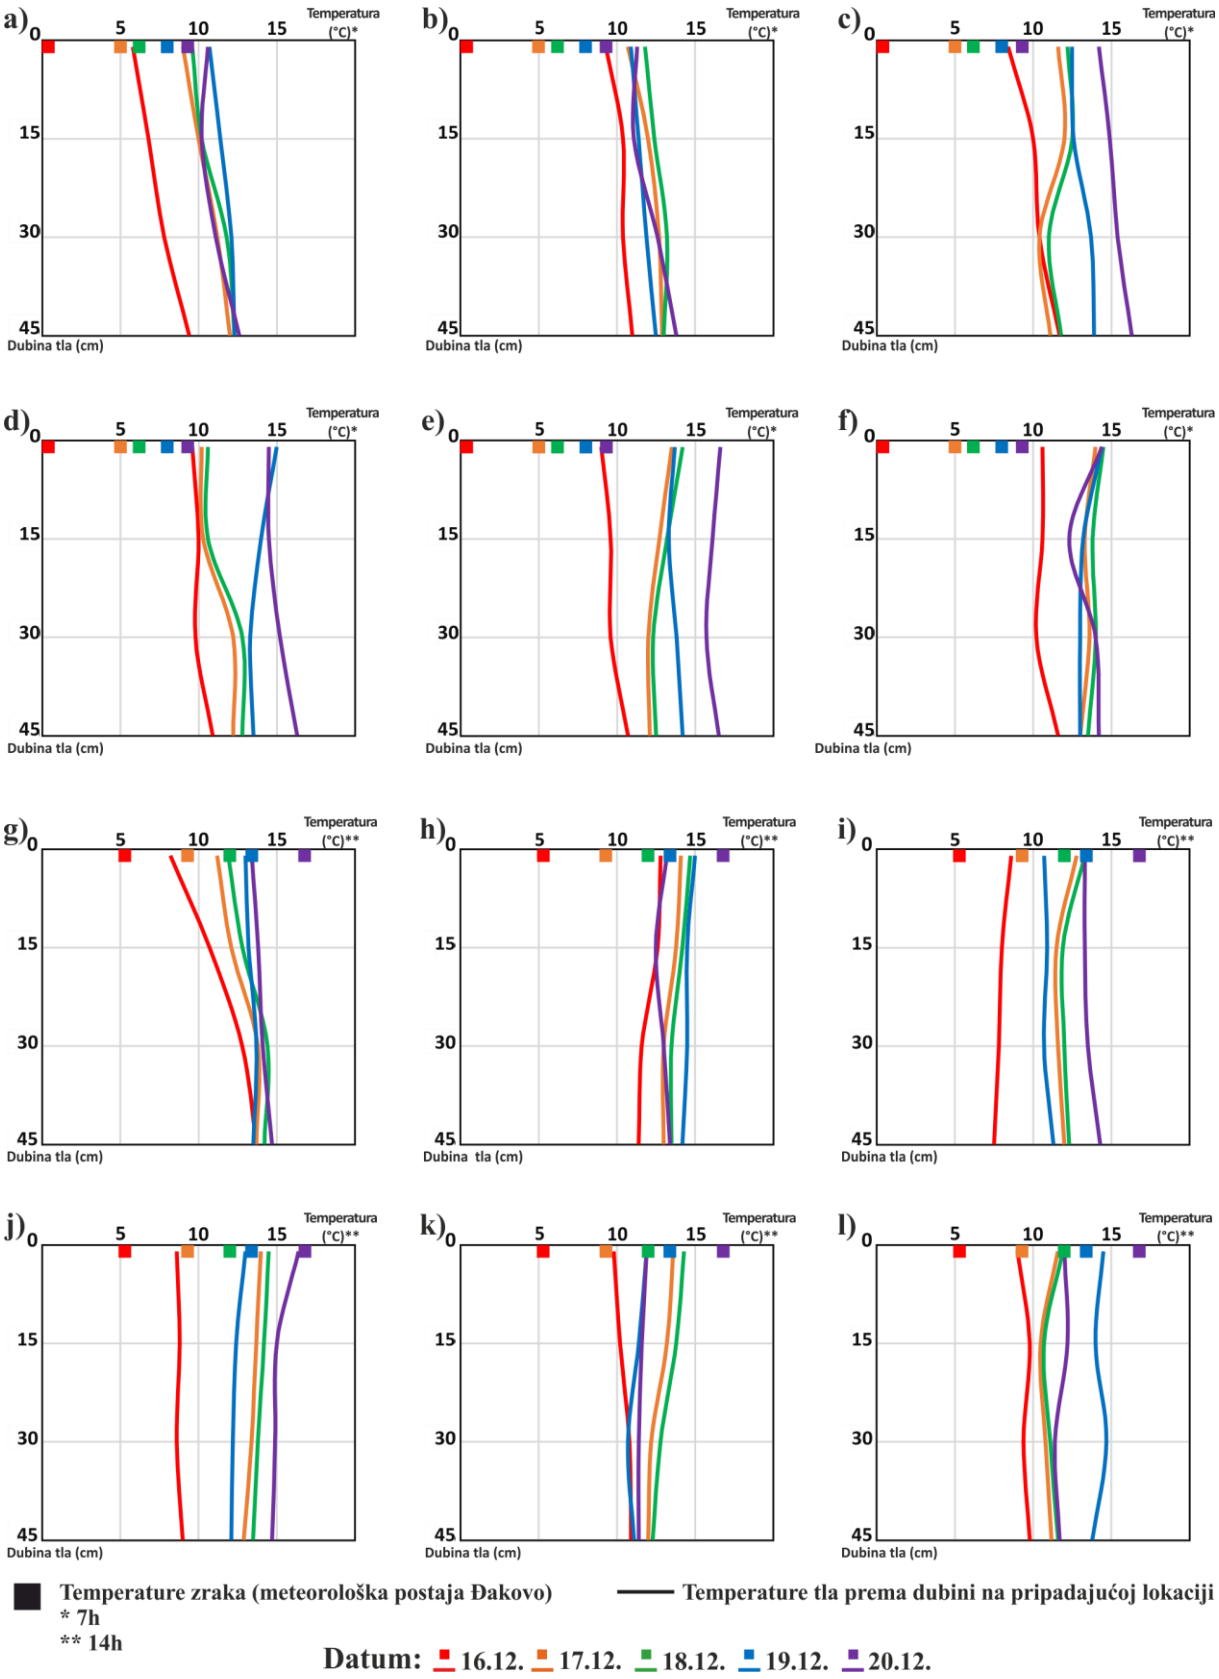

Prilog 23. Vršna i rezidualna čvrstoća tla na lokacijama (vidi Sl. 38. i Sl. 39.) zimi od 25. veljače do 1. ožujka 2019. godine

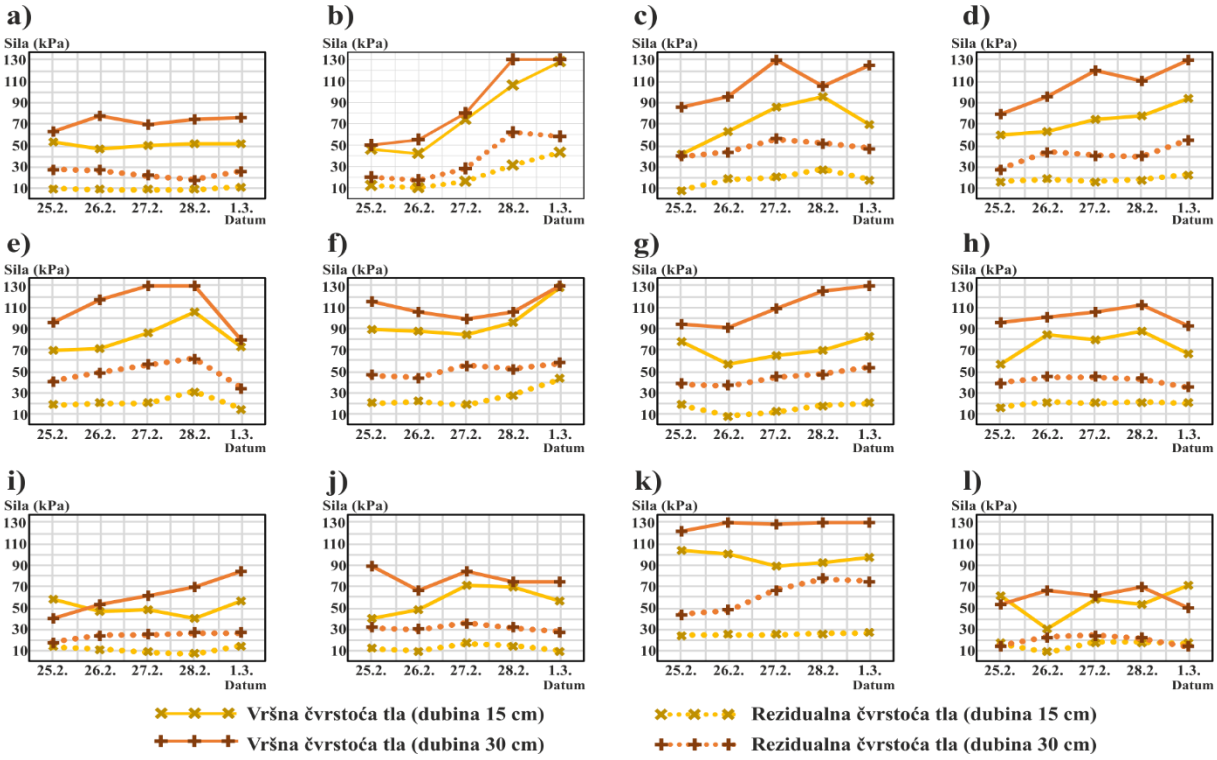

Prilog 24. Vršna i rezidualna čvrstoća tla na lokacijama (vidi Sl. 38. i Sl. 39.) u proljeće od 11. do 15. ožujka 2019. godine

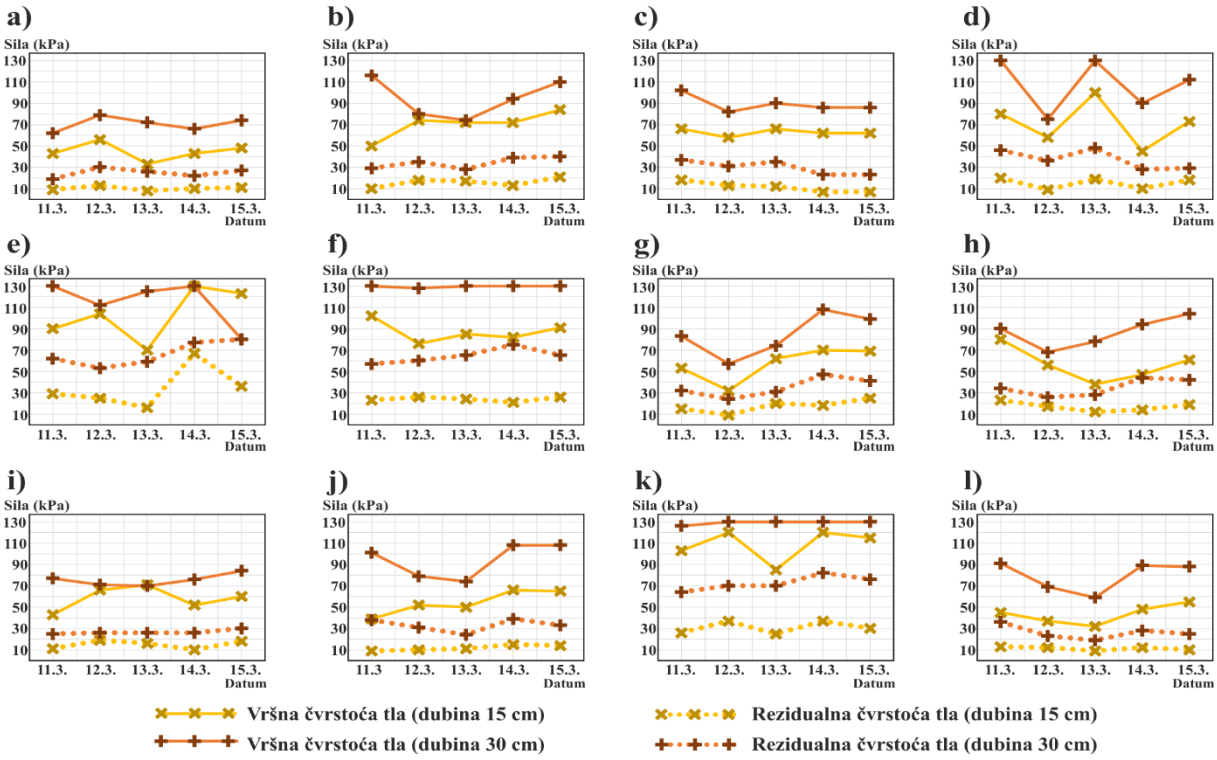

Prilog 25. Vršna i rezidualna čvrstoća tla na lokacijama (vidi Sl. 38. i Sl. 39.) u proljeće od 30. travnja do 4. svibnja 2019. godine

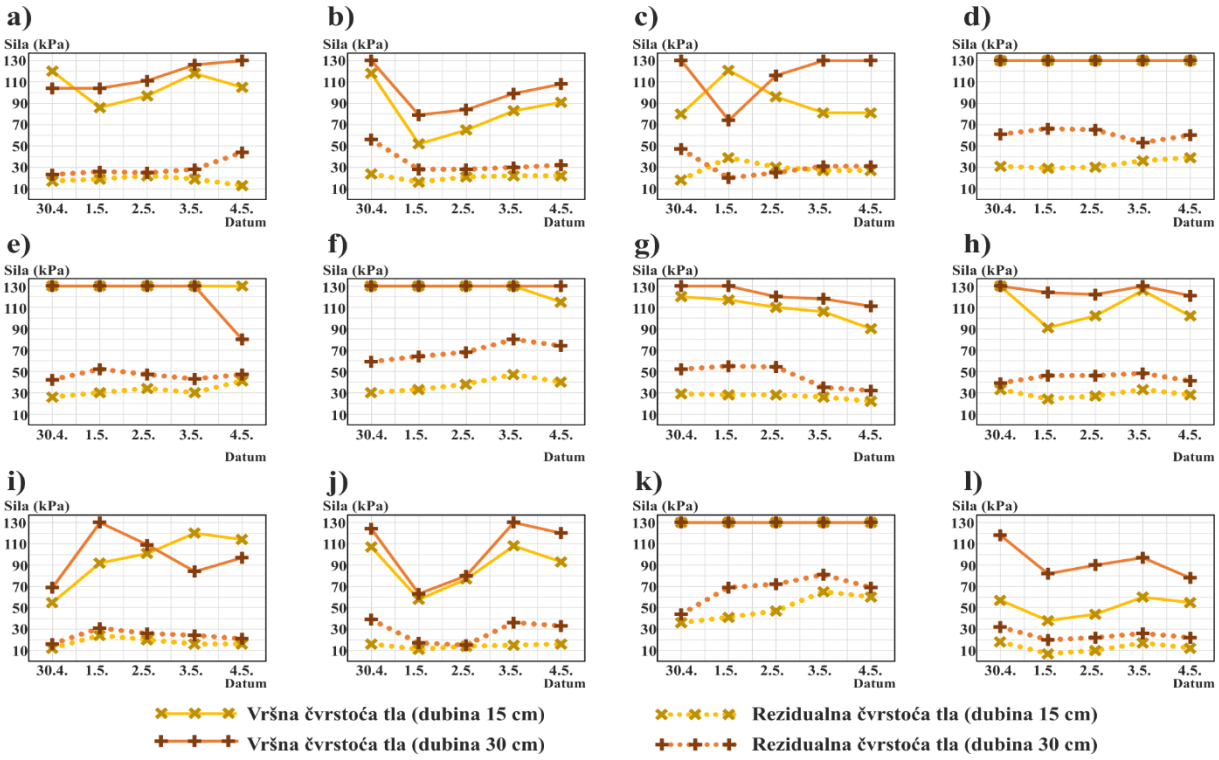

Prilog 26. Vršna i rezidualna čvrstoća tla na lokacijama (vidi Sl. 38. i Sl. 39.) ljeti od 26. do 30. kolovoza 2019. godine

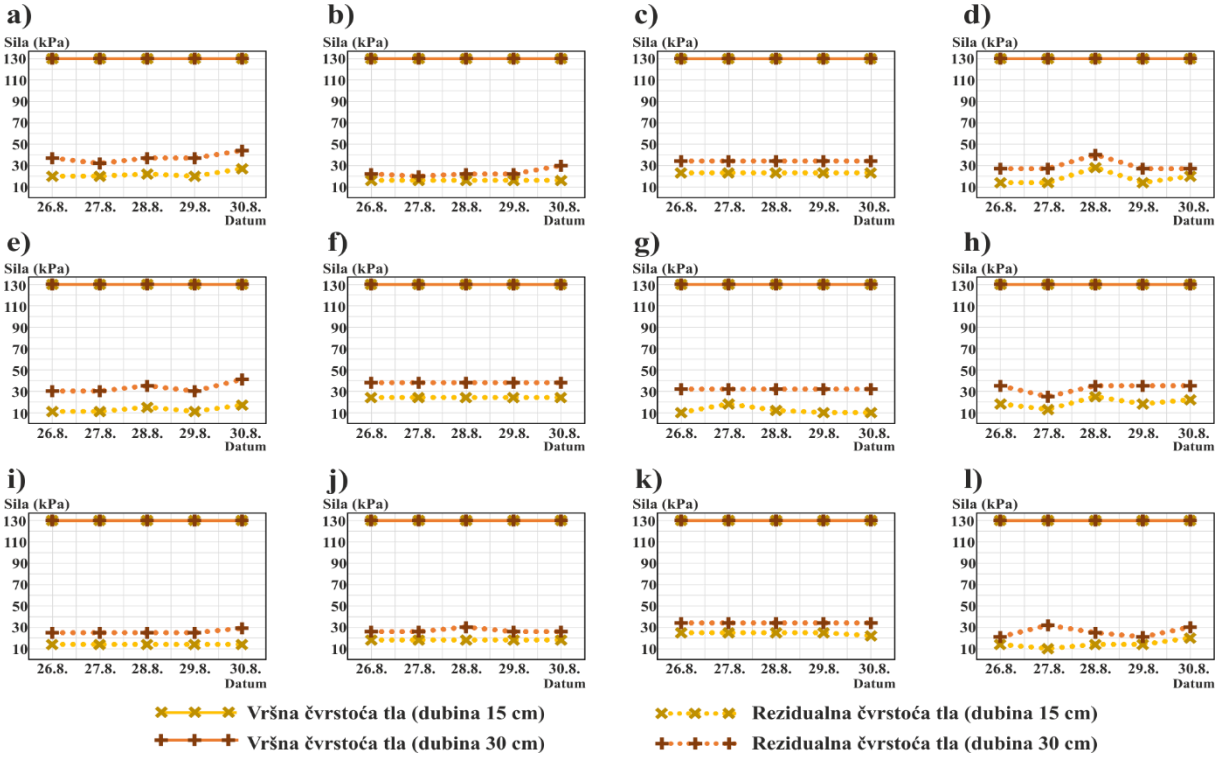

Prilog 27. Vršna i rezidualna čvrstoća tla na lokacijama (vidi Sl. 38. i Sl. 39.) u jesen od 15. do 19. studenog 2019. godine

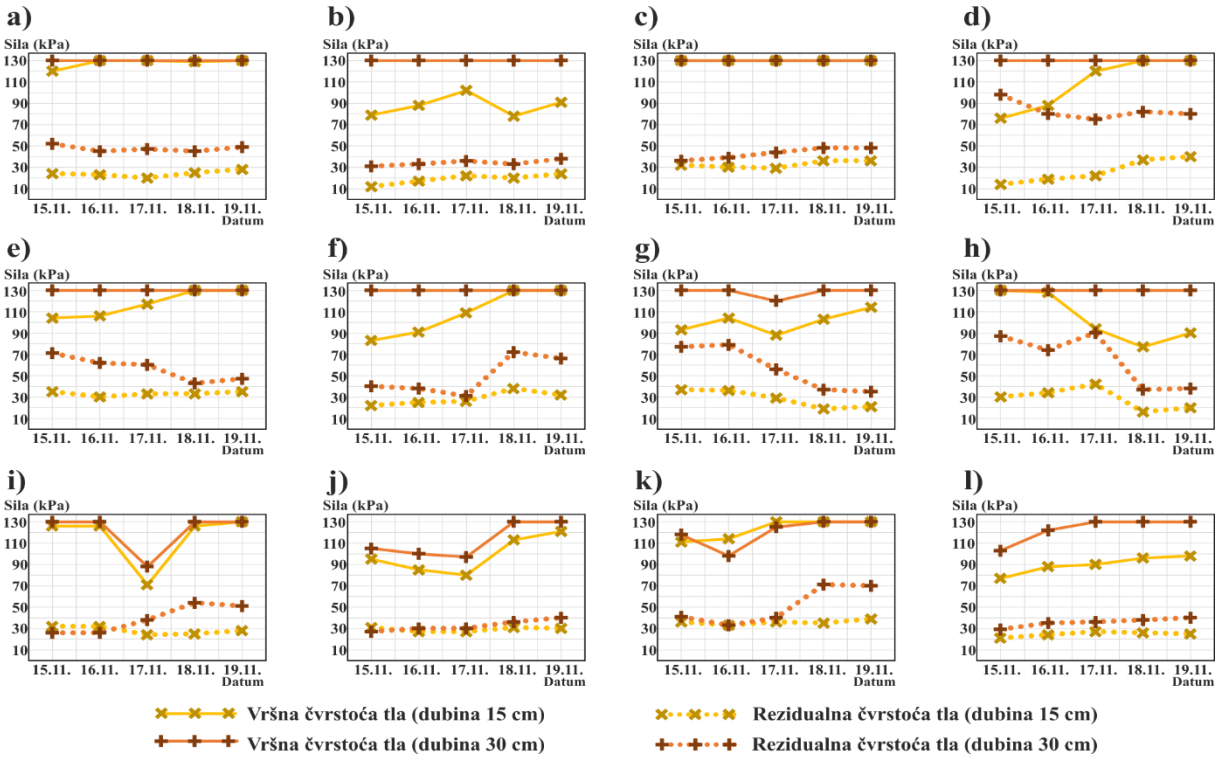

Prilog 28. Vršna i rezidualna čvrstoća tla na lokacijama (vidi Sl. 38. i Sl. 39.) u jesen od 25. do 29. studenog 2019. godine

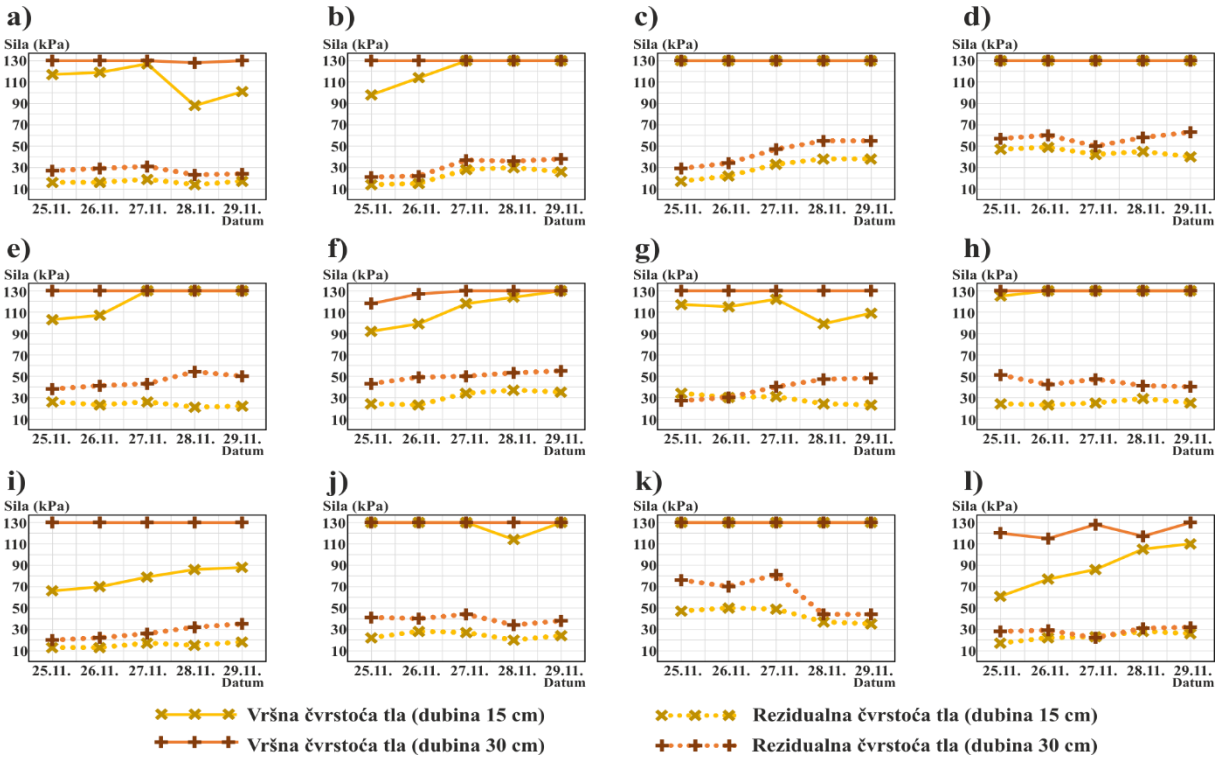

Prilog 29. Vršna i rezidualna čvrstoća tla na lokacijama (vidi Sl. 38. i Sl. 39.) zimi od 16. do 20. prosinca 2019. godine

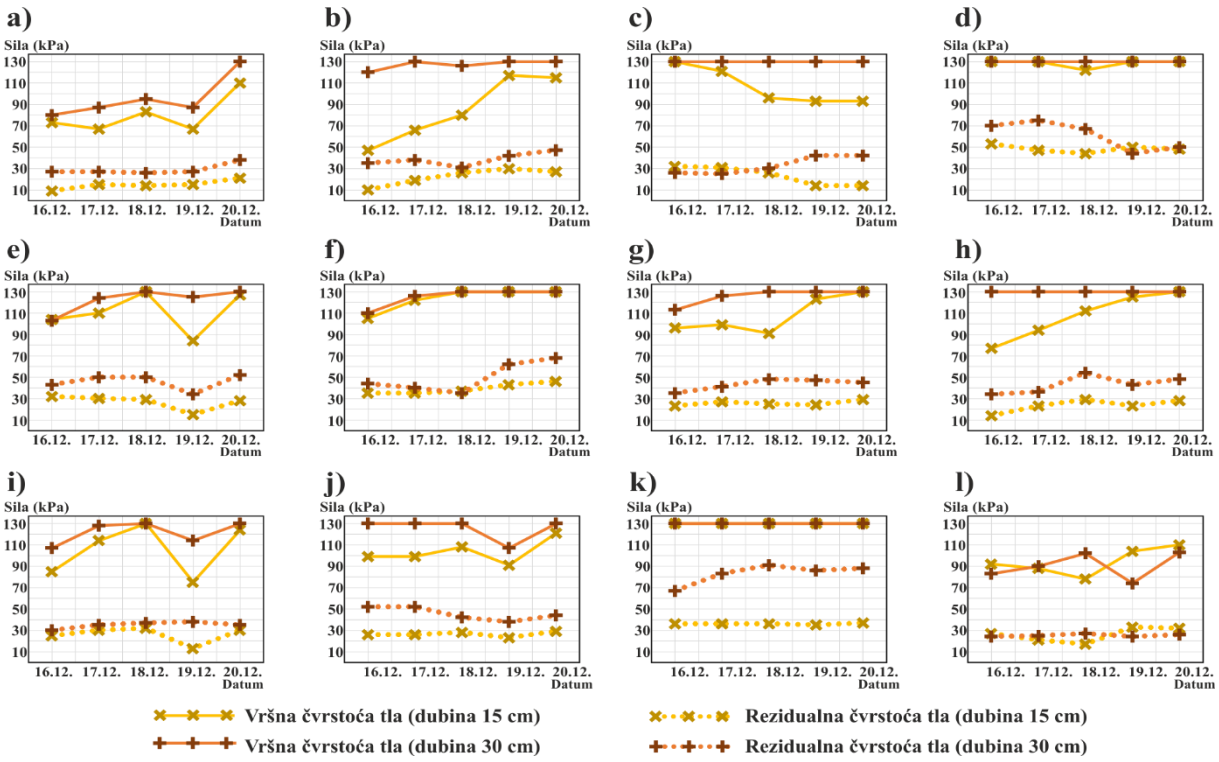

POPIS TABLICA

Tab. 1. Glavna tehnička obilježja vozila korištenih u istraživanju 51
Tab. 2. Odnos površinskog udjela pedoloških jedinica i preuzetih uzoraka za laboratorijsku analizu prema USCS 61
Tab. 3. Prosječne vrijednosti INT za tri uobičajena stanja vlažnosti tla 66
Tab. 4. Faktor osovinskog opterećenja za gusjeničare 68
Tab. 5. Faktor osovinskog opterećenja za kotačna vozila 69
Tab. 6. Lokacije mjerenja prohodnosti tla prema nagibu i orijentaciji padina, tipu tla i grupi tla prema USCS, TIV i biljnom pokrovu 74
Tab. 7. Koeficijenti i parametri usporenja vozila uslijed vertikalne nagnutosti terena 97
Tab. 8. Koeficijenti usporenja uslijed hrapavosti terena 100
Tab. 9. Koeficijenti usporenja vozila uslijed mokrog stanja tla 102
Tab. 10. Prikaz raspona razmaka stabala unutar koeficijenata usporenja (0-1) 103
Tab. 11. Koeficijenti usporenja prema tipu biljnog pokrova i vegetacijskom razdoblju 107
Tab. 12. Koeficijenti usporenja antropogenih objekata i područja 108
Tab. 13. Razdioba rezultata sloja Faktor nagib reljefa (F_n) 113
Tab. 14. Matrica uzoraka (50) preuzetih s istovjetnih lokacija klasificiranih prema USDA teksturnoj klasifikaciji (izvor: OPK) i USCS grupi tla (laboratorijski rezultati) 116
Tab. 15. Nedrenirana posmična čvrstoća glina 132
Tab. 16. Korelacijski parametri (r_p) između vlažnosti tla, sile prodiranja konusnog penetrometra i topografskog indeksa vlaženja (TIV) 137
Tab. 17. Odstupanja vrijednosti nagiba terena na poprečnim profilima dobivenih DMR-ovima i terenskim mjerenjima (preferirane lokacije) 149
Tab. 18. Odstupanja vrijednosti nagiba terena na poprečnim profilima dobivenih DMR-ovima i terenskim mjerenjima (lokacije temeljem slučajnog odabira) 150
Tab. 19. Površina i udio šumske sastojine prema graničnim vrijednostima razmaka stabala za TPV 155
Tab. 20. Površinski udjeli ostale vegetacije (bez šuma) na području istraživanja 156

POPIS SLIKA

Sl. 1. Položaj vojne analize zemljišta unutar ostalih znanosti 3
Sl. 2. Prostor istraživanja – fizičko-geografska karta 7
Sl. 3. Osnovna geološka karta 8
Sl. 4. Nagib padina istraživanog područja 10
Sl. 5. Osnovna pedološka karta 12
Sl. 6. Vodene površine 13
Sl. 7. Hidropedološka karta - načini vlaženja i osnovni tipovi tla 14
Sl. 8. Vegetacija 16
Sl. 9. Prosječne godišnje padaline za klimatsko razdoblje 1960 – 1990 17
Sl. 10. Prosječne padaline prema godišnjim dobima za klimatsko razdoblje 1960 – 1990 18
Sl. 11. Međusobni odnosi osnovnih značajki fizičko-geografskih čimbenika TPV 21
Sl. 12. Postotni udio uključenih faktora u modelima TPV, grupiranih prema čimbenicima: a) Reljef, b) Tlo, c) Meteo-klima, d) Vode, e) Vegetacija 23
Sl. 13. Evaluacijski parametri osnovnih mikroreljefnih formi 25
Sl. 14. Shema različitih pristupa problematici mobilnosti vozila u odnosu na tlo 27
Sl. 15. Komplet za ispitivanje prohodnosti tla. Dijelovi kompleta: a) Konusni penetrometar, b) Čekić za zbijanje tla, c) Cilindar, d) Baza, e) Uzorkivač tla 28
Sl. 16. Shematski prikaz bevametra 29
Sl. 17. Terensko mjerenje bevametrom montiranim na buldožer 30
Sl. 18. Usporedba graničnih vrijednosti veličina čestica USCS i USDA klasifikacijskih sustava 33
Sl. 19. Primjer karte terenske mobilnosti tenka (Stingray) u: a) sušnom periodu i b) kišnom periodu 35
Sl. 20. Primjer karte prohodnosti vozila na strateškoj razini odlučivanja. Njemačka karta prohodnosti vozila za područje Libije (1941). 44
Sl. 21. Primjer karte prohodnosti vozila na operativnoj razini odlučivanja. Dio lista P 5 Serija M641 (CCM), Terenska pokretljivost vozila i karta zemljišta, Halberstadt, Njemačka, 1958, izrađena od strane vojske SAD-a. 45
Sl. 22. Primjer karte prohodnosti vozila na taktičkoj razini odlučivanja. Karta terenske mobilnosti vozila u mjerilu 1:25 000 za područje Tišnova (Češka). 46
Sl. 23. Kawasaki B-Force 750 4x4i 48

Sl. 24 Land Rover Defender 110 48
Sl. 25. BOV Patria 49
Sl. 26. Iveco Eurocargo ML 100 E21 49
Sl. 27. BTR-50 50
Sl. 28. Tenk M-84 50
Sl. 29. Pojednostavljeni prikaz sila koje djeluju na vozilo u pokretu na vertikalnom nagibu . 53
Sl. 30. Grafikon vučnih sila cestovnog vozila s četiri stupnja prijenosa brzine 54
Sl. 31. Spajanje više listova u poliedarskoj projekciji 57
Sl. 32. Osnovna geološka karta s lokacijama USDA profila i uzorka prema USCS 59
Sl. 33. Osnovna pedološka karta s lokacijama USDA profila i uzorka prema USCS 60
Sl. 34. Uzorkovanje tla uzorkivačem „Foil sampler“ na lokaciji Lapovci 63
Sl. 35. Ekstrahirani uzorak tla na lokaciji Široko Polje - sjever 64
Sl. 36. Uzorak tla s lokacije Široko Polje – sjever (prije laboratorijske obrade) 65
Sl. 37. Parametri za računanje ispuštenosti pneumatika 70
Sl. 38. a) Pregledna fizička karta odabranih lokacija, b) Digitalni ortofoto snimak s lokacijama mjerenja na lokaciji VP „Gašinci“ 72
Sl. 39. Lokacije mjerenja prohodnosti tla prema: a) nagibu, b) orijentaciji padina, c) tipu tla i d) biljnom pokrovu 73
Sl. 40. Digitalni konusni penetrometar 75
Sl. 41. Digitalni konusni penetrometar s popratnom opremom 76
Sl. 42. *In situ* mjerenje digitalnim konusnim penetrometrom 76
Sl. 43. Sonda za mjerenje vlažnosti tla ML3 Theta Probe 77
Sl. 44. Mjerenja vlažnosti tla na različitim dubinama tla sondom ML3 ThetaProbe 78
Sl. 45. Svrdlo za bušenje tla 79
Sl. 46. Krilna sonda marke Eijkelkamp 81
Sl. 47. Klimatološke i kišomjerne postaje DHMZ-a na širem području istraživanja 82
Sl. 48. Lokacije mjerenja poprečnih profila vodotoka laserskim daljinomjerom 86
Sl. 49. Laserski daljinomjer TruPulse 360°R 87
Sl. 50. Terensko mjerenje poprečnog profila vodotoka uređajem TruPulse 360°R (lokacija 1014) 87
Sl. 51. Mjerenje nosivosti dna vodotoka na lokaciji "V" 89
Sl. 52. Lokacije (I - IX) mjerenja prohodnosti dna stalnih vodotoka 90
Sl. 53. Shematski prikaz izračuna razmaka stabala u šumama 92
Sl. 54. Kultivirane biljne kulture prema ARKOD-u u 2019. godini 93

Sl. 55. Usporedba funkcionalnih principa Jasne tradicionalne logike i neizrazite logike..... 95
Sl. 56. Prikaz grafa funkcije usporenja Land Rover Defendera 110 u odnosu na nagib terena97
Sl. 57. Prikaz tijeka procesa definiranja stupnja usporenja uslijed nagiba reljefa (za vozilo Land Rover Defender 110) unutar vizualnog programskog jezika *Model Builder* (ArcGIS Pro, verzija 2.4.3)..... 98
Sl. 58. Prikaz linearne funkcije usporenja Land Rover Defendera 110 u odnosu na razmak stabala 104
Sl. 59. Definiranje usporenja vozila unutar šumske vegetacije pomoću alata neizrazite logike korištenjem vizualnog programskog jezika *Model Builder*..... 105
Sl. 60. Programski tijek završne analize usporenja vozila u vizualnom programskom jeziku *Model Builder* (primjer izračuna za vozilo Land Rover Defender 110, scenarij: zima/proljeće – mokro)..... 111
Sl. 61. Koeficijenti usporenja Faktora nagiba reljefa za vozilo Iveco Eurocargo ML 100 E21 4x4 114
Sl. 62. Objekti obuhvaćeni faktorom prohodnosti – hrapavost površine ($\boldsymbol{Fhp}$)..... 115
Sl. 63. Distribucija USCS uzoraka nakon prostorne analize prema USDA teksturnom trokutu 117
Sl. 64. Distribucija rezultata prostorne analize USDA uzoraka na dijagramu plastičnosti.... 117
Sl. 65. Dijagrami plastičnosti uzoraka tla prema USCS na kartiranim pedološkim jedinicama 118
Sl. 66. Dijagram plastičnosti tla uzoraka tla prema USCS na amfiglejnim tipovima tla 119
Sl. 67. Karta prohodnosti tla u različitim uvjetima vlažnosti tla izrađena pomoću neizrazite logike 121
Sl. 68. Srednje vrijednosti dnevnih mjerenja prodirnih značajki tla prema lokacijama (vidi Sl. 38. i Sl. 39.) u odabranim periodima u 2019. godini..... 124
Sl. 69. Srednje vrijednosti dnevnih mjerenja vlažnosti tla prema lokacijama na lokacijama (vidi Sl. 38. i Sl. 39.) u odabranim periodima u 2019. godini..... 127
Sl. 70. Prosječne vrijednosti srednjih dnevnih temperatura zraka i prosječne temperature tla na lokacijama (vidi Sl. 38. i Sl. 39.) u odabranim periodima 2019. godine..... 129
Sl. 71. Srednje vrijednosti dnevnih mjerenja nedrenirane vršne i rezidualne posmične čvrstoće tla prema lokacijama (vidi Sl. 38. i Sl. 39.) u odabranim periodima sondom tvrtke Eijkelkamp..... 131
Sl. 72. Posmična čvrstoća tla i količina padalina najvlažnijeg razdoblja tijekom provedenih mjerenja na odabranim lokacijama (vidi Sl. 38. i Sl. 39.) 133

Sl. 73. Padaline u 2019. godini 134
Sl. 74. Padaline po godišnjim dobima 2019. godine 135
Sl. 75. Topografski indeks vlaženja 138
Sl. 76. Odnos nosivosti tla i topografskog indeksa vlaženja (TIV) sa aproksimiranom eksponencijalnom funkcijom 139
Sl. 77. Konusni indeks nosivosti tla na dubini 15 cm 140
Sl. 78. Konusni indeks nosivosti tla na dubini 30 cm 141
Sl. 79. Koeficijenti usporenja zajedničkog utjecaja klizanja vozila i ljepljivosti tla za kotačna vozila 143
Sl. 80. Koeficijenti usporenja za gusjeničare uslijed ljepljivosti tla 144
Sl. 81. Shematski prikaz ovisnosti točnosti visinskog prikaza Zemljine površine i gustoće uzorkovanja izvornih visinskih podataka 145
Sl. 82. Prikaz utjecaja različitih rezolucija rasterskih podataka na kvalitetu i detaljnost prikaza nagiba ravničarskog reljefa 147
Sl. 83. Usporedba poprečnih profila terena na lokaciji 1014 (Kašnica – Satnica Đakovačka zapad) 151
Sl. 84. Prodirne značajke tla na dnu korita stalnih vodotoka (lokacije vidi na Sl. 52.) 152
Sl. 85. Prosječni promjer stabala (cm) na prsnoj visini (1.35m) 153
Sl. 86. Prosječni razmak (m) između stabala unutar šumske sastojine 154
Sl. 87. Utjecaj antropogenih čimbenika na prohodnost vozila 158
Sl. 88. Karte maksimalne moguće brzine kretanja (km/h) Land Rover Defendera 110 (zima/proljeće - mokro) u više mjerila 161
Sl. 89. Karta maksimalne brzine kretanja za Kawasaki B-Force 750 4x4i (ljeto/jesen – suho) 165
Sl. 90. Karta maksimalne brzine kretanja za Land Rover Defender 110 (ljeto/jesen – suho) 166
Sl. 91. Karta maksimalne brzine kretanja za BOV Patria (ljeto/jesen – suho) 167
Sl. 92. Karta maksimalne brzine kretanja za Iveco Eurocargo ML 100 E21 4x4 (ljeto/jesen – suho) 168
Sl. 93. Karta maksimalne brzine kretanja za BTR-50 (ljeto/jesen – suho) 169
Sl. 94. Karta maksimalne brzine kretanja za Tenk M-84 (ljeto/jesen – suho) 170
Sl. 95. Karta maksimalne brzine kretanja za Kawasaki B-Force 750 4x4i (zima/proljeće - mokro) 174
Sl. 96. Karta maksimalne brzine kretanja za Land Rover Defender 110 (zima/proljeće - mokro) 175

Sl. 97. Karta maksimalne brzine kretanja za BOV Patria (zima/proljeće - mokro) 176
Sl. 98. Karta maksimalne brzine kretanja za Iveco Eurocargo ML 100 E21 4x4 (zima/proljeće - mokro) 177
Sl. 99. Karta maksimalne brzine kretanja za BTR-50 (zima/proljeće - mokro) 178
Sl. 100. Karta maksimalne brzine kretanja za Tenk M-84 (zima/proljeće – mokro) 179
Sl. 101. Karta najbržih ruta kretanja i vremenska udaljenost od polazišta za vozilo Land Rover Defender 110 (zima/proljeće – mokro) 181
Sl. 102. Statistički prikaz* TPV (km^2), za period: ljeto/jesen – suho 183
Sl. 103. Statistički prikaz* TPV (km^2), za period: zima/proljeće – mokro 185

POPIS PRILOGA

Prilog 1. Jedinstvena klasifikacija tla USCS 214
Prilog 2. Prodirne značajke tla zimi na lokacijama (vidi Sl. 38. i Sl. 39.) mjerene digitalnim konusnim penetrometrom od 25. veljače do 1. ožujka 2019. godine 218
Prilog 3. Prodirne značajke tla u proljeće na lokacijama (vidi Sl. 38. i Sl. 39.) mjerene digitalnim konusnim penetrometrom od 11. do 15. ožujka 2019. godine 219
Prilog 4. Prodirne značajke tla u proljeće na lokacijama (vidi Sl. 38. i Sl. 39.) mjerene digitalnim konusnim penetrometrom od 30. travnja do 4. svibnja 2019. godine .. 220
Prilog 5. Prodirne značajke tla ljeti na lokacijama (vidi Sl. 38. i Sl. 39.) mjerene digitalnim konusnim penetrometrom od 26. do 30. kolovoza 2019. godine..... 221
Prilog 6. Prodirne značajke tla u jesen na lokacijama (vidi Sl. 38. i Sl. 39.) mjerene digitalnim konusnim penetrometrom od 15. do 19. studenog 2019. godine..... 222
Prilog 7. Prodirne značajke tla u jesen na lokacijama (vidi Sl. 38. i Sl. 39.) mjerene digitalnim konusnim penetrometrom od 25. do 29. studenog 2019. godine..... 223
Prilog 8. Prodirne značajke tla zimi na lokacijama (vidi Sl. 38. i Sl. 39.) mjerene digitalnim konusnim penetrometrom od 16. do 20. prosinca 2019. godine..... 224
Prilog 9. Vlažnost tla zimi na lokacijama (vidi Sl. 38. i Sl. 39.) mjerena sondom ThetaProbe od 25. veljače do 1. ožujka 2019. godine 225
Prilog 10. Vlažnost tla u proljeće na lokacijama (vidi Sl. 38. i Sl. 39.) mjerena sondom ThetaProbe od 11. do 15. ožujka 2019. godine 226
Prilog 11. Vlažnost tla u proljeće na lokacijama (vidi Sl. 38. i Sl. 39.) mjerena sondom ThetaProbe od 30. travnja do 4. svibnja 2019. godine 227
Prilog 12. Vlažnost tla ljeti na lokacijama (vidi Sl. 38. i Sl. 39.) mjerena sondom ThetaProbe od 26. do 30. kolovoza 2019. godine..... 228
Prilog 13. Vlažnost tla u jesen na lokacijama (vidi Sl. 38. i Sl. 39.) mjerena sondom ThetaProbe od 15. do 19. studenog 2019. godine..... 229
Prilog 14. Vlažnost tla u jesen na lokacijama (vidi Sl. 38. i Sl. 39.) mjerena sondom ThetaProbe od 25. do 29. studenog 2019. godine..... 230
Prilog 15. Vlažnost tla zimi na lokacijama (vidi Sl. 38. i Sl. 39.) mjerena sondom ThetaProbe od 16. do 20. prosinca 2019. godine..... 231
Prilog 16. Temperature zraka i tla zimi od 25. veljače do 1. ožujka 2019. godine..... 232
Prilog 17. Temperature zraka i tla u proljeće od 11. do 15. ožujka 2019. godine 233

Prilog 18. Temperature zraka i tla u proljeće od 30. travnja do 4. svibnja 2019. godine 234
Prilog 19. Temperature zraka i tla ljeti od 26. do 30. kolovoza 2019. godine 235
Prilog 20. Temperature zraka i tla u jesen od 15. do 19. studenog 2019. godine 236
Prilog 21. Temperature zraka i tla u jesen od 25. do 29. studenog 2019. godine 237
Prilog 22. Temperature zraka i tla zimi od 16. do 20. prosinca 2019. godine 238
Prilog 23. Vršna i rezidualna čvrstoća tla na lokacijama (vidi Sl. 38. i Sl. 39.) zimi od 25. veljače do 1. ožujka 2019. godine 239
Prilog 24. Vršna i rezidualna čvrstoća tla na lokacijama (vidi Sl. 38. i Sl. 39.) u proljeće od 11. do 15. ožujka 2019. godine 239
Prilog 25. Vršna i rezidualna čvrstoća tla na lokacijama (vidi Sl. 38. i Sl. 39.) u proljeće od 30. travnja do 4. svibnja 2019. godine 240
Prilog 26. Vršna i rezidualna čvrstoća tla na lokacijama (vidi Sl. 38. i Sl. 39.) ljeti od 26. do 30. kolovoza 2019. godine 240
Prilog 27. Vršna i rezidualna čvrstoća tla na lokacijama (vidi Sl. 38. i Sl. 39.) u jesen od 15. do 19. studenog 2019. godine 241
Prilog 28. Vršna i rezidualna čvrstoća tla na lokacijama (vidi Sl. 38. i Sl. 39.) u jesen od 25. do 29. studenog 2019. godine 241
Prilog 29. Vršna i rezidualna čvrstoća tla na lokacijama (vidi Sl. 38. i Sl. 39.) zimi od 16. do 20. prosinca 2019. godine 242

KRATICE

APPRRR – Agencije za plaćanja u poljoprivredi, ribarstvu i ruralnom razvoju

ARKOD – evidencija uporabe poljoprivrednog zemljišta na području Republike Hrvatske

CROTIS - Hrvatski topografski informacijski sustav

DMR – Digitalni model reljefa

DMV – Digitalni model visina

DKP – Digitalni konusni penetrometar

GPS – Globalni položajni sustav

GIS – Geografski informacijski sustav

HŠ – Hrvatske šume

HTRS96/TM – Hrvatski Terestrički Referentni Sustav za epohu 1995.55, poprečne Mercatorove (Gauss-Krügerove) projekcije

IM – Indeks mobilnosti

INT – Indeks nosivosti tla

KI – Konusni indeks

KIV – Konusni indeks vozila

KMMBKV - Karta maksimalnih mogućih brzina kretanja vozila

NATO – Organizacija Sjeveroatlantskog ugovora (engl. *North Atlantic Treaty Organisation*)

NRMM – NATO Reference Mobility Model

OGK – Osnovna geološka karta

OPK – Osnovna pedološka karta

RI – Remodulirani indeks

RNPČT – Rezidualna nedrenirana posmična čvrstoća tla

TIV – Topografski indeks vlaženja

TPV – Terenska prohodnost vozila

USCS – Jedinstvena klasifikacija tla (engl. *Unified Soil Classification System*)

USDA – Američka agronomska klasifikacija tla (engl. *United States Department of Agriculture*)

VNPČT – Vršna nedrenirana posmična čvrstoća tla

WES – Waterways Experiment Station

SAŽETAK

Istraživanja u sklopu agronomije, šumarstva, razminiravanja i u vojne svrhe imaju zajednički istraživački interes, a to je utvrđivanje sposobnosti i ograničenja upotrebe vozila izvan cestovne infrastrukture. Čimbenici koji definiraju pokretljivost vozila na zemljištu su postojeća mreža prometnica, izgrađeni objekti, morfološka, hidrološka i pedološka obilježja zemljišta, vegetacija i meteorološki uvjeti. U predmetnoj tematici koja se odnosi na utvrđivanje pokretljivosti, mobilnosti i općenito ograničavajućih voznih osobina vozila postoji nekoliko sličnih pojmova koji opisuju svojstva zemljišta ili tehničke mogućnosti vozila. Pojmovi u upotrebi su: terenska prohodnost, terenska mobilnost, terenska pokretljivost, terenska prometnost i manevarska sposobnost vozila. Ovaj rad je orijentiran na proučavanja terenske prohodnosti, odnosno na opis morfometrije, struktura i pojava na zemljištu koje definiraju mogućnost pokreta vozila, dok se ostali pojmovi koriste prilikom opisivanja tehničko-taktičkih sposobnosti vozila.

Istraživani su fizičko-geografski elementi koji uvjetuju pokretljivost vozila na zemljištu, odnosno reljef, vode, tlo, vegetacija i klimatsko-meteorološke prilike. Istraživanje njihove prisutnosti na učinkovitost pokreta vozila zahtijevalo je sveobuhvatan multidisciplinaran pristup. Kvantificirana evaluacija terenske mobilnosti vozila zasnovana je na analizi pojedinačnih geografskih subjekata i pojava na zemljištu, odnosno sintezi njihovih atributa i parametara vozila i vozačkih sposobnosti.

Na kontaktnom prostoru Đakovačke lesne zaravni i pobrđa Dilj gore provedena je analiza usporenja vozila kroz GIS model koji je zasnovan na principima neizrazite logike (engl. *Fuzzy logic*). Model je uspostavljen pomoću postojećih podataka CROTIS baze podataka za 2017. godinu (vodene površine, vegetacijski pokrov i antropogeni objekti), CRONO-GIP baze visinskih podataka, Osnovne geološke karte – OGK (1:100 000), Osnovne pedološke karte – OPK (1:50 000), Hrvatskih Šuma d.o.o., podataka o korištenju zemljišta prema ARKOD-u, količini padalina mjernih postaja DHMZ-a. Postojećim prostornim podacima pridruženi su rezultati terenskog kartiranja, *in situ* mjerenja, terenskog uzorkovanja i laboratorijskih analiza tla. Terenskim mjerenjem laserskim daljinomjerom provedena je kontrola točnosti visinskih podataka CRONO GIP baze podataka na temelju kojih je izrađen DMR. Usporedbom rezultata prostornih analiza različitih prostornih rezolucija sloja nagiba padina s provedenim terenskim mjerenjima poprečnih profila hidrografskih objekata u zaravnjenim dijelovima područja

istraživanja, za referentnu rezoluciju modela odabrana je rezolucija ćelija 1x1m. Na temelju 50 poznatih lokacija istraženih profila tla prema USDA granulometrijskoj klasifikaciji provedeno je terensko uzorkovanje uzoraka tla do 50 cm dubine na istovjetnim lokacijama i dodatnim lokacijama (ukupno 72). Potom je provedena laboratorijska analiza uzoraka tla prema USCS klasifikaciji tla. Kartiranjem nisu utvrđene korelacijske veze između dvaju klasifikacijskih sustava tla. Međutim, uspješno je provedeno kartiranje fizikalnih svojstava tla na osnovu kartografskih jedinica OPK i OGK. Utvrđena je dominantna prisutnost grupa tla koje pripadaju glinama niske plastičnosti (CL) i glinama visoke plastičnosti (CH). Provedena su terenska *in situ* mjerenja unutar uskog područja (prostornog obuhvata 3.5 km^2) na 12 lokacija odabranih na temelju njihove geomorfološke, pedološke i vegetacijske heterogenosti. Rezultati *in situ* mjerenja (digitalni konusni penetrometar, sonda za mjerenje vlažnosti, termometar i krilna sonda) uspješno su translatirani na čitavo područje istraživanja koristeći topografski indeks vlaženja (TIV). Korelacijske veze između parametara konusnog indeksa (KI), vlažnosti tla i TIV su bile u rasponu između 0.67-0.95, dok su transformacijski parametri između KI i TIV-a imali koeficijente reprezentativnosti (R^2) između 0.48-0.91. Rezultatima mjerenja KI tijekom svih godišnjih doba (35 dana, odnosno 7 petodnevnih mjerenja), utvrđeno je da se prohodnost tla može raspodijeliti u dva scenarija. Vršne vrijednosti nosivosti tla integrirane su u scenarij „ljeto/jesen – suho“, a minimalne vrijednosti u scenarij „zima/proljeće – mokro“. Mjerenjem je utvrđeno da tijekom ljeta i jeseni nosivost tla nije ograničavajući čimbenik prohodnosti za svih 6 promatranih tipova vozila uključenih u analize. Analizom hoda količine padalina tijekom godine nije utvrđena izravna ovisnost prohodnosti tla i količine padalina, već da na nju utječu i ostali klimatski elementi (temperatura, insolacija, naoblaka i vjetar). Terenskim kartiranjem i mjerenjima utvrđene su granice isušivanja stalnih vodotoka, dok je uslijed prisutnosti vode u vodotocima utvrđeni KI dna vodotoka prenizak za uspješan prelazak svih vozila.

Kvaliteta i točnost izvora i rezultata vlastitih istraživanja omogućila je formiranje ulaznih parametara koji su objedinjeni GIS modelom koristeći principe neizrazite logike. Pomoću neizrazite logike strukturirani su koeficijenti usporenja svih čimbenika u rasponu vrijednosti: neprohodno (0), uvjetno prohodno (0-1) i prohodno (1). Čimbenici su grupirani u 6 grupa faktora: *Faktor nagiba reljefa, Faktor hrapavosti površine, Faktor tla, Hidrološki faktor, Vegetacijski faktor* i *Antropogeni faktor*.

Rezultati su omogućili kartografski prikaz različitih mjerila i analize dostupnosti područja za 6 različitih tipova vozila kroz scenarije „ljeto/jesen – suho“ i „zima/proljeće – mokro“. Scenariji se razlikuju prema godišnjim promjenama u prohodnosti tla, razini vodostaja stalnih

vodotoka i načinu korištenja poljoprivrednog zemljišta. Prema scenariju „ljeto/jesen – suho“, zavisno o tipu vozila, fizičko-geografski čimbenici čine neprohodnim od 0.98 % do 3.15 % područja. Zaključeno je da dominante ograničavajuće čimbenike prohodnosti čine vode (jezera), vinogradi (za vozila šira od 2.5 m) i živičnjaci (Kawasaki B-Force 750 4x4i), zatim nagib reljefa i gustoća šume. Prema scenariju „zima/proljeće – mokro“ promjenom meteoroloških uvjeta tlo postaje prevladavajući faktor mobilnosti vozila stoga se ukupno neprohodno područje uzrokovano prisutnošću ograničavajućih čimbenika povećava u rasponu od 3.14 % do 11.75 % ukupne površine istraživanja.

Istraživano područje pogoduje manevarskim sposobnostima svih vrsta vozila. Blage padine pobrđa, valovita lesna zaravan i zaravnjeni dijelovi terasnih nizina omogućavaju nesmetano pokret vozila. Tlo ne čini zapreku prohodnosti tijekom ljeta i jeseni. Gustoća šuma i velike oranične površine ne predstavljaju ograničenje mobilnosti vozila. Zaključeno je, ukoliko se izuzmu jezera i površine pod vinogradima, da na zapadnom dijelu pobrđa glavni ograničavajući faktor prohodnosti tijekom ljetnih i jesenskih mjeseci predstavljaju nagibi padina. To su konkretno kontaktna područja dolina i završnih dijelova duboko usječenih padina razgranatih grebena. Prohodnost lesne zaravani i terasnih nizina obilježena je mrežom strmo usječenih kanala i neprohodnim tlom u području blago nagnutih dolina i udolina, te zaravnjenih konkavnih uleknuća tijekom zime i u proljeće nakon intenzivnijih i dugotrajnijih kišnih perioda.

SUMMARY

Research in the fields of agronomy, forestry, demining and military purposes has a common research interest: to determine the possibilities and limits of the use of vehicles outside the road infrastructure. Factors that determine vehicle mobility in the field are the existing road network, structural facilities, morphological, hydrological and pedological characteristics of the terrain, vegetation and meteorological conditions. In the field related to the determination of mobility, maneuverability and generally restrictive driving characteristics of vehicles, there are several similar terms describing the characteristics of the terrain or the technical capabilities of the vehicle. The most common terms are: terrain trafficability, cross-country mobility, cross-country movement, cross-country trafficability and vehicle maneuverability. This paper focuses on the study of terrain trafficability, i.e. the description of morphometry, structures and phenomena on the ground that define the possibility of vehicle movement, while other terms are used to describe the technical and tactical capabilities of the vehicles.

In this research, physical-geographical elements that determine the mobility of vehicles on the ground have been studied, i.e. relief, water, soil, vegetation and climatic-meteorological conditions. Research into their presence on vehicles for efficient movement required a comprehensive multidisciplinary approach. A quantified assessment of cross-country mobility of vehicles is based on the analysis of individual geographical subjects and phenomena on the ground, i.e. the synthesis of their characteristics and parameters of vehicles and driving skills.

An analysis of the vehicle deceleration by a GIS model based on the principles of fuzzy logic was carried out in the contact area of the Đakovo loess plateau and the Dilj gora foothills. The model was created using existing data from the CROTIS database state of data according 2017 (water areas, vegetation cover and anthropogenic objects), CRONO-GIP height database (Digital Elevation Model – DEM), Basic geological maps - BGM (1: 100 000), Basic pedological maps - BPM (1:50 000), Hrvatske Šume d.o.o., land use data according to ARKOD, precipitation data from the measuring stations Croatian Meteorological and Hydrological Service. Existing spatial data linked to the results of field mapping, *in- situ* measurements, field sampling and laboratory analyzes of soil. Field measurements with a laser rangefinder were carried out to determine the accuracy of the spatial database CRONO GIP on which base DEM was created. Comparing the results of spatial analyzes of different spatial resolutions of the slope layer with field measurements of cross sections of hydrographic objects in flat parts of

the study area, a resolution of 1x1m was chosen as the reference model resolution. Based on 50 known locations of the investigated soil profiles according to the USDA granulometric classification, field samples of soil samples up to 50 cm depth were taken at identical locations and additional sites (72 in total). Subsequently, a laboratory analysis of the soil samples according to the USCS soil classification was performed. The mapping showed no correlations between the two soil classification systems. However, the mapping of the physical properties of the soil based on the cartographic units BPM and BGM was successfully performed. The predominant occurrence of soil groups belonging to lean clays (CL) and fat clays (CH) was determined. Field *in situ* measurements were carried out within a narrow area (spatial coverage of 3.5 km^2) at 12 sites selected for their geomorphological, pedological and vegetation heterogeneity. The results of the *in- situ* measurements (digital cone penetrometer, soil moisture sensor, thermometer and vane tester) were successfully transferred to the whole research area using the topographic wettnes index (TWI). The correlation relationships between the cone index (CI), soil moisture, and the parameters of TWI were between 0.67-0.95, while the transformation parameters between CI and TWI showed representativeness coefficients (R^2) between 0.48-0.91. The results of the CI measurements during all seasons (35 days with 7 five-day measurements each) showed that soil trafficability can be divided into two scenarios. The peak values of soil bearing capacity were integrated into the scenario "summer / autumn - dry", the minimum values into the scenario "winter / spring - wet". The measurements showed that in summer and autumn the bearing capacity of the soil for all 6 vehicle types included in the analyzes does not limit the factor of trafficability. The analysis of the course of precipitation over the course of the year did not reveal a direct dependence of soil bearing capacity and precipitation, but rather that it is also influenced by other climatic elements (temperature, solar radiation, clouds and wind). Field mapping and measurements determined the limits of runoff from permanent watercourses, while due to the presence of water in watercourses the CI of the watercourse bottom was determined to be too low for successful crossing by vehicles.

The quality and accuracy of the sources and research results enabled the creation of input parameters that were combined within the GIS model according to the principles of fuzzy logic. Using fuzzy logic, the deceleration coefficients of all factors were structured in the value range: between impassable (0), conditionally passable (0-1) and passable (1). The factors were grouped into 6 groups of factors: Slope factor, Surface roughness factor, Soil factor, Hydrological factor, Vegetation factor and Anthropogenic factor.

The results provided maps in different scales and an analysis of the availability of the area for 6 different vehicle types based on through the scenarios "summer / autumn - dry" and "winter / spring - wet". The scenarios differ according to the annual changes in soil bearing capacity, the water level of the permanent watercourses and the cultivation of agricultural land. According to the scenario "summer / autumn - dry", depending on the type of vehicle, 0.98 % to 3.15 % of the area is not traversable due to physical-geographical factors. It was concluded that the dominant limiting factors of trafficability are open waters (lakes), vineyards (for vehicles wider than 2.5 m) and hedges (Kawasaki B-Force 750 4x4i), then the slope of the terrain and the density of the forest. According to the scenario "winter / spring - wet" with the change of meteorological conditions, the soil becomes the dominant factor of vehicle mobility, therefore the total impassable area caused by the presence of limiting factors increases in the range of 3.14 % to 11.75 % of the total survey area.

The area studied favors the maneuverability of all types of vehicles. The gentle slopes of the hills, the undulating light plateau and the flattened parts of the river terrace lowlands allow unhindered movement of vehicles. The soil does impede the movement of vehicles in summer and autumn. The density of the forests and the large arable land do not restrict the mobility of the vehicles. It was concluded that, if lakes and vineyards are excluded, in the western part of the foothills the slopes are the main limiting factor of the terrain trafficbility during the summer and autumn months. These are in particular the contact areas of the valleys and the end parts of the deeply incised slopes of the ramified reefs. The trafficability of the loess plateau and river terrace lowlands is characterized by a network of steeply incised channels and impassable soils in the area of the slightly sloping valleys and valley bottoms and by flattened concave depressions in winter and spring after long and intensive rainy periods.

ŽIVOTOPIS

Hrvoje Heštera je rođen 26. ožujka 1985. godine u Virovitici. Do odlaska na fakultet živio je u Velikim Zdencima. U Grubišnom Polju je 1999. godine završio Osnovnu školu, te potom 2003. godine i Opću gimnaziju. Diplomski smjer *profesora geografije* na Geografskom odsjeku, Prirodoslovno – matematičkog fakulteta u Zagrebu upisao je 2003. godine. Diplomirao je 2009. godine s temom „Preobrazba češke poljoprivrede u uvjetima tranzicije i integracije u EU“ pod vodstvom mentora prof. dr.sc. Dane Pejnovića. U akademskoj godini 2015./2016. upisao je poslijediplomski „Doktorski studij geografije: prostor, regija, okoliš, pejzaž“, Prirodoslovno-matematičkog fakulteta, Sveučilišta u Zagrebu.

Satnik Hrvoje Heštera je djelatna vojna osoba Oružanih snaga Republike Hrvatske od 2010. godine. Kao časnik roda topništva izvršavao je dužnosti zapovjednika voda unutar Topničko-raketne bojne (Gardijsko mehanizirane brigade) smještene na poligonu „Eugen Kvaternik“ u Slunju. Početkom 2014. godine angažiran je kao član projektnog tima VoGIS u projektu VoGIS, s ciljem kreiranja novih vojnih topografskih karata i baza prostornih podataka područja Republike Hrvatske. Od 2015. godine djelatnik je Hrvatskog vojnog učilišta „Dr. Franjo Tuđman“, Centra za obrambene i strateške studije „Janko Bobetko“, u odjelu VoGIS na mjestu časnika za GIS analizu. 2017. godine završio je Naprednu časničku izobrazbu, usmjerenja – geoinformacijska struka.

Od 2015. godine kao član projektnog tima sudjeluje u provedbi projekta „GIS model opće prohodnosti zemljišta“, odobrenog od strane Vijeća za projekte Centra za obrambene i strateške studije „Janko Bobetko“. U sklopu projekta proveo je kartiranje fizikalnih svojstava tla Republike Hrvatske. Također sudjeluje u aktivnostima NATO STO-a (Science & Technology Organization) unutar projektnog tima AVT-308 / 2nd Cooperative Demonstration of Technology (CDT) for Next-Generation NATO Reference Mobility Model (NG-NRMM).

Od 2017. godine sudjeluje u provedbi predavanja i vježbi na vojno-studijskim programima „Vojno vođenje i upravljanje“ i „Vojno inženjerstvo“ na kolegiju „Vojna geografija s topografijom“. Naslovno zvanje Predavača stekao je 2018. godine. U sklopu izobrazbe djelatnika Oružanih snaga provodi tečajeve GIS-a raznih stupnjeva složenosti i sadržaja.

Znanstveni interes mu je vezan uz fizičku geografiju, vojnu geografiju, kartografiju, topografiju i GIS kroz modeliranje prostornih podataka, analize, programiranje i vizualizaciju tematskih geografskih sadržaja. Samostalno i u koautorstvu objavio je 3 znanstvena rada (2 A1), te je sudjelovao s izlaganjima na 4 znanstvene konferencije (2 međunarodne i 2 domaće).

Objavljeni znanstveni radovi:

Heštera, H., 2020: Analysis of pedological factors and USCS in the contact area of Đakovo loess plateau and Dilj gora, Croatia, *Rudarsko-geološko-naftni zbornik*, 35 (1), 13-22, doi:10.17794/rgn.2020.1.2.

Heštera, H., Pahernik, M., 2018: Fizičko-geografski čimbenici terenske prohodnosti vojnih vozila prema metodologijama zapadnoga svijeta, *Hrvatski geografski glasnik*, 80 (2), 5-31, doi:10.21861/HGG.2018.80.02.01.

Zečević, M., Pahernik, M., Heštera, H., 2017: Prostorna analiza utjecaja geografskih i geoloških čimbenika na provedbu desantne operacije kod Galipolja 1915. godine, *Strategos*, 1, 83-107.