

Modeliranje toka i retencije vode na obronačnom pseudogleju u uvjetima uzgoja vinove loze

Magdić, Ivan

Doctoral thesis / Disertacija

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Agriculture / Sveučilište u Zagrebu, Agronomski fakultet**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:204:126670>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

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



Repository / Repozitorij:

[Repository Faculty of Agriculture University of Zagreb](#)





Sveučilište u Zagrebu

AGRONOMSKI FAKULTET

Ivan Magdić

**MODELIRANJE TOKA I RETENCIJE VODE
NA OBRONAČNOM PSEUDOGLEJU U
UVJETIMA UZGOJA VINOVE LOZE**

DOKTORSKI RAD

Zagreb, 2021.



University of Zagreb

FACULTY OF AGRICULTURE

Ivan Magdić

**MODELING SOIL WATER FLOW AND
RETENTION ON PSEUDOGLEY SOIL IN
SLOPING VINEYARD**

DOCTORAL THESIS

Zagreb, 2021



Sveučilište u Zagrebu

AGRONOMSKI FAKULTET

Ivan Magdić

**MODELIRANJE TOKA I RETENCIJE VODE
NA OBRONAČNOM PSEUDOGLEJU U
UVJETIMA UZGOJA VINOVE LOZE**

DOKTORSKI RAD

Mentori:

Prof.dr.sc. Stjepan Husnjak

Doc.dr.sc. Vilim Filipović

Zagreb, 2021.



University of Zagreb

FACULTY OF AGRICULTURE

Ivan Magdić

**MODELING SOIL WATER FLOW AND
RETENTION ON PSEUDOGLEY SOIL IN
SLOPING VINEYARD**

DOCTORAL THESIS

Supervisors:
Prof. Stjepan Husnjak, PhD
Asst. prof. Vilim Filipović, PhD

Zagreb, 2021

Bibliografski podaci:

- Znanstveno područje: Biotehničke znanosti
- Znanstveno polje: Poljoprivreda (agronomija)
- Znanstvena grana: Ekologija i zaštita okoliša
- Institucija: Sveučilište u Zagrebu Agronomski fakultet, Zavod za pedologiju
- Voditelji doktorskog rada: prof. dr.sc Stjepan Husnjak i doc.dr.sc. Vilim Filipović
- Broj stranica: 168
- Broj slika: 91
- Broj tablica: 29
- Broj priloga: 3
- Broj literaturnih referenci: 254
- Datum obrane doktorskog rada: 15.11.2021.
- Sastav povjerenstva za obranu doktorskog rada:
Predsjednik: prof. dr.sc. Mario Sraka, izvanredni profesor
Član: prof.dr.sc. Darko Preiner, izvanredni profesor
Član: prof.dr.sc. Stanko Ružičić, izvanredni profesor

Rad je pohranjen u: Nacionalnoj i sveučilišnoj knjižnici u Zagrebu, Ulica Hrvatske bratske zajednice 4 p.p. 550, 10 000 Zagreb, Knjižnici Sveučilišta u Zagrebu Agronomskog Fakulteta, Svetošimunska cesta 25, 10 000 Zagreb.

Tema rada prihvaćena je na sjednici Fakultetskog vijeća Agronomskog Fakulteta Sveučilišta u Zagrebu, održanoj dana 09.07.2019. te odobrena na sjednici Senata Sveučilišta u Zagrebu, održanoj 10. prosinca 2019.

SVEUČILIŠTE U ZAGREBU
AGRONOMSKI FAKULTET

IZJAVA O IZVORNOSTI

Ja, **Ivan Magdić**, izjavljujem da sam samostalno izradio doktorski rad pod naslovom:

**MODELIRANJE TOKA I RETENCIJE VODE NA OBRONAČNOM PSEUDOGLEJU U
UVJETIMA UZGOJA VINOVE LOZE**

Svojim potpisom jamčim:

- da sam jedini autor ovoga doktorskog rada;
- da je doktorski rad izvorni rezultat mojeg rada te da se u izradi nisam koristio drugim izvorima osim onih koji su u njemu navedeni;
- da sam upoznat s odredbama Etičkog kodeksa Sveučilišta u Zagrebu (Čl. 19).

U Zagrebu, 15.11.2021.

Potpis doktoranda

Ovu disertaciju ocijenilo je povjerenstvo u sastavu:

1. Prof.dr.sc. Mario Sraka

izvanredni profesor Agronomskog fakulteta Sveučilišta u Zagrebu

2. Prof. dr.sc. Darko Preiner

izvanredni profesor Agronomskog fakulteta Sveučilišta u Zagrebu

3. Prof.dr.sc. Stanko Ružičić

izvanredni profesor Rudarsko geološko naftnog fakulteta Sveučilišta u Zagrebu

Disertacija je obranjena na Agronomskom fakultetu Sveučilišta u Zagrebu, 15.11.2021., pred povjerenstvom u sastavu:

1. Prof.dr.sc. Mario Sraka

izvanredni profesor Agronomskog fakulteta Sveučilišta u Zagrebu

2. Prof. dr.sc. Darko Preiner

izvanredni profesor Agronomskog fakulteta Sveučilišta u Zagrebu

3. Prof.dr.sc. Stanko Ružičić

izvanredni profesor Rudarsko geološko naftnog fakulteta Sveučilišta u Zagrebu

PODACI O MENTORIMA

Stjepan Husnjak, rođen je 1. rujna 1959. godine u Špišić Bukovici gdje je završio osnovnu školu dok je srednju školu završio je u Virovitici. Poljoprivredni fakultet u Zagrebu završio je 1985. godine Na Sveučilištu u Zagrebu Agronomskom fakultetu poslijediplomski studij iz znanstvenog područja "Pedologija" završio je 1993. godine Disertaciju je obranio 2000. godine. Od 1986. do danas radi na Sveučilištu u Zagrebu Zavodu za pedologiju. Od 2015. godine u zvanju je redovitog profesora u trajnom zvanju. Trenutno je koordinator više predmeta na preddiplomskom, diplomskom i poslijediplomskom studiju, te predstojnik Zavoda za pedologiju. Kao autor ili koautor objavio je veliki broj znanstvenih i stručnih radova. Autor je sveučilišnog udžbenika „Sistematika tala Hrvatske“ iz 2014. godine. Na studijskim usavršavanjima i specijalizacijama, boravio je na više sveučilišta u Svijetu. Sudjelovao je na više svjetskih kongresa međunarodnog pedološkog i kartografskog društva. Voditelj je ili suradnik na više znanstvenih i stručnih projekata. Član je Hrvatskog tloznanstvenog društva, Hrvatskog društva za odvodnju i navodnjavanje, Hrvatskog kartografskog društva, te International Society of Soil Science.

Prof.dr.sc. Stjepan Husnjak

Doc. dr. sc. Vilim Filipović rođen je 2. travnja. 1984. u Zagrebu gdje je završio osnovno i srednjoškolsko obrazovanje te je 2008. godine diplomirao na Agronomskom Fakultetu Sveučilišta u Zagrebu na kojemu se i zapošljava. Tijekom 2009. godine upisuje doktorski studij Poljoprivredne znanosti koji završava 2012. godine obranom doktorskog rada naslova „Primjena numeričkog modeliranja u procjeni kretanja vode i koncentracije nitrata u uvjetima hidromorfni tala“, izrađenim pod mentorstvom prof. emeritusa dr. sc. Dragutina Petošića. Za navedeni rad dobiva nagradu Hrvatskih voda za najbolju disertaciju. Nakon doktorskog studija (2013. - 2014.) zapošljava se kao poslijedoktorand u prestižnom znanstvenom institutu INRA (Francuska) te se bavi modeliranjem pronosa pesticida u tlu. U suradnji s djelatnicima Agronomskog fakulteta i pod uredništvom prof. dr. sc. Gabrijela Ondrašeka izdaje knjigu „Voda u agroekosustavima“ za koju je autorima dodijeljena nagrada Hrvatskih voda u 2015. godini. Uz navedeno autor je još nekoliko poglavlja u znanstvenim knjigama. Od 2016. godine radi na Zavodu za melioracije kao docent gdje izvodi nastavu na preddiplomskom, diplomskom i doktorskome studiju. Najveći dio nastavnih aktivnosti provodi na diplomskom studiju Melioracije i Agroekologija, diplomskom studiju na engleskom jeziku - INTEREnAgro te na novom (od 2019.) diplomskom studiju Obnovljivi izvori energije i gospodarenje otpadom. Dosada je bio mentor na 16 diplomskih i završnih radova. Doc. dr. sc. Vilim Filipović redovito sudjeluje u programima ERASMUS, ERASMUS+ i Akademske mobilnosti u težnji za međunarodnom suradnjom i znanstvenim usavršavanjem iz područja agroekologije. Dosada je boravio na vrhunskim međunarodnim institucijama kao što su: CSIRO, Penn State University, University of Florida, University of California, Swedish University of Agricultural Sciences, University of Natural Resources and Life Sciences (BOKU, Austrija, Beč), INRA (Francuska) i ZALF (Njemačka). Područje znanstvenog interesa uključuje procese toka vode i transporta tvari u tlu, monitoring tla i vode u agroekosustavima, modeliranje transporta nutrijenata i pesticida te procjenu hidrauličkih parametara tla u nesaturiranim uvjetima. Bio je voditelj nekoliko međunarodnih znanstvenih projekata, te je trenutno voditelj Uspostavnog istraživačkog projekta Hrvatske zaklade za znanost. Iz navedene je tematike objavio 45 znanstvenih radova indeksirana u bazama podataka WOS (h indeks 9) te prezentirao radove na mnogim međunarodnim i nacionalnim znanstvenim skupovima. Izabran je u urednički odbor znanstvenog časopisa Soil Science Society of America Journal (WoS Q3) i Vadose Zone Journal (WoS Q2). Aktivan je član Hrvatskog tloznanstvenog društva, Soil Science Society of America (SSSA) te je sudjelovao u organizaciji kongresa navedenih društava. Također je član Odbora za znanost i istraživanje te Međunarodnu suradnju Agronomskog fakulteta, European Geoscience Union i International Soil Modeling Consortium.

Doc. Dr. sc. Vilim Filipović

Zahvale

*Veliko hvala mojim mentorima,
prof.dr.sc. Stjepanu Husnjaku, koji mi je omogućio izradu ove disertacije i koji je svojom
nesebičnom pomoći i sugestijama aktivno sudjelovao u provedbi istraživanja.
doc.dr.sc. Vilimu Filipoviću zahvaljujem na nesebičnoj pomoći, sugestijama i komentarima
tijekom cijelog razdoblja istraživanja i pisanja disertacije, a posebno na pomoći pri korištenju
HYDRUS numeričkog modela.*

*Hvala i svim članovima Povjerenstva za ocjenu i obranu disertacije na vrijednim komentarima
i sugestijama.*

*Veliko hvala svim djelatnicima Mladine plus d.d. posebice direktoru Marinku Baljku,
dipl.ing.agr. te tehnologinji Ana-Mariji Adam, dipl.ing.agr. na susretljivosti i ustupljanju
lokacije za provedbu istraživanja.*

*Veliko hvala kolegi i prijatelju doc.dr.sc. Toniju Safneru, na konstruktivnim sugestijama ali i
kritikama te velikoj pomoći pri statističkoj obradi rezultata istraživanja.*

*Zahvaljujem kolegi i prijatelju doc.dr.sc. Vedranu Rubiniću na pomoći prilikom osmišljavanja
istraživanja te opisa pedoloških profila.*

*Hvala, doc.dr.sc. Hrvoju Hegedušu, sa Fakulteta elektrotehnike i računarstva koji je prilikom
nabavke, instalacije ali i tijekom trajanja cijelog istraživanja bio podrška za funkcioniranje
senzora korištenih u terenskom istraživanju.*

*Hvala prof.dr.sc. Radki Kodešovoj te dr.sc. Alešu Klementu sa Czech University of Life
Sciences (Prag, Republika Češka) na pomoći oko procjene poroznog sustava tla pomoću CT
skenera.*

Hvala i Zlatanu za pomoć pri grafičkoj izradi sheme pokusa.

*Zahvaljujem i svim kolegama sa Zavoda za pedologiju Agronomskog fakulteta na podršci
prilikom izrade disertacije.*

*I na kraju, najviše HVALA molim roditeljima, bratu i sestri te Ani na podršci i ohrabrenjima.
Hvala im što su cijelo vrijeme vjerovali u mene.*

Ivan Magdić

Popis kratica:

CT – *computed tomography*

CV – koeficijent korelacije

DHMZ – Državni hidrometeorološki zavod

FAO – *Food and Agriculture Organization of the United Nations*

IPCC – *International panel of climate change*

Kv – kapacitet tla za vodu

Kz – kapacitet tla za zrak

P – ukupni porozitet

RH – Republika hrvatska

RMZ – redoksimorfne značajke

RVZ – relativna vlaga zraka

TDR – *Time domain reflectometry*

Popis tablica:

Tablica 4.1. Minimalne, maksimalne, srednje vrijednosti te koeficijenti varijacije za fizikalna svojstva tla po pozicijama obronka

Tablica 4.2. Minimalne, maksimalne, srednje vrijednosti te koeficijenti varijacije za kemijska svojstva tla po pozicijama obronka

Tablica 4.3. Dubine i oznake horizonata prema Husnjak (2014.) i WBR (2014.) pojedinim pozicijama obronka

Tablica 4.4. Dominantna boja tla za Ap i Bg horizont na P1 do P5 pozicijama na istraživanom obronku

Tablica 4.5. Prikaz vodnog potencijala tla i vodnog potencijala vinove loze (mjenog u jutro i u podne) te korelacijski koeficijenti

Tablica 4.6. Prikaz vodnog potencijala vinove loze i srednje dnevne relativne vlage zraka te korelacijski koeficijenti

Tablica 4.7. Teksturni sastav tla na pet pozicija istraživnog obronka do dubine od 2 metra.

Tablica 4.8. Teksturane oznake Ap i Bg horizonta na istraživanim pozicijama obronka u redu i međurednom prostoru vinograda

Tablica 4.9. ANOVA tablica za teksturni sastav tla istraživanih profila

Tablica 4.10. ANOVA tablica za fizikalna svojstva tla istraživanih profila

Tablica 4.11. Kemijska svojstva tla (pH i sadržaj humusa) istraživanih profila (P1 – P5) do dubine od dva metra.

Tablica 4.12. ANOVA tablica za kemijska svojstva istraživanih profila

Tablica 4.13. ANOVA tablica za vodno-retencijske značajke tla

Tablica 4.14. Vodno-retencijske značajke tla na istraživanoj lokaciji određene na tlačnom ekstraktoru

Tablica 4.15. Prikaz diferencijalne poroznosti u međuredu na istraživanim pozicijama obronka

Tablica 4.16. Prikaz K_s – a odrađenog na aparatu za serijsko određivanje vodopropusnosti i K - sat uređaju

Tablica 4.17. Ukupni i broj crvenih piksela (% pora) na P1 poziciji te u redu i međurednom prostoru vinograda.

Tablica 4.18. Hidraulički parametri dobiveni pomoću HYPROP-FIT softvera korištenjem Van Genuchten original modela uz prikaz statističke pouzdanosti (*RMSE*)

Tablica 4.19. Hidraulički parametri dobiveni pomoću HYPROP-FIT softvera korištenjem Van Genuchten bimodal modela uz prikaz statističke pouzdanosti (*RMSE*)

Tablica 4.20. Prikaz statističkih podataka utjecaja datuma, reda/međureda, pozicije na obronku te njihovih interakcija na sadržaj vlage u tlu dobivenih temeljem linearnog modela

Tablica 4.21. Prosječni sadržaj vlage u tlu tijekom istraživanog razdoblja pet na pozicija obronka u međuredu i redu vinograda te u površinskom (A_p) i potpovršinskom (B_g) horizontu

Tablica 4.22. Prikaz statističkih podataka utjecaja interakcije reda/međureda i pozicije na obronku na sadržaj vlage u tlu dobivenih temeljem linearnog modela

Tablica 4.23. R^2 , *MAE* i *RMSE* za simulacije sa hidrauličkim značajkama iz HYPROP-a

Tablica 4.24. Hidraulički parametri iz ROSETTA – softvera korištenjem „tipa pet“ pedotransferne funkcije

Tablica 4.25. R^2 , *MAE* i *RMSE* za simulacije sa hidrauličkim značajkama iz ROSETTA – e

Tablica 4.26. Hidraulički parametri dobiveni iz inverznog modela

Tablica 4.27. R^2 , *MAE* i *RMSE* za simulacije sa hidrauličkim značajkama nakon inverznog modeliranja (2019. godina)

Tablica 4.28. R^2 , *MAE* i *RMSE* za simulacije sa hidrauličkim značajkama nakon inverznog modeliranja (2020. godina)

Tablica 8.1. Volumetrijski sadržaj vlage [$\text{cm}^3 \text{ cm}^{-3}$] u tlu određen gravimetrijskom metodom tijekom 2019. godine

Popis slika:

Slika 2.1. Dijelovi obronka, prilagođeno prema FAO (2006.)

Slika 2.2. Klasifikacija nagiba s obzirom na oblik obronka prema FAO (2006.)

Slika 2.3. Rasprostranjenost pseudogleja (a) i pseudogleja obronačnog (b) na području RH prema Husnjaku, (2014.)

Slika 3.1. Lokacija istraživanja (prilagođeno prema Google Earth Pro) u Jastrebarskom

Slika 3.2. Matični supstrati šireg područja istraživane lokacije (legenda se odnosi na označeno područje istraživane lokacije) prema Husnjaku (2014.).

Slika 3.3. Grafički prikaz oborina i temperatura tijekom istraživanih godina (2019. i 2020.) i višegodišnji prosjeci (1981. – 2018.)

Slika 3.4. Shema pokusa u Jastrebarskom s prostornim prikazom provedenih istraživanja

Slika 3.5. Uzorkovanje tla u neporušenom stanju u cilindrima volumena 100 cm³ (a) i volumena 250 cm³ (b i c)

Slika 3.6. Analiza proraštenosti tla korijena metodom lica profila na P2 poziciji

Slika 3.7. Postavljanje i položaj TDR senzora i tenziometara na P3 poziciji

Slika 3.8. Razvodna kutija (lijevo) i centralna bazna stanica sa dataloggerom (desno)

Slika 3.9. Prikaz sustava za površinsko otjecanje postavljen u međuredni prostor na istraživanoj lokaciji

Slika 3.10. Uzorkovanje kolona tla u međuredu i redu na istraživanoj lokaciji

Slika 3.11. Uzorkovanje kolona tla za CT skeniranje poroznog sustava tla

Slika 3.12. Mjerenje vodnog potencijala lista vinove loze

Slika 3.13. Shema HYPROP sustava i prikaz mjerenja

Slika 3.14. Shema K-sat sustava i prikaz mjerenja

Slika 3.15. Priprema tla s kolonama i kolone tla tijekom analiza

Slika 3.16. Primjer jedne pozicije u HYDRUS 1D grafičkom sučelju

Slika 3.17. Shema distribucije horizonata tla (Ap, Bg, Cg, 2Cg) po pozicijama (P1 - P5) u HYDRUS 2D modelu za simulacije toka vode na padini istraživanog područja

Slika 4.1. Prikaz pedoloških profila P1 – P5 na istraživanom obronku. Crvena linija označava granicu između površinskog (Ap) i potpovršinskog (Bg) horizonta.

Slika 4.2. Grafički prikaz zastupljenosti veličine i brojnosti korijenja po dubini profila na poziciji P1 u međuredu (lijevo) i u redu (desno) vinograda.

Slika 4.3. Grafički prikaz zastupljenosti veličine i brojnosti korijenja po dubini profila na poziciji P2 u međuredu (lijevo) i u redu (desno) prostoru vinograda.

Slika 4.4. Grafički prikaz zastupljenosti veličine i brojnosti korijenja po dubini profila na poziciji P3 u međuredu (lijevo) i u redu (desno) vinograda.

Slika 4.5. Grafički prikaz zastupljenosti veličine i brojnosti korijenja po dubini profila na poziciji P4 u međuredu (lijevo) i u redu (desno) vinograda.

Slika 4.6. Grafički prikaz zastupljenosti veličine i brojnosti korijenja po dubini profila na poziciji P5 u međuredu (lijevo) i u redu (desno) vinograda.

Slika 4.7. Prosječni sadržaj pijeska na istraživanim pozicijama obronka, u redu i međurednom prostoru vinograda te za Ap i Bg horizonte. Različita slova dodijeljena pozicijama ukazuju na statistički značajne razlike između položaja (P1 – P5) te reda i međurednog prostora u istom horizontu.

Slika 4.8. Prosječni sadržaj praha na istraživanim pozicijama obronka, u redu i međurednom prostoru vinograda te za Ap i Bg horizonte. Različita slova dodijeljena pozicijama ukazuju na statistički značajne razlike između položaja (P1 – P5) te reda i međurednog prostora u istom horizontu.

Slika 4.9. Prosječni sadržaj gline na istraživanim pozicijama obronka, u redu i međurednom prostoru vinograda te za Ap i Bg horizonte. Različita slova dodijeljena pozicijama ukazuju na statistički značajne razlike između položaja (P1 – P5) te reda i međurednog prostora u istom horizontu.

Slika 4.10. Prosječne vrijednosti volumne gustoće na istraživanim pozicijama obronka, u redu i međurednom prostoru vinograda te za Ap i Bg horizonte. Različita slova dodijeljena pozicijama ukazuju na statistički značajne razlike između položaja (P1 – P5) te reda i međurednog prostora u istom horizontu.

Slika 4.11. Prosječne vrijednosti gustoće čvrstih čestica tla na istraživanim pozicijama obronka, u redu i međurednom prostoru vinograda te za Ap i Bg horizonte. Različita slova dodijeljena pozicijama ukazuju na statistički značajne razlike između položaja (P1 – P5) te reda i međurednog prostora u istom horizontu.

Slika 4.12. Prosječne vrijednosti kapaciteta tla za vodu (Kv) na istraživanim pozicijama obronka, u redu i međurednom prostoru vinograda te za Ap i Bg horizonte. Različita slova dodijeljena pozicijama ukazuju na statistički značajne razlike između položaja (P1 – P5) te reda i međurednog prostora u istom horizontu.

Slika 4.13. Prosječne vrijednosti kapaciteta tla za zrak (Kz) na istraživanim pozicijama obronka, u redu i međurednom prostoru vinograda te za Ap i Bg horizonte. Različita slova dodijeljena pozicijama ukazuju na statistički značajne razlike između položaja (P1 – P5) te reda i međurednog prostora u istom horizontu.

Slika 4.14. Prosječne vrijednosti ukupnog poroziteta (P) na istraživanim pozicijama obronka, u redu i međurednom prostoru vinograda te za Ap i Bg horizonte. Različita slova dodijeljena pozicijama ukazuju na statistički značajne razlike između položaja (P1-P5) te reda i međurednog prostora u istom horizontu.

Slika 4.15. Prosječne vrijednosti pH (KCl i H₂O) na istraživanim pozicijama obronka, u redu i međurednom prostoru vinograda te u Ap i Bg horizontu. Različita slova dodijeljena pozicijama ukazuju na statistički značajne razlike između položaja (P1-P5) te reda i međurednog prostora u istom horizontu.

Slika 4.16. Prosječne vrijednosti sadržaja humusa na istraživanim pozicijama obronka, u redu i međurednom prostoru vinograda te u Ap i Bg horizontu. Različita slova dodijeljena pozicijama ukazuju na statistički značajne razlike između položaja (P1-P5) te reda i međurednog prostora u istom horizontu.

Slika 4.17. Istek (ml) iz kolona tla na P1, P3 i P5 poziciji obronka u redu i međurednom prostoru vinograda

Slika 4.18. Prikaz poroznog sustava P1 pozicije skeniranog pomoću CT skenera. a i b slike predstavljaju red, dok c i d predstavljaju međured vinograda.

Slika 4.19. Srednje vrijednosti volumena površinskog otjecanja tijekom istraživanog razdoblja

Slika 4.20 Retencijske krivulje P1 pozicije dobivene korištenjem Van Genuchten original modela pomoću HYPROP–FIT softvera

Slika 4.21. Retencijske krivulje P1 pozicije dobivene korištenjem Van Genuchten bimodal modela pomoću HYPROP–FIT softvera

Slika 4.22. Retencijske krivulje P3 pozicije dobivene korištenjem Van Genuchten original modela pomoću HYPROP–FIT softvera

Slika 4.23. Retencijske krivulje P3 pozicije dobivene korištenjem Van Genuchten bimodal modela pomoću HYPROP–FIT softvera

Slika 4.24. Retencijske krivulje P5 pozicije dobivene korištenjem Van Genuchten original modela pomoću HYPROP–FIT softvera

Slika 4.25. Retencijske krivulje P5 pozicije dobivene korištenjem Van Genuchten bimodal modela pomoću HYPROP–FIT softvera

Slika 4.26. Hidrauličke krivulje P1 pozicije dobivene korištenjem Van Genuchten original modela pomoću HYPROP–FIT softvera

Slika 4.27. Hidrauličke krivulje P1 pozicije dobivene korištenjem Van Genuchten bimodal modela pomoću HYPROP–FIT softvera

Slika 4.28. Hidrauličke krivulje P3 pozicije dobivene korištenjem Van Genuchten original modela pomoću HYPROP–FIT softvera

Slika 4.29. Hidrauličke krivulje P3 pozicije dobivene korištenjem Van Genuchten bimodal modela pomoću HYPROP–FIT softvera

Slika 4.30. Hidrauličke krivulje P5 pozicije dobivene korištenjem Van Genuchten original modela pomoću HYPROP–FIT softvera

Slika 4.31. Hidrauličke krivulje P5 pozicije dobivene korištenjem Van Genuchten bimodal modela pomoću HYPROP–FIT softvera

Slika 4.32. Grafički prikaz volumetrijskog sadržaja vlage tijekom razdoblja istraživanja u redu i međurednom prostoru vinograda za površinski (Ap) horizont.

Slika 4.33. Grafički prikaz volumetrijskog sadržaja vlage tijekom razdoblja istraživanja u redu i međurednom prostoru vinograda za potpovršinski (Bg) horizont. U Bg horizontu u međurednom prostoru, prikazane su vrijednosti volumetrijskog sadržaja vlage u tlu određeng temeljem gravimetrijske metode, zbog previsokih očitanja sadržaja vlage u tlu putem TDR senzora.).

Slika 4.34. Dinamika vlage u tlu na poziciji P1 u razdoblju od 24.4.2019. do 31.12.2020.

Slika 4.35. Dinamika vlage u tlu na poziciji P2 u razdoblju od 24.4.2019. do 31.12.2020.

Slika 4.36. Dinamika vlage u tlu na poziciji P3 u razdoblju od 24.4.2019. do 31.12.2020.

Slika 4.37. Dinamika vlage u tlu na poziciji P4 u razdoblju od 24.4.2019. do 31.12.2020.

Slika 4.38. Dinamika vlage u tlu na poziciji P4 u razdoblju od 24.4.2019. do 31.12.2020.

Slika 4.39. HYDRUS 1D simulacije sa hidrauličkim parametrima iz HYPROP–a za poziciju P1. Slika gore – međured, slika dolje – red.

Slika 4.40. HYDRUS 1D simulacija sa hidrauličkim parametrima iz HYPROP–a za poziciju P3. Slika gore – međured, slika dolje – red.

Slika 4.41. HYDRUS 1D simulacije sa hidrauličkim parametrima iz HYPROP–a za poziciju P5. Slika gore – međured, slika dolje – red.

Slika 4.42. HYDRUS 1D simulacije sa hidrauličkim parametrima iz ROSETTA softvera za poziciju P1. Slika gore – međured, slika dolje – red.

Slika 4.43. HYDRUS 1D simulacije sa hidrauličkim parametrima iz ROSETTA softvera za poziciju P2. Slika gore – međured, slika dolje – red.

Slika 4.44. HYDRUS 1D simulacije sa hidrauličkim parametrima iz ROSETTA softvera za poziciju P3 u međuredu

Slika 4.45. HYDRUS 1D simulacije sa hidrauličkim parametrima iz ROSETTA softvera za poziciju P4. Slika gore – međured, slika dolje – red.

Slika 4.46. HYDRUS 1D simulacije sa hidrauličkim parametrima iz ROSETTA softvera za poziciju P5. Slika gore – međured, slika dolje – red

Slika 4.47. Prikaz inverznog modeliranja za poziciju P1 u razdoblju od 13.9. do 12.10.2019. godine.

Slika 4.48. Prikaz inverznog modeliranja za poziciju P2 u razdoblju od 13.9. do 12.10.2019. godine. (zbog prevelikih vrijednosti sadržaja vlage očitanih TDR senzorom izbačene su vrijednosti za Bg horizont u međurednom prostoru).

Slika 4.49. Prikaz inverznog modeliranja za poziciju P3 u razdoblju od 13.9. do 12.10.2019. godine.

Slika 4.50. Prikaz inverznog modeliranja za poziciju P4 u razdoblju od 13.9. do 12.10.2019. godine.

Slika 4.51. Prikaz inverznog modeliranja za poziciju P5 u razdoblju od 13.9. do 12.10.2019. godine.

Slika 4.52. Prikaz izmjerenih i simuliranih vrijednosti sadržaj vlage u tlu tijekom 2019. godine na poziciji P1. Slika gore – međured, slika dolje – red.

Slika 4.53. Prikaz izmjerenih i simuliranih vrijednosti sadržaj vlage u tlu tijekom 2019. godine na poziciji P2. Slika gore – međured, slika dolje – red. (HYDRUS simulacija za međured, Bg horizont nije provedena zbog prevelikih vrijednosti očitanih TDR senzorom)

Slika 4.54. Prikaz izmjerenih i simuliranih vrijednosti sadržaj vlage u tlu tijekom 2019. godine na poziciji P3. Slika gore – međured, slika dolje – red.

Slika 4.55. Prikaz izmjerenih i simuliranih vrijednosti sadržaja vlage u tlu tijekom 2019. godine na poziciji P4. Slika gore – međured, slika dolje – red.

Slika 4.56. Prikaz izmjerenih i simuliranih vrijednosti sadržaj vlage u tlu tijekom 2019. godine na poziciji P5. Slika gore – međured, slika dolje – red.

Slika 4.57. Prikaz izmjerenih i simuliranih vrijednosti sadržaj vlage u tlu tijekom 2020. godine na poziciji P1. Slika gore – međured, slika dolje – red.

Slika 4.58. Prikaz izmjerenih i simuliranih vrijednosti sadržaj vlage u tlu tijekom 2020. godine na poziciji P2. Slika gore – međured, slika dolje – red. (HYDRUS simulacija za međured, Bg horizont nije provedena zbog prevelikih vrijednosti očitanih TDR senzorom)

Slika 4.59. Prikaz izmjerenih i simuliranih vrijednosti sadržaj vlage u tlu tijekom 2020. godine na poziciji P3. Slika gore – međured, slika dolje – red.

Slika 4.60. Prikaz izmjerenih i simuliranih vrijednosti sadržaj vlage u tlu tijekom 2020. godine na poziciji P4. Slika gore – međured, slika dolje – red.

Slika 4.61. Prikaz izmjerenih i simuliranih vrijednosti sadržaj vlage u tlu tijekom 2020. godine na poziciji P5. Slika gore – međured, slika dolje – red.

Slika 4.62. Simulirane vrijednosti volumetrijske količine vode u tlu ($\text{cm}^3 \text{ cm}^{-3}$) pomoću HYDRUS 2D modela za vrh i dno obronka u redu i međuredu za razdoblje 26.04.2019. do 31.12.2020.

Slika 4.63. Simulirane vrijednosti vodnog potencijala tla (cm) pomoću HYDRUS 2D programa za vrh i dno obronka u redu i međuredu za razdoblje 26.04.2019. do 31.12.2020.

Slika 4.64. Simulirane vrijednosti infiltracije, površinskog otjecanja i isteka vode na dnu obronka (cm) pomoću HYDRUS 2D programa u redu i međuredu za razdoblje 26.04.2019. do 31.12.2020.

Slika 4.65. Simulirane vrijednosti količine vode u tlu ($\text{cm}^3 \text{ cm}^{-3}$) pomoću HYDRUS 2D programa u redu vinograda za suhi (26.10.2019.) i vlažni (31.12.2020.) period. Suhi period: 5 dana bez oborina prije prikaza. Vlažni period: 45,21 mm oborina u 5 dana prije prikaza.

Slika 4.66. Simulirane vrijednosti količine vode u tlu ($\text{cm}^3 \text{ cm}^{-3}$) pomoću HYDRUS 2D programa u međuredu vinograda za suhi (26.10.2019.) i vlažni (31.12.2020.) period. Suhi period: 5 dana bez oborina prije prikaza. Vlažni period: 45,21 mm oborina u 5 dana prije prikaza.

Slika 4.67. Simulirane vrijednosti vodnog potencijala tla (cm) na dan 31.12. 2020. (završni dan simulacija, gore), za blagi klimatski scenarij prema IPCC za red i međured obronka. Simulirane vrijednosti infiltracije, površinskog otjecanja i isteka vode (cm) na dnu obronka pomoću HYDRUS 2D programa u redu i međuredu za razdoblje tijekom 2020. godine prema IPCC blagom scenariju.

Slika 4.68. Simulirane vrijednosti vodnog potencijala tla (cm) na dan 31.12. 2020. (završni dan simulacija, gore), za srednji klimatski scenarij prema IPCC za red i međured padine. Simulirane vrijednosti infiltracije, površinskog otjecanja i isteka vode na dnu padine (cm) pomoću HYDRUS 2D programa u redu i međuredu za razdoblje tijekom 2020. godine prema IPCC srednjem scenariju.

Slika 4.69. Simulirane vrijednosti vodnog potencijala tla (cm) na dan 31.12. 2020. (završni dan simulacija, gore), za ekstremni klimatski scenarij prema IPCC za red i međured padine. Simulirane vrijednosti infiltracije, površinskog otjecanja i isteka vode na dnu padine (cm) pomoću HYDRUS 2D programa u redu i međuredu za razdoblje tijekom 2020. godine prema IPCC ekstremnom scenariju.

Slika 8.1. Prikaz reljefa lokacije danas (lijevo) i 1968. godine (desno). Prilagođeno preko DGU <https://geoportal.dgu.hr/> [pristupljeno: 20. siječnja 2021.]

Slika 8.2. Detalj prevlaka pore – tip redoks koncentracije uz korijen i duž makropore na poziciji P3 u potpovršinskom horizontu.

SAŽETAK

Pseudoglej je drugo najzastupljenije tlo unutar agroekosustava, a karakterizira ga slabije propusni potpovršinski horizont koji utječe na periodičko stagniranje oborinske vode i restrikcije u rastu korijena. S obzirom na prisutne klimatske promjene, izrazito je važno pratiti režim vlažnosti tla kako bi se na vrijeme reagiralo i umanjile štetne posljedice. Cilj ove disertacije bio je utvrditi svojstva rigolanog tla iz pesudogleja obronačnog u uvjetima uzgoja vinograda te utjecaj svojstava tla i proraštenosti tla korijenom na tok i retenciju vode u tlu. TDR senzori za praćenje režima vlažnosti postavljeni su na pet pozicija obronka u površinski (Ap) i potpovršinski (Bg) horizont te u red i međuredni dio vinograda. Na istim pozicijama utvrđena su fizikalna, kemijska i hidraulička svojstva tla. Rezultati analiza fizikalnih svojstava tla pokazuju izrazitu heterogenost s obzirom na položaj na obronku. Tako je utvrđen signifikantan utjecaj pozicije na sadržaj pijeska, praha, gline, humusa, volumne gustoće, kapaciteta tla za vodu, kapaciteta tla za zrak, i ukupnog poroziteta (za sve $P < 0,0001$). Isto tako utvrđene su značajne razlike u fizikalnim svojstvima između reda i međurednog prostora vinograda, za oba horizonta. Tijekom istraživanja uočene su i značajne razlike u volumetrijskom sadržaju vlage u tlu ovisno o poziciji na obronku ($P < 0,0001$) te između reda i međurednog prostora vinograda ($P < 0,0001$). Prosječno najveće vrijednosti volumetrijskog sadržaja vlage u tlu zabilježene su na višim pozicijama obronka (tj., P1 i P2). Navedeno bi moglo biti povezano sa povećanim sadržajem gline na istim pozicijama. Razlike u sadržaju vlage između reda i međurednog prostora pripisane su razlikama u korijenu kultura (vinova loza i trava) koje koriste različite količine vode tijekom vegetacije. HYDRUS 1D model korišten za simuliranje toka i retencije vode na istraživanoj parceli kalibriran je na temelju vrijednosti o volumetrijskom sadržaju vlage u tlu izmjerenim pomoću TDR senzora. Hidraulički parametri korišteni kao ulazni podaci u modelu prilikom simulacija procijenjeni su na tri načina, i to temeljem (i) evapotranspiracijske metode pomoću HYPROP i WP4C uređaja, (ii) „tipa pet“ pedotransfernih funkcija u ROSETTA softveru, te (iii) preko inverznog modeliranja u HYDRUS 1D modelu. Neke simulacije sa hidrauličkim parametrima iz HYPROP i ROSETTA softvera bile su nestabilne (model nije konvergirao). Korištenjem inverznog pristupa, sve simulacije bile su stabilne i pokazale su relativno zadovoljavajuće rezultate ($RMSE = 0,004$ do $0,084 \text{ cm}^3 \text{ cm}^{-3}$). Hidraulički parametri tla procijenjeni inverznim modeliranjem dalje su korišteni kao ulazni parametri za simulacije u HYDRUS 2D/3D modelu kojim se simulirao tok i retencija vode na cijelom istraživanom obronku, te u tri izmijenjena klimatska scenarija. Za još uspješnije korištenje modela, preporuča se posebnu pažnju posvetiti ulaznim parametrima kao što su hidrauličke značajke tla i parametri uzgajane kulture.

Ključne riječi: HYDRUS, HYPROP, korijen, numeričko modeliranje, obronačne pozicije, slabo propusni horizont, vinova loza.

EXTENDED ABSTRACT

MODELING SOIL WATER FLOW AND RETENTION ON PSEUDOGLEY SOIL IN SLOPING VINEYARD

Pseudogley is the second most widespread soil found in the agroecosystems of Croatia (307,453.2 ha). It is characterized by the presence of a less permeable subsurface horizon that affects the occasional (longer or shorter) occurrence of excessive saturation of the upper zone of the profile and have restrictions on root growth. According to FAO (2014), the soil profile of the natural pseudogley profile is designated as A-Eg-Bg-C, while according to the Soil Classification of Croatia as A-E / S-B / S-C (Husnjak, 2014). Since pseudogley as a soil type develops in regions that are in terms of relief and climate suitable for agriculture, a significant part of pseudogley is deeply ploughed for growing permanent crops. Deep ploughing resulted in mixing of the humus-accumulative with the eluvial-pseudogley and the upper part of the illuvial-pseudogley horizon, thus forming an anthropogenic horizon. Such pseudogleys are referred to as Ap-Bg-Cg (FAO, 2014), or P-B / S-C / S (Husnjak, 2014).

Soil moisture distribution and its spatial and temporal variability affect plant growth and development. Due to climate change, it is very important to develop models that will predict their impact on soil, but also on crop production. Given the above, it is extremely important to continuously monitor the water content in the soil with the aim of irrigation scheduling in order to mitigate the effects of drought. Measuring the soil moisture regime requires a lot of field work, is time consuming and expensive. With the development of computer technology, many numerical models have been developed that, based on pedotransfer functions and/or measured hydraulic parameters, can solve water movement in the (un)saturated zone of the soil.

Based on the above stated, the following research hypotheses were set: (i) in the investigated agroecological conditions during the autumn/winter period there is no occurrence of prolonged excessive soil saturation (over 120 days per year) characteristic for pseudogley, (ii) soil moisture regime and water flows are affected by relief or position on the slope and hydraulic parameters of the subsurface horizon, and vine roots, (iii) using a numerical model one can reliably determine the flow and retention of water in the studied agroecological conditions.

The research was conducted over two years (2019, 2020) in Jastrebarsko (45°41'22 "N; 15°38'22" E). The investigated plot is located on the slope with the southeastern exposure, it is 90 m long and has a slope of 14%. A vineyard (*Traminac cv.*) was planted on the investigated plot in 1999, where the planting distance in the row was 1.0 m, and between the rows 2.5 m. The rows are oriented down the slope, and the interrow area is planted with grass to limit the erosion.

On the investigated plot, five pedological profiles were dug, to a depth of 110 cm, which were equidistant from each other (18 m) along the entire length of the slope. From the pedological profiles, disturbed samples and undisturbed soil cores were taken (100 and 250 cm³ volume cylinders). Samples were taken in a row and in the inter-row part of the vineyard.

After sampling, TDR sensors were installed in each of the five profiles for monitoring of soil moisture regime at 30 and 90 cm deep in a row and in the inter-row part of the vineyard. Also, at 30 cm in a row and in the inter-row space, tensiometers were placed to monitor soil water potential, after which the profiles were buried again. In addition to monitoring the soil moisture regime (TDR sensors and/or tensiometers), the level of water stress in the vine can be determined by measuring the leaf water potential of the vine. Therefore, during 2020, at three slope positions (top, middle and bottom of the slope), the water potential on the vine was measured in order to determine the correlation between the soil water potential and the vine (leaf) water potential. The results showed that no significant correlation was observed between the water potential of the soil and the vine. However, the correlation between soil water potential and relative humidity was positive and strong ($r = 0.56 - 0.62$).

Based on standard laboratory analyzes, the basic physical (soil texture, bulk density, differential and total porosity), chemical (pH and humus content) and hydraulic properties of the soil (θ_s , θ_r , α , n , K_s) were determined. The results of the analyzes indicate a pronounced heterogeneity of particle size distribution, bulk density, total porosity with respect to the position on the slope, and pH and humus (for all values of $P < 0.0001$). Significant differences in soil properties between row and inter-row space of vineyards were also found. During the research, significant differences in soil moisture were observed depending on the position on the slope ($P < 0.0001$), as well as differences between the row and the inter-row space of the vineyard ($P < 0.0001$). Thus, the highest values of soil moisture content during the investigated period were observed at the upper P1 and P2 positions of the slope. This could be related with increased clay content at these positions. On average, the highest moisture content in the soil during the investigated period was observed in the row for the surface (Ap) and in the interrow for the subsurface (Bg) horizon. TDR sensors determined that excessive saturation was present in the middle of the slope (P3 position) throughout the study period. This could be related to increased clay content, at P1 and P2 slope positions which could affect the occurrence of subsurface lateral flow. However, although saturation conditions prevailed at the P3 position throughout the investigated period, the relative water content in the soil was lower compared to the positions above. This could be related to the increased sand content in the Bg horizon at P3 compared to other positions and to the fact that the sand has a low water retention capacity.

In addition to measuring the soil moisture regime, the HYDRUS 1D and HYDRUS2D / 3D model was used for its assessment. The hydraulic parameters used in the model were

estimated in three ways: (i) by evapotranspiration method based on HYPROP and WP4C systems, (ii) by “type five” estimation of pedotransfer functions in ROSETTA software, and (iii) by inverse simulation using HYDRUS 1D program. In the first step, the hydraulic parameters (θ_s , θ_r , α , K_s , n and l) of the soil obtained through the HYPROP and WP4C systems were used, by applying which the HYDRUS 1D model was unstable, i.e., did not converge in most cases. In the second step, the estimated hydraulic parameters also did not give satisfactory results in HYDRUS 1D simulations, so in the third step they were estimated by inverse modeling. Inverse modeling was performed on the calibration period (from 13.9. to 12.10.2019) Which was chosen because it had the equal time of wet and dry days. Values of R^2 were generally above 0.90 excluding P1 and P3 positions in a row in which R^2 was, respectively, $R^2 = 0.645$ and $R^2 = 0.882$. $RMSE$ values in most positions are generally less than $0.03 \text{ cm}^3 \text{ cm}^{-3}$, except for P1 position in the row where the $RMSE$ was $0.05 \text{ cm}^3 \text{ cm}^{-3}$. The inverse simulation showed the most reliable (but still not ideal) results of the assessment of hydraulic parameters. However, in the absence of insufficiently good measurements (HYPROP) and estimation of hydraulic parameters (ROSETTA), hydraulic parameters estimated through inverse modeling were further used in the work.

After calibration and validation in the HYDRUS 1D program, the hydraulic parameters estimated by inverse modeling were further used as input parameters for simulations of water flow and retention on the entire slope using the HYDRUS 2D/3D program. With respect to climate change in the HYDRUS 2D/3D program, three climate scenarios were simulated (according to IPCC, 2014) (i). mild (predicting a 1.5°C temperature rise) (ii) medium predicting a 2.5°C temperature rise (iii) extreme predicting a 3.5°C temperature rise. Also, IPCC, 2014 predicts that precipitation in the winter months will increase, while longer periods of drought will prevail in the summer months. Although no significant differences were found between the simulated climate scenarios, it can be concluded that the HYDRUS model after calibration and validation can be successfully used to predict different climate scenarios.

For more successful use of the model and based on the research results obtained in this dissertation, it is recommended during modeling to pay attention to proper soil hydraulic properties determination, since they have the largest impact on the simulation results. Furthermore, for simulations over longer time periods, the hydraulic properties of the soil should be determined on several occasions with respect to their temporal variability which is pronounced in intensively managed arable soils. In addition to the hydraulic properties of the soil, the data on the crop (eng. leaf area index, root depth) have a significant impact on the simulation results and should therefore be given additional attention.

Key words: HYDRUS, HYPROP, root, numerical modeling, slope positions, low permeability horizon, grapevine.

SADRŽAJ

1. UVOD	1
1.1. Hipoteze i ciljevi istraživanja	3
2. PREGLED LITERATURE	4
2.1. Važnost reljefa kao pedogenetskog čimbenika u nastanku tla	4
2.2. Pseudoglej	7
2.2.1. Građa i način postanka pseudogleja	8
2.2.2. Zastupljenost, osnovna fizikalna, kemijska i biološka svojstva pseudogleja te njegov proizvodni potencijal	10
2.3. Specifičnosti uzgoja vinove loze	13
2.4. Voda u tlu	15
2.4.1. Hidraulička svojstva tla	20
2.5. Primjena numeričkih modela u procjeni toka i retencije vode u tlu	21
3. MATERIJALI I METODE	25
3.1. Lokacija istraživanja	25
3.2. Matični supstrat istraživane lokacije	26
3.3. Klima istraživanog područja	27
3.4. Terenska istraživanja	28
3.5. Laboratorijska istraživanja	37
3.6. Modeliranje toka i retencije vode na obronku pomoću HYDRUS softverskog paketa	41
3.6.1. Inicijalni i granični uvjeti modeliranja toka vode	42
3.7. Statistička obrada rezultata	45
4. REZULTATI	47
4.1. Rezultati preliminarnih istraživanja obronka	47
4.2. Svojstva tla po pozicijama obronka	49
4.2.1. Morfološka svojstva pedoloških profila na istraživanom obronku	49
4.2.2. Proraštenost tla korijenom	51
4.2.3. Korelacija vodnog potencijala tla i vodnog potencijala vinove loze	54
4.2.4. Fizikalna svojstva pedoloških profila na istraživanom obronku	56
4.2.5. Kemijska svojstva pedoloških profila na istraživanom obronku	64
4.2.6. Vodno–retencijske značajke tla	66
4.2.7. Hidraulička svojstva tla	74
4.2.7.1. Retencijske krivulje	74
4.2.7.2. Hidrauličke krivulje	81
4.3. Retencija vlage u tlu tijekom istraživanja	86
4.4. Simuliranje toka i retencije vode u tlu istraživanog obronka	93

4.4.1. Simuliranje toka i retencije vode – HYDRUS 1D.....	93
4.4.1.1. Hidraulički parametri procijenjeni pomoću HYPROP sustava	93
4.4.1.2. Simulacije sa hidrauličkim parametrima iz ROSETTA – softvera	95
4.4.1.2. Inverzno simuliranje	100
4.4.1.3. HYDRUS 1D simulacije za 2019. i 2020. godinu temeljem hidrauličkih parametara iz inverznog modeliranja	103
4.4.2. Simulacije toka vode – HYDRUS 2D/3D	111
5. RASPRAVA	118
5.1. Svojstva tla na istraživanom obronku	118
5.1.1. Preliminarna istraživanja	118
5.1.2. Građa profila, morfološka svojstva tla i proraštenost korijenom	118
5.1.3. Fizikalna svojstva profila	121
5.1.4. Kemijska svojstva istraživanih profila	125
5.1.5. Hidraulička svojstva tla	126
5.2. Odnos vodnog potencijala tla i vodnog potencijala vinove loze	129
5.3. Sadržaj vlage u tlu	130
5.4. Numeričko modeliranje	132
5.4.1. Simulacije s hidrauličkim parametrima iz HYPROP – a.....	132
5.4.2. Simulacije sa hidrauličkim parametrima određenim preko pedotransfernih funkcija iz ROSETTA softvera	133
5.4.3. Inverzno simuliranje	134
5.4.4. Primjena kalibriranog HYDRUS 1D modela u opisu toka i retencije vode u tlu	136
5.4.5. HYDRUS 2D simulacije i klimatske predikcije	139
5.4.6. HYDRUS 2D i simuliranje vodnog režima tla uslijed različitih klimatskih scenarija.....	140
6. ZAKLJUČAK	142
7. LITERATURA.....	145
8. PRILOZI.....	164
ŽIVOTOPIS AUTORA	166

1. UVOD

Voda (vlaga) tla jedan je od najvažnijih parametara u hidrološkom ciklusu koji između ostalog regulira rast biljaka i razinu podzemnih voda (Vereecken i sur., 2008.). Sadržaj vlage u tlu varira vremenski i prostorno, a varijacije su uzrokovane klimom (npr. Rosenbaum i sur., 2012., Zhao i sur., 2016.), svojstvima tla (Niemann i Edgell, 1993., Cantón i sur., 2004., Hu i Si, 2014.), topografijom (Western i sur., 2004., Crave i Gascuel-Oudou, 1997., Famiglietti i sur., 1998.), načinom korištenja tla odnosno vegetacijom (Zhu i Shao., 2008., Gerrits i sur., 2010., Liang i sur., 2014.). Voda u tlu predstavlja samo 0,05% ukupne količine vode u globalnom hidrološkom ciklusu i 0,001% ukupno raspoložive slatke vode na Zemlji (Robinson i sur., 2019., Drinkwater, 2009.), ali zbog svoje važne uloge pripada skupini osnovnih klimatskih varijabli (Dorigo i sur., 2011.). Točne informacije o vremenskim i prostornim varijacijama vlažnosti tla koriste se za prognoze poplava i suša (Wanders i sur., 2014., Sheffield i sur., 2014) za izradu studija utjecaja na klimu (Seneviratne i sur., 2010.) te različitih klimatskih scenarija (Li i sur., 2016.). Grubi podaci o vlažnosti tla u površinskoj zoni danas se mogu dobiti daljinskim istraživanjima, npr. fotointerpretacijom satelitskih snimki (Mohanty i sur., 2017.), međutim točne podatke o sadržaju vode po dubini profila (na pojedinoj lokaciji) moguće je dobiti praćenjem režima vlažnosti odnosno periodičnih promjena vlažnosti tla po dubini profila.

Sadržaj vlage u tlu ovisi u prvom redu o klimatskim uvjetima, ali i o svojstvima tla. Obronačne reljefne pozicije karakterizira izrazita heterogenost u svojstvima tla na maloj udaljenosti. Pseudoglej je po zastupljenosti drugi je tip tla u Republici Hrvatskoj, pri čemu se gotovo 55 % od ukupne površine nalazi unutar agroekosustava (Husnjak, 2014.). Pseudoglej obilježava suficitno vlaženje prvenstveno oborinskom vodom i vertikalni teksturni kontrast u profilu tla. Naime ovo tlo karakterizira prisustvo slabije propusnog horizonta koji utječe na tok i retenciju vode u tlu.

Distribucija vlage u tlu, njena vremenska i prostorna varijabilnost utječe na rast i razvoj biljaka. Pored mjerenja sadržaja vlage u tlu i vodnog potencijala tla, važno je mjeriti i vodni potencijal same biljke, kako bi se utvrdila razina eventualnog vodnog stresa pod kojim se biljka nalazi uslijed smanjene količine pristupačne vode u tlu (Centeno i sur., 2010.). Osim o značajkama i sadržaju vlage u tlu, uzgoj vinove loze, a posljedično i kvaliteta vina ovise o klimatskim uvjetima na području uzgoja. Do kraja 21. stoljeća IPCC (2014.) predviđa porast globalne temperature od 1,0 do 3,7 °C, istovremeno će količina oborina u nekim područjima rasti, dok će u drugima prevladavati dulji periodi suše. Osim toga, raspored oborina će se promijeniti što će povećati potrebu za navodnjavanjem (van Leeuwen i Darriet, 2016.). S obzirom na navedeno od iznimne je važnosti konstantno praćenje te poznavanje režima vlažnosti tla. Postoji više načina praćenja režima vlažnosti tla.

Jedan od najstarijih načina odnosi se na praćenje režima vlažnosti tla gravimetrijskom metodom koja se smatra najtočnijom (Cooper, 2016.). Drugi način odnosi se na praćenje režima vlažnosti tla tenziometrima, neutronske i gama mjeračima, te različitim senzorima kao što su gips blokovi za elektrometrijsko određivanje vlage te TDR ili FDR senzorima (Hu i sur., 2014.).

Navedeni načini i metode mjerenja mogu dati informacije o trenutnom sadržaju i dinamici vode u tlu i tako omogućiti pravovremeno reagiranje s ciljem ublažavanja posljedica manjka ili/i viška vode u tlu. Pri tome neki načini i metode praćenja režima vlažnosti tla (primjerice gravimetrijska metoda), naročito ako se režim vlažnosti prati na dnevnoj, tjednoj ili dekadnoj bazi, iziskuju puno terenskog rada i vremena, zbog čega su troškovi takvog praćenja iznimno visoki. Problemi kod gravimetrijskog određivanja vlage tla mogu se javiti ako se žele dobiti učestaliji podaci o sadržaju vode u (npr. svakih nekoliko minuta). Sljedeći problem gravimetrijskog određivanja vlage u tlu odnosi se na prostornu distribuciju uzorkovanja. Naime nakon što se uzorak tla za gravimetrijsko određivanje vlage tla jednom uzme, točno na tom mjestu više nije moguće uzorkovanje. Međutim, danas praćenje režima vlažnosti tla pomoću suvremenih senzora (npr. TDR, FDR senzori) iziskuje samo povremenu kontrolu opreme na terenu, zbog čega su takve metode vremenski znatno manje zahtjevnije, a troškovi niži. Uobičajeno je danas da su spomenuti suvremeni senzori, *on line*, preko *data logger*a povezani sa računalom što omogućava da se u bilo kojem trenutku može saznati trenutačna vlaga tla na istraživanoj lokaciji. Važno je ovdje istaknuti da *in situ* mjerenja režima vlažnosti tla prema gore navedenim načinima, pružaju samo podatke o vlazi tla na konkretnom mjestu mjerenja, te da se odnose na mali volumen tla koji zahvaća senzor. Navedeno predstavlja posebni nedostatak kod heterogenih tala, gdje ovakva praćenja mogu dati krive informacije o sadržaju vlage u tlu na širem području od samih mjernih mjesta.

Treći način odnosi se na činjenicu da su razvojem računalne tehnologije, posljednjih desetljeća razvijeni brojni numerički modeli koji temeljem pedotransfer funkcija i/ili izmjerenih hidrauličkih parametara mogu rješavati probleme kretanja vode, topline, onečišćivača u (ne)saturiranoj zoni tla. U svrhu rješavanja problematike toka vode u tlu, danas se sve veća pozornost posvećuje upravo razvoju numeričkih modela. Jedan od najčešće korištenih numeričkih modela je HYDRUS (1D ili 2D/3D) (Šimůnek i sur., 2016.). HYDRUS softverski paket koristi se za istraživanje i predikciju toka i retencije vode u tlu, u jedno ili više dimenzionalnom prostoru, a baziran je na numeričkom rješavanju Richardsonove jednačine.

Osnovna svrha provedenog istraživanja bila je utvrditi mogućnost primjene suvremenih metoda praćenja (npr. TDR senzorima) i predikcije režima vlažnosti i toka vode HYDRUS numeričkim modelom u uvjetima intenzivne vinogradarske proizvodnje, na rigolanom tlu iz pseudogleja obronačnog.

1.1. Hipoteze i ciljevi istraživanja

Hipoteze postavljene u sklopu ove disertacije bile su sljedeće:

- I. u istraživanim agroekološkim uvjetima tijekom jesensko/zimskog perioda izostaje pojava dužeg trajanja prekomjerne saturacije tla (>120 dana/godina) karakteristične za pseudoglej,
- II. režim vlažnosti i tokovi vode u tlu pod utjecajem su reljefa odnosno pozicije na obronku te hidrauličkih parametara potpovršinskog horizonta i korijena vinove loze,
- III. primjenom numeričkog modela može se pouzdano utvrditi tok i retencija vode u istraživanim agroekološkim uvjetima.

Temeljem hipoteza postavljeni su sljedeći ciljevi istraživanja:


- I. kontinuiranim mjerenjem sadržaja vode u tlu i vodnog potencijala tla odrediti duljinu trajanja prekomjerne saturacije tla,
- II. utvrditi utjecaj reljefa (pozicije na obronku), hidrauličkih parametara potpovršinskog horizonta i korijena vinove loze na režim vlažnosti i tok vode u tlu,
- III. kalibriranim i validiranim numeričkim modelom simulirati tok i retenciju vode u tlu tijekom istraživanog razdoblja te pri izmijenjenim klimatskim scenarijima.

2. PREGLED LITERATURE


2.1. Važnost reljefa kao pedogenetskog čimbenika u nastanku tla

Varijabilnost svojstava tla, a povezano s time i retencija vode u tlu, pod utjecajem je pedogenetskih čimbenika, u koje Jenny (1994.) ubraja klimu, matični supstrat, organizme, vrijeme i reljef, dok pojedini autori (Ollinger, 2002., Husnjak, 2014.) uz navedeno ubrajaju još i ljudsku aktivnost.

Reljef (topografija) predstavlja oblik i položaj Zemljine površine u prostoru. Forma reljefa, reljefna pozicija i oblik padine određuje se procjenom, dok se nagib mjeri neposredno na terenu. Na procese tvorbe tla utječe posredno, zbog čega spada u pasivne pedogenetske čimbenike. Uz to, Jenny (1980.) navodi da je topografija primarni čimbenik u objašnjavanju varijacije svojstava tla. Autor smatra kako je topografija definirana duljinom (m) i postotkom (%) nagiba te njegovom orijentacijom (eng. *aspect* ili *exposure*) s obzirom na strane svijeta. Orijentacija reljefa označava se u stupnjevima od 0° – 360° , gdje 0° predstavlja okrenutost sjeveru, 90° - istoku, 180° - jugu, a 270° - zapadu. Orijentacija nagiba rezultira mikroklimatskim i vegetacijskim razlikama, a posljedično tome i razlikama u svojstvima tla. FAO (2006.) navodi dijelove obronka (Slika 2.1.) i klasifikaciju nagiba s obzirom na njegov oblik (Slika 2.2.).



Slika 2.1. Dijelovi obronka, prilagođeno prema FAO (2006.)



Slika 2.2. Klasifikacija nagiba s obzirom na oblik obronka prema FAO (2006.)

Brojne studije provedene su s ciljem utvrđivanja dominantnog faktora koji utječe na svojstva tla na pojedinom području (Mulugeta i Sheleme, 2010., Sheleme, 2011., Fantaw i sur., 2006., Wang i sur., 2001.). Tako primjerice Wang i sur. (2001.) smatraju topografiju (reljef)

dominantnim čimbenikom koji utječe na varijacije u svojstvima tla uslijed procesa površinskog otjecanja, erozije tla i modifikacija uslijed promjene mikroklima područja, čime je izražen utjecaj topografije na formiranje tla na nagnutim terenima. S obzirom na značajan utjecaj topografije na svojstva tla, ovdje se navodi i pojam katena (eng. *catena*) odnosno toposekvencu (eng. *toposequence*). Jenny (1980.) definira toposekvencu kao skupinu tala različitih svojstava koja se javljaju na istom obronku, pri čemu su ta tla nastala iz istog (ili sličnog) matičnog supstrata, prvenstveno pod utjecajem reljefa.

Položaj na nagibu, kao glavni topografski parametar, ima značajan, neizravni utjecaj na fizikalno – kemijska svojstva tla kontrolirajući kretanje vode i erodiranog materijala na obronku uzrokujući tako prostorne razlike u svojstvima tla (Begum i sur., 2010., Khormali i sur., 2007.). Jedan od najizraženijih procesa koji se javlja na nagnutim terenima je erozija tla uzrokovana vodom. Erozija tla prirodna je pojava koja je prisutna cijelo vrijeme tijekom razvoja tla, međutim intenziviranje procesa erozije tla povećalo se djelovanjem čovjeka. Proces erozije ima velik utjecaj na fizikalna (npr. teksturni sastav), kemijska (sadržaj humusa, pH, sadržaj hranjiva, itd.), ali i biološka svojstva tla, osobito površinskog horizonta tla (koja se razlikuju ovisno o položaju na obronku. Brojne studije koje su se bavile proučavanjem hidropedoloških svojstava nagnutih terena utvrdile su ovisnost različitih svojstva tla o karakteristikama topografije, npr. dubina površinskog horizonta tla (Mayer i sur., 2019., Sarapatka i sur., 2018., Ziadat i sur., 2010.), sadržaj organskog ugljika (Jakšić i sur., 2015., Mayer i sur., 2019., Sarapatka i sur., 2018.), sadržaj vlage u tlu (Jakšić i sur., 2015., Romano i Paladino, 2002.). Gubitak površinskog sloja tla najizraženiji je na konveksnim dijelovima obronka, dok se taloženje materijala odvija u konkavnim dijelovima (Dreibrodt i sur., 2010., Lang, 2003.). Erozija tla utječe na premještanje površinskog sloja tla sa viših na niže reljefne pozicije. Navedeno uzrokuje heterogenost u debljini površinskog horizonta od vrha prema dnu obronka, gdje je na višim reljefnim pozicijama površinski horizont plići, a na nižim pozicijama dublji (Ziadat i sur., 2010., Mulugeta i Sheleme, 2010.). Osim erozije, na premještanje površinskog sloja tla niz obronak na poljoprivrednim tlima utjecaj ima i obrada tla. Učinak erozije i obrade tla dovodi do smanjenja dubine površinskog horizonta tla na gornjim pozicijama. Obradom tla na istoj dubini, na gornjim dijelovima obronka dolazi do postupnog zahvaćanja dubljih horizonata tla (Śintowiak, 2014., Wiaux i sur., 2014.). Kao rezultat navedenog dubina matičnog supstrata duž obronka može varirati od same površine pa do dubine preko 150 cm (npr. Deumilch i sur., 2010.). Osim za dubinu površinskog horizonta duž obronka, gdje se većina znanstvenika slaže kako je površinski horizont plići na višim u odnosu na niže dijelove, takva situacija nije uobičajena kada se govori o utjecaju topografije na pojedina svojstva tla.

Erozija tla utječe na premještanje čestica tla niz obronak, pri čemu su procesu premještanja najpodložnije čestice praha (Carroll i sur., 2000., Cerdan i sur., 2010., Wang i sur., 2016.).

Moore i sur. (1993.) u svom istraživanju također navode kako su uočili razlike u transportu čestica tla ovisno o njihovoj veličini, pri čemu je transport krupnijih čestica (tj. pijesak) bio slabo izražen, dok je najizraženiji transport bio kod čestica srednje veličine (tj. prah). Mulugeta i Sheleme (2010.), navode slične rezultate u svom istraživanju, gdje su uočili porast sitnih frakcija niz obronak. Khan i sur. (2013.) također navode porast količine sitnijih čestica (prah i glina) niz obronak, dok su najveće količine pijeska utvrđene na višim pozicijama obronka. Famiglietti i sur. (1998.) navode kako povećan sadržaj gline niz obronak rezultira smanjenjem hidrauličke vodljivosti, usporavanjem evapotranspiracije, a posljedično tome i povećanjem retencije vlage na nižim u odnosu na povišene pozicije obronka. Osim prisutnog površinskog premještanja čestica niz obronak, moguća je pojava i premještanja čestica (prvenstveno gline) descedentno u profilu tla. Povećan sadržaj čestica gline u dubljim horizontima tla sugerira na pojavu procesa eluvijacije. Proces eluvijacije podrazumijeva premještanje peptiziranih čestica gline procjednom vodom iz površinskih horizonata i njihovo nakupljanje u dubljim dijelovima profila tla (Husnjak, 2014.).

Volumna gustoća tla, kao još jedno važno fizikalno svojstvo tla, također često varira ovisno o poziciji na obronku. Najveće vrijednosti volumne gustoće najčešće su zabilježene na višim pozicijama obronka (Przewoźna, 2014., Kobierski, 2013., Wiśniewski i Märker, 2021., Khan i sur., 2013.). Takvi rezultati nisu neočekivani, s obzirom da na volumnu gustoću velik utjecaj ima tekstura tla. Uslijed premještanja sitnijih čestica (prah i glina) niz obronak, uočava se povećan sadržaj krupnijih čestica (pijesak) na gornjim pozicijama. Kod pjeskovitih tala, u odnosu na glinasta razvija se manji volumen mikropora te veći volumen makropora, što u konačnici rezultira i većom volumnom gustoćom na višim reljefnim pozicijama (Khan i sur., 2013.). Rieckh i sur. (2012.) utvrdili su kako se hidraulička svojstva istih horizonata mogu razlikovati ovisno o položaju na obronku. Thomas i sur. (2017.) smatraju kako bi različita stratigrafija mogla imati utjecaja na dinamiku vlage tla niz obronak.

Iako je sadržaj vlage u tlu usko vezan uz svojstva tla (sadržaj gline, organske tvari), na sadržaj vode također velik utjecaj ima reljef. Reljef svojim usponima, ravnicama i udubinama djeluje na preraspodjelu vode na i u tlu. Zaravnjene reljefne forme prihvaćaju cjelokupnu atmosfersku vodu dok se na uzvišenim dijelovima voda cijedi niz padinu, a u udubljenim se formama nakuplja (Husnjak, 2014.). Osim direktnog utjecaja reljefa na sadržaj vlage u tlu, utjecaj reljefa prvenstveno se ogleda neizravno, preko svojstva tla koja utječu na tok i retenciju vode u tlu. Liu i sur. (2020.) navode kako sadržaj vlage u tlu raste prema nižim pozicijama obronka. Neke studije govore kako biljke također mogu utjecati na sadržaj vlage u tlu i hidraulička svojstva tla, bilo izravno nakupljanjem vlage u biomasi korijena ili modificiranjem strukture i poroznosti tla rastom korijena (Rasse i sur., 2000., Kodešová i sur., 2006.).

Sadržaj humusa u tlu također može varirati ovisno o poziciji na obronku. Tako pojedini autori navode kako sadržaj humusa (organske tvari) raste prema nižim pozicijama obronka (npr. Pierson i Mulla, 1990., Khan i sur., 2013.), dok Liu i sur., (2020.) navode kako je sadržaj organske tvari u tlu najveći na sredini i na višim pozicijama obronka. Rubinić i sur. (2015a.) u svom istraživanju obronačnog pseudogleja pod šumskim ekosustavom navode kako sadržaj humusa ne ovisi od pozicije na obronku. Osim pozicije na obronku, sadržaj humusa varira i s njegovom orijentacijom, odnosno ekspozicijom. Tako Egli i sur. (2009.) u svom istraživanju navodi da obronci orijentirani na sjever imaju veći sadržaj humusa u odnosu na one orijentirane prema jugu.

Liu i sur. (2020.), Jimoh i sur. (2020.) navode kako nema razlike u pH tla ovisno o poziciji na obronku, dok je prema Kotingo (2015.) pH reakcija tla veća je na višim u odnosu na niže pozicije obronka. Khan i sur. (2013.) u svom istraživanju utjecaja pozicije na obronku na fizikalno – kemijska svojstva tla navodi kako je najveća pH vrijednost (veća za 2 do 3 %) zabilježena na sredini obronka u odnosu na ostale pozicije. Međutim ta razlika nije bila statistički opravdana. Povećane pH vrijednosti niz obronak mogu se pripisati ispiranju tvari/otopina sa viših pozicija.

2.2. Pseudoglej

U pedološkoj znanstvenoj literaturi u Hrvatskoj (Racz, 1980., Škorić, 1986., Husnjak, 2014.), pseudoglej se opisuje kao tlo izloženo povremenom suficitnom vlaženju gornjih dijelova profila stagnirajućom površinskom (prvenstveno oborinskom) vodom, koja se zbog prisutnosti slabo propusnog horizonta vrlo sporo procjeđuje kroz solum tla. Zbog navedenog, u jako vlažnom dijelu godine (studen i – travanj) voda se nakuplja i stagnira, a ovisno o njenoj količini uzrokuje saturaciju odnosno pojavu anaerobnih uvjeta određene zone profila tla. U ostalom dijelu godine uglavnom nema prekomjernog vlaženja, odnosno režim vlažnosti varira unutar vlažne (samo rijetko i unutar suhe) faze tla. Takve, periodične promjene saturacijskih, odnosno aeracijskih uvjeta u tlu uzrokuju pojavu karakteristične mramorirane morfologije odnosno pojavu redukcijskih i oksidacijskih procesa. Kao posljedica toga javlja se periodično stagniranje oborinske vode u ili/iznad slabo propusnog horizonta zbog čega dolazi do procesa pseudooglejavanja (Rubinić i sur., 2014.). Prema IUSS Working group WRB (2014.) pseudooglejavanje je rezultat redukcije (i reoksidacije) Fe i /ili Mn spojeva uslijed saturacije tla oborinskom vodom. Redukcijski uvjeti prvenstveno se stvaraju unutar slabo propusnog horizonta (npr. složenog iluvijalno/pseudoglejnog; B/S), a nakon intenzivnijih oborina i u zoni tla iznad njega. Reducirani spojevi (Fe i/ili Mn) postaju topivi odnosno pokretni i mogu se isprati iz tla, ostavljajući tako blijedo, sivkasto tlo, ili se mogu reprecipitirati u obliku narančasto – žuto – smeđe – crvenkastih (i/ili crnih) nakupina. Posljedično, dolazi do razvoja morfologije koja je

karakteristična za pseudoglej, a u literaturi se označava kao „mramorizacija“ (Husnjak, 2014.), odnosno redoksimorfne značajke (Schoeneneberger i sur., 2012., Vepraskas i Williams, 1995.). S obzirom na mehanizam postanka specifične morfologije, redoksimorfne značajke mogu biti uspješno korištene kao indikator vlažnosti tla (Ticehurst i sur., 2007.), međutim ova svojstva mogu biti reliktna te stoga nisu uvijek pouzdan pokazatelj režima vlažnosti tla.

Sadržaj vlage u tlu kod pseudogleja može se podijeliti u tri faze. Označavaju se kao mokra, kod koje su dio ili sve makropore ispunjene vodom (djelomično ili potpuno saturacijski uvjeti), vlažna faza označava sadržaj vlage u tlu između poljskog kapaciteta tla za vodu i točke venuća, dok je suha faza predstavljena količinom vlage koja se u tlu nalazi ispod točke venuća. S obzirom na navedeno, može se ustvrditi kako pseudoglej obilježava pseudoglejni način vlaženja uglavnom tijekom vlažnijeg (studen – travanj), te automorfni način vlaženja pretežno tijekom toplijeg dijela godine (svibanj – listopad). Na samu dužinu trajanja mokre faze utječu klima, reljef, te pozicija slabo propusnog horizonta u profilu tla (Škorić, 1986.). Pozicija ili dubina slabo propusnog horizonta, pored ostalog utječe i na volumen tla koji će biti zahvaćen prekomjernom vlažnošću (Resulović i sur., 2008.).

2.2.1. Građa i način postanka pseudogleja

Tipična građa prirodnog profila pseudogleja označava se kao A-Eg-Bg-C (FAO, 2014., Škorić, 1986.), odnosno prema Klasifikaciji tala Hrvatske građa pseudogleja označava se kao A-E/S-B/S-C (Husnjak, 2014.).

Pseudoglej se u Hrvatskoj razvija u regijama koje su reljefno i klimatski pogodne za poljoprivrednu proizvodnju. Zbog navedenog, jedan dio pseudogleja još je uvijek prirodno tlo, dok je drugi dio antropogeniziran te se danas koristi kao oranično ili rigolano tlo pod višegodišnjim nasadima. Naime, dubokom obradom (rigolanjem) došlo je do miješanja humusno akumulativnog sa eluvijalno-pseudoglejnim i gornjim dijelom iluvijalno-pseudoglejnog horizonta, čime je formirani antropogeni horizont. Takvi se pseudogleji označavaju kao Ap-Bg-Cg (FAO, 2014.), ili P-B/S-C/S (Husnjak, 2014.).

Na postanak pseudogleja velik utjecaj ima i reljef. Naime, razvoj pseudogleja vezan je uz terene na kojima je onemogućeno površinsko i bočno otjecanje vode kao i uz terene gdje dolazi do toga. Najveći dio ovog tla nastaje na pleistocenskim zaravnima s nagibom do 3 %, a znatno manji dio na obroncima s nagibom od 3 do 8 %. Vrlo mali dio pseudogleja, i to isključivo na području sa humidnom klimom, nastaje i na obroncima s umjereno strmim nagibima od 8 do 12 % (Husnjak, 2014.). U utvrđivanju načina postanka pseudogleja važnu ulogu ima


podrijetlo slabo propusnog horizonta. Naime, prema načinu postanka slabo propusnog horizonta, pseudogleji se mogu izdvojiti kao primarni i sekundarni.

Kod primarnog pseudogleja, način nastanka slabo propusnog horizonta vezan je uz slojevite matične supstrate. Na površinski sloj težeg teksturnog sastava, najčešće praškasto glinasto ilovaste do praškasto glinaste teksture, s nepovoljnim vodozračnim odnosima i slabom propusnošću tla za vodu, nanesen je sloj lakšeg teksturnog sastava pjeskovito ilovaste do ilovaste teksture, koji je dobro aeriran i propustan za vodu. S vremenom se u ovom tlu razvija proces pseudooglejavanja, pri čemu slabo propusni horizont poprima funkciju iluvijalnog horizonta, a horizont lakšeg teksturnog sastava funkciju eluvijalnog horizonta (Husnjak, 2014.). Dakle u ovom slučaju nepropusni horizont nije nastao kao rezultat pedogeneze, nego zbog specifične, slojevite građe matičnog supstrata.

Nastanak sekundarnog pseudogleja povezan je sa daljnjim razvojem iluvijalnog horizonta lesiviranog tla, nastalog na matičnim supstratima koji su skloni ispiranju čestica gline u dublje slojeve profila. Naime, iluvijalni horizont kod lesiviranog tla nastao je pedogenetskim procesima, odnosno ispiranjem čestica gline iz eluvijalnog horizonta i njihovim nakupljanjem u iluvijalnom horizontu. Daljnjim nakupljanjem čestica gline, smanjuje se volumen drenirajućih pora, a istovremeno dolazi do sve izraženijeg smanjenja propusnosti tla za vodu i povećanog stagniranja oborinske vode, što dovodi do razvoja i nastanka slabo propusnog horizonta pedogenetskim putem (Husnjak 2014.). Većina pseudogleja u Hrvatskoj nastala je kao sekundarni, dok primarnog pseudogleja ima izuzetno malo.

2.2.2. Zastupljenost, osnovna fizikalna, kemijska i biološka svojstva pseudogleja te njegov proizvodni potencijal

Pseudoglej je drugo najzastupljenije tlo u Hrvatskoj, rasprostranjeno uglavnom u Panonskoj regiji (Bogunović i sur., 1998., Husnjak, 2014., Rubinić i sur., 2015a.) (Slika 2.3.a). Ukupna površina pseudogleja u Hrvatskoj iznosi 558. 731,9 ha, što iznosi ukupno 9,9% od ukupne površine RH. Gotovo 55 % pseudogleja u Hrvatskoj rasprostranjeno je unutar agroekosustava (307.453,2 ha), dok je pod šumskim ekosustavima 45% odnosno 251.278,7 ha (Husnjak, 2014.). Prema podacima iz Namjenske pedološke karte RH mjerila 1:300.000, od ukupnog pseudogleja, procjenjuje se da na pseudoglej obronačni otpada približno 20% odnosno 111.600,3 ha (Slika 2.3.b).



Slika 2.3. Rasprostranjenost pseudogleja (a) i pseudogleja obronačnog (b) na području RH prema Husnjaku, (2014.)

Pseudoglej je tip tla koji karakterizira izrazita heterogenost u svojstvima, koja je rezultat njegovog postanka (različiti matični supstrati, različite reljefne forme, različiti klimatski uvjeti te različit položaj slabo propusnog horizonta u profilu tla) (Husnjak, 2014.). Što se tiče fizikalnih svojstava pseudogleja, najznačajnije obilježje je vertikalni teksturni kontrast u profilu, odnosno teksturna diferencijacija. Kako navodi Ćirić (1984.) površinski horizonti teksturno su (najčešće) okarakterizirani kao praškasta ilovača, dok slabo propusni horizont sadrži povećan sadržaj gline, obično dva do tri puta više u odnosu na horizont iznad njega. Struktura eluvijalnog horizonta je nestabilna, dok slabo propusni iluvijalno-pseudoglejni horizont nema izraženu strukturu. Navedeno uzrokuje ljepljivost tog horizonta u mokroj fazi, dok je u suhom stanju

kompaktan i tvrd (Resulović i Čustović, 2002.). Vodozračni odnosi su nepovoljni, kapacitet tla za zrak (volumen makropora) smanjuje se s porastom dubine, a u iluvijalno-pseudoglejnom horizontu pada ispod 6 % (Ćirić, 1984.).

U pogledu kemijskih svojstava, reakcija tla (pH) je jako kisela do kisela, a kreće se uglavnom od pH (H₂O) 5 – 5,5, dok se zasićenost adsorpcijskog kompleksa bazama kreće u rasponu od 20 do 50 %. U slabo propusnom horizontu pH i zasićenost bazama blago raste, a taj porast često se nastavlja s povećanjem dubine (Ćirić, 1984., Škorić, 1986., Resulović i sur., 2008.). Pseudogleji pod prirodnom vegetacijom općenito su dobro opskrbljeni humusom (poglavito plitki dio površinskog horizonta). U prirodnim tlima opskrbljenost fosforom iznimno je niska, dok je opskrbljenost kalijem osrednja (Husnjak, 2014.). Uslijed nepovoljnih vodozračnih odnosa i izrazito loših kemijskih svojstava, loša su i njegova biološka svojstva (Škorić, 1986., Husnjak, 2014.). Zbog pojave anaerobnih uvjeta u tlu, brojnost aerobnih mikroorganizama izrazito je mala, a slabije propusni horizont negativno utječe na rast i razvoj korijena (Škorić, 1986.).

Obzirom na gore opisana fizikalna, kemijska i biološka svojstva pseudogleja, može se zaključiti kako se radi o tlu uglavnom niskog proizvodnog potencijala kojeg prvenstveno obilježava nepovoljan vodozračni režim, loš toplinski režim, slaba opskrbljenost fiziološki aktivnim hranjivima, niska biološka aktivnost te srednje duboka do plitka ekološka dubina (Husnjak, 2014.). Zbog svega navedenog, ovo tlo svrstava se u skupinu tala s niskim proizvodnim potencijalom, odnosno u skupinu tala ograničeno pogodnih za intenzivnu poljoprivrednu proizvodnju. Ipak, obronačni podtip sekundarnog pseudogleja ima nešto veći proizvodni potencijal u odnosu na podtip razvijen na zaravni, s obzirom na kraće trajanje mokre faze i na nešto veću ekološku dubinu (Husnjak, 2014.). Petošić i Tomić (2011.) navode kako pogodnost pseudogleja za uzgoj različitih poljoprivrednih kultura varira ovisno o trajanju mokre faze u tlu. Isti autori navode kako se na pseudogleju na zaravni najčešće uzgajaju ratarske kulture i industrijsko bilje, dok je manji dio pod pašnjacima. Pseudoglej obronačni najviše se koristi za uzgoj voćnih vrsta (do 10 % nagiba) i vinove loze na nagibima većim od 10 %.

U praksi, kako bi se na pseudogleju omogućila ekonomski profitabilna proizvodnja najčešće se primjenjuju određene agro i hidro tehničke melioracijske mjere. S obzirom da je osnovno ograničenje pseudogleja za intenzivnu poljoprivrednu proizvodnju nepovoljan vodozračni režim, posebna pažnja posvećuje se upravo rješavanju te problematike (Škorić, 1986., Resulović i Čustović, 2002.).

Dakle, ovo tlo obilježava prisustvo slabije propusnog iluvijalno-pseudoglejnog horizonta, odnosno vertikalni teksturni kontrast. Osim što zbijeni potpovršinski horizont nastaje tijekom pedogeneze (npr. lesivirano tlo - pseudoglej), može nastati i uslijed različitih agrotehničkih

operacija ukoliko uzrokuju jako zbijanje tla (Horn i Smucker, 2005.), (npr. upotreba teške mehanizacije, obrada tla u stanju nepovoljne vlažnosti). Prisutnost slabije propusnog horizonta uzrokuje kod pojave prekomjernog vlaženja smanjenu aeraciju sloja iznad njega i ograničenja u rastu korijena (Hardie i sur., 2012.), loš status hranjiva u tlu, eroziju tla, što u konačnici dovodi do smanjenog prinosa usjeva. Zbijeni (ili slabo propusni) horizont u tlu uzrokuje povećanje volumena korijena u gornjim (iznad zbijenog horizonta) i smanjenje volumena korijena u dubljim slojevima tla.

Hardie i sur. (2012.) navode kako na prijelazu između gornje zone i zone slabo propusnog horizonta dolazi do jakog smanjenja infiltracije, što na nagnutim terenima može dovesti do pojave potpovršinskog lateralnog toka. Pojava potpovršinskog lateralnog toka vode na obronačnim tlima utječe na transport otopljenih tvari, a s time i na kakvoću podzemnih, ali i površinskih voda (Garg i sur., 2005.). Potpovršinski lateralni tok vode na obroncima izraženiji je u humidnoj klimi (Weiler i sur., 2005.), međutim može se javiti i u semiaridnim područjima (Pirastru i Niedda 2013., van Schaik i sur., 2008.). Potpovršinski lateralni tok može dovesti do prekomjerne saturacije donjih dijelova obronka.

2.3. Specifičnosti uzgoja vinove loze

Imajući u vidu istraživanje u sklopu ove doktorske disertacije, važno je napomenuti kako se većina vinograda u svijetu nalazi na nagnutim terenima. Prema podacima FAOSTAT – a iz 2021. godine, Hrvatska ima oko 22 000 ha vinograda, od čega se veliki dio njih nalazi na nagnutim terenima. Imajući na umu činjenicu da se upravo pseudoglej obronačni u velikoj mjeri razvija upravo na ovakvim reljefnim formama, za očekivati je da se velike površine vinograda nalaze upravo na pseudogleju obronačnom. Međutim za potvrdu ove teze u literaturi nema podataka.

Rast vinove loze, te kvaliteta grožđa, a kasnije i vina pod velikim je utjecajem interakcije klime, tla i biljke što zajedno s vinogradarskom i enološkom tehnologijom u procesu proizvodnje čini koncept terriora (Deloire i sur., 2005., Reynolds i sur., 2007.). Osim klime, u vinogradarskoj proizvodnji, kvaliteta tla također je ključan čimbenik koji određuje kvalitetu grožđa (van Leeuwen i sur., 2009.), koju je često jako teško održavati zbog prisutnih procesa degradacije tla u vidu erozije. Van Leeuwen i sur. (2004.) navode kako klima, tlo i sorta vinove loze imaju velik utjecaj na koncentraciju sekundarnih metabolita odgovornih za kvalitetu vina, međutim, puni potencijal pojedine sorte nije moguće ostvariti ukoliko se ista ne uzgaja u odgovarajućim agroekološkim uvjetima. Osim što općenito utječe na rast i razvoj vinove loze te na kvalitetu grožđa, tlo u prvom redu utječe na rast i razvoj korijenovog sustava. Vinova loza (*Vitis vinifera*) kao vrsta, svojim korijenovim sustavom uglavnom ne ulazi u tlo već se naciepljuje na različite podloge. Kober 5BB (*Vitis Berlandieri* × *Vitis Riparia*) najzastupljenija je podloga u kontinentalnoj Hrvatskoj. Karakterizira ju dobra adaptacija prema različitim tipovima tala, relativno kratak vegetacijski ciklus. Podnosi do 20% fiziološki aktivnog vapna (60% ukupnog) otporna je na filokseru te na niske zimske temperature (Mirošević i sur., 2009.). Imajući u vidu navedeno Kober 5BB s pravom se smatra univerzalnom podlogom. Fizikalna svojstva tla u osnovi reguliraju rasprostranjenost (proraštenost) korijena u tlu te dostupnost vode i zraka korijenu (Smart i sur., 2006.). Tako je Nagarajah (1987.) uspoređivao dubinu ukorjenjivanja vinove loze na vlastitom korijenu i naciepljenu na podlogu Ramsey (*Vitis champim*). Istraživanjima je utvrdio da je dubina ukorjenjivanja vinove loze veća u grubom (skeletalnom) tlu kod kojeg je korijenje bilo rasprostranjeno cijelom dubinom profila, dok je u teksturno lakšem tlu korijen vinove loze bio rasprostranjen u površinskih 40 do 60 cm profila. Isto tako rezultati istraživanja ukazuju da je vinova loza naciepljena na podlogu razvila veći korijenov sustav u odnosu na vinovu lozu uzgajanu na vlastitom korijenu. O veličini i zdravlju korijena ovisi i kondicija nadzemnog dijela trsa (Smart, 1995.), a samim time prinos i kvaliteta grožđa. Što se pak tiče utjecaja teksture na prinos grožđa, utvrđeno je kako različita tekstura tla može doprinijeti razlikama u prinosu i kvaliteti grožđa (van Leeuwen i sur., 2004.). White (2015.) navodi kako su dubina tla, vodopropusnost i tekstura bili ograničavajući čimbenici kod odabira

položaja za uzgoj vinove loze, s obzirom na njihov izrazit utjecaj na ukorjenjivanje i dostupnost fiziološki aktivne vlage. Trought i sur. (2008.) navode kako je pH grožđa bio viši, a ukupna kiselost niža kod vinove loze koja je rasla na plitkom tlu. Sadržaj vlage u tlu također utječe na prinos i kvalitetu grožđa i jedan je od ograničavajućih čimbenika rentabilne vinogradarske proizvodnje. Iako je nedostatak vode uglavnom povezan s klimom određenog područja, sadržaj vlage u tlu ovisi i o fizikalnim značajkama tla. Ograničenja u skladištenju vlage u tlu mogu proizaći iz teksturnog sastava tla (tla s visokim udjelom pijeska) ili uslijed postojanja zbijenog odnosno slabije propusnog horizonta na određenoj dubini (Lanyon i sur, 2004.) (npr. pseudoglej) koji priječi dubinsko otjecanje vode.

Intenzivna upotreba poljoprivrednih strojeva tijekom različitih operacija u vinogradarskoj proizvodnji utječe na zbijanje tla u međurednom prostoru (Hamza i sur., 2011.). Navedeno uzrokuje smanjenje prinosa uslijed povećanja mehaničke otpornosti na rast korijena u tlu te dostupnosti vode i hranjivih tvari (Lanyon i sur., 2004.).

Iz svega navedenog može se zaključiti kako svojstva tla imaju značajan utjecaj na prinos i kvalitetu grožđa i vina. Heterogenost svojstava tla može imati različit utjecaj na rast i razvoj vinove loze na malom prostoru. Pozicije sa izraženom heterogenošću tla predstavljaju upravo obronačne reljefne forme, gdje se svojstva tla, a posljedično i sadržaj vlage u tlu mijenja ovisno o poziciji na obronku. Obzirom na različita svojstva tla na različitim reljefnim pozicijama za očekivati je da će se prinos i kvaliteta grožđa razlikovati ovisno o poziciji.

Zbog relativno duboko razvijenog korijenovog sustava i fizioloških mehanizama koji kontroliraju transpiraciju, vinova loza dobro je prilagođena mediteranskoj klimi (Chaves i sur., 2010.). Međutim, kombinirani učinak nedostatka vode u tlu i atmosferski uvjeti koji utječu na pojačanu evapotranspiraciju mogu biti štetni u mediteranskim regijama. Osim u primorskim regijama s mediteranskom klimom, u vrijeme kada su klimatske promjene sve izraženije, ovakvi negativni učinci dobivaju na važnosti i u kontinentalnim regijama. Stoga, Chaves i sur. (2010.) navode kako bi primjena navodnjavanja ublažila negativne posljedice suše. S obzirom na ograničene vodne resurse i optimizaciju navodnjavanja od izrazite je važnosti odrediti razinu stresa suše kod vinove loze. Status vode u biljci određen je ravnotežom između upijanja vode od strane korijena, a koji ovise o karakteristikama korijena, količinom raspoložive vlage u tlu te intenzitetom transpiracije (koja ovisi o atmosferskim uvjetima) Mirás – Avalos i Araujo (2021.). Razina vodnog stresa kod biljaka pa tako i vinove loze može se utvrditi mjerenjem vodnog potencijala lista i/ili stabljike. U literaturi postoji nekoliko različitih mišljenja o tome da li potencijal lista mjeren prije izlaska sunca ili točno u podne daje najbolje informacije o vodnom statusu biljke. Tako Williams i Araujo (2002.) navode kako mjerenje vodnog potencijala lista pred svitanje i vodnog potencijala stabljike u podne mogu dati pouzdane informacije o vodnom

stresu biljke. Pojedini znanstvenici navode kako je podatak o vodom potencijalu vinove loze pred svitanje bolji pokazatelj razine vodnog stresa (npr. Deloire i sur., 2005., Lopes i sur., 2011.), dok drugi (npr. Williams i Trout, 2005., Yuste i sur., 2004.) navode kako je minimalni vodni potencijal lista (određen u podne) najkorisniji pokazatelj razine vodnog stresa. Ovakva, oprečna mišljenja mogla bi se objasniti različitim sortama, podlogama, tipu tla i svojstvima tla, sadržaju vode u tlu, vremenskim uvjetima tijekom istraživanja, površini lista, opterećenju trsa (Williams i Araujo, 2002., Williams i Trout, 2005., Choné i sur., 2001.). Pretpostavlja se da vodni potencijal biljke (izmjereno na listu) dolazi u ravnotežu sa vodnim potencijalom tla neposredno prije izlaska sunca, stoga, te vrijednosti neki znanstvenici koriste za procjenu dostupnosti vode u tlu (npr. Choné i sur., 2001.). Međutim, iako su biljni pokazatelji vodnog statusa teoretski pouzdaniji u utvrđivanju vodnog stresa biljke, relativno se teško određuju, potrebno ih je određivati u određeno doba dana i u svemu tome teško je biti kontinuiran tijekom dugog razdoblja (npr. tijekom cijele vegetacije).

2.4. Voda u tlu

Sadržaj vode u tlu jedan je od ključnih parametara globalnog hidrološkog ciklusa. Vlažnost tla vrlo je promjenjiva u vremenu i prostoru zbog kombiniranog utjecaja mnogih čimbenika poput hidrauličkih svojstava tla, topografije, interakcije s površinskim vodnim sustavima, oborinama, ali i ostalim meteorološkim uvjetima (npr. temperaturom zraka, brzinom vjetrova) (Huang i sur., 2016.). Voda u tlu pod utjecajem je različitih sila koje kontroliraju njeno kretanje, a koje su uzrokovane interakcijom čvrste faze tla (matriksa), vode, te u njoj otopljenih tvari, djelovanjem atmosferskog tlaka i sile teže. Zbog tih sila voda ima potencijalnu energiju. Potencijalna energija može se prikazati po jedinici volumena ili po jedinici težine. Ovisno o načinu prikazivanja, vodni potencijal označava se kao ψ [Pa] (energija/volumen) ili kao H [m] (energija/težina). Veza između ψ i H je:

$$\psi = \rho_w g H, \quad (2.1)$$

gdje je ρ_w gustoća vode, a g je akceleracija sile teže (Radcliffe i Šimunek, 2010.). HYDRUS softverski paket koji je korišten u ovom radu, označava vodni potencijal u [m] stoga će se u nastavku rada oznaka za vodni potencijal koristiti H [m].

Potencijal uzrokovan silom teže prikazan je formulom:

$$z = z_s - z_0, \quad (2.2)$$

i nastaje zbog razlike u dubini vode u tlu (z_s) i referentne točke (z_0), za koju se uzima površina tla i uvijek je negativnog predznaka.

Komponenta h javlja se u saturiranim (hidrostatski potencijal) i nesaturiranim (matrični potencijal) uvjetima. U saturiranim uvjetima uzrokovana je hidrostatskim tlakom koji stvara voda u slojevima iznad promatranog

$$h = z_{wt} - z_s, \quad (2.3)$$

gdje je z_{wt} dubina podzemne vode.

Otopljene tvari vezanjem za polarizirane molekule vode smanjuju njezinu energiju, odnosno potencijal vode zbog sadržaja otopljenih tvari (osmotski potencijal, s) je uvijek negativan:

$$s = \frac{-RTC_s}{\rho_w g}. \quad (2.4)$$

Što su veći ukupna koncentracija otopljenih tvari C_s [ML⁻³] i temperatura T [K], veći je iznos negativnog potencijala. R je plinska konstanta.

Sastav čvrste faze tla značajno doprinosi potencijalu vode (h) u nesaturiranim uvjetima preko kapilarnosti i adsorpcije. Naime, što su pore uže, veća je kapilarnost, što posljedično utječe na smanjenje energije vode. Veća količina nabijenih čestica (npr. glina) veže molekule vode i time smanjuje njen potencijal. U nesaturiranom tlu, h je najvažnija komponenta ukupnog potencijala i uvijek je negativnog predznaka, a iznos potencijala ovisi o količini vode u tlu. Oznaka h koristi se i za komponentu vodnog potencijala uzrokovanu hidrostatskim tlakom, ali se ona javlja samo u saturiranim tlima i uvijek je pozitivna.

Tlak zraka u nesaturiranom tlu također utječe na potencijal vode (a) zbog razlike u iznosu atmosferskog tlaka i tlaka zraka u porama tla. S obzirom na to da se njegov doprinos teško mjeri, najčešće se izostavlja u računanju ukupnog potencijala vode.

Dakle, ukupni vodni potencijal u saturiranim uvjetima je

$$H = z + h + s, \quad (2.5)$$

gdje su dominantni članovi doprinosi sile teže (z) i hidrostatskog tlaka (h), dok su u nesaturiranim uvjetima:

$$H = z + h + s + a, \quad (2.6)$$

dominantni doprinosi sile teže (z) i matriksa (h).

Retencijskim krivuljama opisuju se ravnotežna stanja između količine vode u tlu (vol % ili cm³ cm⁻³) i vodnog potencijala tla odnosno sile kojom čestice tla vežu vodu. Predstavljaju važno

hidrauličko svojstvo tla, koje je pod utjecajem teksture i strukture tla te sadržaja organske tvari. Kako je već navedeno, voda u tlu drži se određenim silama, a sva voda u tlu nije dostupna biljci. Naime, biljci je dostupna vlaga koja se u tlu drži silama između 0,33 i 15 bara i predstavlja tzv. fiziološki aktivnu vlagu ili biljci pristupačnu vodu. Voda u tlu koja se drži silama manjim od 0,33 bara je procjedna voda, dakle drenira se kroz makropore u dublje slojeve. Količina vode u tlu koja se drži silama većim od 15 bara predstavlja nepokretnu vodu (vlagu). Sila držanja (eng- *suction*) vode u tlu kod 15 bara naziva se i točka venuća.

Točne podatke o sadržaju vlage po dubini profila (na pojedinoj lokaciji) moguće je dobiti praćenjem sadržaja vlage u tlu, odnosno režima vlažnosti tla koji predstavlja periodične promjene vlažnosti tla po dubini profila. Husnjak i sur. (2002.) praćenjem režima vlažnosti hidromelioriranog pseudoglej – gleja utvrđuju su da je određeni dio godine u tlu rizosferi prisutan višak vode. S obzirom da je navedeno tlo hidromeliorirano (drenirano), višak vode u pripisuju izostanku agrotehničke mjere podrivanja odnosno slabom održavanju sustava detaljne odvodnje. Rastija i sur. (2008.) pratili su režim vlažnosti na lesiviranom tlu tijekom dvije vegetacijske godine. Prve godine, u uvjetima uzgoja kukuruza, utvrdili su da je tijekom cijelog vegetacijskog razdoblja prisutan deficit vode u tlu. Tijekom druge godine istraživanja, u uvjetima uzgoja pšenice, utvrđen je manjak samo u kratkom vremenskom razdoblju (tijekom svibnja).

Tok vode u tlu može se odvijati u saturiranim i ne saturiranim uvjetima, (Weil i Brady, 2016.). Pod saturiranim tlom smatra se ono kod kojeg su mikro i makro pore ispunjene vodom, dok se kod ne saturiranog tla u mikroporama nalazi voda, a u makroporama zrak (Hillel, 2004.). Tok vode, također, može biti stacionaran i nestacionaran. Stacionarni tok je konstantan u vremenu, za razliku od nestacionarnog kod kojeg iznos i/ili smjer i gradijent potencijala variraju u vremenu.

Stacionarni tok vode u saturiranom tlu opisuje se Darcyevim zakonom koji govori da je tok proporcionalan gradijentu potencijala:

$$q_z = -K_s \frac{\partial H}{\partial z}, \quad (2.7)$$

gdje je q_z tok vode (volumen vode [L³] kroz površinu A [L²] u vremenu t [T]) [L/T] (L od eng. *length*, T od eng. *time*), K_s hidraulička vodljivost [L/T] za saturirane uvjete, z je vertikalna koordinata (pozitivno prema gore) [L], a H ukupni potencijal vode (eng. *soil water potential head* ili *hydraulic head*) [m]. Darcyev zakon govori da je za tok vode u tlu bitan gradijent energije i hidraulička vodljivost tla (Radcliffe i Šimunek, 2010.).

Za tok u saturiranim uvjetima, najvažniji parametar tla je hidraulička vodljivost $K_s = \frac{k\rho g}{\eta}$, gdje je

k intrinzična permeabilnost tla [L^2], ρ gustoća fluida [ML^{-3}], g akceleracija sile teže [LT^{-2}], a η koeficijent dinamičke viskoznosti fluida [$ML^{-1}T^{-1}$]. Iz jednačbe za K_s vidljivo je da ona ovisi o temperaturi (preko ovisnosti ρ i η o temperaturi), dok je k konstanta koja ovisi o svojstvima tla. Buckingham (1907.) je proširio Darcyev zakon za uvijete nesaturiranog toka gdje hidraulička vodljivost u ovom slučaju ovisi o vodnom potencijalu h :

$$q = -K(\theta) \left[\frac{\partial h}{\partial z} + 1 \right]. \quad (2.8)$$

Tok vode u tlu uglavnom je nestacionaran, za koji vrijedi jednačba kontinuiteta:

$$\frac{\partial \theta}{\partial t} = -\frac{\partial q}{\partial z}, \quad (2.9)$$

gdje je θ volumni sadržaj vode [$L^3 L^{-3}$], a t vrijeme [T].

Uvrštavanjem Darcy–Buckinghamovog zakona u jednačbu kontinuiteta dobije se Richardsonova jednačba kojom se opisuje tok vode u nesaturiranom tlu:

$$\frac{\partial \theta}{\partial t} = \frac{\partial}{\partial z} \left[K(\theta) \left(\frac{\partial h}{\partial z} + 1 \right) \right] - S, \quad (2.10)$$

gdje S predstavlja izvore (oborine ili navodnjavanje) ($S < 0$) ili usvajanje ($S > 0$) vode (npr. transpiracija tj. usvajanje korijenom).

Za razliku od saturiranih, u nesaturiranim uvjetima hidraulička vodljivost ovisi o vodnom potencijalu.

Ovisnosti hidrauličke vodljivosti o vodnom potencijalu čini Richardsovu jednačbu nelinearnom, te se kao takva, nelinearna parcijalna diferencijalna jednačba, analitički se može riješiti samo u vrlo pojednostavljenim slučajevima, zbog čega se rješava numerički, pomoću modela.

Uz spomenute i detaljno objašnjene uvjete toka vode (u saturiranim i ne saturiranim uvjetima), u tlu se mogu javiti različiti „tipovi“ toka vode. Tako u tlu može doći do pojave vertikalnog toka vode, koji je brži u pjeskovitim i lateralni, koji je izraženiji u glinastim tlima (Weil i Brady, 2016.). Warrick i sur. (1997.) navode kako slojevitost tla može povećati pojavu lateralnih tokova vode u tlu. Potpovršinski lateralni tok javlja se na obroncima (Filipović i sur., 2018a., Kim i sur., 2005.), a odnosi se na procese u kojima se infiltrirana voda akumulira i lateralno kreće niz nagib po površini slabije propusnog horizonta (Hardie i sur., 2012.). Ako se slabo propusni horizont u profilu nalazi ispod propusnog horizonta te ako je granica između horizonata oštra

(s obzirom na teksturu), slabije propusni horizont onemogućava vertikalnu infiltraciju što rezultira potpovršinskim lateralnim tokom (Hardie i sur., 2012.).

Još jedan od bitnih pojmova u opisu toka vode u tlu je preferencijalni tok. Preferencijalni tok predstavlja neravnomjerno, odnosno brže kretanje vode kroz makropore koje mogu nastati nakon odumiranja korijena te djelovanjem faune ili korijena biljaka (Weil i Brady, 2016., Gerke, 2006.), ali i bubrenjem i stezanjem gline te inkorporacijom organskih materijala ili obradom tla (Filipović i sur., 2014., Filipović i sur., 2019.). Najčešće vrste preferencijalnog toka je tok vode kroz makropore (biopore ili pukotine u tlu nastale različitim mehanizmima), "*finger flow*" koji predstavlja neujednačen tok vode uslijed hidraulične heterogenosti u tlu, te ljevkastog tok (eng. *funnel flow*) koji predstavlja tok iznad pojedinih slojeva u tlu (Guo i Lin, 2018.). Preferencijalni tok u prvom redu ovisi o karakteristikama pora i svojstvima tla kao što su tekstura i struktura, hidrauličkim svojstvima te utjecaju čovjeka tijekom obrade tla (Jarvis, 2007.). Pozitivan utjecaj preferencijalnih tokova na ravnom reljefu ogleda se u vidu regulacije poplava, dok na obroncima utječe na sprječavanje erozije i odrona čime se povećava stabilnost obronka (Ghestem i sur., 2011., Guo i Lin, 2018.). Filipović i sur. (2020.) istraživali su strukturu vinogradarskog tla i preferencijalni tok vode u kolonama primjenom različitih nedestruktivnih laboratorijskih metoda kao i primjenom numeričkih metoda (HYDRUS 1D), trasera te CT skeniranja kolona tla. Pretpostavka istraživanja bila je da bi primjena različitih metoda mogla otkriti više informacija o strukturi tla, poroznosti i toku vode. U svom istraživanju kao ulazne podatke za model koristili su informacije o hidrauličkim svojstvima tla dobivenim temeljem evapotranspiracijske metode. Tok vode simuliran je HYDRUS 1D modelom. Podaci prikupljeni tijekom istraživanja nisu potvrdili pojavu neravnoteže protoka i razlika između modela jednostruke poroznosti (eng. *single porosity*) i dvostruke propusnosti (eng. *dual – permeability*) poroznosti. Međutim, primjenom trasera i CT – skeniranjem kolona tla utvrdili su postojanost složene mreže pora tla (eng. *pore – architecture network*) s pojavom horizontalnih i vertikalnih biopora, koje imaju karakteristike preferencijalnog toka. Navedeni autori zaključuju kako kombinacija različitih metoda istraživanja poroznog sustava omogućuje adekvatnu procjenu strukture (poroznog sustava) i preferencijalnog toka kod heterogenih tala kao što su poljoprivredna vinogradarska tla.

Osim potpovršinskog toka, na obronku se javlja i površinsko otjecanje vode u uvjetima kada je tlo maksimalno saturirano ili kada je intenzitet oborina veći od infiltracije. Na pojavu površinskog otjecanja utječu topografija, vegetacija, stabilnost agregata, meteorološki uvjeti (Joel i sur., 2002.).

2.4.1. Hidraulička svojstva tla

Hidraulička svojstva tla (retencija vode i hidraulička vodljivost) najvažniji su parametri koji kontroliraju, odnosno predstavljaju osnovu za razumijevanje raznih procesa u tlu, kao npr., brzinu toka te zadržavanja vode u tlu, kretanje hranjivih tvari ali i onečišćivača u tlu, određivanje količini biljci pristupačne vode, infiltraciju i evaporaciju vode iz tla (Bodhinayake i Si, 2004., Mohanty, 2017., Indoria i sur., 2017.). Dakle, hidraulička svojstva tla opisuju makroskopske odnose između koncentracije tvari u tlu, kemijskog potencijala, te toka vode i u njoj otopljenih tvari i plinova (Durner i Flüher, 2005.). Ti odnosi ovise o mnogim čimbenicima kao što su temperatura, karakteristike matriksa tla, kemijski sastav otopine tla, arhitektura odnosno geometrija pora u tlu, itd. Razumijevanje svih ovih procesa važno je za učinkovito gospodarenje tlom i vodama (Bodhinayake i Si, 2004.). Hidraulička svojstva tla određuju se mjerenjem hidrauličke vodljivosti tla te retencijskih značajki tla, a kasnije ti rezultati mogu poslužiti za određivanje diferencijalne poroznosti (Kreiselmeier i sur., 2019., Weninger i sur., 2018.), odnosno služe kao ulazni parametri za mnoge modele toka i retencije vode u tlu. Karakterizacija hidrauličkih svojstava tla vrlo je važna za razne discipline poput hidrologije, ekologije, pedologije (Durner i Flüher, 2005.), poljoprivrede općenito (Schelle i sur., 2013.) te u modeliranju toka vode i u njoj otopljenih tvari u nesaturiranom tlu (Šimůnek i sur., 2005., Šimůnek i sur., 2016., Vereecken i sur., 2008.). Određivanje hidrauličkih svojstava tla je dugotrajno, zahtijeva korištenje neporušenih uzoraka tla, a i ekonomski je skupo. S obzirom na važnost hidrauličkih svojstava tla za praktične potrebe bitna je njihova brza i jednostavna procjena. Stoga, korištenje tzv. pedotransfer funkcija predstavlja alternativni alat za procjenu hidrauličkih svojstava tla (Patil i Singh, 2016.). Pedotransfer funkcijama moguće je procijeniti hidraulička svojstva tla na temelju lakše mjerljivih svojstva tla (npr. tekstura, volumna gustoća, sadržaj organske tvari u tlu). Glavni nedostatak korištenja pedotransfer funkcija u određivanju hidrauličkih svojstava tla je da mogu biti primjenjive samo na malom prostoru. Hidraulička vodljivost tla, kao glavno svojstvo koje ima velik utjecaj na kretanje vode u tlu (Wang i sur., 2016.), ovisi o teksturi i strukturi tla, koje pokazuju izrazitu prostornu heterogenost (Vereecken i sur., 2008.), na temelju čega se da zaključiti kako je procjena hidrauličke vodljivosti tla na temelju pedotransfer funkcija izrazito teška. Parametrizacija hidrauličkih svojstava tla važna je iz razloga što se hidraulička svojstva tla koriste kao ulazni parametar u modeliranju toka i retencije vode u tlu.

Za određivanje hidrauličkih parametara tla u novije vrijeme koristi se potpuno automatizirani HYPROP (HYdraulic PROperty analizador METER Group, Inc., Pullman, WA, USA) sustav. Osim određivanja hidrauličkih svojstava tla, u HYPROP–FIT softveru postoji mogućnost izrade hidrauličkih i retencijskih krivulja (Schindler i sur., 2010.). Tijekom godina razvijeno je nekoliko jednadžbi (modela) za prilagodbu hidrauličkih i retencijskih krivulja mjerenjima, od kojih se

najviše koriste Brooks–Corey (Brooks i Corey, 1964.), Fredlund–Xing (Fredlund i Xing, 1994.), Kosugi (Kosugi, 1996.), i van Genuchten (van Genuchten, 1980.). Navedene jednadžbe inkorporirane su u HYPROP–FIT softver. Osim osnovnih modela, za neke modele razvijene su i različite varijante koje se mogu koristiti ovisno o homogenosti/heterogenosti poroznog sustava tla. U HYPROP–FIT softver, uključene su varijante: *original*, *bimodal*, *PDI*, *PDI bimodal*. *Original* varijanta modela pretpostavlja homogeni porozni sustav pa nije primjerena za pojedine tipove tala. S obzirom na to, Romano i sur. (2011.) predlažu da se porozni sustav tla razdvoji na teksturalni i strukturalni odnosno na pore unutar i između agregata tla. Sve je više primjera korištenja HYPROP sustava u određivanju hidrauličkih značajki tla (npr. Schelle i sur., 2013., Bezerra – Coelho i sur., 2018., Defterdarović i sur., 2021., Haghverdi i sur., 2020.).

2.5. Primjena numeričkih modela u procjeni toka i retencije vode u tlu

Zbog velike varijabilnosti prirodnih uvjeta, postizanje točnosti u procjeni vlažnosti tla predstavlja velik izazov. U posljednjih 40–ak godina znanstvena zajednica prepoznala je važnost podataka o vlazi tla kao ulaznog parametra za razvoj novih pristupa i tehnika monitoringa te za modeliranje raznih procesa u tlu (Brocca i sur., 2017.). Razvojem računalne tehnologije, u svim granama znanosti sve se češće upotrebljavaju razni numerički modeli. Numerički modeli toka vode služe, između ostalog, za istraživanje i predikciju režima vlažnosti tla u jedno- i/ili više-dimenzionalnom prostoru (Šimůnek i sur., 2016.). Nekoliko je jednodimenzionalnih (1D) modela koji se koriste za simuliranje vode i u njoj otopljenih tvari u varijabilno saturiranom tlu, npr., LEACHM (eng. *Leaching Estimation and Chemistry Model*, Huston i Wagenet, 1989), SWAP (eng. *Soil Water Atmosphere Plant*, van Dam i sur., 1997.), RZWQM (eng. *Root Zone Water Quality Model*, Hanson i sur., 1998.). Međutim, za predviđanje i analizu toka vode te transporta otopina u tlu jedni od najčešće korištenih modela su HYDRUS 1D i HYDRUS 2D/3D. HYDRUS modeli simuliraju tok vode i otopljenih tvari (kao i topline i plinova) u varijabilno saturiranom tlu (Šimůnek i sur., 2012.). Široku primjenu HYDRUS ima i u simuliranju toka otopljenih tvari, uključujući radionuklide (Mallants i sur., 2003.), mineralne dušikove spojeve (Hanson i sur., 2006.), pesticide (Pot i sur., 2005., Dousset i sur., 2007.), antibiotike (Wehrhan i sur., 2007.). HYDRUS modeli nemaju ograničenje prostornih ni vremenskih skala za koje su primjenjivi. Tako je npr., HYDRUS 2D/3D bio primijenjen na prostornim skalama manjim od jednog metra, pa sve do nekoliko stotina metara, uključujući primjene u laboratorijskim (Silliman i sur., 2002.) i terenskim (Yakirevich i sur., 2010.) uvjetima. Ipak, Šimůnek i sur. (2012.) ne preporučuju korištenje HYDRUS modela na velikim trodimenzionalnim domenama zbog ograničenja računalnih resursa (loše performanse računala). Vremenske skale primjene su od nekoliko minuta do nekoliko tisuća godina, što čini

model pogodnim za proučavanje prošle i sadašnje klime (Scanlon i sur., 2003.), kao i posljedicu klimatskih promjena (Leterme i Mallants, 2011.) u budućnosti.

HYDRUS program bazira se na numeričkom rješavanju Richardsonove jednačbe (jednačba 2.10) koristeći metode konačnih elemenata u prostoru i implicitnu shemu konačnih razlika u vremenu (Radcliffe i Šimůnek, 2010.). Za korištenje modela potrebno je znati vrijednosti hidrauličkih parametara tla, te definirati početne i rubne uvjete u modeliranom sustavu. HYDRUS model omogućava i inverzni pristup, gdje se iz numeričkih rješenja jednačbi toka vode određuju hidraulički parametri. Model koristi Marquardt–Levenberg pristup procjene parametara (θ_r , θ_s , α , n , K_s , I) (Marquardt, 1963.). Ovakav pristup sastoji se od minimiziranja funkcije, koja sadrži informacije o odstupanju između izmjerenih i prognoziranih vrijednosti kao što su količina vode i vodni potencijal.

Velik je broj znanstvenih članaka koji koriste HYDRUS softverski paket u opisu toka i retencije vode i u njoj otopljenih tvari. U nastavku su kao primjer spomenute neke od relevantnih studija vezanih za modeliranje toka vode. Wang i sur. (2016.) koriste HYDRUS 1D model za procjenu utjecaja dva tipa vegetacije (grmlje i drveće) na sadržaj vlage u tlu. Sadržaj vlage u tlu praćen je na 10, 20 i 40 cm dubine TDR senzorima. Simulacije dobivene HYDRUS modelom dobro su se podudarale sa podacima izmjerenim senzorima postavljenim u tlu. Filipović i sur. (2018b.) proučavali su utjecaj zbijenog potpovršinskog C horizonta na pojavu potpovršinskog lateralnog toka na obronku. Numeričkom simulacijom pomoću HYDRUS 2D programa, utvrdili su pojavu potpovršinskog lateralnog kretanja vode u tlu tijekom ljetnih oluja s velikim količinama oborina. Li i sur. (2017.) koriste HYDRUS 1D model za simulaciju kretanja vode u tlu u uvjetima reduciranog navodnjavanja. Rezultati istraživanja ukazuju na uspješno korištenje HYDRUS modela u simulaciji toka vode u tlu. Filipović i sur. (2019.) simulirali su infiltraciju vode na opožarenom tlu. Rezultati terenskog mjerenja infiltracije vode u tlo na različitom stupnju opožarenog tla korišteni su kao ulazni podaci za inverzno određivanje hidrauličkih parametara potrebnih za kalibraciju HYDRUS 2D/3D modela. Nakon toga primijenili su jednogodišnji klimatski scenarij (za 2016. godinu) s izmjerenim meteorološkim podacima za simulacije u HYDRUS 1D programu. Rezultati simulacije ukazali su da uslijed izloženosti tla visokim temperaturama (npr. šumski požari) dolazi do povećanja repelentnosti tla za vodu, što kod intenzivnijih oborina dovodi do smanjenja infiltracije i povećanja površinskog otjecanja.

Ursulino i sur. (2019.) koristili su HYDRUS 1D model za procjenu vremenske varijabilnosti vlažnosti tla u riječnom slivu Gameleira na sjeveroistoku Brazila. U svom istraživanju uspoređivali su sadržaj vlage u tlu izmjeren TDR senzorima i sadržaj vlage u tlu dobiven numeričkim simulacijama. Hidraulički parametri korišteni kao ulazni podaci za HYDRUS model određeni su pomoću BEST (Beerkan, Estimation of Soil Transfer Parameters) modela i

optimizirani inverznim modeliranjem. Istraživanje je rezultiralo uspješnom kalibracijom modela, čime je HYDRUS 1D model uspješno simulirao režim vlažnosti tla.

Kako je već navedeno, HYDRUS 1D modelom mogu se procijeniti fizikalni i hidraulički parametri inverznom metodom pomoću raznih podataka izmjerenih na terenu. Ovakav pristup za procjenu, odnosno uspješno korištenje inverzne metode u procjeni fizikalnih parametara koristili su mnogi znanstvenici (npr. Siltecho i sur., 2015., Lai i Ren, 2016., Nascimento i sur., 2018.).

HYDRUS softverski paket pronašao je veliku primjenu u simulacijama u tlu poput procesa transporta pesticida, nitrata, preraspodjele vode u tlu, dubinskog otjecanja, usvajanja vode od strane biljke. Kao rezultat primjene pesticida i nitrata na poljoprivrednim tlima, moguća je njihova pojava u podzemnim ali i površinskim voda. Razgradnja i sorpcija pesticida glavni su procesi koji kontroliraju njihov transport u nesaturiranoj zoni tla (Cheyins i sur., 2010.). Međutim, brzi, neuravnoteženi tok vode kroz makropore (preferencijalni tok) može uzrokovati ispiranje pesticida (ali i nitrata) u podzemne vode prije nego što dođe do njihove degradacije ili sorpcije na koloide tla. Proces ispiranja onečišćivača u dublje slojeve pod utjecajem je svojstava tla i okolišnih uvjeta. Za opisivanje kretanja onečišćivača kroz tlo u HYDRUS model uključene su jednačbe advekcije i disperzije. Brojni su primjeri korištenja HYDRUS softverskog paketa u opisu kretanja i sudbine (eng. fate) onečišćivača u tlu (Köhne i sur., 2006., Horel i sur., 2014., Filipović i sur., 2016.).

Kanzari i sur. (2018.) koristili su HYDRUS 1D model za prognozu zaslanjivanja poljoprivrednog tla u semiaridnom području u Tunisu. U istraživanju je primijenjena voda za navodnjavanje sa četiri različite koncentracije soli (1 dS m^{-1} , 7 dS m^{-1} , 14 dS m^{-1} i 21 dS m^{-1}). Praćenje vlažnosti tla provedeno je pomoću gravimetrijske metode, a salinitet tla mjerenjem električne vodljivosti do 80 cm dubine. Model je kalibriran tijekom 7 dana, a validiran tijekom 383 dana. Izmjerene vrijednosti sadržaja vode u tlu i koncentracije soli slične su simuliranim vrijednostima HYDRUS 1D modelom. Temeljem dobivenih rezultata autori zaključuju kako se HYDRUS 1D model može koristiti kao pouzdan alat za procjenu ekoloških rizika zaslanjivanja tla u uvjetima navodnjavanja vodom lošije kvalitete.


Osim u opisivanju toka i retencije vode u tlu, HYDRUS softverski paket može poslužiti i kao model za prognozu različitih okolišnih čimbenika u budućnosti. Tako su npr. Mallmann i sur. (2014.) koristili HYDRUS model, prilagođen za jednodimenzionalni prostor za simulacije transporta bakra i cinka u tlima s primjenom tekućeg organskog gnojiva za prognozu 100-godišnjeg razdoblja (2000.–2100.) pri različitim načinima obrade tla. Navedeni primjer ukazuje na mogućnost primjene numeričkih modela (npr. HYDRUS) za prognozu različitih okolišnih

čimbenika. S obzirom na navedeno moguće je koristiti HYDRUS model kao alat za prognozu toka i retencije vode u tlu s obzirom na klimatske promjene koje se događaju.

3. MATERIJALI I METODE

3.1. Lokacija istraživanja

Istraživanje u sklopu ove doktorske disertacije provedeno je na vinogradarsko – proizvodnim površinama tvrtke Mladina Plus d.o.o. (prije Mladina d.d.) iz Jastrebarskog. Tvrtka Mladina Plus d.o.o. ima ukupno 70 ha vinograda koji su raspoređeni na nekoliko lokacija na širem području grada Jastrebarskog (Plešivica). Stacionarni pokus postavljen je na lokaciji Rečki gaj (45°41'22" S; 15°38'22" I) (Slika 3.1.). Istraživana parcela, prema Pravilniku o zemljopisnim područjima uzgoja vinove loze (NN, 76/19) pripada pod regiju „Središnja bregovita Hrvatska“, podregiji „Plešivica“, vinogorju „Plešivica“.



Slika 3.1. Lokacija istraživanja (prilagođeno prema Google Earth Pro) u Jastrebarskom


Istraživana parcela nalazi se na obronku jugoistočne ekspozicije, duljine 90 m i oko 14 % nagiba. Nadmorska visina istraživane parcele kreće se od 226 m.n.v. na donjem pa do 240 m.n.v. na gornjem dijelu obronka.

Na istraživanoj parceli 1999. godine zasađen je vinograd sortom Traminac koja je nacijačljena na podlogu Kober 5BB. Razmak sadnje u redu iznosi 1,0 m, a između redova 2,5 m. Redovi su orijentirani niz nagib, a vinograd je zatravnjen. U vinogradu se svake druge godine provodi plitka površinska obrada tla, u svakom drugom međurednom prostoru vinograda. Za vrijeme

trajanja pokusa istraživana parcela nije se obrađivala već su se međuredni prostori održavali košnjom trave s ciljem osiguravanja identičnih uvjeta u tlu tijekom trajanja istraživanja kao i radi sprječavanja oštećenja postavljenje opreme. Međuredni dijelovi vinograda koji su bili uključeni u istraživanje, posljednji put su obrađeni u jesen 2017. godine, a samo istraživanje provedeno je u razdoblju od 1.8.2018. do 1.1.2020.

3.2. Matični supstrat istraživane lokacije

Dominantni matični supstrat koji prevladava na širem području istraživanja okarakteriziran je kao les odnosno pleistocenske ilovine (Slika 3.2.). Prema Husnjaku (2014.) većina kontinentalne Hrvatske prekrivena je upravo lesom odnosno različitim facijesima (derivatima) lesa. Tipični les, uglavnom je homogen, neslojevit, slabo litificiran i izrazito porozan. Obično sadrži od 6-11 % vrlo sitnog i sitnog pijeska, 77-85 % praha te 8-18 % gline, te 6-11 % vrlo sitnog i sitnog pijeska. Pleistocenske ilovine predstavljaju lesne derivate, nekarbonatne su, a nerijetko sadrže preko 30 % gline (Bognar, 1978). Na području Hrvatske mogu se pronaći na zaravnjenim i brežuljkastim predjelima zapadne Slavonije i središnje Hrvatske (Škorić, 1986.).



Slika 3.2. Matični supstrati šireg područja istraživane lokacije (legenda se odnosi na označeno područje istraživane lokacije) prema Husnjaku (2014.).


3.3. Klima istraživanog područja

Prema Gajić – Čapka i Zaninović (2008.), kontinentalna Hrvatska, gdje se nalazi i istraživana lokacija ima umjerenu kontinentalnu klimu, koju karakterizira promjenjivo stanje atmosfere tijekom godine. Prema Köpenu ona se svrstava u umjereno toplu kišnu klimu, a prema Thornthwaiteu u humidnu.

Meteorološki podaci korišteni u ovom doktorskom radu preuzeti su od Državnog hidrometeorološkog zavoda (DHMZ) za mjernu postaju Karlovac. Prilikom planiranja ovog istraživanja, kao ulazni meteo podaci za modeliranje toka i retencije vode u tlu za istraživanu lokaciju planirali su se preuzeti sa meteo postaje Jastrebarsko, međutim zbog kvara na navedenoj postaji meteorološki podaci korišteni u ovom istraživanju preuzeti su sa najbliže meteorološke postaje (Karlovac).

Prema podacima DHMZ – a ukupna količina oborina tijekom 2019. godine iznosila je 934,7, dok je za 2020. godinu iznosila 816,0 mm oborina, dok je za višegodišnji prosjek (1981. – 2018.) prosječna količina oborina iznosila 989,2 mm. Dakle tijekom 2019. godine palo je 54,4 mm , a u 2020. godini 173,2 mm manje oborina u odnosu na višegodišnji prosjek. Iz slike 3.3. vidljivo je kako je količina oborina u 2019. godini tijekom travnja i svibnja, te studenog i prosinca bila veća u odnosu na višegodišnji prosjek, dok je tijekom 2020. godine količina oborina bila veća u svibnju, kolovozu, listopadu i prosincu. Uspoređujući, količinu oborina tijekom 2019. u odnosu na 2020. godinu, može se zaključiti kako je ukupna količina oborina u 2020. bila je manja u odnosu na 2019. godinu za 118,7 mm.

Uspoređujući vrijednosti srednje dnevne temperature zraka za 2019. godinu sa višegodišnjim prosjekom (1981. – 2018.) uočljivo je da je 2019. godina bila toplija za 2,5°C u odnosu na višegodišnji prosjek. Što se tiče vrijednosti srednjih dnevnih temperatura izmjerenih tijekom 2020. godine uočljivo je da je ona bila toplija za 0,9°C u odnosu na višegodišnji prosjek. Uspoređujući međusobno godine istraživanja, 2019. godina bila je prosječno toplija za 1,6°C u odnosu na 2020. godinu. Iz slike 3.3. vidljivo je kako su tijekom 2019. i tijekom 2020. godine svi mjeseci , osim svibnja, bili topliji u odnosu na višegodišnji prosjek.




Slika 3.3. Grafički prikaz oborina i temperatura tijekom istraživanih godina (2019. i 2020.) i višegodišnji prosjeci (1981. – 2018.)

3.4. Terenska istraživanja

Za potrebe izbora redova i međurednih prostora za postavljanje senzora te sustava za površinsko otjecanje, izvršena su preliminarna istraživanja kojima se željela utvrditi homogenost/heterogenost tla po izohipsama istraživane parcele. Ukupno su u preliminarno istraživanje bila uključena tri međuredna prostora vinograda, unutar kojih je na pet pozicija uzorkovano tlo u porušenom stanju u tri ponavljanja od čega je napravljeni prosječni uzorak na jednoj poziciji. Uzorci tla (na svakoj od pozicija) uzorkovani su pedološkom sondom do 110 cm dubine na način da su uzorci podijeljeni prema dubinama i to 0 – 40 cm, 40 – 80 cm i 80 – 110 cm. Dakle ukupno je uzorkovano 45 uzoraka tla (5 pozicija × 3 međuredna prostora × 3 dubine). U rastresitim uzorcima prilikom preliminarnog istraživanja određen je teksturni sastav tla te sadržaj humusa i pH (H_2O i KCl).


Nakon obavljenih preliminarnih istraživanja, u jednom od međurednih prostora vinograda na obronku, izabrano je pet pozicija duž obronka, na kojima su iskopani pedološki profili do dubine od 110 cm. Pozicije odnosno profili bili su jednako udaljeni jedni od drugog. Shema pokusa na obronku prikazana je slikom 3.4.



Slika 3.4. Shema pokusa u Jastrebarskom s prostornim prikazom provedenih istraživanja

Profili u međurednom prostoru orijentirani su tako da je lice profila orijentirano u smjeru nagiba obronka. Profili su odmaknuti 30 cm od reda vinograda.

Opisi pedoloških profila i uzorkovanje tla obavljeno je prema FAO (2006.) i/ili Schoeneberger i sur. (2012.). Nakon utvrđivanja sklopa profila (rasporeda i dubine horizonata) iz svakog horizonta u profilima, u redu i međurednom prostoru uzorkovano je tlo u porušenom i neporušenom stanju za laboratorijske analize. Uzorci u porušenom stanju uzeti su u prethodno označene plastične vrećice, cijelom dubinom horizonta. Uzorci u neporušenom stanju (cilindri volumena 100 cm³) za određivanje fizikalnih analiza uzeti su u pet ponavljanja iz sredine svakog horizonta i po tri cilindra za određivanje brzo i sporo drenirajućih pora na kutiji s pijeskom (eng. *sandbox*). Cilindri su u tlo utiskivani batom i posebnim nastavkom za uzorkovanje tla u neporušenom stanju (Slika 3.5.a). Osim neporušenih uzoraka volumena 100 cm³, na tri pozicije (gore, sredina i dolje) sa dubine od 30 i 90 cm u redu i međurednom prostoru vinograda, uzorkovani su uzorci u neporušenom stanju u cilindrima volumena 250 cm³ (Slika 3.5.b i 3.5.c). Cilindri volumena 250 cm³ korišteni su za određivanje hidrauličkih značajki tla na HYPROP sustavu.



Slika 3.5. Uzorkovanje tla u neporušenom stanju u cilindrima volumena 100 cm³ (a) i volumena 250 cm³ (b i c)

Prilikom opisa pedoloških profila dodatna pažnja posvetila se opisu proraštenosti tla korijenom prema metodi „lica profila“ (eng. *profile wall method*) (Slika 3.6.) koja je detaljno opisana u Böhm (1979.). Analiza rasprostranjenosti korijena određivana je uzduž i okomito na red vinove loze, od 0 – 100 cm dubine, na svih pet pozicija na obronku. Proraštenost tla korijenom u redu analizirala se na 30 cm udaljenosti od stabljike vinove loze, dok je proraštenost tla korijenom u međurednom prostoru (okomito na smjer redova) analizirana u rasponu udaljenosti 30 – 130

cm od stabljike vinove loze. Analiza proraštenosti tla korijenom provedena je pomoću rešetke površine 1 m², sa promjerima otvora 10 × 10 cm (Slika 3.6.). Proraštenost tla korijenom analizirana je na način da je u svakom od otvora na rešetki određen broj korijena različitog promjera. Tako je izbrojano korijenje klasificirano prema promjeru u četiri grupe i to na: > 5 mm, 5 – 2 mm, 2 – 0, 2 mm, te < 0, 2 mm.



Slika 3.6. Analiza proraštenosti tla korijena metodom lica profila na P2 poziciji

Osim opisa proraštenosti tla korijenom, posebna pažnja posvetila se i opisivanju redoksimorfnih značajki tla (RMZ) na istraživanom obronku.

Nakon opisa profila i uzorkovanja tla za laboratorijske analize u tlo su postavljeni “*time domain reflectometer*” (TDR) senzori (CS650 30 cm water content reflectometer plus, Campbell scientific) i tenziometri (253-L Watermark Soil MAttric Potentital Block for Muliplexer Use) za konstantno praćenje sadržaja vlage i vodnog potencijala u tlu. Slika 3.7. prikazuje način postavljanja i raspored senzora i tenziometara u jednom od profila na istraživanom obronku. Senzori su postavljeni u otvorene pedološke profile na svih pet pozicija (P1 do P5) na obronku. Postavljanje TDR senzora u tlo obavljeno je pomoću posebnog nastavka, kojim su u tlu napravljene rupe (istih dimenzija kao igle na TDR senzoru) za precizno postavljanje igle TDR senzora. TDR senzori postavljeni su u red (u glavninu rizosfere vinove loze) te točno u sredinu međurednog prostora vinograda, kako bi se izbjegao utjecaj zbijanja tla uslijed prolaska traktora. Po jedan TDR senzor postavljen je u red i međuredni prostor vinograda i to na 30 i 90 cm dubine dok je po jedan tenziometar postavljen samo na 30 cm dubine, također u redu i međurednom prostoru. Ukupno je po profilu postavljeno četiri TDR senzora i dva tenziometra, što znači je na istraživanoj parceli ukupno postavljeno 20 TDR senzora i 10 tenziometara. Vremenska rezolucija očitavanja sadržaja vode u tlu i vodnog potencijala iznosila je 10 min.



Slika 3.7. Postavljanje i položaj TDR senzora i tenziometara na P3 poziciji

TDR senzori i tenziometri iz svakog profila spojeni su na razvodnu kutiju koja je montirana na armaturu u redu vinograda. Svaka od pet razvodnih kutija od svakog profila spojena je na centralnu baznu stanicu sa koja se sastojala od dataloggera (CR6 Measurement & Control Datalogger), modema sa ruterom za bežični pristup sustavu (Teltonika 4G, TLT – RUT240 – LTE) te sustava napajanja (Slika 3.8.). Sustav napajanja sastojao se od solarnog panela (SOL – PAN – 50) koji je bio postavljen na pocinčani stup na visini tri metra od razine tla. Kao dodatni sustav napajanja u slučaju nedostatka sunčeve energije za napajanje sustava, postavljena je i baterija od 12 V koja je služila za napajanje sustava u vrijeme kada fotonaponska ćelija nije bila u funkciji odnosno kada nije bilo dovoljno sunca (npr. tijekom noći, oblačno vrijeme). Centralna bazna stanica sa dataloggerom nalazila se na sredini obronka.



Slika 3.8. Razvodna kutija (lijevo) i centralna bazna stanica sa dataloggerom (desno)

TDR senzori korišteni u ovom istraživanju mjere volumetrijski sadržaj vlage u tlu u rasponu vlage tla od 0 – 100 %. TDR senzori sastoje se od dvije igle (3,2 mm promjera), međusobno razmaknute 32 mm, duljine 30 cm, koje su napravljene od nehrđajućeg čelika. Senzori mjere sadržaj vlage u volumenu tla od 7800 cm³ (~ 7,5 cm oko svake igle senzora i 4,5 cm od kraja igle). Senzor odašilje impuls kroz iglu i mjeri vrijeme potrebno da impuls dođe do kraja igle i vrati se do početne točke, pri čemu brzina prolaska impulsa ovisi o sadržaju vode u tlu. TDR senzori kalibrirani su prema Malicki i sur. (1996.), koristeći formulu:

$$\theta^* = \frac{1.44 + 7.16\theta - 0.819 - 0.168\rho - 0.159\rho^2}{7.17 + 1.18\rho},$$
 gdje je θ vrijednost izmjerena senzorima, θ^* kalibrirana vrijednost, a ρ volumna gutoća tla.

Tenziometri u tlu određuju potencijal vode mjerenjem električnog otpora. Raspon mjerenja tenziometara korištenih u ovom istraživanju iznosi 0–200 kPa. Tenziometar je konstruiran tako da su dvije koncentrične elektrode smještene unutar referentnog matričnog materijala (tj. gips) koji je omotan sintetičkom membranom za zaštitu od propadanja. Tenziometar postavljen u tlo suši se ili vlaži zajedno sa tlom, a promjena u vlažnosti manifestira se u promjeni otpora (potencijala). Kada je tenziometar mokar, odnosno kada je tlo saturirano, električni otpor je nizak (0 kPa), međutim kako se tlo, a s njime i tenziometar suši, otpor se povećava.

Za praćenje površinskog otjecanja vode na istraživanom obronku (svake godine u jesen) instaliran je sustav za prikupljanje vode (Slika 3.9.). Sustav je postavljan u jesen, a uklonjen u proljeće, radi redovnih operacija u vinogradu koje su se odrađivale traktorom (prskanje vinograda i košnja trave). Sustav za površinsko otjecanje postavljao se u međurednom prostoru na tri pozicije na obronku (gore, sredina i dolje) u ravnini pozicija na koje su postavljeni TDR senzori i tenziometri i to u tri ponavljanja, dakle u tri međuredna prostora. Sustav za površinsko otjecanje sastojao se od limom ograđene parcele površine 1 m² koji je sprječavao pritjecanje vode na ograđenu površinu sa viših pozicija obronka. Isto tako limovi su sprječavali nekontrolirano otjecanje vode po površini, odnosno služili su za usmjeravanje površinskog toga vode u rezervoar na donjem dijelu svake od ograđenih površina. Limovi su postavljeni u oblik romba pri čemu je na donjem dijelu svake parcele bio montiran limeni izljev preko kojeg se količina površinskog toka vode ulijevala u rezervoar (plastične posude volumena 20 litara) (Slika 3.9.) Nakon većih oborina utvrdio se volumen vode u svakom od rezervoara.



Slika 3.9. Prikaz sustava za površinsko otjecanje postavljen u međuredni prostor na istraživanoj lokaciji

S ciljem dobivanja preciznije informacije o svojstvima tla, a u svrhu odabira modela za tok i retenciju vode u istraživanim agroekološkim uvjetima izvršen je laboratorijski eksperiment u kontroliranim uvjetima s kolonama tla u neporušenom stanju. Kolone tla, predstavljale su plastične cijevi promjera 18 cm i visine 40 cm. Prije samog uzorkovanja tla, na cijevi je s unutarnje strane nanoseno ljepilo i kvarcni pijesak, kako bi se prilikom eksperimenta simulacije kišenjem spriječio preferencijalni tok vode između tla i same stijenke cijevi. Cijevi su sa donje strane naoštrene kako bi se lakše utiskivale u tlo. Kolone tla za navedeni eksperiment uzorkovane su u jesen 2020. godine na tri pozicije na obronku, u redu i međurednom prostoru sa dubine 5 – 45 cm. Na svakoj poziciji tlo je uzorkovano u tri ponavljanja, dakle ukupno 18 kolona tla na cijelom istraživanom obronku. Prilikom uzorkovanja kolona tla u međurednom prostoru vodilo se računa o tome da uzorkovanje bude iz sredine međurednog prostora, kako bi se eliminirao utjecaj zbijanja tla uzrokovanog prolaskom traktora. Prije utiskivanja kolona u tlo, uklonjeno je površinskih 5 cm zakorovljenog tla. Kolone su u tlo utiskivane drvenom gredom i batom, pri čemu se vodilo računa da kolone tla u tlo ulaze što je moguće okomitije. Nakon utiskivanja, tlo oko kolona je otkopano, a s donje strane tlo se zarezalo kako bi se kolona odvojila od tla. Kolone su nakon toga omotane u PVC foliju i dopremljene u laboratorij za fiziku tla Zavoda za pedologiju. Slika 3.10. prikazuje uzorkovanje kolona tla.



Slika 3.10. Uzorkovanje kolona tla u međuredu i redu na istraživanoj lokaciji

Osim za eksperiment simulacije kišenja u kontroliranim uvjetima u laboratoriju uzorkovane su i kolone tla s ciljem određivanja točnog izgleda poroznog sustava tla pomoću CT - uređaja. Tlo za ovu analizu uzorkovano je u plastične cijevi, promjera 7,5 cm i visine 10 cm. Prilikom pripreme cijevi za uzorkovanje tla, na unutrašnjost cijevi nanoseno je ljepilo na koje je potom nanesen kvarcni pijesak. Donja strana cijevi zašiljena je kako bi se lakše utiskivala u tlo. Uzorci tla uzorkovani su samo u Ap horizontu na tri pozicije na obronku (gore, sredina, dolje) te u redu i u međurednom prostoru vinograda. Tlo je uzorkovano u tri ponavljanja, dakle ukupno 18 uzoraka tla. Prije uzorkovanja tla, površinskih 5 cm zakorovljenog tla je uklonjeno (Slika 3.11.). Utiskivanje cijevi u tlo vršeno je pomoću daske i čekića, pri tome pazeći da se cijev što ravnomjernije i što okomitije utiskuje u tlo. Nakon utiskivanja, tlo oko cijevi je otkopano, a s donje strane odrezano nožem (Slika 3.11.). Višak tla odrezao se i poravnao s rubom cijevi, nakon čega je na obje strane stavljen filter papir i poklopac, nakon čega su kolone sa tlom zapakirane i poslane na analizu na Czech University of Life Sciences, Prag, Republika Češka.



Slika 3.11. Uzorkovanje kolona tla za CT skeniranje poroznog sustava tla

S ciljem određivanja vodnog stresa vinove loze na različitim pozicijama obronka, mjereno je vodni potencijal na vinovoj lozi prijenosnim uređajem (*Portable Plant Water Status Console, Soil Moisture, USA*) (Slika 3.12.), prema metodi opisanoj u Scholander i sur. (1965.) tijekom vegetacijske sezone u razdoblju od lipnja do sredine rujna 2020. godine. Vodni potencijal mjereno je na potpuno razvijenom lišću vinove loze na tri pozicije na obronku (gore, sredina i dolje – P1, P3 i P5), na trsovima neposredno uz pozicije gdje su u tlo postavili senzori za mjerenje vodnog potencijala tla (trsovi iznad postavljeni senzora). Na svakoj poziciji uzorkovalo se 15 listova (po 5 listova sa 3 trsa) sa sredine mladice, pri čemu se vodilo računa da su listovi podjednake veličine, da nisu oštećeni te da nisu zahvaćeni bolestima. Listovi su uzorkovani u plastične vrećice sa zip zatvaračem koje su stavljene u prijenosni hladnjak, nakon čega su obavljena mjerenja. Uzorkovanje listova provodilo se ujutro (neposredno prije izlaska sunca) i točno u podne. Mjerenje vodnog potencijala vršilo se otprilike svakih 10 dana.



Slika 3.12. Mjerenje vodnog potencijala lista vinove loze

3.5. Laboratorijska istraživanja


Analiza uzoraka tla obavljena je u laboratoriju Zavoda za pedologiju Agronomskog fakulteta u Zagrebu temeljem standardnih laboratorijskih metoda.

Porušeni uzorci tla, nakon dopremanja u laboratorij, osušeni su na zraku, usitnjeni te prosijani kroz sito otvora 2 mm (prema: HRN ISO 11464, 2009.). Mehanički sastav tla odrađen je metodom prosijavanja i sedimentacije nakon disperzije sa natrijevim pirofosfatom ($\text{Na}_4\text{P}_2\text{O}_7$, $c = 0,4 \text{ M}$) (prema: HRN ISO 11277, 2011.). Temeljem dobivenih rezultata postotnog udjela pojedinih frakcija u tlu (pijesak, prah i glina) uzorcima je dodijeljena teksturna klasa pomoću FAO teksturnog trokuta (FAO, 2006.). pH tla određen je elektrometrijski u 1:2,5 suspenziji u destiliranoj vodi i 1M KCl-u temeljem HRN ISO 10390, 2005. Sadržaj humusa odrađen je metodom po Tjurinu, mokrim spaljivanjem sa kalijevim dikromatom ($\text{K}_2\text{Cr}_2\text{O}_7$, $c = 0,4 \text{ M}$) (prema: JDPZ, 1966.). Nadalje, iz porušenih uzoraka određena je i retencija vode u tlu na tlačnom ekstraktoru u kod – 0,33 (Kv) i – 15 bara (Tv) prema Dane i Topp (2002.).

Iz neporušenih uzoraka tla (cilindri volumena 100 cm^3) određena je volumna gustoća (φ_v) suhog tla (HRN ISO 11271, 2004.), gustoća čvrstih čestica tla (φ_c) (HRN ISO 11508: 2004.), kapacitet tla za zrak (Kz) (računski temeljem ukupnog poroziteta (P) i retencijskog kapaciteta tla za vodu (Kv)), ukupna poroznost tla (P) računski temeljem volumne gustoće i gustoće čvrstih čestica. Osim navedenih analiza iz cilindra volumena 100 cm^3 određen je volumen brzo i sporo drenirajućih pora (diferencijalna poroznost) na kutiji s pijeskom (eng. *sandbox*). Volumen brzo drenirajućih pora određen je na podtlaku od – 50 cm (- 0,05 bara), dok je volumen sporo drenirajućih pora određen na podtlaku od – 100 cm (- 0,10 bar). Rezultati analiza vodno – retencijskih značajki tla na kutiji s pijeskom te tlačnom ekstraktoru mogu se koristiti i za izradu retencijskih krivulja.

Određivanje hidrauličkih parametara tla provedeno je temeljem evapotranspiracijske metode (Schindler i Müller, 2017.) pomoću HYPROP automatiziranog sustava (UMS, 2015.) koji je primjenjiv za većinu tipova tala (Haghverdi i sur. 2020.). Ova metoda omogućuje istodobno određivanje retencijske krivulje i hidrauličke vodljivosti nesaturiranog tla u rasponu od potpune saturiranosti tla vodom (0 kPa) i sukcije odnosno podtlaku u tlu do oko - 500 kPa. Kraj mjerenja ne može se točno odrediti, međutim ovisno o teksturi tla varira od pF 3,70 do pF 3,85 (Schindler i sur., 2010.). Na kraju mjerenja izračunava se volumna gustoća tla iz mase apsolutno suhog tla (osušenog na 105°C) i volumena cilindra (250 cm^3). Prije početka mjerenja u uzorku tla posebnim nožićem napravi se mjesto za okomito postavljanje dva tenziometra (gornji – 3,37 cm iznad dna cilindra, i donji 1,25 cm iznad dna cilindra). Nakon postavljanja tenziometara u tlo, cilindar se postavlja na jedinicu senzora za koju se pričvrsti hvataljkama. Cilindar sa tlom se zajedno sa jedinicom senzora postavlja na vagu i sve zajedno spaja se na računalni softver


(Slika 3.13.). Gornji dio cilindra (površina cilindra) izložen je slobodnom isparavanju vode iz uzorka tla. Svaka promjena u masi i podtlaku (tenziji) bilježi se u odabranim vremenskim intervalima (između 10 min i nekoliko sati) (Schindler i sur., 2010). Pojedinačne točke retencijske krivulje izračunavaju se temeljem gubitka vode (promjena u masi) i potencijala vode dobivenog mjerenjem tenziometrima u uzorku tla u određenom trenutku. Ne saturirana (ne zasićena) hidraulička vodljivost izračunava se prema Darcy–Buckinghamovom zakonu (jednadžba 2.8). Dobiveni podaci analizirani su u HYPROP–FIT softveru primjenom „van Genuchten original“ (Van Genuchten, 1980.) i „van Genuchten bimodal“ funkcije (Durner, 1994.).



Slika 3.13. Shema HYPROP sustava i prikaz mjerenja

Mjerenje hidrauličke vodljivosti tla u saturiranim uvjetima provedeno je pomoću K–sat uređaja (Slika 3.14.). Mjerenja se baziraju na Darcyjevoj jednadžbi (2.7). Prije početka određivanja propusnosti tla za vodu uzorke tla potrebno je u potpunosti saturirati vodom. Vrijeme koje je potrebno za saturaciju cilindra ovisi o tipu tla, teksturi te trenutačnoj vlažnost tla. Nakon saturacije uzoraka provedeno je mjerenje propusnosti tla za vodu pomoću K-sat uređaja (UMS, 2012.) na temelju metode padajućeg tlaka (eng. *falling head technique*) koja se bazira na Darcyjevom zakonu (2.7) (Dane i Topp, 2002). Uzorak tla u cilindru (250 cm^3) postavi se na senzor nakon čega se kroz uzorak tla propušta poznati volumen vode (Slika 3.14.). Uređaj automatski bilježi vrijeme protoka vode kroz uzorak temeljem čega se izračunava hidraulička vodljivost tla u saturiranim uvjetima (K_s) izražena u cm dan^{-1} .

S obzirom da evapotranspiracijska metoda daje rezultate o hidrauličkim svojstvima tla u vlažnom dijelu retencijske krivulje, suhi dio krivulje ostaje nepokriven. WP4C uređaj određuje retenciju vlage u suhom dijelu krivulje, omogućujući tako da cijela retencijska krivulja (od potpuno saturiranog do suhog dijela) bude pokrivena.



Slika 3.14. Shema K-sat sustava i prikaz mjerenja

Kombiniranim mjerenjem vodnog potencijala evapotranspiracijskom metodom (u mokrom odnosno vlažnom dijelu retencijske krivulje) i WP4C uređajem (u suhom dijelu) dobije se potpuna retencijska krivulja.

Iz kolona tla u neporušenom stanju koje su uzorkovane na tri pozicije na obronku u redu i međurednom prostoru vinograda u tri ponavljanja, odrađen je pokus toka vode kroz tlo u kontroliranim uvjetima uz primjenu simulacije kišenja, u laboratoriju za fiziku tla Zavoda za pedologiju. Prije samog pokusa, na donjoj strani kolone između tla i stijenke kolone nanoseno je ljepilo, nakon čega se na donji dio kolone stavila sintetska mrežica kako bi se spriječilo eventualno ispadanje tla iz kolone. Kolone tla postavljene su na posebno, za tu namjenu, napravljenu konstrukciju. Na donji dio kolona montiran je lijevak koji je istek vode kroz kolone usmjeravao u menzure. Slika 3.15. prikazuje pripremu kolona i kolone tijekom analiza.



Slika 3.15. Priprema tla s kolonama i kolone tla tijekom analiza

Menzurama je određen volumen procijeđene vode kroz kolone tla u vremenskim intervalima kako slijedi: 10, 20, 30, 60, 120 i 240 min nakon aplikacije 250 ml prokuhane vode na gornji dio kolone tla pomoću prskalice kako bi se volumen dodane vode što ravnomjernije rasporedio po površini kolone i kako bi se što pouzdanije imitiralo kišenje. Simulacije i mjerenja odvijala su se tijekom 20 dana. Nakon aplikacije vode, površina tla je prekrivena folijom kako bi se spriječila evaporacija.

CT skeniranje poroznog sustava tla u kolonama obavilo se na Czech University of Life Sciences, Prag, Republika Češka pomoću Nikon XT H 225ST CT skenera. Nakon mjerenja uzoraka tla u plastičnim cilindrima promjera 7,5 cm i visine 10 cm, pristupilo se rekonstrukciji dobivenih slika. Prilikom rekonstrukcije slike su izrezane na veličinu 46,8161 x 46,8161 x 96,5581 mm. Izlazni format rekonstruiranih podataka bio je u 16 - bitnoj „dubini“ boje. Za analizu slika, dijelovi (eng. *slice*) od 5 mm podijeljeni su u vodoravnom (19 dijelova) i okomitom smjeru (dvije osi, 18 dijelova). Analiza slika provedena je pomoću Image J softvera (verzija 1.53k) pomoću *Color Threshold* funkcije, nakon čega je određen broj crvenih piksela (pora).

3.6. Modeliranje toka i retencije vode na obronku pomoću HYDRUS softverskog paketa

Za modeliranje toka i retencije vode na različitim pozicijama istraživanog obronka korišteni su softverski programi HYDRUS 1D i HYDRUS 2D/3D. Navedeni programi korišteni su za procjenu utjecaja svojstava tla, slabije propusnog potpovršinskog (Bg) horizonta rigolanog pseudogleja, te korijena vinove loze na tok i retenciju vode na obronku. Spomenuti programi rješavaju tok vode numerički pomoću Richardsonove jednadžbe (jednadžba 2.10), a za diskretizaciju prostora koriste Galerkinov tip konačnih elemenata. Numerički model testiran je na temelju podataka dobivenih terenskim mjerenjima volumetrijskog sadržaja vlage u tlu, pomoću TDR senzora. Za verifikaciju modela korištene su računate simulacije predviđanja toka i retencije vode u tlu istraživanog obronka za razdoblje od 24.4. do 14.10.2019. te od 1.1.2020. do 31.12.2020. godine.

Hidrauličke funkcije $\theta(h)$ i $K(h)$ određene su preko van Genuchten–Mualem modela, čiji je izvod prikazan u nastavku.

Efektivna saturacija S_e definirana je kao:

$$S_e = \frac{\theta - \theta_r}{\theta_s - \theta_r}, \quad (3.1)$$

gdje je θ_s volumetrijski sadržaj vode saturiranog tla, a θ_r rezidualni volumetrijski sadržaj vlage.

Jedna od najčešće korištenih retencijskih krivulja je ona od van Genuchtena (1980):

$$S_e = \frac{1}{(1 + |\alpha h|^n)^m}. \quad (3.2)$$

Kombinacijom prethodnih dvaju izraza, dolazi se do ovisnosti volumetrijskog sadržaja vode θ o potencijalu h :

$$\theta(h) = \frac{\theta_s - \theta_r}{(1 + |\alpha h|^n)^m} + \theta_r, \text{ za ne saturirana } (h < 0) \text{ i} \quad (3.3)$$

$$\theta(h) = \theta_s, \text{ za saturirana } (h \geq 0).$$

Vrijednosti četiri parametra: θ_s , θ_r , α i n ($m = 1 - \frac{1}{n}$) određuju se tako da razlika mjerenja i modela bude minimalna.

Mualem (1976.) je razvio model za određivanje vrijednosti hidrauličke vodljivosti ne saturiranog tla u ovisnosti o efektivnoj saturaciji, promatrajući tlo kao dvije skupine kapilarnih cijevi koje su serijski povezane:

$$K(S_e) = K_s S_e^l \frac{\left[\int_0^{S_e} \frac{dS_e}{h(S_e)} \right]^2}{\left[\int_0^1 \frac{dS_e}{h(S_e)} \right]^2}, \quad (3.4)$$

gdje je K_s hidraulička konduktivnost saturiranog tla, a l parametar povezanosti pora. Mualem (1976.) navodi kako za većinu tla l vrijednost iznosi 0,5, stoga se ta vrijednost koristila i u ovom radu.

Van Genuchtenov i Mualemov model međusobno se kombiniraju u zajedničku jednadžbu:

$$K(S_e) = K_s S_e^l [1 - (1 - S_e^{1/m})^m]^2. \quad (3.5)$$

Hidraulički parametri korišteni u simulacijama u HYDRUS 1D modelu, procijenjeni su na tri načina, i to (i) pomoću HYPROP i WP4C sustava, (ii) pomoću pedotransfernih funkcija (tip pet) u ROSETTA softveru (Schaap i sur., 2001.) te (iii) inverznim modeliranjem u HYDRUS 1D modelu.

Prvi način određivanja hidrauličkih parametara proveden je već gore spomenutom evapotranspiracijskom metodom pomoću HYPROP i WP4C sustava. Hidraulički parametri korištenjem ove metode određeni su samo za tri pozicije istraživanog obronka (gore, sredina i dno) u površinskom i potpovršinskom horizontu, te u međuredu i redu vinograda. Temeljem izmjerenih vrijednosti hidrauličkih parametara, u HYPROP-FIT softveru procijenjene su retencijske i hidrauličke krivulje korištenjem Van Genuchten original (jednadžba 3.3) i Van Genuchten bimodal modela. S obzirom da sva tla nemaju uniformni porozni sustav, Durner (1994.) je predložio nadopunu Van Genuchten originalnog modela za aproksimacije tla s dva (bimodal) porozna sustava. Takva proširena jednadžba glasi:

$$\theta(h) = \theta_r + (\theta_s - \theta_r) \left[w_1 \left(\frac{1}{1 + (\alpha_1 h)^{n_1}} \right)^{1-1/n_1} + w_2 \left(\frac{1}{1 + (\alpha_2 h)^{n_2}} \right)^{1-1/n_2} \right], \quad (3.6)$$

gdje su α_1 , α_2 , n_1 , n_2 parametri prvog i drugog poroznog sustava, dok su w_1 i w_2 težine oba sustava i vrijedi $w_1 + w_2 = 1$.


Nadalje, hidraulički parametri za svaku pojedinu poziciju na obronku (P1 – P5) procijenjeni su korištenjem „tipa pet“ pedotransfernih funkcija u ROSETTA softveru, koji je sastavni dio HYDRUS softverskog paketa.

Hidraulički parametri (θ_s , α , n i K_s) za svaku istraživanu poziciju (P1 – P5) na kraju su procijenjeni preko inverznog modeliranja.

3.6.1. Inicijalni i granični uvjeti modeliranja toka vode

Simulacije u jednodimenzionalnom prostoru (HYDRUS 1D) provedene su tijekom dva razdoblja i to od 26.4.2019. do 14.10.2019., te od 1.1. do 31.12.2020. godine. Simulacije su provedene za svaki profil zasebno (P1 – P5). Prilikom modeliranja dubina profila postavljena je na 110 cm. Na dnu profila postavljen je rubni uvjet slobodne drenaže (eng. *free drainage*), dok su na površini postavljeni atmosferski uvjeti koji uključuju i površinsko otjecanje (eng. *atmospheric BC with surface runoff*). Kao početni uvjet prilikom simulacija postavljen je trenutačni sadržaj vode u tlu u početku simulacija (očitan TDR senzorom). Za svaki simulirani profil izrađena je domena sa horizontima različitih dubina temeljem opisa pedoloških profila. Također, za svaki profil te prostor u redu i međuredu primijenjeni su rezultati analize


proraštenosti tla korijenom kako bi se što vjernije opisali uvjeti u svakom od profila. Točke opažanja (eng. *observation points*) za svaki profil (bez obzira na poziciju na obronku) postavljene su na 30 i 90 cm, odnosno na iste dubine na koje su na terenu bili postavljeni TDR senzori. Grafički prikaz domene u HYDRUS 1D programu prikazan je na slici 3.16.



Slika 3.16. Primjer jedne pozicije u HYDRUS 1D grafičkom sučelju

Kao ulazni parametri hidrauličkih svojstava tla korišteni su rezultati evaporacijske metode na HYPROP uređaju, podaci od pedotransfernih funkcija dobivenih ROSETTA softverom koji je sastavni dio HYDRUS softverskog paketa, te je dodatno provedeno inverzno modeliranje. U ROSETTA softveru za predikciju hidrauličkih značajki tla korišten je „tip 5“ pedotransfer funkcije (najkompleksniji i najpouzdaniji) koji uključuje podatke o teksturnom sastavu tla (pijesak, prah, glina), volumnoj gustoći te retencijskim značajkama tla kod – 0,33 i – 15 bara. Za provedbu numeričkih simulacija na cijelom istraživanom obronku korišten je HYDRUS 2D/3D program. Izrađena je domena dužine 90 m koja odgovara dimenzijama na istraživanoj lokaciji vinograda u Jastrebarskom. Distribucija horizonata postavljena je prema opisu pedoloških profila i pojedinih horizonata tla kako je prikazano na slici 3.17. Pri vrhu domene postavljeni su rubni atmosferski uvjeti (eng. *atmospheric boundary conditions*). Uvjeti bez toka (eng. *no water flux*) postavljeni su lateralno dok su na dnu domene postavljeni uvjeti slobodnog procjeđivanja (eng. *free drainage boundary conditions*). U modelu su postavljene i dvije točke opažanja i to na vrhu i dnu obronka. Simulacije su provedene za razdoblje od dvije vegetacijske sezone, odnosno od 26.04.2019. do 31.12. 2020. Navedeni početni datum je odabran kako bi se mogli postaviti realni početni uvjet koji su izmjereni TDR senzorima (količina vode u tlu). Vrijednosti hidrauličkih parametara preuzeti su iz HYDRUS 1D inverznih simulacija koje su pokazale najbolju pouzdanost s rezultatima mjerenja TDR senzorima na različitim pozicijama na obronku (P1–P5). Kako je numerički dvodimenzionalni model zahtjevan, za sve K_s vrijednosti ispod 1 cm dan⁻¹ postavljena je vrijednost 1 cm dan⁻¹. Navedeno ne utječe na

rezultate simulacija, a omogućuje numeričku stabilnost potrebnu za provedbu ovako postavljenih simulacija. Dodatno su simulirana tri klimatska scenarija koristeći prognoze IPCC – a (2014.): blagi, srednji i ekstremni. Navedeni scenariji su primijenjeni na istraživanju za 2020. godinu.



Slika 3.17. Shema distribucije horizonata tla (Ap, Bg, Cg, 2Cg) po pozicijama (P1 - P5) u HYDRUS 2D modelu za simulacije toka vode na padini istraživanog područja

3.7. Statistička obrada rezultata

U preliminarnom istraživanju, homogenost/heterogenost analiziranih svojstava tla na pet točaka uzorkovanja procijenjena je korištenjem koeficijenta varijacije (CV). Kako bi se ispitali učinci položaja na obronku (P1–P5), položaja s obzirom na red/međured i njihove interakcije na svojstva tla i sadržaj vode u tlu, provedena je dvosmjerna analiza varijance (ANOVA). Razina prediktora za koje je utvrđeno da su statistički značajne na alfa razini $P = 0,05$ uspoređena su korištenjem Bonferronijeve korekcije s alfa postavljenom na $P = 0,05$. U slučajevima kada je utvrđeno da je interakcija značajna ($P < 0,05$), višestruke usporedbe provedene su samo između položaja unutar istog reda/međurednog prostora. Analize su provedene zasebno za svaki od dva horizonta.

Za utvrđivanje utjecaja pozicije (P1–P5) na obronku, reda i međurednog prostora vinograda te površinskog (Ap) i potpovršinskog (Bg) horizonta na retenciju vode u tlu korišten je linearni model gdje je nagib kontinuirani, a red/međured i horizont kvantitativni prediktor.

Sve statističke analize provedene su u R 3.3.2 (R Core Team, 2016.) u RStudio 1.1.423 (RStudio Team, 2016.).

Najčešće korištene verifikacijske mjere za opis uspješnosti modela su srednja apsolutna pogreška MAE (eng. *mean absolute error*), korijen srednje kvadratne pogreške RMSE (eng. *root mean square error*), i kvadrat koeficijenta korelacije R^2 .

Srednja apsolutna pogreška računa se kao:

$$MAE = \frac{\sum_{i=1}^N |P_i - O_i|}{N}, \quad (3.7)$$

gdje je N broj mjerenja, a P_i i O_i modelirane, odnosno izmjerene vrijednosti. MAE je mjera točnosti modela koja daje „prosječnu“ magnitudu pogrešaka, ali ne i njihov smjer odstupanja. Raspon vrijednosti je od nula do beskonačno, a savršena prognoza ima vrijednost nula.

Korijen srednje kvadratne pogreške računa se preko formule:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (P_i - O_i)^2}{N}}, \quad (3.8)$$

gdje je N broj mjerenja, a P_i i O_i modelirane, odnosno izmjerene vrijednosti. RMSE može poprimiti bilo koju vrijednost od nula do beskonačno, a uspješnost modela je to bolja što je vrijednost RMSE – a bliže nuli. Mjera je ukupne točnosti i kvadratni parametar uspješnosti koji daje „prosječnu“ magnitudu pogreške, otežanu razmjerno kvadratima pojedinih pogrešaka. Kao i srednja apsolutna pogreška, ne pokazuje smjer odstupanja, ali daje veću težinu velikim

nego malim pogreškama te je stoga prikladniji statistički pokazatelj kada su velike pogreške naročito nepoželjne.

Za razliku od njega, R^2 može poprimiti vrijednosti između 0 i 1 i mjera je ukupne pouzdanosti modela. Također, mjera je linearne povezanosti prognoziranih i izmjerenih vrijednosti. Ne uzima u obzir srednju pogrešku prognoze. Osjetljiva je na velika odstupanja prognoza od mjerenja, tj. događaje izvan uobičajenog raspona vrijednosti. Vrijednost 1 znači da model savršeno opisuje izmjerene vrijednosti. Formula po kojoj se računa je:

$$R^2 = \frac{\left[\sum_1^N O_i P_i - \frac{\sum_1^N O_i \sum_1^N P_i}{N} \right]^2}{\left[\sum_1^N O_i^2 - \frac{\sum_1^N O_i^2}{N} \right] \left[\sum_1^N P_i^2 - \frac{\sum_1^N P_i^2}{N} \right]}, \quad (3.9)$$

gdje je N broj mjerenja, a P_i i O_i modelirane, odnosno izmjerene vrijednosti.

4. REZULTATI

4.1. Rezultati preliminarnih istraživanja obronka

Preliminarna istraživanja za cilj su imala utvrditi homogenost/heterogenost istraživane parcele. Preliminarnim istraživanjima utvrđena je relativna homogenost dijela istraživanog obronka po izohipsama. S obzirom na utvrđenu homogenost parcele, rezultati mjerenja vlage tla sensorima mogu se primijeniti na šire područje istraživanog obronka, odnosno mogu se primijeniti i na ostale redove i međuredne prostore (po izohipsama) na širem području istraživane parcele. Preliminarna istraživanja uključivala su analizu teksturnog sastava, sadržaja humusa te pH tla na pet izabranih pozicija na obronku. Minimalne, maksimalne te srednje vrijednosti i koeficijenti korelacije za fizikalna i kemijska svojstva tla prikazane su u tablici 4.1. i 4.2.

Tablica 4.1. Minimalne, maksimalne, srednje vrijednosti te koeficijenti varijacije za fizikalna svojstva tla po pozicijama obronka

Pozicija	Dubina (cm)	Pijesak 2,0 – 0,063 mm				Prah 0,063 – 0,002 mm				Glina < 0,002 mm			
		min	max	$\bar{x}$	CV	min	max	$\bar{x}$	CV	min	max	$\bar{x}$	CV
P1	0-40	4,1	4,7	4,4	6,89	57,3	58,8	58,0	0,75	37,1	38,0	37,5	0,45
	40-80	3,2	3,9	3,6	10,02	60,1	60,3	60,2	0,10	35,9	36,7	36,2	0,44
	80-110	3,4	4,0	3,7	8,33	6,3	63,8	63,7	0,12	32,2	33,0	32,6	0,40
P2	0-40	9,3	9,8	9,5	2,64	55,8	56,3	56,1	0,26	34,0	34,7	34,4	0,35
	40-80	10,2	10,3	10,3	0,56	54,4	54,8	54,6	0,21	34,9	35,3	35,1	0,20
	80-110	11,6	12,8	12,2	4,93	41,9	42,9	42,5	0,55	44,9	45,5	45,2	0,31
P3	0-40	13,7	14,1	13,9	1,44	53,6	53,6	53,6	0,00	32,3	32,7	32,5	0,20
	40-80	11,4	12,0	11,7	3,56	51,1	52,3	51,6	0,62	36,3	37,2	36,7	0,46
	80-110	31,0	31,6	31,3	0,96	40,1	41,0	40,4	0,49	28,0	28,6	28,3	0,31
P4	0-40	10,2	10,8	10,5	2,86	61,6	62,2	62,0	0,32	27,4	27,6	27,5	0,12
	40-80	11,6	12,0	11,8	1,69	63,5	64,1	63,9	0,35	23,9	24,7	24,3	0,40
	80-110	11,0	11,4	11,1	2,07	63,7	64,9	64,4	0,62	24,1	24,9	24,5	0,40
P5	0-40	10,6	11,1	10,9	2,32	62,4	63,4	63,1	0,58	25,7	26,5	26,1	0,40
	40-80	10,2	10,8	10,5	2,92	62,4	63,7	63,0	0,67	26,1	26,8	26,6	0,40
	80-110	8,2	9,0	8,6	4,72	64,0	64,6	64,2	0,32	26,9	27,5	27,2	0,30

$\bar{x}$ – srednja vrijednosti, CV – koeficijent varijacije

istaknute vrijednosti označavaju koeficijente varijacije čije vrijednosti prelaze „2,00“.

Koeficijenti varijacije za fizikalna svojstva tla uglavnom se kreću ispod 2 osim za sadržaj pijeska. Najveći koeficijenti varijacije izraženi su za P1 poziciju, a najmanji za P3 poziciju.

Tablica 4.2. Minimalne, maksimalne, srednje vrijednosti te koeficijenti varijacije za kemijska svojstva tla po pozicijama obronka

Pozicija	Dubina (cm)	pH (H ₂ O)				pH (KCl)				Humus (%)			
		min	max	$\bar{x}$	CV	min	max	$\bar{x}$	CV	min	max	$\bar{x}$	CV
P1	0-40	5,3	5,4	5,3	0,56	3,9	4,0	4,0	0,29	1,8	1,8	1,8	1,79
	40-80	5,5	5,5	5,5	0,46	3,8	3,8	3,8	0,69	1,3	1,4	1,3	2,50
	80-110	5,8	5,8	5,8	0,46	4,0	4,1	4,0	0,76	0,7	0,8	0,8	5,70
P2	0-40	5,1	5,1	5,1	0,52	3,8	3,8	4,1	0,61	1,9	2,0	1,9	2,75
	40-80	5,2	5,3	5,2	0,69	3,8	3,8	3,8	0,67	1,0	1,1	1,0	5,08
	80-110	5,6	5,6	5,6	0,36	4,1	4,1	3,8	0,49	0,8	0,8	0,8	3,39
P3	0-40	4,7	4,8	4,8	0,63	3,7	3,7	4,1	0,41	2,0	2,1	2,1	2,68
	40-80	5,1	5,1	5,1	0,30	3,6	3,6	3,7	0,43	2,0	2,0	2,0	0,72
	80-110	5,2	5,2	5,2	0,38	3,5	3,6	3,6	0,43	1,5	1,6	1,5	3,37
P4	0-40	5,4	5,5	5,5	0,74	3,9	3,9	3,6	0,53	2,2	2,3	2,3	3,42
	40-80	5,0	5,1	5,0	0,80	3,8	3,9	3,9	0,66	2,3	2,4	2,3	1,69
	80-110	5,2	5,2	5,2	0,29	3,8	3,9	3,8	0,40	1,2	1,3	1,3	5,69
P5	0-40	4,9	5,0	5,0	0,81	3,8	3,8	3,8	0,52	2,8	2,9	2,9	1,48
	40-80	4,8	5,8	5,1	11,4	3,7	3,7	3,7	0,31	1,4	1,5	1,4	2,46
	80-110	5,4	5,4	5,4	0,47	3,9	3,9	3,9	0,39	1,0	1,0	1,0	2,20

$\bar{x}$ – srednja vrijednosti, CV – koeficijent varijacije

istaknute vrijednosti označavaju koeficijente varijacije čije vrijednosti prelaze „2,00“.

Koeficijenti varijacije za pH (H₂O i KCl) kemijska svojstva tla kreću se ispod 2 osim za sadržaj humusa (kod većine uzoraka), te za pH (H₂O) kod pozicije P5 na dubini 40 - 80 cm.

4.2. Svojstva tla po pozicijama obronka


U ovom poglavlju prikazani su detaljni rezultati morfoloških, fizikalnih i kemijskih svojstva tla iz pedoloških profila na pet odabranih pozicija obronka.

4.2.1. Morfološka svojstva pedoloških profila na istraživanom obronku

Tablicom 4.3. prikazane su (Husnjak, 2014., WBR, 2014.) dubine i oznake horizonata u profilima na pet izabranih pozicija obronka. Kasnije u tekstu koristit će se oznake horizonata prema WRB (2014.) klasifikaciji. Slika 4.1. prikazuje lica iskopanih pedoloških profila na istraživanom obronku.

Tablica 4.3. Dubine i oznake horizonata prema Husnjak (2014.) i WBR (2014.) pojedinim pozicijama obronka

Pozicija	Dubina [cm]	Oznaka horizonata prema Husnjak (2014.)	Oznaka prema WRB (FAO, 2014.)
P1	0 – 55	P	Ap
	55 – 110	B/S	Bg
P2	0 – 60	P	Ap
	60 – 110	B/S	Bg
P3	0 – 70	P	Ap
	70 – 110	B/S	Bg
P4	0 – 78	P	Ap
	78 – 110	B/S	Bg
P5	0 – 88	P	Ap
	88 – 110	B/S	Bg



Slika 4.1. Prikaz pedoloških profila P1 – P5 na istraživanom obronku. Crvena linija označava granicu između površinskog (Ap) i potpovršinskog (Bg) horizonta.

Dubina (Ap) horizonta razlikuje se s obzirom na poziciju na obronku, odnosno raste niz obronak, od 55 cm na P1 do 88 cm na P5 poziciji obronka. Prijelaz između Ap i Bg horizonta

na svakoj od pet pozicija je izrazit (u rasponu od 2 – 5 cm), dok je oblik prijelaza između horizonata bio ravan do valovit. Struktura Ap horizonta na svim pozicijama je granularna/subangularna blokna dok je u Bg horizontu angularna/blokna do masivna/koherentna.

Od redoksimorfni obilježja u Ap horizontu na svim pozicijama obronka (P1 – P5) uočena je zastupljenost redoks deplecija ($value \geq 4$, $chroma \leq 2$) i redoks koncentracija, s time da su redoks deplecije zastupljene u većoj mjeri u odnosu na redoks koncentracije. Na svim pozicijama u Ap i Bg horizontu uočena je zastupljenost svih vrsta redoks koncentracija, od Fe masa ($value$ i $chroma > 4$), Fe–Mn masa ($value$ i $chroma > 2$ i ≤ 4), Mn masa ($value$ i $chroma \leq 2$), pa do Fe i Mn nodula/konkrekcija. Zastupljenost redoks koncentracija smanjuje se prema nižim pozicijama obronka. Tako se zastupljenost redoks koncentracija na P1 poziciji u Ap horizontu kreće od dosta do jako puno (5 – 80 %), dok je zastupljenost redoks koncentracija na P5 poziciji vrlo mala do mala (0 – 5 %). U Bg horizontu, bez obzira na poziciju na obronku, zastupljenost redoks koncentracija kreće se od puno do jako puno (15 – 80 %). Zastupljenost redoks deplecija također je manja u Ap, u odnosu na Bg horizont, te se smanjuje prema nižim pozicijama obronka. Za Ap horizont zastupljenost redoks deplecija kreće se od malo do dosta (2 – 50 %) za pozicije P1 – P4 dok kod P5 pozicije redoks deplecija uopće nema ili ih ima vrlo malo (0 – 2 %). Jako puno (40 – 80 %) redoks deplecija uočeno je u Bg horizontu na svim istraživanim pozicijama obronka.

Dominantna boja matriksa tla (u suhom stanju) određena prema Munsellovom atlasu boja za Ap i Bg horizont na svakoj od pet pozicija na obronku prikazana je u Tablici 4.4.


Tablica 4.4. Dominantna boja tla za Ap i Bg horizont na P1 do P5 pozicijama na istraživanom obronku

Pozicija	Horizont	Boja u suhom stanju	Opis boje
P1	Ap	2,5 Y 6/4	Svijetlo žućkasto smeđa
	Bg	10 YR 6/8	Smeđe žuta
P2	Ap	2,5 Y 6/2	Svijetlo smeđe siva
	Bg	10 YR 6/6	Smeđe žuta
P3	Ap	2,5 Y 6/4	Svijetlo žućkasto smeđa
	Bg	10 YR 6/8	Smeđe žuta
P4	Ap	2,5 Y 7/4	Blijedo žuta
	Bg	2,5 Y 6/4	Svijetlo smeđe siva
P5	Ap	2,5 Y 7/4	Blijedo žuta
	Bg	2,5 Y 6/4	Svijetlo žućkasto smeđa

4.2.2. Proraštenost tla korijenom


U nastavku rada prikazan je pregled proraštenosti tla korijenom u svakom od pet istraživanih profila. Grafički je po dubinama od: 0–20, 20–40, 40–60, 60–80, 80–100 cm prikazan broj korijena promjera < 5; 5–2; 2–0,2 i > 0,02 mm u redu i međurednom prostoru vinograda. Prilikom promatranja slika (4.2. do 4.6.) potrebno je obratiti posebnu pažnju na vrijednosti skale broja korijena (x – os) koja se razlikuje od pozicije do pozicije.

Iz Slike 4.2. vidljivo je kako je na poziciji P1, općenito (bez obzira na promjer) veći broj korijenja zastupljen u redu u odnosu na međuredni prostor vinograda. Brojnost korijena smanjuje se s dubinom, gdje na dubini većoj od 80 cm (u redu), a u međuredu i na dubini većoj od 60 cm nema korijena promjera većeg od 5 mm. Na svim dubinama najveća je zastupljenost korijena čiji je promjer manji od 0,2 mm.




Slika 4.2. Grafički prikaz zastupljenosti veličine i brojnosti korijenja po dubini profila na poziciji P1 u međuredu (lijevo) i u redu (desno) vinograda.

Kao i kod pozicije P1, na poziciji P2 (Slika 4.3.), veći broj korijena (bez obzira na promjer) uočen je u redu u odnosu na međuredni prostor vinograda. Za razliku od reda, u međurednom prostoru uočena je pojava korijena svih promjera cijelom dubinom profila, mada je korijenje promjera većeg od 5 mm zastupljeno u vrlo malom broju.




Slika 4.3. Grafički prikaz zastupljenosti veličine i brojnosti korijenja po dubini profila na poziciji P2 u međuredu (lijevo) i u redu (desno) prostoru vinograda.

Iz slike 4.4. je vidljivo kako je na poziciji P3 veći broj korijena zastupljen u redu u odnosu na međuredni prostor vinograda. Zastupljenost korijena (bez obzira na promjer) smanjuje se po dubini profila, gdje na dubini većoj od 80 cm (u redu) i većoj od 60 cm u međurednom prostoru nema korijena čiji je promjer veći od 5 mm.




Slika 4.4. Grafički prikaz zastupljenosti veličine i brojnosti korijena po dubini profila na poziciji P3 u međuredu (lijevo) i redu (desno) vinograda.

Slika 4.5. prikazuje proraštenost tla korijenom na poziciji P4. Iz slike je uočljivo kako u međurednom prostoru vinograda na dubini do 40 cm nije uočena zastupljenost korijena većeg od 5 mm. Kao i kod ostalih pozicija, ponavlja se pravilo da je zastupljenost korijena, veći u redu u odnosu na međured, te da se bez obzira na promjer zastupljenost korijena smanjuje s dubinom.



Slika 4.5. Grafički prikaz zastupljenosti veličine i brojnosti korijena po dubini profila na poziciji P4 u međuredu (lijevo) i u redu (desno) vinograda.

Na poziciji P5 (Slika 4.6.) korijenja većeg od 5 mm, kako u redu tako i u međuredu ima vrlo malo, dok je zastupljenost korijena manjeg od 0,2 mm izrazito velika > 400 u sloju tla od 0-20 cm dubine. Kao i kod ostalih pozicija, općenito, veća je zastupljenost korijena u redu u odnosu na međured, a zastupljenost se smanjuje s dubinom.



Slika 4.6. Grafički prikaz zastupljenosti veličine i brojnosti korijenja po dubini profila na poziciji P5 u međuredu (lijevo) i u redu (desno) vinograda.

Općenito, iz slika (4.2. – 4.6.) uočljivo je kako se brojnost korijena povećava niz obronak. Tako se npr. na poziciji P1 zastupljenost korijena promjera manjeg od 2 mm kreće od 50 – 80 (međured/red), dok se na P5 poziciji zastupljenost korijena promjera manjeg od 2 mm kreće od 400 – 500 (međured/red). Najveća je zastupljenost korijena promjera manjeg od 0,2 mm, a najmanja većeg od 5 mm. U redu je uočena veća zastupljenost korijena u odnosu na međured, a zastupljenost korijena smanjuje se s dubinom.

4.2.3. Korelacija vodnog potencijala tla i vodnog potencijala vinove loze

U ovom poglavlju prikazani su rezultati korelacije vodnog potencijala tla i vinove loze, koji je mjeren tijekom 2020. godine. Tablica 4.5. prikazuje srednje dnevne vrijednosti vodnog potencijala tla na datume kada su usporedno obavljena mjerenja vodnog potencijala vinove loze (prije svitanja i u podne). Iznos vodnog potencijala vinove loze mjeren u podne veći je od iznosa vodnog potencijala izmjenjenog ujutro, odnosno prije svitanja, što znači da je biljka pod većim vodnim stresom. Vodni potencijal vinove loze mjeren u podne kretao se u rasponu od -808 kPa pa do -1425 kPa, dok se vodni potencijal mjeren ujutro kretao u rasponu od -72 do -629 kPa. Iz tablice 4.5. vidi se kako korelacije između vodnog potencijala vinove loze i vodnog potencijala tla nema (P1, $r = -0,18$) ili je vrlo slaba, a koeficijenti korelacije iznose manje od 0,25. Izuzetak je P3 pozicija gdje je utvrđena jaka korelacija ($r = 0,63$) između vodnog potencijala vinove loze izmjenjenog u podne i vodnog potencijala tla.

Tablica 4.5. Prikaz vodnog potencijala tla i vodnog potencijala vinove loze (mjerenog u jutro i u podne) te korelacijski koeficijenti

Datum	P1 pozicija			P3 pozicija			P5 pozicija		
	VP tla [kPa]	VP loze jutro [kPa]	VP loze podne [kPa]	VP tla [kPa]	VP loze jutro [kPa]	VP loze podne [kPa]	VP tla [kPa]	VP loze jutro [kPa]	VP loze podne [kPa]
26.5.2020.	-115	-629	-808	-33	-509	-850	-78	-529	-850
16.7.2020.	-262	-543	-1170	-302	-477	-1373	-167	-353	-1317
23.7.2020.	-262	-100	-947	-139	-100	-1010	-108	-100	-1057
2.8.2020.	-251	-337	-1277	-218	-277	-1337	-162	-360	-1425
7.8.2020.	-142	-273	-1114	-72	-350	-1227	-92	-307	-1236
11.8.2020.	-164	-187	-1127	-125	-221	-887	-131	-244	-920
19.8.2020.	-239	-137	-840	-128	-103	-903	-185	-103	-857
26.8.2020.	-302	-360	-1132	-239	-307	-1050	-267	-283	-1075
3.9.2020.	-53	-215	-1160	-50	-125	-1033	-90	-72	-1093
7.9.2020.	-74	-437	-853	-90	-437	-833	-122	-483	-899
16.9.2020.	-152	-563	-1150	-172	-503	-1000	-180	-517	-1207
<i>r</i>		-0,18	0,23		0,16	0,63		0,01	0,18

r = koeficijent korelacije

Pored korelacije vodnog potencijala tla i vinove loze, a s obzirom da su korelacijski koeficijenti za navedeno bili iznimno niski utvrđen je korelacijski odnos između vodnog potencijala vinove loze (u jutro i u podne) sa srednjom dnevnom relativnom vlagom zraka (RVZ) (Tablica 4.6.). Iz tablice je vidljivo kako između vodnoga potencijala vinove loze (izmjenjen pred svitanje) i srednje dnevne RVZ nije utvrđena korelacija ($r = -0,043$ do $-0,055$). Pozitivna i jaka korelacija utvrđena je između vodnog potencijala vinove loze izmjenjenog u podne i RVZ ($r = 0,56$ do $0,67$).

Tablica 4.6. Prikaz vodnog potencijala vinove loze i srednje dnevne relativne vlage zraka te korelacijski koeficijenti

Datum	P1 pozicija		P3 pozicija		P5 pozicija		Srednja dnevna RVZ [%]
	VP loze jutro [kPa]	VP loze podne [kPa]	VP loze jutro [kPa]	VP loze podne [kPa]	VP loze jutro [kPa]	VP loze podne [kPa]	
26.5.2020.	-629	-808	-509	-850	-529	-850	80
16.7.2020.	-543	-1170	-477	-1373	-353	-1317	73
23.7.2020.	-100	-947	-100	-1010	-100	-1057	75
2.8.2020.	-337	-1277	-277	-1337	-360	-1425	70
7.8.2020.	-273	-1114	-350	-1227	-307	-1236	76
11.8.2020.	-187	-1127	-221	-887	-244	-920	78
19.8.2020.	-137	-840	-103	-903	-103	-857	78
26.8.2020.	-360	-1132	-307	-1050	-283	-1075	69
3.9.2020.	-215	-1160	-125	-1033	-72	-1093	79
7.9.2020.	-437	-853	-437	-833	-483	-899	78
16.9.2020.	-563	-1150	-503	-1000	-517	-1207	78
<i>r</i>	-0,034	0,56	-0,037	0,67	-0,055	0,62	

r – koeficijent korelacije, RVZ – srednja dnevna relativna vlaga zraka

4.2.4. Fizikalna svojstva pedoloških profila na istraživanom obronku

Svi uzorci tla na istraživanom obronku bili su bez skeleta. Temeljem rezultata analize Teksturnog sastava tla (Tablica 4.7.) za površinski i potpovršinski horizont na pet odabranih pozicija obronka u redu i međurednom prostoru vinograda određena je teksturna klasa (Tablica 4.8.) temeljem FAO teksturnog trokuta. Pozicija P1 i P2 dominantno imaju praškasto glinasto ilovastu teksturu u Ap i Bg horizontu kako u redu i tako i umeđurednom prostoru. P3 lokacija u Ap horizontu ima praškasto glinasto ilovastu teksturu dok Bg horizont ima ilovastu teksturu. Na poziciji P4 dominira praškasto glinasto ilovasta tekstura, izuzev Ap horizonta u redu koji ima praškasto ilovastu teksturu. P5 pozicija ima praškasto ilovastu teksturu u oba horizonta. Teksturni sastav tla po pozicijama obronka do 2 metra dubine prikazan je u tablici 4.7.

Tablica 4.7. Teksturni sastav tla na pet pozicija istraživanog obronka do dubine od 2 metra.

Pozicija	Dubina [cm]	Pijesak [%] (2,0-0,063 mm)	Prah [%] (0,063-0,002 mm)	Glina [%] (< 0,002 mm)
P1	0-55	4,07	56,30	39,63
	55-110	2,96	61,57	35,47
	110-140	3,50	60,50	36,00
	140-200	4,50	60,10	35,40
P2	0-60	10,80	51,93	37,27
	60-110	7,56	46,87	45,57
	110-140	18,30	45,70	36,00
	140-200	28,40	45,30	26,30
P3	0-70	13,67	52,40	33,93
	70-110	32,40	44,33	23,27
	110-140	19,90	45,90	34,20
	140-200	14,40	67,00	18,60
P4	0-78	10,53	60,47	29,00
	78-110	15,17	53,63	31,20
	110-155	11,00	61,60	27,40
	155-200	9,90	62,90	27,20
P5	0-88	11,56	68,47	19,97
	88-110	10,30	68,60	24,10
	110-140	9,90	64,30	25,80
	140-200	13,00	55,70	31,30

Tablica 4.8. Teksturane oznake Ap i Bg horizonta na istraživanim pozicijama obronka u redu i međurednom prostoru vinograda

Pozicija	Horizont	Međured	Red
P1	Ap	PrGI	PrGI
	Bg	PrGI	PrGI
P2	Ap	PrGI	PrGI
	Bg	PrGI	PrGI
P3	Ap	PrGI	PrGI
	Bg	I	I
P4	Ap	PrGI	PrI
	Bg	PrGI	PrGI
P5	Ap	PrI	PrI
	Bg	PrI	PrI

PrGI – praškasto glinasta ilovača, I – ilovača, PrI – praškasta ilovača.

Tablicom 4.9. prikazana je ANOVA za rezultate analize teksturnog sastava tla na istraživanim pozicijama obronka, redu i međurednom prostoru, te njihovim interakcijama. Rezultati analize teksturnog sastava tla ukazuju na to da postoje značajne razlike u sadržaju pojedinih frakcija (pijeska, praha i gline) tla prema položaju uz nagib te između reda i međurednog prostora vinograda. Tako je sadržaj pijeska, praha i gline značajno različit ($P < 0,0001$) s obzirom na poziciju na obronku.

Tablica 4.9. ANOVA tablica za teksturni sastav tla istraživanih profila

Efekt	Horizont	Pr > F*			
		SS*	Sadržaj pijeska [%]	Sadržaj praha [%]	Sadržaj gline [%]
P ^a	Ap	4	< 0,0001	< 0,0001	< 0,0001
	Bg	4	< 0,0001	< 0,0001	< 0,0001
R/M ^b	Ap	1	0,4155	0,0126	0,0039
	Bg	1	< 0,0001	< 0,0001	0,2483
P ×	Ap	4	< 0,0001	0,1909	0,0772
R/M	Bg	4	< 0,0001	0,0003	0,0004


^a Pozicija na obronku (P1, P2, P3, P4, P5)

^b Red/međured

* SS – stupnjevi slobode; * Pr > F – stupanj signifikantnosti
Istaknute vrijednosti označavaju statistički značajne razlike


Prosječni sadržaj pijeska na istraživanim pozicijama obronka (P1 – P5) za Ap i Bg horizont te u redu i međurednom prostoru prikazane su na Slici 4.7. Značajne razlike zabilježene su i u prosječnom sadržaju pijeska između reda i međurednog prostora za potpovršinski horizont ($P < 0,0001$), gdje je u prosjeku veći sadržaj pijeska zabilježen u međurednom u odnosu na prostor u redu. Razlika u sadržaju pijeska između reda i međurednog prostora nije uočena za

Ap horizont (Tablica 4.9.). Signifikantno najveći sadržaj pijeska zabilježen je na P3 poziciji, dok je najmanji zabilježen na P1 poziciji kako u redu, tako i u međurednom prostoru (Slika 4.7.).




Slika 4.7. Prosječni sadržaj pijeska na istraživanim pozicijama obronka, u redu i međurednom prostoru vinograda te za Ap i Bg horizonte. Različita slova dodijeljena pozicijama ukazuju na statistički značajne razlike između položaja (P1 – P5) te reda i međurednog prostora u istom horizontu.

Prosječni sadržaj praha na istraživanim pozicijama obronka (P1 – P5) za Ap i Bg horizont te u redu i međurednom prostoru prikazan je na slici 4.8. Sadržaj praha, također se značajno razlikuje ovisno o poziciji na obronku ($P < 0,0001$) (Tablica 4.9.). Najveći prosječni sadržaj praha zabilježen je na P5 poziciji, dok je najmanji prosječni sadržaj praha bio na pozicijama P2 i P3. Razlike u prosječnom sadržaju praha uočene su i između reda i međureda, kako u Ap ($P = 0,0126$) tako i u Bg horizontu ($P < 0,0001$). U oba horizonta je veći sadržaj praha bio u redu u odnosu na međuredni prostor



Slika 4.8. Prosječni sadržaj praha na istraživanim pozicijama obronka, u redu i međurednom prostoru vinograda te za Ap i Bg horizonte. Različita slova dodijeljena pozicijama ukazuju na statistički značajne razlike između položaja (P1 – P5) te reda i međurednog prostora u istom horizontu.

Sadržaj gline također se značajno razlikovao ovisno o položaju na obronku ($P < 0,0001$), gdje je signifikantno najveći prosječni sadržaj gline zabilježen na P1 i P2 poziciji, a najmanji na poziciji P5 (Slika 4.9.). Razlika u sadržaju gline između reda i međurednog prostora uočena je samo u Ap horizontu ($P = 0.0039$), dok razlika u prosječnom sadržaju gline u potpovršinskom horizontu između reda i međurednog prostora nije bila značajna (Tablica 4.9.). Iz slike 4.9. vidljivo je kako sadržaj gline u Ap horizontu pada niz obronak, dok je kod Bg horizonta najveći sadržaj gline zabilježen na P2, a najmanji na P4 i P5 poziciji.



Slika 4.9. Prosječni sadržaj gline na istraživanim pozicijama obronka, u redu i međurednom prostoru vinograda te za Ap i Bg horizonte. Različita slova dodijeljena pozicijama ukazuju na statistički značajne razlike između položaja (P1 – P5) te reda i međurednog prostora u istom horizontu.

Tablicom 4.10. prikazana je ANOVA za rezultate analiza ostalih fizikalnih svojstva tla (volumna gustoća (pv), gustoća čvrstih čestica (pč), kapacitet tla za vodu (Kv), kapacitet tla za zrak (Kz) te ukupni porozitet (P)) na istraživanim pozicijama obronka, redu i međurednom prostoru, te njihovim interakcijama. Rezultati analiza ukazuju na postojanje značajnih razlika u svim spomenutim svojstvima s obzirom na poziciju na obronku.

Tablica 4.10. ANOVA tablica za fizikalna svojstva tla istraživanih profila


Efekt		Pr > F*					
	Horizont	SS*	ρ_v [g cm ⁻³]	ρ_c [g cm ⁻³]	Kv [Vol %]	Kz [Vol %]	P [Vol %]
P ^a	Ap	4	0,0003	< 0,0001	< 0,0001	0,0017	0,0011
	Bg	4	< 0,0001	< 0,0001	< 0,0001	< 0,0001	< 0,0001
R/M ^b	Ap	1	0,7821	0,0003	0,0001	0,0005	0,4792
	Bg	1	< 0,0001	0,0053	< 0,0001	< 0,0001	< 0,0001
P × R/M	Ap	4	0,0004	0,0002	0,1519	0,0108	0,0004
	Bg	4	< 0,0001	< 0,0001	< 0,0001	0,0715	< 0,0001

^a Pozicija na obronku (P1, P2, P3, P4, P5)

^b Red/međured


*SS- stupnjevi slobode; *Pr > F – stupanj signifikantnosti, pv – volumna gustoća, pč – gustoća čvrstih čestica, Kv – kapacitet tla za vodu, Kz – kapacitet tla za zrak, P – ukupni porozitet
Istaknute vrijednosti označavaju statistički značajne razlike

Prosječne vrijednosti volumne gustoće tla na istraživanim pozicijama obronka (P1 – P5) za Ap i Bg horizont te red i međuredni prostor vinograda prikazane su slikom 4.10. Vrijednosti volumne gustoće signifikantno se razlikuju ovisno o poziciji na obronku ($P = 0,0003$ za Ap, i $P < 0,0001$ za Bg horizont) (Tablica 4.10.). Kod Ap horizonta nije zabilježena razlika u (prosječnoj) volumnoj gustoći između reda i međurednog prostora vinograda, dok je kod Bg horizonta signifikantno veća volumna gustoća u redu u odnosu na međuredni prostor vinograda. Najveća volumna gustoća u Ap horizontu zabilježena je na poziciji P5, dok se ostale pozicije u volumnoj gustoći međusobno ne razlikuju. Kod Bg horizonta, najveća volumna gustoća zabilježena je na nižim pozicijama obronka i to kod P4 i P5 u međuredu, te kod P3 pozicije u redu (Slika 4.10.).




Slika 4.10. Prosječne vrijednosti volumne gustoće na istraživanim pozicijama obronka, u redu i međurednom prostoru vinograda te za Ap i Bg horizonte. Različita slova dodijeljena pozicijama ukazuju na statistički značajne razlike između položaja (P1 – P5) te reda i međurednog prostora u istom horizontu.

Slika 4.11. prikazuje prosječne vrijednosti gustoće čvrstih čestica na istraživanim pozicijama obronka (P1 – P5) za Ap i Bg horizonte te u redu i međurednom prostoru vinograda. Vrijednosti gustoće čvrstih čestica signifikantno se razlikuju s obzirom na poziciju na obronku ($P < 0,0001$) i u Ap i Bg horizontu (Tablica 4.10). Također, zabilježene su i signifikantne razlike između reda i međurednog prostora vinograda samo za pojedine pozicije i to za P1 i P4 poziciju u Ap te za P2 poziciju u Bg horizontu (Slika 4.11.).




Slika 4.11. Prosječne vrijednosti gustoće čvrstih čestica tla na istraživanim pozicijama obronka, u redu i međurednom prostoru vinograda te za Ap i Bg horizonte. Različita slova dodijeljena pozicijama ukazuju na statistički značajne razlike između položaja (P1 – P5) te reda i međurednog prostora u istom horizontu.

Prosječne vrijednosti kapaciteta tla za vodu (Kv) prikazane su slikom 4.12. Vrijednosti Kv-a značajno se razlikuju ovisno o poziciji na obronku ($P < 0,0001$) u Ap i Bg horizontu (Tablica 4.10.). Iz slike 4.12. vidljivo je kako se vrijednosti Kv-a smanjuju niz obronak. Međutim, značajno najmanja vrijednost Kv-a zabilježena je u redu na P3 poziciji u Bg horizontu. Općenito, signifikantno veće vrijednosti Kv-a zabilježene su u međuredu u odnosu na prostor u redu (kod oba horizonta).




Slika 4.12. Prosječne vrijednosti kapaciteta tla za vodu (Kv) na istraživanim pozicijama obronka, u redu i međurednom prostoru vinograda te za Ap i Bg horizonte. Različita slova dodijeljena pozicijama ukazuju na statistički značajne razlike između položaja (P1 – P5) te reda i međurednog prostora u istom horizontu.

Prosječne vrijednosti kapaciteta tla za zrak (Kz), prikazane su slikom 4.13. Vrijednosti Kz-a signifikantno se razlikuju ovisno o poziciji na obronku ($P = 0,0005$ za međured i $P < 0,0001$ za red vinograda) (Tablica 4.10.). Najveće vrijednosti Kz-a zabilježene su na P3 i P5 poziciji u redu u Ap horizontu (Slika 4.13.). Iz slike je također vidljivo kako vrijednosti Kz-a u Bg horizontu rastu niz obronak. Također iz slike 4.13. uočljivo je kako su veće vrijednosti Kz-a zabilježene u redu u odnosu na međuredni prostor vinograda, osim kod pozicije P1 (Ap horizont) gdje su veće vrijednosti Kz-a zabilježene u međuredu u odnosu na red vinograda.



Slika 4.13. Prosječne vrijednosti kapaciteta tla za zrak (Kz) na istraživanim pozicijama obronka, u redu i međurednom prostoru vinograda te za Ap i Bg horizonte. Različita slova dodijeljena pozicijama ukazuju na statistički značajne razlike između položaja (P1 – P5) te reda i međurednog prostora u istom horizontu.

Slika 4.14. prikazuje srednje vrijednosti ukupnog poroziteta (P) svih istraživanih pozicija, reda/međureda te Ap i Bg horizonta. Statističkom analizom utvrđeno je kako postoje signifikantne razlike u prosječnim vrijednostima P između pozicija na obronku za Ap ($P = 0,0011$) i za Bg horizont ($P < 0,0001$) (Tablica 4.10.). Razlike u prosječnim vrijednostima P između reda i međurednog prostora nisu uočene za Ap horizont, dok su kod Bg horizonta signifikantno veće vrijednosti ukupnog poroziteta zabilježene u međurednom dijelu vinograda ($P < 0,0001$).



Slika 4.14. Prosječne vrijednosti ukupnog poroziteta (P) na istraživanim pozicijama obronka, u redu i međurednom prostoru vinograda te za Ap i Bg horizonte. Različita slova dodijeljena pozicijama ukazuju na statistički značajne razlike između položaja (P1-P5) te reda i međurednog prostora u istom horizontu.

4.2.5. Kemijska svojstva pedoloških profila na istraživanom obronku

Vrijednosti pH (H_2O i KCl) te sadržaj humusa (%) u istraživanim profilima, do dubine od 2 metra prikazane su u tablici 4.11. Iz tablice je vidljivo kako pH vrijednosti (H_2O i KCl) uglavnom rastu s povećanjem dubine u svim istraživanim profilima. Do 110 cm dubine pH reakcija tla (u KCl-u) uglavnom je jako kisela (manje od pH 4,5). Najveća pH reakcija tla izmjerena je na P3 poziciji na dubini 140-200 cm, gdje je pH reakcija tla okarakterizirana kao neutralna. U pogledu sadržaja humusa tlo na istraživanom obronku uglavnom je vrlo slabo do slabo humozno (0-3 % humusa). Izuzetak je P1 pozicija gdje je na dubini od 110-140 cm uočen veći sadržaj humusa (dosta humozno tlo) u odnosu na ostale pozicije.

Tablica 4.11. Kemijska svojstva tla (pH i sadržaj humusa) istraživanih profila (P1 – P5) do dubine od dva metra.

Pozicija	Dubina [cm]	pH		Humus [%]
		H_2O	KCl	
P1	0-55	5,54	3,36	1,19
	55-110	5,66	3,87	0,44
	110-140	6,34	4,94	3,70
	140-200	6,61	5,02	2,35
P2	0-60	5,84	4,09	1,29
	60-110	6,23	4,56	0,65
	110-140	7,01	6,20	1,14
	140-200	7,57	6,78	1,76
P3	0-70	5,34	3,59	1,28
	70-110	5,57	3,61	0,38
	110-140	5,31	3,75	1,53
	140-200	7,87	7,07	0,96
P4	0-78	5,33	3,70	1,34
	78-110	5,53	3,76	0,42
	110-155	6,02	4,25	0,78
	155-200	6,00	4,48	0,72
P5	0-88	5,09	3,71	1,10
	88-110	5,19	3,83	0,61
	110-140	5,50	3,96	1,73
	140-200	5,95	4,02	1,09

Tablicom 4.12. prikazana je ANOVA za rezultate analize pH tla i sadržaja humusa na istraživanim pozicijama obronka, redu i međurednom prostoru, te njihove interakcije. pH tla signifikantno se razlikuje s obzirom na poziciju na obronku za Ap ($P < 0,0001$) i za Bg horizont pH (KCl) $P = 0,0002$, pH (H_2O) $P < 0,0001$. Razlike u pH tla između reda i međurednog prostora također su signifikantne za pH (H_2O) $P < 0,0001$ za oba horizonta, dok je za pH (KCl) signifikantna razlika između reda i međureda uočena za Ap ($P = 0,0002$), ali ne i za Bg horizont (Tablica 4.12.).

Tablica 4.12. ANOVA tablica za kemijska svojstva istraživanih profila


Efekt		Pr > F*			
	Horizont	SS*	pH [KCl]	pH [H ₂ O]	Humus [%]
P ^a	Ap	4	< 0,0001	< 0,0001	< 0,0001
	Bg	4	0,0002	< 0,0001	< 0,0001
R/M ^b	Ap	1	0,0002	< 0,0001	< 0,0001
	Bg	1	0,4212	< 0,0001	< 0,0001
P × R/M	Ap	4	< 0,0001	< 0,0001	< 0,0001
	Bg	4	0,0378	< 0,0001	< 0,0001

^a Pozicija na obronku (P1, P2, P3, P4, P5)

^b Red/međured


*SS- stupnjevi slobode; *Pr > F – stupanj signifikantnosti
Istaknute vrijednosti označavaju statistički značajne razlike

Slika 4.15. prikazuje prosječne vrijednosti pH (KCl i H₂O) na istraživanim pozicijama obronka (P1 – P5) za Ap i Bg horizonte te u redu i međurednom prostoru vinograda. Najveće vrijednosti pH (KCl i H₂O) zabilježene su na P2 poziciji u međurednom dijelu vinograda i to u oba horizonta (Slika 4.15.).



Slika 4.15. Prosječne vrijednosti pH (KCl i H₂O) na istraživanim pozicijama obronka, u redu i međurednom prostoru vinograda te u Ap i Bg horizontu. Različita slova dodijeljena pozicijama ukazuju na statistički značajne razlike između položaja (P1-P5) te reda i međurednog prostora u istom horizontu.

Slika 4.16. prikazuje prosječne vrijednosti sadržaja humusa na istraživanim pozicijama obronka (P1 – P5) za Ap i Bg horizonte te u redu i međurednom prostoru vinograda. Sadržaj humusa značajno se razlikuje s obzirom na poziciju obronka. Signifikantno veći ($P < 0,0001$) sadržaj humusa uočen je u redu u odnosu na međured kako za Ap tako i za Bg horizont (Tablica 4.11.). Signifikantno najveći sadržaj humusa uočen je na P3 poziciji u redu vinograda, kako u Ap tako i u Bg horizontu. U Ap horizontu najmanji sadržaj humusa zabilježen je na P1 i P5 poziciji, dok je u Bg horizontu u međurednom dijelu vinograda (P1-P4) zabilježen signifikantno manji sadržaj humusa u odnosu na red (Slika 4.16.).



Slika 4.16. Prosječne vrijednosti sadržaja humusa na istraživanim pozicijama obronka, u redu i međurednom prostoru vinograda te u Ap i Bg horizontu. Različita slova dodijeljena pozicijama ukazuju na statistički značajne razlike između položaja (P1-P5) te reda i međurednog prostora u istom horizontu.

4.2.6. Vodno-retencijske značajke tla

Tablicom 4.13. prikazana je ANOVA za vodno-retencijske značajke tla na istraživanoj lokaciji. Iz tablice je vidljivo kako se kapacitet tla za vodu (Kv), točka venuća (Tv), a samim time i fiziološki aktivna vlaga (Fav) značajno razlikuju s obzirom na poziciju na obronku ($P < 0,0001$). Međutim za utjecaj efekta reda i međurednog prostora kao i za pozicije na obronku sa redom i međurednom prostorom, značajne razlike nisu uočene.

Tablica 4.13. ANOVA tablica za vodno-retencijske značajke tla

Efekt		Pr > F*			
	Horizont	SS*	Kv 0,33 bara [cm ³ cm ⁻³]	Tv 15 bara [cm ³ cm ⁻³]	Fav [cm ³ cm ⁻³]
P ^a	Ap	4	< 0,0001	< 0,0001	< 0,0001
	Bg	4	< 0,0001	< 0,0001	< 0,0001
R/M ^b	Ap	1	1,0	1,0	1,0
	Bg	1	1,0	1,0	1,0
P × R/M	Ap	4	1,0	1,0	1,0
	Bg	4	1,0	1,0	1,0

^a Pozicija na obronku (P1, P2, P3, P4, P5)

^b Red/međured

*SS- stupnjevi slobode; *Pr > F – stupanj signifikantnosti, Kv – kapacitet tla za vodu, Tv – točka venuća, Fav – fiziološki aktivna vlaga

Istaknute vrijednosti označavaju statistički značajne razlike

Tablica 4.14. prikazuje vodno-retencijske značajke tla na pet pozicija na obronku u redu i međurednom prostoru vinograda za Ap i Bg horizonte. Kapacitet tla za vodu varira od 0,396 cm³ cm⁻³ na P3 poziciji u međuredu u Bg horizontu, do 0,063 (cm³ cm⁻³) na P2 (red) poziciji u Bg horizontu. Iz tablice je vidljivo kako je veći kapacitet tla za vodu utvrđen na višim pozicijama

obronka (npr. P1 i P2) u odnosu na ostale pozicije. Sadržaj vlage kod točke venuća (Tv) varira od 0,180 cm³ cm⁻³, na P3 poziciji u međuredu, do 0,390 cm³ cm⁻³ na P2 (red) u Bg horizontu. Ovisno o poziciji na obronku te položaju red/međured biljka na raspolaganju ima fiziološki aktivne vlage (FaV) u rasponu od minimalnih 0,216 cm³ cm⁻³ pa do 0,303 cm³ cm⁻³. U pravilu Kv, Tv i Fav rastu s povećanjem dubine od Ap do Bg horizonta, s iznimkom P3 pozicije gdje su veće vrijednosti Kv-a, Tv-a i FaV-a uočene u Ap u odnosu na Bg horizont.

Tablica 4.14. Vodno-retencijske značajke tla na istraživanoj lokaciji određene na tlačnom ekstraktoru

Pozicija	Horizont	Kv 0,33 bara [cm ³ cm ⁻³]	Tv 15 bara [cm ³ cm ⁻³]	FaV [cm ³ cm ⁻³]
P1 međured	Ap	0,498	0,275	0,223
	Bg	0,533	0,255	0,278
P1 red	Ap	0,555	0,307	0,248
	Bg	0,581	0,278	0,303
P2 međured	Ap	0,500	0,271	0,229
	Bg	0,594	0,360	0,234
P2 red	Ap	0,500	0,271	0,229
	Bg	0,644	0,390	0,254
P3 međured	Ap	0,489	0,236	0,253
	Bg	0,396	0,180	0,216
P3 red	Ap	0,453	0,219	0,235
	Bg	0,446	0,203	0,243
P4 međured	Ap	0,450	0,207	0,243
	Bg	0,515	0,248	0,267
P4 red	Ap	0,467	0,215	0,252
	Bg	0,479	0,231	0,248
P5 međured	Ap	0,446	0,196	0,250
	Bg	0,459	0,212	0,247
P5 red	Ap	0,398	0,175	0,223
	Bg	0,456	0,210	0,246

Tablicom 4.15. prikazan je volumen sporo i brzo drenirajućih pora, ukupni porozitet te diferencijalna poroznost na istraživanom obronku u Ap i Bg horizontu u međurednom prostoru vinograda.

Tablica 4.15. Prikaz diferencijalne poroznosti u međuredu na istraživanim pozicijama obronka

Pozicija na obronku	Horizont	Dubina [cm]	Ukupni volumen pora [Vol %]	Volumen makropora [Vol %]	Volumen brzo-drenirajućih pora [Vol %]	Volumen sporo-drenirajućih pora [Vol %]	Volumen mikropora [Vol %]	Odnos kaliparnih i nekapilarnih pora
P1	Ap	0-55	50,77	1,97	1,87	0,10	48,80	24,8:1
	Bg	55-110	59,04	1,98	1,94	0,04	57,06	28,8:1
P2	Ap	0-60	52,59	1,16	1,04	0,12	51,43	44,3:1
	Bg	60-110	57,26	1,24	1,06	0,18	56,02	45,2:1
P3	Ap	0-70	47,71	2,57	2,47	0,10	45,14	17,6:1
	Bg	70-110	48,38	1,64	1,52	0,12	46,74	28,5:1
P4	Ap	0-78	49,90	4,00	3,82	0,18	45,90	11,5:1
	Bg	78-110	41,15	0,77	0,61	0,16	40,38	52,4:1
P5	Ap	0-88	44,72	4,38	4,16	0,22	40,34	9,2:1
	Bg	88-110	42,26	2,66	2,52	0,14	39,60	14,9:1

Iz prikazanih rezultata ukupne i diferencijalne poroznosti vidljivo je kako je ukupni volumen pora najveći na višim pozicijama obronka (tj. P1 i P2) (Tablica 4.15.). Najmanji ukupni porozitet zabilježen je na P4 poziciji u potpovršinskom horizontu, a iznosi 41,15 Vol % (Tablica 4.15.). Veća ukupna poroznost uočena je u Bg u odnosu na Ap horizont za P1, P2 i P3 poziciju, dok je kod P4 i P5 pozicije veća ukupna poroznost zabilježena u Ap u odnosu na Bg horizont. Volumen makropora veći je na nižim pozicijama obronka (P4 i P5), dok je najmanji volumen makropora uočen na P4 poziciji u Bg horizontu. Iz tablice 4.15. vidljivo je kako se volumen brzo – drenirajućih pora kreće u rasponu od 0,61 do 4,16 Vol %, dok se volumen sporo – drenirajućih pora kreće od 0,04 do 0,22 Vol %. Odnosa kapilarnih (mikro) i nekapilarnih (makro) pora kreće se od 14,9:1 na P5 poziciji u Ap horizontu, pa sve do 52,4:1 na P4 poziciji u Bg horizontu.


Tablica 4.16. prikazuje vrijednosti propusnosti tla za vodu određene na aparatu sa serijsko određivanje vodopropusnosti te na K-sat uređaju. Manje vrijednosti vodopropusnosti zabilježene su u potpovršinskom (Bg) u odnosu na površinski horizont. Iznos koeficijenta vodopropusnosti za Ap horizont varira od 1,8 cm dan⁻¹ kod P2 pozicije, do 4,8 cm dan⁻¹ kod P5 pozicije. Što se tiče vrijednosti koeficijenta vodopropusnosti za Bg horizont vrijednosti variraju od 0,7 cm dan⁻¹ na P1 pa do 4,00 cm dan⁻¹ na P3 poziciji. Vrijednosti K_s -a određenog na aparatu za serijsko određivanje vodopropusnosti više su u odnosu na vrijednosti dobivene putem K-sat uređaja.

Tablica 4.16. Prikaz K_s – a određenog na aparatu za serijsko određivanje vodopropusnosti i K - sat uređaju

Pozicija	Horizont	K_s – serijsko određivanje vodopropusnosti [cm dan ⁻¹]	K_s – K-sat [cm dan ⁻¹]
P1 međured	Ap	3,685	0,050
	Bg	0,715	0,140
P1 red	Ap	/	0,134
	Bg	/	2,65
P2 međured	Ap	1,791	/
	Bg	1,322	/
P2 red	Ap	/	/
	Bg	/	/
P3 međured	Ap	2,465	0,935
	Bg	4,016	1,171
P3 red	Ap	/	1,776
	Bg	/	1,111
P4 međured	Ap	3,175	/
	Bg	2,001	/

Pozicija	Horizont	K_s – serijsko određivanje vodopropusnosti [cm dan ⁻¹]	K_s – K-sat [cm dan ⁻¹]
nastavak			
P4 red	Ap	/	/
	Bg	/	/
P5 međured	Ap	4,824	2,656
	Bg	2,081	1,520
P5 red	Ap	/	1,258
	Bg	/	1,596

Slika 4.17. prikazuje rezultate simulacija kišenja na uzorcima tla u kolonama u kontroliranim laboratorijskim uvjetima. Simulacije kišenja odnosno ispiranje kolona tla vršilo se u razdoblju do 20 dana nakon što se ujednačio tok vode kroz tlo unutar kolona. Na kolonu je u vidu simulacije kišenja aplicirano 250 ml vode svaki dan (tijekom 20 dana). Istek na dnu kolone prikupljao se u menzure i mjerio u rasponu od 10, 20, 30, 60, 120 i 140 minuta od aplikacije.




Slika 4.17. Istek (ml) iz kolona tla na P1, P3 i P5 poziciji obronka u redu i međurednom prostoru vinograda

Iz rezultata je vidljivo kako je, na kraju pokusa (240 min nakon aplikacije) najveći ukupni istek vode zabilježen na donjoj P5 poziciji obronka u redu (gotovo 180 ml), dok su najmanje vrijednosti isteka zabilježene na srednjoj (P3) poziciji u redu u iznosu od 68 ml. Najveće

početne vrijednosti isteka (10 min nakon aplikacije) zabilježene su na poziciji P5 u redu (121 ml), dok su najmanje početne vrijednosti isteka zabilježene na P1 poziciji u redu (7 ml). Samo je P5 pozicija imala veći istek u redu u odnosu na međured, dok je kod P1 i P3 pozicije veći istek zabilježen u međuredu u odnosu na red.

Slika 4.18. prikazuje porozni sustav na P1 poziciji dobivenim skeniranjem kolona tla pomoću CT skenera. Slike 4.18a i 4.18b prikazuju porozni sustav u redu dok, slike 4.18c i 4.18d prikazuju izgled poroznog sustava tla u međuredu vinograda. Sivi dio predstavlja čvrstu fazu tla (matriks) dok crveni dio pore. Iz slike 4.18. i tablice 4.17. vidljivo je kako je ukupni volumen pora veći u međuredu u odnosu na red, međutim na slikama 4.18c i 4.18d vidi se kako volumen pora opada nakon dubine od oko 8 cm.




Slika 4.18. Prikaz poroznog sustava P1 pozicije skeniranog pomoću CT skenera. a i b slike predstavljaju red, dok c i d predstavljaju međured vinograda.

Nakon skeniranja slike su analizirane gdje ju temeljem ukupnog broja piksela (sivi i crveni) utvrđen postotak pora. Tablica 4.17. prikazuje zastupljenost pora na P1 poziciji u redu i međuredu vinograda.

Tablica 4.17. Ukupni i broj crvenih piksela (% pora) na P1 poziciji te u redu i međurednom prostoru vinograda.

Pozicija	Broj piksela		Crveni pikseli [%]
	Ukupno	Crveni	
P1 red (a)	2970000	206308	6,95
P1 red (b)	2970000	204433	6,88
P1 međured (c)	2970000	781769	26,32
P1 međured (d)	2970000	648003	21,82

Srednje vrijednosti (od tri ponavljanja na tri pozicije) volumena površinskog otjecanja na datume uzorkovanja prikazane su na slici 4.19.



Slika 4.19. Srednje vrijednosti volumena površinskog otjecanja tijekom istraživnog razdoblja

Općenito, više vrijednosti površinskog otjecanja zabilježene su na poziciji P1, osim na datum 17.01.2020. godine kada su najveće vrijednosti površinskog otjecanja zabilježene na P3 poziciji. Volumen vode koja se površinski kreće niz nagib na P1 poziciji kretao se od gotovo 13,5 L izmjerene 25.11.2019. pa do 0,5 L 21.4.2020. godine. Volumen vode na P5 poziciji kretao se od svega 0,18 L koja je izmjerena 7.2.2020. godine, dok je najveća vrijednost zabilježena 25.11.2019. godine, a iznosila je 10,0 L. Na poziciji P3 raspon volumena površinskog otjecanja varirao je od 0,4 L (5.3.2020.) do 13,5 L (17.1.2020.).

4.2.7. Hidraulička svojstva tla

4.2.7.1. Retencijske krivulje

Na osnovu podataka vodnog potencijala, te sadržaja i toka vode određene su krivulje retencije vode i hidrauličke vodljivosti na uzorcima tla. Hidraulička svojstva tla određena su na HYPROP i WP4C uređaju, a retencijske i hidrauličke krivulje izrađene su u HYPROP-FIT softveru. Hidraulički parametri kao rezultat korištenja Van Genuchtenovog original i bimodal modela (van Genuchten, 1980., Durner, 1994.) u HYPROP-FIT softveru prikazani su u tablici 4.18. i 4.19. Retencijske krivulje prikazane su slikama 4.20. do 4.25. Plave (VG–original model) i crne (VG – bimodal model) linije na slikama predstavljaju krivulje koje su procijenjene na temelju izmjerenih vrijednosti vodnog potencijala tla i sadržaja vode u tlu, a temelje se na Van Genuchten – Mualemovom modelu. Retencijske krivulje ključne su za karakterizaciju dinamike vlažnosti tla, a predstavljaju kontinuiranu promjenu sadržaja vode u tlu od potpune saturacije θ_s pa sve do malih vrijednosti, odnosno do tzv. rezidualnog sadržaja vode u tlu θ_r . Različiti simboli (žuti, crveni i crni) predstavljaju mjerenja, odnosno točke opažanja na tri neporušena uzorka tla temeljem kojih je prilagođena (eng. *fitted*) retencijska krivulja.

Slike 4.20. i 4.21. prikazuju retencijske krivulje za P1 poziciju dobivene pomoću Van Genuchten original i bimodal modela. Na P1 poziciji u međuredu količina vode kod potpune saturacije θ_s određena pomoću Van Genuchten original modela veća je u Bg ($0,518 \text{ cm}^3 \text{ cm}^{-3}$) horizontu u odnosu na Ap ($0,476 \text{ cm}^3 \text{ cm}^{-3}$). U redu je situacija obrnuta, naime količina vode kod potpune saturacije veća je u Ap ($0,470 \text{ cm}^3 \text{ cm}^{-3}$) u odnosu na Bg horizont ($0,424 \text{ cm}^3 \text{ cm}^{-3}$). Rezidualni sadržaj vode θ_r u tlu kod svih pozicija (kod Van Genuchten original modela), za red i za međured, te za Ap i Bg horizont iznosi $0 \text{ cm}^3 \text{ cm}^{-3}$. Općenito se može zaključiti kako je nešto veći sadržaj vode zabilježen je kod saturacijskih uvjeta θ_s primjenom Van Genuchten bimodal modela u odnosu na Van Genuchten original model. Kod Van Genuchten bimodal modela u pravilu je na svim pozicijama, te u redu i međurednom prostoru u Bg horizontu rezidualni sadržaj vode θ_r iznosio $0 \text{ cm}^3 \text{ cm}^{-3}$. Iznimka je P3 pozicija kod koje je u međuredu u Bg horizontu zabilježena vrijednost rezidualnog sadržaja vode (θ_r) u iznosu od $0,125 \text{ cm}^3 \text{ cm}^{-3}$.

Tablica 4.18. Hidraulički parametri dobiveni pomoću HYPROP-FIT softvera korištenjem Van Genuchten original modela uz prikaz statističke pouzdanosti (*RMSE*)


Pozicija	Horizont	θ_r [cm ³ cm ⁻³]	θ_s [cm ³ cm ⁻³]	α [cm ⁻¹]	n [-1]	K_s [cm dan ⁻¹]	I	$RMSE_{\theta}$ [cm ³ cm ⁻³]	$RMSE_{K_s}$ [cm dan ⁻¹]
P1 međured	Ap	0,000	0,476	0,00226	1,228	0,0431	-1,940	0,0100	0,3181
	Bg	0,000	0,518	0,00212	1,263	0,0879	-1,311	0,0102	0,3184
P1 red	Ap	0,000	0,470	0,00329	1,211	0,120	-0,242	0,0127	0,3459
	Bg	0,000	0,424	0,00275	1,225	0,154	1,642	0,0219	0,3189
P3 međured	Ap	0,000	0,454	0,00608	1,172	0,589	-0,751	0,0154	0,2425
	Bg	0,000	0,435	0,00252	1,249	0,0826	1,570	0,0171	0,3004
P3 red	Ap	0,000	0,462	0,0112	1,156	0,667	-2,452	0,0492	0,4034
	Bg	0,000	0,424	0,00275	1,225	0,154	1,642	0,0219	0,3189
P5 međured	Ap	0,000	0,405	0,0164	1,138	2,65	-5,924	0,0139	0,1735
	Bg	0,000	0,404	0,00156	1,301	0,0807	2,310	0,0121	0,2812
P5 red	Ap	0,000	0,442	0,0150	1,173	2,10	-3,744	0,0209	0,1709
	Bg	0,000	0,423	0,00474	1,217	0,739	0,582	0,0137	0,2157

θ_r rezidualni sadržaj vlage u tlu (eng. *Residual soil water content*); θ_s sadržaj vlage u tlu pri saturacijskim uvjetima (eng. *Saturated soil water content*); α empirijski parametar oblika krivulje; n empirijski parametar oblika krivulje; K_s saturirana hidraulička vodljivost (eng. *Saturated hydraulic conductivity*); I parametar povezanosti pora (eng. *Pore connectivity parameter*)


Tablica 4.19. Hidraulički parametri dobiveni pomoću HYPROP-FIT softvera korištenjem Van Genuchten bimodal modela uz prikaz statističke pouzdanosti (*RMSE*)

Pozicija	Horizont	θ_r [cm ³ cm ⁻³]	θ_s [cm ³ cm ⁻³]	α_1 [cm ⁻¹]	α_2 [cm ⁻¹]	n_1 [-1]	n_2 [-1]	K_s [cm dan ⁻¹]	W_2 [-]	I	$RMSE_{\theta}$ [cm ³ cm ⁻³]	$RMSE_{K_s}$ [cm dan ⁻¹]
P1 međured	Ap	0,044	0,481	0,0436	0,00124	2,975	1,342	0,0493	0,949	-4,416	0,0086	0,2186
P1 međured	Bg	0,000	0,529	0,0383	0,00126	2,960	1,328	0,140	0,943	-3,327	0,0073	0,2039
P1 red	Ap	0,031	0,477	0,00130	0,0312	1,318	2,217	0,134	0,087	-0,840	0,0107	0,3082
P1 red	Bg	0,000	0,430	0,0187	0,00055	1,111	2,618	2,65	0,353	1,425	0,0205	0,2668
P3 međured	Ap	0,000	0,459	0,0292	0,00088	1,329	1,252	0,935	0,746	-2,070	0,0137	0,2123
P3 međured	Bg	0,125	0,441	0,00065	0,0255	2,266	1,565	0,171	0,222	-0,412	0,0141	0,2433
P3 red	Ap	0,099	0,470	0,00050	0,0397	1,607	1,776	0,252	0,271	-6,000	0,0476	0,3939
P3 red	Bg	0,000	0,430	0,00055	0,0187	2,618	1,111	2,65	0,647	1,425	0,0205	0,2668
P5 međured	Ap	0,048	0,420	0,00068	0,1300	1,637	1,308	36,2	0,336	-0,744	0,0037	0,0780
P5 međured	Bg	0,000	0,410	0,00050	0,0122	6,999	1,122	1,52	0,609	2,792	0,0073	0,2114
P5 red	Ap	0,059	0,450	0,00059	0,0439	2,143	1,258	5,83	0,563	-1,596	0,0172	0,1371
P5 red	Bg	0,000	0,433	0,0250	0,00047	1,141	15,000	15,2	0,314	3,268	0,0063	0,1842

θ_r rezidualni sadržaj vlage u tlu (eng. *Residual soil water content*); θ_s sadržaj vlage u tlu pri saturacijskim uvjetima (eng. *Saturated soil water content*); α_1 empirijski parametar oblika krivulje prvog poroznog sustava (unutar agregata); α_2 empirijski parametar oblika krivulje drugog poroznog sustava (između agregata); n_1 empirijski parametar oblika krivulje prvog poroznog sustava (unutar agregata); n_2 empirijski parametar oblika krivulje drugog poroznog sustava (poroznog sustava); K_s saturirana hidraulička vodljivost (eng. *Saturated hydraulic conductivity*); W_2 faktor težine drugog poroznog sustava ($W_1 = 1 - W_2$); I parametar povezanosti pora (eng. *Pore connectivity parameter*)




Slika 4.20 Retencijske krivulje P1 pozicije dobivene korištenjem Van Genuchten original modela pomoću HYPROP-FIT softvera




Slika 4.21. Retencijske krivulje P1 pozicije dobivene korištenjem Van Genuchten bimodal modela pomoću HYPROP-FIT softvera

Slike 4.22. i 4.23. prikazuju retencijske krivulje za P3 poziciju (međured/red te Ap i Bg horizonte) dobivene pomoću Van Genuchten original i bimodal modela. U međurednom prostoru te u redu, količina vode kod potpune saturacije θ_s veća je za Ap horizont, (0,454 i 0,462 $\text{cm}^3 \text{cm}^{-3}$), horizontu u odnosu na Bg horizont za koji iznosi (0,435 i 0,424 $\text{cm}^3 \text{cm}^{-3}$). Rezidualni sadržaj vode θ_r u tlu kod P3 pozicije, za red i za međured, te za Ap i Bg horizont iznosi 0 $\text{cm}^3 \text{cm}^{-3}$. Nešto veći sadržaj vode kod saturacijskih uvjeta θ_s zabilježen je primjenom Van Genuchten bimodal modela u odnosu na Van Genuchten original model.




Slika 4.22. Retencijske krivulje P3 pozicije dobivene korištenjem Van Genuchten original modela pomoću HYPROP-FIT softvera




Slika 4.23. Retencijske krivulje P3 pozicije dobivene korištenjem Van Genuchten bimodal modela pomoću HYPROP-FIT softvera

Slike 4.24. i 4.25. prikazuju retencijske krivulje za P5 poziciju (međured/red te Ap i Bg horizont) dobivene pomoću Van Genuchten original i bimodal modela. Kod primjene Van Genuchten original modela u međurednom prostoru gotovo da i nema razlike u sadržaju vode u tlu pri saturacijskim uvjetima između Ap i Bg horizonta. U redu, veći sadržaj vode pri saturacijskim uvjetima zabilježen je u površinskom ($0,442 \text{ cm}^3 \text{ cm}^{-3}$) u odnosu na potpovršinski horizont ($0,423 \text{ cm}^3 \text{ cm}^{-3}$). Primjenom Van Genuchten bimodal modela najveći sadržaj vode pri potpunoj saturaciji na poziciji P5 zabilježen je u Ap horizontu u redu ($0,450 \text{ cm}^3 \text{ cm}^{-3}$), dok je najmanji zabilježen u Bg horizontu u redu ($0,410 \text{ cm}^3 \text{ cm}^{-3}$).



Slika 4.24. Retencijske krivulje P5 pozicije dobivene korištenjem Van Genuchten original modela pomoću HYPROP-FIT softvera




Slika 4.25. Retencijske krivulje P5 pozicije dobivene korištenjem Van Genuchten bimodal modela pomoću HYPROP-FIT softvera


4.2.7.2. Hidrauličke krivulje

Slike 4.26. do 4.31. prikazuju odnos relativne količine vode u tlu i hidrauličke vodljivosti neporušenih uzoraka tla mjerenih na K-Sat uređaju. Hidraulička krivulja predstavlja ovisnost hidrauličke vodljivosti o sadržaju vode u tlu. Plave (VG – original model) i crne (VG – bimodal model) linije na slikama predstavljaju krivulje koje su procijenjene na temelju izmjerenih vrijednosti. Različiti simboli (žuti, crveni i crni) predstavljaju mjerenja, odnosno točke opažanja na tri neporušena uzorka tla temeljem kojih je prilagođena (eng. *fitted*) hidraulička krivulja.

Hidrauličke krivulje P1 pozicije prikazane su slikama 4.26. i 4.27. Koeficijent hidrauličke vodljivosti (VG original model) za P1 poziciju veći je u redu u odnosu na međuredni dio vinograda, a varira od $0,0431 \text{ cm dan}^{-1}$ za Ap horizont u međuredu do $0,154 \text{ cm dan}^{-1}$ za Bg horizont u redu. Kod VG-bimodal modela vrijednost hidrauličke vodljivosti najveći je u redu u Bg horizontu $2,65 \text{ cm dan}^{-1}$, a najmanji u međuredu u Ap horizontu ($0,0493 \text{ cm dan}^{-1}$). Općenito, vidi se da su vrijednosti koeficijenta hidrauličke vodljivosti (za VG original i VG bimodal) na P1 poziciji manje u Ap u odnosu na Bg horizont (Tablica 4.18. i 4.19.).




Slika 4.26. Hidrauličke krivulje P1 pozicije dobivene korištenjem Van Genuchten original modela pomoću HYPROP-FIT softvera




Slika 4.27. Hidrauličke krivulje P1 pozicije dobivene korištenjem Van Genuchten bimodal modela pomoću HYPROP-FIT softvera

Hidrauličke krivulje P3 pozicije prikazane su slikama 4.28. i 4.29. Iz slika 4.28. i 4.19. te tablica 4.18. i 4.19. uočljivo je kako su u redu veće vrijednosti koeficijenata hidrauličke vodljivosti u odnosu na međured (za Ap i Bg horizont). Iznimka je vrijednost koeficijenta hidrauličke vodljivosti određenog prema VG bimodal modelu koji je veći u međuredu u odnosu na red (Ap horizont). Vrijednost koeficijenta hidrauličke vodljivosti dobiven pomoću VG original modela za P3 poziciju veći je u Ap u odnosu na Bg horizont, a kreće se od $0,589 \text{ cm dan}^{-1}$ za međured do $0,667 \text{ cm dan}^{-1}$ u redu. U Bg horizontu vrijednosti koeficijenta hidrauličke vodljivosti kreću se od $0,0826 \text{ cm dan}^{-1}$ u međuredu do $0,154 \text{ cm dan}^{-1}$ u redu. Kod VG bimodal modela vrijednosti koeficijenta hidrauličke vodljivosti nešto su veće u odnosu na VG original, a kreću se od $0,171 \text{ cm dan}^{-1}$ za Bg horizont u međurednom prostoru vinograda pa do $2,65 \text{ cm dan}^{-1}$ za Bg horizont u redu. Kako je vidljivo iz slike 4.28. VG bimodal model nije procijenio hidrauličku krivulju za red u Ap horizontu.




Slika 4.28. Hidrauličke krivulje P3 pozicije dobivene korištenjem Van Genuchten original modela pomoću HYPROP-FIT softvera




Slika 4.29. Hidrauličke krivulje P3 pozicije dobivene korištenjem Van Genuchten bimodal modela pomoću HYPROP-FIT softvera

Na slikama 4.30. i 4.31. prikazane su hidrauličke krivulje P5 pozicije. Iz navedenih slika i tablica 4.18. i 4.19. vidljivo je kako su vrijednosti koeficijenta hidrauličke vodljivosti veće u međuredu u odnosu na red za Ap horizont, dok je kod Bg horizonta situacija obrnuta. Koeficijent hidrauličke vodljivosti dobiven pomoću VG original modela za P5 poziciju veći je u Ap u odnosu na Bg horizont, a kreće se od 2,65 cm dan⁻¹ za međured do 2,10 cm dan⁻¹ u redu. U Bg horizontu vrijednosti hidrauličke vodljivosti kreću se od 0,0807 cm dan⁻¹ u Bg do 0,739 cm dan⁻¹ u redu. Kod VG bimodal modela koeficijenti hidrauličke vodljivosti veći su u odnosu na VG original. Vrijednosti hidrauličke vodljivosti najveće su u površinskom horizontu u međuredu (36,2 cm dan⁻¹, a najmanje u Bg horizontu, također u međuredu (1,52 cm dan⁻¹).



Slika 4.30. Hidrauličke krivulje P5 pozicije dobivene korištenjem Van Genuchten original modela pomoću HYPROP-FIT softvera



Slika 4.31. Hidrauličke krivulje P5 pozicije dobivene korištenjem Van Genuchten bimodal modela pomoću HYPROP-FIT softvera

4.3. Retencija vlage u tlu tijekom istraživanja

U sljedećem poglavlju prikazan je sadržaj vlage u tlu izmjeren TDR senzorima tijekom razdoblja istraživanja na pet pozicija u redu i međurednom prostoru vinograda, te Ap i Bg horizontu. Iz tablice 4.20. vidljivo je kako je sadržaj vlage u tlu značajno različit ovisno o datumu, redu i međurednom prostoru te poziciji na obronku kao i njihovim interakcijama ($P < 0,0001$). Na sadržaj vlage u tlu jedini utjecaj nije imala interakcija datuma $\times$ reda/međureda za Bg horizont

Tablica 4.20. Prikaz statističkih podataka utjecaja datuma, reda/međureda, pozicije na obronku te njihovih interakcija na sadržaj vlage u tlu dobivenih temeljem linearnog modela

Efekt	Horizont	SS*	Zbroj kvadrata	Sadržaj vlage [cm ³ cm ⁻³]
D ^a	Ap	1	0,7381	< 0,0001
	Bg	1	0,1775	< 0,0001
R ^b	Ap	1	0,1261	< 0,0001
	Bg	1	1,6717	< 0,0001
P ^c	Ap	4	6,1356	< 0,0001
	Bg	4	30,6530	< 0,0001
D $\times$ R	Ap	1	0,0303	< 0,0001
	Bg	1	0,0017	0,1035
D $\times$ P	Ap	4	0,0413	< 0,0001
	Bg	4	0,0420	< 0,0001
R $\times$ P	Ap	4	2,6868	< 0,0001
	Bg	4	7,8344	< 0,0001
D $\times$ R $\times$ P	Ap	4	0,0295	< 0,0001
	Bg	4	0,0193	< 0,0001

^a Datum (26.4.2019. do 14.10. 2019. te od 1.1.2020. do 31.12.2020.)

^b Red / međured.

^c Pozicija na obronku (P1, P2, P3, P4, P5).

*SS- stupnjevi slobode; *Pr > F – stupanj signifikantnosti.

Istaknute vrijednosti označavaju statistički značajne razlike.

Tablica 4.21. prikazuje prosječne vrijednosti sadržaja vlage u tlu u redu i međurednom prostoru te u Ap i Bg horizontu, na svim istraživanim pozicijama (P1 – P5). Vrijednosti prikazane u tablici očitane su pomoći TDR senzora te predstavljaju prosjek cijelog istraživanog razdoblja (26.4.2019. do 14.10. 2019. te od 1.1.2020. do 31.12.2020.). Iz tablice je vidljivo kako je najveći prosječni sadržaj vlage zabilježen na P1 poziciji (međured) i to u Bg horizontu, dok je prosječno najmanji sadržaj vlage u tlu zabilježen na P4 poziciji (međured) u Ap horizontu. Za poziciju P2 (međured, Bg horizont) srednje vrijednosti sadržaja vlage nisu prikazane zbog problema sa TDR senzorom. U principu u Ap horizontu zabilježene su veće vrijednosti sadržaja vlage u tlu u redu u odnosu na međured, i to na svim pozicijama osim P1 pozicije. U

Bg horizontu veće vrijednosti sadržaja vlage u tlu zabilježene su u međuredu u odnosu na red osim na P4 poziciji gdje je situacija obrnuta.

Tablica 4.21. Prosječni sadržaj vlage u tlu tijekom istraživnog razdoblja pet na pozicija obronka u međuredu i redu vinograda te u površinskom (Ap) i potpovršinskom (Bg) horizontu

Horizont	M ^a / R ^b	Pozicija na obronku				
		Prosječne vrijednosti sadržaja vlage u tlu [cm ³ cm ⁻³]				
		P1	P2	P3	P4	P5
Ap	M	0,453	0,423	0,360	0,326	0,333
	R	0,387	0,427	0,389	0,399	0,341
Bg	M	0,526	*	0,458	0,410	0,352
	R	0,500	0,488	0,394	0,491	0,338

^a Međured

^b Red

* Vrijednosti sadržaja vlage izbačene su zbog vrlo visokih vrijednosti sadržaja vlage u tlu koje bi mogle biti povezane sa neispravnim TDR senzorom.

Tablicom 4.22. prikazane su *P* vrijednosti utjecaja interakcije reda/međureda i pozicije na obronku (P1 – P5) na sadržaj vlage u tlu tijekom istraživnog razdoblja. Iz tablice je vidljivo kako je signifikantan utjecaj interakcije statistički značajan za Ap i Bg horizonte na svim pozicijama ($P < 0,0001$). Jedina iznimka je Ap horizont na P2 poziciji za koji nije utvrđen utjecaj interakcije reda/međureda sa pozicijom na sadržaj vlage u tlu tijekom istraživnog razdoblja.

Tablica 4.22. Prikaz statističkih podataka utjecaja interakcije reda/međureda i pozicije na obronku na sadržaj vlage u tlu dobivenih temeljem linearnog modela

Efekt		Pr > F*					
	Horizont	SS*	P1	P2	P3	P4	P5
R ^a ×	Ap	5360	< 0,0001	0,089	< 0,0001	< 0,0001	< 0,0001
P ^b	Bg	5360	< 0,0001	< 0,0001	< 0,0001	< 0,0001	< 0,0001


^a Red / međured

^b Pozicija na pobronku (P1, P2, P3, P4, P5).

*SS- stupnjevi slobode; *Pr > F – stupanj signifikantnosti.


Istaknute vrijednosti označavaju statistički značajne razlike.

Slike 4.32. i 4.33. grafički prikazuju vremenski niz izmjerenih vrijednosti sadržaja vlage u tlu u redu i međuredu po horizontima



Slika 4.32. Grafički prikaz volumetrijskog sadržaja vlage tijekom razdoblja istraživanja u redu i međurednom prostoru vinograda za površinski (Ap) horizont.

Značajno veći sadržaj vlage u tlu za Ap horizont zabilježen je u redu u odnosu na međuredni prostor vinograda ($P < 0,0001$). Najveći sadržaj vlage u redu zabilježen je na poziciji P2, dok je najmanji zabilježen na P5 poziciji. U međurednom prostoru u Ap horizontu, najveći sadržaj vlage zabilježen je na P2 i P1 poziciji, a najmanji na poziciji P5. Iz slike 4.32. uočljivo je kako je veća varijabilnost sadržaja vlage u tlu zabilježena tijekom ljetnih u odnosu na zimske mjeseci.



Slika 4.33. Grafički prikaz volumetrijskog sadržaja vlage tijekom razdoblja istraživanja u redu i međurednom prostoru vinograda za potpovršinski (Bg) horizont.


* U Bg horizontu u međurednom prostoru, prikazane su vrijednosti volumetrijskog sadržaja vlage u tlu određenog temeljem gravimetrijske metode, zbog previsokih očitavanja sadržaja vlage u tlu putem TDR senzora.

Značajno veći sadržaj vlage u potpovršinskom (Bg) horizontu tijekom istraživanog razdoblja zabilježen je u međurednom odnosu na red vinograda ($P < 0,0001$). S obzirom na tehničke probleme sa TDR senzorom tijekom 2019. godine postavljenim na P2 poziciji (međured, Bg horizont) vrijednosti volumetrijskog sadržaja vlage prikazane su temeljem podataka dobivenih gravimetrijskom metodom.

Iz slika 4.32 i 4.33. vidljivo je kako su veće varijabilnosti u volumetrijskom sadržaju vlage u tlu zabilježene u Ap u odnosu na Bg horizont. Također, tijekom istraživanog razdoblja zabilježene su veće varijabilnosti sadržaja vlage u tlu u redu u odnosu na međuredni prostor.


U narednom poglavlju prikazan je sadržaj vlage u tlu tijekom istraživanog razdoblja odnosno od 26.4.2019. do 31.12.2020 po pozicijama obronka. Zbog tehničkih problema sa TDR senzorima i datalogerom tijekom razdoblja od 15.10.2019. do 31.12.2019. na grafikonima nisu prikazane očitane vrijednosti volumetrijskog sadržaja vode u tlu. Crvena i crna crtkana linija predstavljaju sadržaj vode kod – 0,33 bara odnosno kapaciteta tla za vodu u Ap i Bg horizontu, dok crvena i crna puna linija predstavljaju sadržaj vode kod – 15 bara odnosno točke venuća.

Slika 4.34. prikazuje dinamiku vlage za navedeno razdoblje na P1 poziciji. Iz slike je vidljivo kako biljka na raspolaganju tijekom cijelog razdoblja istraživanja nije patila od deficita vode (sadržaj vode u tlu izmjeren TDR sensorima nije padao ispod točke venuća u Ap i Bg horizontu). Suprotno tome, u Bg horizontu uočena je pojava prekomjerne saturacije tijekom dijela istraživanog razdoblja. Naime, u 2019. godini, tijekom 186 dana (26.4. 2019. – 14.10.2019. te od 11.10. – 29.10.2020.) u Bg horizontu zabilježena je pojava prekomjerne saturacije, odnosno količina vode u tlu premašila je vrijednosti kapaciteta tla za vodu. Isto tako, u površinskom horizontu (međured) također je, tijekom kraćeg razdoblja (16 dana) zabilježena prekomjerna saturacija. Međutim, važno je napomenuti kako prilikom prekomjerne saturacije sadržaj vode u tlu nije prelazila vrijednosti ukupnog poroziteta (P) (Tablica 4.14.).




Slika 4.34. Dinamika vlage u tlu na poziciji P1 u razdoblju od 24.4.2019. do 31.12.2020.

Slika 4.35. prikazuje volumetrijski sadržaj vode u tlu na poziciji P2 u razdoblju od 26.4.2019. do 31.12.2020. godine. Iz slike se vidi kako je tijekom istraživanog razdoblja veći sadržaj vlage zabilježen u redu u odnosu na međured. Volumetrijski sadržaj vlage u redu, u Ap i Bg horizontu tijekom istraživanog razdoblja kretao se unutar fiziološki aktivne vlage, dakle nije zabilježen ni deficit ni suficit u sadržaju biljci pristupačne vlage na navedenoj poziciji. Kako je već spomenuto u međurednom prostoru (u Bg horizontu) prikazane su vrijednosti sadržaja vlage u tlu utvrđene gravimetrijskom metodom. Vrijednosti očitane pomoću TDR senzora bile su previsoke (više od vrijednosti ukupnog poroziteta) što je ukazalo na neispravan senzor, zbog čega te vrijednosti nisu prikazane. Bez obzira na to, u međurednom prostoru nisu utvrđeni saturacijski uvjeti tijekom 2019. godine.



Slika 4.35. Dinamika vlage u tlu na poziciji P2 u razdoblju od 24.4.2019. do 31.12.2020.


Na slici 4.36. prikazana je dinamika volumetrijskog sadržaj vlage u tlu na P3 poziciji. U redu se sadržaj vlage u tlu tijekom cijelog razdoblja istraživanja kretao između kapaciteta tla za vodu i točke venuća, dakle nije zabilježen deficit i suficit sadržaja vode u tlu na navedenoj poziciji. U međurednom dijelu vinograda u Bg horizontu tijekom cijelog istraživanja (538 dana, odnosno od 26.4. – 14.10.2019. te od 1.1. – 31.12.2020.) količina vlage u tlu bila je iznad kapaciteta tla za vodu. S obzirom na to važno je napomenuti kako vrijednosti sadržaja vlage u tlu tijekom saturacijskih uvjeta nisu prelazile vrijednosti ukupnog poroziteta za navedenu poziciju (Tablica 4.14.). Ap horizont na P3 poziciji međurednom dijelu tijekom istraživanog razdoblja varirao je unutar raspona fiziološki aktivne vlage.



Slika 4.36. Dinamika vlage u tlu na poziciji P3 u razdoblju od 24.4.2019. do 31.12.2020.


Slika 4.37. prikazuje dinamiku vlage u tlu tijekom istraživanog razdoblja na P4 poziciji. Na slici je vidljivo kako je sadržaj vlage u redu u Bg horizontu tijekom 361 bio iznad kapaciteta tla za vodu, odnosno u tlu su prevladavali saturacijski uvjeti. Naime u razdobljima od 26.4. – 14.10.2019; 22.4. – 15.7.2020; 5. – 7.8.2020. i od 1. – 6.9.2020. te 28.9 – 31.12.2020. u tlu su prevladavali saturacijski uvjeti. Za razliku od saturacijskih uvjeta u Bg horizontu u redu sadržaj vlage u Ap horizontu kretao se u rasponu fiziološki aktivne vlage. Što se tiče međurednog

prostora tijekom istraživanog razdoblja sadržaj vlage u tlu kretao se između kapaciteta tla za vodu i točke venuća odnosno u rasponu fiziološki aktivne vlage.



Slika 4.37. Dinamika vlage u tlu na poziciji P4 u razdoblju od 24.4.2019. do 31.12.2020.

Dinamika vlage tijekom istraživanog razdoblja na P5 poziciji prikazan je slikom 4.38. U redu sadržaj vlage u tlu u Ap i Bg horizontu kretao se u rasponu od kapaciteta tla za vodu do točke venuća. Deficit i suficit u sadržaju vlage u tlu tijekom istraživanog razdoblja na P5 poziciji nije uočen ni u međuredu ni u redu kod oba horizonta.




Slika 4.38. Dinamika vlage u tlu na poziciji P4 u razdoblju od 24.4.2019. do 31.12.2020.

4.4. Simuliranje toka i retencije vode u tlu istraživanog obronka


4.4.1. Simuliranje toka i retencije vode – HYDRUS 1D

4.4.1.1. Hidraulički parametri procijenjeni pomoću HYPROP sustava


Za simuliranje retencije vode u tlu tijekom istraživanog razdoblja korišten je HYDRUS 1D softverski paket. U prvom koraku pri modeliranju, kao hidraulički parametri za simuliranje retencije vode korišteni su parametri dobiveni preko HYPROP sustava (Tablica 4.15.). Slike 4.39. do 4.41. prikazuju simulirane i izmjerene vrijednosti (TDR senzorima) volumetrijskog sadržaja vlage u tlu u razdoblju od 26.4. do 14.10.2019. godine. Kao ulazni parametri u HYDRUS 1D model uneseni su podaci dobiveni preko HYPROP i WP4C sustava. U postavkama modela odabrani su početni (vrijednosti volumetrijskog sadržaja vlage u tlu očitani sa TDR senzora na datum 26.4.2019.) te rubni uvjet, gornji – atmosferski rubni uvjet sa površinskim otjecanjem (eng. *atmospheric boundary condition with surface runoff*), te donji rubni uvjet: slobodna drenaža (eng. *free drainage*). Za svaki od profila postavljena je proraštenost tla korijenom koja odgovara rezultatima analize proraštenosti tla korijenom opisana u poglavlju „Materijali i metode“, te u poglavlju „Rezultati“. U grafičkom sučelju za svaki od profila postavljena je granica horizonata na način kako je utvrđeno terenskim opisom. Nakon pokretanja simulacije model je bio nestabilan, odnosno model nije na zadovoljavajući način opisivao mjerenja dobivena TDR senzorima što je vidljivo na slikama (4.39. – 4.41.).



Slika 4.39. HYDRUS 1D simulacije sa hidrauličkim parametrima iz HYPROP-a za poziciju P1. Slika gore – međured, slika dolje – red.



Slika 4.40. HYDRUS 1D simulacija sa hidrauličkim parametrima iz HYPROP-a za poziciju P3. Slika gore – međured, slika dolje – red.



Slika 4.41. HYDRUS 1D simulacije sa hidrauličkim parametrima iz HYPROP-a za poziciju P5. Slika gore – međured, slika dolje – red.

Iz slika 4.39. – 4.41. vidljivo je da za poziciju P1 model ne prati liniju senzora, odnosno rezultati modela se ne poklapaju s rezultatima volumetrijskog sadržaja vode u tlu izmjerenih TDR sensorima. Kod pozicije u međurednom dijelu vinograda model precjenjuje sadržaj vlage u Ap horizontu, dok u Bg horizontu podcjenjuje sadržaj vlage u tlu tijekom cijelog razdoblja simulacije. U redu vinograda model precjenjuje sadržaj vode u tlu u Bg horizontu, dok kod Ap horizonta simulirane vrijednosti relativno dobro opisuju vrijednosti dobivene TDR sensorima. Za poziciju P3 i P5 (slika 4.40. i 4.41.) model ne uspije konvergirati simulaciju za cijelo razdoblje te postaje nestabilan. Tablica 4.23. prikazuje iznose verifikacijskih mjera za simulacije sa hidrauličkim značajkama iz HYPROP – a.

Tablica 4.23. R^2 , MAE i RMSE za simulacije sa hidrauličkim značajkama iz HYPROP–a

Pozicija na obronku	Horizont	R^2	MAE	RMSE
P1 međured	Ap	0,177	0,039	0,044
	Bg	0,046	0,026	0,028
P1 red	Ap	0,415	0,018	0,023
	Bg	0,001	0,064	0,067
P3 međured	Ap	Zbog nestabilnosti modela nije moguće odrediti		
	Bg			
P3 red	Ap	Zbog nestabilnosti modela nije moguće odrediti		
	Bg			
P5 međured	Ap	Zbog nestabilnosti modela nije moguće odrediti		
	Bg			
P5 red	Ap	Zbog nestabilnosti modela nije moguće odrediti		
	Bg			


4.4.1.2. Simulacije sa hidrauličkim parametrima iz ROSETTA – softvera

Tablica 4.24. prikazuje hidrauličke parametre procijenjene pomoću „tipa pet“ pedotransfernih funkcija u ROSETTA softveru. Vrijednosti rezidualnog sadržaja vode u tlu θ_r kreću se u rasponu od 0,0726 cm³ cm⁻³ za P3 poziciju (međured, Bg horizont), pa do 0,1427 cm³ cm⁻³ za P1 poziciju (red, Bg horizont). Vrijednosti sadržaja vlage u tlu pri saturacijskim uvjetima kreću se od 0,4419 cm³ cm⁻³ za P3 poziciju (međured, Bg horizont) do 0,5713 cm³ cm⁻³ za P1 poziciju (red, Bg horizont). Vrijednosti parametara α kreću se od 0,0005 do 0,001. Vrijednosti n parametra kreću se u rasponu od 1,5987 na P1 (međured, Ap horizont) poziciji do 2,396 također na P1 poziciji u redu (Bg horizont). Vrijednosti hidrauličke propusnosti (K_s) kreću se u rasponu od 0,25 cm dan⁻¹ na P2 (red, Bg horizont), do 12,12 cm dan⁻¹ kod P1 (međured, Bg horizont) pozicije. Za poziciju P3 u međurednom dijelu vinograda zbog nestabilnosti modela hidraulički parametri nisu određeni.


Tablica 4.24. Hidraulički parametri iz ROSETTA – softvera korištenjem „tipa pet“ pedotransferne funkcije

Pozicija	Horizont	$\theta_r [cm^3 cm^{-3}]$	$\theta_s [cm^3 cm^{-3}]$	$\alpha [1/cm]$	$N [-1]$	$K_s [cm dan^{-1}]$	I
P1 međured	Ap	0,105	0,5349	0,0017	1,5987	6,62	0,5
	Bg	0,1298	0,568	0,001	2,0288	12,12	0,5
P1 red	Ap	0,1106	0,5299	0,0006	1,837	0,51	0,5
	Bg	0,1427	0,5713	0,0005	2,396	1,71	0,5
P2 međured	Ap	0,1005	0,5144	0,0012	1,6752	3,01	0,5
	Bg	0,1075	0,5634	0,0008	1,6105	1,41	0,5
P2 red	Ap	0,1016	0,5163	0,0012	1,6754	3,02	0,5
	Bg	0,115	0,5592	0,0004	1,7799	0,25	0,5
P3 međured	Ap	0,1049	0,5083	0,001	1,9064	4,21	0,5
	Bg	0,0726	0,4419	0,0021	1,6795	6,73	0,5
P3 red	Ap Bg	MODEL POKAZUJE NESTABILNOST (NE KONVERGIRA)					
P4 međured	Ap	0,0985	0,4921	0,0013	1,8603	6,62	0,5
	Bg	0,1053	0,4852	0,0004	2,1531	0,37	0,5
P4 red	Ap	0,1025	0,4914	0,001	1,9595	3,37	0,5
	Bg	0,1024	0,4922	0,0009	1,9189	1,95	0,5
P5 međured	Ap	0,1025	0,4914	0,001	1,9595	3,37	0,5
	Bg	0,1024	0,4922	0,0009	1,9189	1,95	0,5
P5 red	Ap	0,0812	0,4592	0,002	1,7501	11,32	0,5
	Bg	0,0964	0,4728	0,0009	1,9359	1,57	0,5


Slike 4.42. do 4.46. prikazuju simulirane i izmjerene vrijednosti volumetrijskog sadržaja vode u tlu sa hidrauličkim parametrima iz ROSETTA softvera. Simulirane vrijednosti ne pokazuju zadovoljavajuće trendove u odnosu na izmjerene vrijednosti sadržaja vlage u tlu pomoću TDR senzora. Kod pojedinih pozicija model ili precjenjuje, ili podcjenjuje izmjerene vrijednosti volumetrijskog sadržaja vode u tlu. Na poziciji P3 u redu model je pokazao izrazitu nestabilnost (ne konvergira) te iz tog razloga grafički nije prikazana simulacija na navedenoj poziciji. Iz slika 4.42., 4.43. i 4.46. koje predstavljaju simulacije za P1 i P2 i P5 poziciju uočava se da su simulacije bolje u redu u odnosu na međured vinograda, dok su za pozicije P3 i P4 (Slike 4.44. i 4.45.) bolje simulacije bile u međuredu u odnosu na red.




Slika 4.42. HYDRUS 1D simulacije sa hidrauličkim parametrima iz ROSETTA softvera za poziciju P1. Slika gore – međured, slika dolje – red.




Slika 4.43. HYDRUS 1D simulacije sa hidrauličkim parametrima iz ROSETTA softvera za poziciju P2. Slika gore – međured, slika dolje – red.



Slika 4.44. HYDRUS 1D simulacije sa hidrauličkim parametrima iz ROSETTA softvera za poziciju P3 u međuredu



Slika 4.45. HYDRUS 1D simulacije sa hidrauličkim parametrima iz ROSETTA softvera za poziciju P4. Slika gore – međured, slika dolje – red.



Slika 4.46. HYDRUS 1D simulacije sa hidrauličkim parametrima iz ROSETTA softvera za poziciju P5. Slika gore – međured, slika dolje – red.

Tablica 4.25. prikazuje iznose verifikacijskih mjera za simulacije sa hidrauličkim značajkama procijenjenim pomoću pedotransfer funkcija u ROSETTA softveru. Iz tablice je vidljivo kako vrijednosti R^2 variraju od 0,007 za P4 poziciju (red, Bg horizont) pa do 0,805 za P5 poziciju (red, Bg horizont). MAE vrijednosti kreću se u rasponu od 0,010 $\text{cm}^3 \text{cm}^{-3}$ kod P3 pozicije (međured, Bg) pa do 0,233 $\text{cm}^3 \text{cm}^{-3}$ na P1 poziciji (međured, Bg horizont). Vrijednosti RMSE – a kreću se u rasponu od 0,013 $\text{cm}^3 \text{cm}^{-3}$ na P3 poziciji (međured, Bg horizont) pa do 0,238 $\text{cm}^3 \text{cm}^{-3}$ na P1 poziciji (međured, Bg horizont). Vrijednosti verifikacijskih mjera za pozicije P2 i P3 u redu nije bilo moguće odrediti zbog nestabilnosti modela.

Tablica 4.25. R^2 , MAE i RMSE za simulacije sa hidrauličkim značajkama iz ROSETTA – e

Pozicija na obronku	Horizont	R^2	MAE	RMSE
P1 međured	Ap	0,307	0,170	0,172
	Bg	0,499	0,233	0,238
P1 red	Ap	0,450	0,024	0,030
	Bg	0,092	0,023	0,029
P2 međured	Ap	0,574	0,022	0,025
	Bg	0,050	0,169	0,171
P2 red	Ap	Zbog nestabilnosti modela nije moguće odrediti		
	Bg			


Pozicija na obronku	Horizont	R^2	MAE	RMSE
nastavak				
P3 međured	Ap	0,585	0,025	0,031
	Bg	0,133	0,010	0,013
P3 red	Ap	Simulacija pokazuje nestabilnost već na početku		
	Bg			
P4 međured	Ap	0,334	0,036	0,044
	Bg	0,327	0,059	0,059
P4 red	Ap	0,007	0,051	0,057
	Bg	0,168	0,120	0,125
P5 međured	Ap	0,345	0,064	0,066
	Bg	0,295	0,056	0,058
P5 red	Ap	0,442	0,080	0,087
	Bg	0,805	0,031	0,040

Zbog nestabilnosti modela i vizualno nezadovoljavajućih rezultata simulacija, pristupilo se inverznom modeliranju u HYDRUS 1D modelu na razdoblju kalibracije od 30 dana u kojem je utvrđeno podjednako trajanje suhih i vlažnih razdoblja (od 13.9. do 12.10.2019.).


4.4.1.2. Inveržno simuliranje

Nakon neuspješnog (ne zadovoljavajućeg) simuliranja retencije vode tijekom 2019. godine na temelju hidrauličkih parametara dobivenim HYPROP sustavom, pristupilo se inverznom modeliranju u HYDRUS 1D softveru. Naime, HYDRUS softverski paketi imaju ugrađen Marquardt–Levenbergov tip optimizacije parametra tako da gotovo svaka primjena koja se može pokrenuti u direktnom načinu (u slučaju kada su svi parametri, te početni i rubni uvjeti određeni) može biti uspješno pokrenuta i na inverzni način. Kao ulazni parametri za inveržno modeliranje korišteni su podaci o volumetrijskom sadržaju vode u tlu izmjereni TDR senzorima (za svaku poziciju P1 – P5, red/međured te površinski i potpovršinski horizont), klimatski parametri (oborine, temperature, brzina vjetra, relativna vlaga zraka, insolacija) tijekom razdoblja od 13.9. do 12.10.2019. godine. Nakon unosa navedenih parametara u grafičkom sučelju postavljeni su isti rubni uvjeti kao i kod korištenja hidrauličkih parametara iz HYPROP sustava. Na temelju izmjerenih vrijednosti volumetrijskog sadržaja vode u tlu i klimatskih parametara u programu se odredilo koje hidrauličke parametre želimo optimizirati (θ_s , α , n , K_s). Tijekom simulacija povećavan je broj iteracija sve dok se funkcija minimizacije nije prestala smanjivati. Slike 4.47. do 4.51. predstavljaju rezultate inverznog modeliranja za navedeno razdoblje od 30 dana za pet pozicija na obronku, red/međured te Ap i Bg horizonte. Crveni i crni kružići predstavljaju izmjerene vrijednosti volumetrijskog sadržaja vode u tlu, a crne i crvene linije predstavljaju rezultate inverzne simulacije. Općenito, iz slika je vidljivo kako simulacije jako dobro prate izmjerene vrijednosti volumetrijskog sadržaja vode u tlu pomoću


TDR senzora. Za sve pozicije R^2 iznosio je uglavnom iznad 0,90 izuzev P1 i P3 pozicije u redu kod kojih je R^2 iznosio, redom, $R^2 = 0,645$ i $R^2 = 0,882$. Vrijednosti $RMSE$ – a kod većine pozicija uglavnom su manje od $0,03 \text{ cm}^3 \text{ cm}^{-3}$, osim kod pozicije P1 u redu gdje je $RMSE$ iznosio $0,05 \text{ cm}^3 \text{ cm}^{-3}$.




Slika 4.47. Prikaz inverznog modeliranja za poziciju P1 u razdoblju od 13.9. do 12.10.2019. godine.




Slika 4.48. Prikaz inverznog modeliranja za poziciju P2 u razdoblju od 13.9. do 12.10.2019. godine. (zbog prevelikih vrijednosti sadržaja vlage očitanih TDR senzorom izbačene su vrijednosti za Bg horizont u međurednom prostoru).



Slika 4.49. Prikaz inverznog modeliranja za poziciju P3 u razdoblju od 13.9. do 12.10.2019. godine.



Slika 4.50. Prikaz inverznog modeliranja za poziciju P4 u razdoblju od 13.9. do 12.10.2019. godine.



Slika 4.51. Prikaz inverznog modeliranja za poziciju P5 u razdoblju od 13.9. do 12.10.2019. godine.

Vrijednosti R^2 dobivene inverznim modeliranjem u kalibracijskom periodu od mjesec dana (13.9. do 12.10.2019.) kretale su se od 0,645 na P1 poziciji u redu do 0,996 na P2 poziciji u međurednom prostoru vinograda. Vrijednosti $RMSE$ – a kretale su se u rasponu od 0,0072 $\text{cm}^3 \text{cm}^{-3}$ na P2 poziciji u međuredu, do 0,0548 $\text{cm}^3 \text{cm}^{-3}$ na P1 poziciji u redu. S obzirom na takve vrijednosti R^2 i $RMSE$ –a, vrijednosti hidrauličkih parametara koji su procijenjeni nakon inverznog simuliranja korišteni su dalje kao ulazni parametri za simulacije sadržaja vode tijekom cijelog razdoblja istraživanja, odnosno u razdoblju od 26.4. – 14.10. 2019. te od 1.1. – 31.12.2020. godine. Vrijednosti hidrauličkih parametara dobivenih nakon inverzne simulacije prikazani su u tablici 4.26. Iz tablice je vidljivo kako se vrijednosti rezidualnog sadržaja vode u tlu θ_r kreću u rasponu od 0,0726 $\text{cm}^3 \text{cm}^{-3}$ na P3 poziciji (međured, Bg horizont) do 0,1324 $\text{cm}^3 \text{cm}^{-3}$ na P poziciji (red, Bg horizont). Vrijednosti sadržaja vode u tlu pri saturacijskim uvjetima (θ_s) kreće se u rasponu od 0,335 $\text{cm}^3 \text{cm}^{-3}$ na P5 poziciji (red, Bg horizont) do 0,584 $\text{cm}^3 \text{cm}^{-3}$ na P1 poziciji (međured, Bg horizont). Vrijednosti α parametra kreću se u rasponu od 0,00018 na P4 poziciji (međured, Bg horizont), do 0,00318 na P3 poziciji (međured, Ap horizont). Vrijednosti n parametra kreću se u rasponu od 1,036 na P3 poziciji (međured, Bg horzont) do 6,214 na P1 poziciji (red, Ap horizont). Vrijednosti K_s – a kreću se u rasponu od minimalnih 0,0379 cm dan^{-1} na P1 poziciji (red, Ap horzont), do maksimalnih 80,167 cm dan^{-1} na poziciji P5 (red, Bg horizont).


Tablica 4.26. Hidraulički parametri dobiveni iz inverznog modela

Pozicija	Horizont	$\theta_r [cm^3 cm^{-3}]$	$\theta_s [cm^3 cm^{-3}]$	$\alpha [1/cm]$	$n [-1]$	$K_s [cm dan^{-1}]$	I
P1 međured	Ap	0,105	0,52485	0,0015877	1,4192	0,23915	0,5
	Bg	0,1298	0,58366	0,0012331	1,1467	4,6442	0,5
P1 red	Ap	0,1106	0,50008	0,000619	6,2138	0,037902	0,5
	Bg	0,1324	0,53301	0,000498	1,7869	3,0608	0,5
P2 međured	Ap	0,1005	0,52267	0,00078772	1,4095	3,4699	0,5
	Bg	Vrijednosti su izbačene zbog problema s TDR senzorom					
P2 red	Ap	0,1016	0,4827	0,001762	1,8761	0,17341	0,5
	Bg	0,115	0,50304	0,000774	1,13408	0,5855	0,5
P3 međured	Ap	0,1049	0,53944	0,0031856	1,4586	9,99773	0,5
	Bg	0,0726	0,46757	0,0014108	1,0306	10,139	0,5
P3 red	Ap	0,0969	0,45609	0,001761	1,3633	0,0405207	0,5
	Bg	0,0816	0,44241	0,001243	1,8016	0,12855	0,5
P4 međured	Ap	0,0985	0,37975	0,00090483	1,4055	25,383	0,5
	Bg	0,1053	0,40906	0,00018888	1,2049	1,0503	0,5
P4 red	Ap	0,1025	0,48553	0,00070676	2,0191	4,2231	0,5
	Bg	0,1024	0,54366	0,00042786	1,587	0,49549	0,5
P5 međured	Ap	0,0937	0,40188	0,001	2,4562	4,541	0,5
	Bg	0,0975	0,38005	0,001071	1,2605	5,2033	0,5
P5 red	Ap	0,0812	0,4083	0,001785	1,2689	80,167	0,5
	Bg	0,0964	0,33486	0,0010131	1,1	4,8964	0,5


4.4.1.3. HYDRUS 1D simulacije za 2019. i 2020. godinu temeljem hidrauličkih parametara iz inverznog modeliranja

U narednom dijelu prikazani su rezultati simulacije HYDRUS 1D modelom za razdoblje od 26.4.2019. do 14.10.2019. te od 1.1. do 31.12.2020. godine primjenom hidrauličkih parametara procijenjenim preko inverznog modeliranja (Tablica 4.26.). Simulacije su provedene odvojeno za razdoblje u 2019. i u 2020. godini. Kao i kod prvotnih simulacija (sa hidrauličkim parametrima iz HYPROP sustava) kao početni uvjeti za simulacije tijekom 2019. godine postavljene su vrijednosti očitane sa TDR uređaja na dan 26.4.2019. Kao rubni uvjeti domene postavljeni su gornji – atmosferski rubni uvjet sa površinskim otjecanjem (eng. *atmospheric boundary condition with surface runoff*) dok je za donji rubni uvjet slobodno procjeđivanje (eng. *free drainage*). Slike 4.52. do 4.56. prikazuju simulirane i izmjerene vrijednosti sadržaja vlage u tlu tijekom razdoblja 26.4. do 14.10. 2019. godine, odnosno u razdoblju od ukupno 172 dana. Iz slika je vidljivo kako model jako dobro prati vrijednosti volumetrijskog sadržaja vode u tlu


izmjerene pomoću TDR senzora. Veće oscilacije u sadržaju vode u tlu tijekom istraživanog (i simuliranog) razdoblja uočene su za površinski u odnosu na potpovršinski horizont.




Slika 4.52. Prikaz izmjerenih i simuliranih vrijednosti sadržaj vlage u tlu tijekom 2019. godine na poziciji P1. Slika gore – međured, slika dolje – red.




Slika 4.53. Prikaz izmjerenih i simuliranih vrijednosti sadržaj vlage u tlu tijekom 2019. godine na poziciji P2. Slika gore – međured, slika dolje – red. *HYDRUS simulacija za međured, Bg horizont nije provedena zbog prevelikih vrijednosti očitanih TDR senzorom



Slika 4.54. Prikaz izmjerenih i simuliranih vrijednosti sadržaj vlage u tlu tijekom 2019. godine na poziciji P3. Slika gore – međured, slika dolje – red.



Slika 4.55. Prikaz izmjerenih i simuliranih vrijednosti sadržaja vlage u tlu tijekom 2019. godine na poziciji P4. Slika gore – međured, slika dolje – red.



Slika 4.56. Prikaz izmjerenih i simuliranih vrijednosti sadržaj vlage u tlu tijekom 2019. godine na poziciji P5. Slika gore – međured, slika dolje – red.


U tablici 4.27. prikazane su vrijednosti verifikacijskih mjera za 2019. godinu za simulacije sa hidrauličkim značajkama procijenjene pomoću inverznog modeliranja. Iz tablice je vidljivo kako se vrijednosti R^2 kreću u rasponu od 0,009 za P4 (red, Bg horizont) poziciju, do 0,682 za P3 (red, Bg horizont) poziciju. MAE vrijednosti kreću se u rasponu su od 0,003 $\text{cm}^3 \text{cm}^{-3}$ kod P5 (međured, Bg horizont) pozicije, do 0,035 $\text{cm}^3 \text{cm}^{-3}$ kod P2 (međured, Bg horizont) pozicije. Vrijednosti RMSE – a u rasponu su od 0,004 $\text{cm}^3 \text{cm}^{-3}$ na P5 (međured, Bg horizont) poziciji, do 0,084 $\text{cm}^3 \text{cm}^{-3}$ na P2 (međured, Bg horizont) poziciji.

Tablica 4.27. R^2 , MAE i RMSE za simulacije sa hidrauličkim značajkama nakon inverznog modeliranja (2019. godina)


Pozicija na obronku	Horizont	R^2	MAE	RMSE
P1 međured	Ap	0,480	0,022	0,043
	Bg	0,150	0,015	0,044
P1 red	Ap	0,462	0,023	0,030
	Bg	0,198	0,015	0,018
P2 međured	Ap	0,560	0,012	0,015
	Bg	0,053	0,035	0,084
P2 red	Ap	0,633	0,017	0,020
	Bg	Nije određivano		
P3 međured	Ap	0,585	0,025	0,031
	Bg	0,133	0,010	0,013

Pozicija na obronku	Horizont	R^2	MAE	RMSE
nastavak				
P3 red	Ap	0,068	0,010	0,014
	Bg	0,682	0,010	0,011
P4 međured	Ap	0,560	0,011	0,014
	Bg	0,064	0,006	0,008
P4 red	Ap	0,128	0,020	0,027
	Bg	0,009	0,014	0,017
P5 međured	Ap	0,533	0,011	0,015
	Bg	0,627	0,003	0,004
P5 red	Ap	0,484	0,014	0,017
	Bg	0,379	0,017	0,020


Slike 4.57. do 4.61. prikazuju simulirane i izmjerene vrijednosti volumetrijskog sadržaja vode u tlu na P1 – P5 pozicijama tijekom 2020 godine. Iz slika je vidljivo kako model relativno dobro opisuje vrijednosti volumetrijskog sadržaja vode u tlu izmjenjenog TDR senzorima, međutim u određenom dijelu godine dolazi do pomaka (precjenjivanje ili podcjenjivanje sadržaja vlage) simuliranih vrijednosti u odnosu na vrijednosti izmjerene TDR senzorima. Veće su oscilacije sadržaja vode u tlu (i izmjerene i simulirane vrijednosti) u površinskom (Ap) u odnosu na potpovršinski (Bg) horizont.




Slika 4.57. Prikaz izmjerenih i simuliranih vrijednosti sadržaj vlage u tlu tijekom 2020. godine na poziciji P1. Slika gore – međured, slika dolje – red.




Slika 4.58. Prikaz izmjerenih i simuliranih vrijednosti sadržaj vlage u tlu tijekom 2020. godine na poziciji P2. Slika gore – međured, slika dolje – red. *HYDRUS simulacija za međured, Bg horizont nije provedena zbog prevelikih vrijednosti očitanih TDR senzorom



Slika 4.59. Prikaz izmjerenih i simuliranih vrijednosti sadržaj vlage u tlu tijekom 2020. godine na poziciji P3. Slika gore – međured, slika dolje – red.



Slika 4.60. Prikaz izmjenjenih i simuliranih vrijednosti sadržaj vlage u tlu tijekom 2020. godine na poziciji P4. Slika gore – međured, slika dolje – red.



Slika 4.61. Prikaz izmjenjenih i simuliranih vrijednosti sadržaj vlage u tlu tijekom 2020. godine na poziciji P5. Slika gore – međured, slika dolje – red.


Tablica 4.28. prikazuje iznose verifikacijskih mjera za 2020. godinu za simulacije sa hidrauličkim značajkama procijenjene pomoću inverznog modeliranja. Iz tablice je vidljivo kako se vrijednosti R^2 kreću u rasponu od 0,027 za P1 poziciju u redu (Bg horizont), do 0,582 na P5 poziciji u redu (Ap horizont). Vrijednosti $RMSE$ -a kreću se u rasponu od 0,010 na poziciji P3 u međuredu (Bg horizont) do 0,072 na istoj poziciji u redu u Bg horizontu. Iz tablice se vidi kako su vrijednosti $RMSE$ -a bolji pokazatelj uspješnosti modela u odnosu na R^2 .

Tablica 4.28. R^2 , MAE i $RMSE$ za simulacije sa hidrauličkim značajkama nakon inverznog modeliranja (2020. godina)

Pozicija na obronku	Horizont	R^2	MAE	$RMSE$
P1 međured	Ap	0,122	0,026	0,031
	Bg	0,336	0,035	0,036
P1 red	Ap	0,069	0,042	0,052
	Bg	0,027	0,066	0,070
P2 međured	Ap	0,364	0,028	0,031
	Bg	Nije određivano		
P2 red	Ap	0,206	0,031	0,039
	Bg	0,389	0,016	0,018
P3 međured	Ap	0,289	0,045	0,052
	Bg	0,028	0,009	0,010
P3 red	Ap	0,469	0,013	0,019
	Bg	0,048	0,064	0,072
P4 međured	Ap	0,535	0,027	0,032
	Bg	0,119	0,014	0,017
P4 red	Ap	0,446	0,046	0,052
	Bg	0,286	0,022	0,025
P5 međured	Ap	0,237	0,039	0,049
	Bg	0,053	0,015	0,017
P5 red	Ap	0,582	0,024	0,027
	Bg	0,127	0,026	0,029


4.4.2. Simulacije toka vode – HYDRUS 2D/3D

Nakon uspješne kalibracije i validacije HYDRUS 1D modela, simuliran je tok i retencija vode na cijelom obronku pomoću HYDRUS 2D modela tijekom cijelog razdoblja istraživanja neprekidno, dakle od 26.4.2019. do 31.12.2020 godine, u ukupnom trajanju od 538 dana. Posebno je simuliran tok i retencija vode u tlu u redu, a posebno u međurednom prostoru vinograda. Za simulacije su korišteni hidraulički parametri procijenjeni iz inverznih simulacija (Tablica 4.26.). Točke opažanja prilikom simulacije postavljene su na vrhu i na dnu obronka. Simulacije volumetrijskog sadržaja vode u tlu na vrhu i na dnu padine prikazane su slikom 4.62. Iz slike je vidljivo kako je volumetrijski sadržaj vode u tlu tijekom istraživanog razdoblja veći na vrhu u odnosu na dno obronka, što se poklapa i sa simulacijama u HYDRUS 1D modelu te podacima izmjerenih pomoću TDR senzora. Vidljivo je također, kako sadržaj vode u tlu više oscilira u površinskom u odnosu na potpovršinski horizont. Najveće oscilacije sadržaja vode u tlu tijekom istraživanog razdoblja uočene su na dnu obronka u redu vinograda.




Slika 4.62. Simulirane vrijednosti volumetrijske količine vode u tlu ($\text{cm}^3 \text{cm}^{-3}$) pomoću HYDRUS 2D modela za vrh i dno obronka u redu i međuredu za razdoblje 26.04.2019. do 31.12.2020.

Osim volumetrijskog sadržaja vode u tlu, HYDRUS 2D modelom simuliran je i vodni potencijal tla tijekom istraživanog razdoblja (Slika 4.63.). Simulacije vodnog potencijala tla, također su odrađene za vrh i dno obronka te u redu i međurednom prostoru vinograda. Iz slike je vidljivo kako se vodni potencijal tijekom istraživanog razdoblja kreće između – 20 pa sve do – 500 cm. Vodni potencijal između reda i međureda na vrhu i na dnu obronka relativno jednako oscilira, međutim ako se uspoređuju oscilacije u vodnom potencijalu tla između vrha i dna obronka, onda su veće oscilacije uočene na dnu u odnosu na vrh obronka.




Slika 4.63. Simulirane vrijednosti vodnog potencijala tla (cm) pomoću HYDRUS 2D programa za vrh i dno obronka u redu i međuredu za razdoblje 26.04.2019. do 31.12.2020.

Slika 4.64. prikazuje simulirane vrijednosti infiltracije, površinskog otjecanja i isteka vode na dnu obronka tijekom cijelog razdoblja istraživanja 26.04.2019. do 31.12.2020. Iz slike je vidljivo kako su na dnu obronka veće vrijednosti infiltracije zabilježene u međuredu u odnosu na red vinograda. Također, veće vrijednosti isteka zabilježene su u međuredu u odnosu na red, dok su veće vrijednosti površinskog otjecanja zabilježene su u redu u odnosu na međuredni prostor vinograda.




Slika 4.64. Simulirane vrijednosti infiltracije, površinskog otjecanja i isteka vode na dnu obronka (cm) pomoću HYDRUS 2D programa u redu i međuredu za razdoblje 26.04.2019. do 31.12.2020.

Slika 4.65. prikazuje simulacije u HYDRUS 2D modelu za jedan suhi i jedan vlažni period istraživanja u redu vinograda. Za suhi period odabran je 26.10.2019. iz razloga što pet dana prije navedenog datuma nije bilo oborina. Za simulaciju u vlažnom periodu izabran je 31.12.2020. iz razloga što je u razdoblju od pet dana prije navedenog datuma palo preko 45 mm oborina. Iz slike je vidljivo kako su najveće količine vlage u tlu u suhom periodu zabilježene na P1 poziciji, dok su najmanje vrijednosti zabilježene na P3 i P5. Potpovršinski horizonti P2 i P4 pozicije također pokazuju veće vrijednosti sadržaja vlage u tlu u odnosu na P5 i P3 poziciju. Tijekom vlažnog perioda najmanja količina vlage u tlu zabilježena je na P5 i P3 poziciji. P1, P2 i P4 pozicije u površinskom i potpovršinskom horizontu imale su podjednaku količinu vlage, međutim najveće vrijednosti sadržaja vlage u tlu zabilježene su na poziciji P1.



Slika 4.65. Simulirane vrijednosti količine vode u tlu ($\text{cm}^3 \text{cm}^{-3}$) pomoću HYDRUS 2D programa u redu vinograda za suhi (26.10.2019.) i vlažni (31.12.2020.) period. Suhi period: 5 dana bez oborina prije prikaza. Vlažni period: 45,21 mm oborina u 5 dana prije prikaza.


Slika 4.66. prikazuje simulacije u HYDRUS 2D modelu za jedan suhi i jedan vlažni period istraživanja u međurednom prostoru vinograda. U suhom periodu najveća količina vlage zabilježena je na P2 poziciji u Bg horizontu, a najmanja na P5 poziciji cijelom dubinom profila. Ista je situacija i u vlažnom periodu, gdje je najveća količina vlage u tlu zabilježena u na P2 poziciji u Bg horizontu. Prema dnu obronka (pozicije P4 i P5) sadržaj vlage u tlu se smanjuje.



Slika 4.66. Simulirane vrijednosti količine vode u tlu ($\text{cm}^3 \text{cm}^{-3}$) pomoću HYDRUS 2D programa u međuredu vinograda za suhi (26.10.2019.) i vlažni (31.12.2020.) period. Suhi period: 5 dana bez oborina prije prikaza. Vlažni period: 45,21 mm oborina u 5 dana prije prikaza.


Nakon uspješnog simuliranja retencije vode na istraživanom obronku HYDRUS 2D modelom, izabrana (izrađena) su tri klimatska scenarija temeljem IPCC – a (2014.). Simulirana su tri scenarija za razdoblje od 2081. do 2100. godine. Za to razdoblje IPCC predviđa da će temperatura zraka narasti za $1,5^\circ\text{C}$ do $3,5^\circ\text{C}$, količina oborina u nekim područjima će rasti, dok će u nekima padati. Raspored oborina tijekom godine također će se promijeniti. S obzirom na to uzeta su tri klimatska scenarija – blagi koji predviđa porast temperature od $1,5^\circ\text{C}$, srednji klimatski scenarij predstavlja porast temperature za $2,5^\circ\text{C}$, te ekstremni koji predviđa porast temperature za $3,5^\circ\text{C}$. Količina oborina će se u zimskim mjesecima povećati, dok će tijekom ljeta prevladavati dulji periodi suše, s učestalijom pojavom ekstremnih oborina. Za simulacije sadržaja vlage u tlu uzeta su tri navedena klimatska scenarija, čiji su rezultati simulacije prikazani na slikama 4.67. do 4.69. Na slikama je uočljivo kako nema velikih razlika u vodnom potencijalu tla tijekom različitih klimatskih scenarija. Prognozirani iznosi vodnog potencijala tla kod blagog klimatskog scenarija različiti su ovisno o pozicijama na obronku te s obzirom na red i međuredni prostor vinograda. Tako je iz slike 4.67. vidljivo kako će se prognozirani (predviđeni) iznos vodnog potencijala tla u redu (za blagi klimatski scenarij) kretati između - 11 do - 100 cm na P2 poziciji, dok će se na P4 i P5 poziciji iznos vodnog potencijala kretati u

rasponu od - 100 do - 200 cm. Prognozirani iznos vrijednosti vodnog potencijala za međured vinograda kreće se u rasponu od - 36 do - 80 cm na P1 te od - 160 do - 240 cm na P3 poziciji.




Slika 4.67. Simulirane vrijednosti vodnog potencijala tla (cm) na dan 31.12. 2020. (završni dan simulacija, gore), za blagi klimatski scenarij prema IPCC za red i međured obronka. Simulirane vrijednosti infiltracije, površinskog otjecanja i isteka vode (cm) na dnu obronka pomoću HYDRUS 2D programa u redu i međuredu za razdoblje tijekom 2020. godine prema IPCC blagom scenariju.

Prognozirani iznosi vodnog potencijala u srednjem klimatskom scenariju za razdoblje od 2081. do 2100. prikazani su slikom 4.68. Tako se iznos vodnog potencijala u redu kreće od - 5 do -100 cm na P1, P2 i P3 poziciji, dok se iznos potencijala na P4 i P5 poziciji kreće u rasponu od - 110 do - 220 cm. U međurednom prostoru iznos vodnog potencijala kreće se od - 30 do - 160 cm na P1, P2 i P4 poziciji pa do - 160 do - 240 cm na P3 poziciji.



Slika 4.68. Simulirane vrijednosti vodnog potencijala tla (cm) na dan 31.12. 2020. (završni dan simulacija, gore), za srednji klimatski scenarij prema IPCC za red i međured padine. Simulirane vrijednosti infiltracije, površinskog otjecanja i isteka vode na dnu padine (cm) pomoću HYDRUS 2D programa u redu i međuredu za razdoblje tijekom 2020. godine prema IPCC srednjem scenariju.

Prognozirani iznosi vodnog potencijala u ekstremnom klimatskom scenariju za razdoblje od 2081. do 2100. prikazani su slikom 4.69. Tako se iznos vodnog potencijala u redu kreće od - 7 do -120 cm na P1, P2 i P3 poziciji, dok se iznos potencijala na P4 i P5 poziciji kreće u rasponu od - 120 do - 240 cm. U međurednom prostoru iznos vodnog potencijala kreće se od - 33 do - 160 cm na P1, P2 pozicijama. Na P3 poziciji prognozirani iznos vodnog potencijala tla kreće se od - 160 do - 240 cm, a na P4 i P5 poziciji u rasponu od - 80 do - 240 cm.



Slika 4.69. Simulirane vrijednosti vodnog potencijala tla (cm) na dan 31.12. 2020. (završni dan simulacija, gore), za ekstremni klimatski scenarij prema IPCC za red i međured padine. Simulirane vrijednosti infiltracije, površinskog otjecanja i isteka vode na dnu padine (cm) pomoću HYDRUS 2D programa u redu i međuredu za razdoblje tijekom 2020. godine prema IPCC ekstremnom scenariju.

5. RASPRAVA

5.1. Svojstva tla na istraživanom obronku

5.1.1. Preliminarna istraživanja

Koeficijenti varijacije (CV) za preliminarna istraživanja većine svojstava tla (sadržaj praha, gline i pH) po izohipsama ne prelaze 2,00 (Tablica 4.1. i 4.2.). Izuzetak je sadržaj pijeska i humusa za koji je utvrđen nešto veći koeficijent korelacije međutim on ne prelazi vrijednost 10. Nešto viši korelacijski koeficijent sadržaja pijeska u odnosu na ostala svojstva tla, mogao bi biti povezan sa pripremom uzorka tla prilikom laboratorijskih analiza. S obzirom na relativno mali sadržaj pijeska u istraživanim uzorcima (uglavnom ispod 12 %), u odnosu na ostale frakcije moguće je da je zbog nedovoljne homogenizacije samog uzorka prilikom laboratorijskih analiza zahvaćen dio uzorka koji je sadržavao nereprezentativni udio pijeska, što je u konačnici rezultirao takvim koeficijentima varijacije. Bez obzira na to, može se zaključiti kako je heterogenost svojstava tla po izohipsama dovoljno mala da omogući generalizaciju rezultata analiza iz iskopanih pedoloških profila na šire područje istraživanog obronka. Takvi rezultati preliminarnih istraživanja logični su s obzirom na to da se procesi na obronačnim reljefnim formama (npr. erozija, površinsko otjecanje) dominantno odvijaju okomito (niz obronak), a ne duž izohipsi. Dakle, lijevo i desno po istraživanom obronku (na istoj izohipsi) razlike u svojstvima tla su zanemarive, dok je razlika u svojstvima tla uočena ovisno o poziciji tla na obronku unutar iste toposekvence. Jenny (1980.) navodi kako su razlike u svojstvima tla duž toposekvence nastale prvenstveno pod utjecajem reljefa (npr. utjecaj gravitacije). Činjenica da se u istraživanjima tla obronka različiti tretmani i ponavljanja obavljaju u više toposekvenci, govori u prilog tome da je zanemariva heterogenost svojstava tla po izohipsama logična.

5.1.2. Građa profila, morfološka svojstva tla i proraštenost korijenom

Svaki od istraživanih profila na pet odabranih pozicija obronka imali su građu Ap-Bg-Cg koja u principu odgovara građi antropogeniziranog pseudogleja. Tipična građa prirodnog profila pseudogleja označava se kao A-Eg-Bg-C (WRB, 2014., Škorić, 1986.), odnosno prema Klasifikaciji tala Hrvatske kao A-E/S-B/S-C (Husnjak, 2014.). Prije podizanja nasada vinograda na istraživanoj parceli (obronku) provedena je duboka obrada (rigoliranje) do dubine od otprilike 50 cm čime je narušen prirodni profil pseudogleja. Dubokom obradom došlo je do miješanja humusno akumulativnog, eluvijalno pseudoglejnog te gornjeg dijela iluvijalno – pseudoglejnog horizonta čime je stvoren „novi“ antropogeni horizont. Dakle, novo stvoreni antropogeni (Ap) horizont „poprimio“ je svojstva eluvijalno/iluvijalno – pseudoglejnog horizonta. Građa takvog pseudogleja označava se kao Ap-Bg-Cg (FAO, 2014), ili P-B/S-C/S (Husnjak, 2014.). Tako je,

nakon duboke obrade, građa profila karakteristična za prirodni profil pseudogleja bila manje izražena. Schneider i sur. (2017.) navode kako duboka obrada tla remeti zahvaćene horizonte, narušava njihova izvorna svojstva stvarajući novi (dublji) homogeni sloj. Husnjak (2014.) navodi kako uslijed duboke obrade tla, ali i kalcifikacije te gnojidbe dolazi do prekida prirodne evolucije izvornog pseudogleja, a P horizont dobiva tehnički karakter i značajno izmijenjena svojstva u odnosu na genetske horizonte iz kojih je nastao.

Temeljem terenskog opisa profila na terenu utvrđena je granularna do subangularna blokna struktura u površinskom dijelu (Ap) horizonta (do otprilike 30 – ak cm dubine). U površinskom dijelu Ap horizonta (zona rizosfere travne vegetacije, do dubine od oko 10 cm) dominira granularna struktura. S povećanjem dubine u Ap horizontu (> 10 cm pa do otprilike 30 - ak cm) prevladava subangularna blokna struktura koja je ujedno i karakteristična struktura tla za površinske horizonte. Subangularnu strukturu karakteriziraju zaobljeni agregati nastali uslijed stalnog miješanja tla i utjecaja korijena. U dubljim slojevima Ap horizonta (otprilike 30 – 60 cm) dominantno je utvrđena angularna struktura koja postepeno prelazi u masivnu/koherentnu. Na P3 poziciji obronka masivna struktura zabilježena je već na dubini od 60 cm. Ista struktura na ostalim pozicijama uočena je na dubinama većim od 80-85 cm. Ovakva struktura na P3 poziciji vjerojatno je rezultat povećane vlažnosti tla na toj poziciji. U slučaju da je struktura tla određivana pri manjem stupnju vlažnosti, odnosno u suhom stanju vjerojatno bi bila okarakterizirana kao angularna blokna.

Boja površinskih horizonata istraživanih profila tla kretala se od svjetlo žućkasto smeđe za P1 i P3 poziciju, blijedo žute za P4 i P5 te svjetlo smeđe sivkaste za P2 poziciju (*hue* 2.5 Y). Boja potpovršinskih horizonata bila je smeđe žuta za P1, P2 i P3 poziciju (*hue* 10 YR) i svjetlo smeđe siva za P4 i P5 poziciju (*hue* 2.5 Y). Na svim istraživanim profilima, u površinskom i u potpovršinskom horizontu uočene su redoksimorfne značajke. Od redoksimorfnihi značajki redoks deplecija ima više u odnosu na redoks koncentracije. Deplecije su, također, više izraženije u potpovršinskom u odnosu na površinski horizont. U prirodnim profilima u humusno akumulativnim horizontima redoksimorfna obilježja često nisu uočljiva golim okom zbog visokog udjela organske tvari koja bojom na neki način prikriva (zamaskira) takva obilježja tla (Vepraskas i Williams, 1995.). S obzirom da su u istraživanim profilima uočena redoksimorfna svojstva i u površinskom horizontu to može biti rezultat miješanja horizonata tla uslijed duboke obrade i smanjenog sadržaja organske tvari koja bi utjecala na prikrivanje navedenih svojstava. Veća zastupljenost redoks deplecija u potpovršinskom horizontu u odnosu na površinski u skladu je s navodima Vepraskasa i Williamsa (1995.). Naime, do formiranja većih deplecija (> 2 mm) dolazi oko stabilnih makropora. Takve makropore javljaju se u horizontima sa malo bioturbacije (npr. potpovršinski Bg horizont) u kojem prevladavaju agregati veći od 3 cm (Vepraskas i Williams 1995.). S obzirom da površinski (Ap) horizont ima manje agregate,

veći sadržaj organske tvari te izraženiju bioturbaciju u odnosu na potpovršinski (Bg) horizont, redoks deplecije su manje izražene.

Na poziciji P3 uočena je najveća zastupljenost redoks koncentracija prvenstveno prevlaka pora (eng. *pore linings*), u odnosu na ostale pozicije u potpovršinskom horizontu (Prilozi, Slika 8.2.). Navedeno bi se moglo objasniti činjenicom kako su na P3 poziciji gotovo tijekom čitavog istraživanog razdoblja prevladavali saturacijski uvjeti. Prema Vepraskasu i Williamsu (1995.) prevlake pora javljaju se u saturacijskim uvjetima oko korijena kada biljka transportira kisik iz lista u korijen čime se stvaraju oksidacijski uvjeti potrebni za formiranje redoks koncentracija. Izraženije redoksimorfne značajke (posebice redoks deplecije) na višim pozicijama obronka (P1, P2 i P3) u odnosu na niže pozicije (P4 i P5), mogu se povezati sa činjenicom da je tijekom istraživanog razdoblja više pozicije obronka (tj. P1 i P2) bile vlažnije.

Površinski dijelovi Ap horizonta (0 -15 cm) svih istraživanih profila (P1 – P5) bili su izrazito prokorijenjeni. Veći broj sitnijeg korijenja u površinskih 0–15 (20) cm utvrđen je u međurednom prostoru u odnosu na prostor u redu. Navedeno je u skladu s istraživanjima Celettea i sur. (2008.) koji navode kako korijenov sustav trava doseže najveću gustoću na dubini od 15 cm i brzo se smanjuje prema dubljim slojevima tla. Općenito, veća zastupljenost korijena promjera većeg od 5 mm u redu u odnosu na međured logična je s obzirom da vinova loza razvija korijenje većeg promjera u odnosu na korijen zeljastih kultura (trave). U međurednom prostoru u površinskih 20 cm tla zabilježeno je prosječno 40–50 % ukupnog korijena, dok je do dubine od 40 cm zabilježeno 65-80 % ukupnog broja korijena. Općenito, bez obzira na promjer korijena, veći broj korijenja zabilježen je u redu u odnosu na međuredni prostor vinograda. Navedeno se može objasniti činjenicom kako je i u redu vinograda (bez obzira na tretman herbicidima) uočena znatna zakorovljenost. U redu vinograda do dubine od 20 cm zastupljenost korijena kreće se od 40–50 %, dok se do dubine od 40 cm zastupljenost korijena od 60–70 %. Do dubine od 80 cm zabilježeno je 95 % razvijenosti korijena. Navedeni rezultati djelomično se poklapaju s rezultatima istraživanja Smarta i sur. (2006.) koji navode kako se oko 80% volumena korijena vinove loze razvija do dubine od 90 cm. Međutim rasprostranjenost korijena vinove loze u tlu ovisi u prvom redu o podlozi vinove loze, te svojstvima tla.

Dubina površinskog Ap horizonta kretala se od 0 – 55 cm na gornjoj (P1), pa sve do 0 – 88 cm na donjoj (P5) poziciji obronka. S obzirom na različitu dubinu površinskog (Ap) horizonta duž istraživanog obronka, evidentna je prisutnost erozijskih procesa. Naime erozijom zahvaćeni zemljišni materijal premješta se s viših pozicija obronka i nakuplja na nižim reljefnim pozicijama, što za posljedicu ima smanjivanje dubine horizonta na višim te povećanje dubine horizonta na nižim reljefnim pozicijama (Mulugeta i Sheleme, 2010., Ziadat i sur., 2010.).

Razlika u debljini površinskog Ap horizonta od gotovo 33 cm (od vrha do dna obronka) izuzetno je velika. Iz navedenog se može zaključiti kako su procesi erozije izraženi na gornjim dijelovima obronka, dok su prema dnu obronka izraženi procesi taloženja erodiranog materijala. Brojni autori navode kako su stope gubitka tla erozijom i količina površinskog otjecanja najveći u vinogradima (Biddoccu i sur., 2016., Rodrigo – Comino i sur., 2017b.) te da do toga dolazi uslijed nedostatka lisne mase tijekom kasno – jesenskog, zimskog i rano - proljetnog perioda što omogućuje direktan utjecaj kišnih kapi na pojavu erozijskih procesa. Intenzivna, plitka obrada tla koja se provodi u međurednim prostorima, obično se provodi u jesen u kombinaciji sa inkorporacijom mineralnih gnojiva u tlo, (Rodrigo–Comino i sur., 2017a., Bogunović i sur., 2017.) te primjena herbicida (García-Díaz i sur., 2017.) također imaju značajan utjecaj na intenziviranje erozijskih procesa na obronačnim vinogradarskim područjima. Rodrigo – Comino i sur. (2017b.) navode kako je erozija tla u vinogradima bila najveća tijekom godina neposredno nakon sadnje vinove loze te da se njen intenzitet smanjivao s vegetativnim porastom vinove loze. Naime, kako vinova loza raste tako svojim nadzemnim dijelom prekiva sve veću površinu tla, a sve razvijeniji korijenov sustav konzervira tlo i umanjuje eroziju. U klimatskim podnebljima koja imaju dovoljno oborina tijekom vegetacije, međuredni prostori obično su zatravljeni, što pozivno utječe na ublažavanje erozijskih procesa. S obzirom da je istraživani obronak pod vinogradom trenutno zatravljen za pretpostaviti je da su se erozijski procesi odvijali u prošlosti, te da su s obzirom na trenutni način gospodarenja tlom u vinogradu ti procesi usporeni. Osim što erozijski procesi utječu na debljinu površinskog horizonta, oni utječu i na varijaciju u svojstvima tla na istraživanom obronku.

5.1.3. Fizikalna svojstva profila

Rezultati analize teksture tla ukazuju na činjenicu da postoje značajne razlike u sadržaju pojedinih čestica tla prema položaju na obronku. Tekstura tla istraživanih profila u površinskom i u potpovršinskom horizontu mogla bi se označiti kao praškasto ilovasta (P5) do praškasto glinasto ilovasta (P1, P2, te Ap horizont P3 profila). Jedino na P3 poziciji u potpovršinskom horizontu tekstura tla označava se kao ilovasta. Navedeno je karakteristično za tipičan teksturni sastav tla prirodnog pseudogleja.

Sadržaj pijeska signifikantno se razlikuje s obzirom na poziciju obronka, pri čemu je značajno veći sadržaj pijeska zabilježen na sredini obronka (P3 pozicija). Međutim, na ostalim istraživanim pozicijama (P1, P2, P4 i P5) u Ap i Bg horizontu, sadržaj pijeska ne prelazi 15%. Istraživani profili imaju nešto veći sadržaj pijeska u odnosu na tipični pseudoglej, međutim oni se mogu povezati s matičnim supstratom koji kao i les može sadržavati i preko 11 % pijeska Husnjak (2014.). Povećan sadržaj pijesak na P3 poziciji u Bg horizontu (27 % u redu, te 32 % u međurednom prostoru) nije očekivan s obzirom da je matični supstrat istraživane parcele

okarakteriziran kao les, odnosno lesni derivati (pleistocenske ilovine). Međutim Šilkić i sur. (1979.) u Tumaču geološke karte Hrvatske mjerila (1:100 000) za list Zagreb navode kako je moguća pojava proslojaka koji sadrže povećane udjele pijeska, kao rezultat procesa ispiranja i nakupljanja materijala koji su se odvijali u prošlosti na području istraživanja odnosno Plešivice.

Kod svih istraživanih profila u površinskom i potpovršinskom horizontu dominantna frakcija teksturnog sastava je frakcija praha. Navedeno je i očekivano s obzirom da je tlo na istraživanom obronku nastalo iz lesnog (i lesu sličnog – lesnih derivata) matičnog supstrata (Husnjak, 2014., Rubinić i sur., 2015a., 2015b.). Povećanje sadržaja praha prema nižim pozicijama obronka je očekivano s obzirom da su čestice praha najpodložnije erozijskim procesima. Nekoliko autora navodi kako su čestice praha podložnije kretanju niz nagib u odnosu na čestice pijeska i gline (npr. Torri i sur., 1997., Cerdan i sur., 2010.).

Sadržaj gline najveći je na višim pozicijama obronka (P1 i P2)z, što je u suprotnosti sa istraživanjima brojnih znanstvenika koji su u svojim istraživanjima utvrdili veći sadržaj sitnijih čestica (i gline i praha) na nižim reljefnim pozicijama (npr. Telak i sur., 2021., Razaei i sur., 2015.). Povećan sadržaj gline na višim pozicijama (poglavito u Ap horizontu) u ovom slučaju mogao bi se objasniti utjecajem erozije i duboke obrade tla. Naime, erozija tla uzrokovala je stanjivanje izvornog površinskog horizonta, nakon čega je potpovršinski horizont (koji u prirodnom pseudogleju ima povećan sadržaj gline) bio bliži površini. Dubokom obradom tla zahvaćen je potpovršinski horizont koji je obradom došao na površinu što bi objasnilo povećani sadržaj gline na gornjim pozicijama obronka. Navedene pretpostavke potvrđuju i istraživanja Gerke i Hierold (2012.), koji navode kako erozija dovodi do odnošenja gornjeg sloja tla, što prilikom obrade rezultira zahvaćanjem dijela potpovršinskih horizonta i njihovo homogeniziranje u novi antropogeni horizont (P, Ap). Naime, prirodni pseudoglej na proučavanom obronku vjerojatno je imao povećan sadržaj gline u potpovršinskom horizontu, gdje je duboka obrada narušila građu prirodnog profila pseudogleja, a iluvijalni (Bg) horizont je pomiješan s gornjim horizontima (A i Eg) i razvijen je novi, antropogeni (P) horizont. Nakon sadnje vinograda, međuredni prostor je zatravnjen što je pozitivno utjecao na ublažavanje erozijskih procesa duž obronka i sprječavanje transporta sitnijih čestica niz obronak (osobito gline).

Općenito, takvi rezultati raspodjele pijeska i gline (povećan sadržaj pijeska na P3 i gline na P1 i P2 poziciji obronka) nisu tipični za pojedine položaje na obronku, oni mogu biti rezultat meliorativnih zahvata koji su provedeni prije sadnje vinograda (npr. krčenje panjeva, ravnanje terena, duboka obrada tla). Naime oko samog nasada vinograda na području istraživanja nalazi se šuma, koja je vrlo vjerojatno prije sadnje vinograda pokrivala i samo područje na

kojem se danas nalazi vinograd. Krčenje panjeva i ravnanje terena vjerojatno je dovelo do netipičnog rasporeda pojedinih frakcija tla na pojedinim pozicijama obronka. U prilog ovoj teoriji govori satelitska snimka iz 1968. godine (Prilog, slika 8.1.), gdje se vidi da su redovi vinograda bili drugačije orijentirani u odnosu na današnju situaciju. Nadalje, sredinom parcele prolazio je put, koji se „uklonio“ nakon krčenja tadašnjeg vinograda i dovođenja parcele u stanje kakvo je i danas. Navedeno ukazuje na važnost gospodarenja obronačnim poljoprivrednim prostorima jer antropogeni utjecaji imaju veliku ulogu u fizikalno-kemijskim karakteristikama koje posljedično utječu na vodni režim obronka.

Volumna gustoća također se značajno razlikovala s obzirom na poziciju na obronku. Veća volumna gustoća tla utvrđena je na nižim pozicijama obronka (tj. P3, P4 i P5). Takvi rezultati volumne gustoće očekivani su s obzirom na to da je sadržaj gline najveći na položajima P1 i P2. Takav omjer volumne gustoće tla i raspodjele veličine čestica u tlu može se objasniti ukupnom poroznošću. Naime, tla u kojima prevladavaju čestice pijeska imaju relativno veliku volumnu gustoću jer imaju manji ukupni porozitet u odnosu na praškasta ili glinasta tla (USDA, 2014., Hillel, 2004.). Pozicija P1 koja ima najveći sadržaj gline, ima najmanju volumnu gustoću tla. Prema Tanveeri i sur. (2016.) sadržaj pijeska pokazao je pozitivnu korelaciju s volumnom gustoćom tla ($r = 0.60$), dok je sadržaj gline negativno korelirao s volumnom gustoćom ($r = -0.41$). Aubertin i Kardos (1965.) navode kako su uobičajene vrijednosti volumne gustoće za glinu 1.0 do 1.6 g cm⁻³, a za pijesak od 1.2 do 1.8 g cm⁻³. Razlike između volumne gustoće tla u redu i međurednom prosotoru također su značajne, što može biti povezano s utjecajem korijena biljaka (red – vinova loza, međuredni dio – korov/trava). Veća volumna gustoća u potpovršinskom horizontu u redu vinograda može biti povezana s korijenom vinove loze, koji raste u dublje slojeve tla u odnosu na zatravnjeni međuredni prostor vinograda. Prema Hillelu (2004.) aktivnosti korijena komprimiraju agregate tla, korijenje poboljšava stabilnost agregata zbog izlučivanja raznih tvari (npr. mucigel), odumiranja i propadanja, što simulira mikrobnu aktivnost i potiče stvaranje tzv. humusnog cementa koji utječe na povećanje volumne gustoće tla. Lucas i sur. (2019.) navodi da na mjestu kontakta sa tlom korijen povećava volumnu gustoću tla. Veća volumna gustoća u redu u odnosu na međuredni prostor za Ap horizont može biti povezana i sa korištenjem herbicida u redu vinograda. Naime, Sajid i sur. (2018.) navode kako korištenje herbicida sprječava rast trave (korova), čime se smanjuje unos organske tvari u tlo za koju se zna da utječe na smanjenje volumne gustoće preko pozitivnog utjecaja na strukturu i ublažavanje zbijanja tla (Chaudhari i sur., 2013., Virto i sur., 2018.).

Analizom ostalih fizikalnih svojstava tla utvrđeno je kako su najveće vrijednosti kapaciteta tla za vodu (Kv), na P1 poziciji obronka. Najveće vrijednosti kapaciteta tla za zrak utvrđene su na sredini (P3) i na dnu obronka (P5). Kapacitet tla za vodu na istraživanom obronku kretao se

od osrednjeg do velikog. Navedeni rezultat očekivan je s obzirom na rezultate analize teksturnog sastava gdje P1 i P2 pozicija imaju povećan sadržaj gline u odnosu na ostale pozicije na obronku. Kapacitet tla za vodu ujedno predstavlja i volumen mikropora, pa tako Hillel (2004.) navodi da se veći volumen mikropora javlja tipično u tlima sa povećanim sadržajem gline.

Najveći volumen makropora zabilježen je na P3 poziciji, koja ima najveći sadržaj pijeska. Vrijednosti kapaciteta tla za zrak uvelike su ovisile o vrijednostima kapaciteta tla za vodu, a načelno su odgovarale navodima Škorića (1991.) da se kapacitet tla za zrak u tlu smanjuje s dubinom, i općenito se kreće u rasponu od 1–3 % vol. Veći volumen makropora u redu u odnosu na međuredni prostor vinograda, može biti povezan sa aktivnošću korijena vinove loze. Naime, uzorci u neporušenom stanju u cilindrima volumena 100 cm³ uzorkovani su na dubini od 30 i 90 cm u redu i međurednom prostoru vinograda. S obzirom da korijen vinove loze raste u dublje slojeve u odnosu na korijen trave (korova), moguće je da korijen svojim rastom razrahljuje tlo čime stvara veći volumen makropora u redu u odnosu na međured vinograda. Za razliku od makropora, volumen mikropora veći je u međurednom prostoru vinograda. Navedenu tezu potvrđuju istraživanja Bodnera i sur. (2014.) koji navode kako grubo (krupnije) korijenje povećava volumen makropora, dok finije (sitno) korijenje povećava volumen mikropora u tlu. Također, nekoliko studija opisuje da je razvoj i formiranje makropora (koje mogu predstavljati preferencijalne tokove) povezano sa aktivnostima živog korijena, ali i tzv. korijenskim kanalima nastalim odumiranjem korijena, ali i procesima vlaženja i sušenja tla koji su intenzivniji u tlu pod drvenastom višegodišnjom vegetacijom (Noguchi i sur., 1999., Lange i sur., 2009., Beven i Geerman, 2013.). Nadalje, veći volumen mikropora u međurednom prostoru također bi mogao biti povezan s prisutnošću korijena trave (korova). Kako je već spomenuto, uzorci u neporušenom stanju uzorkovani su sa dubine od 30 cm, a obzirom da korijen trave u međurednom dijelu vinograda ne prodire u dublje slojeve od 20 cm nije izražen njegov utjecaj na strukturu tla, a time i porozitet na dubini od 30 cm.

Još jedno od mogućeg objašnjenja većeg volumena mikropora u međuredu u odnosu na red vinograda, mogao bi biti povezan sa intenzivnim prolascima traktora koji utječu na zbijanje tla što dovodi do povećanja volumena mikropora (Bogunović i sur., 2017.).

Ukupna poroznost tla ovisi o teksturnom sastavu tla i strukturi. Veći ukupni porozitet veći je u glinastim u odnosu na pjeskovita tla, što je također u skladu s literaturom (USDA, 2014., Hillel, 2004.). Isto tako, ukupna poroznost veća je u tlima sa većim sadržajem organske tvari. Suprotno rezultatima istraživanja, Rubinića i sur. (2016.) u istraživanju svojstva pseudogleja (prvenstveno Eg i Btg horizonta) u šumskim ekosustavima navode kako se ukupni porozitet smanjio s dubinom, gdje je u Eg horizontu prosječno iznosio gotovo 50 % dok je u Btg horizontu ukupna poroznost iznosila prosječno 43,8%. Isti autori navode kako je ukupna poroznost u

snažnoj negativnoj korelaciji sa sadržajem gline, i pozitivnoj korelaciji sa sadržajem humusa. Ukupni porozitet, i diferencijalna poroznost izravno utječu na različita hidraulička svojstva tla kao što su: hidraulička vodljivost, zadržavanje vode u tlu, infiltraciju, te kapacitet fiziološki aktivne vode (Luxmore, 1981., Pagliali i Vignozz, 2002.).

5.1.4. Kemijska svojstva istraživanih profila

S obzirom da je pseudoglej jako kiselo tlo (Husnjak, 2014., Rubinić i sur., 2015b.), svaki od istraživanih profila na obronku bio je nekarbonatan. Statistička analiza pokazala je da se pH tla (u oba horizonta) značajno razlikovao bez obzira na položaj na padini ($P < 0.0001$), gdje je značajno najveća pH vrijednost utvrđena na poziciji P2 (za Ap i Bg horizont). Slične rezultate za pH tla dobili su Sun i sur. (2021.) u istraživanju svojstava tla na obronačnim tlima u uvjetima uzgoja agruma, gdje su otkrili da se pH tla smanjuje prema nižim reljefnim položajima. Također, Kotingo (2015.) je u svojim istraživanjima dobio slične rezultate i navodi da je pH tla veći na višim u usporedbi s nižim položajima na padini. Međutim, suprotno rezultatima dobivenim u ovom istraživanju, neki autori (Kisić i sur. 2002., Jurišić i sur. 2012.) u svojim istraživanjima svojstava pseudogleja obronačnog navode kako pH reakcija tla uglavnom raste niz obronak. Za razliku od njih Rubinić i sur. (2015b.) nisu potvrdili utjecaj reljefne pozicije profila pseudogleja na reakciju tla.

Utvrđene su značajne razlike u pH tla između reda i međurednog prostor vinograda također su bile značajne ($P < 0.0001$), gdje su značajno veće pH vrijednosti utvrđene u međurednom prostoru (za oba horizonta) u odnosu na prostor u redu. Takvi rezultati u suprotnosti su sa rezultatima istraživanja Hendgena i sur. (2020.) koji nisu utvrdili razlike u pH vrijednosti između reda i međurednog prostora vinograda. Niže vrijednosti pH tla u redu vinove loze mogu biti povezane sa usvajanjem hranjiva od strane vinove loze (kationa). Naime, usvajanjem kationa korijen u tlo ispušta više H^+ iona koji utječu na smanjenje pH tla. Još jedan razlog smanjenog pH tla u redu vinograda mogao bi biti povezan sa tretiranjem vinograda sumpornim preparatima. Naime, poznato je kako su vinogradi jedni od najčešće tretiranih usjeva u poljoprivrednom proizvodnji (Gill i Garh, 2014., Provost i Pedneault, 2016.) bakrenim i sumpornim preparatima s ciljem kontrole biljnih bolesti, a prvenstveno pepelnice i peronospre. Tretiranjem vinove loze sumpornim preparatima, dio preparata se s lišća vinove loze ispere u tlo (najviše u redu) gdje tijekom razgradnje u tlu utječe na smanjivanje pH reakcije tla. S obzirom na navedeno s pravom se nameće zaključak kako bi upravo ovakva praksa u vinogradima (tretiranje fungicidima) mogla utjecati na smanjenu pH vrijednost tla u redu u odnosu na međuredni prostor vinograda.

Sadržaj humusa na istraživanom obronku doista je heterogen i značajno se razlikuje ($P < 0.0001$) ovisno o poziciji na obronku. Najveći sadržaj humusa u Ap horizontu zabilježen je na poziciji P3 u redu, a najniži na P5 poziciji u međuredu. Statistička analiza otkrila je značajnu razliku u sadržaju humusa između reda i međurednog prostora vinograda, gdje je u redu (u oba horizonta) utvrđen značajno veći sadržaj humusa u odnosu na međuredni prostor vinograda (Tablica 4.11.). Tlo na svim pozicijama istraživanog obronka u pogledu sadržaja humusa okarakterizirano je kao vrlo slabo do slabo humozno. Općenito, pretvaranjem prirodnog tla u poljoprivredno, sadržaj humusa s vremenom se smanjuje (Kizilkaya i Dengiz, 2010., Haghighi i sur., 2010.), što objašnjava nizak sadržaj humusa u svim istraživanim profilima. Veći sadržaj humusa u redu u odnosu na međuredni prostor može se pripisati povremenoj obradi tla u međurednom prostoru vinograda što utječe na bržu mineralizaciju humusa u odnosu na red u kojem se nakuplja. Naime, kako je već spomenuto, u vinogradu se svake druge godine u svakom drugom međurednom prostoru obavlja plitka obrada tla (do oko 30 cm). Hendgen i sur. (2020.) u svojim istraživanjima u biodinamičkom sustavu uzgoja vinograda otkrili su razlike u sadržaju organske tvari u tlu između reda i međurednog prostora gdje je veći sadržaj humusa zabilježen u redu. Molina i sur. (2019.) proučavali su svojstva tla na padinama različitih nagiba pod različitom prirodnom vegetacijom (šuma, travnjaci) i nisu uočili razlike u sadržaju humusa između pozicija na obronku. Rubinić i sur. (2015b.) također nisu utvrdili utjecaj nagiba na sadržaj humusa u pseudogleju obronačnom u šumskom ekosustavu.

5.1.5. Hidraulička svojstva tla

Hidraulička svojstva tla (θ_r , θ_s , α , n , K_s , I) u sklopu istraživanja ove doktorske disertacije određena su pomoću HYPROP i WP4C sustava te pomoću kutije s pijeskom i tlačnog ekstraktora, dok je hidraulička vodljivost tla u saturiranim uvjetima (K_s) odrađena na K-sat uređaju te na aparatu za serijsko određivanje vodopropusnosti. Hidraulička vodljivost predstavlja sposobnost tla za transport vode (i u njoj otopljenih tvari) kroz tlo. S obzirom na rezultate istraživanja hidrauličke vodljivosti, može se zaključiti da tlo na istraživanoj lokaciji ima jako male vrijednosti ovog hidrauličkog svojstva (Tablice: 4.15. 4.17. i 4.18.). Vrijednosti hidrauličke vodljivosti kretale su se u rasponu od 0,043 do 2,65 cm dan⁻¹ (sa prosječnom vrijednosti od 0,62 cm dan⁻¹) za van Genuchten original model, dok su se vrijednosti hidrauličke vodljivosti dobivene primjenom van Genuchten bimodal modela kretale u rasponu od 0,049 do 36,6 cm dan⁻¹ (sa prosječnom vrijednosti od 5,48 cm dan⁻¹). Najmanje vrijednosti hidrauličke vodljivosti, utvrđene su na vrhu obronka. Navedeni rezultati u skladu su s rezultatima analize teksturnog sastava tla, obzirom da je na vrhu obronka utvrđen i najveći sadržaj gline. Hillel (2004.) navodi da je u saturiranim uvjetima, hidraulička vodljivost veća u teksturno lakšim tlima

(tla u kojima prevladavaju čestice pijeska) u odnosu na teksturno teža (glinasta) tla. Isti autor navodi kako hidraulička vodljivost ovisi o strukturi i teksturi tla, te o veličini i ukupnom volumenu makropora. Navedena tvrdnja u skladu je s rezultatima vrijednosti izmjerenog i procijenjenog K_s – a izmjerenom na P3 poziciji u Bg horizontu, gdje upravo ta pozicija u navedenom horizontu ima signifikantno najveći sadržaj pijeska u odnosu na ostale pozicije.

Veće vrijednosti hidrauličke vodljivosti (vodopropusnosti) izmjerene su na aparatu za serijsko određivanje vodopropusnosti u odnosu na K–sat uređaj. Takvi rezultati mogu biti rezultat različitog volumena tla koji je bio korišten u pojedinoj analizi. Naime, aparat za serijsko određivanje hidrauličke vodljivosti koristi cilindre tla volumena 100 cm^3 dok K – sat uređaj koristi uzorke tla od 250 cm^3 . Moguće je da su ovakva mjerenja, na uzorcima manjeg volumena podložnija većim pogreškama tijekom mjerenja, odnosno dobivanju drugačijeg (ne nužno i krivog) rezultata u odnosu na uzorke tla većeg volumena, što ukazuje na značajno variranje fizikalnih značajki tla na malim udaljenostima. Reynolds i sur. (2000.) navodi kako velike varijabilnost u vrijednostima K_s – a (prilikom određivanja na cilindrima u laboratoriju) mogu biti povezane sa samom metodom mjerenja u kojoj biopore (npr. korijenski kanali) mogu znatno utjecati na rezultate mjerenja.

S obzirom da je hidraulička vodljivost na cilindrima volumena 100 cm^3 odrađena samo u međured, a ne i u redu, nije moguća usporedba red/međured kod navedenih uzoraka. Međutim, na K-sat sustavu odrađeni su uzorci (od 250 cm^3) u redu i u međurednom prostoru vinograda. Iz rezultata je vidljivo kako su općenito veće vrijednosti K_s – a zabilježene u redu u odnosu na međured. Takvi rezultati u skladu su s istraživanjima Julicha i sur. (2021.) koji su u svom istraživanju određivali hidrauličke značajke na pseudoglejnom tlu u šumskom ekosustavu različite starosti (mlada i stara šuma). Temeljem rezultata svog istraživanja zaključuju kako se K_s povećava s povećanjem volumena makropora. Do sličnih rezultata došli su i drugi znanstvenici (npr. Beven i Geerman, 2013., Noguchi i sur., 1999.) koji navode kako se osim s povećanjem volumena makropora vrijednosti hidrauličke vodljivosti saturiranog tla (K_s) povećavaju i uslijed smanjenja volumne gustoće tla, ali i s povećanjem sadržaja organske tvari u tlu.

Korištenjem HYPROP–FIT softvera za izradu retencijskih i hidrauličkih krivulja bolji *RMSE* pokazao je van Genuchten bimodal u odnosu na van Genuchten original model (Tablica 4.16. i 4.17.). Bolji vrijednosti *RMSE*–a korištenjem van Genuchten bimodal modela u skladu su s rezultatima istraživanja Haghverdi i sur. (2020.). Navedeni autori uspješnije korištenje van Genuchten bimodal modela u odnosu na original pripisuju tome što bimodal uzima u obzir dvije domene poroznog sustava (unutar i izvan agregata).

Bezerra–Coelho i sur. (2018.) koristili su HYPROP sustav za određivanje hidrauličkih svojstava na tlima sa različitim teksturnim sastavom (fina, srednje gruba do gruba tekstura). Za procjenu

retencijskih i hidrauličkih krivulja korištena je van Genuchten original i bimodal funkcija. Korištenjem van Genuchten original modela za fino teksturna tla Bezerra–Coelho i sur. (2018.) dobili su slične vrijednosti hidrauličkih parametara (osim K_s -a) kao i u ovom radu ($\theta_s = 0,5 \text{ cm}^3 \text{ cm}^{-3}$, $\alpha = 0,008$, $n = 1,30$, $K_s = 10 \text{ cm dan}^{-1}$). Iz tablice 4.18. uočava se kako su vrijednosti hidrauličkih parametara (osim $K_s - a$) procijenjenih van Genuchten original modelom u ovom radu slični vrijednostima hidrauličkih parametara navedenih autora. Za takva, teksturno teža tla autori su zaključili kako je primjena van Genuchten original modela zadovoljavajuća. Rezultati istraživanja ukazuju na problem korištenja van Genuchten original modela kod određivanja hidrauličke propusnosti na skeletnim tlama kod kojih je n vrijednost vrlo visoka ($n = 10,0$). U takvim slučajevima (za tla sa srednjim do visokim n vrijednostima) preporučaju odvojeno određivanje hidrauličke propusnosti tla (K_s).

Defterdarović i sur. (2021.) koristili su HYPORP sustav za određivanje hidrauličkih značajki na tri slična tipa tla (Calcaric Phaeozem, Calcaric Regosol, Calcaric Fluvic Phaeozem, odnosno rendzine na fluvijalnom nanosu) sa istim načinom korištenja u istim klimatskim uvjetima, ali na različitim lokacijama diljem Zagreba (Hrvatska). Rezultati istraživanja ukazuju na različita hidraulička svojstva površinskog horizonta, ali slična hidraulička svojstva dubljih horizonata istraživanih profila tla. Navedeno je u skladu i sa rezultatima u ovom istraživanju gdje se generalno svojstva tla (fizikalna, kemijska i hidraulička) više razlikuju po pozicijama te između reda i međurednog prostora u Ap nego u Bg horizontu.

Schelle i sur. (2013.) u svom istraživanju usporedili su i procijenili više načina mjerenja retencije vode u tlu na širokom rasponu teksturnih klasa tala (pjeskovita, praškasta, ilovasta, pjeskovito ilovasta, glinasto ilovasta, glina). Rezultati retencijskih krivulja dobivenih pomoću evapotranspiracijske metode na HYPROP uređaju pokazali su veliku sličnost kod vlažnih do srednje vlažnih uzoraka. Rezultati mjerenja visoke rezolucije dobiveni ovom metodom rezultirali su jednakom, a u nekim slučajevima čak i preciznijom procjenom retencijskih krivulja tla u usporedbi s podacima dobivenim pomoću kutije s pijeskom i tlačnog ekstraktora.

Rezultati statističke obrade rezultata o retenciji vode u tlu, ukazuju na značajnu razliku obzirom na poziciju obronka. Navedeni rezultati logični su s obzirom na značajne razlike u teksturnom sastavu tla na različitim pozicijama obronka. Kako navode Indoria i sur. (2017.) tla koja imaju visok udio gline imaju veću sposobnost retencije vode u odnosu na tla u kojima prevladavaju čestice pijeska.

5.2. Odnos vodnog potencijala tla i vodnog potencijala vinove loze

Korelacijski koeficijenti između vodnog potencijala tla i vodnog potencijala vinove loze zanemarivi su i kreću se uglavnom u rasponu od ($r = -0.18$ do 0.23). Značajnija (jaka) korelacija vodnog potencijala tla i vinove loze zabilježena je na sredini obronka (P3 pozicija) gdje je utvrđeni korelacijski koeficijent između vodnog potencijala tla i vinove loze (u podne) iznosio $r = 0.63$. Veće vrijednosti korelacijskog koeficijenta kod P3 pozicije obronka mogla bi biti povezana sa teksturnim sastavom tla. Naime, P3 pozicija u Bg horizontu ima značajno najveći sadržaj pijeska (i najmanji sadržaj gline) koji omogućuje lakše usvajanje vode od strane vinove loze u odnosu na ostale pozicije koje imaju povećani sadržaj gline. Općenito, ovakvi rezultati vrlo slabe korelacije na P1 i P5 poziciji između vodnog potencijala tla i vinove loze u suprotnosti su sa istraživanjima Centenoa i sur. (2010.) koji su utvrdili visoku korelaciju između vodnog potencijala tla i vinove loze. Suprotno istraživanjima u sklopu ove disertacije, gdje nije utvrđena korelacija, Van Leeuwen i sur. (2009.) te Deloire i sur. (2005.) u svojim istraživanjima utvrdili su snažnu korelaciju između vodnog potencijala tla i vodnog potencijala vinove loze (izmjenjenog prije svitanja). Međutim, Williams i Trout (2005.) navode kako vodni potencijal vinove loze izmjenjen prije svitanja nije dobar pokazatelj vodnog stresa biljke. Obrazloženje ove tvrdnje leži u činjenici da su tijekom noći, zbog odsustva svjetla potrebnog za fotosintezu i smanjene potrebe za rashlađivanjem lišća, puči zatvorene te stoga ne dolazi do transpiracije, što dopušta (ponovnu) hidrataciju biljke i uspostavu ravnoteže između potencijala tla i biljke. S obzirom na to neki znanstvenici navode kako je korelacija između vodnog potencijala tla i vodnog potencijala vinove loze značajnija u podne (Williams i Trout, 2005., Williams i Araujo, 2002.).

S obzirom da je korelacija između vodnog potencijala vinove loze i vodnog potencijala tla vrlo slaba (P1 i P5 pozicije), dodatno je izračunat korelacijski koeficijent između vodnog potencijala vinove loze i srednje dnevne relativne vlage zraka. Iznosi korelacijskih koeficijenata ukazuju kako nema korelacije između vodnog potencijala vinove loze u jutro (prije svitanja) i srednje dnevne relativne vlage zraka. Navedeno je u skladu s već gore opisanim razlozima. Međutim, utvrđena je jaka korelacija ($r = 0.56$ do 0.67) korelacija između vodnog potencijala vinove loze izmjenjenog u podne i srednje dnevne relativne vlage zraka (Tablica 4.6.). Bolju korelaciju vodnog potencijala lista paprike i relativne vlage zraka u odnosu na korelaciju sa vodnim potencijalom tla u svom radu utvrdili su i Coolong i sur. (2012.). Navedeni autori navode kako je vodni potencijal tla jako slabo korelirao sa vodnim potencijalom lista, dok je vodni potencijal lista dobro korelirao sa meteorološkim parametrima (temperatura, relativna vlažnost zraka i sunčevo zračenje). Također, autori navode kako vodni potencijal lista biljke nije dobar indikator

sadržaja vode u tlu, jer je više pod utjecajem okolišnih (meteoroloških) uvjeta nego sadržaja vlage u samom tlu.

5.3. Sadržaj vlage u tlu

Veći sadržaj vlage u tlu tijekom istraživanih razdoblja uočen je na gornjim (P2 i P1) pozicijama obronka, dok je najmanji sadržaj vlage zabilježen na donjoj (P5) poziciji. Takvi rezultati u suprotnosti su sa brojnim istraživanjima. Tako su npr. Basile i sur. (2020.) istraživali režim vlažnosti na obronku u uvjetima uzgoja vinograda u mediteranskoj klimi. Rezultati istraživanja ukazuju kako je najveći sadržaj vlage u tlu zabilježen na donjem u odnosu na gornji dio obronka. Ipak, autori upozoravaju da se takva raspodjela sadržaja vlage u tlu na obronku ne smije generalizirati zbog moguće drugačije raspodjele svojstava tla na sličnim reljefnim formama. Neki autori navode kako se voda s vrha obronka slijeva na niže dijelove što za posljedicu ima veći sadržaj vlage u tlu na dnu u odnosu na vrh obronka (Biddoccu i sur., 2017., Brillante i sur., 2017.). Iako su rezultati istraživanja u sklopu ove doktorske disertacije u suprotnosti sa brojnim literaturnim navodima, oni su rezultat heterogenih fizikalnih svojstva tla na obronku. Naime, veći sadržaj vlage u tlu na višim pozicijama (P1 i P2) može biti povezan sa povećanim sadržajem gline upravo na tim pozicijama. Kako navodi Poni i sur. (2018.) tekstura i struktura tla utječu na kapacitet retencije vode u tlu. Također, Indoria i sur. (2017.) navode kako tla sa povećanim sadržajem gline imaju veću sposobnost retencije vode u odnosu na pjeskovita tla. Mnogobrojni autori potvrđuju pozitivan utjecaj sadržaja gline na zadržavanje vode u tlu (npr. Gaiser i sur., 2000., Al Majou i sur., 2008., Da Costa i sur., 2013.).

Također, utvrđene su relativno heterogene vrijednosti sadržaja vlage u tlu između reda i međurednog prostora vinograda. Međutim, općenito se može zaključiti kako je sadržaj vlage u Ap horizontu veći u redu u odnosu na međured, dok je kod Bg horizonta veći sadržaj vlage u međuredu u odnosu na red. Veći sadržaj vlage u redu mogao bi se pripisati različitom korijenovom sustavu trave i vinove loze (Smart i sur., 2006., Celette i sur., 2008.). Naime, korijen trave (u međurednom prostoru) upija vodu iz površinskih slojeva tla s obzirom da razvija plići korijenov sustav u odnosu na vinovu lozu. Isto tako Celette i sur. (2008.) u svom istraživanju utvrdili su pozitivan utjecaj trave (zatravnjenog međurednog prostora) na infiltraciju vode u dublje slojeve tla. Nadalje, još jedno od mogućih objašnjenja većeg sadržaja vlage u redu u odnosu na međuredni prostor mogao bi biti povezan sa povremenom površinskom obradom tla međurednog prostora vinograda. Naime, u vinogradu se svake druge godine (u svakom drugom međuredu) provodi plitka površinska obrada tla do dubine od otprilike 30 cm. Amami i sur. (2021.) navode kako obrada tla poboljšava infiltraciju vode u tlo. Veća infiltracija u međurednom prostoru mogla bi objasniti i razlike u sadržaju vlage u tlu između reda i međureda u Bg horizontu. Naime u Bg horizontu veći sadržaj vlage zabilježen je u međuredu u odnosu na red. Nadalje, navedene razlike u sadržaju vlage između reda i međurednog

prostora mogle bi se pripisati i dublje razvijenom korijenu vinove loze koji upija vodu iz dubljih slojeva tla u odnosu na travu koja ne razvija dubok korijenov sustav što joj onemogućuje usvajanje vode iz dubljih slojeva.

Veće oscilacije sadržaja vlage u tlu zabilježene su u površinskom u odnosu na potpovršinski horizont tla. Navedena činjenica logična je s obzirom da je površinski horizont tla izloženiji djelovanju atmosferskih uvjeta (npr. temperatura, brzina vjetra, relativna vlaga zraka) koji više utječu na isušivanje tla u plićim nego u dubljim slojevima.

Tijekom cijelog razdoblja istraživanja nije zabilježeno da je sadržaj vode u tlu bio ispod točke venuća bez obzira na poziciju obronka. S druge pak strane, na nekim pozicijama uočena je povremena pojava prekomjerne saturacije tla kada je sadržaj vlage u tlu bio iznad Kv-a (ali ispod ukupnog poroziteta). Međutim, prekomjerna saturacija na P3 poziciji u međuredi (Bg horizont) trajala je tijekom cijelog istraživnog razdoblja (538 dana). Ovi se rezultati, na prvu, nisu očekivani s obzirom da P3 pozicija u odnosu na ostale pozicije ima najveći sadržaj pijeska i gotovo najmanji sadržaj gline. Naime, povećani sadržaj gline u Bg horizontu na P1 i P2 poziciji (35,47 % i 45,57 %) vjerojatno su utjecali na pojavu potpovršinskog lateralnog tok i kretanja vode po Bg horizontu do P3 pozicije. Povećani sadržaj pijeska u Bg horizontu na P3 poziciji vjerojatno je prekinuo („presjekao“) potpovršinski lateralni tok i time spriječio njegovo daljnje kretanje prema nižim pozicijama obronka (P4 i P5). Filipović i sur. (2018a.) proučavali su lateralni potpovršinski tok na erodiranom Haplic Luvisolu s relativno zbijenim C horizontom. Glavni cilj njihovog istraživanja bio je kvantificirati potencijalnu pojavu potpovršinskog lateralnog toka u profilima tla duž obronka. Pretpostavljeno je da bočni tok ovisi o pedološkim i prostorno promjenjivim hidrauličkim uvjetima zahvaćenima erozijom. Numerička analiza (pomoću programskog paketa HYDRUS 2D) sugerirala je pojavu lateralnog potpovršinskog toka na granici između Bt – C horizonta tijekom ekstremnih ljetnih kišnih oluja.

Međutim, važno je napomenuti da iako je sadržaj vlage u tlu na P3 poziciji bio iznad kapaciteta tla za vodu (Kv), apsolutni sadržaj vlage u tlu bio je niži na P3 poziciji u usporedbi s P1 i P2 pozicijama i to bez obzira na horizont te red i međured. Navedeno se može pripisati retencijskim svojstvima čestica pijeska, koji u usporedbi s ostalim frakcijama ima najmanju mogućnost zadržavanja vode (Indoria i sur., 2017., Gaiser i sur., 2000.). Posljedično, P3 pozicija ima i najmanji kapacitet za retenciju vlage.

5.4. Numeričko modeliranje

HYDRUS softverski paket kao ulazne parametre za simulaciju toka i retencije vode zahtijeva vrijednosti hidrauličkih parametara (θ_s , θ_r , α , n i l) u modelu jednostruke poroznosti (eng. *single porosity*, van Genuchten 1980.). Hidraulički parametri korišteni u ovom radu određeni su ili procijenjeni na tri načina, i to direktnim određivanjem pomoću HYPROP i WP4C sustava, preko tipa pet pedotransferne funkcije u ROSETTA softveru koji je sastavni dio HYDRUS softverskog paketa, te optimizacijom hidrauličkih parametara inverznim modeliranjem. Hidraulički parametri jedni su od najvažnijih ulaznih parametara o kojima ovise rezultati simulacije (Chen i sur., 2014), stoga je njihovo precizno i točno određivanje od izrazite važnosti.

5.4.1. Simulacije s hidrauličkim parametrima iz HYPROP – a

Za simulacije, prvo su korišteni hidraulički parametri dobiveni primjenom evapotranspiracijske metode, korištenjem HYPROP i WP4C uređaja (Schindler i Müller, 2017.). Hidraulički parametri određeni su za gornju, srednju i donju poziciju obronka (redom: P1, P3 i P5) u redu i međurednom prostoru vinograda te u Ap i Bg horizontu. Prilikom pokretanja simulacija HYDRUS 1D modelom, kao ulazne parametre koristeći hidrauličke značajke tla iz HYPROP i WP4C sustava (θ_s , θ_r , α , n i l) model je bio nestabilan (za simulacije na P3 i P5 poziciji, u redu i međurednom prostoru te u Ap i Bg horizontu), te rješenje simulacije nije konvergiralo. Nestabilnost modela može biti uzrokovana lošom procjenom hidrauličkih parametara, gdje vrijednosti izmjerene u laboratoriju ne odgovaraju stvarnoj situaciji na terenu. Durner i Lipsius (2005.) navode kako se vrijednosti K_s –a izmjerene na terenu i u laboratoriju mogu razlikovati za dva i više reda veličina. Vrijednosti K_s –a dobivenih preko HYPROP sustava (Tablica 4.18. i 4.19.) manji su u odnosu na vrijednosti procijenjene inverznim simuliranjem (Tablica 4.26.), što bi moglo biti uzrok da simulacije ne konvergiraju sa hidrauličkim značajkama procijenjenim preko HYPROP sustava. Moguće je da procijenjene hidrauličke značajke tla inverznim simuliranjem bolje odgovaraju svojstvima tla na terenu u odnosu na hidrauličke značajke (prvenstveno K_s) procijenjene pomoću HYPROP sustava.

Takvi rezultati u suprotnosti su s drugim istraživanjima gdje su autori korištenjem hidrauličkih parametara dobivenih iz HYPROP i WP4C sustava utvrdili najbolje rezultate simulacije toka i retencije vode u tlu. Tako su Domínguez-Niño i sur. (2020.) koristili hidrauličke značajke dobivene pomoću evapotranspiracijske metode HYPROP sustavom i ROSETTA softverom u HYDRUS 3D simulacijama dinamike vode u tlu u navodnjavanom voćnjaku. Rezultati simulacija testirani na temeljem podataka o sadržaju vode u tlu izmjerenim neutronske sondama i tenziometrima. Najbolje rezultate simulacija postigli su sa hidrauličkim značajkama parametriziranim iz HYPROP + WP4C sustava.

HYPROP i WP4C sustav dobro je opisao retencijske i hidrauličke krivulje na izmjerenim uzorcima tla (Slike 4.20. – 4.31.) Međutim vrijednostii hidrauličkih značajki tla određeni preko HYPROP i WP4C sustava nisu pokazali zadovoljavajuće rezultate u HYDRUS 1D simulacijama. Navedeno bi moglo biti povezano sa heterogenošću tla na istraživanom obronku. Naime, preliminarnim istraživanjima uočeno je kako sadržaj pijeska i humusa najviše varira po izohipsama obronka. S obzirom da upravo sadržaj pijeska i humusa znatno utječe na rezultate hidrauličkih značajki tla za pretpostaviti je da bi upravo ovaj parametar mogao utjecati na ne reprezentativna hidraulička svojstva dobivena HYPROP i WP4C sustavom. U slučaju da su uzorci tla uzorkovani neposredno uz postavljene TDR senzore, vjerojatno bi hidrauličke značajke tla dobivene HYPROP i WP4C sustavom točnije opisivale kretanje i retenciju vode u promatranoj točki.

5.4.2. Simulacije sa hidrauličkim parametrima određenim preko pedotransfernih funkcija iz ROSETTA softvera

S obzirom na nezadovoljavajuće hidrauličke značajke tla dobivene pomoću HYPROP i WP4C sustava, pristupilo se određivanju hidrauličkih značajki tla pomoću ROSETTA softvera (Schaap i sur., 2001.). Za procjenu parametara dostupno je pet pedotransfer funkcija. Prva uključuje podatke o teksturnoj klasi tla, druga uključuje podatke o sadržaju pijeska, praha i gline, treća uz navedeno uključuje podatke o volumnoj gustoći tla, četvrta uz navedeno zahtjeva podatke o volumetrijskom sadržaju vode u tlu pri 0,33 bara, dok peta razina pedotransfer funkcije uz navedeno zahtjeva i podatke o volumetrijskom sadržaju vode u tlu pri 15 bara. Za procjenu hidrauličkih parametara u našem slučaju korišten je “tip pet” pedotransfer funkcije.

Kao i sa hidrauličkim značajkama dobivenim iz HYPROP i WP4C sustava, simulacije sa hidrauličkim parametrima procijenjenima na temelju pedotransfer funkcija iz ROSETTA softvera na određenim pozicijama također su bile nestabilne (P2 i P3 pozicija u redu). Osim toga, simulacije na ostalim pozicijama vizualnim pregledom pokazuju izrazita nepoklapanja sa izmjerenim vrijednostima volumetrijskog sadržaja vode u tlu. Uz vizualnu identifikaciju ne poklapanja, verifikacijske mjere (R^2 , MAE i $RMSE$) također ne pokazuju zadovoljavajuće vrijednosti, npr. vrijednosti $RMSE$ – a do $0,238 \text{ cm}^3 \text{ cm}^{-3}$.

Nedostatak takvih pedotransfer funkcija je da za procjenu hidrauličkih parametara tla ne uzimaju u obzir strukturu i mineraloški sastav tla te umjesto toga pretpostavljaju da tla sličnog teksturnog sastava imaju i slična hidraulička svojstva (Carsel i Parrish, 1988., Wösten i sur., 1999.). Također, prilikom određivanja retencijskih značajki tla na tlačnom ekstraktoru (pri – 0,33 i – 15 bara), a koji su korišteni kao jedni od ulaznih parametara za ROSETTA – u, uzorci tla morali su se usitniti i prosijati kroz sito otvora promjera 2 mm, što je utjecalo na narušavanje

strukture tla. S obzirom na to, vrijednosti sadržaja vode u tlu pri – 0,33 i – 15 bara vjerojatno su se razlikovale od stvarnih. Navedeno je moglo negativno utjecati na dobivanje drugačijih vrijednosti hidrauličkih svojstava tla od stvarnih vrijednosti na terenu.

Alvarez – Acosta i sur., (2012.) u svom istraživanju uspoređivali su uspješnost svih pet pedotransfer funkcija iz ROSETTA softvera na pjeskovito ilovastom tlu. Rezultati istraživanja ukazuju na to kako se funkcija 5 pokazala najuspješnijom za predviđanje K_s – a. Vrijednosti R^2 svih pet funkcija redom su iznosile: 7,4E-5; 0,22; 0,15; 0,55; 0,51. Iako je R^2 funkcije tipa pet bolji od R^2 funkcije tipa četiri, vrijednost RMSE – a manje su za funkcije tipa četiri, stoga su ju autori smatraju najboljom.

Imajući u vidu navedeno i rezultate simulacija vlastitog istraživanja sa hidrauličkim parametrima procijenjenima pomoću ROSETTA – e predlaže se uključivanje većeg broja prediktora (npr. zbijenost tla, volumen mikro i makro pora, ukupni porozitet) u postojeće pedotransfer funkcije kako bi procijenjena hidraulička svojstva tla što bolje odgovarala stvarnim vrijednostima na terenu.

5.4.3. Inveržno simuliranje

S obzirom na nestabilne i nezadovoljavajuće simulacije retencije vode (usporedba sa podacima sa senzora) u tlu sa hidrauličkim parametrima iz ROSETTA – e, pristupilo se inverznom modeliranju. Inveržno modeliranje izvršilo se za razdoblje od 13.9. do 12.10.2019 u ukupnom trajanju od 30 dana u kojem je podjednako utvrđen broj dana s i bez oborina (kiše). Početne vrijednosti hidrauličkih parametara uzete su iz pedotransfer funkcije (tipa pet) iz ROSETTA softverskog paketa. Hidraulički parametri (θ_s , α , n i K_s) bili su optimizirani inverznim modeliranjem. Različiti autori navode kako su hidraulički parametri tla različito osjetljivi na optimizaciju. Tako npr. Hupet i sur. (2002.) i Ritter i sur. (2003.), analizirajući osjetljivost WAVE (eng. *Water and Agrochemicals in the soil, crop and Vadose Environment*) modela na hidrauličke parametre zaključuju kako je sadržaj vode u tlu visoko osjetljiv na promjene θ_s , θ_r i n . Zabilježena je niska, ali i dalje signifikantna osjetljivost na promjene K_s – a. Od svih hidrauličkih parametara najmanja osjetljivost bila je na promjene α vrijednosti. Iste rezultate u svom istraživanju dobili su i Musters i sur. (2000.) koji su analizirali osjetljivost SWAP (eng. *Soil Water Atmosphere Plant*) modela na već navedene hidrauličke parametre. Wegehenkel i Beyrich (2014.) inverznim modeliranjem optimizirali su θ_r i θ_s parametre u HYDRUS 1D modelu.

Broj iteracija povećavan je sve dok se vrijednost funkcije minimizacije nije prestala smanjivati. Za kalibracijski period na svim pozicijama postignute su zadovoljavajuće vrijednosti R^2 i RMSE – a (Slike 4.47. do 4.51.). One su u međuredu bile $R^2 \geq 0,93$, $RMSE \leq 0,0340 \text{ cm}^3 \text{ cm}^{-3}$. U redu, vrijednosti verifikacijskih mjera bile su nešto lošije, gdje je najniža vrijednost R^2

iznosila 0,645, a najviša vrijednost $RMSE$ – a 0,0548 cm³ cm⁻³. Ovakve vrijednosti R^2 smatraju se zadovoljavajuće, stoga su hidraulički parametri procijenjeni inverznom metodom korišteni u daljnjim simulacijama za cijelo istraživano razdoblje odnosno od 26.04. do 14.10.2019, te od 01.01. do 31.12.2020. godine.

Lai i Ren (2016.) određivali su hidraulička svojstva za heterogeno tlo kombiniranim korištenjem HYDRUS 1D i PEST modela. Autori navode da kod heterogenih tala ne postoje jedinstvena, prosječna svojstva tla koja bi se mogla koristiti kao ulazni parametri prilikom simulacija sadržaja vode u tlu. Rezultati njihovog istraživanja ukazuju da je inverzno modeliranje dobar pristup u simuliranju vodnog režima tla, međutim zahtijeva dodatnu optimizaciju parametara poglavito u slojevitim tlima (npr. prisustvo slabije propusnog horizonta). Ket i sur. (2018.) uspješno su procijenili hidraulička svojstva tla korištenjem HYDRUS 1D modela baziranim na mjerenjima vlage i vodnog potencijala tla. Filipović i sur. (2018b.) koristili su inverzno modeliranje u HYDRUS 2D/3D softveru za procjenu hidrauličkih svojstava tla na temelju mjerenja infiltracije tenzijskim disk infiltrometrom (eng. *tension disk infiltrometer*). Inverzno modeliranje rezultiralo je uspješnom procjenom hidrauličkih parametara tla (R^2 i $E > 0,9$), što ukazuje na dobro poklapanje izmjerenih i simuliranih vrijednosti infiltracije.

Navedeni primjeri govore u prilog mogućnosti uspješnog korištenja inverznog modeliranja za procjenu hidrauličkih značajki tla u slučaju kada terenska ili laboratorijska mjerenja ne pružaju zadovoljavajuće informacije o svojstvima tla na istraživanoj lokaciji. Vrijednosti hidrauličkih parametara procijenjenih preko inverznog modeliranja pokazali su se bolji u odnosu na one određene u laboratoriju (pomoću HYPROP - a i WP4C sustava) prilikom simulacija u HYDRUS 1D modelu. Slične rezultate u svom istraživanju dobili su Nascimento i sur. (2018.) koji su uspoređivali laboratorijski određene (preko SYSTAT softvera) i inverznim modeliranjem procijenjene hidrauličke parametre na Argissolu. Rezultati njihovog istraživanja ukazuju na bolje i konzistentnije vrijednosti hidrauličkih parametara procijenjenih preko inverznog modeliranja, te ukazuju na činjenicu kako se korištenjem inverznog modeliranja može uštedjeti vrijeme i trud koji bi se inače utrošio na laboratorijska mjerenja odnosno određivanje hidrauličkih parametara tla.

5.4.4. Primjena kalibriranog HYDRUS 1D modela u opisu toka i retencije vode u tlu

Iako se simulacije za cijelo istraživano razdoblje sa hidrauličkim parametrima inverznog modeliranja, vizualnim pregledom može potvrditi praćenje trendova i poklapanje sa izmjerenim vrijednostima volumetrijskog sadržaja vode u tlu, verifikacijske mjere (R^2 , MAE , $RMSE$ – tablica 4.25. i 4.26.) nisu u potpunosti zadovoljavajuće.

Uspoređujući vrijednosti $RMSE$ – a za 2019. godinu vidljivo je poboljšanje u točnosti modela u odnosu na korištenje parametara iz ROSETTA softvera (od $0,013 - 0,238 \text{ cm}^3 \text{ cm}^{-3}$ iz ROSETTA – e u odnosu na $0,004 - 0,084 \text{ cm}^3 \text{ cm}^{-3}$ za optimizirane parametre). Vrijednosti $RMSE$ – a iz optimiziranih parametara za 2020. godinu kretale su se u rasponu od $0,010 \text{ cm}^3 \text{ cm}^{-3}$ do $0,072 \text{ cm}^3 \text{ cm}^{-3}$. Slične vrijednosti $RMSE$ – a u svom istraživanju dobili su i Wegehenkel i Beyrich (2014.) u iznosu od $0,02$ do $0,05 \text{ cm}^3 \text{ cm}^{-3}$.

Dobiveni R^2 u sklopu ove doktorske disertacije bio je lošiji za Bg u odnosu na Ap horizont. Chen i sur. (2014.) istraživali su režim vlažnosti tla pomoću HYDRUS modela kalibriranog na temelju TDR senzora postavljenih u tlu na širem području dva sliva u Novom južnom Walesu (Australija) tijekom trogodišnjeg razdoblja (2005. – 2007.). Istraživanje je rezultiralo uspješnom kalibracijom HYDRUS modela za simulaciju i predviđanje sadržaja vode u istraživanim uvjetima, na dubini od 30 cm, dok su se nešto slabiji rezultati dobili za sadržaj vode u tlu na većim dubinama (30 – 60 i 60 – 90 cm). Također, lošije vrijednosti R^2 za dublje slojeve tla dobili su i Wegehenkel i Beyrich (2014.).

Općenito, za 2019. i 2020. godinu (Slike 4.52. – 4.61.) može se primijetiti kako model u većini situacija pokazuje jaču reakciju na oborine u odnosu na TDR senzore (poglavito u Ap horizontu). Slične rezultate u svom istraživanju zabilježili su i De Alcântara i sur. (2021.), koji su primijetili da je model reagirao na oborine u slučajevima kada TDR senzori nisu. Međutim, uočljive su i situacije kada u Bg horizontu model uopće ne reagira na oborinu (dok TDR sensor reagira). S obzirom da R^2 ukazuje na to koliko dobro model opisuje varijabilnost mjerenja, ovakvo ne reagiranje na oborinu u Bg horizontu za posljedicu ima niže vrijednosti R^2 , u odnosu na Ap horizont. Ne reagiranje modela na oborinu u Bg horizontu mogao bi biti povezan sa teksturnim sastavom tla, odnosno sa smektitnim tipom gline koji u vlažnim uvjetima bubri dok se u sušnim dijelovima godine steže. Bubrenje odnosno stezanje gline u tlu ostavlja pukotine koje mogu djelovati kao preferencijalni tok i tako za vrijeme oborina poboljšati descendentne tokove vode u tlu (Greco, 2002.). Navedeno bi moglo uzrokovati da senzor na većoj dubini (90 cm) brže reagira na sadržaj vode u tlu u odnosu na senzor postavljen u Ap horizontu (30 cm), iako je on bliže površini.

Još jedan od razloga zašto bi moglo doći do izostanka odgovora modela na povećani sadržaj vode u Bg horizontu je pojava potpovršinskog lateralnog toka na pojedinim pozicijama obronka. Slične rezultate u svom istraživanju utvrdili su Le Bourgeois i sur. (2016.) koji su istraživali primjenu inverznog modeliranja (HYDRUS 1D) baziranog na NSGA – II algoritmu za opis sadržaja vlage u tlu na sredini obronka u pjeskovito ilovastom tlu na jugu Francuske. Istraživanje je provedeno na 12 slučajeva kišenja tijekom tri godine (2008. – 2010.), a količine oborina varirale su između 50 i 250 mm u trajanju od jednog do pet dana. Senzori za praćenje volumetrijskog sadržaja vlage u tlu bili su postavljeni na 20, 40 i 60 cm dubine. U pojedinim epizodama kiše, model nije reproducirao porast sadržaja vode u tlu na 60 cm. Autori su zaključili kako je podcjenjivanje modela vjerojatno rezultat pojave lateralnog potpovršinskog toka kojeg HYDRUS 1D model nije reproducirao.

De Alcântara i sur. (2021.) pratili su dinamiku vlažnosti tla u semiaridnom području Brazila na prirodnom i degradiranom (pašnjak) tlu pomoću TDR senzora i HYDRUS 1D modela. U svom istraživanju koristili su inverzno simuliranje u HYDRUS 1D softveru primjenom pet različitih hidrauličkih modela (jednostruke i dvostruke poroznosti te sa i bez primjene histereze poroznog sustava). Rezultati istraživanja ukazuju na činjenicu kako se za opis retencije vode i u prirodnom tlu mogu koristiti modeli (i model jednostruke i dvostruke poroznosti), međutim bolje rezultate na degradiranom tlu pokazao je model dvostruke poroznosti.

Navedeno bi moglo biti razlog ne dovoljno dobrom poklapanju modela jednostruke poroznosti sa izmjerenim vrijednostima sadržaja vlage u tlu u vlastitim istraživanjima. Naime za simulaciju toka i retencije vode korišten je HYDRUS 1D model jednostruke poroznosti. U skladu sa zaključcima istraživanja De Alcântara i sur. (2021.), a s obzirom da istraživano područje u sklopu ovog rada karakterizira antropogenizirano (degradirano) tlo vjerojatno bi primjena hidrauličkog modela dvostruke poroznosti dala bolje rezultate.

Promatrajući slike 4.57. do 4.61. vizualno je uočljivo bolje poklapanje simulacija i TDR senzora u razdoblju od kraja rujna do kraja 2020. godine. Navedeno bi moglo biti posljedica korištenja konstantne vrijednosti indeksa lisne površine (eng. *Leaf Area Indeks*) u ulaznim parametrima HYDRUS 1D modela. Naime, s obzirom da iz tehničkih razloga indeks lisne površine vinove loze nije određen na terenu, njegove vrijednosti preuzete su iz literature. Orlando i sur. (2016.) navode kako se indeks lisne površine vinove loze kreće u rasponu od 0,13 do 1,41.

Zbog veće bujnosti vinove loze na nižim u odnosu na više pozicije obronka za simulacije u HYDRUS 1D modelu, ovisno o poziciji, korištene su različite vrijednosti indeksa lisne površine. Isto tako drugačiji indeksi lisne površine uneseni su u model za red (za vinovu lozu) u odnosu na međuredni prostor koji je bio zatravnjen.

S obzirom da se indeks lisne površine mijenja tijekom vegetacije, a u HYDRUS 1D simulacijama je korištena konstantna vrijednost za cijelo istraživano razdoblje, za zaključiti je

kako je do ne poklapanja simuliranih i izmjerenih vrijednosti došlo upravo zbog navedenog faktora. Naime, povećanjem površine lišća (indeksa lisne površine) povećava se i transpiracija odnosno usvajanje vode iz tla.

Navedene pretpostavke potvrđuju istraživanja Rittera i sur. (2003.) koji su osim analize osjetljivosti WAVE modela na hidrauličke parametre, analizirali i osjetljivost modela na promjenu indeksa lisne površine. Testovima osjetljivosti utvrdili su da je indeks lisne površine parametar na koji je model osjetljiviji nego na neke hidrauličke parametre (npr. θ_r , α , K_s , I). Tako su, Wegehenkel i Beyrich (2014.) za simulacije sadržaja vode u tlu koristeći HYDRUS 1D inverzno modeliranje kao ulazne parametre koristili dnevne vrijednosti indeksa lisne površine. Indeks lisne površine procijenili su korištenjem WOFOST 6.0 modela.

Chen i sur. (2014.) navode kako su i hidraulička svojstva tla i indeks lisne površine imali najveći utjecaj na rezultate simulacija vlažnosti tla.

Još jedan razlog nepoklapanja simuliranih i izmjerenih vrijednosti sadržaja vlage u tlu tijekom dijela istraživanih razdoblja mogao bi biti zbog temporalne promjene hidrauličkih svojstava tla. Naime, Ket i sur. (2018.) temeljem rezultata svojih istraživanja ukazuju na problem korištenja konstantnih hidrauličkih parametara u simulacijama vodnog režima tla tijekom dužeg vremenskog perioda.

Imajući u vidu gore navedene činjenice, za poboljšanje rezultata simulacija potrebno bi bilo odrediti godišnji hod indeksa lisne površine i takve rezultate koristiti kao ulazne parametre za simulacije tijekom duljih vremenskih skala (npr. tijekom jedne godine).

Iako su simulacije korištenjem hidrauličkih parametara iz inverznog modeliranja uspješnije u odnosu na one iz HYPROP-a i ROSETTA softvera još uvijek nisu u potpunosti zadovoljavajuće. Međutim, sve navedeno treba uzeti s oprezom s obzirom da u simulacije nisu bili uključeni meteorološki podaci izmjereni točno na istraživanoj parceli (nego su preuzeti sa meteorološke postaje Karlovac). Nadalje, ovakav rezultat mogao bi se pripisati i temporalnoj varijabilnosti hidrauličkih značajki tla, koje su u ovom istraživanju određene na početku pokusa gdje su se njihove vrijednosti koristile za cijelo istraživano razdoblje. TDR senzori kao relativno novija tehnologija određivanja sadržaja vlage u tlu osjetljiva je na sadržaj i tip gline, sadržaj organske tvari u tlu, volumnu gustoću, temperaturu tla, što bi također moglo utjecati na rezultate izmjerene sensorima (Stangl i sur., 2009.). Unatoč ne zadovoljavajućim vrijednostima R^2 , a boljim vrijednostima MAE i RMSE, te relativno dobrim poklapanjem trendova izmjerenih i simuliranih vrijednosti sadržaja vlage u tlu, HYDRUS 1D model može se koristiti u procjeni režima vlažnosti u navedenim agroekološkim uvjetima.

5.4.5. HYDRUS 2D simulacije i klimatske predikcije

Rezultati simulacije infiltracije vode na dnu obronka HYDRUS 2D modelom ukazuju na veću infiltraciju u redu u odnosu na međuredni prostor (Slika 4.64.). Ista je situacija sa volumenom površinskog otjecanja, gdje su također veće vrijednosti utvrđene u redu. Veće vrijednosti infiltracije u redu u odnosu na međuredni prostor mogle bi se pripisati činjenici kako je u redu zabilježen veći volumen makropora koje utječu na veću infiltraciju u odnosu na međuredni prostor (objašnjeno u poglavlju 5.1.3.). Navedenu tvrdnju potvrđuju i rezultati istraživanja Zhang i sur. (2020.) koji navode kako korijen (živi i odumrli) povećava stopu infiltracije vode u tlo. Nadalje, veća infiltracija u redu u odnosu na međured mogla bi biti povezana sa intenzivnim prolascima traktora kroz međured što utječe na zbijenost, a samim time i na smanjenu infiltraciju u međurednom prostoru vinograda.

Isto tako, rezultati simulacije HYDRUS 2D modelom ukazuju na veće vrijednosti površinskog otjecanja u redu u odnosu na međuredni prostor (na donjoj poziciji obronka) (Slika 4.64.). Navedeno je vjerojatno povezano sa drugačijim fizikalnim (razlika u porozitetu između reda i međurednog dijela vinograda), hidrauličkim značajkama tla. Nadalje, ovakav rezultat moguće je posljedica i drugačijeg korijenovog sustava u redu (korijen vinove loze) i međurednog, zatravnjenog dijela vinograda.

Rezultati simulacije za jedan suhi i vlažni period u skladu su sa izmjerenim vrijednostima sadržaja vlage u tlu na istraživanom obronku. Naime, praćenjem režima vlažnosti najveća retencija vlage u tlu zabilježena je na gornjim (P1 i P2) u odnosu ostale pozicije obronka. Rezultati simulacije HYDRUS 2D modelom ukazuju na to da je najmanji sadržaj vlage u tlu zabilježen na P3 poziciji. Navedeni rezultati također su u skladu sa vrijednostima izmjerenim TDR sensorima. Razlike u sadržaju vode u tlu između reda i međureda te po pozicijama istraživanog obronka objašnjene su u poglavlju 5.3.

Tahir i sur., (2016.). proučavali su dinamiku režima vlažnosti tla na obronku i dostupnost vode biljci u uvjetima uzgoja citrusa i kikirikija u južnoj Kini od 2012. do 2014. godine. Sadržaj vlage u tlu konstantno je praćen primjenom FDR senzora na tri pozicije (gore, sredina i dno obronka) na dubinama od 5, 20, 40 i 80 cm. HYDRUS 2D uspješno je korišten za simuliranje sadržaja vode u tlu duž obronka. Isti autori navode kako je HYDRUS 2D najbolja alternativa mjerenju vlažnosti tla u situacijama kada podaci izmjereni sensorima nisu bili dostupni/izmjereni (npr. problemi sa *data loggerom*).

Basile i sur. (2020.) uspješno su koristili HYDRUS 2D model za simulacije toka vode na obronku u uvjetima uzgoja vinove loze. Tijekom dvije godine pratili su režim vlažnosti tla TDR sensorima (na dubini do 100 cm) na vrhu i dnu obronka. Cilj istraživanja bio im je utvrditi utjecaj hidrauličkih svojstava i nagiba obronka na vodni režim tla. Rezultati numeričkih simulacija ukazuju na značajniji utjecaj hidrauličkih svojstava tla na vodni režim u odnosu na nagib

obronka. Zhou i sur. (2007.) uspoređivali su APRI i HYDRUS 2D model za simulacije sadržaja vlage u tlu. Rezultati istraživanja ukazuju kako je APRI model dao bolje rezultate simulacije sadržaja vode u tlu u aridnim područjima u odnosu na HYDRUS 2D model.

5.4.6. HYDRUS 2D i simuliranje vodnog režima tla uslijed različitih klimatskih scenarija

Rezultati simulacija predikcija vodnog režima tla na istraživanom obronku međusobno se ne razlikuju s obzirom na izmijenjene klimatske scenarije. Takva neosjetljivost modela na promjene klimatoloških parametara vjerojatno je posljedica načina na koji su ti parametri određeni. Naime, klimatski scenariji korišteni kao ulazni parametri za predikciju režima vlažnosti tla u budućnosti procijenjeni su na temelju meteoroloških podataka izmjerenih tijekom 2020. godine i klimatskih scenarija predstavljenih u IPCC (2014.).

S obzirom na to uzeta su tri klimatska scenarija: blagi, srednji i ekstremni, gdje blagi predviđa porast temperature od 1,5 °C, srednji predstavlja porast temperature za 2,5 °C, a ekstremni za 3,5 °C. Količina oborina će se u zimskim mjesecima povećati, dok će tijekom ljeta prevladavati dulji periodi suše, s učestalijom pojavom ekstremnih oborina.

S obzirom da su klimatski scenariji napravljeni na temelju izmjena klimatskih podataka 2020. godine koja je klimatološki bila prosječna (bez ekstremnih kišnih perioda, duljih perioda suše ili ekstremnih temperatura) niti izmijenjeni klimatski scenariji nisu bili ekstremni u tom pogledu. Da se kao referentna godina uzela neka ekstremna godina, u kojoj su npr. zabilježene visoke količine oborina, sušni periodi ili ekstremne temperature, vjerojatno bi i klimatski scenariji imali značajan utjecaj na promjene u simuliranom režimu vlažnosti tla u budućnosti. Preporuka je da se za takve tipove predikcija koriste rezultati simulacija klimatoloških modela.

Međutim, iako predikcija režima vlažnosti tla, u budućnosti, s obzirom na izmijenjene klimatske scenarije nije polučila zadovoljavajuće rezultate, postoje istraživanja gdje se HYDRUS model koristi u tu svrhu.

Tako su Haghazari i sur. (2020.) koristili HYDRUS 2D/3D model za procjenu utjecaja klimatskih promjena na procjeđivanje vode i nitrata u uvjetima uzgoja uljane repice pod sustavom cijevne drenaže. U istraživanje je bilo uključeno četiri drenažna sustava koji su se razlikovali po dubini i razmaku postavljenih drenažnih cijevi. HYDRUS model prvo je kalibriran i validiran na temelju podataka isteka iz drenažnih cijevi tijekom dvije vegetacijske sezone. Nakon uspješne kalibracije i validacije, model je kasnije primijenjen za simulacije toka vode i nitrata u različitim sustavima odvodnje, u izmijenjenim meteorološkim uvjetima koji se očekuju u budućnosti. Klimatski scenariji preuzeti su od strane IPCC – a iz 2013., a predstavljali su klimatske projekcije za 2041. – 2070. godinu. Rezultati simulacija ukazuju da će klimatske

promjene uzrokovati povećanje količine odvodnje do 148 % te povećanje gubitaka nitrata iz različitih sustavi odvodnje u rasponu od 4 – 125 %.

Okello i sur. (2020.) istraživali su mogući utjecaj klimatskih promjena na vodni režim tla, s posebnim osvrtom na dubinsko procjeđivanje, površinsko otjecanje i sadržaj vode u tlu uz pomoć HYDRUS 1D programa. Blagi i ekstremni klimatski scenariji prilagođeni su temeljem IPCC – a iz 2013. za istraživano područje. Rezultati simulacija ukazuju da će dubinsko procjeđivanje i površinsko otjecanje biti veći 2100. godine u odnosu na referenti period (1986. – 2005.). Dubinsko otjecanje povećat će se za 14 % za blagi i 10 % za ekstremni scenarij, dok će se prosječne vrijednosti površinskog otjecanja povećati za 188 % za blagi i 284 % za ekstremni scenarij. Sadržaj vode u tlu za blagi scenarij porast će za 1 % dok će se za ekstremni scenarij smanjiti za 2 %.

6. ZAKLJUČAK

- Temeljem rezultata analiza fizikalnih i kemijskih svojstava tla na istraživanom obronku utvrđena je izrazita heterogenost svojstava tla. Na višim pozicijama obronka veći je sadržaj gline u odnosu na ostale pozicije. Sadržaj praha povećava se niz obronak, dok je sadržaj pijeska najveći na sredini obronka. Rezultati analiza fizikalnih svojstava tla vjerojatno su povezani s antropogenim utjecajem prilikom agrotehničkih melioracija na istraživanom području prilikom podizanja nasada vinograda.
- U istraživanim agroekološkim uvjetima tijekom jesensko/zimskog perioda na pojedinim pozicijama obronka dolazi do prekomjerne saturacije tla u trajanju dužem od 120 dana/godina. Na poziciji P1 u potpovršinskom Bg horizontu utvrđena je prisutnost saturacijskih uvjeta u tlu u trajanju od 186 dana. Na poziciji P3, također u međurednom prostoru, utvrđeno je trajanje prekomjerne saturacije tijekom čitavog razdoblja istraživanja, odnosno tokom 538 dana. Kod P4 pozicije prekomjerna saturacija utvrđena je u redu vinograda u trajanju od 361 dan. Prekomjerna saturacija na pojedinim pozicijama može se objasniti heterogenim svojstvima tla, prvenstveno teksturnim sastavom. Navedeno djelomično opovrgava hipotezu o izostajanju trajanja prekomjerne saturacije na istraživanom obronku.
- Heterogenost svojstava tla na obronku izrazito utječe na različitu retenciju vode u tlu istraživanog obronka. Više pozicije na obronku (P1 i P2) imaju najveći volumetrijski sadržaj vode u tlu tijekom istraživanog razdoblja u odnosu na ostale pozicije obronka. Navedene pozicije imaju i najveći sadržaj gline u profilu koja pozitivno korelira sa sadržajem, odnosno retencijom vode u tlu. S obzirom na to, može se zaključiti kako na sadržaj vode u tlu utječu svojstva tla (teksturni sastav i hidraulička svojstva) te pozicija na obronku, što potvrđuje hipotezu o utjecaju reljefa te hidrauličkih parametara na tok i retenciju vode u tlu.
- Što se tiče utjecaja korijena na tok i retenciju vode u tlu utvrđene su izraženije oscilacije sadržaja vode u tlu tijekom godine u redu u odnosu na međuredni prostor vinograda. Tako je veći sadržaj vlage u tlu u Ap horizontu utvrđen u redu, dok je za Bg horizont veći sadržaj vlage utvrđen u međurednom prostoru vinograda. Razlog tome je različita dubina proraštenosti tla korijenom u redu u odnosu međured. S obzirom na navedeno, može se zaključiti kako i volumen tla koji je prorašten korijenom ima značajan utjecaj na tok i retenciju vode u tlu. S obzirom na takve rezultate, možemo potvrditi hipotezu kako je režim vlažnosti i tok vode u tlu pod utjecajem korijena vinove loze.

- Rezultati ovog istraživanja ukazuju na činjenicu da se primjenom kalibriranog numeričkog modela (HYDRUS 1D i HYDRUS 2D/3D) može pouzdano utvrditi tok i retencija vode u istraživanim agroekološkim uvjetima. Veliku pažnju prilikom kalibracije numeričkog modela potrebno je posvetiti određivanju hidrauličkih značajki tla jer one najviše utječu na rezultate simulacija. Osim hidrauličkih značajki tla, jedan od najvažnijih parametara jesu meteorološki parametri, prvenstveno količina oborina, te parametri uzgajanje kulture (npr. dubina i gustoća korijenovog sustava, indeks lisne površine). Navedena tvrdnja potvrđuje hipotezu da se primjenom numeričkog modela može pouzdano utvrditi tok i retencija vode u istraživanim agroekološkim uvjetima.
- U procjeni hidrauličkih parametara van Genuchten bimodal (HYPROP–FIT softveru) dao je bolje vrijednosti *RMSE*–a u odnosu na van Genuchten original model. Općenito, van Genuchten bimodal model preporučljivo je koristiti u heterogenim tlima, gdje porozni sustav nije uniforman.
- Pojedine simulacije uz korištenje hidrauličkih parametara iz HYPROP i WP4C sustava i preko pedotransfernih funkcija u ROSETTA softveru nisu konvergirale, dok su sve simulacije s hidrauličkim parametrima iz inverznog načina simuliranja bile stabilne te su pokazale najbolje rezultate simulacija. Imajući u vidu navedeno, može se zaključiti kako kod nedostatka ili ne zadovoljavajućih terenskih i/ili laboratorijskih mjerenja inverzno simuliranje može poslužiti kao dobar izvor hidrauličkih parametara potrebnih za simulacije.
- Primjenom, u radu kalibriranog i validiranog modela, moguća je simulacija različitih klimatskih scenarija u vidu klimatskih promjena. Prilikom takvih simulacija posebnu pažnju trebalo bi posvetiti ulaznim klimatskim parametrima. Klimatski parametri trebali bi se uzimati iz klimatoloških modela, koji mogu dati informacije o predviđenim klimatskim parametrima za točno određeno (istraživano) područje.
- Kalibrirani TDR senzori kao relativno novija tehnologija praćenja volumetrijskog sadržaja vode daju relativno točan podatak o količini vode u tlu na istraživanoj lokaciji. Povećanjem broja senzora može se dobiti veća rezolucija toka i retencije vode u tlu što omogućuje kvalitetniju kalibraciju modela. Korištenje većeg broja, ali i drugih tipova senzora za praćenje količine vode u tlu, može dati vrlo precizne podatke o režimu vlažnosti tla ako su TDR senzori tvornički kalibrirani, međutim zbog točnijih podataka

dobivenih putem TDR senzora preporuča se kalibraciju izvršiti i na terenu temeljem gravimetrijske metode.

- Temeljem analiza rezultata simulacija i vlastitih zapažanja tijekom istraživanja, a u svrhu uspješnijeg korištenja modela u narednim (sličnim) istraživanjima preporuča se:
 - posebnu pažnju posvetiti određivanju hidrauličkih značajki tla, gdje se njihove vrijednosti za dulje simulacije (npr. godinu dana) ne bi trebale uzimati kao konstantne s obzirom da su promjenjive u vremenu,
 - odrediti oscilacije indeksa lisne površine tijekom vegetacije s obzirom da se te vrijednosti također ne bi trebale uzimati kao konstantne
 - posebnu pažnju posvetiti proraštenosti tla korijenom treba detaljno odrediti s obzirom da je to jedan od ulaznih parametara u modelu koji značajno utječe na rezultate simulacija,
 - u svrhu bolje kalibracije (i validacije) modela preporuča se postavljanje većeg broja senzora (prvenstveno u površinskim slojevima tla koji su najizloženiji promjenama u sadržaju vlage) po dubini profila, a posebno u vertikalno heterogenim tlima.

7. LITERATURA

1. Al Majou, H. Bruand, A., Duval, O., Cousin, I. (2008.) Prediction of soil water retention properties after stratification by combining texture, bulk density and the type of horizon. *Soil Use Manage*, 24: 383-391.
2. Alvarez – Acosta, C., Lascano, R.J., Stroosnijder, L. (2012.) Test of Rosetta Pedotransfer Function for Saturated Hydraulic Conductivity. *Open Journal of Soil Science*, 2(3): 203-212
3. Amami, R., Ibrahim, K., Sher, F., Milham, P., Ghazouani, H., Chehaibi, S., Hussain, Z., Iqbal, H.M.N.(2021). Impacts of Different Tillage Practices on Soil Water Infiltration for Sustainable Agriculture. *Sustainability* 13: 3155
4. Aubertin, G. M., Kardos, L.T. (1965.) Root growth through porous media under controlled conditions,"*Soil Science of America Proceedings*, 29: 290–293.
5. Basile, A., Albrizio, R., Autovino, D., Bonfante, A., De Mascellis, R., Terribile, F., Giorio, P. (2020.) A modelling approach to discriminate contributions of soil hydrological properties and slope gradient to water stress in Mediterranean vineyards. *Agricultural Water Management*, 241:106338
6. Begum, F., Bajracharya, R. M., Sharma, S., Sitaula, B. K. (2010). Influence of slope aspect on soil physico-chemical and biological properties in the mid hills of central Nepal. *Int. J. Sustain. Dev. World*, 17:438–443.
7. Beven, K. i Germann, P. (2013.) Macropores and water flow in soils revisited. *Water Resour. Res.* 49, 3071–3092.
8. Bezerra – Coelho, C.R., Zhuang, L., Barbosa, M.C., Alfaro Soto, M. van Genuchten, M.Th. (2018.) Further tests of the HYPROP evaporation method for estimating the unsaturated soil hydraulic properties. *Y. Hydrol. Hydromech.*, 66 (2) 161-169
9. Biddoccu, M., Ferraris, S., Pitacco, A., Cavallo, E. (2017.) Temporal variability of soil management effects on soil hydrological properties, runoff and erosion at the field scale in a hillslope vineyard, North-West Italy. *Soil Tillage Res.*, 165, 46–58
10. Biddoccu, M., Ferraris, S., Opsi, F., Cavallo, E. (2016.) Long-term monitoring of soil management effects on runoff and soil erosion in sloping vineyards in Alto Monferrato (North–West Italy). *Soil Tillage Res.* 155: 176–189
11. Bodner, G., Leitner, D., Kaul, H.P. (2014.) Coarse and fine root plants affect pore size distributions differently. *Plant Soil.*, 380: 133–151.
12. Bognar, A. (1978.) Les i lesu slični sedimenti Hrvatske. *Hrvatski geografski glasnik*, 40(1): 21-38.
13. Bogunović, I., Bilandžija, D., Andabaka, Z., Stupic, D., Rodrigo-Comino, J., Cacic, M., Brezinscak, L., Maletic, E., Pereira, P. (2017.) Soil compaction under different management practices in a Croatian vineyard. *Arab. J. Geosci.*, 10: 1–9.

14. Bogunović, M., Vidaček, Ž., Racz, Z., Husnjak, S., Špoljar, A., Sraka, M. (1998.) FAO/Unesco Croatian soil map, small scale 1:1000000, University of Zagreb, Faculty of Agriculture, project Monitoring Agriculture with Remote Sensing
15. Bodhinayake, W., Si, B.C. (2004.) Near-saturated surface soil hydraulic properties under different land uses in the St Denis National Wildlife Area, Saskatchewan, Canada. *Hydrol. Process.* 18, 2835-2850
16. Böhm, W. (1979.) *Methods of studying root systems* (Ecological studies vol. 33), Springer-Verlag Berlin
17. Brillante, L., Mathieu, O., Lévêque, J., van Leeuwen, C., Bois, B. (2017.) Water status and must composition in grapevine cv. Chardonnay with different soils and topography and a mini meta-analysis of the $\delta^{13}\text{C}$ /water potentials correlation. *J. Sci. Food Agric.* 98, 691–697.
18. Brocca L., Ciabatta L., Massari C., Camici S. and Tarpanelli A. (2017.) Soil Moisture for Hydrological Applications: Open Questions and New Opportunities, *Water*, 9(2), 140.
19. Brooks, R. H., Corey, A.T. (1964.) Hydraulic properties of porous media. *Hydrol.* 3:1–27, Colorado State Univ., Fort Collins
20. Buckingham, E. (1907.) *Studies on the movement of soil moisture*. U.S.Dept. of Agr. Bur. Of Soils. Bull. 38.
21. Cantón, Y., Solé-Benet, A., Domingo, F. (2004.) Temporal and spatial patterns of soil moisture in semiarid badlands of SE Spain. *J Hydrol* 285, 199-214.
22. Carroll, C., Merton, L., Burger, P. (2000.) Impact of vegetative cover and slope on runoff, erosion, and water quality for field plots on a range of soil and spoil materials on central Queensland coal mines. *Soil Res.*, 38, 313–328.
23. Carsel, R.F., Parrish, R.S. (1988.) Developing joint probability distributions of soil water retention characteristics. *Water Resour. Res.* 24, 755–769.
24. Celette, F., Gaudin, R., Gary, C. (2008.) Spatial and temporal changes to the water regime of a Mediterranean vineyard due to the adoption of cover cropping. *Eur J Agron.*, 29:153-162.
25. Centeno A., Baeza P., Lissarrague, J. R. (2010.) Relationship between soil and plant water status in wine grapes under various water deficit regimes. *Horttechnology*, 20(3): 585-593
26. Cerdan, O., Govers, G., Le Bissonnais, Y., Van Oost, K., Poesen, J., Saby, N., Gobin, A., Vacca, A., Quinton, J., Auerwald, K., Klik, A., Kwaad, F. J. P. M., Raclot, D., Ionita, I., Rejman, J., Rousseva, S., Muxart, T., Roxo, M. J., Dostal, T. (2010.) Rates and spatial variations of soil erosion in Europe: A study based on erosion plot data. *Geomorphology*, 122, 167–177.
27. Chaudhari, P. R., Ahire, D. V., Ahire, V. D., Chkravarty, M., Maity, S. (2013.) Soil bulk density as related to soil texture, organic matter content and available total nutrients of Coimbatore

- soil. *Int. J. Sci. Res.* 3, 1–8.
28. Chaves, M.M. Zarrouk, O., Francisco, R., Costa, J.M., Santos, T., Regalado, A.P., Rodrigues, M.L., Lopes, C.M. (2010.) Grapevine under deficit irrigation, hints from physiological and molecular data. *Ann Bot* 105: 661-676.
 29. Cheyns, K., Mertens, J., Diels, J., Smolders, E., Springael, D. (2010.) Monod kinetics rather than a first-order degradation model explains atrazine fate in soil mini-columns: Implications for pesticide fate modelling. *Environ. Pollut* 158: 1404-1411.
 30. Choné, X., Van Leeuwen, C., Dubourdieu, D., Gaurillères, J.P. (2001.) Stem water potential is a relative sensitive indicator of grapevine water status. *Ann Bot* 87: 477-483.
 31. Coolong, T., Snyder, J., Warner, R., Strang, J., Surendran, S. (2012.) The Relationship Between Soil Water Potential, Environmental Factors, and Plant Moisture Status for Poblano Pepper Grown Using Tensiometer – Scheduled Irrigation. *International Journal of Vegetable Science*. 18:137 – 152.
 32. Cooper, J. D. (2016.). *Soil water measurement. A practical handbook*, Wiley Blackwell
 33. Crave, A., Gascuel-Oudoux, C. (1997). The influence of topography on time and space distribution of soil surface water content. *Hydrological Processes* 11: 203–210.
 34. Ćirić M. (1984). *Pedologija*. Svjetlost, Sarajevo
 35. Da Costa, A., Albuquerque, J.A., da Costa, A., Pértile, P., da Silva, F.R. (2013.) Water retention and availability in soils of the state of Santa Catarina – Brasil: Effect of textural classes, soil classes and lithology. *R. Bras. Ci. Solo*. 37: 1535-1548
 36. Dane, J.H., Topp, G. C. (2002.) *Methods of Soil Analysis*. Dio 4. Physical Methods. (Eds.). Soil Science Society of America Book Series 5. Madison, Wisconsin.
 37. De Alcântara, L. R. P., Coutinho, A. P., dos Santos Neto, S. M., de Gusmão, C., da Cunha R. A.E., Antonino, A.C.D. (2021.) Modeling of the Hydrological Processes in Caatinga and Pasture Areas in the Brazilian Semi-Arid. *Water*, 13, 1877.
 38. Defterdarović, J., Filipović, L., Kranjčec, F., Ondrašek, G., Kikić, D., Novosel, A., Mustać, I., Krevh, V., Magdić, I., Rubinić, V., Bogunović, I., Dugan, I., Čopeć, K. He, H., Filipović, V. (2021.) Determination of Soil Hydraulic Parameters and Evaluation of Water Dynamics and Nitrate Leaching in the Unsaturated Layered Zone: A Modeling Case Study in Central Croatia. *Sustainability*. 13, 6688
 39. Deloire A., Vaudour E., Carey V., Bonnardot V. and van Leeuwen C. (2005.) Grapevine responses to terroir: A global approach. *J. Int. Sci. Vigne Vin*, 39 (4): 149-162
 40. Deumlich D., Schmidt R., Sommer M. (2010.) A multiscale soil–landform relationship in the glacial-drift area based on digital terrain analysis and soil attributes. *J. Plant Nutr. Soil Sci.*, 173: 843–851.
 41. Domínguez-Niño, J. M., Arbat, G., Raji-Hoffman, I., Kisekka, I., Girona, J., Casadesús, J. (2020.) Parametrization of Soil Hydraulic Parameters for HYDRUS-3D Simulation of Soil

Water Dynmics in a Dryp-Irrigated orchard. Water,1858

42. Dorigo, W. A., Wagner, W., Hohensinn, R., Paulik, C., Xaver, A., Gruber, A., Drusch, M., Mecklenburg, S., van Oevelen, P., Robock, A., Jackson, T. (2011.) The International Soil Moisture Network: A data hosting facility for global in situ soil moisture measurements. *Hydrol. Earth Syst. Sci.*, 15, 1675–1698.
43. Dousset, S., Thevenot, M. Pot, V. Šimůnek, J. Andreux. F. (2007.). Evaluating equilibrium and non-equilibrium transport of bromide and isoproturon in disturbed and undisturbed soil columns. *J. Contam. Hydrol.* 94 (3-4): 261-276.
44. Dreibrodt, S., Lomax, J., Nelle, O., Lubos, C., Fischer, P., Mitusov, A., Reiss, S., Radtke, U., Nadeau, M., Grootes, P.M., Bork, H.R. (2010.). mAre mid-latitude slopes sensitive to cli-matic oscillations? Implications from an early Holocene sequence of slope depositsand buried soils from eastern Germany. *Geomorphology* 122, 351–369.
45. Drinkwater, L.E. (2009.) *Ecological Knowledge: foundation for sustainable organic agriculture in organic farming: the ecological system.* Cornell University, Ithaca, Ed Charles Francis.
46. Durner, W. (1994.) Hydraulic conductivity estimation for soils with heteroge- neous pore structure. *Water Resour Res* 30: 211–223.
47. Durner, W., Flüher, H. (2005.) *Soil Hydraulic Properties*, Encyclopedia of hydrological sciences, John Wiley & Sons.
48. Durner, W., Lipsius, K. (2005.) *Determining Soil Hydraulic Properties.* Encyclopedia of Hydrological Sciences, edited by M.G. Anderon, Jonh Wiley & Sons.
49. Egli, M., Sartori, G., Mirabella, A., Favilli, F., Giacci, D., Delbos, E. (2009.) Effect of north and south exposure on organic matter in high Alpine soils, *Geoderma*149:124-136.
50. Famiglietti, J. S., Rudnicki, J. W., Rodell, M. (1998.) Variability in surface moisture content along a hillslope transect: Rattlesnake Hill, Texas. *J. Hydrol.*, 210, 259–281.
51. Fantaw, Yimer, Ledin, S., Abdelkadir, A. (2006.) Soil property variations in relation to topographic aspect and vegetation community in south-eastern highlands of Ethiopia. *For. Ecol. Manag.* 232, 90–99.
52. FAO, (2021.) *FAOSTAT Database.* Food and Agriculture Organization of the United Nations. [Online] Available at: [http://www.fao.org/ faostat/en/#data/QC](http://www.fao.org/faostat/en/#data/QC) [Pristupljeno: 23. ožujka 2021].
53. FAO, (2006.) *Guidelines for soil description.* fourth ed. FAO, Rome.
54. Filipović, V., Coquet, Y., Gerke, H.H. (2019.) Representation of Plot-Scale Soil Heterogeneity in Dual-Domain Effective Flow and Transport Models with Mass Exchange. *Vadose Zone J.* 18:180174.

55. Filipović, V., Coquet, Y., Pot, V., Houot, S., Benoit, P. (2014.) Modeling the effect of soil structure on water flow and isoproturon dynamics in an agricultural field receiving repeated urban waste compost application. *Sci Total Environ*, 16424.
56. Filipović, V., Coquet Y., Pot, V., Houot, S., Benoit, P. (2016.) Modeling water and isoproturon dynamics in a heterogeneous soil profile under different urban waste compost applications, *Geoderma* 268, 29-40.
57. Filipović, V., Defterdarović, J., Šimůnek, J., Filipović, L. (2020.) Estimation of vineyard soil structure and preferential flow using dye tracer, X-ray tomography, and numerical simulations, *Geoderma* 380 (2-3):114699
58. Filipović, V., Gerke, H. H., Filipović, L., Sommer, M. (2018a.) Quantifying Subsurface Lateral Flow along Sloping Horizon Boundaries in Soil Profiles of a Hummocky Ground Moraine, *Vadose Zone Journal*, p 12.
59. Filipović, L., Mešić, M., Weninger, T., Schwen, A., Novosel, A., Maretić, M., Filipović, V. (2019.) Effect of fire-induced water repellency on soil hydraulic properties and water flow, *Agric. conspec. sci.* 84: 2.
60. Filipović, V. Weninger, T. Filipović, L. Schwen, A. Bristow, K. L. (2018b.) Zechmeister-Boltenstern, S.; Leitner, S. Inverse Estimation of Soil Hydraulic Properties and Water Repellency Following Artificially Induced Drought Stress. *J. Hydrol. Hydromech.* 66: 170–180.
61. Fredlund, D. G. i Xing, A. (1994.) Equations for the Soil-Water Characteristic Curve. *Canadian Geotechnical Journal.* 31: 521-532.
62. Gaiser, T., Graef, F., Cordeiro, J. C. (2000.) Water retention characteristics of soils with contrasting clay mineral composition in semi-arid tropical regions. *Aust. J. Soil Res.*, 38: 523-526.
63. Gajić – Čapka M. I Zaninović K. (2008.) *Klima Hrvatske*. U: Zaninović K. Gajić – Čapka M., Perčec Tadić M. *Klimatski atlas Hrvatske – Climate Atlas of Croatia 1961.-1990., 1971.-2000.* DHMZ. Zagreb.
64. García-Díaz, A., Bienes, R., Sastre, B., Novara, A., Gristina, L., Cerdà, A. (2017.) Nitrogen losses in vineyards under different types of soil groundcover. A field runoff simulator approach in central Spain. *Agric. Ecosyst. Environ.* 236: 256–267.
65. Garg, K. K., Jha, M. K. Kar, S. (2005.) Field investigation of water movement and nitrate transport under perched water table conditions, *Biosyst. Eng.*, 92, 69-84
66. Gerke, H. H. (2006.) Preferential flow descriptions for structured soils, *Journal of Plant Nutrition and Soil Science*, Vol. 169(3): 382-400
67. Gerke, H. H., Hierold, W. (2012.) Vertical bulk density distribution in C – horizons from marley till as indicator for erosion history in a hummocky post – glacial soil landscape. *Soil and Tillage research.* 125: 116-122-

68. Ghestem, M., Sidle R.C., Stokes, A. (2011.) The influence of plant root systems on subsurface flow: implications for slope stability. *BioScience* 61: 869–879.
69. Gill, H. K., Garh, H. (2014.) Pesticides: environmental impacts and management strategies, u *Pesticides – Toxic aspects*, ed. Solenski, S., Larramendy, M.L., Marcelo, L. 187 – 230.
70. Gerrits, A. M. J., Pfister, L., Savenije, H. H. G. (2010.) Spatial and temporal variability of canopy and forest floor interception in a beech forest. *Hydrol. Process.*, 24: 3011–3025.
71. Greco, R. (2002.) Preferential flow in macroporous swelling soil with internal catchment: model development and applications. *Journal of Hydrology* 269: 150 – 168.
72. Guo, L. i Lin, H. (2018.) Chapter 2 - Addressing Two Bottlenecks to Advance the Understanding of Preferential Flow in Soils. *Advances in Agronomy*, 147: 61-117.
73. Haghighi, F., Gorji, M., Shorafa, M. (2010.) A study of the effects of land use changes on soil physical properties and organic matter. *Land degradation and development*, 21 (5), 496-502.
74. Haghnazari, F., Karandish, F., Darzi – Naftchali, A., Šimůnek, J. (2020.) Dynamic assessment of the impacts of global warming on nitrate losses from a subsurface – drained rainfed – canola field. *Agricultural Water Management*. 242:104420.
75. Haghverdi, A., Najarchi, M., Öztürk, H.S. Durner, W. (2020). Studying Unimodal, Bimodal, PDI and Bimodal – PDI Variants of Multiple Soil Water Retention Models: I. Direct Model Fit Using the Extended Evaporation and Dewpoint Methods. *Water*.12:900
76. Hamza H., Elbekkay M., Ben Abederrahim M. A., Ferchichi A. (2011). Molecular and morphological analyses of date palm (*Phoenix dactylifera* L.) subpopulations in southern Tunisia, *Spanish Journal of Agricultural Research* 9 (2): 488.
77. Hanson, J. D., Ahuja, L. R., Schaffer, M. D., Rojas, K. W., DeCoursey, D. G., Farahani, H., Johnson, K. (1998). RZWQM: Simulating the effects of management on water quality and crop production. *Agric. Syst.* 57(2):161-195
78. Hanson, B. R., Šimůnek, J., Hopmans, J. W. (2006.) Evaluation of urea-ammonium-nitrate fertigation with drip irrigation using numerical modeling. *Agric. Water Mgmt.* 86 (1-2): 102-113.
79. Hardie M. A., Doyle R. B., Cotching W. E., Lisson S. (2012). Subsurface lateral flow in texture-contrast (duplex) soils and catchments with shallow bedrock, *Apple. Environ. Soil. Sci.* 86:1358.
80. Hendgen, M., Döring, J., Stöhrer, V., Schulze, F., Lehnart, R., Kauer. R. (2020.) Spatial Differentiation of Physical and Chemical Soil Parameters under Integrated, Organic, and Biodynamic Viticulture. *Plants*, 9: 1361
81. Hillel, D. (2004). *Introduction to Environmental Soil Physics*. Elsevier Academic Press, New York
82. Horel, A., Lichner, L., Alaoui, A., Czachor, H., Nagy, V., Tóth, E. (2014.) Transport of iodide

- in structured clay–loam soil under maize during irrigation experiments analyzed using HYDRUS model, *Biologia* 69(11): 1531—1538.
83. Horn R., Smucker A. (2005). Structure Formation and its Consequences for gas and water transport in unsaturated arable and forest soils. *Soil & Till. Res.* 82/5:14
 84. HRN ISO 11508. (2004). Kakvoća tla - Određivanje gustoće čvrstih čestica (ISO 11508:1998), Hrvatski zavod za norme, Zagreb.
 85. HRN ISO 11271. (2004). Kakvoća tla - Određivanje volumne gustoće tla u suhom stanju - Hrvatski zavod za norme, Zagreb.
 86. HRN ISO 10390. (2005). Kakvoća tla - Određivanje pH-vrijednosti (ISO 10390:2005), Hrvatski zavod za norme, Zagreb.
 87. HRN ISO 11464. (2009). Kakvoća tla - Priprema uzorka za fizikalno-kemijske analize (ISO 11464:2006), Hrvatski zavod za norme, Zagreb.
 88. HRN ISO 11277. (2011). Kvaliteta tla - Određivanje raspodjele veličine čestica (teksturnog sastava) u mineralnom dijelu tla - Metoda prosijavanja i sedimentacije (ISO 11277:2009), Hrvatski zavod za norme, Zagreb.
 89. Hu, W., Si, B. C. (2014.) Revealing the relative influence of soil and topographic properties on soil water content distribution at the watershed scale in two sites. *J. Hydrol.*, 516: 107–118.
 90. Huang, J., Yu, H., Guan, X., Wang, G., Guo, R. (2016.) Accelerated dryland expansion under climate change. *Nat. Clim. Change*, 6(2): 166–171.
 91. Hupet, F., Lambot, S., Javaoux, M., Vanclooster, M. (2002.) On the identification of macroscopic root water uptake parameters from soil moisture observations. *Water Resour. Res.* 38 (12): 1300
 92. Husnjak S., Bogunović M., Šimunić I. (2002.) Soil Moisture Regime of Ameliorated Gleyic Stagnosol. *Agric. conspec. sci.* 67(4): 169-179
 93. Husnjak, S. (2014.) *Sistematika tala Hrvatske*, Hrvatska sveučilišna naklada, Zagreb.
 94. Huston, J.L ., Wagenet, R.J. (1989.) *LEACHM: Leaching Estimation and Chemistry Model—A Process Based Model of Water and Solute Movement, Transformations, Plant Uptake and Chemical Reactions in the Unsaturated Zone*; Version 2; Centre for Environmental Research, Department of Agronomy, Cornell University: Ithaca, NY, USA, 148.
 95. Indoria, A.K, Sharma, K.L., Reddy, K.S., Rao, C.S. (2017.) Role of physical properties in soil health management and crop productivity in rainfed system. I: Soil physical constraints and scope. *Curr. Sci.* 112(12): 2405–2414.
 96. IPCC (International Panel on Climate Change) (2014.) *Climate change 2014: Impacts, Adaption, and Vulnerability*.
 97. IUSS Working Group WRB. *World Reference Base for Soil Resources* (2014.) Update

- 2015: International soil classification system for naming soils and creating legends for soil maps; World Soil Resources Reports: 106; FAO: Rome, Italy, pp. 192.
98. Jakšik, O., Kodešová, R., Kubiš, A., Stehlíková, I., Drábek, O., Kapička, A. (2015.) Soil aggregate stability within morphologically diverse areas. *Catena*, 127: 287–299.
 99. Jarvis, N. J. (2007.) A review of non-equilibrium water flow and solute transport in soil macropores: Principles, controlling factors and consequences for water quality, *European Journal of Soil Science*, 58(3): 523-546.
 100. JDPZ, (1966.) Metoda po Tjurinu. Kemijske metode istrativanja zemljišta, Beograd.
 101. Jenny, H. (1980). The soil resource, origin and behavior. Springer, New York.
 102. Jenny, H. (1994.) Factors of soil formation: a system of quantitative pedology. Dover Publications, Inc. New York.
 103. Jimoh, I., Yau, S. L., Essoka, P. (2020.) Impact of Land use/cover on Pedogenetic Forms of Iron and Manganese in Afaka Forest Reserve, Northern Guinea Savanna Zone of Nigeria, *Nigerian Journal of Soil and Environmental Research* 19(1): 52 – 60
 104. Joel, A., Messing, I., Seguel, O., Casanova, M. (2002.) Measurement of surface water runoff from plots of two different sizes. *Hydrol. Process.* 16 (7): 1467–1478.
 105. Julich, S., Krieselmeier, J., Scheibler, S., Petzold, R., Schwärzel, K., Feger, K.H. (2021.) Hydraulic Properties of Forest Soils with Stagnic Conditions. *Forests* 12, 1113
 106. Jurišić, A., Kisić, I., Zgorelec, Ž., Kvaternjak, I. (2012.) Influence of water erosion on copper and sulphur distribution in vineyard soils. *J. Environ. Prot. Ecol.* 13/2A, 880-889.
 107. Kanzari S., Ben Nouna B., Rezig M., Ben Mariem S. (2018.) HYDRUS 1-D model calibration and validation in various field conditions for simulating water flow and salts transport in a semi-arid region of Tunisia. *Sustain. Environ. Res.* 28(6): 350-356
 108. Ket, P., Oeurng, C. Degré, A. (2018.) Estimating Soil Water Retention Curve by Inverse Modelling from Combination of In Situ Dynamic Soil Water Content and Soil Potential Data. *Soil. Sist.* 2: 55.
 109. Khan, S., Chao, C., Waqas, M., Arp, H.P.H., Zhu, Y.G. (2013.) Sewage sludge biochar influence upon rice (*Oryza sativa* L) yield, metal bioaccumulation and greenhouse gas emissions from acidic paddy soil. *Environ. Sci. Technol.* 47: 8624–8632.
 110. Khormali, F., Ayoubi, S., Foomani, F. K., Fatemi, A., Hemmati, K. (2007.) Tea yield and soil properties as affected by slope position and aspect in Lahijan area, Iran. *Int. J. Plant Prod.*, 1: 245–259.
 111. Kim H.J., Sidle R. C., Moore R .D. (2005). Shallow lateral flow from a forested hillslope: influence of antecedent wetness. *Catena* 60(3): 293-306.

112. Kisić, I., Bašić, F., Nestroy, O., Mesić, M., Butorac, A. (2002.) Chemical properties of eroded soil material. *J Agron Crop Sci.* 188(5): 323-334.
113. Kizilkaya, R., Dengiz, O. (2010.) Variation of land use and land cover effects on some soil physico-chemical characteristics and soil enzyme activity. *Zemdirb Agric*, 97(2):15–24.
114. Kobierski, M. (2013.) Morphology, properties and mineralogical composition of eroded Luvisols in selected morainic areas of the Kujavian and Pomeranian Province. University of Technology and Life Sciences, Bydgoszcz (in Polish with English summary).
115. Kodešová, R., Kodeš, V., Zigova, A., Šimůnek, J. (2006.) Impact of plant roots and soil organisms on soil micromorphology and hydraulic properties. *Biologia*, 61(19): 339–343.
116. Köhne, J. M., Köhne, S., Šimůnek, J. (2006.) Multi-process herbicide transport in structured soil columns: Experiment and model analysis. *J. Contam. Hydrol.* 85:1–32.
117. Kosugi, K. (1996). Lognormal distribution model for unsaturated soil hydraulic properties. *Water Resour. Res.* 32, 2697–2703.
118. Kotingo, K. E. (2015). Toposequence analysis of soil properties of an agricultural field in the Obudu mountain slopes, Cross River State-Nigeria. *Eur. J. Phys. Agric. Sci.*, 3 (1).
119. Kreiselmeier, J., Chandrasekhar, P., Weninger, T., Schwen, A., Julich, S., Feger, K. H., Schwärzel, K. (2019). Quantification of soil pore dynamics during a winter wheat cropping cycle under different tillage regimes. *Soil Tillage Res.* 192: 222–232.
120. Lai, J. i Ren, L. (2016.) Estimation of Effective Hydraulic Parameters in Heterogeneous Soils at Field Scale. *Geoderma*, 264: 28–41.
121. Lang, A. (2003.) Phases of soil erosion-caused colluviation in the loess hills of South Germany . *Catena* 51: 209-221.
122. Lange, B., Lüescher, P., Germann, P. F. (2009.) Significance of tree roots for preferential infiltration in stagnic soils. *Hydrol. Earth Syst. Sci.* 13: 1809–1821.
123. Lanyon, D. M., Cass, A., Hansen, D. (2004.) The effect of soil properties on vine performance. CSIRO Land and Water Technical Report 34/04.
124. Le Bourgeois, O., Bouvier, C., Brunet, P. Ayral, P.A. (2016.) Inverse modeling of soil water content to estimate the hydraulic properties of a shallow soil and the associated weathered bedrock. *Journal of Hydrology, Elsevier, Flash, Floods, Hydro-geomorphic response and risk management*, 541: 116 – 126.
125. Leterme, B., Mallants, D. (2011.) Climate and land use change impacts on groundwater recharge. In *Proc. ModelCARE2011: Models - Repositories of Knowledge*. Wallingford, U.K. IAHS Press.
126. Li, S., Liang, W., Zhang, W., Liu, Q. (2016.) Response of soil moisture to hydro - meterological variables under different precipitation gradients in the Yellow River basin. *Water Resour. Manag.* 30: 1867–1884.
127. Li, Y., Wang, X. F., Cao, Z .K., Si, B. C. (2017.) Water repellency as a function of soil

- water content or suction influenced by drying and wetting processes. *Can. J. Soil Sci.* 97: 226–240.
128. Liang, W. L., Hung, F. X., Chan, M. C., Lu, T. H. (2014.) Spatial structure of surface soil water content in a natural forested headwater catchment with a subtropical monsoon climate. *J. Hydrol.* 516: 210–221.
 129. Liu, L., Gudmunsson, L., Hauser, M., Qin, D., Li, S., Seneviratne, S. I. (2020.) Soil moisture dominates dryness stress on ecosystem production globally, *Nature Communications* 11: 4892.
 130. Lucas, M., Schlüter, S., Vogel, H.J., Vetterlein, D. (2019.) Roots compact surrounding soil depending on the structures they encounter, *Scientific reports* 9:16236
 131. Luxmore, R.J., (1981.) Micro-, meso- and macroporosity of soil. *Soil Sci.Soc. Am.J.* 45: 241 – 245.
 132. Lopes, C.M., Santos, T. P., Monteiro, A., Rodrigues, M. L., Costa, J. M., Chaves, M. M. (2011.) Combination cover cropping with deficit irrigation in a Mediterranean low vigor vineyard. *Sci Hortic* 129: 603 – 612.
 133. Mallants, D., D. Jacques, and T. Zeevaert. (2003). Modeling ²²⁶Ra, ²²²Rn, and ²¹⁰Pb migration in a proposed surface repository of very low-level long-lived radioactive waste. Paper No. ICEM03-4632. In *Proc. ICEM2003: 9th Intl. Conf. on Radioactive Waste Mgmt. and Environ. Remediation*, 823-830. New York, N.Y.: ASME.
 134. Mallman, F. J. K., Reinheimer, D. S., Ceretta, C. A., Cella, C., Minella, J. P. G., Guma, R.L., Filipović, V., van Oort, F., Šimunek, J. (2014). Soil tillage to reduce surface metal contaminant: Model development and simulations of zinc and copper concentration profile in a pig slurry-amended soil. *Agric. Ecosyst. Environ.* 196:59-68.
 135. Malicki, M. A., Plagge, R., Roth, C. H. (1996.) Improving the calibration of dielectric TDR soil moisture determination taking into account the solid soli. *Eur. J. Soil Sci.* 47: 357-366.
 136. Marquardt. D. W. (1963.) An algorithm for least-squares estimation of nonlinear parameters. *SIAM J. Appl. Math*, 11: 431-441.
 137. Mayer, S., Kühnel, A., Burmeister, J., Kögel-Knabner, I., Wiesmeier, M. (2019.) Controlling factors of organic carbon stocks in agricultural topsoils and subsoils of Bavaria. *Soil Tillage Res.*, 192: 22–32.
 138. Mirás – Avalos, J. M., Araujo, E. S. (2021.) Optimization of Vineyard Water Management: Challenges, Strategies, and Perspectives. *Water* 13(6): 746
 139. Mirošević, N., Alpeza, I., Bolić, J., Brkan, B., Hruškar, M., Husnjak, S., Jeleska, V., Karoglan Kontić, J., Maletić, E., Mihaljević, B., Ričković, M., Šestan, I., Zorčić, M. (2009.) *Atlas Hrvatskog vinogradarstva i vinarstva*, Golden marketing, Tehnička knjiga, Zagreb.
 140. Mohanty, B. P., Cosh, M., Lakshmi, V., Montzka, C. (2017.) Soil moisture remote

- sensing: State-of-the-science. *Vadose Zone Journal*, 16(1): 1– 9.
141. Molina, A.J., Llorens, P., Garcia-Estringana, P., Moreno se las Heras, M., Cayuela, C., Gallart, F., Latron, J. (2019.) Contribution of throughfall, forest and soil characteristics to near-surface soil water-content variability at the plot scale in a mountains Mediterranean area. *Sci. Total Environ.* 647: 1421-1432.
 142. Moore, I. D., Gessler, P. E., Nielsen, G. A., Petersen, G. A. (1993.) Soil attribute prediction using terrain analysis. *Soil Sci Soc Am J.* 57: 443-452.
 143. Mualem, Y. (1976.) A new model for predicting the hydraulic conductivity of unsaturated porous media, *Water Resour. Res.* 12: 593-622
 144. Mulugeta, D., Sheleme, B. (2010.) Characterization and Classification of soil along toposequence of Kyndo Koye Watershed in Southern Ethiopia. *East African Journal of Sciences.* 4(2): 65-77.
 145. Musters, P. A. D., Bouten, W., Verstraten. J. M. (2000.) Potentials and limitations of modeling vertical distributions of root water lands. uptake of an Austrian pine forest on a sandy soil. *Hydrol. Processes* 14: 103–115.
 146. Nagarajah, S. (1987.) Effects of Soil Texture on the Rooting Patterns of Thompson Seedless Vines on Own Roots and on Ramsey Rootstock in Irrigated Vineyards, *Am J Enol Vitic.* January 38: 54-59
 147. Nascimento, Í. V., AssisJ, R. N., Araujo, J. C., Alencar, T. L., Freire, A. G., Lobato, M. G. R., Silva, C. P., Mota, J. C. A., Nascimento, C. D. V. (2018.) Estimation of van Genuchten equation parameters in laboratory and through inverse modeling with Hydrus-1D. *J. Agric. Sci.* 10(3).
 148. Niemann, K. O., Edgell, M. C. R. (1993.) Preliminary analysis of spatial and temporal distribution of soil moisture on a deforested slope, *Phys. Geogr.*, 14(5): 449–464
 149. NN 76/19 – Narodne novine(9.8.201.) Pravilnik o zemljopisnim područjima uzgoja vinove loze, Ministarstvo poljoprivrede Republike Hrvatske
 150. Noguchi, S., Tsuboyama, Y., Sidle, R. C., Hosoda, I. (1999). Morphological Characteristics of Macropores and the Distribution of Preferential Flow Pathways in a Forested Slope Segment. *Soil Sci. Soc. Am. J.* 63: 1413–1423.
 151. Okello, C., Greggio, N., Soile Giambasitani, B.M., Wambiji, N., Nzeve, J., Antonellini, M. (2020.) Modelling Projected Changes in Soil Water Budget in Coastal Kenia under Different Long – Term Climate Change Scenarios. *Water* 12: 2455.
 152. Ollinger, S. V., Smith, M. L., Martin, M. E., Hallett, R. A., Goodale, C. L., Aber, J. D. (2002.) Regional variation in foliar chemistry and N cycling among forests of diverse history and composition. *Ecology.* 83: 339–355.

153. Orlando, F., Movedi, E., Coduto, D., Parisi, S., Brancadoro, L., Pagani, V., Guarneri, T., Confalonieri, R. (2016.) Estimatin Leaf Area Indeks (LAI) in Vineyards Using the PocketLAI Smart-App, *Sensors* (Basel). 16(12): 2004.
154. Pagliali, M., Vignozz, N., (2002.) The soil pore system as an indicator of soil quality, *Advances in geoecology*, 35: 69-80.
155. Patil, N. G., Singh, S. K. (2016.) Pedotransfer Functions for Estimating Soil Hydraulic Properties: A Review. *Pedosphere*. 26 (4):417-430.
156. Petošić D., Tomić F. (2011.) Reguliranje suvišnih voda. Agronomski fakultet sveučilišta u Zagrebu. Zagreb.
157. Pierson F. B. i Mulla D. J. (1990.) Aggregate stability in the Palouse region of Washington: Effect of landscape position. *Soil Science Society of American Journal*, vol. 54 (5):1407-1412.
158. Pirastru, M., Niedda, M. (2013.) Evaluation of the soil water balance in an alluvial flood plain with a shallow groundwater table. *Hydrol Sci J*. 58(4): 898-911.
159. Poni, S., Gatti, M., Palliotti, A., Dai, Z., Duchêne, E., Truong, T.T., Ferrara, G., Matarrese, A.M.S., Gallotta, A., Bellincontro, A., Mencarelli, F., Tombesi, S. (2018.) Grapevine quality: a multiple choice issue. *Sci. Hortic*. 234: 445–462.
160. Pot, V., Šimůnek, J., Benoit, P., Coquet, Y., Yra, A., Martínez-Cordón, M. J. (2005.) Impact of rainfall intensity on the transport of two herbicides in undisturbed grassed filter strip soil cores. *J. Contam. Hydrol*. 81(1-4): 63-88.
161. Provost, C., Pedneault, K. (2016.) The organic vineyard as a balanced ecosystem:improved organic grape management and impacts on wine quality. *Sci. Hortic*. 2018: 43-56.
162. Przewoźna, B. (2014.) Changes of bulk density, air-water properties and morphology of soils in basins without outlets as an effect of erosion and anthropogenic denudation (a study from northwestern Poland). *Soil. Sci. Plant. Nutr*. 60(1): 30-37.
163. R Core Team (2016). *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria.
164. RStudio Team (2016.) *RStudio: Integrated Development for R*. RStudio, Inc., Boston, MA.
165. Racz, Z. (1980.) *Meliorativna pedologija I dio*, Zagreb: Geodetski fakultet Sveučilišta u Zagrebu.
166. Radcliffe D. E., Šimůnek J. (2010.) *Soil Physics with HYDRUS, Modeling and Applications*, CRC Press.
167. Rasse, D. P., Smucker, A. J. M., Santos, D. (2000.) Alfalfa root and shoot mulching effects on soil hydraulic properties and aggregation. *Soil Sci. Soc. Am. J.*, 64(2): 725–731.

168. Rastija, D., Loncaric, Z., Karalic, K., Bensa, A. (2008.) Liming and fertilization impact on nutrient status in acid soil. *Cereal Res. Commun.* 36: 399–342.
169. Razaei, H. Jafarzadeh, A. A. Alijanpour, A. Shahbazi, F. Kamran, K. V. (2015.) Effect of Slope Position on Soil Properties and Types Along an Elevation Gradient of Arasbaran Forest, Iran. *Int. J. Adv. Sco. Eng. Inf. Technol.* 5: 2088–5334.
170. Resulović, H., Čustović, H. (2002.) *Pedologija. Opšti dio (knjiga 1)* Univerzitet u Sarajevu.
171. Resulović H., Čustović H., Čengić I. (2008.) *Sistematika tla/zemljišta: Nastanak, svojstva i plodnost.* Poljoprivredno-prehrambeni fakultet Univerziteta u Sarajevu. Sarajevo
172. Reynolds, W. D., Bowman, B. T., Brunke, R. R., Drury, C. F., Tan, C. S. (2000.) Comparison of Tension Infiltrometer, Pressure Infiltrometer, and Soil Core Estimates of Saturated Hydraulic Conductivity. *Soil Sci. Soc. Am. J.* 64: 478–484.
173. Reynolds, A. G., Lowrey, W. D., Tomek, L., Hakimi, J., De Savigny, C. (2007.) Influence of irrigation on vine performance, fruit composition, and wine quality of Chardonnay in a cool, humid climate. *Am. J. Enol. Vitic.*, 58: 217-228.
174. Rieckh, H., Gerke, H. H., Sommer, M. (2012.) Hydraulic properties of characteristic horizons depending on relief position and structure in a hummocky glacial soil landscape. *Soil Tillage Res.*, 125:123–131.
175. Ritter, A., Hupet, F., Muñoz-Carpena, R., Lambot, Vanclosser, M. (2003). Using inverse methods for estimating soil hydraulic properties from field data as an alternative to direct methods, *Agricultural Water Management*, 59 (2):77-96
176. Robinson, D. A., Hopmans, J. W., Filipović, V., van der Ploeg, M., Lebron, I., Jones, S. B., Reinsch, S., Jarvis, N., Tuller, M. (2019.) Global environmental changes impact soil hydraulic functions through biophysical feedbacks, *Global change biology* 25 (6): 1895-1904.
177. Rodrigo-Comino, J., Senciales González, J.M., Ramos, M.C., Martínez-Casasnovas, J.A., Lasanta Martínez, T., Brevik, E.C., Ries, J.B., Ruiz-Sinoga, J.D., (2017a.) Understanding soil erosion processes in Mediterranean sloping vineyards (Montes de Málaga, Spain). *Geoderma* 296:47–59.
178. Rodrigo-Comino, J., Brings, C., Iserloh, T., Casper, M. C., González, Senciales, Seeger, M., Brevik, E.C., Ruiz-Sinoga, J.D., Ries, J.B. (2017b.) Temporal changes in soil water erosion on sloping vineyards in the Ruwer-Mosel Valley. The impact of age and plantation works in young and old vines. *J. Hydrol. Hydromech.* 65.
179. Romano, N., Nasta, P., Severino, G., Hopmans, J. W. (2011.) Using Bimodal Lognormal Functions to Describe Soil Hydraulic Properties. *Soil Sci. Soc. Am. J.* 75: 468–480.
180. Romano, N., Palladino, M. (2002.) Prediction of soil water retention using soil physical

- data and terrain attributes, *Journal of Hydrology* 265(1-4):56-75.
181. Rosenbaum, U., Bogaen, H. R., Herbst, M., Huisman, J. A. (2012.) Seasonal and event dynamics of spatial soil moisture patterns at the small catchment scale, *Water Resour. Res.* 48.
 182. Rubinić, V., Durn, G., Husnjak, S., Tadej, N. (2014.) Composition, properties and formation of Pseudogley on loess along a precipitation gradient in the Pannonian region of Croatia. *Catena*, 113:138-149.
 183. Rubinić, V., Galović, L., Husnjak, S., Durn, G. (2015b.). Climate vs. parent material – Which is the key of Stagnosol diversity in Croatia? *Geoderma* 241/242: 250-261.
 184. Rubinić, V., Husnjak, S. (2016.) Clay and humus contents have the key impact on physical properties of Croatian pseudogleys. *Agriculturae Conspectus Scientificus*, 81 (4): 187-191.
 185. Rubinić V., Lazarević B., Husnjak S., Durn G., (2015a.). Climate and relief influence on particle size distribution and chemical properties of Pseudogley soils in Croatia. *Catena*, 127C: 340-348.
 186. Sajid, M., Ahmad, S., Jaskani, M.J., Yasin, M. (2018.) Optimum weed control method increases the yield of kinnow by improving the physical properties of soil. *Planta Daninha*. 36: 018168903.
 187. Sarapatka, B., Cap, L., Bila, P. (2018.) The varying effect of water erosion on chemical and biochemical soil properties in different parts of Chernozem slopes. *Geoderma*, 314: 20–26.
 188. Scanlon, B., Keese, K., Reedy, R. C., Šimůnek, J., Andraski, B. (2003.) Variations in flow and transport in thick desert vadose zones in response to paleoclimatic forcing (0 - 90 kyr): Monitoring, modeling, and uncertainties. *Water Resour. Res.* 39(7): 131-137.
 189. Schaap, M. G., Leij, F. J., van Genuchten, M. T. (2001). ROSETTA: a computer program for estimating soil hydraulic parameters with hierarchical pedotransfer functions, *J. Hydrol.*, 251: 163–176.
 190. Schelle, H., Hiese, L., Jänicke, K., Durner, W. (2013.) Water retention characteristics of soils over the whole moisture range: a comparison of the laboratory methods. *European Journal of Soil Science*, 64, 814-821.
 191. Schindler, U., Müller, L. (2017.) Soil hydraulic functions of international soils measured with the Extended Evaporation Method (EEM) and the HYPROP device. *Open Data J. Agric. Res.* 3, 10–16-
 192. Schindler, U., von Unold, G., Durner, W., Müller, L. (2010.) Evaporation method for measuring unsaturated hydraulic properties of soil: extending the range. *Soil. Sci. Soc.Am.J.* 74: 1071–1083

193. Schneider, F., Don, A., Hennings, I., Schmittmann, O., Seidel, S.J. (2017.) The effect of deep tillage on crop yield – What do we really know? *Soil & Tillage Research*, 147: 193-204.
194. Schoeneberger, P. J., Wysocki, D. A. Benham, E. C., Soil Survey Staff. (2012.) Field book for describing and sampling soils, Version 3.3. Natural Resources Conservation Service, National Soil Survey Center, Lincoln, NE.
195. Scholander, P. F., Hammel, H. T., Bradstreet, E. D., Hemmingsen, E. A. (1965.) Sap pressure in vascular plants. *Science* 148: 339-46.
196. Seneviratne, S. I., Corti, T., Davin, E. L., Hirschi, M., Jaeger, E. B., Lehner, I., Orlowsky, B., and Teuling, A. J. (2010.) Investigating soil moisture-climate interactions in a changing climate: A review, *Earth-Sci. Rev.*, 99: 125–161.
197. Sheffield, J., Wood, E.F., Chaney, N., Guan, K., Sadri, S., Yuan, X., Olang, L., Amani, A., Ali, A., Demutch, S., Ogalo, L. (2014.) A drought monitoring and forecasting system for sub-Saharan African water resources and food security. *Bull. Amer. Meteor. Soc.*, 95, 861–882.
198. Sheleme, B. (2011.) Soil characterization along toposequence in Gununo area, southern Ethiopia. *J. Sci. Dev.* 1(1): 31-39.
199. Silliman, S., Berkowitz, B., Šimůnek, J., van Genuchten, M. Th. (2002.) Fluid flow and chemical migration within the capillary fringe. *Ground Water* 40(1): 76-84.
200. Siltecho, S., Hammecker, C., Sriboonlue, V., Clermont-Dauphin, C., Trelo-ges, V., Antonino, A.C.D., Angulo-Jaramillo, R. (2015.) Use of field and laboratory methods for estimating unsaturated hydraulic properties under different land uses. *Hydrol. Earth Syst. Sci.* 19: 1193–1207.
201. Smart, R., Bonfiglioli, R., Magarey, P. (1995.) Grapevine yellows disease: Avoiding a potential threat to Australia Chardonnay production, *Australian Grapegrower & Winemaker*, 408:11-17.
202. Smart, D. R., Schwass, E., Morano, L., Lakso, A. N. (2006.) Grapevine root distributions: A comprehensive analysis and a review. *Am J Enol Vitic*, 56, 157-168.
203. Stangl, R., Buchan, G.D., Loiskandl, W. (2009.) Field use and calibration of TDR – based probe for monitoring water content in a high – clay soil in Austria. *Geoderma*. 150: 23 – 31.
204. Sun, S., Zhang, G., He, T., Song, S., Chu, X. (2021.) Effect of Landscape Positions and Landscape Type on Soil Properties Chlorophyll Content of Citrus in a Sloping Orchard in the Tree Gores Reservoir Area, China. *Sustainability*, 13, 4288.
205. Śintowiak, M. (2014.) Use of soil profile truncation to estimate influence of accelerated erosion on soil cover transformation in young morainic landscapes, north-eastern Poland. *Catena* 116:173–184.

206. Šilkić, K., Basch, O., Šimunić, A. (1979.) Osnovna geološka karta SFRJ 1:100 000, Tumač za list Zagreb L33 – 80- Insitut za geološka istraživanja, Zagreb (1972); Savezni geološki insititut, Beograd.
207. Šimůnek J., van Genuchten M. Th., Šejna M. (2012.) HYDRUS: Model use, validation and calibration, American Society of Agricultural and Biological Engineers, Vol. 55(4): 1261-1274.
208. Šimůnek, J., van Genuchten, M. Th. Šejna, M. (2005.) The HYDRUS-1D software package for simulating the one-dimensional movement of water, heat, and multiple solutes in variably-saturated media. Version 3.0. HYDRUS Softw. Ser. 1. Dep. of Environ. Sci. Univ. of California, Riverside, CA.
209. Šimůnek J., van Genuchten M. Th., Šejna M. (2016.) Recent Developments and Applications of the HYDRUS Computer Software Packages. Vadose Zone J. 15(7). 1- 25.
210. Škorić, A. (1986.) Postanak razvoj i sistematika tla. Fakultet poljoprivrednih znanosti Sveučilišta u Zagrebu, Zagreb.
211. Škorić, A. (1991.) Sastav i svojstva tla. Fakultet poljoprivrednih znanost Sveučilišta u Zagrebu, Zagreb.
212. Tahir, M., Lw, Y., Gao, L., Hallett, P.D., Peng, X. (2016.) Soil water dynamics and availability for citris and peanut along a hillslope an the Sunjia Red Soil Critical Zone Observatory (CZO). Soil and Tillage Research, 163: 110 – 118.
213. Tanveera, A., Kanth, T. A., Tali, P. A., Naikoo, M. (2016.) Relation of soil bulk density with texture, total organic matter content and porosity in the soil of Kandi Area of Kashmir valley, India. Int. Res. J. Earth Sci., 4 (1): 1-6.
214. Telak, L.J., Dugan, I., Bogunovic, I. (2021). Soil Management and Slope Impacts on Soil Properties, Hydrological Response, and Erosion in Hazelnut Orchard. Soil Syst., 5:5.
215. Thomas, M. A., Collins, B. D., Stock, J. D., Corbett, S. C., Schmidt, K. M., Reid, M. E., Mirus, B. B., Lu, N., Godt, J. W., Coe, J. A. (2017.) Field data used to support hydrologic modeling for the U.S. Geological Survey's San Francisco Bay Area "BALT1" landslide monitoring site (U.S. Geological Survey Data Release). Reston, VA: U.S. Geological Survey.
216. Ticehurst, J. L., Cresswell, H. P., McKenzie, N. J., Clover, M. R. (2007.) Interpreting soil and topographic properties to conceptualise hillslope hydrology. Geoderma 137: 279-292
217. Torri, D., Poesen, J., Borselli, L. (1997.) Predictability and uncertainty of the soil erodibility factor using a global dataset. Catena, 31, 1–22.
218. Trought, M. C. T., Dixon, R., Mills, T., Greven, M., Agnew, R., Mauk, J. L., Praat, J. P. (2008.) The impact of differences in soil texture within a vineyard on vine vigour, vine earliness and juice composition. Journal International des Sciences de la Vigne et du Vin, 42(2): 62-72.

219. UMS (2012.) HYPROP - Laboratory evaporation method for the determination of pF-curves and unsaturated conductivity, http://www.ums-muc.de/en/products/soil_laboratory.html [pristupljeno: 26.travnja 2021.].
220. UMS (2015.) HYPROP-FIT User Manual. UMS GmbH, München, Germany, Str. 37, 81379 http://www.ums.muc.de/static/Manual_HYPROP-FIT.pdf. [Pristupljeno: 26. travnja 2021.].
221. Ursulino, B. S., Montenegro, S. M. G. L., Coutinho, A. P., Rabelo Coelho, V. H., dos Santos Araujo, D. C., Villar Gusmao, A. C., dos Santos Neto, S. M., Lassatere, L., Angulo – Jaramillo, R. (2019). Modeling soil water dynamics from soil hydraulic parameters estimated by an alternative method in a Tropical Experimental Basin. *Water*, 11, 1007.
222. USDA, (2014.) Soil Bulk density/Moisture/Aeration, Soil Health-Guidelines for Educators, United States Department of Agriculture, Natural Resource Conservation Service
223. Van Dam, J. C., Huygen, J., Wesseling, J. G., Feddes, R. A., Kabat, P., van Walsum, P. E. V., Groenendijk, P., van Diepen, C. A. (1997). Theory of SWAP version 2.0. Simulation of water flow, solute transport and plant growth in the Soil- Water-Atmosphere-Plant environment. Wageningen University and Alterra. Technical Document 45.
224. van Genuchten M. Th. (1980.) A closed form equation for predicting the hydraulic conductivity of unsaturated soils, *Soil Sci. Soc. Am. J.* 44: 892-898.
225. van Leeuwen C., Tregoat O., Chone X., Bois B., Pernet D., Gaudillere J. P. (2009). Vine water status is a key factor in grape ripening and vintage quality for red Bordeaux wine. How can it be assessed for vineyard management purposes? *Journal international des sciences de la vigne et du vin*, 43: 3.
226. van Leeuwen, C., Friant, Ph., Chone, X., Trégoat; O., Koundouras, S., Dubourdieu, D., (2004). Influence of climate, soil and cultivar on terroir. *Am. J. Enol. Vitic.*, 55: 207-217.
227. van Schaik, N. L. M. B., Schnabel, S., Jetten, V. G. (2008.) The influence of preferential flow on hillslope hydrology in a semiarid watershed (in the Spanish Dehesas), *Hydrol. Process.* 22: 3844-3855.
228. Vereecken, H., Kama, T., Harter, T., Kasteel, R., Hopmans, J. W., Huisman, J. A., Vanderborght, J. (2008,) Comment on “Field observations of soil moisture variability across scales” by James S. Famiglietti et al. *Water Resour. Res.*, 44: 12601.
229. Vepraskas, M. J. Williams, J. P. (1995.) Hydraulic Conductivity of Saporlite as a Function of Sample Dimensions and Measurement Technique, *Soil. Sci.. Soc. Am. J.* 59
230. Virto, I., Antón, R., Apesteguía, M., Plante, A. (2018.) Role of carbonates in the physical stabilization of soil organic matter in agricultural Mediterranean soils. In *Soil Management and Climate Change*; Munoz, M.A., Zornoza, R., Eds.; Academic Press: Cambridge, MA, USA, 121–136.

231. Wanders, N., D. Karssenberg, A. de Roo, S. M. de Jong, M. F. P. Bierkens, (2014.) The suitability of remotely sensed soil moisture for improving operational flood forecasting. *Hydrol. Earth Syst. Sci.* 18: 2343–2357.
232. Wang, J., Fu, B., Qiu, Y., Chen, L. (2001.) Soil nutrients in relation to land use and landscape position in semi-arid small catchment of the loess plateau in China. *J. Arid Environ.* 48: 537–550.
233. Wang, X., Zhao, X., Zhang, Z., Yi, L., Zuo, L., Wen, Q., Liu, B. (2016.) Assessment of soil erosion change and its relationships with land use/cover change in China from the end of the 1980s to 2010. *Catena*, 137: 256–268.
234. Warrick A., Wierenga P., Pan L. (1997.) Downward water flow through sloping layers in the vadose zone: analytical solutions for diversions. *J Hydrol* 192 (1): 321-337
235. Wegehenkel, M., Beyrich, F. (2014.) Modelling of hourly evapotranspiration and soil water content at the grass-covered boundary-layer field site Falkenberg, Germany. *Hydrological Sciences Journal*, 59 (2): 376–394.
236. Wehrhan, A., R. Kasteel, J. Šimůnek, J. Groeneweg, and H. Vereecken. (2007.) Transport of sulfadiazine in soil columns: Experiments and modeling approaches. *J. Contam. Hydrol.* 89(1-2): 107-135.
237. Weil R. R., Brady N. C. (2016.) *The Nature and Properties of Soils*, Pearson Publishing
238. Weiler, M., McDonnell, J. J., van Meerveld, I. T., Uchida, T. (2005.) Subsurface Stormflow, *Encyclopedia of hydrological sciences*, edited by M. G. Anderson. John Wiley and Sons, Ltd.
239. Weninger, T. Bodner, G. Kreiselmeier, J. Chandrasekhar, P. Julich, S. Feger, K. H. Schwärzel, K. Schwen, A. (2018). Combination of Measurement Methods for a Wide-Range Description of Hydraulic Soil Properties. *Water*, 10: 1021.
240. Western, A. W., Zhou, S. L., Grayson, R. B., McMahon, T.A., Blöschl, G., Wilson, D. J. (2004.) Spatial correlation of soil moisture in small catchments and its relationship to dominant spatial hydrological processes. *J. Hydrol.*, 286: 113–134
241. White, R.E. (2015.) *Understanding vineyard soils*, Second edition. Oxford university press.
242. Wiaux, F., Cornelis, J. T., Cao, W., Vanclooster, M., Van Oost, K. (2014.) Combined effect of geomorphic and pedogenic processes on the distribution of soil organic carbon quality along an eroding hillslope on loess soil. *Geoderma*, 216: 36-47.
243. Williams, L. E., Araujo, F. J. (2002.) Correlation among predawn leaf, midday leaf, and midday stem water potential and their correlation with other measurements of soil and plant water status in *Vitis vinifera*. *J Am Soc Hortic Sci* 127(3): 448 – 454.


244. Williams, L. E. Trout, T. J. (2005.) Relationship among vine- and soil. Based measures of water status in a Thompson Seedless vineyard in response to high – frequency drip irrigation. *Am J Enol Vitic* 56(4): 357 – 366.
245. Wiśniewski, P., Märker, M. (2021.) Comparison of Topsoil Organic Carbon Stocks on Slopes under Soil-Protecting Forests in Relation to the Adjacent Agricultural Slopes, *Forests* 2021, 12(4): 390.
246. Wösten, J.H.M., Lilly, A., Nemes, A., Le Bas, C. (1999.) Development and use of a database of hydraulic properties of European soils. *Geoderma* 90, 169–185.
247. Yakirevich, A., Gish, T. J., Šimůnek, van Genuchten, M. Th., Pachepsky, Y. A., Nicholson, T. J., Cady. R. E. (2010.) Potential impact of a seepage face on solute transport to a pumping well. *Vadose Zone J.* 9(3): 686-696.
248. Yuste, J., Gutiérrez, I., Rubio, J.A., Alburquerque, M.V. (2004.) Leaf and stem water potential as vine water status indicators in Tempranillo grapevine under different water regimes in the Duero Valey. *J Int Des Sci* 38: 21 – 26.
249. Zhang, D., Dai, Y., Wang, L., Chen, L. (2020.) Influence of Living and Dead Roots of GansuPoplar on Water Infiltration and Distribution in Soil, *Appl. Sci.* 10: 3593.
250. Zhao, X. K., Li, Z. Y., Zhu, Q. K. (2016.) Response of Soil moisture on climate characteristics based on SPI and SPEI in Loess Region of Northern Shaanxi. *Trans. Chin. Soc. Agric. Mach.*, 47, 155–163.
251. Zhou, Q., Kang, S., Zhang, L., Li, F. (2007.) Comparison of APRI and HYDRUS 2D models to simulate soil water dynamisc in a vineyard under alternate partial root zone drip irrigation. *Plant Soil*, 291: 211 – 223.
252. Zhu, Y. J., Shao, M. A. (2008.) Variability and pattern of surface moisture on a small-scale hillslope in Liudaogou catchment on the northern Loess Plateau of China. *Geoderma*, 147: 185–191.
253. Ziadat, F. M., Taimeh, A. Y., Hattar, B. I. (2010.) Variation of soil physical properties and moisture content along toposequence in the arid to semiarid area. *Arid. Land Res. Manag.* 24: 81-97.

Popis internetskih stranica

1. <https://geoportal.dgu.hr/> [pristupljeno: 20. siječnja 2021.]

8. PRILOZI

PRILOG 1



Slika 8.1. Prikaz reljefa lokacije danas (lijevo) i 1968. godine (desno). Prilagođeno preko DGU <https://geoportal.dgu.hr/> [pristupljeno: 20. siječnja 2021.]

PRILOG 2



Slika 8.2. Detalj prevlaka pore – tip redoks koncentracije uz korijen i duž makropore na poziciji P3 u potpovršinskom horizontu.

PRILOG 3

Tablica 8.1. Volumetrijski sadržaj vlage [$\text{cm}^3 \text{ cm}^{-3}$] u tlu određen gravimetrijskom metodom tijekom 2019. godine

Datum (2019.)	P1				P2				P3				P4				P5			
	Međured		Red		Međured		Red		Međured		Red		Međured		Red		Međured		Red	
	Ap	Bg	Ap	Bg	Ap	Bg	Ap	Bg	Ap	Bg	Ap	Bg	Ap	Bg	Ap	Bg	Ap	Bg	Ap	Bg
31.1.	0,466	0,418	0,450	0,465	0,488	0,388	0,436	0,425	0,393	0,462	0,371	0,460	0,397	0,355	0,327	0,397	0,393	0,409	0,383	0,440
27.2.	0,435	0,431	0,410	0,433	0,393	0,426	0,380	0,356	0,338	0,417	0,365	0,392	0,397	0,542	0,351	0,519	0,411	0,362	0,359	0,396
29.3.	0,428	0,437	0,456	0,390	0,479	0,508	0,378	0,431	0,397	0,439	0,374	0,399	0,422	0,544	0,399	0,536	0,412	0,358	0,399	0,428
26.4.	0,449	0,427	0,433	0,397	0,397	0,465	0,392	0,431	0,358	0,405	0,329	0,470	0,385	0,570	0,348	0,458	0,412	0,384	0,350	0,396
22.5.	0,491	0,453	0,422	0,459	0,480	0,436	0,424	0,474	0,395	0,466	0,364	0,473	0,376	0,493	0,373	0,465	0,375	0,416	0,376	0,403
1.7.	0,418	0,466	0,414	0,440	0,410	0,442	0,375	0,385	0,301	0,407	0,327	0,378	0,287	0,444	0,307	0,447	0,320	0,378	0,336	0,387
17.7.	0,401	0,489	0,400	0,485	0,413	0,498	0,305	0,515	0,418	0,412	0,386	0,395	0,357	0,398	0,354	0,398	0,396	0,377	0,354	0,396
19.8.	0,419	0,473	0,398	0,451	0,420	0,468	0,366	0,452	0,360	0,441	0,383	0,454	0,366	0,485	0,371	0,503	0,403	0,392	0,371	0,410
9.9.	0,452	0,479	0,410	0,440	0,420	0,475	0,367	0,433	0,359	0,435	0,379	0,441	0,362	0,485	0,370	0,494	0,416	0,398	0,366	0,401
3.10.	0,481	0,463	0,407	0,426	0,449	0,491	0,407	0,423	0,416	0,427	0,391	0,427	0,401	0,483	0,370	0,486	0,425	0,400	0,385	0,401
14.10.	0,454	0,454	0,375	0,421	0,433	0,486	0,384	0,420	0,397	0,425	0,378	0,422	0,387	0,477	0,362	0,476	0,405	0,392	0,374	0,399
18.11	0,470	0,462	0,465	0,464	0,466	0,497	0,420	0,489	0,414	0,491	0,389	0,468	0,405	0,502	0,373	0,505	0,427	0,404	0,389	0,441
16.12.	0,440	0,450	0,440	0,447	0,433	0,457	0,392	0,467	0,396	0,481	0,372	0,462	0,393	0,488	0,355	0,485	0,413	0,399	0,378	0,438

* Uzorkovanja tla za određivanje trenutne vlage provedena su samo tijekom 2019. godine: Uzorkovanje je provedeno svaki put u drugom redu i međurednom prostoru vinograda po istim izohipsama gdje su postavljeni TDR senzori za konstantno očitavanje sadržaja vlage u tlu

ŽIVOTOPIS AUTORA

Ivan Magdić rođen je 30. kolovoza 1990. godine u Ogulinu. Nakon završene osnovne škole u Ogulinu, upisuje srednju Poljoprivrednu školu u Zagrebu. U četvrtom razredu sudjeluje na državnom natjecanju „AGRO“ gdje osvaja prvo mjesto te tako ostvaruje pravo na izravan upis na Agronomski fakultet u Zagrebu. 2009. upisuje preddiplomski studij Hortikulture, a završava ga 2013. godine obranom završnog rada „*Utjecaj kalcizacije tla na primanje hranjiva i mineralni sastav krumpira*“. Iste godine upisuje diplomski studij Agroekologije, usmjerenje Agroekologija, kojeg završava 2015. godine obranom diplomskog rada naslova „*Morfološke karakteristike korijena graha u uvjetima smanjene dostupnosti fosfora*“. Dobitnik je Rektorove nagrade za studentski rad na temu „*Vertikalna varijabilnost nitrarnog dušika i ostalih kemijskih značajki tla u agroekološkim uvjetima gorske i panonske Hrvatske*“. Za uspjeh tijekom diplomskog studija dodijeljena mu je pohvala „*Magna cum laude*“.

Od 2015. godine zaposlen je na Agronomskom fakultetu, Zavodu za pedologiju na radnom mjestu asistenta. 2016. godine upisuje poslijediplomski studij Poljoprivredne znanosti. Aktivno, kao suradnik sudjeluje u izvođenju nastave na preddiplomskom (*Pedologija*) te diplomskom studiju (*Fizika tla, Meliorativna pedologija*) na Agronomskom fakultetu. Kao neposredni voditelj sudjelovao je u izradi osam diplomskih i četiri završna rada na Zavodu za pedologiju, pri čemu su dva diplomatska rada proizašla iz dijela istraživanja u sklopu ove disertacije.

Od 2016 aktivan je član Hrvatskog tloznanstvenog društva.

Od 2015. godine znanstveno i stručno se usavršava na nekoliko tečajeva i radionica:

- HydrometNetworks, Campbell/Corobor Workshop, Zagreb 20. studenog 2018.
- HYDRUS short course „Modeling water flow and contaminant transport in soils and groundwater using the HYDRUS software packages“ August 31. - September 2, 2020, Prague, Check republic.

Kao autor ili koautor objavio je osam A1 znanstvenih radova, jedan A2 te pet znanstvenih radova A3 kategorije.

Popis A1 radova:

1. Magdić, I., Safner, T., Rubinić, V., Rutić, F., Husnjak, S., Filipović, V. (rad prihvaćen za objavu, uz recenziju) Effect of slope position on soil properties and soil moisture regime of Stagnosol in the vineyard, J. Hydrol. Hydromech.

2. Jelinčić, A. Sertić, D., Željковиć, K., Magdić I., Sraka, M. (rad prihvaćen za objavu, uz recenziju) Changes in soil physical properties under the influence of haypasture-colonizing successional grasses, Journal of Central European Agriculture.
3. Rubinić, V., Pavlović, A., Magdić, I. (2021.) Predikcija sadržaja organske tvari tla pomoću boje tla na tri lokacije s različitim načinom korištenja zemljišta u Zagrebu (Hrvatska), Journal of Central European Agriculture, 22(3), p.646-656
[doi: /10.5513/JCEA01/22.3.3193](https://doi.org/10.5513/JCEA01/22.3.3193)
4. Pintar, A., Svečnjak, Z., Lakić, J., Magdić, I., Brzoja, D., Barić, K. (2021.) The Susceptibility of Pea (*Pisum sativum* L.) to Simulated Mesotrione Residues at Affected by Soil pH Manipulation. Agriculture, 11 (8): 688
doi.org/10.3390/agriculture11080688
5. Deftardarović, J., Filipović, L., Kranjčec, F., Ondrašek, G., Kikić, D., Novosel, A., Mustać, I., Krevh, V., Magdić, I., Rubinić, V., Bogunović, V., Dugan, I., Čopeć, K., He, H., Filipović, V. (2021.) Determination of Soil Hydraulic Parameters and Evaluation of Water Dynamics and Nitrate Leaching in the Unsaturated Layered Zone: A Modeling Case Study in Central Croatia, Sustainability, 13, 6688, doi.org/10.3390/su13126688
6. Bogunović, I., Viduka, A., Magdić, I., Telak, L.J., Francos, M., Pereira, P. (2020.) Agricultural and Forest Land – Use Impact on Soil Properties in Zagreb Periurban Area (Croatia). 10(9), 1331, doi.org/10.3390/agronomy10091331
7. Rubinić, V., Ilijanić, N., Magdić, I., Bensa, A., Husnjak, S., Krklec, K. (2020.) Plasticity, Mineralogy, and WRB Classification of Sole Typical Clay Soils along the Two Major Rivers in Croatia. Eurasian Soil Sci, 53 (7) 922 – 940, [doi: 10.1134/S1064229320070121](https://doi.org/10.1134/S1064229320070121)
8. Sraka, M., Škevin, D., Obranović, M., Butorac, J., Magdić, I. (2019.) Agroecological conditions of industrial hemp production in the western Pannonian agricultural subregion and fatty acid composition of hemp seed oil. JCEA. 20 (3) p. 809 – 822, [doi: /10.5513/JCEA01/20.3.2529](https://doi.org/10.5513/JCEA01/20.3.2529)

Popis A2 radova:

1. Bogunović, I., Đekemati, I., Magdić, I., Vrbanić, M., Matošić, S., Mesić, M. (2016.) Spatial modeling for describing spatial variability of soil physical properties in eastern Croatia, Poljoprivreda 22(1) 46-52 [doi: 10.18047/poljo.22.1.7](https://doi.org/10.18047/poljo.22.1.7)

Popis A3 radova:

1. Rubinić, V., Krajnik, A.M., Magdić, I. (2021.) Utjecaj uklanjanja organske tvari tla na analizu mehaničkog sastava slabo humoznih praškasto ilovastih uzoraka. 56. hrvatski i 16. međunarodni simpozij agronoma / 5.do 10. rujna 2021., Vodice, Hrvatska

2. Magdić, I., Popović, R., Rubinić, V. (2020.). Mogućnost pojednostavljenja postupka određivanja gustoće čvrstih čestica tla piknometarskom metodom, 55 th Croatian and 15th international Symposium on Agriculture/February 16-21, 2020, Vodice, Croatia
3. Štajcer, I., Magdić, I., Rubinić, V. (2019.). Utjecaj korištenja zemljišta na kemijska svojstva tla na obiteljskom poljoprivrednom gospodarstvu u općini Krašić. 54th Croatian and 14th international Symposium in Agriculture/February 17-22, 2019, Vodice, Croatia
4. Magdić, I., Svržnjak, D., Sraka, M., Filipović, V., Rubinić, V. (2018.) Utjecaj disperznih sredstava na rezultate analize mehaničkog sastava tla, 53. Hrvatski i 13. međunarodni simpozij agronoma /18 do 23. veljače 2018, Vodice, Hrvatska.
5. Lazarević, B., Šimon, S., Magdić, I., Sedlar, M., Poljak, M. (2015.) Utjecaj kalcizacije tla na mineralnu ishranu krumpira (*Solanum tuberosum* L.)