Sveučilište u Zagrebu

AGRONOMSKI FAKULTET

Jasmina Defterdarović

Identifikacija i kvantifikacija hidrauličkih svojstava tla i preferencijalnih tokova u padinskom poljoprivrednom tlu

DOKTORSKI RAD

Zagreb, 2024.

Sveučilište u Zagrebu

FACULTY OF AGRICULTURE

Jasmina Defterdarović

Identification and quantification of soil hydraulic properties and preferential flow in agricultural hillslope soil

DOCTORAL THESIS

Zagreb, 2024

Sveučilište u Zagrebu

AGRONOMSKI FAKULTET

Jasmina Defterdarović

Identifikacija i kvantifikacija hidrauličkih svojstava tla i preferencijalnih tokova u padinskom poljoprivrednom tlu

DOKTORSKI RAD

Mentor:

Izv. prof. dr. sc. Vilim Filipović

Zagreb, 2024.

Sveučilište u Zagrebu

FACULTY OF AGRICULTURE

Jasmina Defterdarović

Identification and quantification of soil hydraulic properties and preferential flow in agricultural hillslope soil

DOCTORAL THESIS

Supervisor:

Assoc. Prof. Vilim Filipović, PhD

Zagreb, 2024

Bibiliografski podaci:
- Znanstveno područje: Biotehničke znanosti
- Znanstveno polje: Poljoprivreda (agronomija)
- Znanstvena grana: Ekologija i zaštita okoliša
- Institucija: Sveučilište u Zagrebu Agronomski fakultet, Zavod za melioracije
- Voditelj doktorskog rada: izv. prof. dr. sc. Vilim Filipović
- Broj stranica: 131
- Broj slika: 56
- Broj tablica: 13
- Broj priloga: 10
- Broj literaturnih referenci: 224
- Datum obrane doktorskog rada: dd.mm.gggg.
- Sastav povjerenstva za obranu doktorskog rada:
  Predsjednik: prof. dr. sc. Gabrijel Ondrašek, Sveučilište u Zagrebu Agronomski fakultet
  Član: izv. prof. dr. sc. Vedran Rubinić, Sveučilište u Zagrebu Agronomski fakultet
  Član: izv. prof. dr. sc. Zoran Kovač, Sveučilište u Zagrebu Rudarsko-geološko-naftni fakultet

Rad je pohranjen u:
Nacionalnoj i sveučilišnoj knjižnici u Zagrebu, Ulica Hrvatske bratske zajednice 4 p.p. 550, 10 000 Zagreb, Knjižnici Sveučilište 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 08. veljače 2022. godine, te odobrena na sjednici Senata Sveučilišta u Zagrebu, održanoj dana 12. travnja 2022. godine.

SVEUČILIŠTE U ZAGREBU
AGRONOMSKI FAKULTET

IZJAVA O IZVORNOSTI

Ja, **Jasmina Defterdarović**, izjavljujem da sam samostalno izradila doktorski rad pod naslovom:

Identifikacija i kvantifikacija hidrauličkih svojstava tla i preferencijalnih tokova u padinskom poljoprivrednom tlu

Svojim potpisom jamčim:

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

U Zagrebu, dana _____

_____
Potpis doktorandice

Ovu disertaciju ocijenilo je povjerenstvo u sastavu:

1. Prof. dr. sc. Gabrijel Ondrašek
   Redoviti profesor Agronomskog fakulteta Sveučilišta u Zagrebu
2. Izv. prof. dr. sc. Vedran Rubinić
   Izvanredni profesor Agronomskog fakulteta Sveučilišta u Zagrebu
3. Izv. prof. dr. sc. Zoran Kovač
   Izvanredni profesor Rudarsko-geološko-naftnog fakulteta Sveučilišta u Zagrebu

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

1. Prof. dr. sc. Gabrijel Ondrašek

   _____

   Redoviti profesor Agronomskog fakulteta Sveučilišta u Zagrebu

2. Izv. prof. dr. sc. Vedran Rubinić

   _____

   Izvanredni profesor Agronomskog fakulteta Sveučilišta u Zagrebu

3. Izv. prof. dr. sc. Zoran Kovač

   _____

   Izvanredni profesor Rudarsko-geološko-naftnog fakulteta Sveučilišta u Zagrebu

Životopis mentora

Izv. prof. dr. sc. Vilim Filipović rođen je 02. travnja 1984. godine u Zagrebu. Diplomirao je na Agronomskom fakultetu Sveučilišta u Zagrebu 2008. te se iste godine i zaposlio na Zavodu za melioracije. Diplomu doktora znanosti stječe 2012. godine obranom doktorske disertacije naslova „Primjena numeričkog modeliranja u procjeni kretanja vode i koncentracije nitrata u uvjetima hidromorfnih tala“ koja je izrađena pod mentorstvom prof. emeritusa dr. sc. Dragutina Petošića. 2013. godine odlazi u Francusku na institut INRA (National Institute for Agriculture Research) kao poslijedoktorand gdje se bavi modeliranjem pronosa pesticida u tlu. Tijekom svoje karijere boravio je na mnogim međunarodnim institucijama među kojima su najistaknutije Commonwealth Scientific and Industrial Research Organisation (CSIRO, Australija), Penn State University, University of Florida, University of California, Swedish University of Agricultural Sciences, University of Natural Resources and Life Sciences (BOKU, Austrija), Czech University of Life Sciences Prague, Leibniz Centre for Agricultural Landscape Research (ZALF, Njemačka), Federation University Australia i University of Queensland. Od 2016. godine radi kao docent na Zavodu za melioracije, a od 2022. i kao izvanredni profesor. Izvodi nastavu na preddiplomskom, diplomskom i poslijediplomskom studiju, kao i na diplomskom studiju na engleskom jeziku te je dosada mentorirao preko 20 diplomskih radova i jednu doktorsku disertaciju. Također je bio voditelj i nekoliko nacionalnih i međunarodnih projekata, te sudjeluje na više projekata kao suradnik. Područje znanstvenog interesa obuhvaća fiziku tla i procjenu hidrauličkih svojstava tla, transportne procese u tlu te modeliranije toka vode i transport otopljenih tvari u heterogenim tlima. Iz navedene tematike je objavio više desetaka znanstvenih radova indeksiranih u bazama podataka WOS. Rezultate svojih istraživanja redovito prezentira na međunarodnim konferencijama. Trenutno je pomoćni urednik u *Soil Science Society of America Journal* i *Vadose Zone Journal*. Dobitnik je nagrade Soil Society of America Early Career Award 2019. godine. Član je Hrvatskog tloznanstvenog društva, International Soil Modeling Consortium, Soil Science Society of America i European Geosciences Union.

Istraživanje prikazano u ovom doktorskom radu provedeno je u sklopu znanstvenog projekta “Podpovršinski preferencijalni transportni procesi u poljoprivrednim padinskim tlima – SUPREHILL (UIP-2019-04-5409)” financiranog od strane Hrvatske zaklade za znanost.

Zahvala

SAŽETAK

U biljnoj proizvodnji posebno su zahtjevni tereni na nagibu uslijed degradacije tla koja se javlja kao posljedica obrade i velike heterogenosti u svojstvima tla čak i na relativno malom području. Navedeno dovodi do pojave neravnotežnih procesa toka i pronosa tvari, odnosno do bržeg otjecanja agrokemikalija do površinskih voda, ali i bržeg procjeđivanja do podzemnih voda. Glavni cilj doktorske disertacije bio je utvrditi procese koji se odvijaju u tlu nakon pojedinih vremenskih (ne)prilika i imaju direktan utjecaj na agroekosustav i potencijalne opasnosti za okoliš poput erozije i onečišćenja površinskih i podzemnih voda.

Istraživanje je provedeno na vinogradarsko-vinarskom pokušalištu Jazbina tijekom dvogodišnjeg razdoblja (2021. – 2022.) na rigolanom tlu iz pseudogleja obronačnog s izraženim Btg horizontom. Obronak je podijeljen ovisno o nagibu na tri pozicije, odnosno vrh – sredina (17,5%) i sredina – dno (25,4%). Na istraživanoj lokaciji su uzeti uzorci tla na vrhu, sredini i dnu na različitim dubinama u tri replikacije kako bi se odredila fizikalna, kemijska i hidraulička svojstva tla. Postavljeni su nevagajući tlačni pasivni lizimetri na 40 cm dubine u kojima je mjeren volumen jednom mjesečno. Klimatski podaci prikupljani su na meteorološkoj stanici. Na dnu padine je mjereno površinsko otjecanje i potpovršinsko procjeđivanje u tri replikacije. Na istraživanoj padini su postavljeni i senzori za mjerenje volumetrijske vlage tla te vodnog potencijala tla, a na istim pozicijama na površini tla je mjerena i infiltracijska sposobnost tla. Tok vode je određen aplikacijom briljantno plavog bojila i kalijeva bromida. Na kraju je provedeno numeričko modeliranje toka i retencije vode u terenskim i laboratorijskim uvjetima u HYDRUS-1D programu koristeći modele dvostruke poroznosti i propusnosti.

Provedenim istraživanjima kao najbolji model za procjenu hidrauličkih svojstava tla na heterogenim tlima pokazao se van Genuchtenov bimodalni model. Analizom prostornih i vremenskih dinamika vodnog režima istraživane padine utvrđen je velik utjecaj preferencijalnih tokova na hidrologiju cijele padine. Razlike u toku vode utvrđene su ne samo ovisno o poziciji na padini nego i između replikacija. Također je utvrđena jasna prisutnost lateralnog preferencijalnog toka kada se nakon pojedinih kišnih događaja nije zabilježila razlika u vlazi tla na površini, ali je u većim dubinama. Numeričkim modeliranjem utvrđena je najveća pouzdanost modela dvostruke poroznosti. Međutim, i taj se model pokazao pouzdaniji u simulacijama kolona u usporedbi s terenskim mjerenjima gdje bi se vjerojatno boljim pokazao još kompleksniji model koji uzima u obzir sve tri dimenzije.

Ključne riječi: padinska tla, preferencijalni tokovi, senzori, HYDRUS, hidraulička svojstva tla, kolone s neporušenim tlom, heterogenost tla

EXTENDED ABSTRACT

Identification and quantification of soil hydraulic properties and preferential flow in agricultural hillslope soil

Agricultural production on a slope is particularly demanding due to greater degradation caused by tillage and soil heterogeneity, even on a relatively small area, which can cause non-equilibrium flow and transport processes i.e., faster runoff of agrochemicals to surface waters and faster leaching to groundwater. The main aim of this research was to determine processes happening in the soil after certain weather events and have a direct impact on the agroecosystem and potential environmental hazards such as soil erosion and pollution of surface and groundwater. Thus, the research hypotheses were set as (i) unimodal functions are not sufficient for the estimation of hydraulic soil properties of heterogeneous hillslopes with a developed structure; (ii) local heterogeneities have a dominant influence on the water regime of the investigated hillslope; (iii) the application of numerical models of dual porosity and permeability allow the quantification of preferential flows in the soil. The research objectives were set as follows (i) analyse the soil hydraulic properties in heterogeneous hillslope soils with a developed structure using unimodal and bimodal functions; (ii) analyse the spatial and temporal dynamics of the soil water regime of the investigated slope and determine the occurrence of preferential flow in order to quantify the influence of local soil heterogeneities; (iii) determine the reliability of complex numerical models for the quantification of non-equilibrium and preferential flow processes.

The study was conducted at Experimental station Jazbina (45º51'24'' N 16º00'22'' E) during the two years (2021 – 2022). According to the World Reference Base (WRB) classification system, this location is classified as Dystric Luvic Stagnosol. The investigated vineyard is divided into two parts based on the slope – 17.5% from hillslope to backslope, and 25.4% from backslope to footslope. Disturbed soil samples were taken in triplicate at the hilltop, backslope, and footslope from 0 – 30, 30 – 60, and 60 – 90 cm depth to determine the physicochemical soil properties. Undisturbed soil samples were also taken from the hilltop, backslope, and footslope from 15 – 20, 35 – 40, 55 – 60, and 70 – 75 cm to estimate the hydraulic soil properties. Additionally, undisturbed soil samples were taken to determine hillslope stability. Furthermore, wick lysimeters were also set at the hilltop, backslope, and footslope at 40 cm depth. Lysimeters were used to measure percolated water once a month. A meteorological station was set at the backslope of the investigated vineyard and it collects climate data (air temperature, humidity, wind speed and direction, solar radiation, and precipitation). The volume of the subsurface runoff was measured in surface runoff instruments set at the

footslope in three rows which represents replications. Volume was also measured once a month. At the same position surface runoff instruments were set to measure the volume of the surface runoff. The dynamics of volume measurements were the same as for the subsurface runoff. Furthermore, soil moisture and soil water potential sensors were set at the hilltop, backslope, and footslope at 40 and 80 cm depth, i.e. 40 cm depth. For precise determination of preferential flow, a thicker sensor network was set at the same location as the meteorological station. Sensors were set at 15, 30, 50, 75, and 100 cm with a reading resolution of 15 minutes. Determination of soil infiltration rate and hydraulic conductivity was obtained using a mini disk infiltrometer. The measurements were conducted again at the hilltop, backslope, and footslope, while the unsaturated hydraulic conductivity was calculated via a Microsoft Excel spreadsheet provided by the manufacturer. Determination of preferential flow was obtained both at the field and in the controlled conditions using two traces (Brilliant Blue and potassium bromide). After Brilliant Blue was infiltrated into the soil, the dyed area was analysed in *ImageJ*, while bromide concentration was determined in leachate samples collected in wick lysimeters once a month. Water flow was also determined in controlled conditions on undisturbed soil columns using Brilliant Blue, potassium bromide, sensors, and tensiometers. Undisturbed soil columns, 25 cm in depth and 16 cm in diameter, were taken from the field at the hillslope, backslope, and footslope. All collected data were used for numerical modeling of water flow and water retention. Simulations on undisturbed soil columns are used to investigate vertical water flow, while vertical water flow in combination with surface runoff and evapotranspiration was simulated using data from wick lysimeters. Sensors obtained data for simulations of vertical and lateral flows, surface runoff, and evapotranspiration. Dual-porosity and dual-permeability models were used for numerical modeling.

Obtained results showed that for most properties the more complex van Genuchten bimodal model shows the highest reliability compared to other models. The analysis of the spatial and temporal dynamics of the water regime of the investigated hillslope showed an influence of preferential flows on the hydrology of the entire slope. Differences in water flow were found not only depending on hillslope position but between replications as well. The presence of lateral preferential flow was also seen after certain rainfall events when no difference in soil moisture was measured on the surface sensor but was measured in deeper depths. Furthermore, numerical modeling showed the highest reliability of the dual porosity model. However, it was also proven that the model shows better reliability for modeling undisturbed soil columns compared to the field conditions. While the conditions at the field are more complex compared to the soil column, thus the more complex model, such as HYDRUS-3D would show even greater reliability.

Key words: hillslope soils, preferential flow, sensors, HYDRUS, soil hydraulic properties, undisturbed soil columns, soil heterogeneity

SADRŽAJ

1. UVOD 1
1.1. Hipoteze i ciljevi istraživanja 4
1.1.1. Hipoteze 4
1.1.2. Ciljevi 4
2. PREGLED LITERATURE 5
2.1. Padinska tla i klimatske promjene 5
2.2. Utjecaj svojstava tla na procese u tlu i proizvodni potencijal 7
2.2.1. Hidraulička svojstva tla 8
2.3. Tok vode u tlu 11
2.3.1. Preferencijalni tok vode 11
2.3.2. Površinsko otjecanje i potpovršinsko procjeđivanje 14
2.4. Numeričko modeliranje u hidrologiji 16
3. MATERIJALI I METODE 20
3.1. Opis lokacije istraživanja 20
3.2. Terenska istraživanja 25
3.2.1. Lizimetarska i senzorska mjerenja 25
3.2.2. Infiltracijska sposobnost tla 28
3.2.3. Određivanje toka vode traserima (briljantno plavo bojilo i kalijev bromid) na terenu 29
3.3. Laboratorijska istraživanja 30
3.3.1. Hidraulička svojstva tla 30
3.4. Određivanje toka vode primjenom trasera na neporušenim kolonama tla 34
3.5. Numeričko modeliranje 36
4. REZULTATI 40
4.1. Terenska istraživanja 40
4.1.1. Lizimetarska i senzorska mjerenja 40
4.1.2. Infiltracijska sposobnost tla 55
4.1.3. Određivanje toka vode traserima (briljantno plavo bojilo i kalijev bromid) na terenu 56
4.2. Laboratorijska istraživanja 60
4.2.1. Hidraulička svojstva tla 60
4.3. Određivanje toka vode primjenom trasera na neporušenim kolonama tla 69
4.3.1. Procjena hidrauličkih svojstava tla 69
4.3.2. Mjerenje toka vode upotrebom senzora i tenziometara 70
4.3.3. Procjena dinamike toka vode upotrebom bromida 71

4.3.4. Identifikacija i kvantifikacija preferencijalnog toka upotrebom briljantno plavog bojila 73
4.4. Numeričko modeliranje 78
5. RASPRAVA 84
5.1. Terenska istraživanja 84
5.1.1. Lizimetarska i senzorska mjerenja 84
5.1.2. Infiltracijska sposobnost tla 88
5.1.3. Određivanje toka vode traserima (briljantno plavo bojilo i kalijev bromid) na terenu 88
5.2. Laboratorijska istraživanja 89
5.2.1. Hidraulička svojstva tla 89
5.3. Određivanje toka vode primjenom trasera na neporušenim kolonama tla 90
5.3.1. Procjena hidrauličkih svojstava tla 90
5.3.2. Mjerenje toka vode upotrebom senzora i tenziometara 90
5.3.3. Procjena dinamike toka vode upotrebom bromida 92
5.3.4. Identifikacija i kvantifikacija preferencijalnog toka upotrebom briljantno plavog bojila 93
5.4. Numeričko modeliranje 94
6. ZAKLJUČCI 96
7. LITERATURA 98
8. ŽIVOTOPIS 119
9. PRILOZI 122

Popis kratica

MDI – mini disk infiltrometar

CT – kompjutorska tomografija

ET – evapotranspiracija

E.C. – električna vodljivost

C_{org} – organski ugljik

K – hidraulička vodljivost

RMSE – korijen srednje kvadratne devijacije (eng. *root mean square error*)

R^2 – koeficijent determinacije

AIC – Akaike informacijski kriterij

PET – potencijalna evapotranspiracija

LAI – indeks lisne površine (eng. *leaf area index*)

SR – sustav za mjerenje površinskog otjecanja (eng. *surface runoff*)

SS – sustav za mjerenje potpovršinskog procjeđivanja (eng. *subsurface flow*)

WL – nevagajući tlačni pasivni lizimetar (eng. *wick lysimeter*)

KSAT – uređaj za mjerenje hidrauličke vodljvosti tla pri saturiranim uvjetima

Popis tablica

Tablica 3.1.1. Raspodjela granulometrijskog sastava na različitim dubinama na vrhu, sredini i dnu padine.

Tablica 3.1.2. Prikaz kemijskih karakteristika tla istraživane lokacije na vrhu, sredini i dnu padine.

Tablica 3.1.3. Vrijednosti dobivene nakon test opterećenja i testa smicanja tla na neporušenim uzorcima uzetih s vrha (A), sredine (B) i dna (C) padine.

Tablica 4.1.1.1. Prosječni volumen prikupljen u nevagajućim tlačnim pasivnim lizimetrima tijekom pojedinog godišnjeg doba na vrhu (A), sredini (B) i dnu (C) padine u 2021. i 2022. godini.

Tablica 4.1.2.1. Vrijednost infiltracijske sposobnosti tla mjerena na površini tla u tri replikacije na vrhu (A), sredini (B) i dnu (C) padine pri različitim podtlakovima.

Tablica 4.1.3.1. Postotni udio obojene površine tla svakog pojedinog presjeka na vrhu (A), sredini (B) i dnu (C) padine.

Tablica 4.1.3.2. Koncentracija ispranih bromida u mjernim instrumentima na vrhu (A), sredini (B) i dnu (C) padine tijekom 2022. godine.

Tablica 4.2.1.1. Statistička analiza (*RMSE_θ*, *RMSE_K* i *AICc*) različitih modela dostupnih u HYPROP-FIT programu (van Genuchten unimodalni, van Genuchten bimodalni, Fredlund-Xing, Brooks-Corey, Kosugi). Zelenom bojom su označene statistički najpogodnije vrijednosti.

Tablica 4.2.1.2. Hidraulička svojstva tla neporušenih uzoraka tla uzetih u tri replikacije na vrhu (AI, AII, AIII), sredini (BI, BII, BIII) i dnu (CI, CII, CIII) padine na dubinama 15 – 20 cm, 35 – 40, 55 – 60 i 70 – 75 cm određenih u HYPROP-FIT programu koristeći van Genuchten bimodalnu funkciju.

Tablica 4.2.1.3. Ukupna poroznost i gustoća tla procijenjeni u HYPROP-FIT programu na dubinama 15 – 20, 35 – 40, 55 – 60 i 70 – 75 cm na vrhu (A), sredini (B) i dnu (C) padine.

Tablica 4.3.1.1. Procijenjene hidrauličke karakteristike tla na vrhu (A), sredini (B) i dnu (C) padine koristeći HYPROP-FIT (van Genuchten bimodal).

Tablica 4.3.3.1. Utjecaj pozicije na padini na procijeđeni volumen, koncentraciju i masu bromida ispranu iz kolona s neporušenim tlom. Slova *a*, *b* i *c* označuju signifikantnu razliku između pozicija na padini.

Tablica 4.3.4.1. Udio obojenja tla nakon aplikacije briljantno plavog bojila i obrade fotografija na tri replikacije kolona s neporušenim tlom uzorkovanih na vrhu, sredini i dnu padine.

Popis slika

Slika 2.1.1. Prikaz dvaju klimatskih scenarija na padinama: A) sušno razdoblje i B) ekstremne oborine. Crvenim slovima su označeni negativni utjecaji klimatskih promjena na padinama, a zelenim slovima su označeni primjeri održivog gospodarenja vodama. Izvor: (Wang i sur., 2022).

Slika 2.1.2. Prostorna distribucija jačine suše i udio različitih pet klasa indeksa zdravlja vegetacije (eng. *Vegetation Health Index*, VHI).

Slika 2.3.1.1. Prikaz različitih oblika preferencijalnog toka koji se mogu javiti u tlu (Hendrickx i Flury, 2001).

Slika 2.3.2.1. Prikaz specifičnih tokova vode koji se javljaju na terenima na nagibu.

Slika 2.4.1. Prikaz konceptualnih modela (jednostruke i dvostruke poroznosti i dvostruke propusnosti) toka vode i transporta otopljenih tvari. θ predstavlja sadržaj vode, θ_{im} nepokretnu vodu, θ_{mo} pokretnu vodu, θ_m voda u matriksu tla, a θ_f voda u makroporama tla (Simunek i van Genuchten, 2007).

Slika 3.1.1. Prikaz profila do 60 cm dubine na rigolanom tlu iz pseudogleja obronačnog s izraženim Btg horizontu na vrhu (a), sredini (b) i dnu (c) padine na vinogradarsko-vinarskom pokušalištu Jazbina, Hrvatska.

Slika 3.1.2. Lokacija SUPREHILL observatorija i prikaz istraživane padine s označenim vrhom (A), sredinom (B) i dnom (C) padine.

Slika 3.1.3. Uzorkovanje neporušenih uzoraka tla volumena 236 cm^3 na vrhu (A), sredini (B) i dnu (C) padine.

Slika 3.1.4. Provođenje testa opterećenja tla na neporušenim uzorcima tla volumena 236 cm^3 uzorkovanih s vrha (A), sredine (B) i dna (C) padine na Sveučilištu u Kielu (Fotografirao: Steffen Beck-Broichsitter).

Slika 3.2.1.1. Prikaz konstrukcije nevagajućih tlačnih pasivnih lizimetara te njihovo postavljanje na istraživanoj lokaciji.

Slika 3.2.1.2. a) i b) Postavljanje sustava za mjerenje potpovršinskog procjeđivanja na dnu padine i c) sustav za prikupljanje površinskog otjecanja površine 4 m^2 postavljeni na istraživanoj lokaciji.

Slika 3.2.1.3. a) Senzori za mjerenje sadržaja vode u tlu (TEROS-10) te za određivanje vodnog potencijala tla (TEROS-21) i b) Senzori postavljeni na BII lokaciji postavljeni na 15, 30, 50, 75 i 100 cm dubine.

Slika 3.2.2.1. Mjerenje infiltracijske sposobnosti tla mini-disk infiltrometrom.

Slika 3.2.3.1. Aplikacija briljantno plavog bojila na površini od 1 m^2 na vrhu padine.

Slika 3.3.1.1. Uzorkovanje neporušenih uzoraka tla volumena 250 cm^3 za procjenu hidrauličkih svojstava tla.

Slika 3.3.1.2. Prikaz (a) KSAT, (b) HYPROP i (c) WP4C uređaja pomoću kojih su procjenjena hidraulička svojstva tla.

Slika 3.4.1. Utiskivanje kolona u tlo i uzimanje neporušenih uzoraka tla na istraživanoj lokaciji.

Slika 3.4.2. Prikaz kolona s neporušenim tlom u laboratoriju s postavljenim senzorima na dubini od 7 cm i tenziometrima na dubini od 17 cm.

Slika 3.5.1. Shematski prikaz provedenih istraživanja od najšireg područja prema užem području istraživanja i statističkih analiza.

Slika 4.1.1.1. Istek iz nevagajućih tlačnih pasivnih lizimetara na vrhu, sredini i dnu padine kroz dvogodišnje razdoblje (2021. – 2022.).

Slika 4.1.1.2. Prosječni volumen [L] prikupljen u nevagajućim tlačnim pasivnim lizimetrima tijekom pojedinog godišnjeg doba na vrhu, sredini i dnu padine u tri replikacije u 2021. i 2022. godini.

Slika 4.1.1.3. Istek iz sustava za površinsko otjecanje u tri replikacije na dnu padine kroz dvogodišnje razdoblje (2021. – 2022.).

Slika 4.1.1.4. Prosječni volumen prikupljen u sustavima za površinsko otjecanje u tri replikacije tijekom pojedinog godišnjeg doba u 2021. i 2022. godini.

Slika 4.1.1.5. Istek iz sustava za mjerenje potpovršinskog procjeđivanja na dnu padine kroz dvogodišnje razdoblje (2021. – 2022.).

Slika 4.1.1.6. Prosječni volumen prikupljen u sustavima za mjerenje potpovršinskog procjeđivanja u tri replikacije tijekom pojedinog godišnjeg doba u 2021. i 2022. godini.

Slika 4.1.1.7. Volumetrijska vlaga tla za vrh i dno padine na dubini od 40 i 80 cm kroz period od dvije godine (2021 – 2022).

Slika 4.1.1.8. Prosječna volumetrijska vlaga tla izmjerene na vrhu i dnu padine na dubini od 40 i 80 cm tijekom pojedinog godišnjeg doba u 2021. i 2022. godini.

Slika 4.1.1.9. Vodni potencijal tla za vrh i dno padine na dubini od 40 cm kroz period od dvije godine (2021 – 2022).

Slika 4.1.1.10. Prosječni vodni potencijal tla za vrh i dno padine na dubini od 40 cm tijekom pojedinog godišnjeg doba u 2021. i 2022. godini.

Slika 4.1.1.11. Prikaz volumetrijske vlage tla kroz cijeli profil tla (100 cm) na sredini padine kroz period od dvije godine (2021. – 2022.).

Slika 4.1.1.12. Prikaz promjena volumetrijske vlage tla i identifikacije preferencijalnog toka kroz cijeli profil tla (100 cm) na sredini padine u pojedinim periodima tijekom razdoblja istraživanja (2021. – 2022.).

Slika 4.1.1.13. Prosječna volumetrijska vlaga tla za cijeli profil tla (100 cm) na sredini padine i oborina tijekom pojedinog godišnjeg doba u 2021. i 2022. godini.

Slika 4.1.1.14. Prosječne vrijednosti oborina na istraživanoj lokaciji u ovisnosti o godišnjim dobima tijekom 2021. i 2022. godine.

Slika 4.1.3.1. Fotografije presjeka površine tla od 1 m^2 nakon infiltracije briljantno plavog bojila (Brilliant Blue) i obrađene fotografije u *ImageJ* programu (crno-bijele fotografije) za vrh (A) padine.

Slika 4.1.3.2. Fotografije presjeka površine tla od 1 m^2 nakon infiltracije briljantno plavog bojila (Brilliant Blue) i obrađene fotografije u *ImageJ* programu (crno-bijele fotografije) za sredinu (B) padine.

Slika 4.1.3.3. Fotografije presjeka površine tla od 1 m^2 nakon infiltracije briljantno plavog bojila (Brilliant Blue) i obrađene fotografije u *ImageJ* programu (crno-bijele fotografije) za dno (C) padine.

Slika 4.2.1.1. Retencijske krivulje tla prve replikacije (AI, BI, CI) određene u HYPROP-FIT programu koristeći različite modele za vrh (zelena boja), sredinu (žuta boja) i dno (crvena boja) padine na dubinama 15 – 20 cm (a), 35 – 40 cm (b), 55 – 60 cm (c) i 70 – 75 cm (d).

Slika 4.2.1.2. Retencijske krivulje tla druge replikacije (AII, BII, CII) određene u HYPROP-FIT programu koristeći različite modele za vrh (zelena boja), sredinu (žuta boja) i dno (crvena boja) padine na dubinama 15 – 20 cm (a), 35 – 40 cm (b), 55 – 60 cm (c) i 70 – 75 cm (d).

Slika 4.2.1.3. Retencijske krivulje tla treće replikacije (AIII, BIII, CIII) određene u HYPROP-FIT programu koristeći različite modele za vrh (zelena boja), sredinu (žuta boja) i dno (crvena boja) padine na dubinama 15 – 20 cm (a), 35 – 40 cm (b), 55 – 60 cm (c) i 70 – 75 cm (d).

Slika 4.3.1.1. Retencijske krivulje tla određene u HYPROP-FIT programu koristeći VGM model za vrh (a), sredinu (b) i dno (c) padine.

Slika 4.3.2.1. Promjene u sadržaju vode u tlu između dva navodnjavanja (250 mL kišnice) izmjerene senzorima postavljenim na 7 cm dubine unutar kolona s neporušenim tlom na (a) vrhu, (b) sredini i (c) dnu padine.

Slika 4.3.2.2. Promjene u matričnom potencijalu između dva navodnjavanja (250 mL kišnice) izmjerene tenziometrima postavljenim na 17 cm dubine unutar kolona s neporušenim tlom na (a) vrhu, (b) sredini i (c) dnu padine.

Slika 4.3.3.1. Prikaz odnosa relativne koncentracije bromida isprane iz kolona s neporušenim tlom i procijeđenim volumenom na vrhu (a), sredini (b) i dnu padine (c) uzete u tri replikacije.

Slika 4.3.4.1. Fotografije poprečnih presjeka uzorkovanih kolona (lijevo) i crno-bijelih fotografija nakon obrade u *ImageJ* programu (desno) na prvoj replikaciji na vrhu padine. Slovo *a* predstavlja desnu polovicu kolone tla, a slovo *b* lijevu polovicu kolone. Brojevi 1, 2 i 3 predstavljaju poprečni presjek.

Slika 4.3.4.2. Fotografije poprečnih presjeka uzorkovanih kolona (lijevo) i crno-bijelih fotografija nakon obrade u *ImageJ* programu (desno) na drugoj replikaciji na vrhu padine. Slovo *a* predstavlja desnu polovicu kolone tla, a slovo *b* lijevu polovicu kolone. Brojevi 1, 2 i 3 predstavljaju poprečni presjek.

Slika 4.3.4.3. Fotografije poprečnih presjeka uzorkovanih kolona (lijevo) i crno-bijelih fotografija nakon obrade u *ImageJ* programu (desno) na trećoj replikaciji na vrhu padine. Slovo *a* predstavlja desnu polovicu kolone tla, a slovo *b* lijevu polovicu kolone. Brojevi 1, 2 i 3 predstavljaju poprečni presjek.

Slika 4.3.4.4. Fotografije poprečnih presjeka uzorkovanih kolona (lijevo) i crno-bijelih fotografija nakon obrade u *ImageJ* programu (desno) na prvoj replikaciji na sredini padine. Slovo *a* predstavlja desnu polovicu kolone tla, a slovo *b* lijevu polovicu kolone. Brojevi 1, 2 i 3 predstavljaju poprečni presjek.

Slika 4.3.4.5. Fotografije poprečnih presjeka uzorkovanih kolona (lijevo) i crno-bijelih fotografija nakon obrade u *ImageJ* programu (desno) na drugoj replikaciji na sredini padine. Slovo *a* predstavlja desnu polovicu kolone tla, a slovo *b* lijevu polovicu kolone. Brojevi 1, 2 i 3 predstavljaju poprečni presjek.

Slika 4.3.4.6. Fotografije poprečnih presjeka uzorkovanih kolona (lijevo) i crno-bijelih fotografija nakon obrade u *ImageJ* programu (desno) na trećoj replikaciji na sredini padine. Slovo *a* predstavlja desnu polovicu kolone tla, a slovo *b* lijevu polovicu kolone. Brojevi 1, 2 i 3 predstavljaju poprečni presjek.

Slika 4.3.4.7. Fotografije poprečnih presjeka uzorkovanih kolona (lijevo) i crno-bijelih fotografija nakon obrade u *ImageJ* programu (desno) na prvoj replikaciji na dnu padine. Slovo *a* predstavlja desnu polovicu kolone tla, a slovo *b* lijevu polovicu kolone. Brojevi 1, 2 i 3 predstavljaju poprečni presjek.

Slika 4.3.4.8. Fotografije poprečnih presjeka uzorkovanih kolona (lijevo) i crno-bijelih fotografija nakon obrade u *ImageJ* programu (desno) na drugoj replikaciji na dnu padine. Slovo *a* predstavlja desnu polovicu kolone tla, a slovo *b* lijevu polovicu kolone. Brojevi 1, 2 i 3 predstavljaju poprečni presjek.

Slika 4.3.4.9. Fotografije poprečnih presjeka uzorkovanih kolona (lijevo) i crno-bijelih fotografija nakon obrade u *ImageJ* programu (desno) na trećoj replikaciji na dnu padine. Slovo *a* predstavlja desnu polovicu kolone tla, a slovo *b* lijevu polovicu kolone. Brojevi 1, 2 i 3 predstavljaju poprečni presjek.

Slika 4.4.1. Prikaz senzorskih mjerenja volumetrijske vlage tla u kolonama s neporušenim tlom uzetih na vrhu (A), sredini (B) i dnu (C) padine te simulirane vrijednosti u modelima dvostruke poroznosti i dvostruke propusnosti koristeći HYDRUS-1D.

Slika 4.4.2. Prikaz isteka iz kolona s neporušenim tlom s uzetih na vrhu (A), sredini (B) i dnu (C) padine te simulirane vrijednosti u modelu dvostruke poroznosti koristeći HYDRUS-1D.

Slika 4.4.3. Prikaz izmjerenih i simuliranih vrijednosti volumetrijske vlage tla mjerene senzorima na istraživanoj lokaciji na vrhu (A) i dnu (C) padine. Oznaka a) označuje period od 04. lipnja do 03. srpnja 2021. (sušenje), b) od 01. rujna do 30. rujna 2022. (vlaženje) i c) od 09. studenog do 08. prosinca 2022. (saturacija). Oznaka 1 se odnosi na senzore postavljene na 40 cm, a oznaka 2 na senzore postavljene na 80 cm dubine.

Slika 4.4.4. Prikaz izmjerenih i simuliranih isteka iz nevagajućih tlačnih pasivnih lizimetara koristeći model dvostruke poroznosti i inverzno modeliranje u HYDRUS-1D u periodu rujan – prosinac 2022. godine.

Slika 9.1. Infiltracijska sposobnost tla izmjerena mini disk infiltrometrom pri različitim usisima (1, 2, 3, 4 i 5 cm) na vrhu padine (prva replikacija – AI).

Slika 9.2. Infiltracijska sposobnost tla izmjerena mini disk infiltrometrom pri različitim usisima (1, 2, 3, 4 i 5 cm) na vrhu padine (druga replikacija – AII).

Slika 9.3. Infiltracijska sposobnost tla izmjerena mini disk infiltrometrom pri različitim usisima (1, 2, 3, 4 i 5 cm) na vrhu padine (treća replikacija – AIII).

Slika 9.4. Infiltracijska sposobnost tla izmjerena mini disk infiltrometrom pri različitim usisima (1, 2, 3, 4 i 5 cm) na sredini padine (prva replikacija – BI).

Slika 9.5. Infiltracijska sposobnost tla izmjerena mini disk infiltrometrom pri različitim usisima (1, 2, 3, 4 i 5 cm) na sredini padine (druga replikacija – BII).

Slika 9.6. Infiltracijska sposobnost tla izmjerena mini disk infiltrometrom pri različitim usisima (1, 2, 3, 4 i 5 cm) na sredini padine (treća replikacija – BIII).

Slika 9.7. Infiltracijska sposobnost tla izmjerena mini disk infiltrometrom pri različitim usisima (1, 2, 3, 4 i 5 cm) na sredini padine (prva replikacija – CI).

Slika 9.8. Infiltracijska sposobnost tla izmjerena mini disk infiltrometrom pri različitim usisima (1, 2, 3, 4 i 5 cm) na sredini padine (druga replikacija – CII).

Slika 9.9. Infiltracijska sposobnost tla izmjerena mini disk infiltrometrom pri različitim usisima (1, 2, 3, 4 i 5 cm) na sredini padine (treća replikacija – CIII).

Slika 9.10. Snimke izgleda poroznog sustava na istraživanoj lokaciji snimljenog pomoću kompjutorske tomografije (CT) prije (a) i poslije (b) kompakcije tla.

1. UVOD

Prema podacima Ujedinjenih naroda, svjetski broj stanovnika bilježi veliki porast. Tako je broj ljudi porastao s oko 1 milijarde 1800. godine do 2,5 milijarde 1950. godine pa sve do preko 8 milijardi koliko danas bilježimo. Očekuje se da će taj broj nastaviti rasti te će dosegnuti gotovo 10 milijardi stanovnika do 2050. godine (Lutz i Kc, 2010). Ovakav porast u broju stanovnika na svjetskoj razini nosi sa sobom izazove osiguravanja dovoljne količine hrane. S druge strane, upravo intenzivna poljoprivredna proizvodnja može dovesti do degradacije tala (Bogunovic i sur., 2023; Cárceles Rodríguez i sur., 2022; Dugan i sur., 2024). S obzirom na klimatske promjene, navedeno postaje sve veći izazov. Kao posljedica klimatskih promjena sve se češće javljaju ekstremi pa se tako na istom području javljaju velike količine oborina koje rezultiraju poplavama u jednom periodu, a s druge strane, ponekad i svega nekoliko dana nakon, javljaju se ekstremno visoke temperature i sušni periodi. Osim toga, klimatske promjene utječu i na gubitak bioraznolikosti, desertifikaciju i degradaciju ekosustava (FAO, 2022).

Tla na nagibu nerijetko su korištena u poljoprivrednoj proizvodnji, zbog prednosti koje imaju u uzgoju pojedinih kultura, kao što su primjerice izloženost Sunčevoj svjetlosti i izraženije kretanje zraka. Sunčeva svjetlost povoljno djeluje na dozrijevanje grožđa, dok je zbog kretanja zraka u vinogradu niža vlaga zraka što smanjuje mogućnosti razvoja bolesti (Striegler i sur., 2015). S druge strane, u pojedinim područjima to su jedine raspoložive površine. Ipak, poljoprivredna tla na nagibu smatraju se među najsloženijim ekosustavima zbog specifičnih procesa koji se javljaju, a među kojima su površinsko otjecanje, erozija, potpovršinski preferencijalni i lateralni tok i drugi. Navedeno je posebice izraženo tijekom ekstremnih vremenskih prilika, posebice obilnih oborina. Nerijetko se događa da, prilikom velikih količina oborina, infiltracijska sposobnost tla nije dovoljna kako bi se oborine infiltrirale u tlo što rezultira pojavom površinskog otjecanja. Nadalje, površinskom otjecanju može pridonijeti i repelentnost tla za vodu (Bayad i sur., 2022; Varela i sur., 2005). Površinsko otjecanje ima brojne štetne posljedice na okoliš među kojima su erozija tla, onečišćenje površinskih i podzemnih voda i tala u nižim predjelima primijenjenim tvarima kao što su pesticidi i gnojiva, ali i opasnosti od poplava u nižim predjelima (Ahmad i sur., 2023; Coblinski i sur., 2019; Müller i sur., 2006; Wu i sur., 2021). Osim toga, tla na nagibu podložna su formiranju klizišta (Fan i sur., 2016). Također, padinska tla karakterizira i velika heterogenost u svojstvima tla čak i na relativno malom području, a koja nastaje kao rezultat obrade tla, erozije, te prolaska teške mehanizacije (Defterdarović i sur., 2023; Kovač i sur., 2023; Krevh i sur., 2023c).

Voda u tlu je jedan od najvažnijih čimbenika koji utječu na hidrološki ciklus padine te utječe i na rast i razvoj biljaka. Smatra se da se danas na svjetskoj razini oko 70% slatkovodnih voda

koristi upravo za potrebe poljoprivrede (Ingrao i sur., 2023). S obzirom da dostupnost vode na Zemlji kontinuirano postaje sve izazovnija, potrebna su istraživanja tokova vode u tlu. Količina vode u tlu može biti vrlo promjenjiva ovisno o drugim parametrima kao što su primjerice temperatura (Pham i sur., 2023), brzina i smjer vjetra (Poulsen i sur., 2022), te količina oborina (X. Liu i sur., 2021). Količina vode u tlu i brzina vjetra također će utjecati i na eroziju tla vjetrom. Kako bi voda koja dospije na tlo, bilo oborinama ili navodnjavanjem, uopće bila dostupna biljkama potrebno je poznavanje hidrauličkih svojstava tla. Različita tla imaju različita hidraulička svojstva koja se mogu odrediti gravimetrijski ili se mogu procijeniti pojedinim uređajima u laboratoriju. Za procjenu hidrauličkih svojstava tla koriste se KSAT i HYPROP automatizirani sustavi kojim se dobivaju retencijske krivulje i krivulje hidrauličke vodljivosti (Bezerra-Coelho i sur., 2018; Hohenbrink i sur., 2023; Lipovetsky i sur., 2020) te WP4C kojim se određuje suhi dio krivulje. Nakon što se voda infiltrirala u tlo kretat će se ascedentno i/ili descedentno te tok može biti ujednačen ili neujednačen. U prirodi je najčešće prisutan neujednačen tok uslijed prisutnosti pukotina u tlu, flore i faune tla, te razlika u hidrauličkoj vodljivosti i/ili teksturi tla između dva horizonta (Li i sur., 2020; Phillips, 2021; Zhang i sur., 2014). Postoji nekoliko metoda kojima se mogu odrediti preferencijalni tokovi u tlu, bilo u terenskim ili laboratorijskim uvjetima. Najčešće korištene metode su primjene različitih obilježivača (trasera) (Filipović i sur., 2020; Kodešová i sur., 2015, 2012; Li i sur., 2020; Zhang i sur., 2021, 2018), a kao neinvazivna metoda koristi se kompjutorska tomografija (CT) (Leue i sur., 2019; Luo i sur., 2008; Zhang i sur., 2018). Kao obilježivači se koriste otopine, najčešće klorida ili bromida (Bero i sur., 2016; Dusek i sur., 2015; Everts i Kanwar, 1990; Huang i sur., 2019; Pietrzak i sur., 2019; Rasul i sur., 2018) s obzirom da su oni negativno nabijeni kao i tlo te ne dolazi do njihovog vezanja za čestice tla. S druge strane, za vizualizaciju toka vode mogu se koristiti pojedina bojila, a najčešće se koristi briljatno plavo bojilo (Brilliant Blue). Pomoću bojila jasno je vidljiv tok vode što kasnije može biti obrađeno koristeći program kao što je *ImageJ* (Defterdarović i sur., 2023; Filipović i sur., 2020). Nadalje, promjene sadržaja vode u tlu, a time i indirektno preferencijalni tokovi, mogu se pratiti i u realnom vremenu postavljanjem senzora u tlo. Senzori indirektno određuju sadržaj vode mjerenjem, npr. električne vodljivosti, tenzije kojom se voda drži u tlu (Defterdarović i sur., 2023), radioaktivnim mjerenjem (Van Der Veeke i sur., 2020) ili mjerenjem dielektrične konstante (Kargas i sur., 2020). Prednost senzora je što imaju veliku rezoluciju te omogućuju kontinuirano praćenje sadržaja vode u tlu. Nadalje, informacija o tokovima vode u tlu može se dobiti i postavljanjem nevagajućih tlačnih pasivnih lizimetara na određenu dubinu u tlo. Ovom metodom može se odrediti volumen procijeđene vode u određenom periodu uz mogućnost prikupa uzoraka za kemijske analize (Way i sur., 2011). Kako bi se precizno odredila vodna bilanca tla uzimajući u obzir količinu oborina, evapotranspiraciju (ET) i tok vode u upotrebi su vagajući lizimetri (Krevh i sur., 2023b). Takvi lizimetri predstavljaju neporušeni monolit tla, najčešće cilindričnog

oblika smještenih na vagu visoke preciznosti i temporalne razlučivosti. Promjenom težine lizimetra određuje se i promjena sadržaja vode u tlu. Osim vage koja kontinuirano mjeri te promjene, unutar lizimetara se nalaze i senzori za mjerenje sadržaja vode u tlu.

Posljednjih desetljaća primjena numeričkih modela sve je učestalija u brojnim područjima znanosti zbog mogućnosti relativno brzog i jednostavnog predviđanja različitih prirodnih procesa i/ili vremenskih (ne)prilika. U istom periodu se nerijetko javljaju sve veći klimatski ekstremi koji značajno utječu na ekosustave i gospodarstvo. Stoga se, između ostalog, numerički modeli koriste za izrade simulacija tokova vode u tlu što posljedično utječe i na transport otopljenih tvari. Jedan od najčešće korištenih modela za predviđanje mogućih scenarija u jedno-, dvo- i trodimenzionalnim simulacijama je HYDRUS. Osim što omogućuje prikaz u tri dimenzije, također uzima u obzir i heterogenost, a time i kompleksnost pojedinih tala te omogućuje simulaciju kako jednostavnijih modela (jednostruke poroznosti), tako i kompleksnijih modela (dvostruke poroznosti i dvostruke propusnosti). Također, s obzirom da HYDRUS omogućuje i postavljanje različitih početnih i rubnih uvjeta, u kratkom vremenu je moguće predvidjeti potencijalne opasnosti ovisno o različitim uvjetima u prirodi. Kao što je već spomenuto, istraživanje padinskih tala iznimno je izazovno zbog velikih heterogenosti u svojstvima tla čak i na malim udaljenostima što zahtjeva izradu simulacija kompleksnijim modelima.

Glavni cilj istraživanja bio je, širokom bazom prikupljenih podataka, pratiti vremensku i prostornu dinamiku preferencijalnog toka vode što dovodi do boljeg shvaćanja procesa koji se odvijaju u tlu nakon pojedinih vremenskih (ne)prilika, a kao takvi imaju direktan utjecaj na agroekosustav i predstavljaju potencijalne opasnosti za okoliš u vidu erozije tla i onečišćenja površinskih i podzemnih voda.

1.1. Hipoteze i ciljevi istraživanja

1.1.1. Hipoteze

H1 Unimodalne funkcije za procjenu hidrauličkih svojstava tla nisu dovoljno prilagođene heterogenim padinskim tlima s razvijenom strukturom.

H2 Lokalne heterogenosti tla imaju dominantan utjecaj na vodni režim istraživane padine.

H3 Primjena numeričkih modela dvostruke poroznosti i propusnosti omogućuju kvantifikaciju preferencijalnih tokova u tlu.

1.1.2. Ciljevi

C1 Analizirati hidrauličke funkcije tla u heterogenim padinskim tlima s razvijenom strukturom primjenom unimodalnih i bimodalnih funkcija **(H1)**.

C2 Analizirati prostornu i vremensku dinamiku vodnog režima tla istraživane padine te utvrditi vrstu i pojavu preferencijalnog toka kako bi kvantificirali utjecaj lokalnih heterogenosti tla **(H2)**.

C3 Utvrditi pouzdanost kompleksnih numeričkih modela za kvantifikaciju neravnotežnih i preferencijalnih procesa toka u tlu **(H3)**.

2. PREGLED LITERATURE

2.1. Padinska tla i klimatske promjene

Poljoprivredna zemljišta zauzimaju oko pet milijardi hektara, što čini oko 38% ukupne globalne kopnene površine (FAOSTAT, 2020). Molotoks i sur. (2018) naveli su nekoliko istraživanja koja upućuju da će se uslijed porasta stanovništa potrebe za hranom povećati između 60 i 110% do 2050. godine. S obzirom na sve češće i sve ekstremnije klimatske uvjete, zadovoljavanje potreba za hranom postat će sve izazovnije. Također, sve su češće pojave viška vode u jednom periodu godine i manjka vode u drugom periodu godine u istom području. Prema podacima se procjenjuje da suša uzrokovana klimatskim promjenama dovodi do prosječnih gubitaka od najmanje 60 milijardi dolara godišnje (Wang i sur., 2022). Upravo iz tog razloga je bitno bolje poznavanje hidrologije poljoprivrednih tala, a posebice tala na nagibu na kojima se javljaju dodatni izazovi. Slika 2.1.1. prikazuje dva klimatska ekstrema, sušu i ekstremne oborine, te moguće negativne utjecaje klimatskih promjena na padinama, ali i primjere održivog gospodarenja (Wang i sur., 2022). Prema Organizaciji za prehranu i poljoprivredu (eng. *Food and Agriculture Organization of the United Nations*, FAO), tla s izraženim nagibom smatraju se ona tla čiji nagib prelazi 12%.

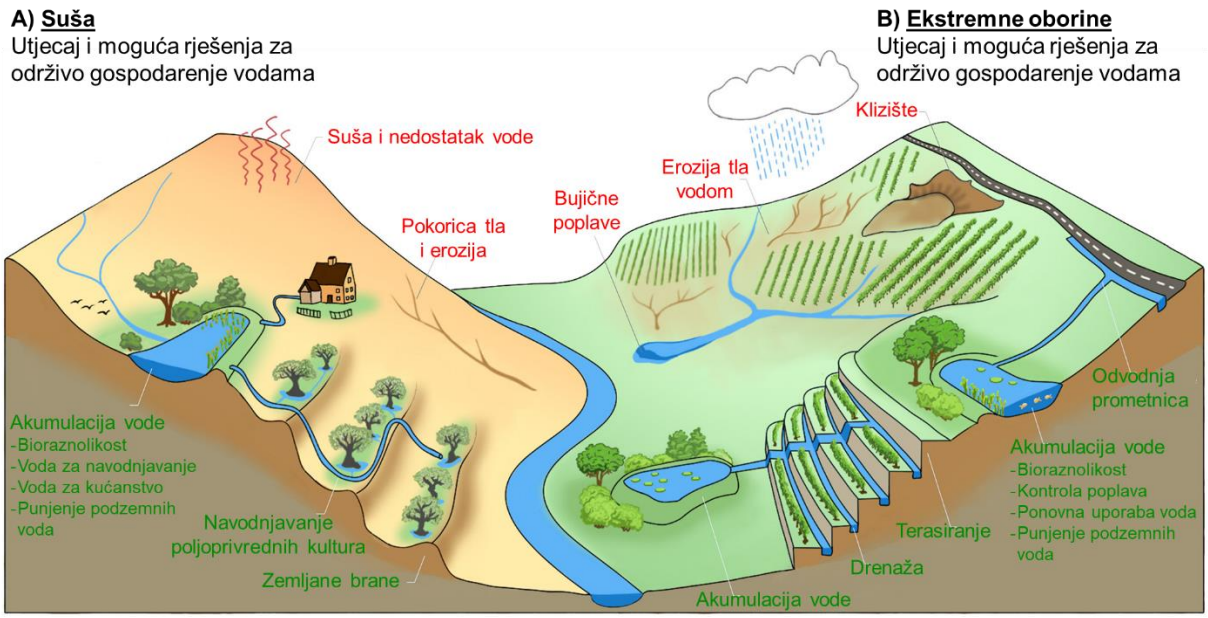

Slika 2.1.1. Prikaz dvaju klimatskih scenarija na padinama: A) sušno razdoblje i B) ekstremne oborine. Crvenim slovima su označeni negativni utjecaji klimatskih promjena na padinama, a zelenim slovima su označeni primjeri održivog gospodarenja vodama. Izvor: (Wang i sur., 2022).

Tarolli i sur. (2021) navode da poljoprivreda na padinama pridonosi proizvodnji hrane i gospodarskom rastu te iako su, s jedne strane, pogodna za uzgoj pojedinih kultura, s druge strane, su upravo takva tla i najranjiva u pogledu erozije, manjka vode te povećanim rizicima od dezertifikacije (Deandreis, 2022; Wang i sur., 2022). Što je veći nagib tla, veća je vjerojatnost da će doći do izraženije erozije (Gao i sur., 2020). Erozija i plodnost tla usko su povezani s gospodarenjem vodom na padinskim tlima s obzirom da suvišak vode može dovesti do površinskog otjecanja (Fariborzi i sur., 2021; Hallema i sur., 2016; Scherrer i sur., 2007; Wu i Qi, 2021) što posljedično uzrokuje nedostatak vode za uzgajane kulture. Erozija tla nastala kao posljedica površinskog otjecanja posljedično uzrokuje i gubitak organske tvari i hranjiva (Coblinski i sur., 2019). Osim površinskog otjecanja, na tlima na nagibu se javlja i potpovršinsko procjeđivanje (Bachmair i Weiler, 2012; Dusek i Vogel, 2019; Fariborzi i sur., 2021), neujednačeni, odnosno preferencijalni tokovi (Chen i sur., 2021; Zhang i sur., 2018; Zhao i sur., 2020), te drugačija dubina slabije propusnog horizonta na vrhu i dnu padine (Filipović i sur., 2018; Magdić i sur., 2022), a česte su i heterogenosti u svojstvima tla duž padine (Chen i sur., 2002; John i sur., 2023; Liu i sur., 2020; Magdić i sur., 2022). Tla na nagibu su povoljan odabir za uzgoj vinove loze zbog ekspozicije koja osigurava zadovoljavajuću osunčanost vinograda, dreniranost tla, te manju opasnost od magle i mrazeva (Evans, 2000). Međutim, vinogradi, osim što su često uzgajani na padini, uz to imaju velike međuredne prostore te se upotrebljava teška mehanizacija što dovodi do dodatne kompleksnosti i rizika od pojačane erozije tla (Apollonio i sur., 2021; GOVERS i sur., 1994; Lobb, 2008; Wang i sur., 2021; Wysocka-Czubaszek i Czubaszek, 2014; Zhang i sur., 2017). Nadalje, poljoprivredna tla zahtijevaju gnojidbu, kao i upotrebu sredstava za zaštitu bilja što s obzirom na specifičnost hidrologije često može predstavljati izraženiju opasnost od onečišćenja površinskih i podzemnih voda (Coblinski i sur., 2019; Kumar i sur., 2021; Lima i sur., 2023; Y. Liu i sur., 2021; Misman i sur., 2023; Rad i sur., 2022; Sasakova i sur., 2018). Prema Wang i sur. (2024) vinogradi su uzgajani na 11% područja koji se nalaze na tlima s izraženim nagibom, a još dio je uzgajan na slabije nagnutim terenima. U Europi se na nagnutim terenima najčešće uzgaja vinova loza, maslina, pojedine voćne vrste, te začinsko i aromatično bilje, dok se u Hrvatskoj najviše uzgaja vinova loza te je prisutna u područjima od Dalmacije, Istre preko Hrvatskog Zagorja do Slavonije. Wang i sur. (2024) u svom su radu naveli da je tijekom ljeta 2022. godine gotovo polovica terena s izraženim nagibom bila izložena suši. Upravo su vinogradi bili najviše ugroženi sa 79%, posebice u Portugalu, Španjolskoj, Italiji, Francuskoj i Rumunjskoj. Nadalje, u svom radu navode i predviđanja drugih autora prema kojima postoji mogućnost sve češćih pojava ekstremnih suša posebice u Europi. Po pitanju suše, tla na nagibu su izloženija nedostatku vode u usporedbi s drugim poljoprivrednim tlima. Slika 2.1.2. prikazuje prostornu distribuciju jačine suše i udio pet različitih klasa indeksa zdravlja vegetacije (eng. *Vegetation Health Index*, VHI).

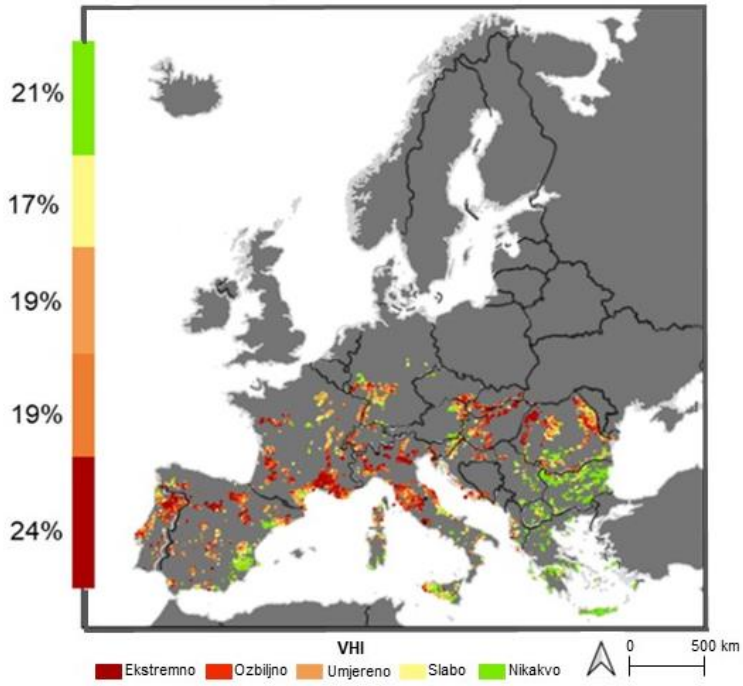

Slika 2.1.2. Prostorna distribucija jačine suše i udio različitih pet klasa indeksa zdravlja vegetacije (eng. *Vegetation Health Index*, VHI). Izvor: (Wang i sur., 2024)

2.2. Utjecaj svojstava tla na procese u tlu i proizvodni potencijal

Tlo je rastresiti površinski sloj Zemljine kore kojeg čine organske i anorganske komponente (Brady i Weil, 2016; Jones i sur., 2012), te je karakteriziran fizikalnim, kemijskim i biološkim svojstvima. U fizikalne karakteristike tla ubrajaju se mehanički sastav, struktura, poroznost, gustoća i konzistencija, a u kemijske reakcija tla, adsoprcijski kompleks, mikro- i makroelementi i humus. Tlo se sastoji od čvrste faze koju čini mineralna i organska komponenta, zraka i vode. Tekstura i struktura tla ovisit će o odnosu mineralne i organske komponente. Nadalje, s obzirom da tekstura tla predstavlja sadržaj pojedinih veličina čestica u tlu, imat će direktan utjecaj na sposobnost zadržavanja vode kao i na brzinu infiltracije i toka vode u tlu, ali i na izloženost eroziji. Struktura tla, kao fizikalno svojstvo, predstavlja način na koje se čestice tla međusobno agregiraju te utječe na fizikalna i kemijska svojstva tla. Struktura tla direktno utječe na veličinu i količinu pora u tlu što posljedično utječe i na kretanje zraka i vode u tlu, zadržavanje hranjivih tvari, ali i otpornost tla na eroziju. U porama se, ovisno o njihovoj veličini, nalazi voda ili zrak (odnosno drugi plinovi). Tako se najčešće u mikroporama ili kapilarnim porama nalazi voda, dok se u makroporama ili nekapilarnim porama nalazi zrak. Međutim, voda se nakon oborina može nalaziti i u makroporama tla, ali s obzirom da su makropore većih dimenzija (> 50 μm), u njima nema kapilarnih sila te voda slobodno istječe i

zadržava se samo u kraćim periodima (Guo i Lin, 2018; Jarvis, 2007). Upravo će ukupna poroznost uz sadržaj organske tvari, ali i teksturu i strukturu tla imati najveći utjecaj na sadržaj vode u tlu koji je jedan od bitnijih čimbenika za razvoj biljaka (Basset i sur., 2023; Gómez-Guerrero i Doane, 2018; Ramesh i sur., 2019; Rawls i sur., 2003; Schowalter, 2011; Upadhyay i Raghubanshi, 2020; Zhao i sur., 2022). Nadalje, mehanička stabilnost padine predstavlja otpornost padine na klizanje, odnosno urušavanje pod težinom samog tla ili pod utjecajem vanjskih sila (gravitacije, oborina, ljudske aktivnosti i slično) (Harabinová i sur., 2021; Kaizer Hassan i Loo, 2023). Neki od čimbenika koji imaju utjecaj na stabilnost padine su vrsta tla, vlažnost tla, vegetacijski pokrov tla i, kao najvažniji čimbenik, nagib padine. Volpe i sur. (2022) navode da korištenje teške mehanizacije stvara pretjerani pritisak na tlo što uzrokuje nestabilnost padine i degradaciju tla. Također, navode više znanstvenih radova koji upućuju na pozitivni utjecaj vegetacijskog pokrova na padini. S jedne strane, gustoća i veličina vegetacije obrnuto je proporcionalna s kinetičkom energijom kišnih kapi koje udaraju na površinu tla što smanjuje eroziju. S druge strane, korijenje biljaka uzrokuje veću stabilnost padine, odnosno smičnu čvrstoću, a jačina utjecaja direktno je ovisna o gustoći korijenovog sustava i njegova promjera. Poljoprivredne kulture uzgajaju se u kritičnoj, odnosno vadoznoj zoni tla. Kritična zona tla obuhvaća područje od površine tla do razine podzemne vode te je u toj zoni antropogeni utjecaj najizraženiji. Zbog toga je važno uspostaviti observatorije vadozne zone koji osim što prate prirodne procese u vadoznoj zoni, omogućuju i praćenje utjecaja potencijalnih onečišćivača koji se javljaju kao posljedica ljudske aktivnosti (Nimmo, 2009). U nastavku Pregleda literature bit će dalje detaljnije obrađena samo ona svojstva tla koja su direktno povezana s istraživanjima ove doktorske disertacije.

2.2.1. Hidraulička svojstva tla

Hidraulička svojstva tla određuju brzinu kojom će se voda i otopljene tvari kretati kroz tlo, a odnose se na infiltraciju, hidrauličku vodljivost i sposobnost zadržavanja vode. Tekstura i struktura tla, gustoća tla, porozitet i organska tvar, kao i obrada tla i vegetacija imaju značajan utjecaj na hidraulička svojstva tla. S obzirom da određuju tok vode isto tako utječu i na transport primijenjenih hranjiva i onečišćivača. Određivanje hidrauličkih svojstava tla važno je za predviđanje kretanja i zadržavanja vode u tlu, odvodnje i navodnjavanja, otjecanja, ispiranja hranjivih tvari, procjene proizvodnog potencijala tla, ali i za izradu klimatskih modela. Indoria i sur. (2020.) navode nekoliko istraživanja koja pokazuju da hidraulička svojstva tla direktno ili indirektno utječu na gotovo sva svojstva tla. Prostorno i vremenski su varijabilna, što rezultira kompleksnošću predviđanja toka vode u tlu. Također, nerijetko se razlikuju u različitim horizontima tla, ali se također mogu javiti i razlike u istom horizontu tla (Indoria i sur., 2020).

Infiltracijska sposobnost tla određuje brzinu upijanja vode u tlo. Infiltracija se odvija u nesaturiranim uvjetima te je voda pod utjecajem kapilarnih, osmotskih te gravitacijskih sila, a ovisi i o količini oborina, količini vode u tlu, karakteristikama tla među kojima su tekstura, hidraulička vodljivost, poroznost i zbijenost tla, sadržaju organske tvari, pokrovu tla i razvijenošću korijenovog sustava, te nagibu (Cheremisinoff, 1997; Govindaraju i Goyal, 2022; Indoria i sur., 2020). Brzina kojom voda ulazi u tlo naziva se stopa infiltracije. Količina oborina i količina vode u tlu mogu biti ključni faktori koji će utjecati na infiltracijsku sposobnost tla. Na primjer, na istoj proizvodnoj površini u ljetnim i zimskim mjesecima se infiltracijska sposobnost tla može razlikovati. U ljetnim mjesecima izraženiji su sušni periodi, ali i kratkotrajne oborine visokog intenziteta što može rezultirati nižom infiltracijom. Posebno je to izraženo na nagnutim terenima gdje će uslijed niže infiltracije doći do povećanog površinskog otjecanja i erozije tla, a u iznimnim situacijama može doći i do poplave na dijelovima niže nadmorske visine ili čak do razvoja klizišta (Scherrer i sur., 2007; Tichavský i sur., 2019). Također, količina površinskog otjecanja utjecat će i na ispiranje primijenjenih agrokemikalija, punjenje podzemnih vodnih resursa, te konačno i na rast i razvoj biljaka te održivost ekosustava (Chen i sur., 2021; Defterdarović i sur., 2024; Indoria i sur., 2020). Nadalje, infiltracija ovisi i o kvaliteti vode pri čemu će, primjerice, zaslanjenost vode imati direktan utjecaj na brzinu infiltracije. Obrada tla kratkoročno pozitivno djeluje na infiltraciju, odnosno povećava je, ali dugoročno su poroznost tla i infiltracija manji u odnosu na tla prekrivena malčom (Indoria i sur., 2020). Uz to, obrada tla može biti posebice izazovna na tlima na nagibu zbog pojačane erozije tla (Bogunovic i sur., 2018; Telak i Bogunovic, 2020). Defterdarović i sur. (2024) navode rad Morbidellija i suradnika (Morbidelli i sur., 2018), prema kojemu se stopa infiltracije smanjuje kako se povećava nagib jer se smanjuje raspoloživo vrijeme za infiltraciju oborina. Infiltracijska sposobnost tla, može se, među ostalim, odrediti mini disk infiltrometrom (MDI). To je često korištena metoda za određivanje infiltracije i u laboratorijskim (Li i sur., 2005; Soracco i sur., 2019) i u terenskim (Bátková i sur., 2020; Naik i sur., 2019; Radinja i sur., 2019) uvjetima. Hidrauličko svojstvo tla koje utječe na infiltraciju je hidraulička vodljivost jer upravo to svojstvo određuje brzinu infiltracije. Veća hidraulička vodljivost omogućuje izraženiju infiltraciju oborina čime se smanjuje površinsko otjecanje, a time i erozija (Chen i sur., 2021). Saturirana hidraulička vodljivost predstavlja masu vode koja prolazi kroz jedinicu površine u jedinici vremena u saturiranim uvjetima (Blok i sur., 2019). Na saturiranu hidrauličku vodljivost najviše utječe vegetacija, tekstura, topografija, klimatski uvjeti i ljudska aktivnost (Indoria i sur., 2020). Hidraulička vodljivost je općenito svojstvo tla koje je varijabilno kroz prostor i vrijeme, što posebice dolazi do izražaja na nagnutim terenima. Ovisna je o teksturi i gustoći tla, agrotehničkim mjerama, vegetaciji i rasprostranjenosti korijenovog sustava, fauni tla, a to su sve parametri koji se mogu uvelike razlikovati na različitim pozicijama na padini (Chen i sur., 2021). Hidraulička vodljivost tla može se mjeriti u saturiranim i nesaturiranim uvjetima te na

terenu i u laboratoriju. Neke od metoda kojima se može odrediti hidraulička vodljivost tla su mjerenja prikupljena mini disk infiltrometrom, prstenastim inifltrometrima (eng. *single ring i double ring infiltrometer*), tlačnim infiltrometrom, permeametrom ili pomoću KSAT i HYPROP uređaja. Hidraulička vodljivost mjerena je izračunom volumetrijskog toka vode, površine i dužine uzorka tla i hidrauličkom gradijentu, odnosno Darcyjevom jednadžbom (UMS, 2017). Nakon što se voda infiltrirala u tlo, iduće važno svojstvo je zadržavanje vode u tlu, odnosno sposobnost tla da zadrži vodu u porama tla izloženim raznim silama koje se javljaju u tlu. Rast i razvoj vegetacije na pojedinoj lokaciji ovisno je o ovome svojstvu. Zadržavanje vode u tlu najviše ovisi o teksturi, poroznosti tla i organskoj tvari (Indoria i sur., 2020). Također, pod pojmovima kapaciteta tla za vodu razlikujemo i maksimalni kapacitet tla za vodu, poljski kapacitet tla za vodu te točku venuća. Pod pojmom maksimalni kapacitet tla za vodu podrazumijevamo maksimalnu količinu vode koju tlo može primiti, ali ne i zadržati. To je stanje potpune saturiranosti tla vodom. Pri poljskom vodnom kapacitetu makropore tla ispunjene su zrakom, a mikropore vodom. Poljski kapacitet označava maksimalnu količinu vode zadržanu u tlu koja je pristupačna biljakama. Točka venuća je količina vode u tlu koja je nedovoljna potrebama biljke pri čemu ubrzo dolazi do venuća. Za većinu biljaka točka venuća je kada vodni potencijal tla padne ispod -1500 kPa (Brady i Weil, 2016).

Procjena hidrauličkih svojstava tla moguća je u laboratorijskim uvjetima pomoću HYPROP (HYdraulic PROPerty analizator, METER Group, Inc., Pullman, WA, USA) sustava, kutije s pijeskom (eng. *sandbox*), tlačnog ekstraktora i tlačne membrane. Mjerenje pomoću HYPROP sustava (Bezerra-Coelho i sur., 2018; Hohenbrink i sur., 2023; Lipovetsky i sur., 2020) bazira se na evaporacijskoj metodi pri čemu se kontinuirano mjeri promjena u masi neporušenog uzorka (Campbell i sur., 2015). WP4C se koristi kako bi se odredile točke u suhom dijelu krivulje. Nakon provedenog mjerenja, procjenjuju se pojedini parametri među kojima su i rezidualna količina vode, količina vode u saturiranim uvjetima te hidraulička vodljivost. Nadalje, HYPROP-FIT program omogućuje izradu retencijskim krivulja i krivulja hidrauličke vodljivosti tla. U navedenom programu moguće je birati između *original,* odnosno unimodalne funkcije, *PDI*, što se odnosi na imena autora (Peters, Durner i Iden), *bimodalne* i *bimodalne PDI*, a ovisi o kompleksnosti, odnosno homogenosti i heterogenosti istraživanog tla. Također, moguće je birati i između Brooks-Corey, Fredlund-Xing, Kosugi i van Genuchten (Durner, 2017). Navedena svojstva tla su dalje korištena za numeričko modeliranje kao ulazi podaci. Tako su Filipović i sur. (2022) usporedili uni- i bimodalni model korišten u HYRPOP-FIT programu kako bi usporedili razlike između tri vinograda izložena eroziji te između vrha i dna padina. Defterdarović i sur. (2024) koristili su ga u radu gdje su istraživali utjecaj poljoprivrede na padinskim tlima na zbijenost tla i sezonsku varijabilnost u dinamici vode u tlu. Domúnguez-Niño i sur. (2020) uspoređivali su simulacije u HYDRUS-3D programu u kojima su hidraulička

svojstva tla dobivena putem Rosette i HYPROP-FIT programa te su se rezultati dobiveni HYPROP metodom pokazali bolji. Osim navedenih istraživanja postoje još mnogi radovi u kojima je korištena navedena metoda (Bezerra-Coelho i sur., 2018; Haghverdi i sur., 2020, 2018; Jabro i Stevens, 2022; Karbout i sur., 2018; Lipovetsky i sur., 2020; Mbarki i sur., 2023; Singh i sur., 2021). Hidraulička svojstva tla važna su za razumijevanje toka vode i transporta tvari i imaju direktan utjecaj na zadržavanje vode, brzinu toka, transport hranjiva, kemikalija i onečišćivača u tlu. Osim toga, određuju i dostupnost vode za usvajanje od strane biljaka, kao i njihov rast i razvoj. Upravo je zbog toga važno poznavanje hidrauličkih svojstava tla kako bi se osiguralo optimalno upravljanje tlima i vodama (Defterdarović i sur., 2021).

2.3. Tok vode u tlu

Tok vode u tlu odvija se u saturiranim i nesaturiranim uvjetima (Brady i Weil, 2016), a najvažniji parametri koji utječu na tok vode su tekstura i struktura tla, te slojevitost tla (O'Geen, 2013). Tok vode započinje kada se javi energetski gradijent između dvije zone u tlu pri čemu se tok odvija iz područja većeg vodnog potencijala prema području manjeg. Brady i Weil (Brady i Weil, 2016) objasnili su razlike između saturiranog i nesaturiranog toka vode. Saturirani tok vode javlja se u uvjetima kada su sve pore ispunjene vodom, a pod utjecajem je gravitacije. Saturacija tla vodom može se javiti u donjim horizontima slabije propusnih tala ili iznad slabije propusnih horizonata u tlu koji ograničavaju tok vode u dublje horizonte. Također, gornji slojevi tla mogu biti saturirani tijekom i odmah nakon oborina ili navodnjavanja. Saturirani tok vode u tlu opisan je Darcyjevim zakonom. Ipak, u tlu se većinom odvija kompleksniji, nesaturirani tok vode. U ovom slučaju, voda se nalazi samo u mikroporama tla, dok su makropore ispunjene zrakom, a sadržaj vode i vodni potencijal vrlo su varijabilni. Upravo će to utjecati na brzinu i smjer toka vode što čini određivanje toka u nesaturiranim uvjetima izazovnijim. Nesaturirani tok je pod utjecajem matričnog potencijala, odnosno tok se javlja zbog razlika u matričnom potencijalu vlažnog i suhog dijela tla. Tok vode iz vlažnijeg u suši dio tla, bit će izraženiji u početku, a kako se smanjuje razlika u matričnim potencijalima, tok će se smanjivati. U prirodi je najčešće prisutan neujednačeni tok vode uslijed prisutnosti pukotina u tlu, kao i flore i faune tla, razlika u hidrauličkoj vodljivosti i/ili teksturi tla između dva horizonta i drugo (Li i sur., 2020; Phillips, 2021; Zhang i sur., 2014). Takav tok naziva se preferencijalni tok vode.

2.3.1. Preferencijalni tok vode

Preferencijalni, odnosno neujednačen ili nejednak tok, pojava je u kojoj se plin, tekućina i/ili otopljene tvari prvenstveno kreću kroz jedan dio poroznog medija pritom zaobilazeći veći dio

poroznog sustava (Guo i Lin, 2018). Više faktora utječe na pojavnost preferencijalnog toka u tlu. Vegetacija djeluje dvojako na preferencijalni tok. S jedne strane, korijenje biljaka osigurava više pora u tlu te time povećava preferencijalni tok, a s druge strane korijenje usvaja vodu što smanjuje količinu vode koja se kreće preferencijalnim tokom (Stumpp i Maloszewski, 2010). Fauna tla povećava preferencijalni tok tako što stvara nove puteve za tok vode (Hartmann i sur., 2020). Zbijanje tla također može imati dvojaki utjecaj – s jedne strane može uzrokovati jači lateralni preferencijalni tok uslijed razlike u hidrauličkoj vodljivosti između dva horizonta, a s druge strane može narušiti sustav makropora (Jarvis, 2007; Sander i Gerke, 2007). Nimmo (2021) navodi brojna istraživanja preferencijalnog toka upravo zbog velikog ekološkog i ekonomskog utjecaja kojeg ima. S ekološkog aspekta važan je jer smanjuje vrijeme prolaska otopljenih tvari kroz nesaturiranu zonu što može izazvati onečišćenje vodnih resursa (Brindt i sur., 2023; Steenhuis i sur., 2004). Također, ima utjecaj i na hidrološki ciklus, eroziju tla, poljoprivrednu proizvodnju, kvalitetu okoliša te na druge biokemijske i ekološke procese. Pozitivan utjecaj ima na regulaciju poplava, sprečavanje erozije i napajanje vodonosnika, a negativni utjecaj uglavnom u bržem pronosu onečišćivača u podzemne vode čime bitno utječe na kvalitetu vode (Guo i Lin, 2018; Nimmo, 2021). Nimmo (2021) također upućuje na važnost preferencijalnog toka u poljoprivrednoj proizvodnji s obzirom da utječe na potrebe za navodnjavanjem, količinu vode oko korijena, kao i na distribuciju i transport hranjivih tvari i otpadnih kemikalija. U tlima se često nalaze velike povezane pukotine nastale, na primjer, kretanjem glista, raspadnutog korijenja ili pukotinama nastalih sušenjem glinenih tala koja bubre (Gerke, 2006). Preferencijalni tok može se podijeliti na tok u makroporama tla koji nastaje kao posljedica aktivnosti flore i faune tla te erozijskih pukotina, zatim ljevkasti tok (engl. *funnel flow*) koji nastaje kao posljedica teksturne heterogenosti što rezultira različitom hidrauličkom vodljivošću, te prstasti tok (eng. *finger flow*) koji nastaje kao posljedica repelentnosti tla za vodu (Gerke, 2006; Guo i Lin, 2018; Nimmo, 2021). Slika 2.3.1.1. prikazuje različite oblike preferencijalnog toka koji se mogu javiti u tlu.

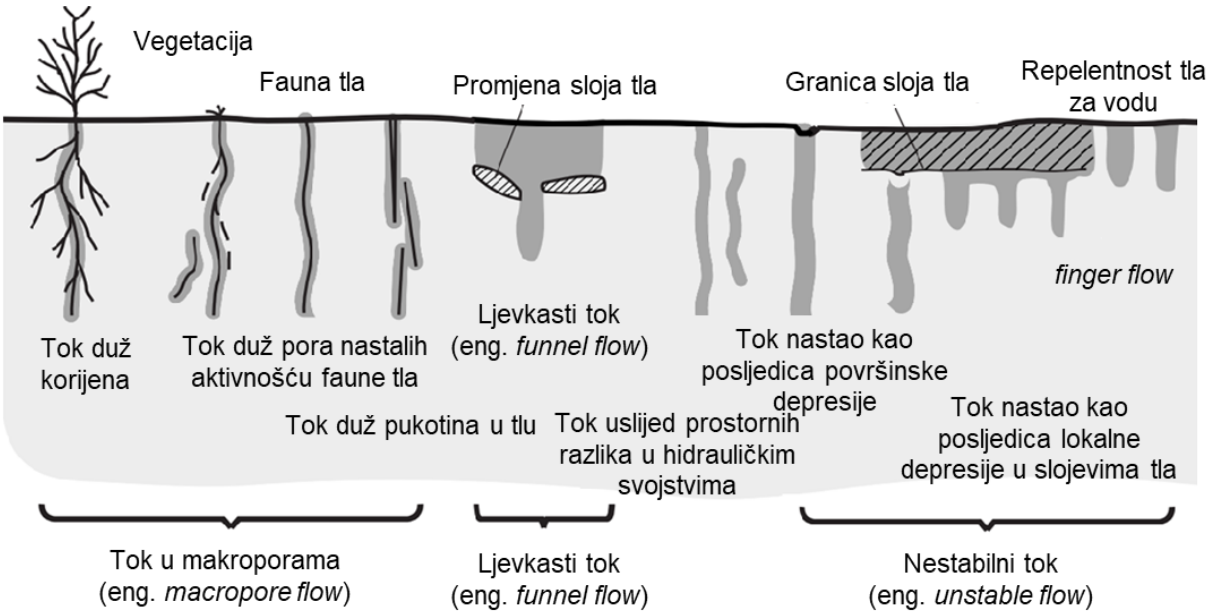

Slika 2.3.1.1. Prikaz različitih oblika preferencijalnog toka koji se mogu javiti u tlu (Hendrickx i Flury, 2001).

Nimmo (2021) je detaljnije opisao razlike između ovih oblika preferencijalnog toka. S obzirom da ljevkasti tok (eng. *funnel flow*) karakterizira promjena u hidrauličkim svojstvima tla, često se javlja na prijelazima iz jednog horizonta tla u drugi. U tim slučajevima voda će zaobići dijelove tla sa slabijom hidrauličkom vodljivošću te će se tok nastaviti u dubljim, propusnijim dijelovima tla (Gerke, 2006; Nimmo, 2021). Upravo ta promjena u hidrauličkoj vodljivosti dovodi do ljevkastog izgleda toka po čemu je ova vrsta preferencijalnog toka i dobila ime (Slika 2.3.1.1.). Također, isti autor navodi da ovaj tok ima važan doprinos u potpovršinskom procjeđivanju. Nimmo (2021) citira nekoliko radova u kojima je opisan utjecaj ljevkastog toka. Tako je Beasleyovo istraživanje pokazalo da se uslijed prisutnosti slabo propusnog glinenog horizonta na padini čak 90% oborina lateralno procijedilo potpovršinskim putem. Nadalje, tzv. *finger flow* se javlja zbog razlike u vlažnosti. Te razlike se mogu javiti zbog drugačije strukture ili teksturnog sastava tla ili zbog hidrofobnosti tla. Kod ovog oblika preferencijalnog toka vidi se značajan utjecaj sadržaja vode u tlu na hidrauličku vodljivost. Te vrijednosti mogu varirati i preko sedam redova veličine pri čemu će se preferencijalni tok uspostaviti u vlažnijim dijelovima tla. Što je veća razlika u vlažnosti tla, tok će biti izraženiji. U slučaju navedenog toka, preferencijalni tok je pod utjecaj gravitacije te se ne javlja tok u lateralnom smjeru zbog slabije propusnosti uslijed niže vlage tla (Nimmo, 2021., de Rooij, 2000.). Najpoznatiji oblik, koji je često i korišten kao sinonim za preferencijalni tok, je tok u makroporama tla. Tok kroz makropore ovisi o njihovoj dužini, promjeru, povezanosti i kontinuitetu (Jarvis, 2007; Nimmo, 2021). Gerke (2006) navodi kako se preferencijalni tok makroporama može podijeliti na tok u pojedinačnim porama ili u mreži povezanih pora. Makropore se najčešće odnose na biopore

nastale aktivnostima flore i faune tla, pukotine nastale bubrenjem i skupljanjem gline, ali također se odnose i na manje izražene pore u tlu (Gerke, 2006; Nimmo, 2021). Upravo ovim oblikom toka, mogu se transportirati velike količine vode. Isti autor navodi istraživanje u kojem je utvrđeno da iako se preferencijalni tok javio samo dva do sedam puta tijekom jedne godine, bio je odgovoran za čak 16 – 27% tokova u zoni korijena. Postoji nekoliko metoda kojima se mogu odrediti preferencijalni tokovi u tlu, bilo na terenu ili u laboratoriju. Najčešće korištene metode su primjene različitih obilježivača (trasera) (Filipović i sur., 2020; Kodešová i sur., 2015, 2012; Li i sur., 2020; Zhang i sur., 2021, 2018), a kao neinvazivna metoda koristi se kompjutorska tomografija (CT) (Leue i sur., 2019; Luo i sur., 2008; Zhang i sur., 2018). Kao obilježivači se koriste otopine, najčešće klorida ili bromida (Bero i sur., 2016; Dusek i sur., 2015; Everts i Kanwar, 1990; Huang i sur., 2019; Pietrzak i sur., 2019; Rasul i sur., 2018) s obzirom da su oni negativno nabijeni kao i tlo te ne dolazi do njihovog vezanja za čestice tla. S druge strane, za vizualizaciju toka vode mogu se koristiti pojedina bojila, a najčešće se koristi briljatno plavo bojilo (Brilliant Blue) (Defterdarović i sur., 2023; Filipović i sur., 2020).

2.3.2. Površinsko otjecanje i potpovršinsko procjeđivanje

Površinsko otjecanje predstavlja kretanje vode po površini tla, a javlja se kada je dotok vode na površini tla veći od infiltracijske sposobnosti tla (Ramke, 2018). Također, otjecanje se može javiti i prilikom intenzivnih oborina, u slučajevima saturacije tla ili repelentnosti tla za vodu. Repelentnost tla za vodu ili hidrofobnost tla svojstvo je koje spriječava da se voda infiltrira u tlo. Taj period može potrajati od nekoliko minuta do čak nekoliko tjedana (Doerr i sur., 2000). Popović i Cerdà (Popović i Cerdà, 2023) navode rad Smettem i sur. (2021.) gdje se kao parametri koji utječu na repelentnost tla spominje vegetacija, klima, tip tla, hidrološki procesi i gospodarenje u agroekosustavima. Yost i Hartemink (2019) tome još dodaju i teksturu tla, sadržaj organske tvari i pH te navode da pjeskovita tla postaju repelentnija što je veći sadržaj organske tvari i niži pH. Prema Popović i Cerdà (2023.) vegetacija ima važnu ulogu u razvoju repelentnosti tla s obzirom da pojedine kulture mogu biti izvor hidrofobnih spojeva. Hidrofobnost tla utječe na infiltraciju oborina, te samim time direktno i na površinsko otjecanje, eroziju, gubitak organske tvari i smanjenje plodnosti tla (Popović i Cerdà, 2023). Također, hidrofobnost utječe i na pojavu preferencijalnih tokova čime se ubrazava i pronos agrokemikalija te lošije gospodarenje vodom (Doerr i sur., 2000; Nimmo, 2021). U današnje vrijeme sve su češće pojave ekstremnih klimatskih uvjeta koji rezultiraju manjom količinom oborina, odnosno kratkotrajnim oborinama visokog intenziteta, visokim temperaturama i sušom u ljetnom periodu što povećava repelentnost tla. Nadalje, kao što je već ranije spomenuto, u radu Defterdarović i sur. (2024), infiltracija ima direktan utjecaj na površinsko

otjecanje što je posebice izraženo na tlima na nagibu. Što je veći nagib, infiltracija se smanjuje zbog kraćeg vremena koje je raspoloživo za infiltraciju oborina. Prema Ramke (2018) površinsko otjecanje ovisno je i o vegetaciji, tipu tla i početnom sadržaju vode u tlu, dok Hallema i sur. (2016) navode i topografske čimbenike koji utječu na površinsko otjecanje (npr. nadmorska visina, nagib, duljina padine, te zakrivljenost profila i tlocrta). Površinsko otjecanje posebno je izraženo u sušnim uvjetima kada površina tla postane hidrofobna te voda otječe u niže dijelove padine, a s tokom vode se javlja i erozija tla. Phi i sur. (2013) proveli su istraživanje u kojem su između ostalog proučavali utjecaj početne vlage tla na pojavnost površinskog otjecanja te su utvrdili da vlažnije tlo prije reagira na oborine u usporedbi sa sušim tlom. Meshkat i sur. (2019) ističu rad u kojem je utvrđeno da se površinsko otjecanje smanjuje povećanjem koeficijenta hrapavosti. Isti autori navode i još jedan rad u kojem je istraživano devet različitih intenziteta kiše od 10 do 90 mm h^{-1} pod nagibom između 0 i 40%. Rezultati su pokazali da je najveće površinsko otjecanje zabilježeno na nagibu od 20%, a porastom nagiba iznad toga nije zabilježeno signifikantno povećanje u površinskom otjecanju. Slično istraživanje su proveli i Qian i sur. (2016) koji su istraživali utjecaj nagiba od 5º, 10º, 15º i 20º i intenzitet oborina između 0,6 i 2,54 mm min^{-1}. Prema njihovim rezultatima ključan nagib je bio od 10º, a sedimentacija tla na nižim dijelovima padine uslijed otjecanja bila je pod utjecajem i intenziteta oborina i nagiba. Ipak, utjecaj intenziteta oborina bio je nešto izraženiji od utjecaja nagiba. Slika 2.3.2.1. prikazuje tokove vode na padini.

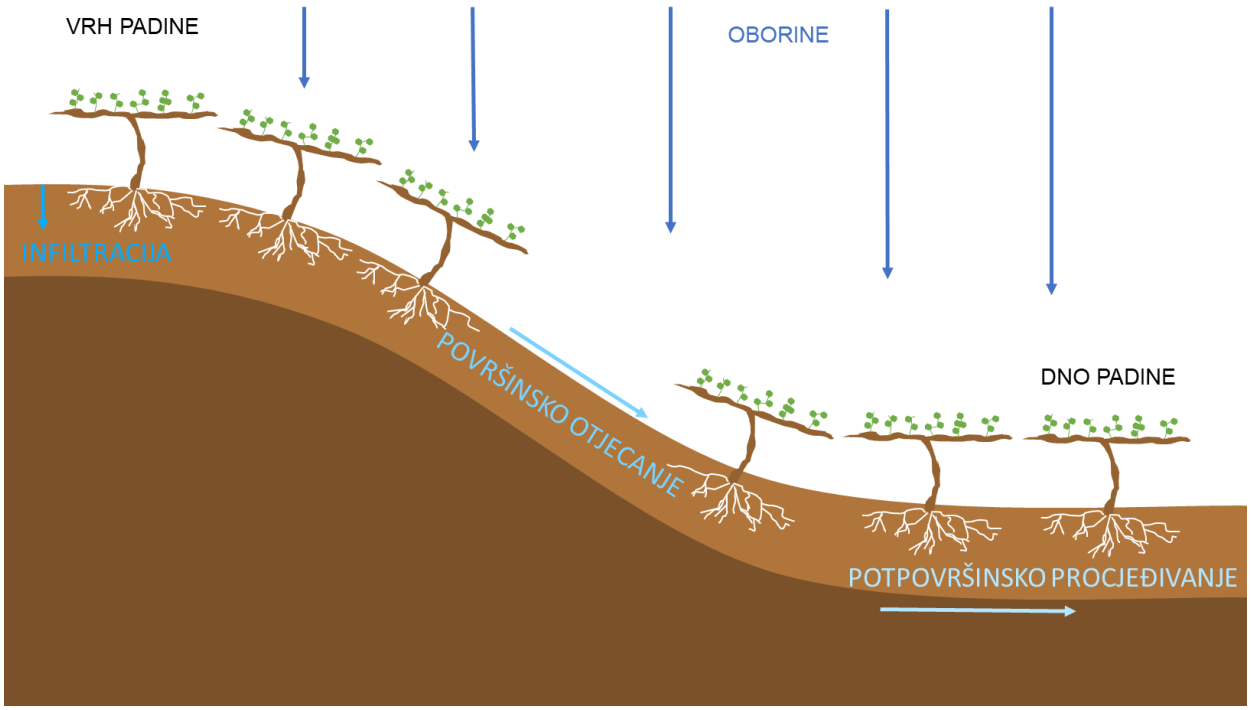

Slika 2.3.2.1. Prikaz specifičnih tokova vode koji se javljaju na terenima na nagibu.

Potpovršinsko procjeđivanje javlja se na granici dva horizonta tla gdje dolazi do promjene u gustoći tla ili hidrauličkoj vodljivosti (van i sur., 2011). Sličnu definiciju spominju i Ehrhardt i sur. (2023) koji navode rad prema kojemu se lateralni potpovršinski tok javlja uslijed preusmjeravanja vertikalnog toka kao posljedica nailaska na granice horizonata ili tabana pluga koji se javlja kao posljedica stalne obrade na istoj dubini. Kako bi se potpovršinski lateralni tok razvio, bitno je da je osim razlike između dva horizonta prisutan i nagib. Najčešće je takav tok najizraženiji na sredini padine jer je obično tamo i najizraženiji nagib, a voda se zatim akumulira na dnu padine (van i sur., 2011). Potpovršinski tok dovodi do pojačanog transporta apliciranih pesticida i hranjivih tvari dalje u okoliš, dok je procjena transporta i dalje vrlo izazovna zbog heterogenosti koje se javljaju u nezasićenoj zoni tla (Ehrhardt i sur., 2023). Također, potpovršinski tok može u pojedinim slučajevima utjecati i na stabilnost padine. Početni sadržaj vode u tlu, kao i kod površinskog otjecanja, utječe i na potpovršinsko procjeđivanje. Tako su Dahlke i sur. (2012) istraživali potpovršinski tok vode te su, između ostalog, utvrdili da će se većom saturacijom potpovršinskih horizonata, smanjiti vertikalna perkolacija vode što će rezultirati pojavom lateralnog potpovršinskog toka. Nadalje, Kampf (2011) je istraživala utjecaj inicijalnog sadržaja vode u tlu na pojavnost potpovršinskog otjecanja tijekom oborina.

2.4. Numeričko modeliranje u hidrologiji

S obzirom na navedeno, ali također imajući na umu i aktualne klimatske promjene, jasno je da su potrebna i potencijalna predviđanja, kako za odvodnju tako i za navodnjavanje, ali također i za potencijalne opasnosti koje prijete ekosustavima. Prema Šimůnek i sur. (2024) HYDRUS se već nekoliko desetljeća koristi prilikom istraživanja fizikalnih, kemijskih i bioloških procesa posebice u vadoznoj zoni tla. HYDRUS radi na principu linearne metode konačnih elemenata Galerkinovog tipa. Program također omogućuje i izradu inverznih modela pri čemu je moguće odrediti nepoznata svojstva tla preko onih poznatih (Šimůnek i sur., 2024). Predviđanje i opisivanje specifičnih procesa u (ne)saturiranoj zoni tla omogućeno je modelima toka vode i pronosa tvari koji je ovisan o toku vode u nesaturiranoj zoni te je za modeliranje važno procijeniti vodnu bilancu tla (Ondrašek i sur., 2015). Simulacija toka vode najčešće je opisana Richardsovom jednadžbom za Darcyjev tok vode u (ne)saturiranom poroznom mediju (Deng i Wang, 2017), dok je transport otopljenih tvari opisan jednadžbom advekcije i disperzije. Richardsova jednadžba uglavnom se koristi za uniformni tok vode u (ne)saturiranom poroznom mediju. HYDRUS koristi retencijsku krivulju i hidrauličku vodljivost procijenjene Brooks i Corey (1964.), van Genuchten (1980.), Kosugi (1996.) ili Durner (1994.) modelima (Šimůnek i sur., 2008). Osim toga, podatke o retenciji vode i K_S mogu se dobiti i

korištenjem pedotransfernih funkcija (PTF) pri čemu su navedeni parametri procijenjeni preko teksture tla (Šimůnek i sur., 2024). Tijekom izrade modela moguće je postaviti različite granične, odnosno atmosferske uvjete, od infiltracije, zadržavanja vode, površinskog otjecanja, navodnjavanja do evaporacije. Međutim primjena ovih jednadžbi ograničena je za simulacije uniformnih tokova u tlu jer ne uzimaju u obzir heterogenosti koje se javljaju pri preferencijalnim tokovima i neravnotežnim transportnim procesima (Gerke, 2006; Šimůnek i sur., 2008). Kao što je već ranije spomenuto, očitiji primjeri preferencijalnog toka su brzo kretanje vode i otopljenih tvari kroz makropore između agregata tla, kroz pore nastale aktivnošću flore i faune tla ili čak unutar fragmenata stijena, međutim preferencijalni tok se javlja i kao posljedica razlika u teksturi tla ili uslijed repelentnosti tla za vodu. Upravo se preferencijalni tokovi u makroporama i fragmentima stijena zbog svoje heterogenosti rješavaju kompleksnijim modelima dvostruke poroznosti i dvostruke propusnosti (Šimůnek i sur., 2008).

Kao što je već ranije spomenuto, poljoprivredna proizvodnja na nagnutim terenima često rezultira takvim heterogenostima duž padine te je nerijetko upravo iz tog razloga potrebna upotreba kompleksnijih modela jer modeli jednostruke poroznosti često ne daju pouzdane rezultate u takvim uvjetima. Slika 2.4.1. prikazuje razliku između tri navedena modela.

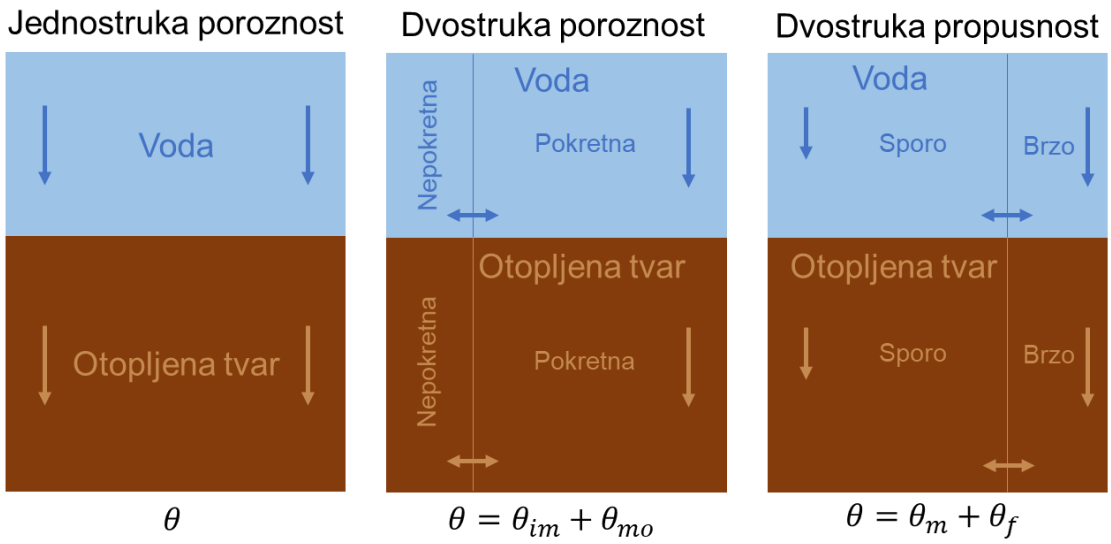

Slika 2.4.1. Prikaz konceptualnih modela (jednostruke i dvostruke poroznosti i dvostruke propusnosti) toka vode i transporta otopljenih tvari. θ predstavlja sadržaj vode, θ_{im} nepokretnu vodu, θ_{mo} pokretnu vodu, θ_m vodu u matriksu tla, a θ_f vodu u makroporama tla (Simunek i van Genuchten, 2007).

Pretpostavka modela jednostruke poroznosti je da postoji samo jedan sustav koji je u potpunosti dostupan vodi i otopljenoj tvari. S druge strane, model dvostruke poroznosti i dvostruke propusnosti pretpostavljaju da se porozni medij sastoji od dva međusobno povezana sustava pri čemu je jedan povezan s interagregatom, odnosno makroporama, a

drugi s intraagregatom, odnosno mikroporama. Razlika između modela dvostruke poroznosti i dvostruke propusnosti je da prvi model kreće od pretpostavke da voda u matriksu tla stagnira, dok drugi model uzima u obzir i tok vode unutar matriksa tla (Gärdenäs i sur., 2006; Simunek i van Genuchten, 2007).

S druge strane, simulacije transporta otopljenih tvari kompleksnije su u odnosu na simulacije toka vode te zahtijevaju unos određenih parametara kao na primjer disperzivnosti, koeficijenta difuzije u tekućoj i plinovitoj fazi, sorpciju i degradaciju (Gerke, 2006; Šimůnek i sur., 2008). Postoji nekoliko načina kojima se može simulirati transport otopljenih tvari. SWMS_2D i SWMS_3D su modeli koji su prethodili HYDRUS modelu koji su polazili od pretpostavke da se otopljene tvari u tlu nalaze samo u tekućoj i čvrstoj fazi. Međutim, HYDRUS polazi od pretpostavke da se tvari nalaze i u plinovitoj fazi te da sudjeluju u lančanim reakcijama raspada prvog reda. Neravnotežni transport otopljenih tvari u HYDRUS-1D i HYDRUS (2D/3D) modelima podijeljen je u tri grupe pri čemu se prva odnosi na fizikalni neravnotežni transport, druga na kemijski neravnotežni transport, dok je u trećoj grupi obuhvaćena kombinacija fizikalnog i kemijskog neravnotežnog transporta. Općenito je pri simulaciji transporta otopljenih tvari u tlu potrebno uzeti u obzir brojne čimbenike jer se transport odvija pod utjecajem brojnih nelinearnih i interaktivnih fizikalnih, kemijskih i bioloških procesa. Kako bi se i pri izradi simulacija uzeli u obzir navedeni čimbenici u HYDRUS su uključeni razni programski dodatci kao na primjer UNSATCHEM, PHREEQC (HP1) i CW2D (Šimůnek i sur., 2008).

Filipović i sur. (2020) koristili su modele jednostruke poroznosti i dvostruke propusnosti za opisivanje toka vode i pronosa otopljenih tvari preferencijalnim tokovima u tlu s izraženom strukturom. Za potrebe istraživanja uzorkovane su kolone s neporušenim tlom na kojima se pratio tok vode isprekidanim navodnjavanjem. Simulacije toka vode bazirale su se na Richardsovoj jednadžbi u modelu jednostruke poroznosti. Jednadžba advekcije i disperzije korištena je kako bi se simulirao transport otopljenih tvari, u ovom slučaju briljantno plavog bojila. Simulacije toka vode u modelu dvostruke propusnosti također su se bazirale na Richardsovoj jednadžbi, ali ovaj put u kombinaciji dvije formule pri čemu je jedna korištena za domenu makropora, a druga za matriks tla. Simulacije transporta otopljenih tvari u modelu dvostruke propusnosti dobivene su kombinacijom jednadžbi advekcije i disperzije. Köhne i sur. (2006) koristili su inverzni model dvostruke propusnosti kako bi simulirali preferencijalne tokove u koloni s tlom. Inverzni modeli omogućuju procjenu svojstava koje je inače teško utvrditi, a potrebni su za simulacije neravnotežnih tokova u tlu i modele dvostruke propusnosti. Filipović i sur. (2019) koristili su 1D model dvostruke propusnosti kako bi simulirali tok vode i transport bromida u tlu koje je zbijeno uslijed mehanizacije. Također, za prikaz transporta bromida, Gerke i sur. (2007) koristili su 2D model dvostruke propusnosti. Zhou i sur. (2023) koristili su HYDRUS-1D kako bi simulirali tok vode i transport otopljenih tvari s površine tla do

podzemnih voda u tri profila s različitim udjelima pijeska u teksturnom sastavu. U istraživanju su korišteni modeli jednostruke i dvostruke poroznosti te je utvrđen utjecaj potpovršinske heterogenosti na brzinu transporta onečišćivača u tlu. Krevh i sur. (2022) su pomoću HYDRUS-1D istraživali kako oscilacije podzemnih voda utječu na vlagu tla u gornjim slojevima. Za određivanje vodnog režima, u obzir su uzete razine podzemnih voda, distribucija oborina i visina obližnje rijeke, a sve ovisno o promjenama tijekom godišnjih doba. Imig i sur. (2023) koristili su HYDRUS-1D za simulaciju nesaturiranog toka i transporta stabilnih izotopa vode. Gumuła-Kawęcka i sur. (2017) koristili su 1D model za tok vode u nesaturiranoj zoni u kombinaciji s 3D modelom za podzemnu saturiranu zonu kako bi procijenili infiltraciju i napajanje podzemnih voda za različite teksturne klase tla i biljni pokrov. U svom istraživanju su koristili HYDRUS program s MODFLOW paketom što je omogućilo, s jedne strane, simulaciju toka podzemne vode MODFLOW nadogradnjom, a s druge strane, 1D simulaciju nesaturirane zone baziranu na Richardsovoj jednadžbi. Također, u navedenom paketu može se koristiti i BEST model za određivanje hidrauličkih svojstava tla pri čemu se koristi van Genuchtenov model za određivanje funkcije retencije i Brooks-Coreyev model za određivanje funkcije hidrauličke vodljivosti. Tan i sur. (2014) koristili su HYDRUS-1D kako bi simulirali tok vode u rižinim poljima tijekom sezone rasta u dvije godine (2010. – 2011.) na temelju izmjerenih hidrauličkih svojstava tla. S obzirom da se tijekom uzgoja riže koriste velike količine vode, istraživanje je obuhvaćalo usporedbu toka vode pri kontinuiranom navodnjavanju te pri isprekidanom navodnjavanju, odnosno izmjenama perioda vlaženja i sušenja. Izmjerene i simulirane vrijednosti su pokazale da je isprekidano navodnjavanje smanjilo perkolaciju za oko 38 – 40% u prvoj godini istraživanja i za oko 23 – 27% u drugoj godini istraživanja u usporedbi s kontinuiranim navodnjavanjem. Glæsner i sur. (2018) proučavali su potencijalne opasnosti aplikacije gnojnice na poljoprivrednim površina, odnosno mogućnosti ispiranja hranjiva u površinske i podzemne vode. Kako bi se bolje razumjeli procesi koji se odvijaju u tlu nakon aplikacije gnojnice, provedeni su pokusi na kolonama s neporušenim tlom pri različitim početnim i graničnim uvjetima. Prikupljeni podaci korišteni su za provedbu simulacija u modelima jednostruke i dvostruke poroznost te u modelima pokretnog-nepokretnog transporta otopljenih tvari koristeći HYDRUS program. Tijekom istraživanja je korišteno isprekidano navodnjavanje koje je imitiralo prirodne uvjete, odnosno oborine prisutne na terenu što je rezultiralo periodima sušenja i ponovnog vlaženja tla. Upravo takvi uvjeti su pokazali veću opasnost od procjeđivanja otopljenih tvari u odnosu na kontinuirano navodnjavanje. Nadalje, Wang i sur. (2018) istraživali su pouzdanost HYDRUS programa pri izradi simulacija na tlima na kojima je utvrđena repelentnost za vodu. Cilj je bio utvrditi kumulativnu infiltraciju, vlaženje i volumetrijsku vlagu tla tijekom horizontalne imbibicije i vertikalne infiltracije u slabije i jače izraženim repelentnim tlima. Dobiveni rezultati pokazali su da je HYDRUS adekvatan pri izradi simulacija i u uvjetima repelentnosti tla za vodu.

3. MATERIJALI I METODE

3.1. Opis lokacije istraživanja

Istraživanje je provedeno u sklopu SUPREHILL (Podpovršinski preferencijalni transportni procesi u poljoprivrednim padinskim tlima - SUbsurface PREferential transport processes in agricultural HILLslope soils) projekta na vinogradarsko-vinarskom pokušalištu Jazbina (45º51'24'' N 16º00'22''E) tijekom dvogodišnjeg razdoblja (2021. – 2022.). Pokusno područje nalazi se na obronku jugozapadne ekspozicije, duljine 93 m, na rigolanom tlu iz pseudogleja obronačnog s izraženim Btg horizontom (IUSS Working Group WRB, 2022). Profili su prikazani na Slici 2.1.1..

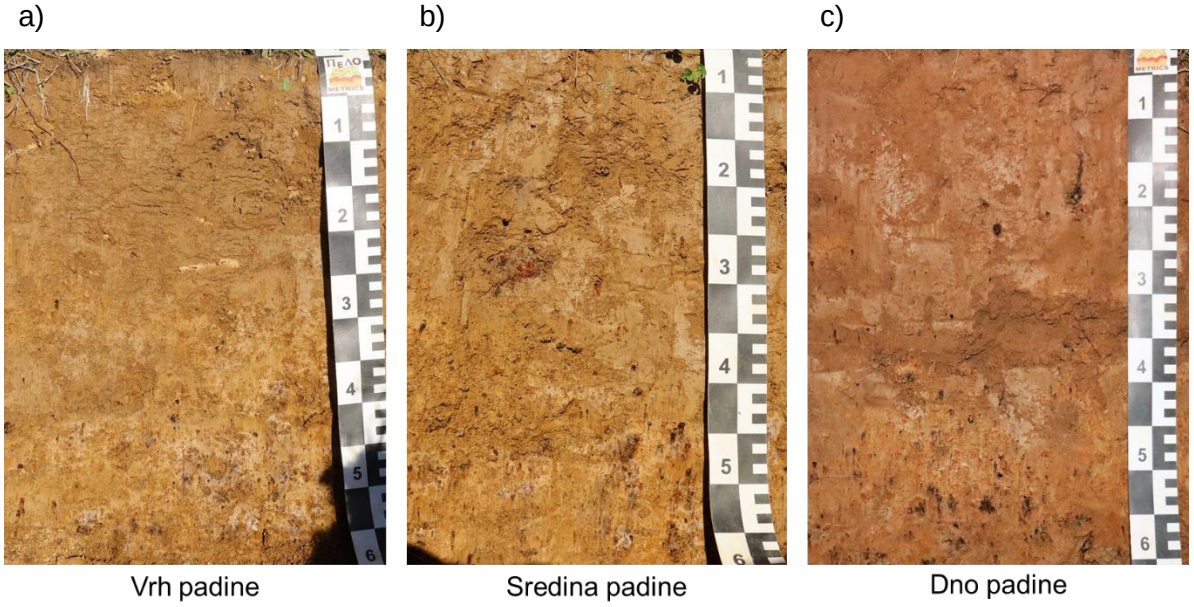

Slika 3.1.1. Prikaz profila do 60 cm dubine na rigolanom tlu iz pseudogleja obronačnog s izraženim Btg horizontu na vrhu (a), sredini (b) i dnu (c) padine na vinogradarsko-vinarskom pokušalištu Jazbina, Hrvatska.

Na istraživanoj lokaciji podignut je petnaestogodišnji nasad sorata Syrah, Dornfelder i Frankovka (*Vitis vinifera* L.). Razmak sadnje u redu je 1,2 m, dok je između redova 2,0 m te je vinograd zatravljen u redu i međuredu. Obronak je s obzirom na nagib podijeljen na dva pada – 17,5 % (vrh – sredina padine) i 25,4 % (sredina – dno padine), te je sukladno tome i pokus podijeljen na tri pozicije duž padine (Slika 3.1.2.) – vrh (A), sredina (B) i dno (C).

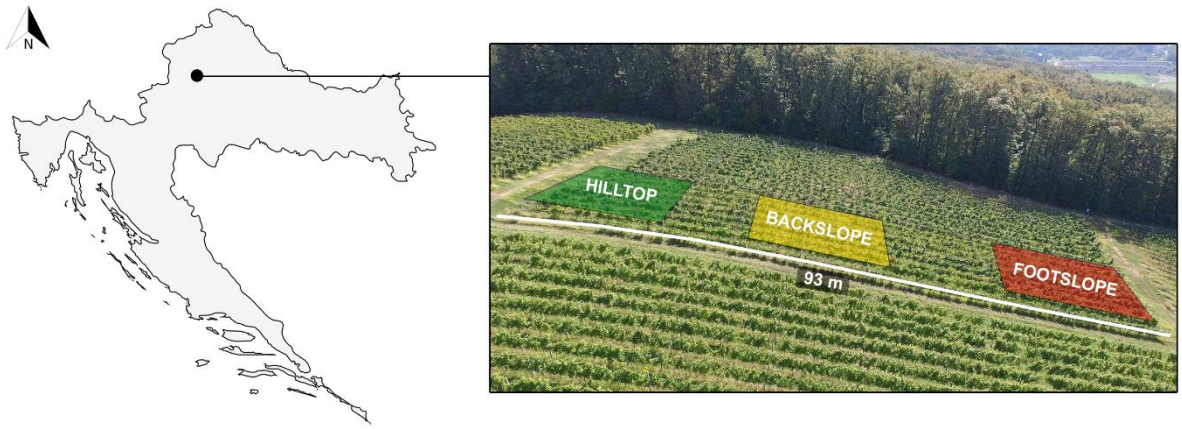

Slika 3.1.2. Lokacija SUPREHILL observatorija i prikaz istraživane padine s označenim vrhom (A), sredinom (B) i dnom (C) padine.

Prosječna godišnja količina oborina (1970. – 2020.) iznosi 856,5 mm, a prosječna godišnja temperatura zraka je 11,2 ºC. Meteorološki podaci tijekom istraživanja će se prikupljati s meteorološke stanice ATMOS41 (METER Group) koja je smještena u sredini opservatorija. Istraživanje je provedeno u periodu od 01. siječnja 2021. godine do 31. prosinca 2022. godine. Tijekom trajanja istraživanja vinograd je održavan košnjom te nije bio obrađivan kako bi se spriječilo potencijalno oštećivanje postavljene opreme.

Analiza fizikalnih i kemijskih značajki tla obavljena je u analitičkom laboratoriju Zavoda za melioracije (MELILAB) prema standardiziranim laboratorijskim metodama. Analize tla određene su na porušenim uzorcima tla uzetih s vrha (A), sredine (B) i dna (C) padine u tri ponavljanja i na tri dubine (0 – 30, 30 – 60, 60 – 90 cm). Porušeni uzorci tla pripremljeni su prema standardiziranom postupku pripreme uzoraka za fizikalne i kemijske analize HRN ISO 11464:2004 („ISO - ISO 11464:1994 - Soil quality — Pretreatment of samples for physico-chemical analyses“, bez dat.), odnosno nakon dopremanja u laboratorij osušeni su na zraku, te usitnjeni i prosijani kroz sito promjera mreže 0,5 i 2,0 mm. Granulometrijski sastav (Tablica 3.1.1.), odnosno udio pijeska, gline i praha određen je metodom prosijavanja i sedimentacije nakon disperzije s natrijevim pirofosfatom ($Na_4P_2O_7$) prema HRN ISO 11277:2004 („ISO - ISO 11277:1998 - Soil quality — Determination of particle size distribution in mineral soil material — Method by sieving and sedimentation“, bez dat.).

Tablica 3.1.1. Raspodjela granulometrijskog sastava na različitim dubinama na vrhu, sredini i dnu padine.

Pozicija na padini	Oznaka uzorka	Dubina [cm]	MEHANIČKI SASTAV TLA %				
			Krupni pijesak 2 – 0,2 mm	Sitni pijesak 0,2 – 0,063 mm	Krupni prah 0,063 – 0,02 mm	Sitni prah 0,02-0,002 mm	Glina < 0,002 mm
Vrh	AI	0 – 30	1	3	33	39	24
	AI	30 – 60	1	3	32	39	25
	AI	60 – 90	3	4	28	38	27
	AII	0 – 30	2	5	31	39	23
	AII	30 – 60	1	3	31	38	27
	AII	60 – 90	3	4	27	36	30
	AIII	0 – 30	2	4	31	40	23
	AIII	30 – 60	2	4	29	38	27
	AIII	60 – 90	5	3	21	31	40
Sredina	BI	0 – 30	2	4	32	39	23
	BI	30 – 60	2	4	31	37	26
	BI	60 – 90	11	5	20	31	33
	BII	0 – 30	3	4	29	41	23
	BII	30 – 60	3	4	31	39	23
	BII	60 – 90	9	6	28	35	22
	BIII	0 – 30	3	4	30	39	24
	BIII	30 – 60	6	6	29	35	24
	BIII	60 – 90	13	6	23	31	27
Dno	CI	0 – 30	4	4	36	42	14
	CI	30 – 60	3	4	35	43	15
	CI	60 – 90	3	3	35	38	21
	CII	0 – 30	3	4	31	44	18
	CII	30 – 60	3	4	32	40	21
	CII	60 – 90	3	4	30	38	25
	CIII	0 – 30	2	3	30	42	23
	CIII	30 – 60	3	4	29	37	27
	CIII	60 – 90	2	4	27	35	32

U Tablici 3.1.2. prikazane su kemijske karakteristike tla istraživanog vinograda. Električna vodljivost (E.C.) tla izmjerena je u suspenziji s vodom u omjeru tlo/voda 1:5 prema normi HRN ISO 11265:2004 („ISO - ISO 11265:1994/Cor 1:1996 - Soil quality — Determination of the specific electrical conductivity — Technical Corrigendum 1“, bez dat.) na EC-metru MPC 227. U ispitivanju je korišten i referentni uzorak tla dobiven međunarodnom usporedbom laboratorija za analize tla i sedimenata WEPAL-ISE (Van Dijk i Houba, 1999) u svrhu kontrole kvalitete provođenja postupka. pH tla izmjeren je u suspenziji u vodi u omjeru tlo/voda 1:5, u otopini 1 mol/l kalijeva klorida (KCl; omjer tlo/KCl 1:5) te u otopini 0,01 mol/l kalcijeva klorida ($CaCl_2$; omjer tlo/$CaCl_2$ 1:5) prema normi HRN ISO 10390:2005 („ISO - ISO 10390:2005 - Soil quality — Determination of pH“, bez dat.) na *Mettler Toledo* pH-metru. Nadalje, organski ugljik (C_{org}) određen je sulfokromnom oksidacijom prema HRN ISO 14235:1998 („ISO - ISO

14235:1998 - Soil quality — Determination of organic carbon by sulfochromic oxidation“, bez dat.).

Tablica 3.1.2. Prikaz kemijskih karakteristika tla istraživane lokacije na vrhu, sredini i dnu padine.

Pozicija na padini	Oznaka uzorka	Dubina [cm]	pH (25°C)			EC dS m^{-1}	C_{org} g kg^{-1}
			H_2O	KCl	$CaCl_2$		
Vrh	AI	0 – 30	5,3	3,9	4,7	0,039	12,18
	AI	30 – 60	5,0	3,6	4,5	0,029	6,56
	AI	60 – 90	5,0	3,6	4,5	0,039	2,61
	AII	0 – 30	5,1	3,9	4,7	0,026	11,37
	AII	30 – 60	5,1	3,6	4,5	0,040	5,39
	AII	60 – 90	5,2	3,6	4,7	0,055	1,51
	AIII	0 – 30	5,4	4,0	4,8	0,028	12,24
	AIII	30 – 60	5,3	3,9	5,0	0,041	5,80
	AIII	60 – 90	5,4	3,9	4,8	0,047	1,91
Sredina	BI	0 – 30	5,4	3,9	4,5	0,025	10,09
	BI	30 – 60	5,3	3,8	4,5	0,040	5,97
	BI	60 – 90	5,2	3,8	4,4	0,046	2,38
	BII	0 – 30	5,5	4,0	4,5	0,029	10,91
	BII	30 – 60	5,3	3,7	4,3	0,032	6,56
	BII	60 – 90	5,1	3,6	4,3	0,040	3,48
	BIII	0 – 30	5,5	3,9	4,5	0,025	8,30
	BIII	30 – 60	5,3	3,6	4,3	0,057	5,68
	BIII	60 – 90	5,3	3,5	4,3	0,056	1,74
Dno	CI	0 – 30	5,7	4,5	4,9	0,042	13,69
	CI	30 – 60	5,4	4,0	4,6	0,029	9,69
	CI	60 – 90	5,1	3,7	4,4	0,041	5,97
	CII	0 – 30	5,4	4,0	4,5	0,029	11,54
	CII	30 – 60	5,3	3,8	4,5	0,028	8,30
	CII	60 – 90	5,0	3,8	4,3	0,042	4,29
	CIII	0 – 30	5,3	3,9	4,5	0,031	11,83
	CIII	30 – 60	5,2	3,7	4,3	0,038	6,27
	CIII	60 – 90	5,0	3,5	4,2	0,051	3,94

Tijekom postavljanja eksperimenta na istraživanoj lokaciji uzeti su i uzorci za procjenu mehaničkih parametara i strukture tla. Neporušeni uzorci volumena 236 cm^3 (Slika 3.1.3.) uzeti su na vrhu (A) na dubinama od 25 i 60 cm, sredini (B) na dubinama od 30 i 60 cm te na dnu (C) padine na dubinama od 35 i 70 cm. Uzorci su dostavljeni na Sveučilište u Kielu gdje je proveden test opterećenja i test smicanja tla (Pc test) te je određena struktura tla.

Slika 3.1.3. Uzorkovanje neporušenih uzoraka tla volumena 236 cm^3 na vrhu (A), sredini (B) i dnu (C) padine.

Neporušeni uzorci tla (pet uzoraka po horizontu) zbijeni su pri poljskom vodnom kapacitetu tla za vodu (-60 hPa, pF 1,8) koristeći pneumatski edometar (engl. *uniaxial confined compression test*) pri osam različitih opterećenja od 20, 40, 60, 80, 100, 150, 300 i 400 kPa (Slika 3.1.4.). Kako bi se izbjegao dodatni stres na neporušenim uzorcima tla, trajanje testa pri svakom opterećenju bilo je dva sata (Schroeder i sur., 2022).

Na neporušenim uzorcima tla (tri uzorka po horizontu) određen je kut unutrašnjeg trenja (ϕ) i kohezije (c) koristeći Mohr-Columbov zakon čvrstoće. Uzorci su podvrgnuti testu smicanja također pri poljskom kapacitetu tla za vodu (-60 hPa, pF 1,8) pri pet različitih razina opterećenja od 20, 50, 70, 200 i 400 kP.

Slika 3.1.4. Provođenje testa opterećenja tla na neporušenim uzorcima tla volumena 236 cm^3 uzorkovanih s vrha (A), sredine (B) i dna (C) padine na Sveučilištu u Kielu (Fotografirao: Steffen Beck-Broichsitter).

Faktor stabilnosti padine, η (-), je definiran koristeći slijedeću jednadžbu (GDA-Empfehlung E2-7, 2015):

$$\eta = \frac{\tan\varphi}{\tan\beta} \geq 1{,}3 \qquad (1)$$

gdje je ϕ kut trenja [º], a β je nagib padine [º].

Vrijednost Pc kretala se između 90 i 120 kPa što se prema Njemačkom klasifikacijskom sustavu (DVWK, 1995) klasificira kao visoka. Vrijednosti parametra ϕ kretale su se između 36,5 i 42,8 º, dok su vrijednosti parametra c bile između 14,6 i 25,1 (Tablica 3.1.3.).

Tablica 3.1.3. Vrijednosti dobivene nakon test opterećenja i testa smicanja tla na neporušenim uzorcima uzetih s vrha (A), sredine (B) i dna (C) padine.

Pozicija na padini	Dubina [cm]	Pc [kPa]	ϕ [º]	c [kPa]	η 17,5 %	η 25,4 %
A	25	100,2 ± 9,1	36,5 ± 0,8	22,4 ± 5,7	6,4	3,2
	60	113,8 ± 7,4	42,8 ± 2,3	14,6 ± 2,8	7,5	3,8
B	30	93,2 ± 9,7	39,5 ± 2,9	25,1 ± 4,6	6,9	3,5
	65	110,8 ± 5,3	38,2 ± 2,4	25,8 ± 2,6	6,7	3,4
C	35	99,4 ± 9,1	39,7 ± 7,5	22,6 ± 2,5	6,9	3,5
	70	106,6 ± 4,2	37,2 ± 5,9	24,4 ± 3,3	6,5	3,3

Na jednom neporušenom uzorku tla volumena 236 cm^3 također je provedena analiza poroznog sustava prije i poslije kompakcije tla te će rezultati ukratko biti prikazani u Prilozima. Uzorci su snimljeni kompjutorskom tomografijom (CT; GE v|tome|xM 300µCT). Energija fotona X-zraka postavljena je na 220 keV s 300 µA. Slika 9.10. prikazuje CT snimku izgleda poroznog sustava na istraživanoj lokaciji prije i poslije kompakcije tla.

3.2. Terenska istraživanja

3.2.1. Lizimetarska i senzorska mjerenja

Na istraživanoj lokaciji postavljeni su nevagajući tlačni pasivni lizimetri u međurednom prostoru na dubini od 40 cm na vrhu (A), sredini (B) i dnu (C) padine (Slika 3.2.1.1.). Ukupno je postavljeno 18 nevagajućih tlačnih pasivnih lizimetara duž padine u tri reda koja čine ponavljanja. Lizimetri su napravljeni vlastitom konstrukcijom od nehrđajućeg čelika debljine 1,5 mm, a dimenzije lizimetra su 250 mm x 250 mm x 40 mm. Unutar lizimetra je postavljena mrežica u svrhu sprečavanja začepljivanja. Nadalje, kako bi se osigurao procjeđivanje, u svaki lizimetar je postavljena i stakloplastika (fiberglas) koja omogućava mali podtlak. Lizimetri su ispunjeni prosušenim tlom iz istog profila tla uz dodatak kvarcnog brašna (71 µm) na površinu

lizimetra kako bi se osigurao bolji kontakt s tlom iznad lizimetra. Ispod svakog lizimetra nalazi se kanister u koji se skuplja procijeđena voda za daljnja mjerenja. Volumen prikupljene vode mjeren je jednom mjesečno.

Slika 3.2.1.1. Prikaz konstrukcije nevagajućih tlačnih pasivnih lizimetara te njihovo postavljanje na istraživanoj lokaciji.

Meteorološka stanica (ATMOS 41, METER) smještena je na sredini vinograda te prikuplja klimatske podatke (temperatura zraka, vlažnost, brzina i smjer vjetra, Sunčevo zračenje i oborine).

Na dnu padine postavljeni su sustavi za mjerenje potpovršinskog procjeđivanja (vlastita konstrukcija; Slika 3.2.1.2. a) i b)) u tri reda koja predstavljaju ponavljanja. Također, postavljeno je tri sustava za prikupljanje površinske vode u tri reda koji su također izrađeni samostalno. Površinska voda se prikuplja s površine od 4 m^2 (2 x 2 m) omeđene pocinčanim limom kako bi se spriječio dotok vode s viših pozicija (Slika 3.2.1.2. c)).

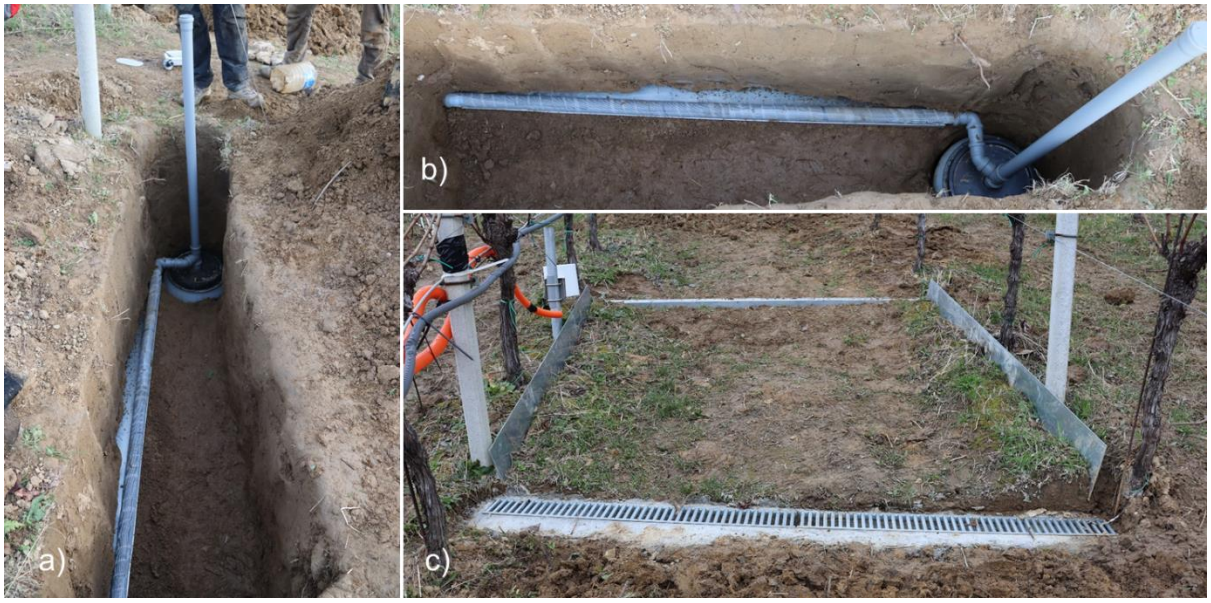

Slika 3.2.1.2. a) i b) Postavljanje sustava za mjerenje potpovršinskog procjeđivanja na dnu padine i c) sustav za prikupljanje površinskog otjecanja površine 4 m^2 postavljeni na istraživanoj lokaciji.

Na istraživanoj lokaciji postavljeni su senzori za mjerenje sadržaja vode u tlu (TEROS-10, METER) te za određivanje vodnog potencijala tla (TEROS-21, METER) na vrhu (A), sredini (B) i dnu (C) padine u međurednom prostoru (Slika 3.2.1.3. a)). Senzori za mjerenje sadržaja vlage u tlu postavljeni su na 40 i 80 cm dubine, dok su senzori za određivanje vodnog potencijala tla postavljeni na 40 cm. Senzori su spojeni s uređajima za zapis i pohranu podataka (engl. *dataloggers*) te je time omogućeno mjerenje svakih 15 minuta.

Kako bi se detaljno pratio preferencijalni tok kroz profil tla, senzori su postavljeni na jednoj mikrolokaciji (BII pozicija). Senzori za mjerenje volumetrijske vlage tla (Slika 3.2.1.3. b)) postavljeni su na 15, 30, 50, 75 i 100 cm s vremenskom rezolucijom od 15 minuta.

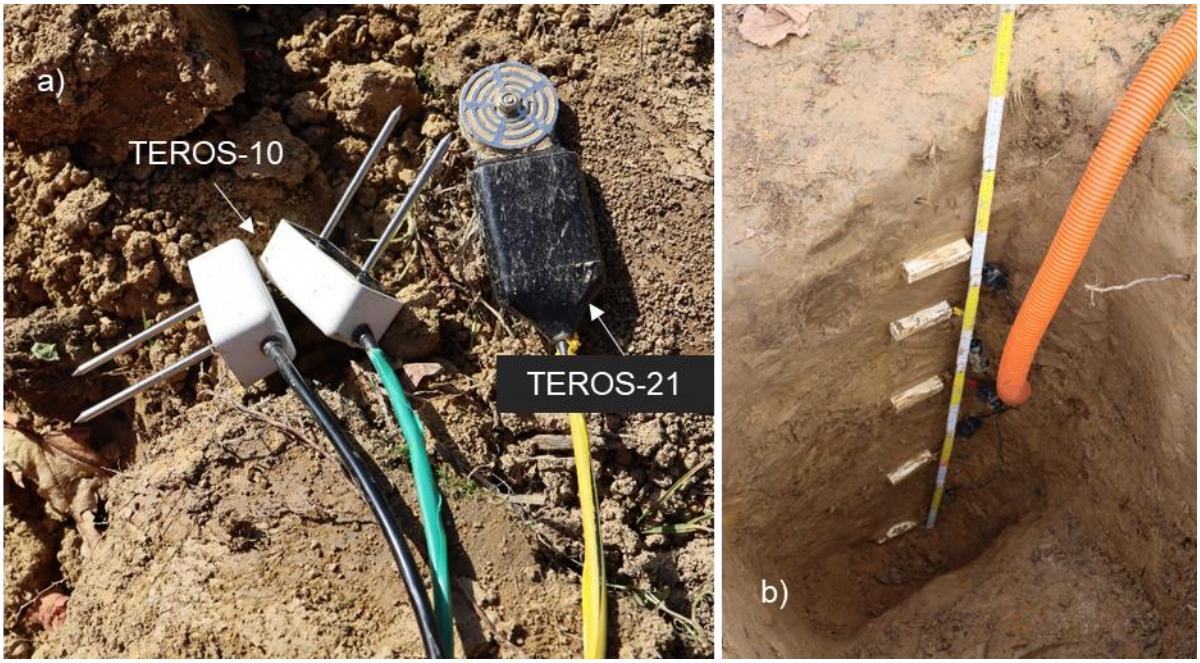

Slika 3.2.1.3. a) Senzori za mjerenje sadržaja vode u tlu (TEROS-10) te za određivanje vodnog potencijala tla (TEROS-21) i b) Senzori postavljeni na BII lokaciji postavljeni na 15, 30, 50, 75 i 100 cm dubine.

3.2.2. Infiltracijska sposobnost tla

Infiltracijska sposobnost tla u nesaturiranim uvjetima mjerena je mini-disk infiltrometrom (Slika 3.2.2.1.). Terenska mjerenja provedena su na vrhu (A), sredini (B) i dnu (C) padine na površini tla u tri reda (I, II i III) koji predstavljaju ponavljanja s usisnom visinom između 1 i 5 cm. Nesaturirana hidraulička vodljivost tla izračunata je u Microsoft Excel proračunskoj tablici proizvođača *Decagon*. Prije početka mjerenja, trava je uklonjena s površine tla te je apliciran kvarcni pijesak kako bi se osigurao bolji kontakt između infiltrometra i površine tla. Voda iz infiltrometra se infiltrira u tlo te se volumen procijeđene vode bilježi kroz određeni vremenski period ovisno o tipu tla (Decagon Devices Inc, 2016).

Infiltracija je kasnije izračunata prema Zhangovoj jednadžbi (Zhang, 1997) koja podrazumijeva mjerenje kumulativne infiltracije u odnosu na vrijeme uz prilagođavanje rezultata funkciji:

$$I = C_1 t + C_2 \sqrt{t} \quad (2)$$

gdje je C_1 (m s^{-1}) povezan s hidrauličkom vodljivošću, a C_2 (m $s^{-1/2}$) je sorpcijska sposobnost tla. Hidraulička vodljivost (k) je zatim izračunata prema formuli:

$$k = \frac{C_1}{A} \quad (3)$$

gdje je C_1 nagib krivulje kumulativne infiltracije u odnosu na kvadratni korijen vremena. *A* je vrijednost koja povezuje van Genuchtenove parametre za određeni tip tla s usisnom brzinom i polumjerom infiltrometra. Parametar *A* izračunat je prema formuli:

$$A = \frac{11.65(n^{0.1}-1)exp[2.92(n-1.9)\alpha h_0]}{(\alpha r_0)^{0.91}} \; n \geq 1.9 \qquad (4)$$

$$A = \frac{11.65(n^{0.1}-1)exp[7.5(n-1.9)\alpha h_0]}{(\alpha r_0)^{0.91}} \; n < 1.9 \qquad (5)$$

gdje su *n* i *α* van Genuchtenovi parametri za tlo, r_0 je radijus diska, h_0 je podtlak na površini diska. Podtlak mini-disk infiltrometra je između -0,5 i -6 cm, a radijus je 2,25 cm (Decagon Devices Inc, 2016).

Slika 3.2.2.1. Mjerenje infiltracijske sposobnosti tla mini-disk infiltrometrom.

3.2.3. Određivanje toka vode traserima (briljantno plavo bojilo i kalijev bromid) na terenu

Određivanje toka vode i identifikacija preferencijalnih tokova u tlu provedeno je na istraživanoj lokaciji gdje je aplicirano briljantno plavo bojilo i kalijev bromid. Bojilo koncentracije 10 g L^{-1} aplicirano je na vrhu, sredini i dnu padine u međurednom prostoru na površini od 1 m^2. Na Slici 3.2.3.1. prikazana je aplikacija bojila na vrhu padine. Nakon što se bojilo infiltriralo u tlo,

tlo se vertikalno uklanjalo svakih 12,5 cm kako bi se fotografirala obojenost tla do 20 cm dubine. Fotografije su zatim obrađene u *ImageJ* programu te je izračunat udio obojene površine na presjecima. Nadalje, na mjestima gdje su postavljeni nevagajući tlačni pasivni lizimetri na vrhu, sredini i dnu padine u tri reda, ručnom prskalicom je apliciran kalijev bromid (KBr) koncentracije 2 g L^{-1}. Uzorci vode uzimali su se jednom mjesečno te su isprani bromidi mjereni bromidnom ion selektivnom elektrodom (HI4102; Hanna Instruments).

Slika 3.2.3.1. Aplikacija briljantno plavog bojila na površini od 1 m^2 na vrhu padine.

3.3. Laboratorijska istraživanja

3.3.1. Hidraulička svojstva tla

Neporušeni uzorci tla volumena 250 cm^3 uzeti su tijekom postavljanja eksperimenta na vrhu (A), sredini (B) i dnu (C) padine u tri replikacije u tri reda (sveukupno 9 uzoraka po lokaciji na padini) na četiri dubine (15 – 20, 35 – 40, 55 – 60, 70 – 75 cm; Slika 3.3.1.1.). Dodatni uzorci tla uzeti su na mjestima uzimanja kolona s neporušenim tlom na dubini 12 – 17 cm. Neporušeni uzorci tla korišteni su za procjenu hidrauličkih svojstava tla koji će se ujedno koristiti i kao ulazni podaci za modeliranje. Uzorci su saturirani vodom u plastičnoj posudi te su pripremljeni za daljnje analize. Mjerenje hidrauličke vodljivosti tla pri saturiranim uvjetima je provedeno pomoću KSAT uređaja (Slika 3.3.1.2.a). Metoda se bazira na Darcyjevoj jednadžbi (Darcy, 1865) prema kojoj je brzina kretanja vode kroz tlo proporcionalna hidrauličkom gradijentu i koeficijentu propusnosti (Hadas, 1964):

$$Ks = -(L \times V)/H \times A \times t \quad (6)$$

gdje *L* predstavlja visinu uzorka tla [cm], *V* volumna količina vode [cm^3], *H* visinu stupca vode u bireti (koja iznosi 5 cm po mjerenju) [cm], *A* površina uzorka [cm^2], a *t* vrijeme [dani].

a) b)

Slika 3.3.1.1. Uzorkovanje neporušenih uzoraka tla volumena 250 cm^3 za procjenu hidrauličkih svojstava tla.

Nakon KSAT analize, daljnja hidraulička svojstva tla određena su HYPROP sustavom (Slika 3.3.1.2. b). Sustav se sastoji od vage, jedinice senzora, te dva tenziometra koji se postavljaju na različite dubine (1,25 i 3,75 cm) u cilindar s neporušenim tlom. Analiza HYPROP sustavom temelji se na pojednostavljenoj evaporacijskoj metodi pri čemu vaga bilježi promjene u masi uzorka tijekom mjerenja te procjenjuje hidraulička svojstva. Cilindar s neporušenim uzorkom tla volumena 250 cm^3 se postavi sa senzorskom jedinicom na vagu čime započinje mjerenje težine tla i vodnog potencijala tla. Pomoću tenziometara određuje se prosječna vrijednost vodnog potencijala (Ψ) uzorka tla. Navedena vrijednost odgovara prosječnoj vrijednosti količine vode u odnosu na masu cijelog uzorka. Vodni potencijal i masa mjere se u vremenskim intervalima od 1 do 30 minuta. Hidraulički gradijent izračunava se na temelju potencijala tijekom vremenskog perioda mjerenja. Tok vode dobiva se iz razlika težine tla odnosno razlika volumena vode u tlu. HYPROP uređajem određuje se količina vode u tlu u uvjetima potpune saturacije, odnosno θ_s, zajedno s rezidualnom količinom vode θ_r.

WP4C (METER Group, 2017.; Slika 3.3.1.2. c) je uređaj kojim se određuje vodni potencijal uzorka tehnikom hlađenog zrcala u točki kondenzacije. Uređaj uravnotežuje uzorak s prostorom iznad uzorka u zatvorenoj komori. U instrumentu se nalazi zrcalo koje očitava trenutak pojave kondenzacije. Kada su uzorak i prostor iznad uzorka uravnoteženi, vodni potencijal zraka u komori jednak je vodnom potencijalu uzorka. Temperatura zrcala je precizno

kontrolirana termoelektričnim (Peltier) hladnjakom. Fotoelektričnom ćelijom se određuje točka u kojoj se kondenzacija prvi put pojavljuje na zrcalu. WP4C usmjerava snop svjetlosti na zrcalo koje se reflektira u fotodetektor koji zabilježi promjenu refleksije kada započinje kondenzacija na zrcalu. Termopar, koji je pričvršćen na zrcalo, bilježi temperaturu pri kojoj dolazi do kondenzacije. Na kraju mjerenja instrument prikazuje vrijeme (u minutama) koje je bilo potrebno za očitanje, temperaturu uzorka i vodni potencijal u megapaskalima (MPa) i pF vrijednostima (logaritam negativnog hidrostatskog tlaka).

a) b) c)

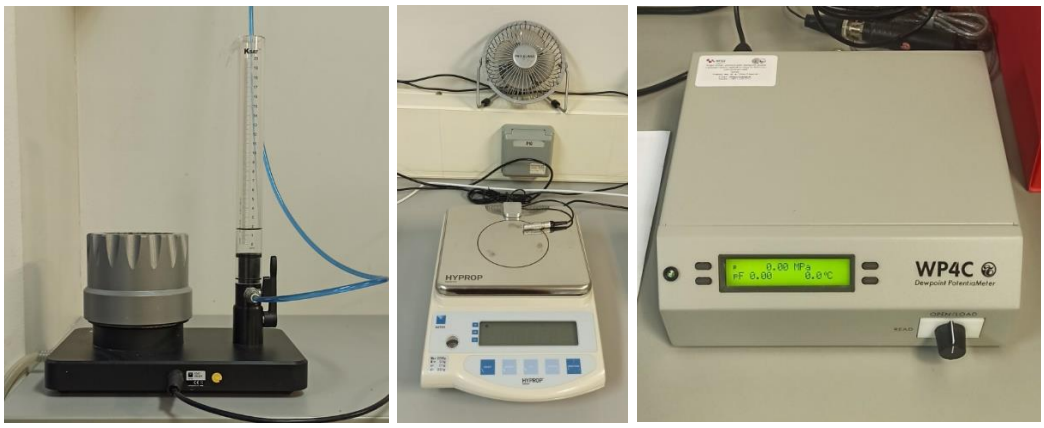

Slika 3.3.1.2. Prikaz (a) KSAT, (b) HYPROP i (c) WP4C uređaja pomoću kojih su procjenjena hidraulička svojstva tla.

Za evaluaciju mjerenja koristi se HYPROP-FIT softver. Kako bi se utvrdio najpogodniji model za procjenu hidrauličkih svojstava tla korištene su unimodalne funkcije Brooks-Corey, Fredlund-Xing, Kosugi i van Genuchten modela te van Genuchten bimodalna funkcija. Pojedine točke retencijske krivulje automatski se, pomoću HYPROP-FIT softvera, izračunavaju na temelju gubitka vode po volumenu uzorka u određenom vremenu i povezuju sa srednjim vrijednostima površinske napetosti u uzorku (Schindler i Müller, 2017). Retencijske krivulje prikazuju odnos između relativne količine vode u tlu *θ* (masa vode u tlu / masa osušenog tla) i vodnog potencijala tla *h*.

Sadržaj vode izražen je efektivnom saturacijom (S_e) u svim retencijskim funkcijama prema formuli:

$$S_e = \frac{\theta - \theta_r}{\theta_s - \theta_r} \quad (7)$$

gdje je θ [cm^3 cm^{-3}] volumetrijski sadržaj vode, θ_r rezidualni sadržaj vode, a θ_s saturirani sadržaj vode.

U Brooks-Coreyevom modelu (Brooks R.H., 1964) izračunata je prema formuli:

$$S_e(h) = \begin{cases} (\alpha|h|)^{-\lambda} & \text{za } (\alpha|h|) > 1 \\ 1 & (\alpha|h|) \leq 1 \end{cases} \quad (8)$$

Prema Fredlundu i Xingu (Fredlund i Anqing Xing, 1994) je izračunata prema formuli:

$$\theta(h) = \theta_s \chi(h) \Gamma(h) \quad (9)$$

$$\Gamma(h) = \{\ln[e + (\alpha h)^n]\}^{-m} \quad (10)$$

$$\chi(h) = 1 - \frac{\ln(1+h/h_r)}{\ln(1+h_0/h_r)} \quad (11)$$

Prema Kosugiju (Kosugi, 1996) je izračunata prema formuli:

$$S_e = Q\left[\frac{\ln(h/h_m)}{\sigma}\right] \quad (12)$$

Prema van Genuchtenu (unimodalna funkcija) (van Genuchten, 1980) efektivna saturacija izračunata je prema:

$$S_e(h) = \left[\frac{1}{1+(\alpha|h|)^n}\right]^{1-\frac{1}{n}} \quad (13)$$

Bimodalna funkcija van Genuchtenovog modela izračunava efektivnu saturaciju prema formuli:

$$S_e(h) = \sum_{i=1}^{2} w_i \left[\frac{1}{1+(\alpha_i|h|)^{n_i}}\right]^{1-\frac{1}{n_i}} \quad (14)$$

gdje je h [cm] visina tlaka, α [1/cm] inverzna vrijednost ulaska zraka, Γ [–] je relativna funkcija saturacije, e je Eulerov broj, n [–] je zakrivljenost krivulje, h_r i m [–] su parametri oblika krivulje, Q je interval Gaussove normalne distribucije, σ [–] je standardna devijacija distribucije gustoće veličine pora, a w je ponderirana superpozicija dvije van Genuchtenove funkcije.

Mjera evaluacije kvalitete kalibriranog modela izražava se u obliku korijena srednje kvadratne devijacije (*RMSE;* eng. *root mean square error*). *RMSE* predstavlja srednju devijaciju između modela i podataka. Pogreška modela vodne retencije (*RMSE_TH*) izračunata je odvojeno od pogreške modela hidrauličke vodljivosti (*RMSE_K*).

$$RMSE = \sqrt{\frac{1}{r}\sum_{i=1}^{r}[y_i - \hat{y}_i]^2} \quad (15)$$

gdje je y_i izmjerena vrijednost, a $\hat{y}_i$ predviđena vrijednost modela.

Koeficijent determinacije (R^2) izražava jačinu linearne povezanosti između dva faktora, tj. koliko će promjena jednog faktora utjecati na promjenu drugog, a izračunava se kvadratom koeficijenta korelacije.

$$R^2 = 1 - \frac{\sum_1^r [y_i - \hat{y}_i][\hat{y}_i - \bar{\hat{y}}_i]}{\sqrt{\sum_1^r [y_i - \bar{y}_i]^2 [\hat{y}_i - \bar{\hat{y}}_i]^2}} \quad (16)$$

Akaike informacijski kriterij (Akaike, 1974), AIC, je dodatni kriterij za odabir najboljeg modela koji predstavlja mjeru kvalitete, a računa se prema:

$$\mathrm{AIC} = 2(\mathrm{L} + \mathrm{k}) \quad (17)$$

gdje je L funkcija vjerojatnosti, a k broj parametara za prilagođavanje.

$$\mathrm{AICc} = \mathrm{n}\ln(\phi_{\min}/\mathrm{n}) + 2\mathrm{k} + \frac{2\mathrm{k}(\mathrm{k}+1)}{\mathrm{n}-\mathrm{k}-1} \quad (18)$$

gdje je n broj izmjerenih vrijednosti, a k broj parametara za prilagođavanje.

Statističkim analizama (*RMSE_θ, RMSE_K I AICc)* kao najpogodniji model pokazala se bimodalna funkcija van Genuchtenovog modela te je stoga taj model korišten dalje u numeričkom modeliranju.

3.4. Određivanje toka vode primjenom trasera na neporušenim kolonama tla

Kolone s neporušenim tlom, dubine 25 cm i promjera 16 cm, uzete su na vrhu (A), sredini (B) i dnu (C) padine u tri ponavljanja u zatravljenom međurednom prostoru vinograda. Unutar kolona je prije uzimanja uzoraka apliciran kvarcni pijesak kako bi se smanjili rubni uvjeti po bočnim stranama kolone. Kako bi se uzeo neporušeni uzorak tla, kolone su postavljene na površinu tla te su utiskivane do dubine od 25 cm (Slika 3.4.1.). U laboratoriju je dodatno aplicirano ljepilo na vrhu kolone kako bi se spriječilo procjeđivanje trasera uz stijenke te je odstranjen višak tla na dnu svake kolone nakon čega slijedi njihova saturacija.

Slika 3.4.1. Utiskivanje kolona u tlo i uzimanje neporušenih uzoraka tla na istraživanoj lokaciji.

Nakon saturacije postavljeni su lijevci ispunjeni kvarcnim pijeskom na dno kolone kako bi se spriječili atmosferski uvjeti, odnosno njihovo sušenje. Također, unutar svake kolone postavljena su dva senzora, odnosno jedan ECH$_2$O EC-5 (METER) senzor na dubini od 7 cm koji mjeri volumetrijski sadržaj vode te jedan T5X tenziometar (METER) na dubini od 17 cm (Slika 3.4.2.) s rezolucijom mjerenja svakih 15 minuta. Nadalje, na vrh svake kolone je aplicirano 150 mL kalijeva bromida (KBr) koncentracije 1 g L^{-1} ručnom prskalicom kako bi se osigurala ravnomjerna aplikacija po cijeloj površini. Kolone su zatim navodnjavane dva puta dnevno s 250 mL (55 mm h^{-1}) kišnice kroz period od 16 dana također koristeći ručnu prskalicu. Kišnica je prethodno prikupljana na terenu te je analizirana kako bi se osiguralo da ne sadrži elemente koji bi mogli interferirati ion selektivnoj elektrodi za određivanje ispranih bromida. Uzorci procijeđene vode također su uzimani dva puta dnevno i analizirani bromidnom ion selektivnom elektrodom (HI4102; Hanna Instruments). Statistička obrada prikupljenih i izmjerenih podataka provedena je u SAS programu (SAS Institute Inc, 2020). Jednosmjerna analiza varijance (one-way ANOVA) i Tukeyjev test s p-vrijednosti 0,05 korišteni su kako bi se odredila signifikantnost između srednjih vrijednosti. Nakon što su bromidi isprani iz kolona, slijedila je aplikacija briljantno plavog bojila (Brilliant Blue) kako bi se odredio udio obojenog tla, odnosno identificirali i kvantificirali preferencijalni tokovi. Bojilo je aplicirano u obliku otopine koncentracije 10 g L^{-1} te je ručnom prskalicom aplicirano ukupno 800 mL u osam obroka po 100 mL kako bi se izbjeglo nakupljanje sloja otopine na vrhu kolone. Nakon što se bojilo procijedilo, kolone su vertikalno prerezane na pola. Zatim se na svakoj strani kolone uklonilo tlo debljine 2,5 cm te su kolone fotografirane (ukupno 6 presjeka po koloni). Presjeci su fotografirani i analizirani koristeći *ImageJ* program stvarajući binarne slike s obojenim i neobojenim dijelovima tla koji su kasnije preračunati u postotne udjele.

Slika 3.4.2. Prikaz kolona s neporušenim tlom u laboratoriju s postavljenim senzorima na dubini od 7 cm i tenziometrima na dubini od 17 cm.

3.5. Numeričko modeliranje

Numeričko modeliranje toka i retencije vode u terenskim i laboratorijskim istraživanjima provedeno je u softverskom programu HYDRUS-1D (version 4.17.0140). Simulacije na neporušenim kolonama tla prate vertikalni tok vode, na nevagajućim tlačnim pasivnim lizimetrima uz vertikalni tok praćeno je i površinsko otjecanje i ET, dok su na terenskim mjerenjima senzorima praćeni vertikalni i lateralni tokovi, površinsko otjecanje i ET. Pri izradi simulacija korišteni su modeli dvostruke poroznosti i propusnosti. Prema modelu dvostruke poroznosti tok vode je ograničen na međuagregatne pore i makropore, dok je voda u matriksu tla nepokretna. Model je baziran na Richardsovoj jednadžbi (19) toka vode u makroporama i jednadžbi ravnoteže mase za opis dinamike vlage u matriksu (20) (Šimůnek i sur., 2003):

$$\frac{\partial \theta}{\partial t} = \frac{\partial}{\partial x}\left[K\left(\frac{\partial h}{\partial x} + \cos\alpha\right)\right] - S \tag{19}$$

$$\frac{\partial \theta_{mo}}{\partial t} = \frac{\partial}{\partial x}\left[K(h)\left(\frac{\partial h}{\partial x} + \cos\alpha\right)\right] - S_{mo} - \Gamma_w$$

$$\frac{\partial \theta_{im}}{\partial t} = \frac{\partial}{\partial x}\left[K(h)\left(\frac{\partial h}{\partial x} + \cos\alpha\right)\right] - S_{im} - \Gamma_w \tag{20}$$

gdje su S_{mo} i S_{im} voda koju biljka usvaja u mobilnoj i nemobilnoj fazi, a Γ_w predstavlja brzinu toka vode iz međuagregatnih u unutaragregatne pore. S je volumen vode uklonjen s jedinice volumena tla po jedinici vremena zbog usvajanja vode od strane biljaka.

Za razliku od modela dvostruke poroznosti, model dvostruke propusnosti uzima u obzir i mogućnost kretanja vode kroz matriks. Richardsova jednadžba implementirana je u HYDRUS-1D za oba područja pora prema Gerke i van Genuchten (Gerke i van Genuchten, 1993; Gerke i Van Genuchten, 1996) (21):

$$\frac{\partial \theta_f(h_f)}{\partial t} = \frac{\partial}{\partial x}\left[K_f(h_f)\left(\frac{\partial h_f}{\partial x} + \cos\alpha\right)\right] - S_f(h_f) - \frac{\Gamma_w}{w}$$

(21)

$$\frac{\partial \theta_m(h_m)}{\partial t} = \frac{\partial}{\partial x}\left[K_m(h_m)\left(\frac{\partial h_m}{\partial x} + \cos\alpha\right)\right] - S_m(h_m) + \frac{\Gamma_w}{1-w}$$

gdje je w omjer volumena makropora i ukupnog tla, dok θ_f i θ_m označavaju sadržaj vode matriksa i u makroporama tla.

Hidraulička svojstva tla procijenjena su HYPROP i WP4C uređajima, a retencijske krivulje tla prikazane su u HYPROP-FIT programu van Genuchtenovim bimodalnim modelom (Poglavlje 3.3.1.). Kalibracija modela napravljena je inverznom optimizacijom hidrauličke vodljivosti KSAT uređajem. U pokusu s neporušenim kolonama tla korišteni su podaci o navodnjavanju dok su u ostalim mjerenjima korišteni podaci o oborinama prikupljeni s meteorološke postaje ATMOS41 (METER Group).

Rubni uvjeti u neporušenim kolonama tla postavljeni su na atmosferske uvjete s površinskim slojem na vrhu i procjednim graničnim uvjetima (eng. *seepage face*) na dnu (s visinom tlaka (eng. *pressure head*) od 0 cm). Dubina profila tla za modeliranje je 25 cm što je ujedno i stvarna dubina kolone. Kao početni uvjeti su uzete izmjerene vrijednosti volumetrijske vlage tla na početku provođenja pokusa. Nadalje, pri terenskim mjerenjima, rubni uvjeti na vrhu su isti i za lizimetarska i za senzorska mjerenja i postavljeni su na atmosferske uvjete s površinskim otjecanjem, dok se uvjeti na dnu i dubina domene razlikuju. Tako je dubina lizimetarskih istraživanja postavljena na 40 cm jer je to ujedno i stvarna dubina na kojoj su postavljeni te procjedni granični uvjeti (h = -50 cm). Pri modeliranju senzorskih mjerenja dubina profila tla je 120 cm. Rubni uvjeti na dnu domene postavljeni su na slobodno procjeđivanje (eng. *free drainage*). Početni uvjeti postavljeni su prema izmjerenim vrijednostima volumetrijske vlage tla na početku istraživanog perioda. Točke opažanja (eng. *observation points*) postavljene su na 7, 17 i 25 cm za neporušene kolone tla gdje su 7 i 17 cm ujedno i dubine na kojima su postavljeni senzori, a 25 cm je dno kolone. Nadalje, pri modeliranju lizimetarskih istraživanja opaža se samo dno domene (40 cm) jer je to i dubina lizimetara, dok su pri modeliranju senzorskih mjerenja točke opažanja postavljene na 40 i 80 cm jer su to i stvarne dubine na kojima su senzori postavljeni na terenu. Za modeliranje senzorskim mjerenja na terenu izabrana su tri značajna događaja (sušenje, vlaženje i

saturacija), te su simulacije napravljene u periodu od mjesec dana za svaki pojedinačni događaj.

Usvajanje vode korijenom (eng. *root water uptake*) modelirano je prema Feddesu i suradnicima (Feddes R.A., Kowalik P.J., 1978) te su postavljeni sljedeći parametri *P0* na -10 cm, *POpt* na -25 cm, *P2H* na -300 cm, *P2L* na -1000 cm, *P3* na -8000 cm, dok je *r2H* = 0,5 cm dan^{-1}, a *r2L* = 0,1 cm dan^{-1}.

Rezultati dobiveni numeričkim modelima validirani su istecima ili izmjerenim vrijednostima senzora za mjerenje volumetrijske vlage u tlu. Za validaciju su korišteni statistički parametri korijena srednje kvadratne pogreške (eng. *Root mean square error – RMSE*; 22) i koeficijenta determinacije (R^2; 23):

$$RMSE = \sqrt{\frac{\sum_{i=1}^{N}(P_i - O_i)^2}{N}} \tag{22}$$

$$R^2 = \left[\frac{\sum_{i=1}^{N}(O_i - \bar{O})(P_i - \bar{P})}{\left[\sum_{i=1}^{N}(O_i - \bar{O})^2\right]^{0,5}\left[\sum_{i=1}^{N}(P_i - \bar{P})^2\right]^{0,5}}\right] \tag{23}$$

Slika 3.5.1. prikazuje shemu provedbe eksperimenata od najšireg područja istraživanja prema sve užem. Istraživanje je završilo detaljnim prikazom preferencijalnog toka na jednoj mikrolokaciji, ali s mjerenjima na pet dubina do 100 cm vremenske razlučivosti 15 minuta. Sve provedene metode su statistički analizirane te je podebljan model koji se pokazao statistčki najpouzdanijim i koji je korišten u sljedećem koraku.

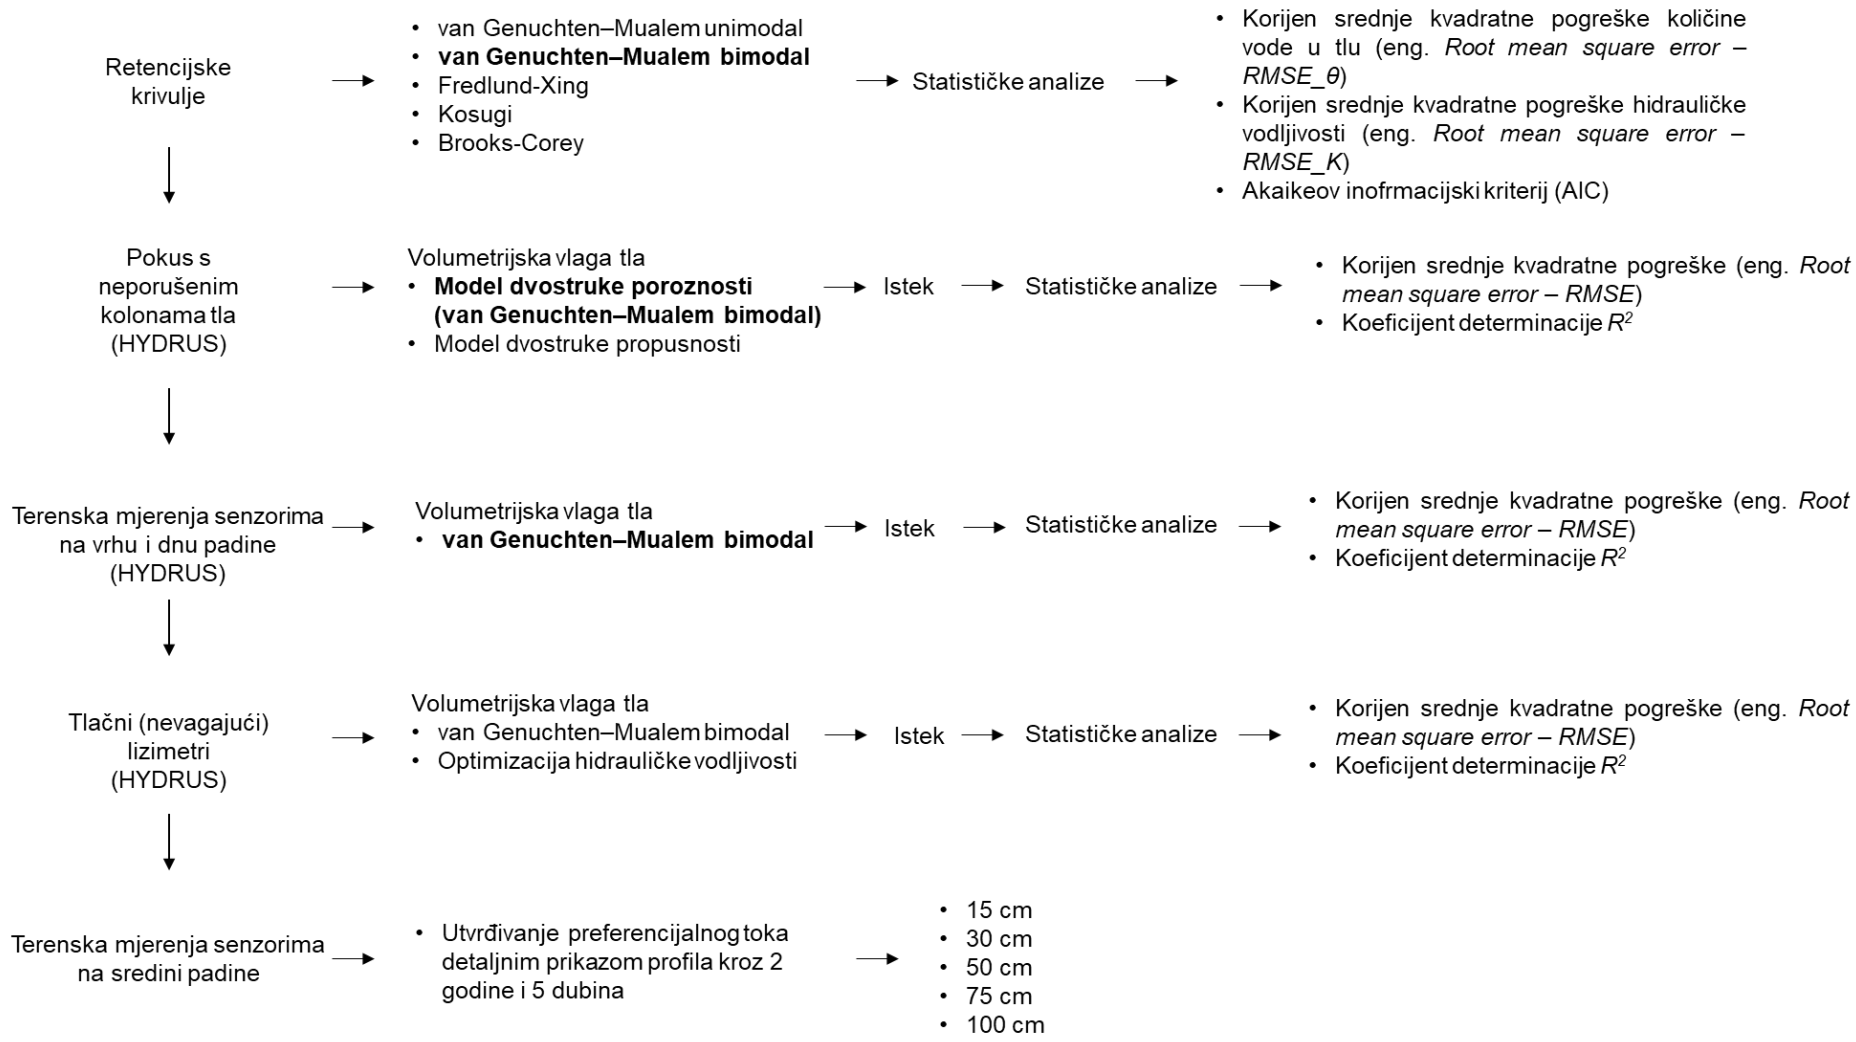

Slika 3.5.1. Shematski prikaz provedenih istraživanja od najšireg područja prema užem području istraživanja i statističkih analiza.

4. REZULTATI

4.1. Terenska istraživanja

4.1.1. Lizimetarska i senzorska mjerenja

U ovom poglavlju prikazani su isteci iz nevagajućih tlačnih pasivnih lizimetara na vrhu, sredini i dnu padine, zatim isteci površinskog otjecanja, te isteci iz sustava za mjerenje potpovršinskog procjeđivanja na dnu padine. Svi podaci su prikazani za cijeli period istraživanja, od siječnja 2021. i prosinca 2022. godine. Iz grafičkog prikaza vidljivo je da je najmanji prosječni volumen uzorkovan na dnu padine, a najveći prosječni volumen uzorkovan je na vrhu padine. Prosječni uzorci svake pojedine pozicije na padini (vrh, sredina i dno) međusobno su se razlikovale u prosječnim vrijednostima prikupljenih volumena. Tako su se te vrijednosti na vrhu kretale između 2,00 i 3,29 L, na sredini između 2,30 i 2,49, a na dnu padine između 0,40 i 2,18 L. Vrijednosti volumena najmanje su se razlikovale na sredini padine što može biti posljedica najvećeg pada uslijed čega oborine površinskim putem otječu na dno padine. Također, tijekom ljetnih mjeseci uglavnom nije prikupljen volumen isteka zbog sušnog perioda, dok je glavnina svih uzoraka prikupljena u vlažnijim mjesecima u godini. Nadalje, jasno je vidljivo da se u ljetnim mjesecima smanji vlažnost tla te čak ni pojedini kišni događaji ne uzrokuju procjeđivanje vode. Najčešće te oborine površinskim putem otječu na dnu padine. Iz Slike 4.1.1.1. je vidljivo da u pojedinim mjesecima jedna replikacija (II DNO) s dna padine odskače od ostalih vrijednosti. Iako prosječno dno padine ima najmanji volumen, u pojedinim mjesecima (u 2021. godini to su dva mjerenja u siječnju, dva mjerenja u veljači i u svibnju, a u 2022. godini to su mjerenja u listopadu i studenom), na ovoj replikaciji se javljaju i najviše izmjerene vrijednosti. Također je utvrđeno i da pojedine replikacije (npr. II VRH) najčešće imaju veće vrijednosti od drugih replikacija s iste pozicije na padini. S druge strane, na poziciji I DNO kroz čak sedam mjeseci u dvije godine nije prikupljen volumen isteka, dok je u još dodatnih devet mjeseci prikupljeno manje od 1 L.

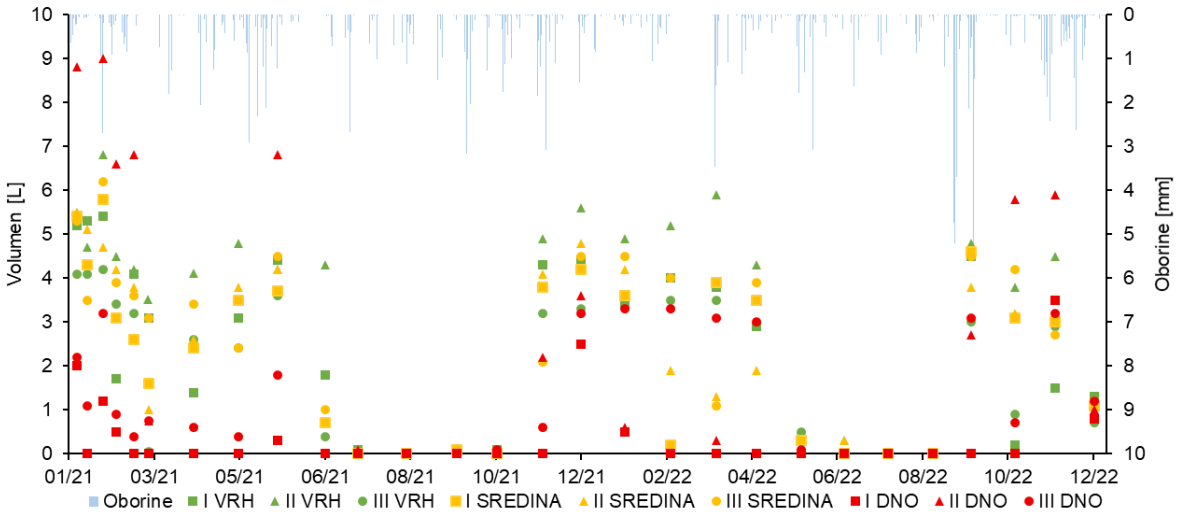

Slika 4.1.1.1. Istek iz nevagajućih tlačnih pasivnih lizimetara na vrhu, sredini i dnu padine kroz dvogodišnje razdoblje (2021. – 2022.).

Na Slici 4.1.1.2. prikazan je prosječni volumen prikupljen u nevagajućim tlačnim pasivnim lizimetrima na svakoj poziciji duž padine u svakom pojedinačnom godišnjem dobu tijekom razdoblja istraživanja. Po godišnjim dobima, uglavnom je, očekivano, najmanje prikupljenog volumena u lizimetrima bilo u ljetnim mjesecima, dok je najviše bilo u zimskim. Vidljiva je razlika i između dvije promatrane godine (Tablica 4.1.1.1.) pa je tako u jesen 2021. godine prikupljen manji prosječni volumen (0,32 – 1,39 L) u odnosu na jesen 2022. godine (2,33 – 3,00 L). Tijekom zimskog perioda, u 2021. godini zabilježen je veći prosječni volumen u odnosu na 2022. godinu na sredini (4,04 u odnosu na 3,54 L) i dnu (2,46 u odnosu na 1,89 L) padine, dok je na vrhu manji (4,06 u odnosu na 4,21 L). U proljeće 2021. godine prosječni prikupljeni volumen se kretao između 1,10 i 3,40 L, dok je u 2022. godini bio između 0,73 i 2,66 L. U ljetnim mjesecima u obje godine prikupljeni volumeni bili su niski. Ipak, 2022. godina bila je suša od 2021. te je voda prikupljena samo na drugoj replikaciji na vrhu i sredini padine, dok na ostalih sedam pozicija nije uopće prikupljen volumen. Iz Slike 4.1.1.2. vidljivo je da je u svim godišnjim dobima tijekom 2021. i 2022. godine najviši prosječni volumen na vrhu padine u drugoj replikaciji (II VRH). Na sredini padine maksimalne prosječne vrijednosti su se izmjenjivale po godišnjim dobima, dok su na dnu padine najčešći maksimalni volumeni također prikupljeni na drugoj replikaciji (II DNO), osim tijekom zime i proljeća, 2022. godine. Općenito uspoređujući pozicije na padini, tijekom gotovo svih godišnjih doba najveći volumeni su prikupljeni na vrhu padine (II VRH) uz iznimku zime 2021. i jeseni 2022. godine gdje je u oba slučaja prikupljen nešto veći volumen na dnu padine (II DNO).

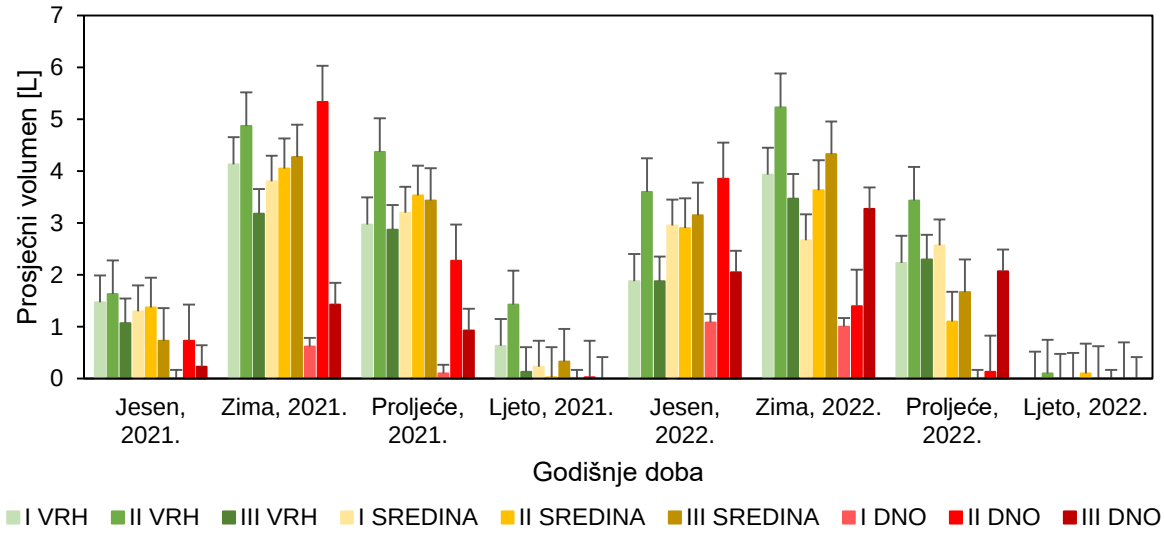

Slika 4.1.1.2. Prosječni volumen [L] prikupljen u nevagajućim tlačnim pasivnim lizimetrima tijekom pojedinog godišnjeg doba na vrhu, sredini i dnu padine u tri replikacije u 2021. i 2022. godini.

Nadalje, najveće vrijednosti standardne pogreške su određene upravo na pozicijama na padini gdje su izmjereni i najveći prosječni volumeni tijekom pojedinog godišnjeg doba. Tijekom zime i proljeća 2021. godine na dnu padine (II DNO) zabilježena su odstupanja od gotovo 4 L. Na drugoj replikaciji na vrhu padine prosječno izmjereni volumeni tijekom jeseni i ljeta 2021., te proljeća 2022. godine odstupali su oko 3 L.

Tablica 4.1.1.1. Prosječni volumen prikupljen u nevagajućim tlačnim pasivnim lizimetrima tijekom pojedinog godišnjeg doba na vrhu (A), sredini (B) i dnu (C) padine u 2021. i 2022. godini.

Godišnje doba	VRH [L]	SREDINA [L]	DNO [L]
Jesen, 2021.	1,39	1,13	0,32
Zima, 2021.	4,06	4,04	2,46
Proljeće, 2021.	3,40	3,39	1,10
Ljeto, 2021.	0,73	0,20	0,01
Jesen, 2022.	2,45	3,00	2,33
Zima, 2022.	4,21	3,54	1,89
Proljeće, 2022.	2,66	1,78	0,73
Ljeto, 2022.	0,03	0,03	0,00

Slika 4.1.1.3. prikazuje istek iz sustava za površinsko otjecanje u tri replikacije (I SR, II SR, III SR) na dnu padine kroz 2021. i 2022. godinu. Vidljivo je da su se u pojedinim mjesecima razlikovali volumeni koji su prikupljeni u sustavima za površinsko otjecanje. Tako je primjerice u siječnju, 2021. godine na drugoj replikaciji izmjereno 35,8 L, dok su prva i treća imale 0,0 i 4,2 L. Nadalje, u prosincu, 2021. godine druga i treća replikacije su imale visoke vrijednosti (67,2 i 62,5 L), dok je prva imala samo 3,2 L. Kroz zimski period 2022. godine na sve tri replikacije prikupljen je približno isti volumen.

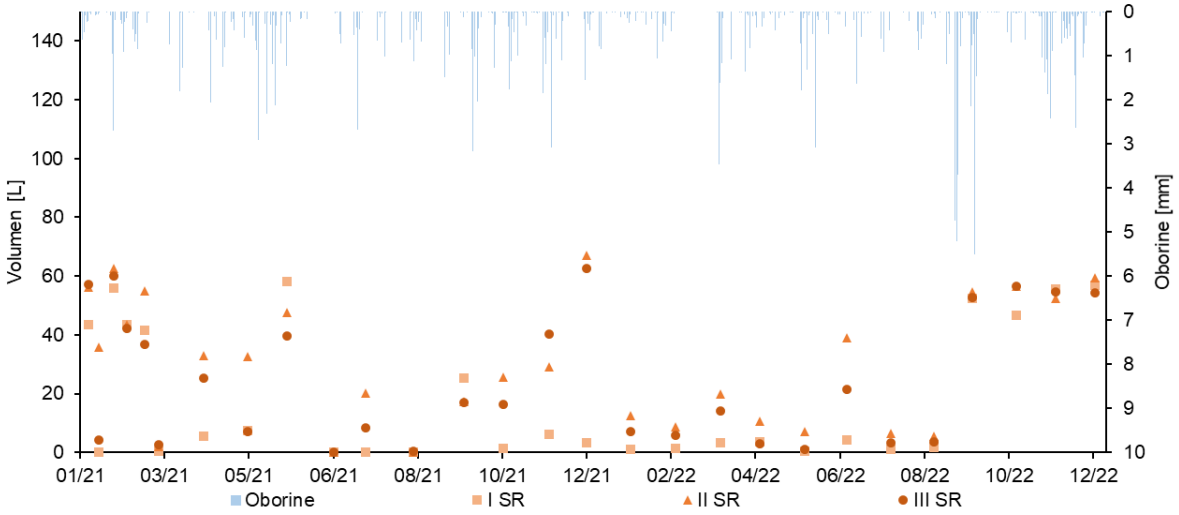

Slika 4.1.1.3. Istek iz sustava za površinsko otjecanje u tri replikacije na dnu padine kroz dvogodišnje razdoblje (2021. – 2022.).

Slika 4.1.1.4. prikazuje prosječni volumen prikupljen u sustavima za površinsko otjecanje. Utvrđene su razlike između svakog pojedinačnog godišnjeg doba, ali i između mjerenja u 2021. i 2022. godini. Tako su se vrijednosti u jesen 2021. godine kretale od 10,97 do 24,57 L, a u jesen 2022. godine između 52,83 i 55,73 L. Standardna devijacija bila je veća u jesen 2021. u sve tri replikacije. Tijekom zime 2021. te vrijednosti su se kretale između 30,83 i 42,50 L, a u zimu 2022. između 1,90 i 29,53 L. Standardna devijacija je za prvu replikaciju bila veća u 2021. godini u odnosu na 2022., a u druge dvije replikacije je bila veća kroz 2022. godinu. U proljeće 2021. godine prikupljeno je između 23,73 i 37,73 L, a u istom periodu 2022. između 2,43 i 6,13 L. Standardna devijacija je ponovno bila veća u 2021. u odnosu na 2022. godinu. U ljeto 2021. prikupljeno je 0,00 – 6,70 L, dok je tijekom ljeta 2022. godine prikupljeno 2,37 – 17,03 L. Standardna devijacija bila je veća tijekom ljeta 2022. godine u odnosu na ljeto 2021. godine.

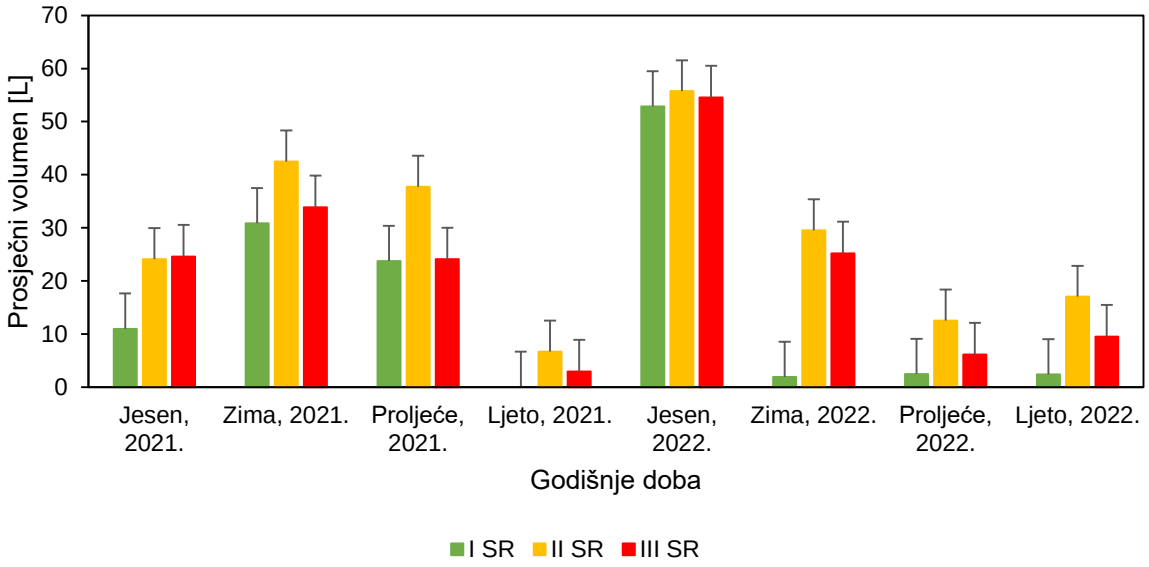

Slika 4.1.1.4. Prosječni volumen prikupljen u sustavima za površinsko otjecanje u tri replikacije tijekom pojedinog godišnjeg doba u 2021. i 2022. godini.

Slika 4.1.1.5. prikazuje istek iz sustava za mjerenje potpovršinskog procjeđivanja postavljenog na dnu padine u tri replikacije kroz 2021. i 2022. godinu. Vidljivo je da je na trećoj replikaciji (III SS) najčešće prikupljen najveći volumen potpovršinskog procjeđivanja. Najveća odstupanja od ostalih mjerenja u periodu istraživanja zabilježena su u prosincu 2021. i ožujku 2022. godine. Ovo su i najveća odstupanja između replikacija, gdje u oba mjeseca na prvoj replikaciji (I SS) potpovršinsko procjeđivanje nije bilo prisutno, dok je na drugoj replikaciji (II SS) zabilježeno 59,8 L u prosincu 2021. godine, odnosno 31,7 L u ožujku 2022. godine. U trećim replikacijama (III SS) zabilježeno je 93,5 L u prosincu 2021., odnosno 110,5 L u ožujku 2022. godine. Nadalje, vidljivo je da u ljetnim mjesecima obje godine nije izmjeren volumen čak niti nakon većih oborina. Period bez izmjerenog volumena u sve tri replikacije započeo je u 2021. godini kasnije (srpanj), ali je trajao duže te je prvi volumen u sustavima za mjerenje potpovršinskog procjeđivanja zabilježen tek u studenom 2021. godine, međutim vrijednosti su se kretale od 0,2 do 0,8 L. U prosincu su se te vrijednosti značajno povećale. Samo je još u kolovozu zabilježen volumen u sve tri replikacije, ali se taj volumen kretao do maksimalnih 0,4 L. S druge strane, u 2022. period je počeo ranije, odnosno već u svibnju, ali je i prvi volumen u ponovnom vlaženju tla zabilježen u rujnu (u lipnju je zabilježen volumen samo na trećoj replikaciji od 3,5 L).

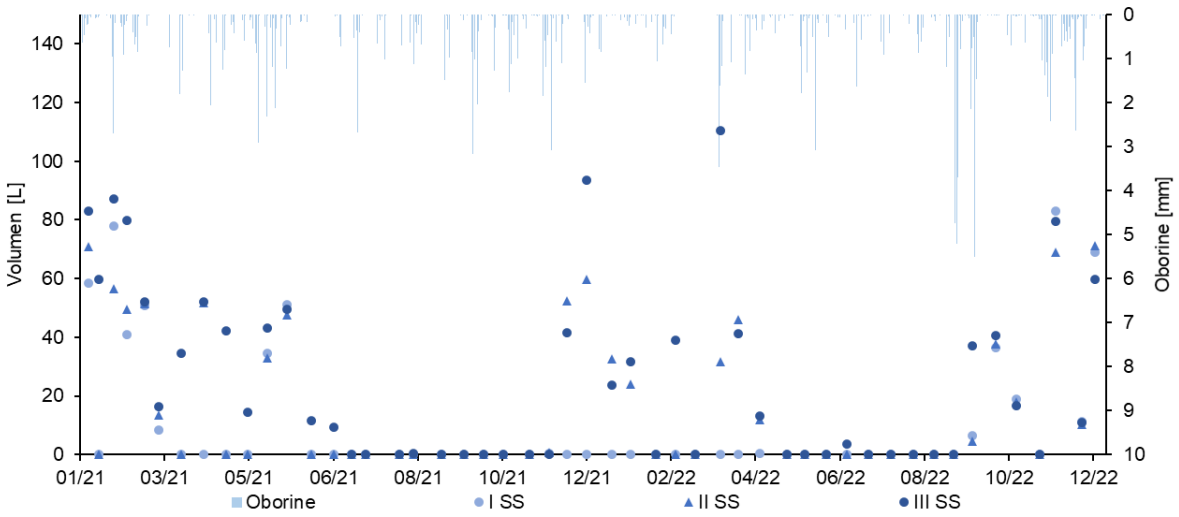

Slika 4.1.1.5. Istek iz sustava za mjerenje potpovršinskog procjeđivanja na dnu padine kroz dvogodišnje razdoblje (2021. – 2022.).

Slika 4.1.1.6. prikazuje prosječni volumen prikupljen u sustavima za mjerenje potpovršinskog procjeđivanja na dnu padine uspoređujući razlike između godišnjih doba kroz period istraživanja.Velika razlika vidljiva je između jeseni 2021., gdje su se izmjereni volumeni kretali između 0,04 i 0,16 L, dok su se za isti period 2022. godine kretali između 30,10 i 34,97 L. Standardna devijacija, s obzirom na rezultate, bila je očekivano veća u 2022. godini. Nadalje, tijekom zime 2021. vrijednosti su bile veće (39,42 – 63,03 L) u odnosu na zimu 2022. godine (0,00 – 37,56 L). Vrijednosti standardne devijacije bile su veće na prvoj i drugoj replikaciji u 2021., ali manje u trećoj u usporedbi s 2022. godinom. U proljeće 2021. izmjereni volumeni kretali su se između 17,12 i 40,26 L, dok su se u istom razdoblju iduće godine kretale između 0,10 i 32,98 L. Standardna devijacija u prvoj godini bila je veća za prvu i drugu replikaciju, ali manja za treću. Prikupljeni volumeni tijekom ljeta bili su veći u 2021. godini, kao i standardne devijacije u odnosu na 2022. godinu.

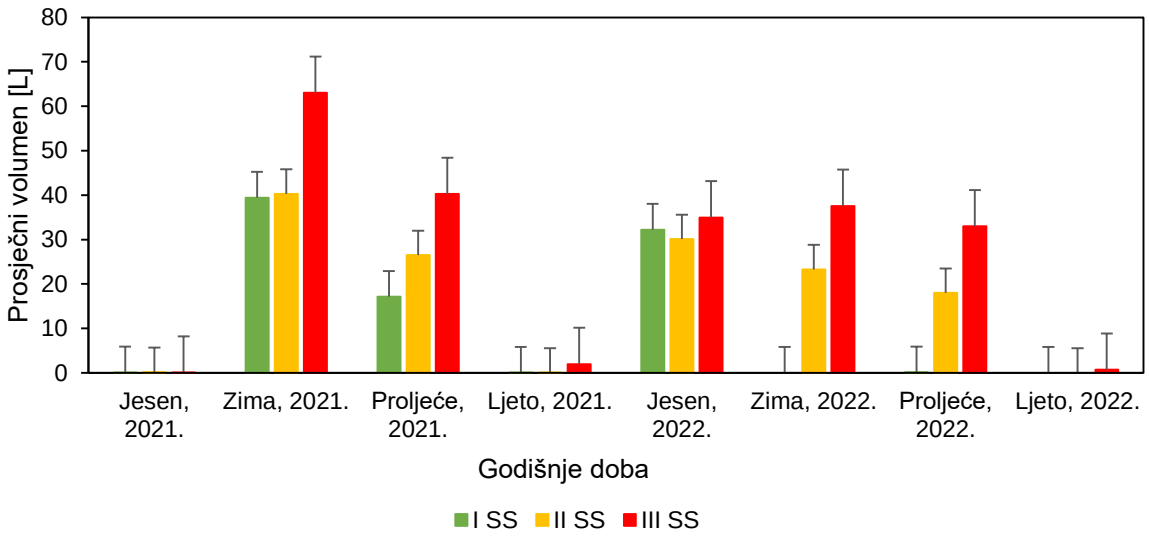

Slika 4.1.1.6. Prosječni volumen prikupljen u sustavima za mjerenje potpovršinskog procjeđivanja u tri replikacije tijekom pojedinog godišnjeg doba u 2021. i 2022. godini.

Slika 4.1.1.7. prikazuje volumetrijsku vlagu tla na dubini od 40 i 80 cm izmjerenu na vrhu i dnu padine tijekom 2021. i 2022. godine. Iz Slike je vidljivo da su na dnu padine prisutne veće oscilacije u sušenju i vlaženju tla u odnosu na vrh padine. Posebice su te oscilacije izražene u trenutku ponovnog vlaženja tla nakon ljetnih mjeseci. Tijekom zimskih mjeseci vrijednosti volumetrijske vlage tla bile su uglavnom slične između vrha i dna padine, a u pojedinim trenucima bi i dno padine bilo vlažnije. S druge pak strane, tijekom ljetnih mjeseci, najviše vrijednosti volumetrijske vlage tla zabilježene su na vrhu padine i to na dubini od 80 cm, dok su najmanje vrijednosti zabilježene na dnu padine na dubini od 40 cm što je i u skladu s izmjerenim volumenima na nevagajućim tlačnim pasivnim lizimetrima. Period sušenja tla je u 2021. godini započeo u lipnju te završio u listopadu, dok je u 2022. godini započeo u svibnju i završio u rujnu. Vrijednosti volumetrijske vlage tla izmjerena na vrhu padine na 80 cm i na dnu padine na 80 cm bile su vrlo slične tijekom ljetnih perioda.

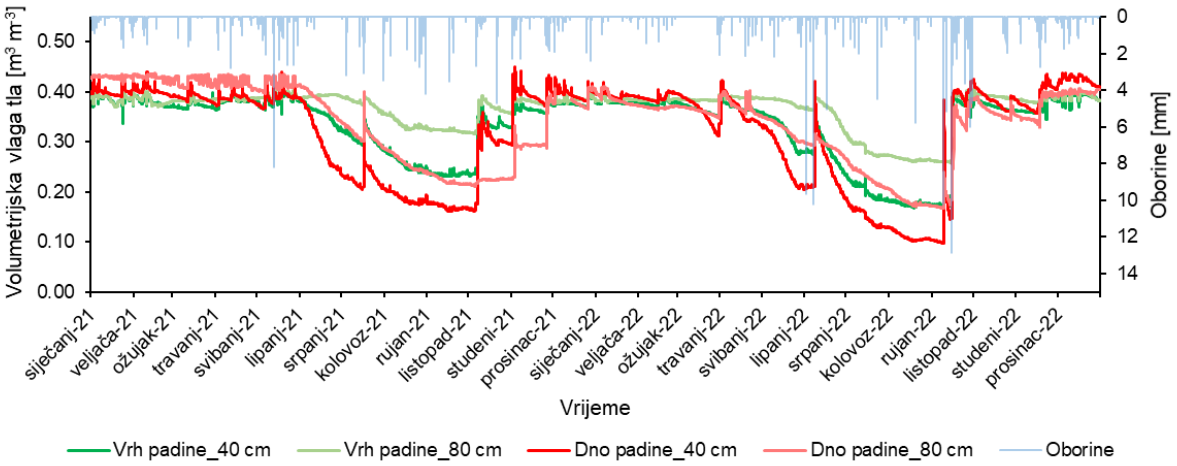

Slika 4.1.1.7. Volumetrijska vlaga tla za vrh i dno padine na dubini od 40 i 80 cm kroz period od dvije godine (2021. – 2022.).

Slika 4.1.1.8. prikazuje prosječne vrijednosti volumetrijske vlage tla na vrhu i dnu padine na dvije dubine (40 i 80 cm) s usporedbom u ovisnosti o godišnjim dobima tijekom istraživanog perioda (2021. i 2022. godine). U jesen 2021. prosječne vrijednosti volumetrijske vlage tla bile su malo niže u odnosu na jesen 2022. na obje dubine. Nadalje, na dnu padine su također bile zabilježene niže vrijednosti volumetrijske vlage tla u jesen 2021. u usporedbi s 2022., ali te razlike su također bile i izraženije u odnosu na vrh padine. Tijekom zime 2021. prosječne vrijednosti vlage tla na vrhu padine bile su iste u usporedbi sa zimom 2022. godine na obje dubine. Na dnu padine na 40 cm prosječne vrijednosti su se minimalno razlikovale (0,40 m^3 m^{-3} za 2021. i 0,39 m^3 m^{-3} za 2022.), dok je na 80 cm ta razlika bila izraženija (0,43 m^3 m^{-3} za 2021. i 0,38 m^3 m^{-3} za 2022.). U proljeće 2021. prosječne vrijednosti vlage tla bile su veće i na vrhu i na dnu padine na obje dubine u odnosu s 2022. godinom. Razlika je bila izraženija na dnu padine, dok su na vrhu padine, posebice na 80 cm bile gotovo jednake. Tijekom ljetnog perioda 2021. godine prosječne vrijednosti su također bile veće uspoređujući s 2022. godinom. Ovaj put su te razlike bile nešto izraženije na vrhu padine.

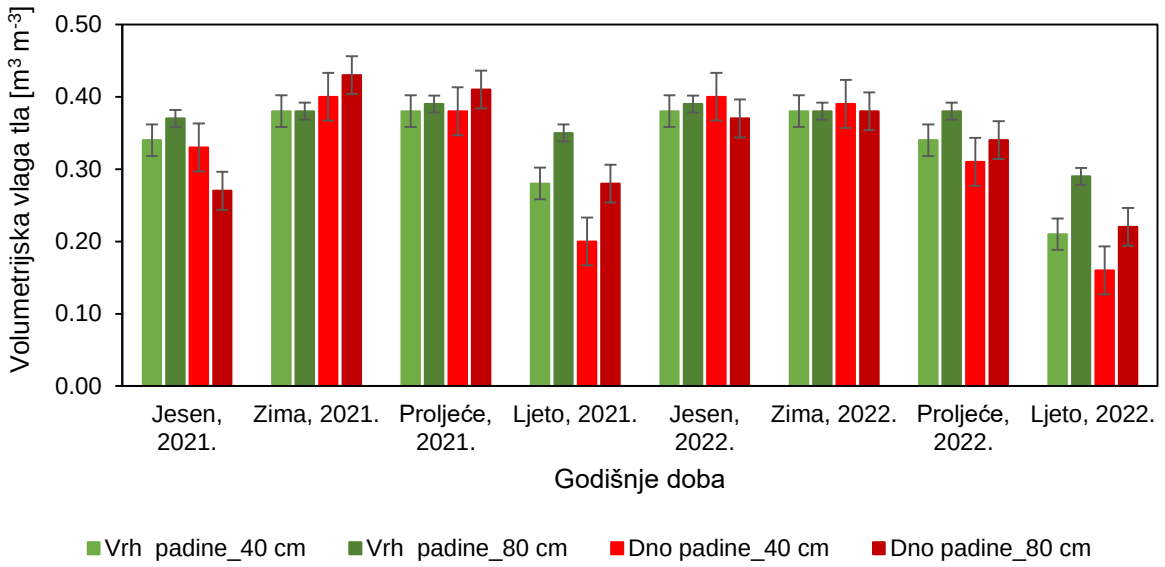

Slika 4.1.1.8. Prosječna volumetrijska vlaga tla izmjerene na vrhu i dnu padine na dubini od 40 i 80 cm tijekom pojedinog godišnjeg doba u 2021. i 2022. godini.

Najveća odstupanja od prosječnih mjerenja zabilježena na dnu padine na 40 cm dubine, dok su s druge strane, najmanja odstupanja izmjerena na vrhu padine na 80 cm. Vrijednosti standardne devijacije bile su veće tijekom jeseni 2021. za sva mjerenja u usporedbi s jeseni 2022. godine. Tijekom zime su odstupanja bila gotovo jednaka u obje istraživane godine. Tijekom proljeća 2022. jedino na vrhu padine na 80 cm nisu zabilježena veća odstupanja u odnosu na proljće 2021. godine, dok su u ljeto 2022. godine u svim mjerenjima zabilježene veće vrijednosti standardne devijacije.

Slika 4.1.1.9. prikazuje vodni potencijal tla na dubini od 40 cm na vrhu i dnu padine tijekom 2021. i 2022. godine. S obzirom da se vrijednosti vodnog potencijala kreću do -2500 kPa, najsuši periodi godine su i najistaknutiji. Vrijednosti vodnog potencijala tla uglavnom su bile vrlo slične na vrhu i dnu padine tijekom cijele godine, osim ljetnih mjeseci. Tijekom ljeta 2021. godine, maksimalne vrijednosti su se izmijenjivale između vrha i dna padine. Isto tako, vidljivo je da je dno padine tijekom ljeta 2022. godine bilo uglavnom vlažnije u odnosu na vrh padine. Suši ljetni period u 2021. započeo je u lipnju i trajao do listopada, dok je u 2022. godini taj period započeo nešto ranije, odnosno u svibnju i trajao do rujna. Nadalje, od 19. rujna u večernjim satima do 20. rujna 2021. godine zabilježene su oborine kroz gotovih svakih 15 minuta. To je uzrokovalo vlaženje na dnu padine u ranim jutarnjim satima 20. rujna, dok na vrhu padine nisu zabilježene značajne promjene. Već istoga dana (20. rujna) u popodnevnim satima, dno padine se počinje ponovno sušiti te nekoliko dana kasnije postiže slične vrijednosti s vrhom padine. Nadalje, u lipnju 2022. zabilježene su dvije izraženije oborine (gotovo najveće u cijelom istraživanom razdoblju) u razmaku nekoliko dana (9,62 i 10,17 mm) te su vrijednosti

vodnog potencijala porasle svega nekoliko sati nakon na obje pozicije. Najveća količina oborina u istraživanom razdoblju iznosila je 12,8 mm sredinom rujna 2022. godine. Nagli porast vodnog potencijala zabilježen je i na vrhu i na dnu padine pet sati nakon, s time da je bilo oborina kroz cijeli dan.

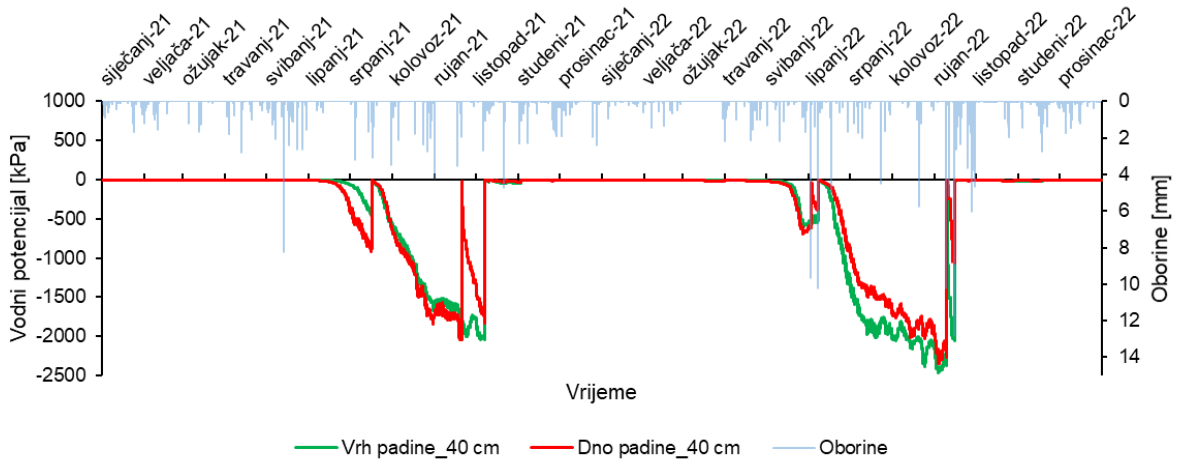

Slika 4.1.1.9. Vodni potencijal tla za vrh i dno padine na dubini od 40 cm kroz period od dvije godine (2021 – 2022).

Slika 4.1.1.10. prikazuje prosječne vrijednosti vodnog potencijala tla izmjerenog na dubini od 40 cm na vrhu i dnu padine tijekom različitih godišnjih doba u 2021. i 2022. godini. Prosječno je jesen 2022. bila vlažnija u odnosu na jesen 2021. Ipak, razlike u standardnoj devijaciji bile su znatno izraženije u jesen 2021. što bi značilo da je razlika u vlažnom i sušem periodu bila izraženija u odnosu na 2022. godinu. Dok su se kroz cijelu jesen 2022. vrijednosti vodnog potencijala tla kretale između -16 i -10 kPa na vrhu padine, odnosno između -15 i -10 kPa na dnu padine, do 7. listopada 2021. vrijednosti vodnog potencijala bile su manje od -770 kPa i na vrhu i na dnu padine. Nakon 7. listopada vodni potencijal tla raste te se vrijednosti kreću između -48 i -10 kPa na vrhu padine i -29 i -10 kPa na dnu padine. Nadalje, vodni potencijal tla tijekom zime u obje istraživane godine bio je sličan s malim odstupanjima u standardnoj devijaciji. Proljeće 2021. bilo je vlažnije u usporedbi s proljećem 2022. Također i ovdje su vrijednosti standardne devijacije visoke što upućuje na učestalo sušenje i vlaženje tla tijekom proljeća 2022. godine. Vodni potencijal tla tijekom proljeća 2021. kretao se između -15 i -10 kPa, a na dnu padine od -58 do -9 kPa. Sredinom lipnja 2021. na dnu padine vrijednosti vodnog potencijala počele su padati. Nadalje, tijekom proljeća 2022. vrijednosti su se kretale od -655 do -10 kPa, odnosno na dnu padine od -688 do -10 kPa. Kao što je već navedeno, sušni period započeo je u 2022. godini već u svibnju što je rezultiralo padom vrijednosti vodnog potencijala. Kao i tijekom 2021. godine i ovaj put su vrijednosti vodnog potencijala na dnu padine izraženije padale u odnosu na vrijednosti na vrhu padine. Očekivano, tijekom oba

ljeta u istraživanom razdoblju vrijednosti vodnog potencijala značajno su pale u odnosu na druga godišnja doba. Ipak, ljeto 2021. je bilo vlažnije nego ljeto iduće godine. Vrijednosti standardnih devijacije bile su visoke za oba ljeta što je i očekivano zbog ekstremnijih količina oborina nakon kojih slijede sušni periodi što dovodi do velikih promjena u vodnom potencijalu tla.

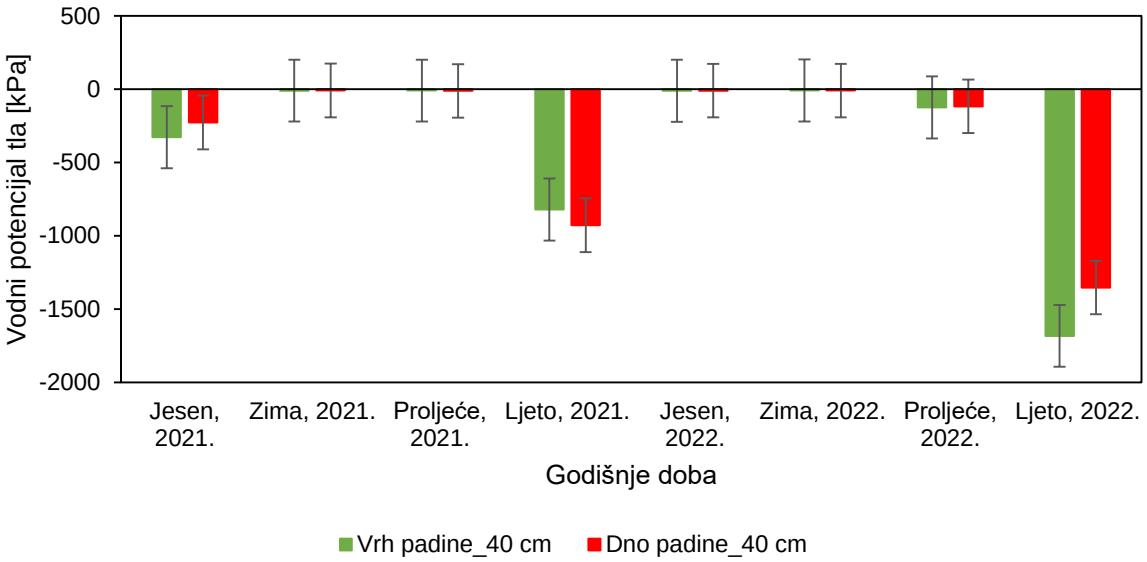

Slika 4.1.1.10. Prosječni vodni potencijal tla za vrh i dno padine na dubini od 40 cm tijekom pojedinog godišnjeg doba u 2021. i 2022. godini.

Slika 4.1.1.11. prikazuje promjenu volumetrijske vlage tla kroz cijeli profil tla do dubine od 100 cm na sredini padine tijekom 2021. i 2022. godine. S obzirom da su na ovoj poziciji postavljeni senzori za mjerenje volumetrijske vlage tla na pet različitih dubina (15, 30, 50, 75 i 100 cm), isto omogućuje detaljno praćenje preferencijalnog toka na jednoj mikrolokaciji. Također, točno na ovoj lokaciji postavljena je meteorološka stanica te će stoga prosječne oborine kroz istraživani period biti ovdje prikazane. Tijekom razdoblja istraživanja u nekoliko navrata nakon oborina nije zabilježen porast u volumetrijskoj vlazi tla čak ni na najplićem senzoru (npr. sredina svibnja 2021. i 2022. te srpanj 2021. i 2022.) što upućuje na repelentnost tla za vodu i/ili površinsko otjecanje. S druge strane, u svibnju i srpnju 2021. godine zabilježeni su veliki volumeni prikupljeni u sustavima za površinsko otjecanje što navodi da je većina oborina otjecala po površini te zbog toga nisu zabilježene promjene u volumetrijskoj vlazi tla čak ni na najplićim senzorima. Do ponovnog vlaženja cijelog profila nakon ljetnog sušnog perioda dolazi u studenom 2021. godine. Tijekom zimskih mjeseci, najviše vrijednosti volumetrijske vlage tla zabilježene su na 30 i 100 cm dubine. 02. lipnja je pala velika količina oborina (samo u jednom mjerenju od 15 minuta palo je 9,62 mm) koja je uzrokovala porast volumetrijske vlage tla u cijelom profilu tla te su senzori reagirali već u idućem mjerenju (nakon samo 15 minuta) na svim dubinama. Senzor na 15 cm zabilježio je promjenu s 0,240 na 0,318 m^3 m^{-3}, na 30 cm s

0,233 na 0,330 m^3 m^{-3}, na 50 cm s 0,281 na 0,292 m^3 m^{-3}, na 75 cm s 0,256 na 0,301 m^3 m^{-3}, te na 100 cm s 0,336 na 0,349 m^3 m^{-3}. Najveće promjene zabilježene su na 30 cm, a najmanje na 50 cm. Iako uglavnom tijekom cijelog kolovoza 2022. godine nisu zabilježene značajnije oborine, 20. kolovoza zabilježena je kratka oborina tijekom dva uzastopna mjerenja (2,99 i 5,73 mm) nakon koje je veća promjena senzora izmjerena samo na 50 cm (volumetrijska vlaga tla narasla je s 0,224 na 0,255 m^3 m^{-3}) što upućuje na lateralni preferencijalni tok. Prva značajnija promjena tijekom rujna dogodila se nakon devet dana. Zabilježeno je preko 10 mm oborina što je uzrokovalo porast vlage tla na 15 cm s 0,171 na 0,303 m^3 m^{-3}, na 30 cm s 0,167 na 0,309 m^3 m^{-3}, na 50 cm s 0,223 na 0,243 m^3 m^{-3}, na 75 cm s 0,185 na 0247 m^3 m^{-3}, na 100 cm s 0,244 na 0,302 m^3 m^{-3}. Sve promjene su se dogodile unutar pola sata od prvih zabilježenih oborina. Nakon toga ponovno slijedi period sušenja te već sredinom mjeseca prve dvije dubine padaju ispod 0,200 m^3 m^{-3}.

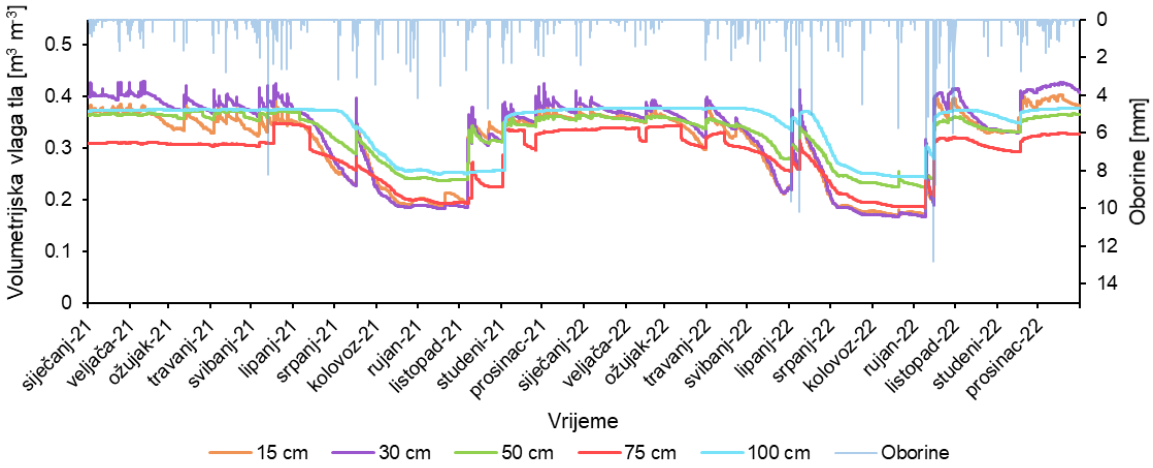

Slika 4.1.1.11. Prikaz volumetrijske vlage tla kroz cijeli profil tla (100 cm) na sredini padine kroz period od dvije godine (2021. – 2022.).

Na Slici 4.1.1.12. su izdvojeni pojedini periodi tijekom razdoblja istraživanja u kojima se može vidjeti prisutnost preferencijalnog toka. Senzori postavljeni na 30 cm su reagirali izraženije od senzora postavljenih na 15 cm u gotovo svim izdvojenim događajima te su često imali i veću volumetrijsku vlagu tla. Na Slici 4.1.1.12. a) vidljivo je da je tijekom cijelog siječnja i veljače prve godine istraživanja najveća volumetrijska vlaga tla bila na 30 cm, dok je na 75 cm bila vidljivo najniža. Također, na 30 cm su i promjene u vrijednostima vlage tla bile izraženije u usporedbi s 15 cm. Slična situacija je vidljiva i na Slici 4.1.1.12. b), međutim ovdje je zabilježen i nagli porast vlage na 75 cm tijekom svibnja, te zatim nagli pad u lipnju. S druge strane, tijekom istog perioda senzori postavljeni na 50 cm nisu izmjerili tako značajne promjene u volumetrijskoj vlazi tla. Ipak, najizraženija promjena je zabilježena u srpnju na 30 cm gdje je u vrlo kratkom vremenu došlo do drastičnog porasta u vlazi tla koje je bilo izraženije čak i od onoga na 15 cm. Nadalje, na Slici 4.1.1.12. c) vidljivo je da izraženije povećanje volumetrijske

vlage tla na dubini od 100 cm u usporedbi sa senzorom postavljenim na 75 cm. Također, tijekom studenog na dubini od 75 cm vidljiv je najizraženiji pad vrijednosti volumetrijske vlage tla koji je kasnije praćen izraženijim porastom i promjenom tih vrijednosti u odnosu na senzore na drugim dubinama. Osim toga, na istoj Slici je vidljivo da je u tijekom pojedinih kišnih događaja promjena vrijednosti vlage tla na 30 cm bila izraženija nego na 15 cm. Na Slici 4.1.1.12. d) je vidljiv najizraženiji pad vlage tla u prvom dijelu veljače na dubini od 75 cm, međutim svega nekoliko dana kasnije je upravo 30 i 75 cm dubine zabilježena najveća promjena u volumetrijskoj vlazi tla. Nadalje, na Slici 4.1.1.12. e) se može vidjeti da je senzor postavljen na 50 cm izraženije reagirao na jake oborine krajem kolovoza u odnosu na senzore na 15 i 30 cm dubine. Štoviše, senzor na 30 cm dubine nije pokazao nagli porast volumetrijske vlage tla kao što je to slučaj na senzorima na 15 i 50 cm već je do porasta došlo postupno. U jednom trenutku tijekom navedenog kišnog događaja na 50 cm dubine su izmjerene i najveće vrijednosti volumetrijske vlage tla. Nakon oborina početkom rujna, senzori na 75 cm dubine reagirali su nešto prije nego senzori na 50 cm, te su također izmjerene izraženije promjene u volumetrijskoj vlazi tla (Slika 4.1.1.12. f)). Također je nakon pojedinih oborina promjena u volumetrijskoj vlazi tla na 100 cm dubine bila izraženija u odnosu na 75 cm.

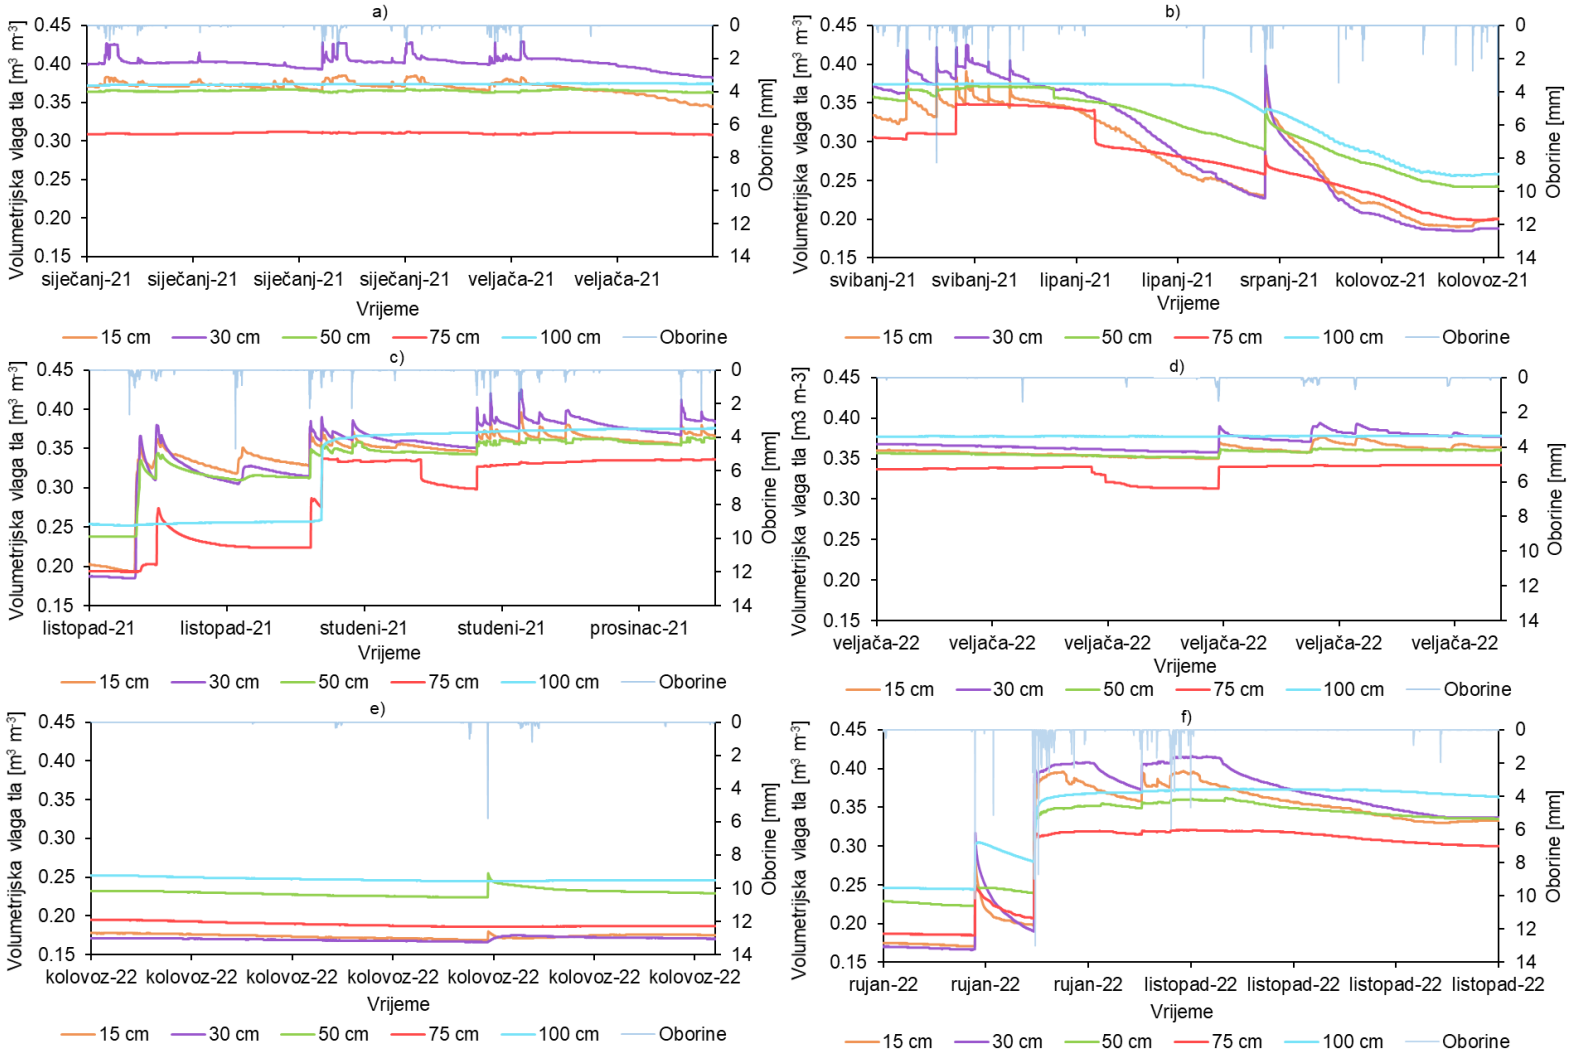

Slika 4.1.1.12. Prikaz promjena volumetrijske vlage tla i identifikacije preferencijalnog toka kroz cijeli profil tla (100 cm) na sredini padine u pojedinim periodima tijekom razdoblja istraživanja (2021. – 2022.).

Slika 4.1.1.13. prikazuje prosječnu volumetrijsku vlagu tla kroz cijeli profil tla do dubine od 100 cm na sredini padine kroz različita godišnja doba. Prosječne vrijednosti volumetrijske vlage tla praćene su na pet dubina (15, 30, 50, 75 i 100 cm) kroz dvije godine (2021. i 2022.). S obzirom da je meteorološka postaja postavljena točno na ovoj lokaciji, prosječne oborine kroz istraživani period također će biti prikazane (Slika 4.1.1.14.). Vidljivo je da su tijekom gotovo cijelog istraživanog razdoblja prosječne vrijednosti vlage tla zabilježene na 30 i 100 cm bile veće u odnosu na vrijednosti na 15 cm. Najmanje prosječne vrijednosti zabilježene su na 75 cm tijekom svih godišnjih doba osim ljeta. Prosječne vrijednosti volumetrijske vlage tla u cijelom profilu tijekom jeseni bile su više u 2022. u odnosu na 2021. godinu. Tijekom zime vrijednosti su se razlikovale na 30 i 75 cm, s tim da su na 30 cm više vrijednosti zabilježene u 2021., dok je na 75 cm vlaga tla bila viša u 2022. godini. Na dubinama od 15, 50 i 100 cm zabilježene su prosječno približno jednake vrijednosti volumetrijske vlage tla. Prosječne vrijednosti volumetrijske vlage tla tijekom proljeća i ljeta obje godine bile su više u 2021. u odnosu na 2022. godinu na svim dubinama. Što se tiče oborina, tijekom jeseni je prosječno izmjerena veća količina oborina u drugoj godini istraživanja, dok je u istoj godini i standardna devijacija bila nešto viša nego prethodne godine. Nadalje, tijekom zime 2021. prosječne količine oborina bile su nešto veće nego u idućoj godini, dok su oborine tijekom proljeća obje godine bile približno jednake. Ipak, standardna devijacija tijekom oba godišnja doba bila je veća u prvoj godini istraživanja. U ljeto 2022. godine prosječne količine oborina bile su gotovo dvostruko veće u odnosu na prethodnu godinu kao i standardna devijacija. Navedeno upućuje na veće razlike tijekom druge godine istraživanja, što je posljedica povremenih kišnih događaja tijekom kojih je pala znatna količina oborina što je i vidljivo iz Slike 4.1.1.11.

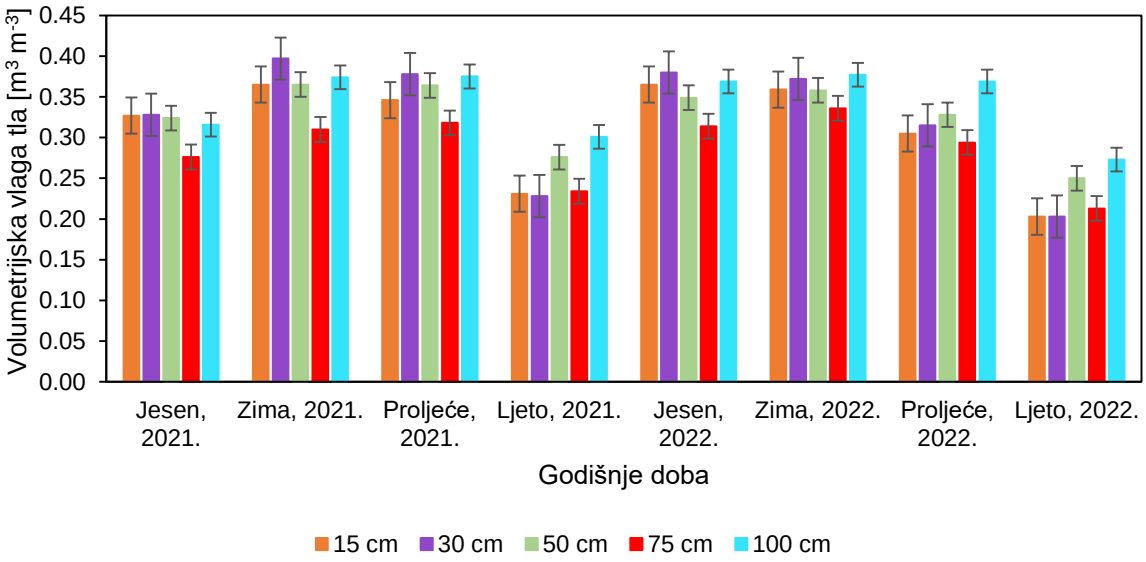

Slika 4.1.1.13. Prosječna volumetrijska vlaga tla za cijeli profil tla (100 cm) na sredini padine i oborina tijekom pojedinog godišnjeg doba u 2021. i 2022. godini.

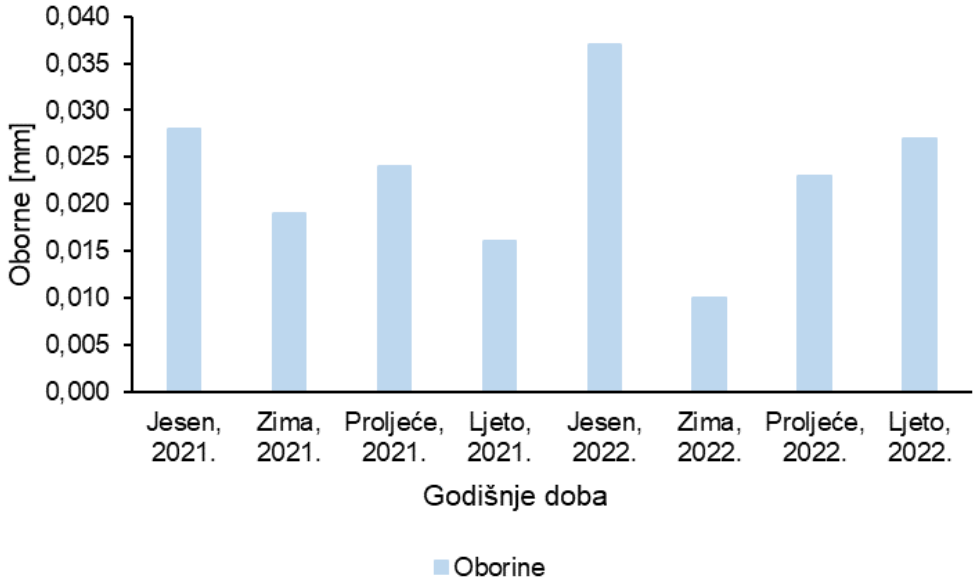

Slika 4.1.1.14. Prosječne vrijednosti oborina na istraživanoj lokaciji u ovisnosti o godišnjim dobima tijekom 2021. i 2022. godine.

4.1.2. Infiltracijska sposobnost tla

Vrijednosti infiltracijske sposobnosti tla (Tablica 4.1.2.1.) varirale su ovisno o podtlaku i poziciji na padini. Tako su se, na primjer, vrijednosti za 1 cm kretale od 18,87 do 27,83 cm dan^{-1} za vrh padine, od 2,45 do 37,28 cm dan^{-1} na sredini padine, te 8,23 do 12,57 cm dan^{-1} na dnu

padine. S druge strane, pri podtlaku od 5 cm, vrijednosti su se kretale između 1,30 i 7,35 cm dan^{-1} na vrhu padine, od 2,56 do 6,55 cm dan^{-1} na sredini padine, te od 3,14 do 3,85 cm dan^{-1} na dnu padine. R^2 se kretao između 0,96 i 1,00 pri svakom mjerenju što ukazuje na visoku podudarnost. Standardna devijacija se na vrhu padine kretala od 2,41 do 8,22, na sredini od 2,01 do 17,79 te na dnu padine od 0,36 do 3,01 što upućuje na heterogenost istraživane padine. Niži podtlak uzrokuje veću vodljivost te se i tok odvija kroz veće pore, dok se pri višim vrijednostima podtlaka dobiva informacija o mikroporama. Rezultati standardne devijacije ukazuju na najveću homogenost na dnu padine s obzirom da su vrijednosti najmanje pri svim mjerenjima. Slike 9.1. – 9.9. prikazuju inifltracijsku sposobnost tla izmjerenu mini disk infiltrometrom pri različitim podtlakovima (1, 2, 3, 4 i 5 cm) za svaku pojedinu poziciju na padini i njihove replikacije.

Tablica 4.1.2.1. Vrijednost infiltracijske sposobnosti tla mjerena na površini tla u tri replikacije na vrhu (A), sredini (B) i dnu (C) padine pri različitim podtlakovima.

Pozicija na padini	Podtlak [cm]				
	1	2	3	4	5
	Hidraulička vodljivost [cm dan^{-1}]				
AI	27,50	25,29	14,60	9,16	7,35
AII	18,87	8,88	5,62	4,76	1,30
AIII	27,83	18,04	6,70	5,24	1,52
S.D.	5,08	8,22	4,90	2,41	3,43
BI	2,45	2,26	7,43	3,41	2,56
BII	37,28	11,99	9,84	6,36	4,91
BIII	26,19	18,63	14,34	8,99	6,55
S.D.	17,79	8,23	3,51	2,79	2,01
CI	8,23	8,10	8,25	4,84	3,14
CII	12,57	12,21	11,62	6,57	3,48
CIII	11,13	9,71	5,62	6,50	3,85
S.D.	2,21	2,07	3,01	0,98	0,36

4.1.3. Određivanje toka vode traserima (briljantno plavo bojilo i kalijev bromid) na terenu

Poprečni presjeci fotografirani na terenu te obrada tih fotografija u *ImageJ* programu prikazana je na Slikama 4.1.3.1. za vrh, 4.1.3.2. za sredinu i 4.1.3.3. za dno padine, a u Tablici 4.1.3.1. su prikazani udjeli obojane površine. Iz fotografija je vidljivo da obojenje nije jednolično niti kroz cijelu površinu aplikacije bojila niti na svim pozicijama. Na vrhu padine udio obojene površine kretao se između 29,45 i 47,35 %, na sredini od 32,73 do 51,89 %, a na dnu padine od 37,59 do 54,39 %. Prosječno je najmanji udio obojene površine na vrhu padine (38,49 %) dok su sredina i dno padine gotovo jednaki (44,04 i 45,60 %).

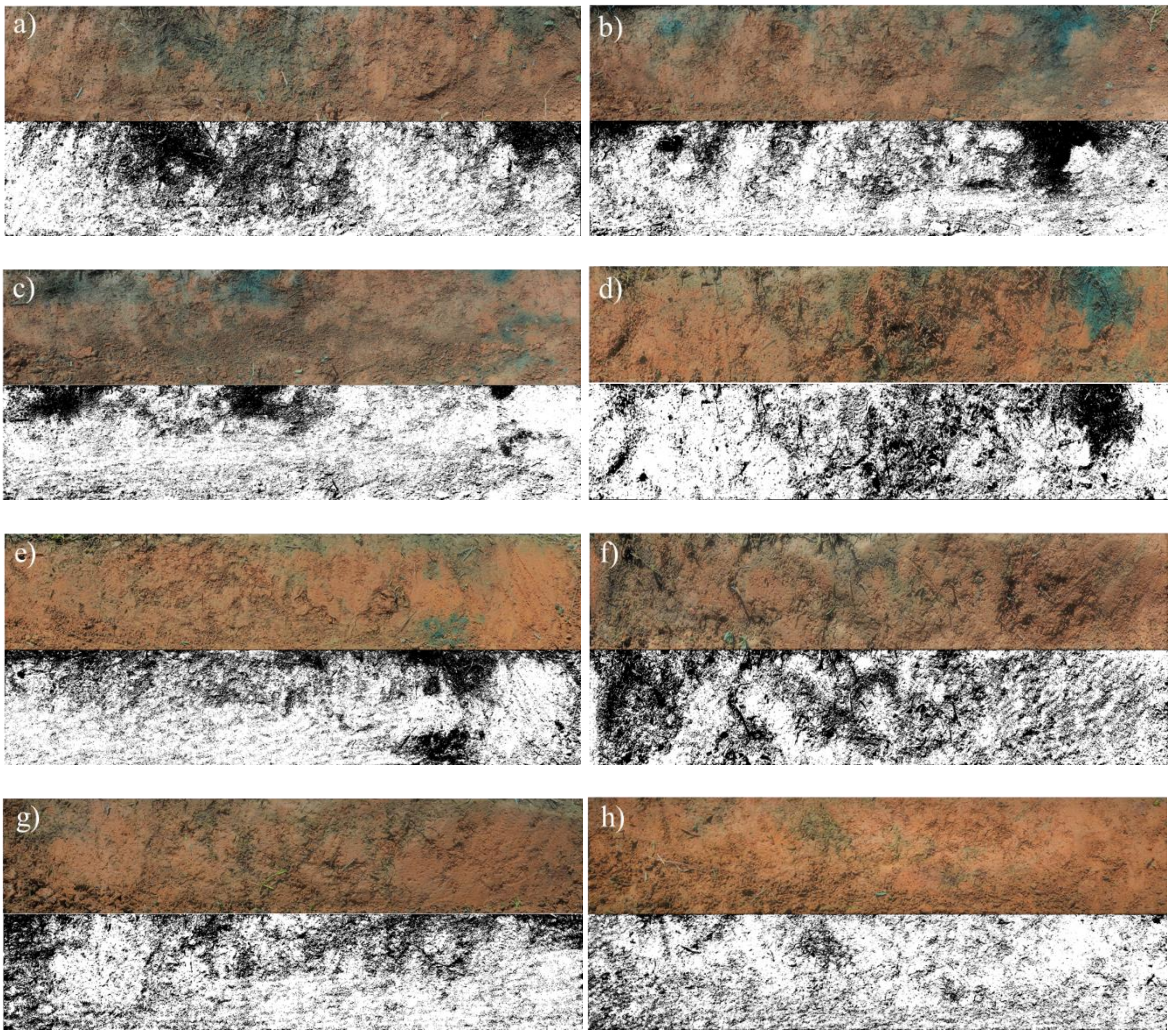

Slika 4.1.3.1. Fotografije presjeka površine tla od 1 m^2 nakon infiltracije briljantno plavog bojila (Brilliant Blue) i obrađene fotografije u *ImageJ* programu (crno-bijele fotografije) za vrh (A) padine.

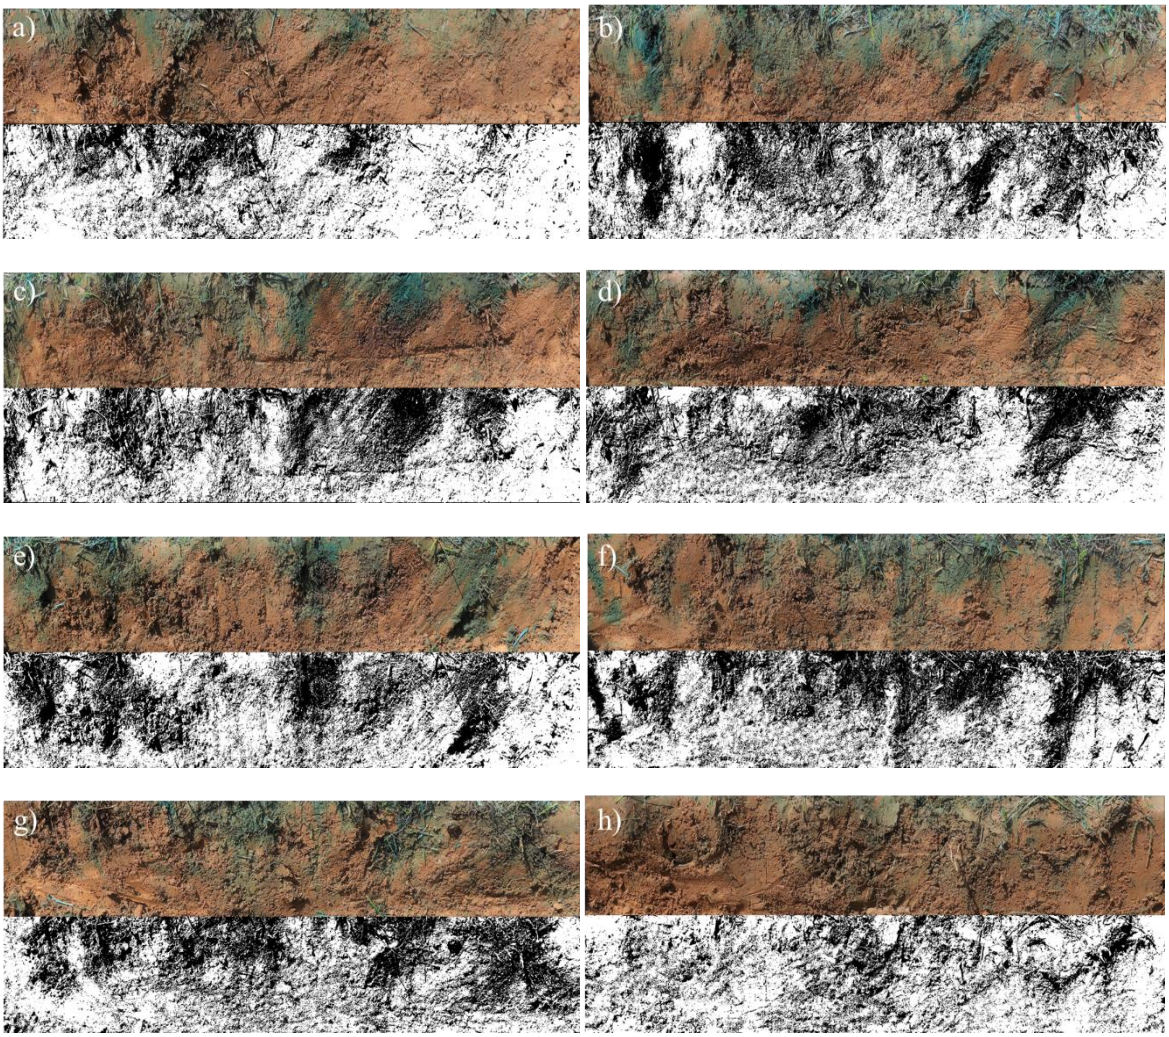

Slika 4.1.3.2. Fotografije presjeka površine tla od 1 m^2 nakon infiltracije briljantno plavog bojila (Brilliant Blue) i obrađene fotografije u *ImageJ* programu (crno-bijele fotografije) za sredinu (B) padine.

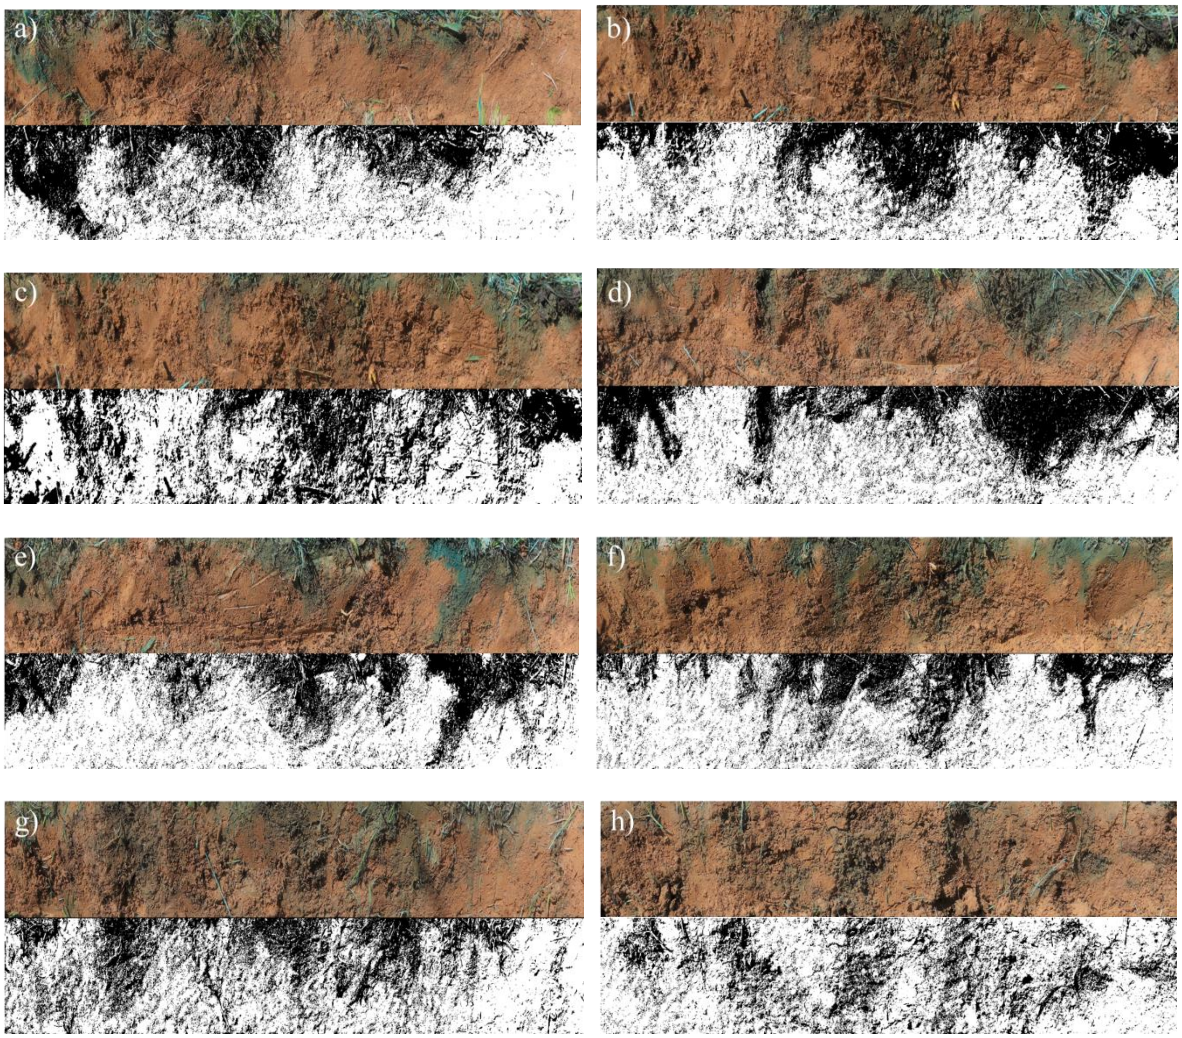

Slika 4.1.3.3. Fotografije presjeka površine tla od 1 m^2 nakon infiltracije briljantno plavog bojila (Brilliant Blue) i obrađene fotografije u *ImageJ* programu (crno-bijele fotografije) za dno (C) padine.

Tablica 4.1.3.1. Postotni udio obojene površine tla svakog pojedinog presjeka na vrhu (A), sredini (B) i dnu (C) padine.

Presjek	Pozicija na padini	a)	b)	c)	d)	e)	f)	g)	h)
Udio obojene površine tla [%]	A	43,38	34,37	32,18	32,15	42,15	46,88	47,35	29,45
	B	32,73	45,22	41,60	45,82	42,72	51,89	50,95	41,37
	C	44,61	54,39	41,33	51,67	43,32	45,76	46,10	37,59

Tablica 4.1.3.2. prikazuje koncentracije ispranih bromida na vrhu (A), sredini (B) i dnu (C) padine u mjernim instrumentima smještenim u međurednom prostoru. Oznake WL (engl. *wick lysimeter*), odnose se na nevagajuće tlačne pasivne lizimetre postavljene na 40 cm dubine, dok SS (engl. *subsurface flow*), označuje potpovršinski tok vode. Iz rezultata je vidljivo da je svibanj 2022. bio sušan te su prikupljeni uzorci iz svega tri nevagajuća tlačna pasivna lizimetra

nakon čega slijede lipanj, srpanj i kolovoz u kojima nije prikupljen nijedan uzorak vode te stoga ni koncentracije bromida nisu mogle biti izmjerene. Oborine tijekom rujna postaju učestalije stoga su i prikupljeni uzorci vode iz gotovo svih mjernih instrumenata. Očekivano, u zimskim mjesecima (studeni i prosinac) prikupljeno je najviše uzoraka, odnosno sa svih mjernih instrumenata. Iz rezultata je vidljivo da su se bromidi počeli ispirati u rujnu kada je došlo do ponovnog vlaženja tla te je tokom vode omogućen transport bromida unutar profila tla. Nadalje, vidljivo je da se glavnina bromida ipak zadržava na plićim dubinama s obzirom da niti u jednom mjesecu nije zabilježen drastičan porast koncentracije ispranih bromida (vrijednosti ne prelaze 0,1 ppm).

Tablica 4.1.3.2. Koncentracija ispranih bromida u mjernim instrumentima na vrhu (A), sredini (B) i dnu (C) padine tijekom 2022. godine.

Pozicija na padini	Oznaka	Datum				
		31.05.	27.09.	28.10.	25.11.	23.12.
		Koncentracija ispranih bromida [ppm]				
A	WL_4	/	0,150	0,513	0,039	0,214
	WL_8	/	2,220	0,894	0,098	0,276
	WL_12	0,390	3,780	1,774	0,478	1,008
B	WL_16	0,163	0,284	0,985	0,372	0,781
	WL_20	/	0,253	0,226	0,072	0,168
	WL_24	/	0,438	0,160	0,044	0,133
C	WL_28	/	/	/	0,075	0,094
	WL_32	/	/	0,583	0,043	0,132
	WL_36	/	0,092	0,144	0,051	0,078
A	SS_1	/	0,039	0,093	0,040	0,076
B	SS_2	/	0,038	0,085	0,050	0,063
C	SS_3	/	0,064	0,116	0,085	0,062

Napomena: u pojedinim mjesecima i na pojedinim mjernim instrumentima nije bilo dovoljno uzoraka za analizu te su oni označeni s /.

4.2. Laboratorijska istraživanja

4.2.1. Hidraulička svojstva tla

Slike 4.2.1.1. – 4.2.1.3. prikazuju retencijske krivulje za tri replikacije te su prikazani Fredlund-Xing, Brooks-Corey, Kosugi, van Genuchten uni- i bimodalni modeli. Statističkim analizama (*RMSE_θ*, *RMSE_K* i *AICc*; Tablica 4.2.1.1.) utvrđeno je da je najpogodniji model van Genuchten bimodal te se stoga taj model odabrao za daljnu obradu.

Tablica 4.2.1.2. prikazuje procjenjena hidraulička svojstva tla u HYPROP-FIT programu koristeći van Genuchten bimodalnu funkciju. Sadržaj vode u tlu pri saturiranim uvjetima (θ_s) kretao se od 0,344 do 0,456 $cm^3\ cm^{-3}$ na vrhu padine, 0,318 do 0,448 $cm^3\ cm^{-3}$ na sredini te 0,376 do 0,456 $cm^3\ cm^{-3}$ na dnu padine za sve replikacije. Najniže vrijednosti hidrauličke

vodljivosti na svim pozicijama na padini iznosile su 0,5 cm dan^{-1}, dok su najviše vrijednosti bile 31,70 cm dan^{-1} na vrhu, 10,00 cm dan^{-1} na sredini, te 8,33 cm dan^{-1} na dnu padine. Nadalje, u Tablici 4.2.1.3. prikazane su vrijednosti ukupne poroznosti i gustoće tla. Ukupna poroznost kretala se između 35 i 47 % na vrhu, 34 i 43 % na sredini i 40 i 46 % na dnu padine. Na vrhu i dnu padine, ukupna poroznost bila je uglavnom nešto veća na prvoj dubini (15 – 20 cm) u usporedbi s drugom dubinom (35 – 40 cm). S druge strane, na sredini padine je u svim replikacijama bila niža u usporedbi s drugom dubinom. Gustoća tla se ovisno o dubini kretala između 1,42 i 1,71 g cm^{-3} na vrhu padine, 1,51 i 1,75 g cm^{-3} na sredini padine, te 1,45 i 1,58 g cm^{-3} na dnu padine. Na dubinama 15 – 20 i 35 – 40 cm prosječno najviši sadržaj vode u tlu u saturiranim uvjetima bio je na vrhu padine, dok je prosječno najniži bio na sredini padine. S druge strane, na dubinama 55 – 60 i 70 – 75 cm najviši sadržaj vode je na dnu padine, dok je na sredini i dalje najniži. Ukupna poroznost tla nije se značajno razlikovala ovisno o poziciji na padini, ali razlike su ipak uočene. Tako je na dubini 15 – 20 i 35 – 40 cm prosječno najveća je na vrhu padine, a najmanja na sredini. S druge strane, nakon 55 cm prosječno je najveća na dnu padine, pri čemu je na dubini 55 – 60 cm najmanja na vrhu, a na dubini 70 – 75 cm najmanja na sredini padine. Nadalje, prosječna gustoća tla bila je najveća na sredini padine za dubinu 15 – 20 cm, dok je najmanja bila na vrhu padine. Na dubini 35 – 40 cm, prosječna gustoća tla bila je ista na sredini i dnu padine, dok je najmanja bila na vrhu padine, ali razlike su zanemarive. Na dubini 55 – 60 cm prosječno najveća gustoća tla bila je na vrhu padine, dok je najmanja zabilježena na dnu padine. Na dubini 70 – 75 cm, najveća je na sredini padine, a najmanja na dnu. Što se tiče hidrauličke vodljivosti, na prvoj dubini (15 – 20 cm) prosječne vrijednosti su približno iste na cijeloj padini. Na dubini od 35 do 45 cm prosječno najveće vrijednosti hidrauličke vodljivosti izmjerene su na vrhu, a najmanje na dnu padine. Na dubini 55 – 60 i 70 – 75 cm prosječne vrijednosti su bile slične na sredini i dnu padine, dok su na vrhu bile najveće. Ipak, na dubini 55 – 60 cm te su razlike bile izraženije u odnosu na 70 – 75 cm.

Tablica 4.2.1.1. Statistička analiza (*RMSE_θ*, *RMSE_K* i *AICc*) različitih modela dostupnih u HYPROP-FIT programu (van Genuchten unimodalni, van Genuchten bimodalni, Fredlund-Xing, Brooks-Corey, Kosugi). Zelenom bojom su označene statistički najpogodnije vrijednosti.

Pozicija na padini	Dubina	VGM unimodal			VGM bimodal			Fredlund-Xing			Brooks-Corey			Kosugi		
		RMSE (θ)	RMSE (K)	AICc	RMSE (θ)	RMSE (K)	AICc	RMSE (θ)	RMSE (K)	AICc	RMSE (θ)	RMSE (K)	AICc	RMSE (θ)	RMSE (K)	AICc
AI	15-20	0.0171	0.4487	-4380	0.0175	0.3780	-4420	0.0178	0.3618	-4424	0.0223	0.8744	-3896	0.0175	0.4098	-4400
	35-40	0.0153	0.5579	-4116	0.0112	0.4220	-4407	0.0105	0.4117	-4454	0.0289	0.8902	-3553	0.0111	0.4193	-4419
	55-60	0.0152	0.5703	-4372	0.0147	0.4595	-4489	0.0157	0.4537	-4456	0.0244	0.9270	-3859	0.0150	0.4821	-4460
	70-75	0.0092	0.3469	-4289	0.0077	0.3389	-4373	0.0085	0.3080	-4381	0.0093	0.5451	-4039	0.0089	0.3797	-4263
AII	15-20	0.0103	0.4305	-4265	0.0095	0.3930	-4345	0.0109	0.3703	-4316	0.0192	0.8211	-3654	0.0101	0.3921	-4323
	35-40	0.0133	0.4015	-4358	0.0115	0.3229	-4526	0.0115	0.2985	-4553	0.0254	0.8232	-3677	0.0116	0.3443	-4499
	55-60	0.0121	0.2666	-4263	0.0113	0.2683	-4308	0.0203	0.4175	-3783	0.0142	0.4616	-4006	0.0128	0.2660	-4220
	70-75	0.0166	0.4026	-3554	0.0154	0.3912	-3607	0.0154	0.3961	-3609	0.0150	0.4645	-3592	0.0170	0.4203	-3531
AIII	15-20	0.0131	0.4192	-2910	0.0116	0.3277	-3018	0.0130	0.3344	-2968	0.0246	0.8221	-2474	0.0117	0.3491	-3007
	35-40	0.0172	0.4048	-3686	0.0138	0.2811	-3903	0.0134	0.2987	-3916	0.0278	0.6152	-3271	0.0149	0.2733	-3856
	55-60	0.0132	0.3938	-4658	0.0138	0.2791	-4731	0.0159	0.2254	-4653	0.0200	0.8248	-4046	0.0144	0.3275	-4663
	70-75	0.0148	0.5414	-4244	0.0148	0.4360	-4326	0.0211	0.4273	-4077	0.0129	0.8695	-4002	0.0137	0.6525	-4180
BI	15-20	0.0107	0.4769	-4973	0.0108	0.3743	-5117	0.0119	0.4094	-5013	0.0148	0.7940	-4462	0.0107	0.4442	-5021
	35-40	0.0228	0.3690	-3947	0.0224	0.3358	-3972	0.0227	0.3661	-3952	0.0224	0.5580	-3869	0.0226	0.3782	-3953
	55-60	0.0128	0.4424	-4955	0.0120	0.3866	-5060	0.0198	0.3738	-4704	0.0105	0.8367	-4513	0.0110	0.5901	-4816
	70-75	0.0081	0.4112	-3690	0.0085	0.2321	-3931	0.0149	0.3688	-3507	0.0138	0.7238	-3236	0.0066	0.5930	-3482
BII	15-20	0.0098	0.5649	-4949	0.0111	0.4113	-5129	0.0148	0.4337	-4336	0.0201	0.9341	-4287	0.0090	0.5275	-5033
	35-40	0.0132	0.6261	-4208	0.0127	0.4745	-4380	0.0140	0.4525	-4352	0.0202	1.0407	-3718	0.0132	0.5131	-4326
	55-60	0.0130	0.3571	-4371	0.0131	0.3073	-4412	0.0136	0.3030	-4394	0.0201	0.7805	-3784	0.0132	0.3474	-4375
	70-75	0.0129	0.3282	-4164	0.0104	0.3393	-4285	0.0108	0.3656	-4239	0.0126	0.5096	-4023	0.0134	0.3344	-4134
BIII	15-20	0.0285	0.3998	-4038	0.0279	0.3989	-4055	0.0283	0.3989	-4044	0.0295	0.7660	-3857	0.0286	0.3766	-4045
	35-40	0.0087	0.4960	-4831	0.0093	0.3343	-5081	0.0104	0.3120	-5055	0.0175	0.8928	-4146	0.0091	0.4375	-4915
	55-60	0.0131	0.3454	-3977	0.0123	0.3414	-4015	0.0254	0.5091	-3441	0.0115	0.5510	-3851	0.0128	0.3770	-3963
	70-75	0.0108	0.3992	-3275	0.0106	0.3493	-3328	0.0101	0.3856	-3311	0.0075	0.5418	-3205	0.0110	0.4333	-3237

CI	15-20	0.0097	0.4077	-4694	0.0078	0.3322	-4907	0.0100	0.4148	-4664	0.0125	0.6981	-4238	0.0089	0.3951	-4748
	35-40	0.0080	0.3199	-4753	0.0062	0.2943	-4901	0.0084	0.3231	-4720	0.0133	0.5888	-4177	0.0074	0.3182	-4789
	55-60	0.0180	0.3114	-4395	0.0164	0.3304	-4451	0.0184	0.2766	-4392	0.0248	0.6762	-3929	0.0173	0.3107	-4429
	70-75	0.0188	0.2278	-4452	0.0176	0.2405	-4498	0.0185	0.2311	-4465	0.0217	0.4852	-4184	0.0185	0.2331	-4462
CII	15-20	0.0081	0.4807	-4959	0.0083	0.4074	-5073	0.0098	0.3869	-5044	0.0144	0.8914	-4279	0.0080	0.4299	-5053
	35-40	0.0093	0.5481	-4451	0.0097	0.3838	-4664	0.0111	0.3751	-4612	0.0163	0.9223	-3900	0.0098	0.4361	-4593
	55-60	0.0174	0.3734	-3900	0.0100	0.2396	-4387	0.0148	0.2294	-4104	0.0289	0.6088	-3429	0.0122	0.2250	-4265
	70-75	0.0136	0.2902	-3839	0.0094	0.2137	-4141	0.0123	0.2059	-3959	0.0253	0.5764	-3282	0.0104	0.2017	-4090
CIII	15-20	0.0088	0.3705	-4902	0.0084	0.3540	-4949	0.0091	0.3647	-4897	0.0129	0.7293	-4285	0.0081	0.4006	-4882
	35-40	0.0120	0.4764	-4849	0.0131	0.3280	-4980	0.0131	0.3365	-4979	0.0194	0.9182	-4184	0.0117	0.4599	-4884
	55-60	0.0124	0.2688	-4556	0.0120	0.2642	-4578	0.0121	0.2681	-4574	0.0152	0.4383	-4259	0.0125	0.2742	-4546
	70-75	0.0162	0.3950	-4273	0.0145	0.4032	-4337	0.0159	0.3988	-4279	0.0210	0.6154	-3946	0.0157	0.3980	-4294

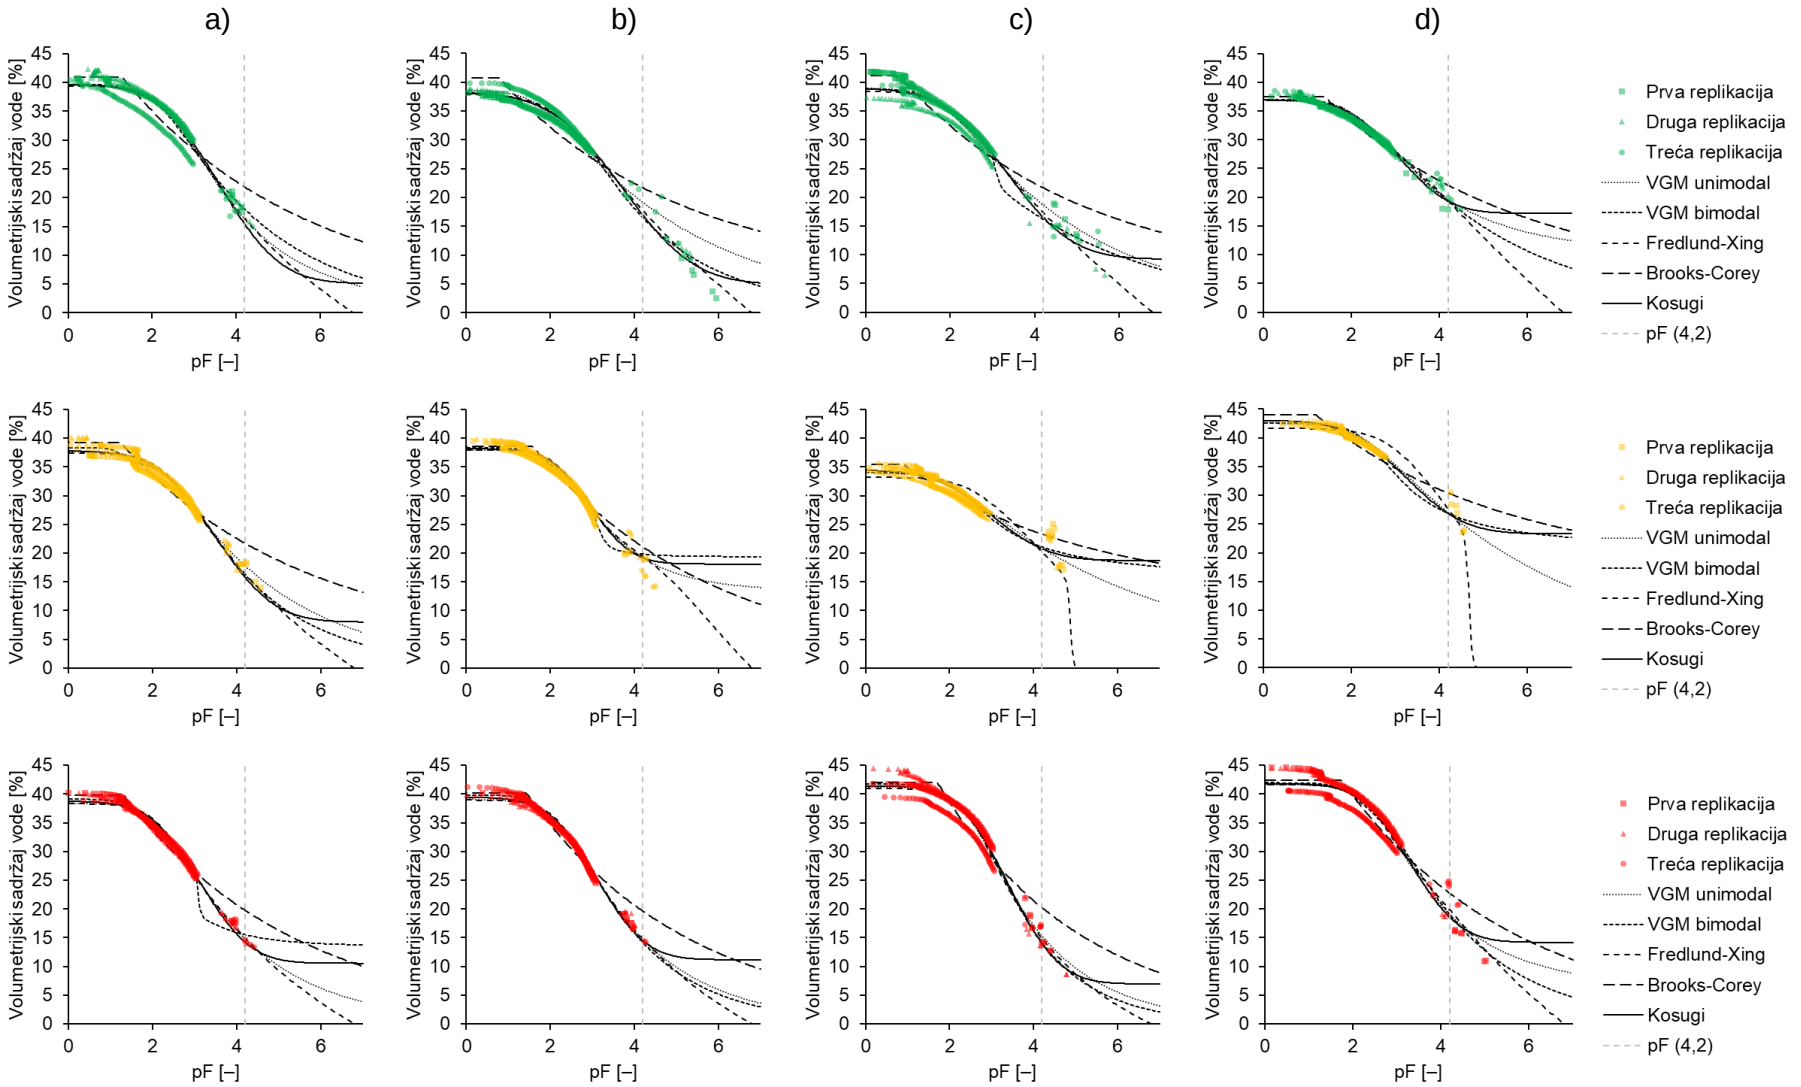

Slika 4.2.1.1. Retencijske krivulje tla prve replikacije (AI, BI, CI) određene u HYPROP-FIT programu koristeći različite modele za vrh (zelena boja), sredinu (žuta boja) i dno (crvena boja) padine na dubinama 15 – 20 cm (a), 35 – 40 cm (b), 55 – 60 cm (c) i 70 – 75 cm (d).

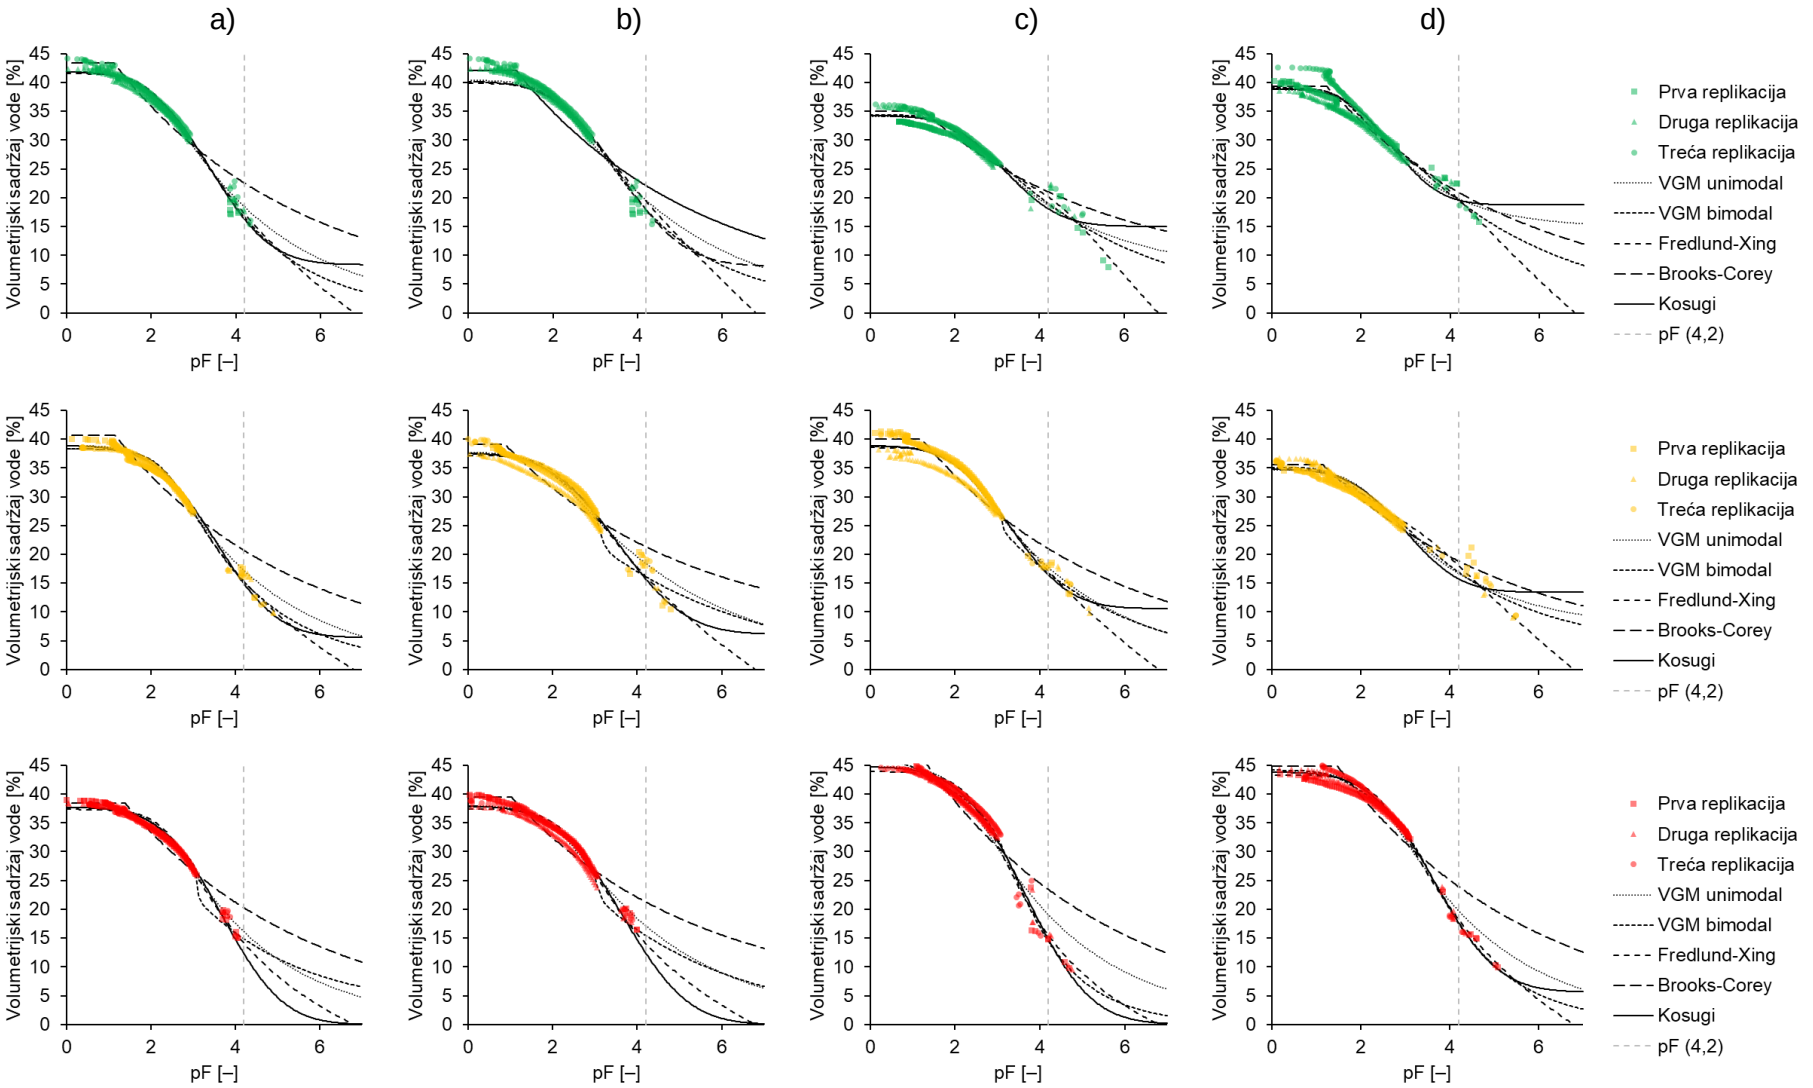

Slika 4.2.1.2. Retencijske krivulje tla druge replikacije (AII, BII, CII) određene u HYPROP-FIT programu koristeći različite modele za vrh (zelena boja), sredinu (žuta boja) i dno (crvena boja) padine na dubinama 15 – 20 cm (a), 35 – 40 cm (b), 55 – 60 cm (c) i 70 – 75 cm (d).

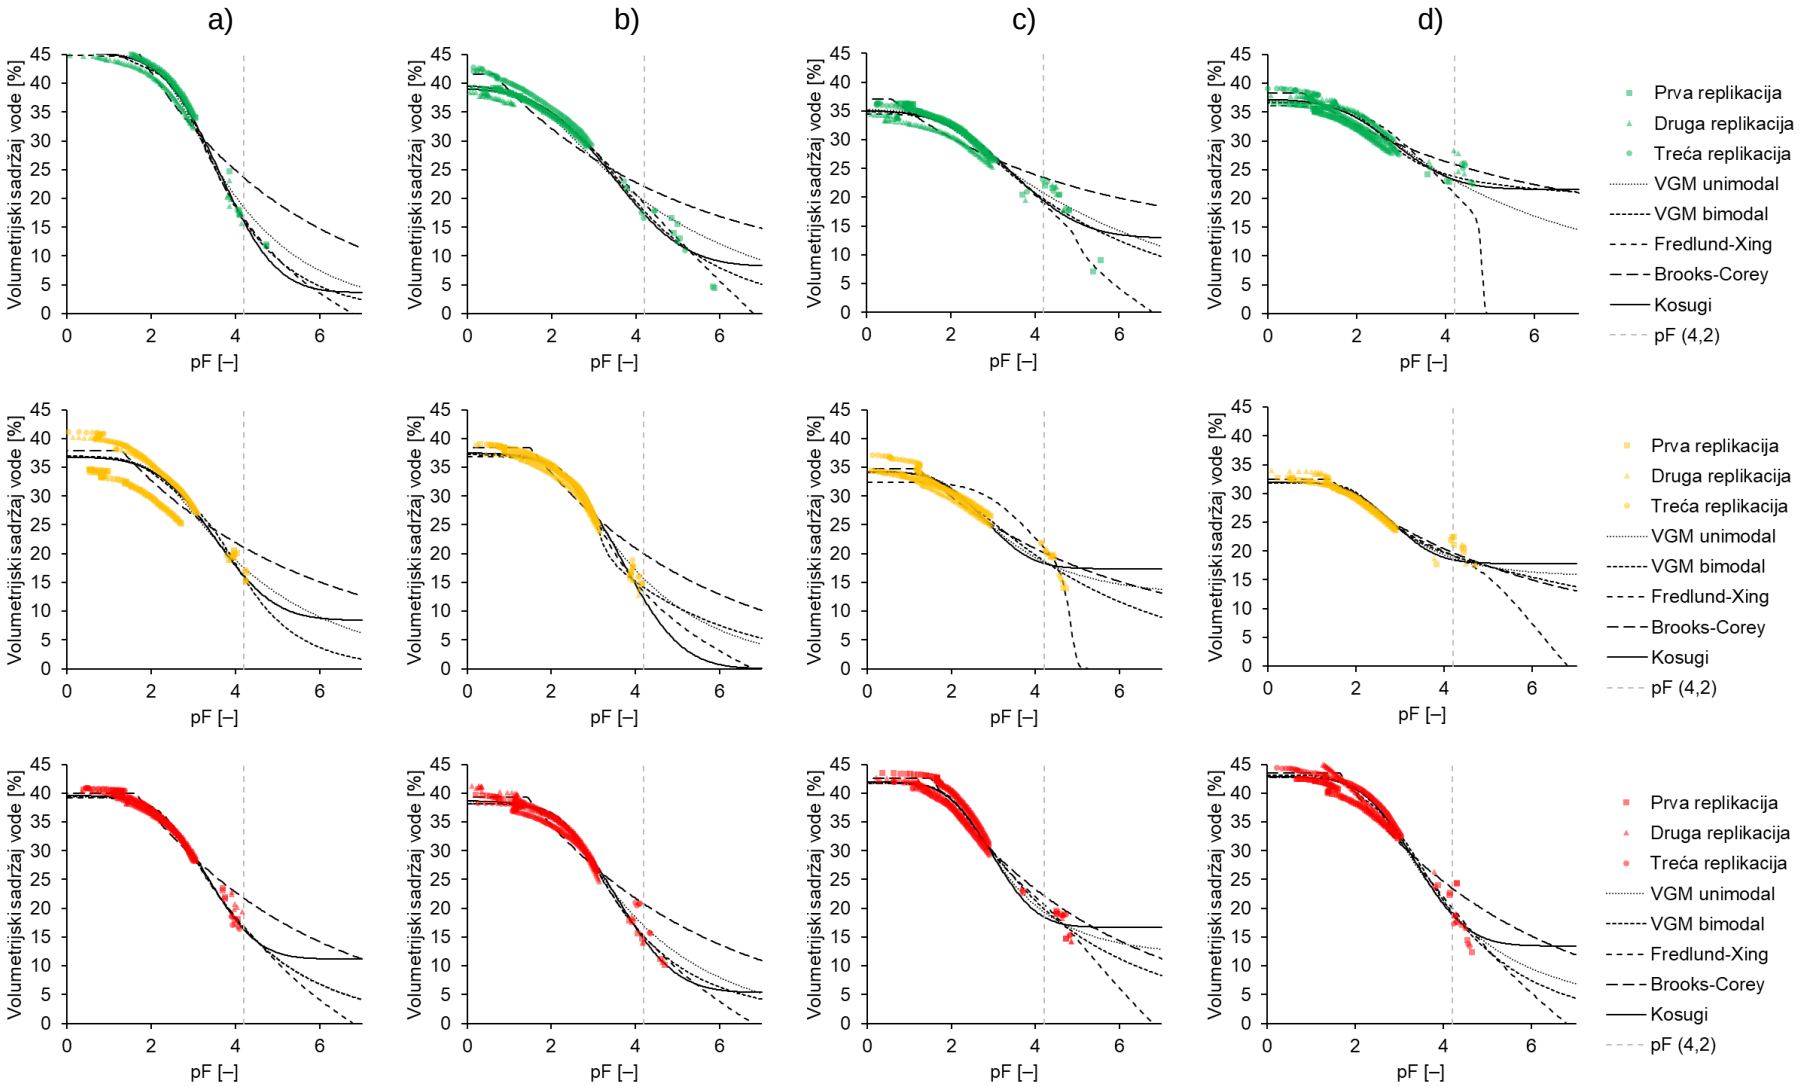

Slika 4.2.1.3. Retencijske krivulje tla treće replikacije (AIII, BIII, CIII) određene u HYPROP-FIT programu koristeći različite modele za vrh (zelena boja), sredinu (žuta boja) i dno (crvena boja) padine na dubinama 15 – 20 cm (a), 35 – 40 cm (b), 55 – 60 cm (c) i 70 – 75 cm (d).

Tablica 4.2.1.2. Hidraulička svojstva tla neporušenih uzoraka tla uzetih u tri replikacije na vrhu (AI, AII, AIII), sredini (BI, BII, BIII) i dnu (CI, CII, CIII) padine na dubinama 15 – 20 cm, 35 – 40, 55 – 60 i 70 – 75 cm određenih u HYPROP-FIT programu koristeći van Genuchten bimodalnu funkciju.

Pozicija na padini	Dubina [cm]	θ_s [$cm^3\ cm^{-3}$]	θ_r [$cm^3\ cm^{-3}$]	α_1 [cm^{-1}]	n1 [-]	KSAT [$cm\ dan^{-1}$]	α_2 [cm^{-1}]	n2 [-]	w [-]
AI	15 – 20	0,395	0,000*	0,00174	1,303	1,00	0,01300	1,146	0,502
	35 – 40	0,382	0,000*	0,00230	1,227	17,00	0,06790	1,137	0,293
	55 – 60	0,390	0,000*	0,00088	7,291	11,00	0,02290	1,121	0,850
	70 – 75	0,370	0,000*	0,01790	2,087	1,00	0,00260	1,144	0,894
AII	15 – 20	0,419	0,000*	0,00130	1,244	1,67	0,00130	1,244	0,581
	35 – 40	0,401	0,000*	0,00136	1,270	7,00	0,02070	1,135	0,524
	55 – 60	0,344	0,000*	0,02500	1,681	3,33	0,00239	1,124	0,866
	70 – 75	0,390	0,000*	0,00135	1,133	2,67	0,02010	1,784	0,253
AIII	15 – 20	0,456	0,000*	0,04810	2,264	0,50	0,00166	1,295	0,941
	35 – 40	0,397	0,000*	0,09260	1,237	28,00	0,00120	1,191	0,700
	55 – 60	0,349	0,000*	0,00978	1,116	31,70	0,5000*	1,010	0,024
	70 – 75	0,366	0,000*	0,01620	1,010	5,33	0,00725	1,470	0,353
BI	15 – 20	0,384	0,000*	0,01200	1,192	1,00	0,00075	15,00	0,200
	35 – 40	0,383	0,000*	0,02400	2,236	1,00	0,00132	1,598	0,845
	55 – 60	0,340	0,000*	0,00687	1,374	3,00	0,01220	1,010	0,577
	70 – 75	0,426	0,000*	0,00719	1,010*	0,50	0,00430	1,425	0,410
BII	15 – 20	0,383	0,000*	0,00390	1,226	1,00	0,00050	5,00	0,009
	35 – 40	0,376	0,000*	0,02290	1,113	10,00	0,00082	6,53	0,163
	55 – 60	0,387	0,000*	0,00078	15,00	4,67	0,01010	1,15	0,925
	70 – 75	0,351	0,000*	0,03980	2,332	3,00	0,00355	1,18	0,872
BIII	15 – 20	0,369	0,000*	0,01370	1,273	1,00	0,00023	1,388	0,572
	35 – 40	0,372	0,000*	0,00760	1,152	2,00	0,00088	4,017	0,213
	55 – 60	0,342	0,000*	0,01830	2,252	2,00	0,00404	1,115	0,886
	70 – 75	0,318	0,000*	0,00230	1,049	0,50	0,00675	1,710	0,294
CI	15 – 20	0,391	0,000*	0,01510	1,399	1,00	0,00085	13,966	0,328
	35 – 40	0,398	0,000*	0,03280	3,234	1,00	0,00319	1,243	0,928
	55 – 60	0,417	0,000*	0,03190	2,759	1,00	0,00194	1,297	0,941
	70 – 75	0,420	0,000*	0,01080	1,840	0,67	0,00111	1,219	0,853
CII	15 – 20	0,376	0,000*	0,01300	1,191	0,67	0,00111	1,360	0,567
	35 – 40	0,379	0,000*	0,00098	6,329	3,00	0,01560	1,132	0,847
	55 – 60	0,456	0,000*	0,05420	1,696	8,33	0,00106	1,348	0,847
	70 – 75	0,441	0,000*	0,00081	1,291	4,33	0,02700	1,506	0,173
CIII	15 – 20	0,395	0,000*	0,00083	15,000	0,50	0,00624	1,276	0,829
	35 – 40	0,381	0,000*	0,07200	1,010	2,00	0,00321	1,253	0,952
	55 – 60	0,419	0,000*	0,00257	1,214	1,33	0,01220	1,719	0,213
	70 – 75	0,432	0,000*	0,01570	1,932	0,67	0,00113	1,230	0,872

Napomena: *pretpostavka modela

Tablica 4.2.1.3. Ukupna poroznost i gustoća tla procijenjeni u HYPROP-FIT programu na dubinama 15 – 20, 35 – 40, 55 – 60 i 70 – 75 cm na vrhu (A), sredini (B) i dnu (C) padine.

Pozicija na padini	Dubina [cm]	Ukupna poroznost [%]	Gustoća tla [g cm^{-3}]
AI	15 – 20	42	1,52
	35 – 40	42	1,54
	55 – 60	40	1,59
	70 – 75	38	1,63
AII	15 – 20	45	1,48
	35 – 40	43	1,51
	55 – 60	35	1,71
	70 – 75	41	1,56
AIII	15 – 20	47	1,42
	35 – 40	43	1,50
	55 – 60	36	1,71
	70 – 75	38	1,65
BI	15 – 20	39	1,61
	35 – 40	41	1,56
	55 – 60	36	1,70
	70 – 75	34	1,75
BII	15 – 20	40	1,59
	35 – 40	41	1,55
	55 – 60	41	1,58
	70 – 75	36	1,69
BIII	15 – 20	40	1,60
	35 – 40	43	1,51
	55 – 60	37	1,68
	70 – 75	34	1,75
CI	15 – 20	45	1,46
	35 – 40	44	1,50
	55 – 60	42	1,53
	70 – 75	43	1,51
CII	15 – 20	42	1,54
	35 – 40	42	1,54
	55 – 60	46	1,45
	70 – 75	45	1,47
CIII	15 – 20	42	1,53
	35 – 40	40	1,58
	55 – 60	44	1,49
	70 – 75	44	1,48

4.3. Određivanje toka vode primjenom trasera na neporušenim kolonama tla

4.3.1. Procjena hidrauličkih svojstava tla

Hidraulička svojstva tla (Tablica 4.3.1.1.) i retencijske krivulje (Slika 4.3.1.1.) procijenjene su u HYPROP-FIT programu na dodatnim neporušenim uzorcima tla uzetim na dubini 12 – 17 cm što odgovara sredini uzorkovanih kolona s neporušenim tlom. Pouzdanost modela potvrđena je sličnim vrijednostima svih replikacija. Sadržaj vode u tlu pri saturiranim uvjetima kretao se između 0,457 (sredina padine) i 0,511 $cm^3\ cm^{-3}$ (dno padine). Ukupna poroznost također je bila najviša na dnu padine te je iznosila 54%, a najniža na sredini gdje je iznosila 47%. Posljedično je najmanja hidraulička vodljivost procijenjena na sredini padine te je iznosila 2,7 cm dan^{-1}, dok je na dnu padine bila znatno veća te je iznosila 187,7 cm dan^{-1}. *RMSE_θ* je iznosio 0,0192 za vrh padine, 0,0111 na sredini te 0,0113 na dnu padine, dok je *RMSE_K* iznosio 0,4300 na vrhu, 0,5094 na sredini te 0,3765 na dnu padine.

Tablica 4.3.1.1. Procijenjene hidrauličke karakteristike tla na vrhu (A), sredini (B) i dnu (C) padine koristeći HYPROP-FIT (van Genuchten bimodal).

Pozicija na padini	θ_s [$cm^3\ cm^{-3}$]	θ_r [$cm^3\ cm^{-3}$]	α_1 [cm^{-1}]	n1 [-]	KSAT [cm dan^{-1}]	α_2 [cm^{-1}]	n2 [-]	w [-]	Ukupna poroznost [%]
A	0,506	0,000	0,00387	1,246	24,3	0,1233	2,052	0,161	51
B	0,457	0,000	0,0199	1,264	2,7	0,0008	1,399	0,514	47
C	0,511	0,000	0,0025	1,279	187,7	0,1519	1,501	0,299	54

θ_s – sadržaj vode u saturiranim uvjetima; θ_r - rezidualni sadržaj vode; α i *n* – parametri krivulje; KSAT – hidraulička vodljivost

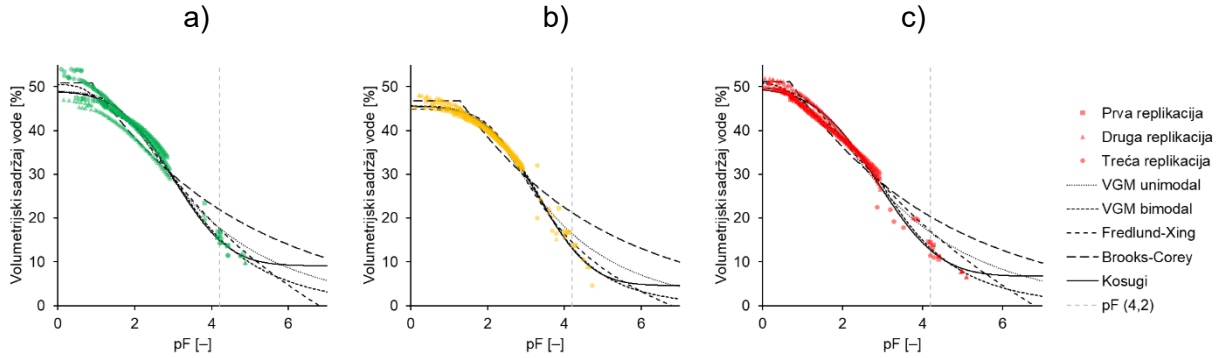

Slika 4.3.1.1. Retencijske krivulje tla određene u HYPROP-FIT programu koristeći VGM model za vrh (a), sredinu (b) i dno (c) padine.

4.3.2. Mjerenje toka vode upotrebom senzora i tenziometara

Senzor za mjerenje volumetrijskog sadržaja vode (EC-5) kao i tenziometar (T5X) pokazali su promjene ubrzo nakon svakog navodnjavanja tijekom trajanja eksperimenta. Slika 4.3.2.1. prikazuje promjene sadržaja vode u tlu tijekom procesa sušenja i vlaženja, dok Slika 4.3.2.2. prikazuje razlike u matričnom potencijalu. Aplicirana kišnica najbrže se procijedila kroz kolone uzete na dnu padine, a najsporije na kolonama sa sredine padine koje su bile najvlažnije te je duže trajalo procjeđivanje. Tijekom trajanja eksperimenta (u periodu od 16 dana), tenziometri su prosječno izmjerili najviše vrijednosti matričnog potencijala u kolonama sa sredine padine (3,4 hPa), a najmanje na kolonama s dna (-1,5 hPa), dok je u kolonama s vrha padine prosječno izmjereno 0,6 hPa. Isti rezultati izmjereni su i senzorima za mjerenje volumetrijskog sadržaja vlage, odnosno prosječno najviše vrijednosti su bile u kolonama sa sredine padine (0,46 m^3 m^{-3}), a najniže na dnu padine (0,39 m^3 m^{-3}).

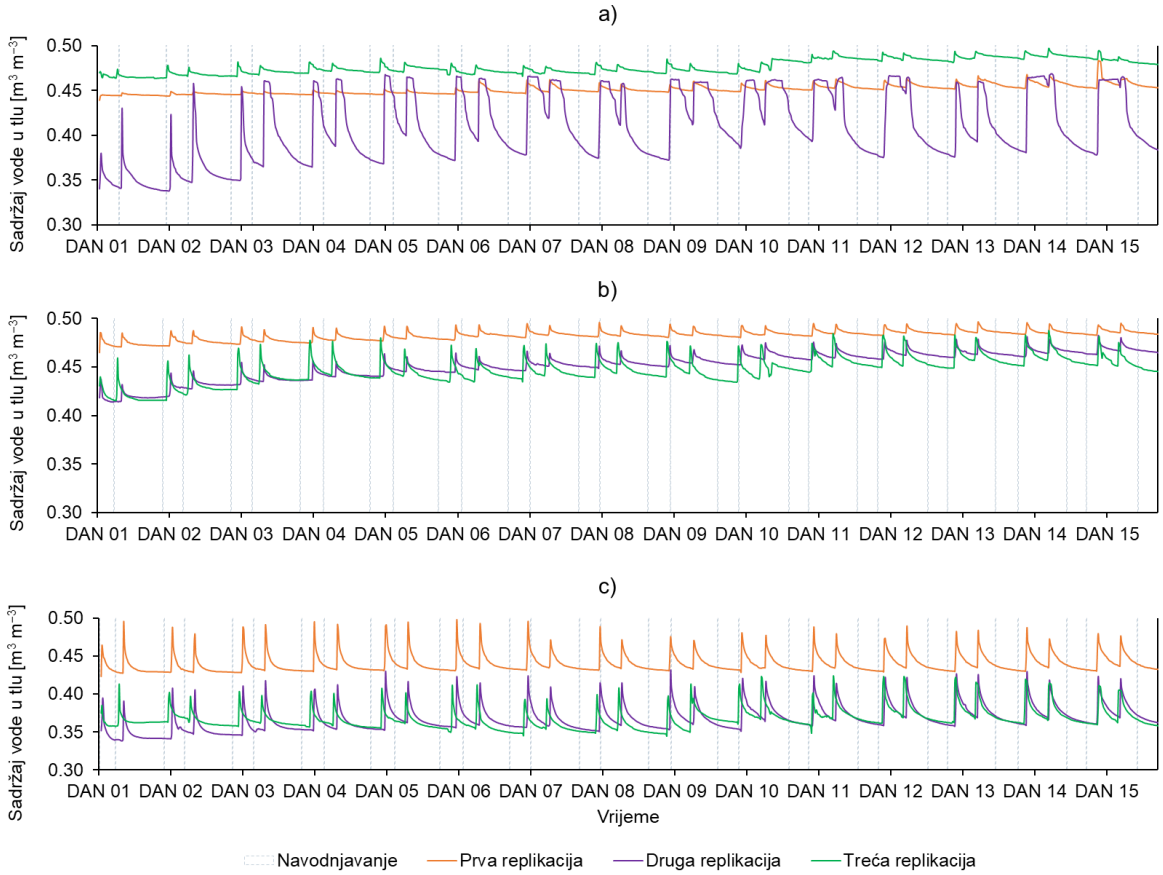

Slika 4.3.2.1. Promjene u sadržaju vode u tlu između dva navodnjavanja (250 mL kišnice) izmjerene senzorima postavljenim na 7 cm dubine unutar kolona s neporušenim tlom na (a) vrhu, (b) sredini i (c) dnu padine.

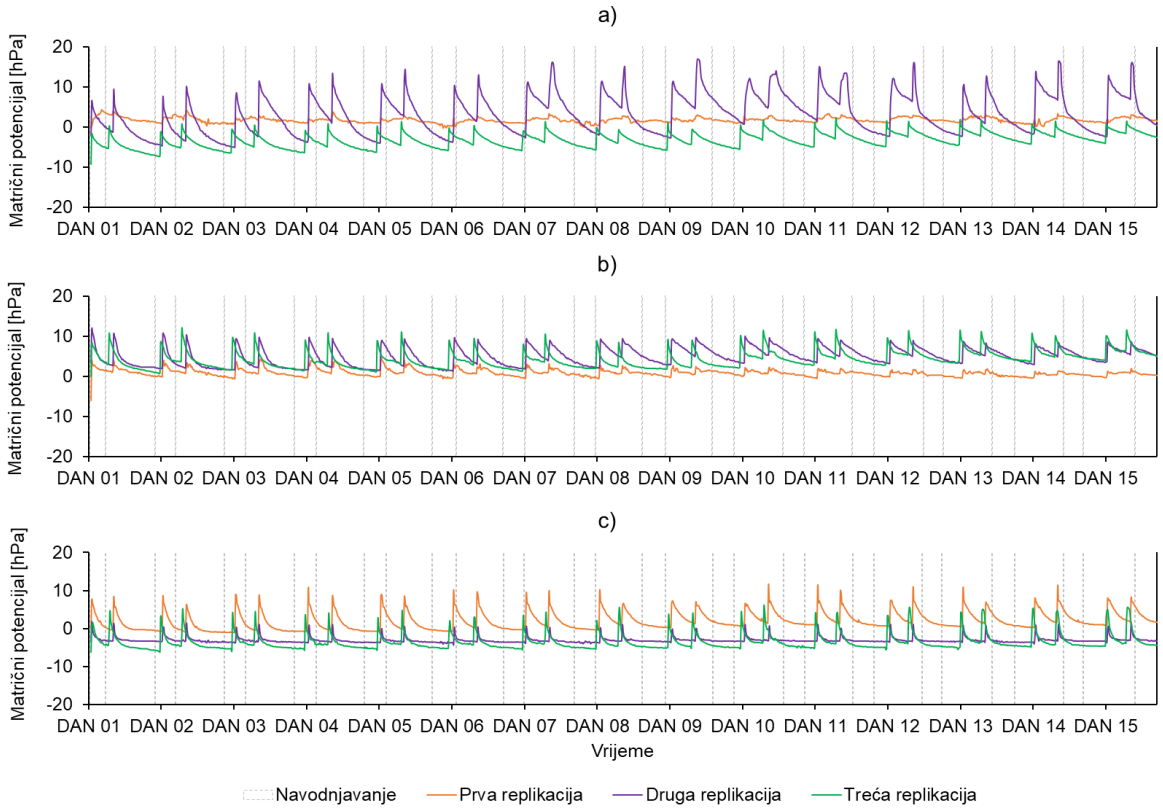

Slika 4.3.2.2. Promjene u matričnom potencijalu između dva navodnjavanja (250 mL kišnice) izmjerene tenziometrima postavljenim na 17 cm dubine unutar kolona s neporušenim tlom na (a) vrhu, (b) sredini i (c) dnu padine.

4.3.3. Procjena dinamike toka vode upotrebom bromida

Prikupljeni procijeđeni uzorci vode statistički su obrađeni te je osim procjeđenog volumena utvrđena i koncentracija i masa bromida koji su isprani iz svake kolone. Tablica 4.3.3.1. prikazuje utjecaj pozicije na padini na izmjerene vrijednosti. Pozicija na padini gdje su se uzimali neporušeni uzorci tla nisu utjecali na procijeđeni volumen te su srednje vrijednosti gotovo jednake na svim pozicijama (224,00 mL na vrhu, odnosno 225,00 mL na sredini i dnu padine). Koncentracija bromida se također nije signifikantno razlikovala s obzirom na poziciju na padini te se kretala od 22,49 mg L^{-1} (sredina padine) do 39,37 mg L^{-1} (vrh padine). Međutim, na masu bromida koja je isprana iz svake kolone utjecao je položaj na padini te su utvrđene signifikantne razlike između sve tri pozicije. Tako je na vrhu utvrđena najmanja masa, odnosno 0,21 mg, na sredini 4,01 mg i na dnu 6,59 mg bromida.

Tablica 4.3.3.1. Utjecaj pozicije na padini na procijeđeni volumen, koncentraciju i masu bromida ispranu iz kolona s neporušenim tlom. Slova *a*, *b* i *c* označuju signifikantnu razliku između pozicija na padini.

Pozicija na padini	Procijeđeni volumen [mL]	Koncentracija bromida [mg L^{-1}]	Masa bromida [mg]
Vrh	224,00 a	39,37 a	0,21 c
Sredina	225,00 a	22,49 a	4,01 b
Dno	225,00 a	31,20 a	6,59 a

Odnos isprane koncentracije bromida u odnosu na procijeđeni volumen prikazan je na Slici 4.3.3.1. Vidljivo je da je većina apliciranih bromida isprana u prvih nekoliko uzoraka u kolonama uzetih s vrha i sredine padine dok su promjene u ispiranju bromida manje vidljive na kolonama s dna padine te je ispiranje bromida bilo ujednačenije. Također, koncentracija ispranih bromida u prvim uzorcima s vrha i sredine padine bile su više od koncentracija bromida koji su isprani iz kolona s dna padine (Slika 4.3.3.1.).

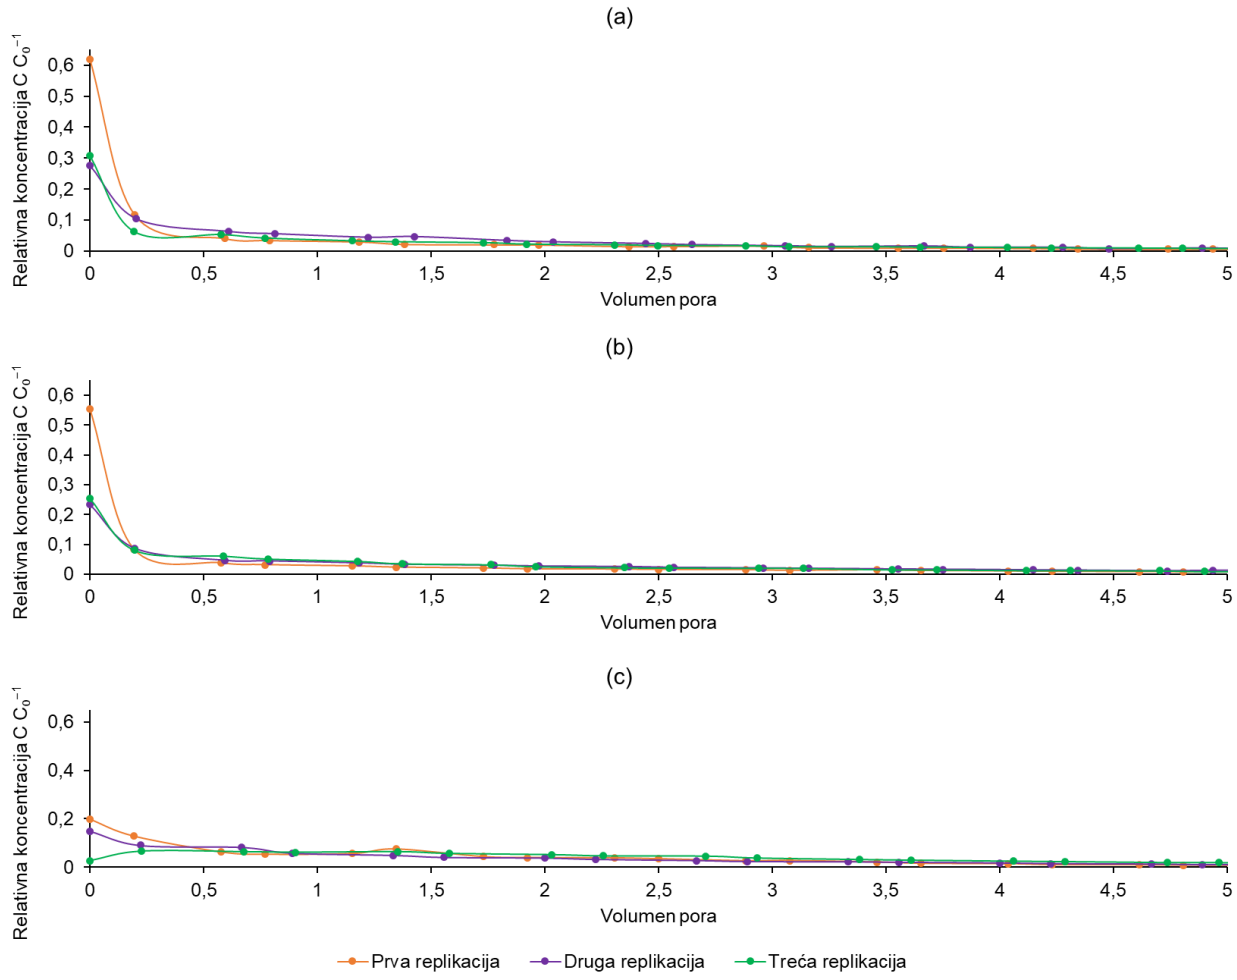

Slika 4.3.3.3. Prikaz odnosa relativne koncentracije bromida isprane iz kolona s neporušenim tlom i procijeđenim volumenom na vrhu (a), sredini (b) i dnu padine (c) uzete u tri replikacije.

4.3.4. Identifikacija i kvantifikacija preferencijalnog toka upotrebom briljantno plavog bojila

Nakon provedenih eksperimenata s otopinom KBr-a, na iste kolone se apliciralo briljantno plavo bojilo kako bi se utvrdili preferencijalni tokovi. Slike 4.3.4.1. – 4.3.4.9. prikazuju fotografije poprečnih presjeka nakon što se bojilo procijedilo (lijevo) te crno-bijele fotografije nakon obrade originalnih fotografija u programu *ImageJ* (desno) za vrh (Slike 4.3.4.1. – .3.4.3.), sredinu (Slike 4.3.4.4. – 4.3.4.6.) i dno (Slike 4.3.4.7. – 4.3.4.9.) padine. Tablica 4.3.4.1. prikazuje udio obojenja nakon obrade u *ImageJ* programu. Sveukupno se udio obojenja na vrhu padine kretao između 20,82 i 37,57%, na sredini između 18,63 i 37,81% i na dnu padine između 15,69 i 69,48%.

Tablica 4.3.4.1. Udio obojenja tla nakon aplikacije briljantno plavog bojila i obrade fotografija na tri replikacije kolona s neporušenim tlom uzorkovanih na vrhu, sredini i dnu padine.

Broj presjeka	Obojena površina [%]								
	Vrh			Sredina			Dno		
	1	2	3	1	2	3	1	2	3
1a	30,83	33,39	33,24	19,69	26,86	34,64	22,67	35,41	65,67
1b	26,71	34,44	37,57	18,63	26,98	36,18	24,40	32,02	54,43
2a	20,84	25,13	31,89	21,69	22,68	37,81	17,47	32,29	58,64
2b	20,82	27,66	36,22	28,13	27,45	30,79	18,37	28,27	69,48
3a	24,89	29,22	36,02	18,65	26,49	30,83	15,69	33,04	52,64
3b	33,52	28,51	35,70	35,43	27,97	33,46	17,62	38,34	59,89

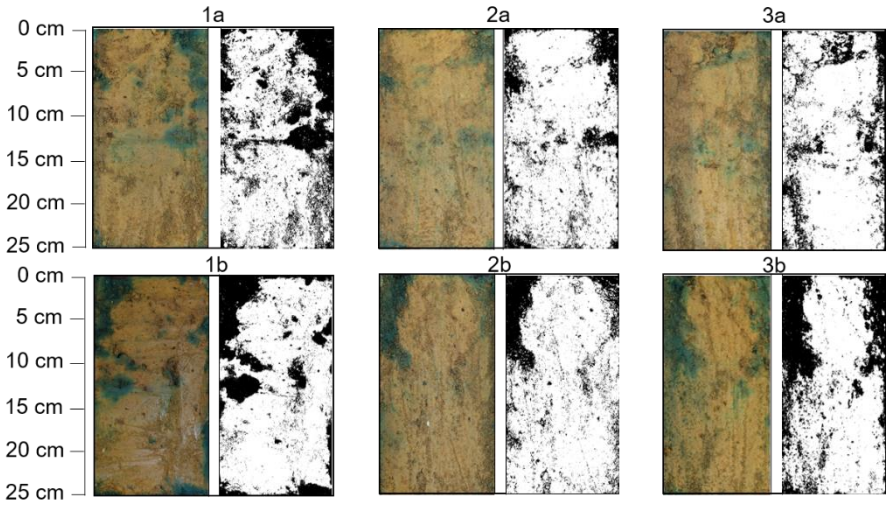

Slika 4.3.4.1. Fotografije poprečnih presjeka uzorkovanih kolona (lijevo) i crno-bijelih fotografija nakon obrade u *ImageJ* programu (desno) na prvoj replikaciji na vrhu padine. Slovo *a* predstavlja desnu polovicu kolone tla, a slovo *b* lijevu polovicu kolone. Brojevi 1, 2 i 3 predstavljaju poprečni presjek.

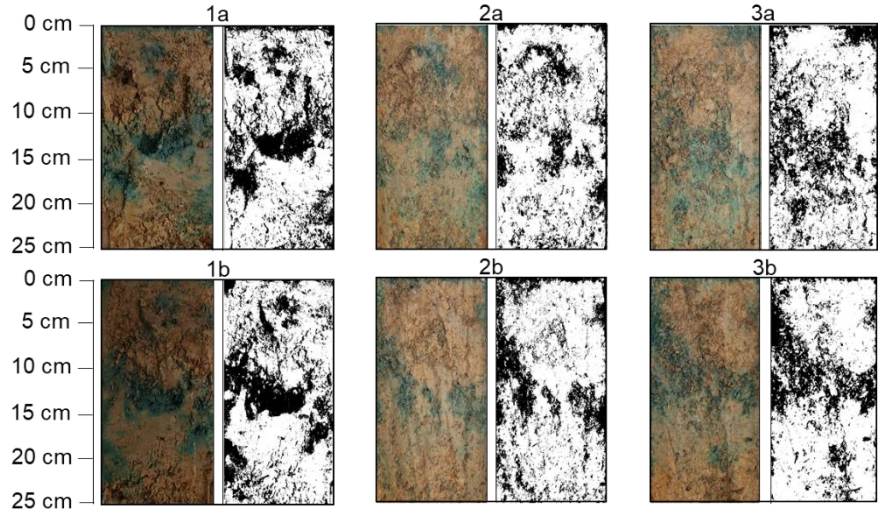

Slika 4.3.4.2. Fotografije poprečnih presjeka uzorkovanih kolona (lijevo) i crno-bijelih fotografija nakon obrade u *ImageJ* programu (desno) na drugoj replikaciji na vrhu padine. Slovo *a* predstavlja desnu polovicu kolone tla, a slovo *b* lijevu polovicu kolone. Brojevi 1, 2 i 3 predstavljaju poprečni presjek.

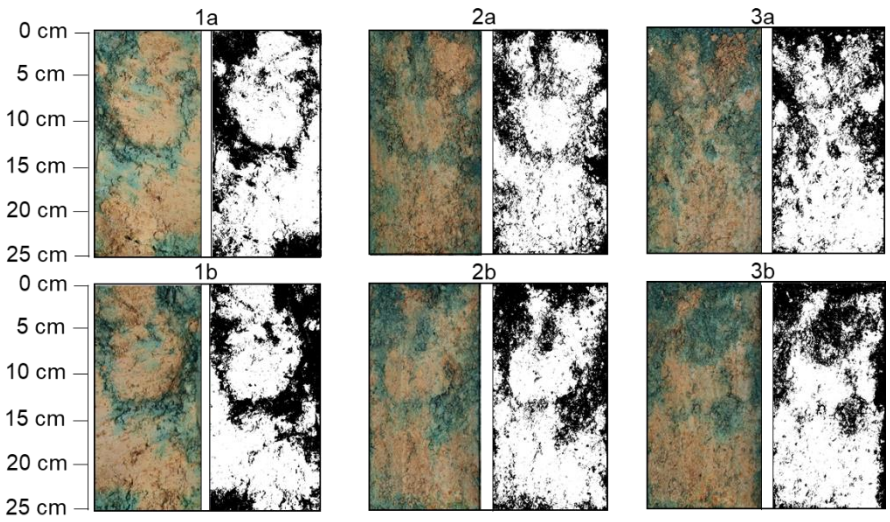

Slika 4.3.4.3. Fotografije poprečnih presjeka uzorkovanih kolona (lijevo) i crno-bijelih fotografija nakon obrade u *ImageJ* programu (desno) na trećoj replikaciji na vrhu padine. Slovo *a* predstavlja desnu polovicu kolone tla, a slovo *b* lijevu polovicu kolone. Brojevi 1, 2 i 3 predstavljaju poprečni presjek.

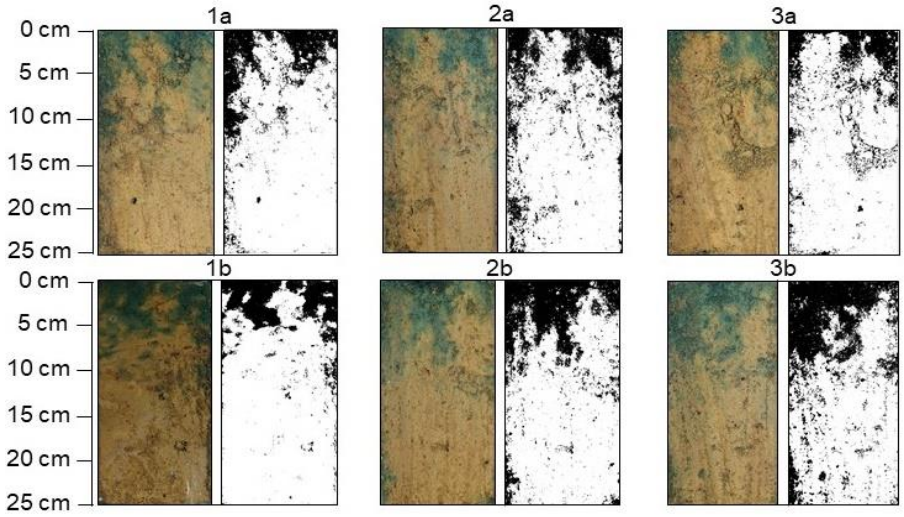

Slika 4.3.4.4. Fotografije poprečnih presjeka uzorkovanih kolona (lijevo) i crno-bijelih fotografija nakon obrade u *ImageJ* programu (desno) na prvoj replikaciji na sredini padine. Slovo *a* predstavlja desnu polovicu kolone tla, a slovo *b* lijevu polovicu kolone. Brojevi 1, 2 i 3 predstavljaju poprečni presjek.

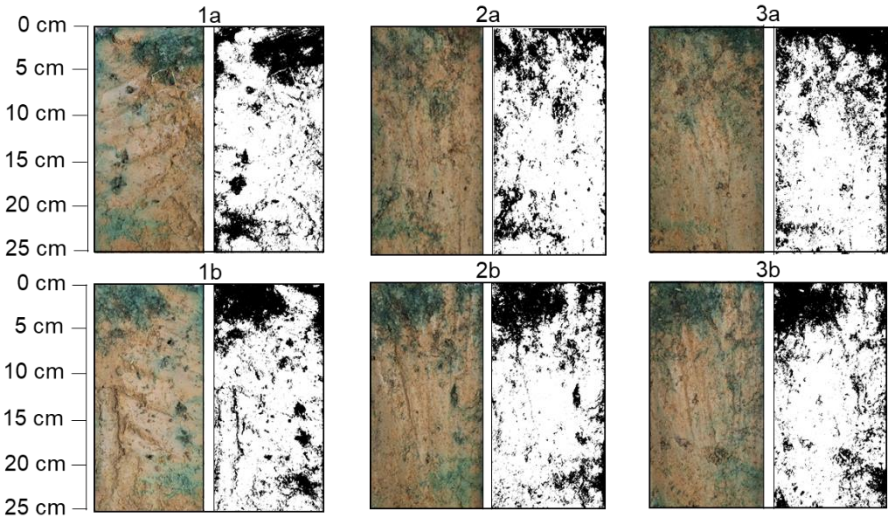

Slika 4.3.4.5. Fotografije poprečnih presjeka uzorkovanih kolona (lijevo) i crno-bijelih fotografija nakon obrade u *ImageJ* programu (desno) na drugoj replikaciji na sredini padine. Slovo *a* predstavlja desnu polovicu kolone tla, a slovo *b* lijevu polovicu kolone. Brojevi 1, 2 i 3 predstavljaju poprečni presjek.

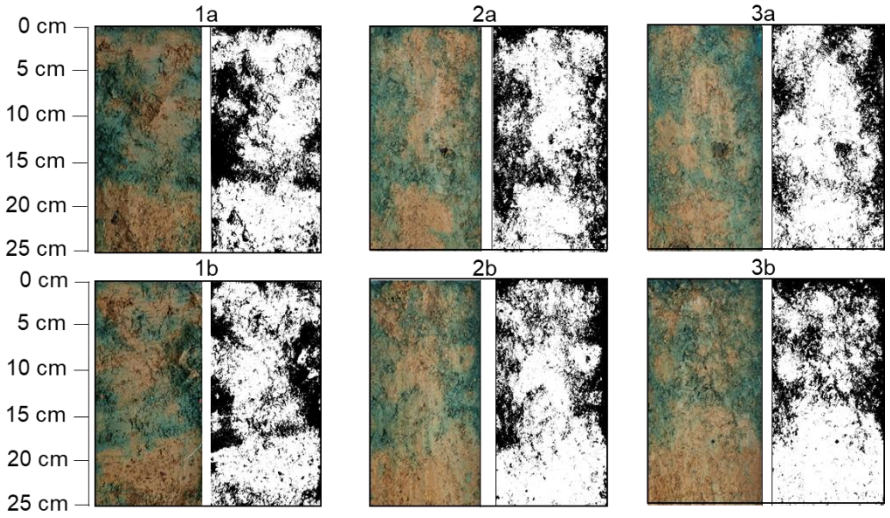

Slika 4.3.4.6. Fotografije poprečnih presjeka uzorkovanih kolona (lijevo) i crno-bijelih fotografija nakon obrade u *ImageJ* programu (desno) na trećoj replikaciji na sredini padine. Slovo *a* predstavlja desnu polovicu kolone tla, a slovo *b* lijevu polovicu kolone. Brojevi 1, 2 i 3 predstavljaju poprečni presjek.

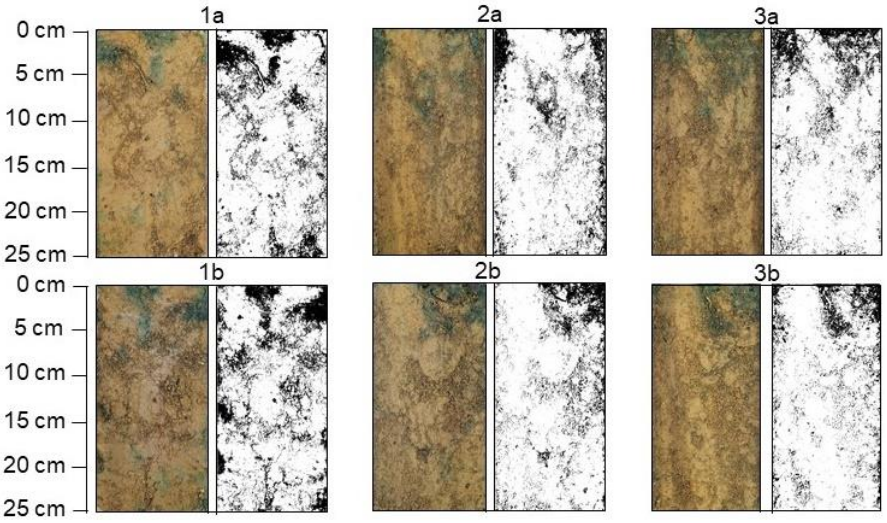

Slika 4.3.4.7. Fotografije poprečnih presjeka uzorkovanih kolona (lijevo) i crno-bijelih fotografija nakon obrade u *ImageJ* programu (desno) na prvoj replikaciji na dnu padine. Slovo *a* predstavlja desnu polovicu kolone tla, a slovo *b* lijevu polovicu kolone. Brojevi 1, 2 i 3 predstavljaju poprečni presjek.

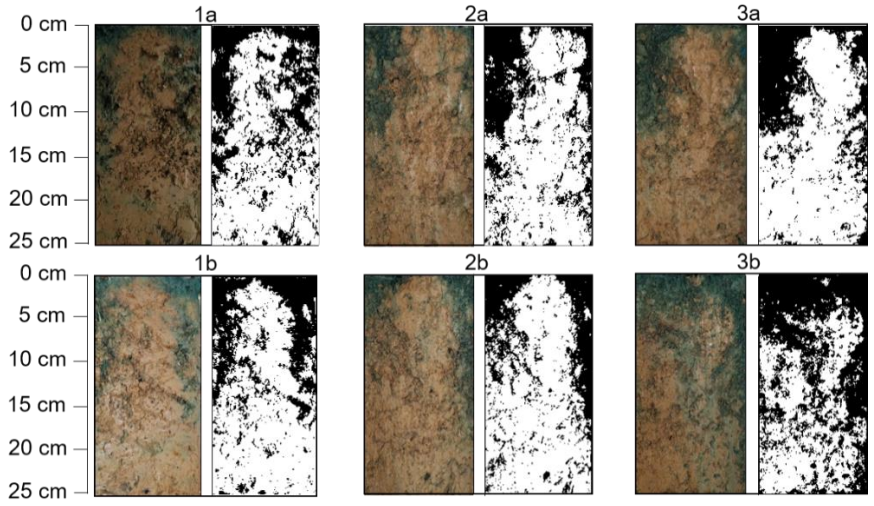

Slika 4.3.4.8. Fotografije poprečnih presjeka uzorkovanih kolona (lijevo) i crno-bijelih fotografija nakon obrade u *ImageJ* programu (desno) na drugoj replikaciji na dnu padine. Slovo *a* predstavlja desnu polovicu kolone tla, a slovo *b* lijevu polovicu kolone. Brojevi 1, 2 i 3 predstavljaju poprečni presjek.

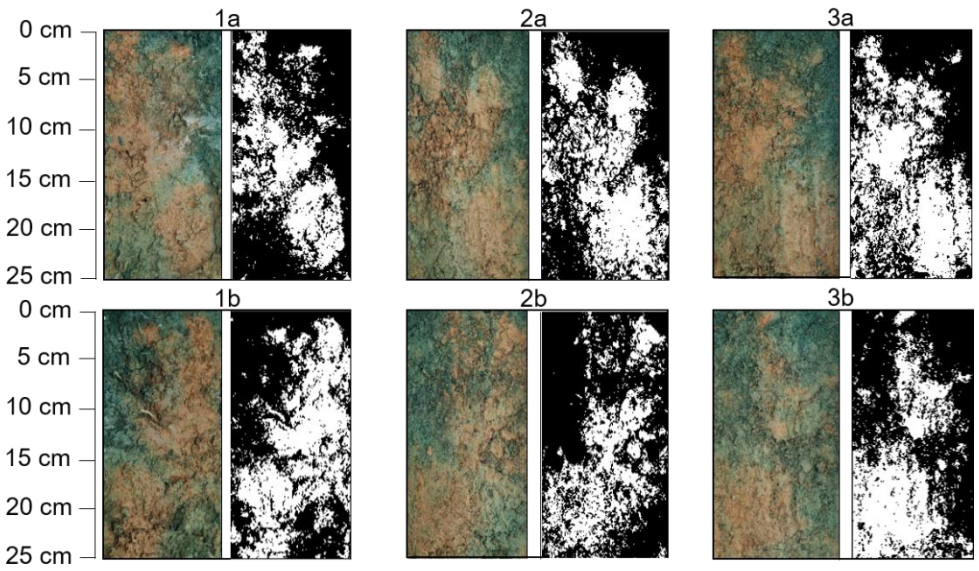

Slika 4.3.4.9. Fotografije poprečnih presjeka uzorkovanih kolona (lijevo) i crno-bijelih fotografija nakon obrade u *ImageJ* programu (desno) na trećoj replikaciji na dnu padine. Slovo *a* predstavlja desnu polovicu kolone tla, a slovo *b* lijevu polovicu kolone. Brojevi 1, 2 i 3 predstavljaju poprečni presjek.

4.4. Numeričko modeliranje

Numeričkim modeliranjem na kolonama s neporušenim tlom pratio se vertikalni tok vode. Slika 4.4.1. prikazuje senzorska mjerenja volumetrijske vlage tla u kolonama uzetim na vrhu (A), sredini (B) i dnu (C) padine. Volumetrijska vlaga tla simulirana je u modelima dvostruke poroznosti i dvostruke propusnosti koristeći HYDRUS-1D. Istek iz kolona s neporušenim tlom simuliran je u modelu dvostruke poroznosti koristeći HYDRUS-1D te su rezultati prikazani na Slici 4.4.2.

Prosječno najveći sadržaj vode u modelu dvostruke poroznosti zabilježen je na vrhu padine, dok su sredina i dno prosječno imali gotovo iste vrijednosti. Nadalje, najmanje vrijednosti sadržaja vode u istom modelu zabilježene su na dnu padine (0,43 m^3 m^{-3}), dok su najviše zabilježene na vrhu padine (0,51 m^3 m^{-3}). Što se tiče modela dvostruke propusnosti, prosječno najveći sadržaj vode zabilježen je također na vrhu padine, a najmanji na sredini padine. Najmanje vrijednosti zabilježene su na sredini padine (0,41 m^3 m^{-3}), a najviše na dnu (0,46 m^3 m^{-3}). Model dvostruke propusnosti općenito je pokazao uniformnije vrijednosti, odnosno procesi vlaženja i sušenja tla između navodnjavanja nisu bili toliko izraženi kao kod modela dvostruke poroznosti, ali i stvarnih mjerenja senzorima. Prema modelu dvostruke poroznosti na sredini padine prosječne vrijednosti volumetrijskog sadržaja vode iznosile su 0,45 cm^3

cm^{-3}. Iste vrijednosti prema ovom modelu bile su i na dnu padine. S druge strane, prema modelu dvostruke propusnosti te vrijednosti su 0,41 cm^3 cm^{-3}, odnosno 0,43 cm^3 cm^{-3}. U svim mjerenjima, model dvostruke poroznosti pokazivao je veće vrijednosti u odnosu na model dvostruke propusnosti. Tako se model dvostruke poroznosti pokazao bolji za više vrijednosti, a model dvostruke propusnosti za niže vrijednosti. Ipak, model dvostruke poroznosti pokazao je veću pouzdanost pri procijeni visokih vrijednosti u usporedbi s modelom dvostruke propusnosti i predviđanjima za niže vrijednosti.

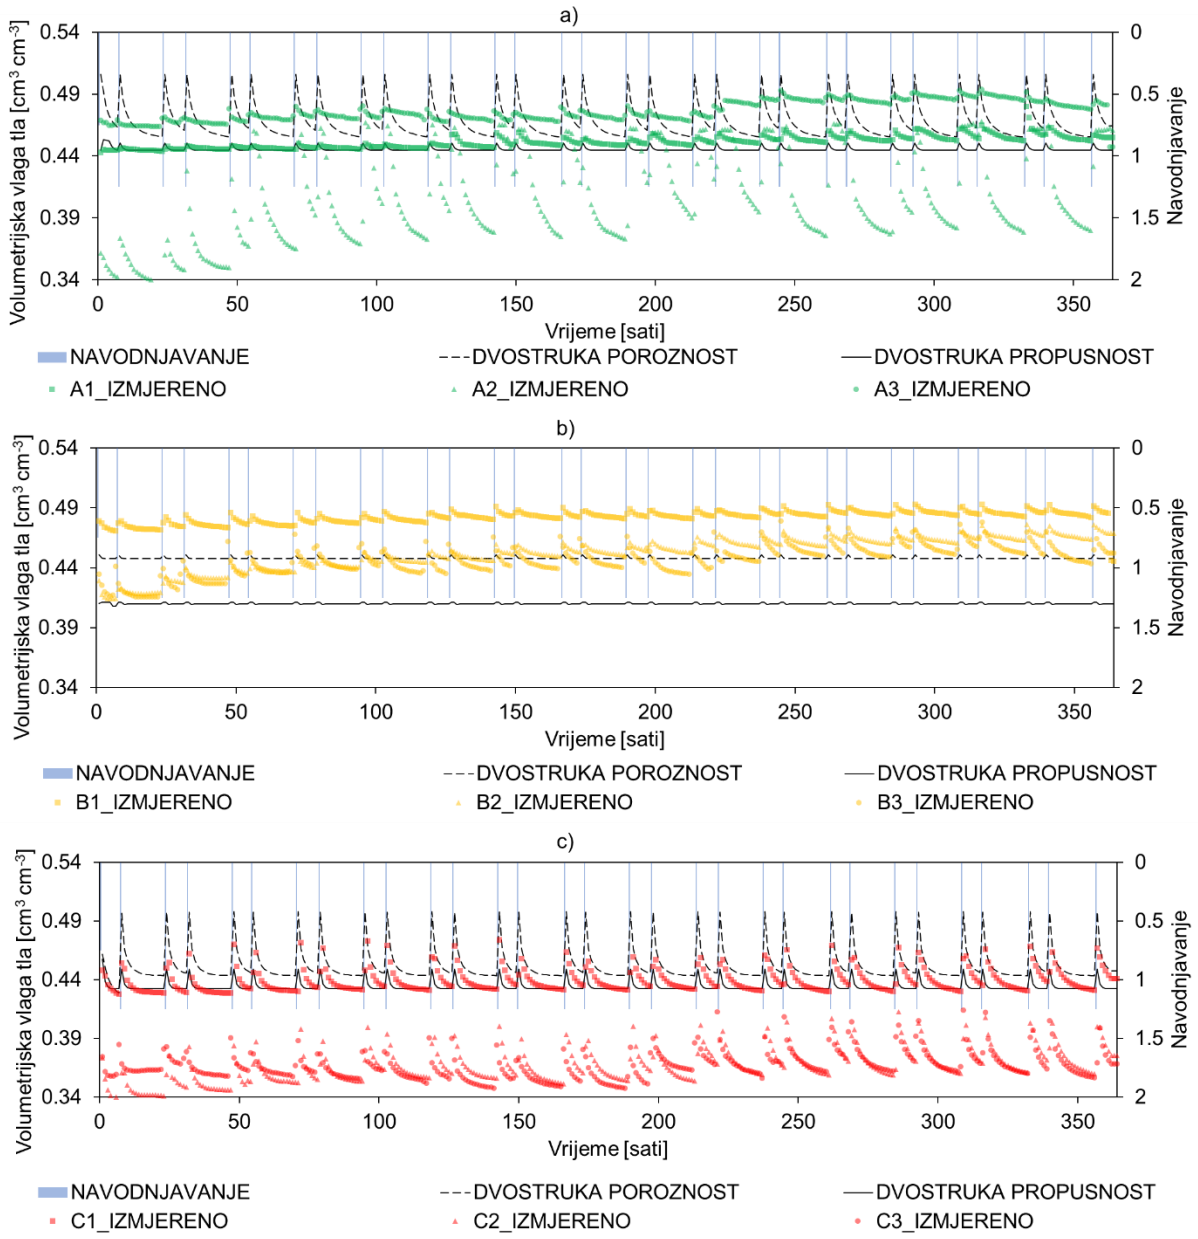

Slika 4.4.1. Prikaz senzorskih mjerenja volumetrijske vlage tla u kolonama s neporušenim tlom uzetih na vrhu (A), sredini (B) i dnu (C) padine te simulirane vrijednosti u modelima dvostruke poroznosti i dvostruke propusnosti koristeći HYDRUS-1D.

Kako bi se dodatno potvrdila pouzdanost modela procijenjen je istek iz kolona s neporušenim tlom koristeći model dvostruke poroznosti te su rezultati prikazani na Slici 4.4.2. Statističke analize pokazale su visoku pouzdanost pri čemu je R^2 za sva mjerenja bio 0,99. *RMSE* se kretao od 1,21 do 2,05 cm na vrhu padine, 1,15 – 1,72 cm na sredini padine, te od 1,06 do 2,35 cm na dnu padine.

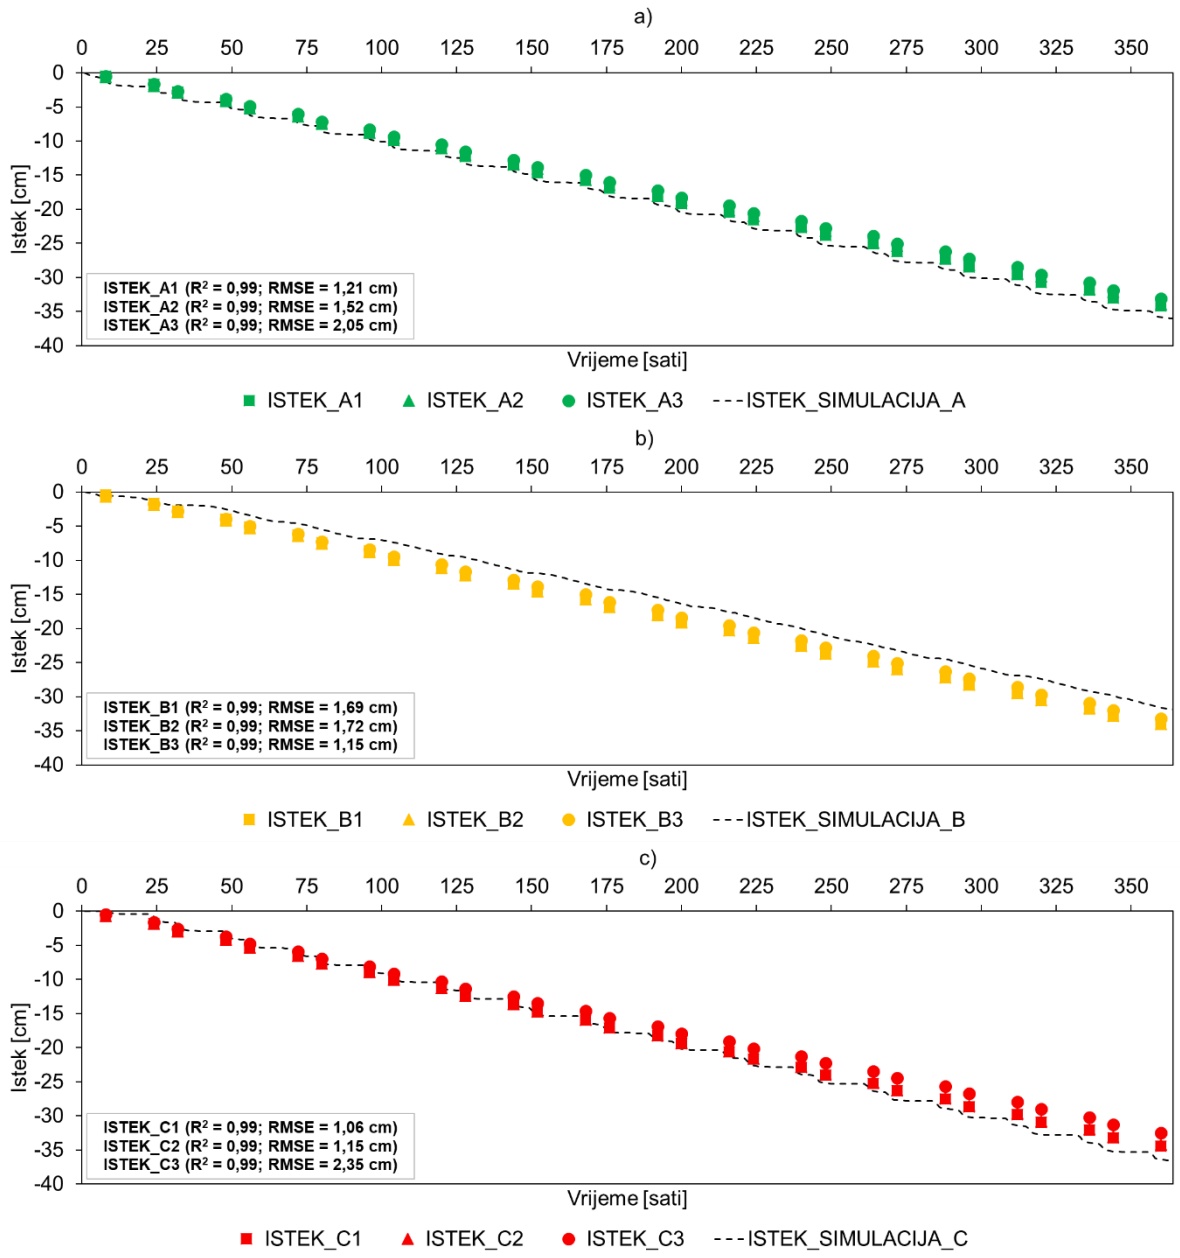

Slika 4.4.2. Prikaz isteka iz kolona s neporušenim tlom s uzetih na vrhu (A), sredini (B) i dnu (C) padine te simulirane vrijednosti u modelu dvostruke poroznosti koristeći HYDRUS-1D.

Slika 4.4.3. prikazuje izmjerene i simulirane vrijednosti volumetrijske vlage tla mjerene senzorima na istraživanoj lokaciji na vrhu (A) i dnu (C) padine za tri različita perioda (sušenje, vlaženje i saturacija) na dubinama od 40 i 80 cm. S obzirom da se radi o 1D modelu, isti se

pokazao boljim u simuliranju toka na kolonama s neporušenim tlom nego na terenskim podacima. Iz Slike 4.4.3. vidljivo je da model najmanju pouzdanost pokazuje pri procjeni toka vode u periodu vlaženja, dok se nešto bolji pokazao u simulacijama sušenja i saturacije. Nadalje, sličan problem se pojavio i na dubini od 80 cm, odnosno najmanja pouzdanost modela u procesu ponovnog vlaženja tla, dok nedostatak modela nije toliko izražen tijekom sušenja i saturacije tla.

Nakon provedenih simulacija za senzore, HYDRUS-1D korišten je kako bi se simulirali isteci iz lizimetara na vrhu, sredini i dnu padine. S obzirom da je model pokazao najlošiju pouzdanost tijekom vlaženja, odnosno u rujnu 2022. godine, navedeni mjesec se uzeo kao početak za modeliranje isteka iz lizimetara. Slika 4.4.4. prikazuje izmjerene i simulirane isteke iz lizimetara u periodu od rujna do prosinca 2022. godine. Nakon provedenog modela, pomoću statističkih parametara R^2 i *RMSE* utvrđena je pouzdanost modela. R^2 vrijednosti uglavnom su bile niske, čak i do 0,34, dok su *RMSE* vrijednosti uglavnom bile visoke (i do 16,60 cm). S obzirom na navedeno, u modelu je provedena optimizacija hidrauličke vodljivosti. Optimiziranim modeliranjem vrijednosti R^2 kretale su se između 0,80 i 0,95. Vrijednosti *RMSE* bile su između 2,85 i 8,90 cm.

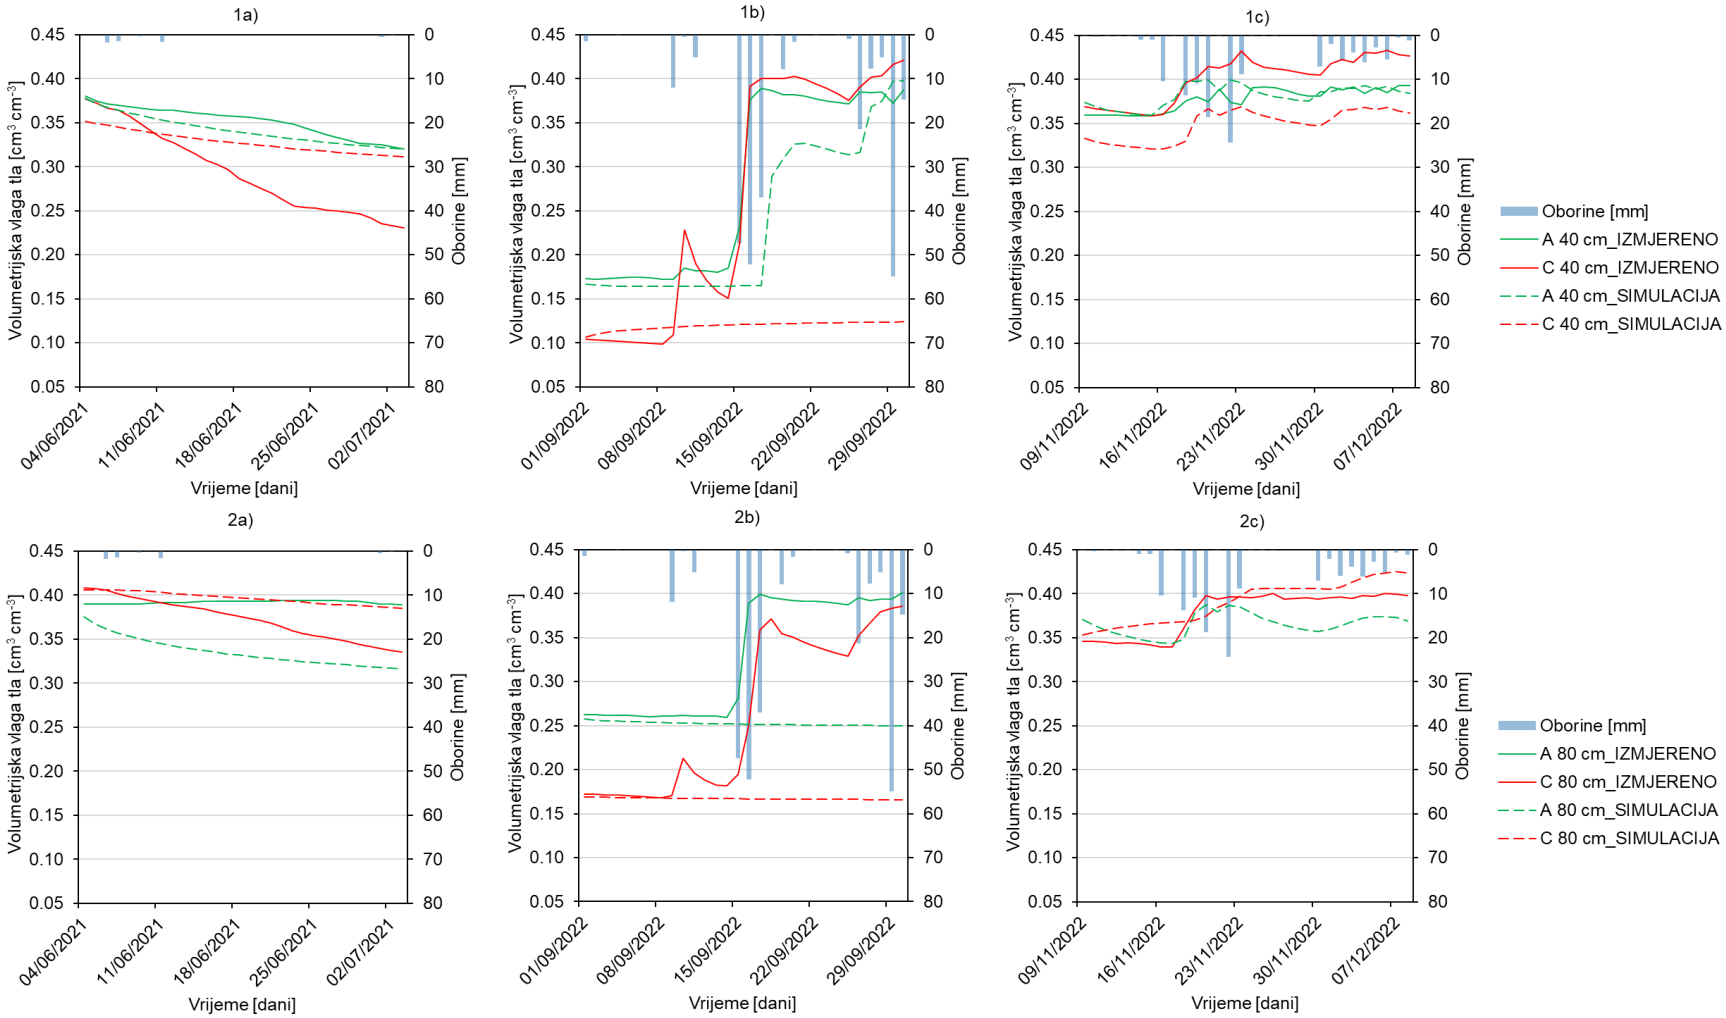

Slika 4.4.3. Prikaz izmjerenih i simuliranih vrijednosti volumetrijske vlage tla mjerene senzorima na istraživanoj lokaciji na vrhu (A) i dnu (C) padine. Oznaka a) označuje period od 04. lipnja do 03. srpnja 2021. (sušenje), b) od 01. rujna do 30. rujna 2022. (vlaženje) i c) od 09. studenog do 08. prosinca 2022. (saturacija). Oznaka 1 se odnosi na senzore postavljene na 40 cm, a oznaka 2 na senzore postavljene na 80 cm dubine.

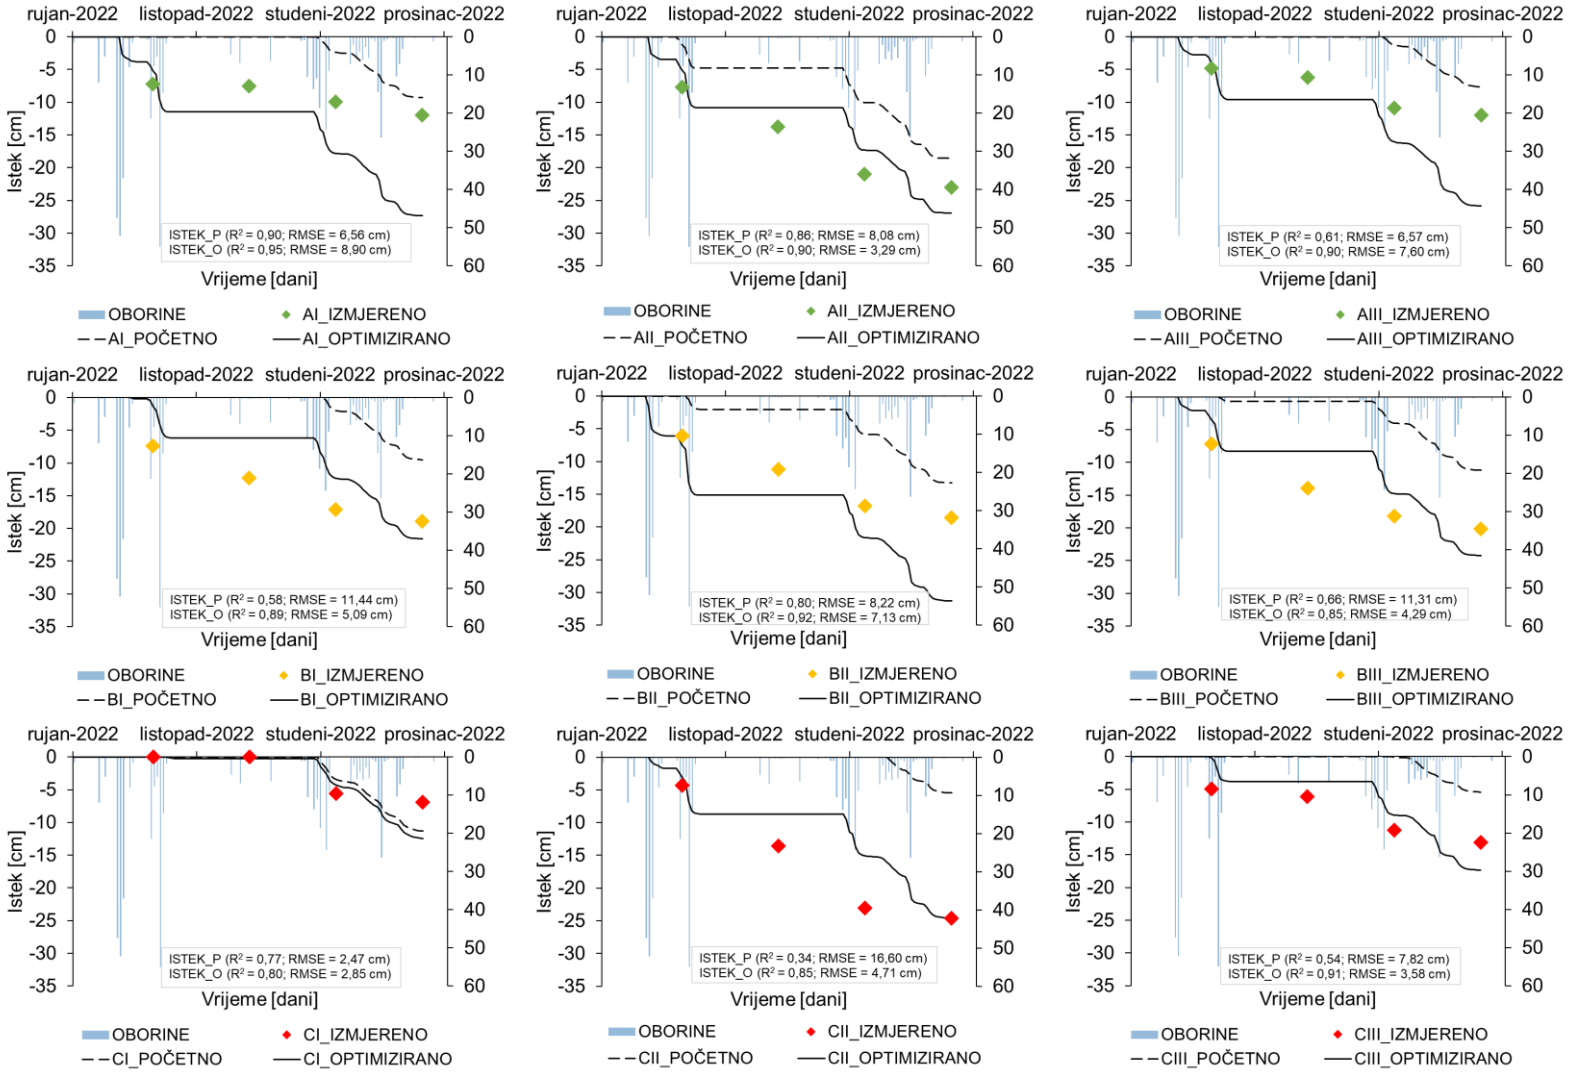

Slika 4.4.4. Prikaz izmjerenih i simuliranih isteka iz nevagajućih tlačnih pasivnih lizimetara koristeći model dvostruke poroznosti i inverzno modeliranje u HYDRUS-1D u periodu rujan – prosinac 2022. godine.

5. RASPRAVA

5.1. Terenska istraživanja

5.1.1. Lizimetarska i senzorska mjerenja

Najmanji prosječni volumen u nevagajućim tlačnim pasivnim lizimetrima uzorkovan je na dnu padine (Slika 4.1.1.1.), dok je najveći uzorkovan na vrhu padine. Iako su takvi rezultati u suprotnosti s većinom prijašnjih istraživanja, slične rezultate navodi i Magdić (2021) koji je također izmjerio veći sadržaj vlage na gornjim pozicijama u istraživanom vinogradu smještenom na padini. Chen i sur. (2021) u svom su istraživanju otkrili da je preferencijalni tok bio izraženiji na vrhu padine u odnosu na dno. Navedeno je u skladu i s rezultatima dobivenim mjerenjem infiltracijske sposobnosti tla (Tablica 4.1.2.1.). Prema tim rezultatima najmanje vrijednosti hidrauličke vodljivosti bile su upravo na dnu padine što je onda i rezultiralo manjim izmjerenim volumenima. S druge strane, na vrhu padine su uglavnom izmjerene najviše vrijednosti tijekom mjerenja infiltracijske sposobnosti tla. Navedeno je u skladu s istraživanjem kojeg su proveli Chen i sur. (2021) čiji su rezultati pokazali da je infiltracija najveća na vrhu padine te se smanjuje prema dnu. Nadalje, na dnu padine je izmjeren statistički značajno veći sadržaj sitnog praha u odnosu na vrh i sredinu padine. Prema Bandini i Sathiskumar (2009) prah smanjuje hidrauličku vodljivost tla što je rezultiralo manjim volumenima procijeđenim u nevagajućim tlačnim pasivnim lizimetrima. Također, prema KSAT mjerenjima na vrhu padine su na dubini 35 – 40 cm izmjerene najviše vrijednosti hidrauličke vodljivosti u usporedbi sa sredinom i dnom padine. Upravo je navedena dubina također i dubina na kojoj su postavljeni lizimetri. Također, na dubini 15 – 20 cm je procjenjena i nešto niža vrijednost gustoće tla u odnosu na sredinu i dno padine što je također utjecalo na procjeđivanje oborina. Izmjereni volumeni vode u nevagajućim tlačnim pasivnim lizimetrima najujednačeniji su na sredini padine što je posljedica najizraženijeg pada terena na toj lokaciji. Uslijed velikog nagiba, i zato najkraćeg vremena u kojem se oborine mogu infiltrirati u tlo, na ovoj je lokaciji najizraženije površinsko otjecanje što je u skladu s drugim istraživanjima (Haggard B.E., Moore Jr. P.A., 2005; Jourgholami i sur., 2021). Kao što je u poglavlju Rezultata spomenuto, u pojedinim mjesecima na replikaciji II DNO javljaju se čak i najviše izmjerene vrijednosti volumena iako su na dnu izmjereni prosječno najmanji volumeni. Prva mjerenja tijekom 2021. godine mogu upućivati na slijeganje tla nakon provedene instalacije svih mjernih instrumenata krajem 2020. godine. Međutim, maksimalne izmjerene vrijednosti javljaju se na ovoj lokaciji i kasnije što upućuje na pojavu preferencijalnih tokova, bilo vertikalnim ili lateralnim putem, u pojedinim uvjetima. Također, u Rezultatima je prikazano da pojedine replikacije (npr. II VRH) najčešće imaju veće vrijednosti od drugih replikacija s iste pozicije na padini što također upućuje na prisutnost preferencijalnog toka. Navedeno se može javiti kao posljedica veće proraštenosti

korijenovog sustava što doprinosi preferencijalnom toku. Spomenuto je i da na poziciji I DNO kroz sedam mjeseci u istraživanom razdoblju nije uopće prikupljen volumen, a u dodatnih devet mjeseci izmjereni volumen je bio manji od 1,0 L. Tijekom mjerenja volumena i prikupljanja uzoraka vode na terenu upravo su uzorci prikupljeni na ovoj lokaciji često bili zamućeni što upućuje na eroziju sitnijih čestica tla dublje u tlo pri čemu može doći do „začepljenja“ poroznog sustava. Iz činjenice da su na replikaciji II DNO u pojednim mjesecima izmjereni čak najviši volumeni, a s druge strane volumeni na replikaciji I DNO kroz gotovo cijelo istraživano razdoblje ili nisu izmjereni ili su te vrijednosti bile vrlo niske vidljive su velike heterogenosti na malom području. Iako se radi o istim pozicijama na padini, volumeni su se u potpunosti razlikovali čime je potvrđena prisutnost preferencijalnih tokova. Nadalje, iz Tablice 4.1.1.1. je vidljivo da je u svim godišnjim dobima tijekom 2021. i 2022. godine najviši prosječni volumen prikupljen na vrhu na drugoj replikaciji (II VRH) što upućuje na preferencijalne tokove na ovoj poziciji. Iz iste Tablice je vidljivo da na poziciji I DNO kroz čak četiri godišnja doba (jesen i ljeto 2021. te proljeće i ljeto 2022.) nije prikupljen volumen u mjernim instrumentima. Tijekom ljeta 2022. godine, uzroci su prikupljeni samo na dvije lokacije iako je prema Slici 4.1.1.14. zabilježena veća količina oborina tijekom ljeta 2022. u usporedbi s ljetom 2021. godine. Međutim, vidljivo je da su razlike u 2022. bile veće što znači da iako je količinski palo više oborina, one su bile nepovoljnije raspoređene, odnosno zabilježen je manji broj oborina, ali većeg intenziteta. S obzirom da je tlo bilo vrlo suho između dva kišna događaja rezultiralo je repelentnošću tla za vodu. Bayad i sur. (2020) navode da se repelentnost tla povećava sušenjem tla. Navedeno je usporilo infiltraciju vode u tlu, te je uz to intenzitet oborina prelazio infiltracijsku sposobnost tla te je većina oborina površinskim putem otjecala u niže dijelove. Navedeno je u skladu s prijašnjim radom Popović i Cerdà (2023) koji navode da repelentnost tla direktno utječe na infiltraciju oborina i površinsko otjecanje i eroziju.

Volumeni prikupljeni u sustavima za površinsko otjecanje pokazali su u pojedinim mjesecima velika odstupanja među redovima, odnosno replikacijama. Iz Slike 4.1.1.3. vidljivo je da II SR najčešće imala najviše prikupljene volumene u sustavima za površinsko otjecanje. Kako je navedeno u poglavlju Rezultata najveće razlike između replikacija vidljive su u siječnju i prosincu 2021. godine. Iz Slike 4.1.1.2. vidljivo je, primjerice, tijekom zime 2021. godine da je na dnu padine najveći volumen iz nevagajućih tlačnih pasivnih lizimetara prikupljen na II DNO. Navedeno je posljedica najviših izmjerenih volumena u sustavima za prikupljanje površinskog otjecanja upravo u tom redu. S druge strane, tijekom istog perioda u sustavima za prikupljanje potpovršinskog procjeđivanja najveći volumeni su prikupljeni na III DNO što jasno upućuje na lateralni potpovršinski preferencijalni tok koji je nastao kao posljedica slabije propusnog horizonta (Wang i sur., 2017). Iz Slike 4.1.1.4. vidljivo je da je tijekom svih godišnjih doba najmanji prosječni volumen izmjeren na prvoj replikaciji, dok je najviši bio na drugoj replikaciji

(osim u jesen 2021. godine gdje je izmjeren zanemarivo niži volumen u odnosu na treću replikaciju). Nadalje, prema Slici 4.1.1.5. vidljivo je da su u sustavima za potpovršinsko procjeđivanje najčešće su prikupljeni najveći volumeni na trećoj replikaciji (III SS) što upućuje da je lateralni preferencijalni tok najjače izražen u tom redu. Također, u periodu ljetnih mjeseci tijekom obje istraživane godine nije izmjeren volumen niti nakon većih oborina što upućuje da su oborine uglavnom otjecale površinskim putem ili se zadržavale na plićim dubinama. Također, iz Slike je vidljivo da su na I SS prikupljeni najmanji volumeni što je posebice izraženo tijekom proljeća i ljeta 2021., te zime i proljeća 2022. godine. Najveće razlike između istraživanih godina po godišnjima dobima zabilježene su tijekom jeseni i zime.

Kako je spomenuto u Rezultatima, na Slici 4.1.1.2. je vidljivo da su na dnu padine prisutne veće oscilacije u sušenju i vlaženju tla u odnosu na vrh padine. Navedeno se, između ostalog, javlja kao posljedica većeg nagiba padine na dnu padine u usporedbi s vrhom što rezultira manjim promjenama u volumetrijskoj vlazi na vrhu padine. Također, na dnu padine na dubini od 80 cm su izmjerene veće vrijednosti volumetrijske vlage tla u odnosu na istu poziciju, ali na 40 cm dubine što upućuje na moguću pojavu lateralnog preferencijalnog toka. Izmjerene vrijednosti vodnog potencijala tijekom ljeta 2022. bile su više na dnu padine što može biti rezultat i nešto viših vrijednosti C_{org} na toj dubini (Védère i sur., 2022). Kao što je spomenuto u Rezultatima, oborine tijekom 19. i 20. rujna 2021. uzrokovale su vlaženje na dnu padine, ali na vrhu padine nisu zabilježene značajnije promjene. Spomenuto navodi na pojavu preferencijalnog toka.

Prisutnost preferencijalnih tokova najpreciznije je zabilježena na BII lokaciji koja je predstavljala mikrolokaciju s gušćom mrežom senzora. Senzori su postavljeni na pet različitih dubina (15, 30, 50, 75 i 100 cm) u profilu tla do dubine 100 cm te je na istoj lokaciji postavljena i meteorološka stanica što omogućuje precizno praćenje svih promjena. Kao što je spomenuto već na početku istraživanog perioda vidljiv je utjecaj preferencijalnog toka u profilu. Tako su tijekom prvih pet mjeseci vrijednosti volumetrijske vlage tla na dubini do 75 cm bile niže u odnosu na 100 cm. Vrijednosti izmjerene senzorima na 75 cm su tijekom gotovo cijelog razdoblja istraživanja bile niže od vrijednosti na 100 cm. Štoviše, tijekom istraživanog razdoblja na dubini od 75 cm najčešće su bila zabilježena odstupanja od ostalih mjerenja, odnosno senzori na toj dubini nisu ili su slabije reagirali nakon oborina čak i kada su senzori na svim drugim dubinama reagirali. Navedeno je u skladu s prijašnjim istraživanjima, npr. Anderson i sur. (2009) i Chen i sur. (2021). Oni upućuju na veliki utjecaj povezanosti pora što omogućuje preferencijalne tokove duž padine. Nadalje, prosječne vrijednosti volumetrijske vlage tla po godišnjim dobima pokazale su gotovo uvijek više vrijednosti na 30 i 100 cm u odnosu na 15 cm. Senzori na dubini od 50 cm su tijekom proljeća i ljeta također pokazivale više vrijednosti nego na 15 cm. S obzirom da je upravo 15 cm najplića dubina na kojoj su

postavljeni senzori vidljiv je i najveći utjecaj evaporacije što rezultira nižim vrijednosti volumetrijske vlage u odnosu na druge dubine u tlu (Or i Lehmann, 2019). Tijekom ljeta 2021. također je zabilježen događaj da iako je promjena u volumetrijskoj vlazi tla bila najveća, vrijednosti vlage tla bile su više na 30 i 50 cm u odnosu na 15 cm. To je također u skladu s prethodnom rečenicom jer će upravo na toj lokaciji najčešće biti zabilježene najveće oscilacije u vrijednostima. Ipak, nakon pojedinih oborina došlo je do ranije reakcije senzora na većim dubinama nego na 15 cm. U pojedinim periodima na najplićim senzorima nije zabilježena promjena ili je ona vrlo mala, dok su dublji senzori reagirali. Navedeno upućuje na prisutnost preferencijalnog toka pri čemu se tok vode odvijao ili vertikalnim putem kroz pukotine u tlu ili lateralnim putem s viših pozicija na padini (Gerke, 2006). Tijekom sušnih perioda najčešće niti tijekom, niti nakon obilnijih oborina nije zabilježena promjena u volumetrijskoj vlazi tla čak ni na 15 cm što upućuje da su sve oborine površinskim putem otjecale u niže dijelove padine. Navedeno se javlja kao posljedica repelentnosti tla za vodu koja se povećava sušenjem tla (Bayad i sur., 2020). Ipak, kada je promjena u senzorima bila zabilježena, najbrži skok u vrijednostima volumetrijske vlage bile su zabilježene na 15 cm, a s porastom dubine poraslo je i vrijeme potrebno za povećanje volumetrijske vlage tla. Tijekom ljetnih mjeseci nerijetko su vrijednosti vlage tla bile i niže od 0,300 m^3 m^{-3} pa čak i oko 0,200 m^3 m^{-3} što predstavlja iznimno suho tlo i drastično smanjuje mogućnost usvajanja vode korijenom i može dovesti do ozbiljnih gubitaka prinosa (Jungk i Claassen, 1997). Osim toga, na tako suhim tlima se javlja i opasnost od narušavanja strukture tla i erozije uslijed udara kišnih kapi (Marzen i Iserloh, 2021; Vaezi i sur., 2017), a kada se tlo ponovno osuši i od stvaranja pokorice tla (Epstein i Grant, 1973; Lázaro i sur., 2023; Yeom i Sjoblom, 2016). U pojedinim uvjetima došlo je do porasta vlage na svim dubinama osim na 75 cm što upućuje na nižu hidrauličku vodljivost na toj dubini koja se može javiti kao rezultat slabije propusnog horizonta. Tok vode se odvija vertikalnim putem do navedene dubine gdje se tok usporava, a promjene u izmjerenim vrijednostima na 100 cm su zabilježene uslijed lateralnog toka s viših pozicija na padini (Gerke, 2006). Također, primjerice tijekom ljeta 2022. godine, vidljivo je da su u pojedinim trenucima senzori reagirali nakon oborina te su vrijednosti vlage tla porasle, međutim te se vrijednosti nisu dugo zadržavale. Najčešće je do pada vlage došlo svega nekoliko sati nakon oborina te su vrijednosti padale i ispod 0,300 m^3 m^{-3}. Općenito su rezultati pokazali da su po godišnjim dobima veći volumeni prikupljeni na svim mjernim instrumentima u jesen 2022. godine te u proljeće i ljeto 2021. godine. Jedino su se razlikovale oborine, a shodno tome i površinsko otjecanje. Uslijed kratkotrajnih, ali vrlo intenzivnih oborina tijekom ljeta 2022. su, kao što je već spomenuto, zabilježene veće vrijednosti u odnosu na ljeto 2021. godine, ali s većim vrijednostima standardne devijacije. Shodno tome, i na sustavima za mjerenje površinskog otjecanja su zabilježeni veći prosječni volumeni u odnosu na ljeto 2021. godine.

5.1.2. Infiltracijska sposobnost tla

Niži podtlak uzrokuje veću vodljivost te se i tok odvija kroz veće pore, dok se pri višim vrijednostima podtlaka dobiva informacija o mikroporama. Navedeno je i vidljivo u dobivenim rezultatima, osim na lokaciji BI gdje je moglo doći do greške u samom mjerenju. Na sredini padine uočene su najveće oscilacije i pri podtlaku od 1 cm i pri podtlaku od 5 cm. Najmanje prosječne vrijednosti su zabilježene na dnu padine što upućuje na najmanju hidrauličku vodljivost što se može javiti kao posljedica statistički značajno višeg sadržaja sitnog praha koji smanjuje hidrauličku vodljivost (Bandini i Sathiskumar, 2009). Rezultati mjerenja infiltracijske sposobnosti tla pokazuju razlike s obzirom na poziciju na padini (A, B i C), ali i na ponavljanja (I, II i III) što upućuje na heterogenost istraživane padine. Zhu i sur. (2023) su također proveli istraživanje na padini i utvrdili heterogenosti u infiltracijskoj sposobnosti tla na različitim pozicijama na padini. Navedeno dokazuje kompleksnost hidrologije padina gdje su i na relativno malim područjima prisutne heterogenosti u hidrauličkim svojstvima tla. Infiltracija će kao prvi korak ulaska vode u tlo direktno utjecati na daljne tokove na istraživanoj padini (Indoria i sur., 2020). Na dnu padine zabilježene su manje varijacije između najnižih i najviših vrijednosti podtlaka. Nadalje, iz rezultata je vidljivo da je pri vrijednostima od 1 cm hidraulička vodljivost najveća te dobivamo informaciju o prisutnosti većih pora u tlu, dok je pri vrijednostima od 5 cm najmanja i prikazuje mikropore (Decagon Devices Inc, 2016).

5.1.3. Određivanje toka vode traserima (briljantno plavo bojilo i kalijev bromid) na terenu

Primjena briljatno plavog bojila za određivanje toka vode na terenu rezultirala je obojenjem tla do dubine od 20 cm, odnosno do dubine na kojoj se razvija glavnina korijena zatravnjene površine (Liu i sur., 2019). Na vrhu padine su zabilježeni najmanji udjeli obojene površine u usporedbi s ostalim pozicijama na padini. Ovdje je obojenje bilo koncentrirano samo u jednom dijelu ukupno fotografirane površine. Na Slici 4.1.3.1. b) jasno je vidljiva promjena u hidrauličkoj vodljivosti te se vidi da bojilo, odnosno tok vode ima oštru granicu toka. Na Slici 4.1.3.1. d) vidljivo je da se tok vode proširio, ali je i dalje prisutna oštra granica gdje je manja vodljivost. Na Slici 4.1.3.1. e) uočeno je obojenje na vrhu i dnu fotografije, ali ga na sredini nije bilo. Navedeno upućuje da je moguća prisutnost pora kojima se kretalo obojenje. Upravo to je i vidljivo na f) fotografiji. Tok vode se kretao u tim porama te se zbog toga obojenje pojavilo na vrhu i dnu fotografije, a zaobišlo je sredinu. Na sredini padine tok vode nije toliko koncentriran na jednom mjestu kao na vrhu padine, ali su i ovdje vidljivi preferencijalni tokovi. Na Slici 4.1.3.2. b) vidljivo je da je obojenje, odnosno tok na samoj površini prisutan cijelom dužinom, a s dubinom se taj tok smanjuje i prevladavaju preferencijalni tokovi. Na e) i g)

fotografijama najmanje je izražena obojenost cijele površine tla, te se preferencijalni tokovi uglavnom javljaju odmah. Što se tiče dna padine, najizraženija promjena u hidrauličkoj vodljivosti vidljiva je na e) fotografiji, dok se na f) fotografiji vidi tok kroz bioporu. Iz Slika 4.1.3.1. – 4.1.3.3. vidljivo je da, iako se radi o površini od 1 m^2, prisutne su velike razlike u toku i na istoj poziciji na padini, ali i između pozicija.

Rezultati prikupljeni aplikacijom bromida upućuju na izraženiji površinski tok. Također, u međurednom prostoru postoji mogućnost zbijanja tla uslijed prolaska mehanizacije što može rezultirati manjim porozitetom (Berisso i sur., 2012; Pagliai, 1992). S obzirom da su bromidi aplicirani neposredno prije sušnog perioda koji je uslijedio, kombinacijom sušenja tla i pojedinih događaja kratkotrajnih oborina visokog intenziteta koji su se javili, dio apliciranih bromida se nije procijedio do mjernih instrumenata nego je površinski otjecalo u niže dijelove padine. Nažalost, kako je spomenuto u Materijalima i metodama, sustavi za mjerenje površinskog otjecanja su ograničeni na prikupljanje vode s površine od 4 m^2 te zbog površinskih granica na istima nije bilo moguće prikupiti uzorke bromida. Iz rezultata je vidljivo da je svibanj bio sušan te su prikupljeni uzroci iz svega tri mjerna instrumenta, tijekom lipnja, srpnja i kolovoza nije prikupljen niti jedan uzorak što upućuje da oborine nisu dospjele do dubine od 40 cm. U jesen kada je ponovno započelo vlaženje tla i kada je bilo uzoraka u svim mjernim instrumentima, vidljivo je da te koncentracije nisu bile visoke što je još jedan znak da se dio bromida isprao površinskim putem. Navedeni rezultati upućuju na potencijalne rizike prilikom aplikacije zaštitnih sredstava i gnojiva. U istim uvjetima došlo bi do gubitka agrokemikalija površinskim tokovima što ima negativne ekološke i ekonomske posljedice (Bell i Koh, 2011; Gonzalez, 2018; Luna Juncal i sur., 2023).

5.2. Laboratorijska istraživanja

5.2.1. Hidraulička svojstva tla

Usporedbom van Genuchtenovog unimodalnog i bimodalnog modela, te Fredlund-Xingovog, Brooks-Coreyevog i Kosugijevog modela statističkim analizama utvrđeno je da je van Genuchtenov bimodalni model najpouzdaniji za istraživanu lokaciju. Prema prijašnjim istraživanjima (Fang i sur., 2023; GHANBARIAN-ALAVIJEH i sur., 2010) upravo je van Genuchtenov model najčešće korišten, a ovisno o heterogenosti i kompleksnosti istraživanog tla može se koristiti unimodalna ili bimodalna verzija. Prema rezultatima dobivenim HYPROP-FIT programom procjenjeno je da su vrijednosti θ_S bile najvarijabilnije na sredini padine što je u skladu s mehaničkim sastavom na ovoj poziciji gdje je utvrđen prosječno najviši udio pijeska u usporedbi s drugim pozicijama. Na sredini padine na prvoj dubini su utvrđene i najviše

vrijednosti gustoće tla što je moglo dodatno pridonijeti površinskom otjecanju (Khaerudin, 2017). Nadalje, iz rezultata prikupljenih na dnu padine na dubini od 55 do 75 cm vidljivo je da su vrijednosti θ_S i ukupne poroznosti bile najviše u usporedbi s vrhom i sredinom padine, dok su vrijednosti gustoće tla bile najniže što može biti posljedica različitih sadržaja C_{org}. Naime, na dnu padine na dubini 60 – 90 cm utvrđene su statistički značajno veće vrijednosti C_{org} u usporedbi s vrhom i dnom padine. Robinson i sur. (2022) navode da sadržaj C_{org} povoljno djeluje na porozitet tla te θ_S. Navedeno upućuje na mogućnost potpovršinskog procjeđivanja što je i vidljivo u volumenima prikupljenim na tim mjernim instrumentima. Iako je na dnu padine prosječno prikupljen najmanji volumen na WL, iz Slike 4.1.1.5. vidljivo je da su volumeni izmjereni u SS bili visoki. Iako su rezultati pokazali da je ukupna poroznost najveća na dnu padine, prosječno izmjereni volumeni na toj poziciji su bili najniži. Određivanjem infiltracijske sposobnosti tla dobiveni su isti rezultati. Ipak, ukupna poroznost tla ne daje informaciju o odnosu mikro- i makropora (Defterdarović i sur., 2021), a navedeni rezultati upućuju da je na ovoj poziciji prisutno više mikropora što je smanjilo hidrauličku vodljivost tla.

5.3. Određivanje toka vode primjenom trasera na neporušenim kolonama tla

5.3.1. Procjena hidrauličkih svojstava tla

Kao što je već navedeno, dno padine ima najveći procjenjeni sadržaj vode u saturiranim uvjetima što može biti posljedica najvećeg sadržaja organskog ugljika (12,4 g kg^{-1}). U ranijim istraživanjima je utvrđen pozitivan utjecaj organskog ugljika na retenciju vode u tlu (Ankenbauer i Loheide, 2017; Kodešová i sur., 2010). Nadalje, erozija tla, sadržaj organskog ugljika (Mashalaba i sur., 2020), ali i bolja povezanost pora mogući su uzročnici razlika u K_s vrijednostima. K_s je vrlo varijabilan duž padine iako ukupna poroznost ne pokazuje takve razlike. Ipak, kao što je već ranije spomenuto, ukupna poroznost ne daje informacije o raspodjeli mikro- i makropora kao ni o povezanosti pora (Defterdarović i sur., 2021) što je vjerojatno uzrokovalo velike razlike u K_s vrijednostima. S obzirom da je na dnu padine prisutan i dublji rahliji horizont (Filipović i sur., 2022; Magdić i sur., 2022), vertikalni tok je izraženiji što može rezultirati i ispiranjem sitnijih čestica u dublje horizonte tla.

5.3.2. Mjerenje toka vode upotrebom senzora i tenziometara

Početni sadržaj vode bio je drugačiji čak i na istim pozicijama na padini te se također razlikovao i od procijenjenog sadržaja vode u saturiranim uvjetima. Takvi rezultati upućuju na

veliku heterogenost tla koja je prisutna i na istim pozicijama na padini, a što posljedično utječe i na tok vode. Također, tijekom provođenja daljnjih pokusa na prvoj replikaciji sa sredine padine utvrđena je veća pora koja se nalazila u blizini senzora što je uzrokovalo veći sadržaj vode tijekom eksperimenta kao i različite početne uvjete u odnosu na drugu i treću replikaciju na istoj lokaciji (Slika 4.3.2.1.b).

Prema mjerenjima senzora i tenziometara kolone s dna padine imaju najveće oscilacije između sušenja i vlaženja tla što je u skladu s hidrauličkim karakteristikama tla. Naime, iz neporušenih uzoraka tla na 12 – 17 cm dubine utvrđeno je da je najviši sadržaj vlage u saturiranim uvjetima procijenjen na dnu padine što je u skladu s drugim istraživanjima (Liu i sur., 2020), te je ta pozicija imala i najvišu hidrauličku vodljivost u saturiranim uvjetima kao i porozitet što je rezultiralo bržim procjeđivanjem aplicirane kišnice i samim time bržim sušenjem kolone i nižim vrijednostima sadržaja vode u tlu. Također, ova lokacija ima niži sadržaj gline što omogućuje veću propusnost te time i manju retenciju vode. U ranijim istraživanjima je utvrđeno da čestice gline imaju pozitivan utjecaj na retenciju vode (Mashalaba i sur., 2020). S druge strane, kolone uzorkovane na sredini padine imale su veći sadržaj vode zbog vrlo niskih vrijednosti hidrauličke vodljivosti u saturiranim uvjetima što je uzrokovalo duže vrijeme koje je bilo potrebno za procjeđivanje aplicirane kišnice kroz kolone tla te samim time i manje izražen proces sušenja tla. Ovo je glavna razlika između kolona i terenskih uvjeta jer bi na padini u uvjetima smanjene hidrauličke vodljivosti došlo do površinskog otjecanja ili lateralnog potpovršinskog preferencijalnog toka što bi utjecalo na tok vode na cijeloj padini.

Iako su kolone s neporušenim tlom uzete na istim lokacijama na padini gdje su postavljeni i drugi mjerni instrumenti, rezultati su različiti. Tako je na terenu izmjeren najmanji prosječni volumen u nevagajućim tlačnim pasivnim lizimetrima na dnu padine dok je u kolonama s tlom na toj poziciji utvrđeno najbrže procijeđivanje aplicirane kišnice. Navedene razlike javile su se kao posljedica nekoliko faktora. Najprije, istraživanja na terenu su provedena u periodu od dvije godine, dok su neporušeni uzorci u kolonama uzorkovani u drugoj godini istraživanja zbog čega je došlo do promjena u hidrauličkim svojstvima tla (Abu-hashim M., Lilienthal H., Schnug E., Kucher D.E., 2022; Kumar i Ojha, 2023; Schwen i sur., 2011). Tako je primjerice utvrđeno da je ukupna poroznost tijekom postavljanja pokusa na dnu padine iznosila 43%, dok je u uzorcima prikupljenim tijekom pokusa s kolonama tla iznosila 54%. Također, prilikom uzorkovanja kolona utvrđena je najmanja volumna gustoća tla kao i najveća hidraulička vodljivost na dnu padine što je doprijenilo bržem procijeđivanju kišnice. Nadalje, pri uzorkovanju neporušenih uzoraka tla tijekom postavljanja pokusa na terenu na dnu je utvrđen θ od 0,387 dok je u uzorcima kolona bio 0,511 $cm^3\ cm^{-3}$. Sve navedeno, kao i različito vrijeme uzorkovanja i lokalne heterogenosti tla doprinijele su različitim rezultatima u terenskim i

laboratorijskim uvjetima. Osim toga, u kolonama s tlom tok vode se odvija isključivo u vertikalnom smjeru dok je na padinskim tlima prisutan lateralni potpovršinski tok i površinsko otjecanje (Filipović i sur., 2018; Magdić i sur., 2022; Zhao i sur., 2020) koji uvelike mogu utjecati na volumene prikupljenog perkolata. Uz to, u stvarnim uvjetima su prisutni i brojni drugi faktori (npr. flora i fauna tla, nagib, obrada tla, mehanizacija) koji utječu na tok vode i povezanost poroznog sustava u tlu.

5.3.3. Procjena dinamike toka vode upotrebom bromida

Utvrđene razlike u ispiranju bromida mogu se javiti kao posljedica erozije tla, a zatim i heterogenosti karakteristika tla koje su ranije utvrđene na istraživanoj lokaciji (Filipović i sur., 2022). Heterogenost tla uzrokovana je erozijom česta na nagnutim terenima te rezultira dubljim rastresitim horizontom na dnu padine u odnosu na vrh. Slabije propusni horizont često se javlja kao posljedica obrade tla na dubini na kojoj se obrađuje (Nisha i sur., 2023). Zbijeni potpovršinski horizont je uslijed erozije tla plići na vrhu padine nego na dnu što će rezultirati lateralnim preferencijalnim tokom na višim pozicijama u vinogradu. Također, dobivene Pc vrijednosti (Tablica 3.1.3.) upućuju na dominantno pločastu strukturu tla što rezultira većim K_s u horizontalnom u odnosu na vertikalni smjer (Beck-Broichsitter i sur., 2020). Posljedica navedenog vidljiva je u dobivenim rezultatima gdje je hidraulička vodljivost najveća na dnu padine uslijed povoljnije strukture tla i povezanosti pora što rezultira izraženijim vertikalnim preferencijalnim tokom i većom masom ispranih bromida. S obzirom da je hidraulička vodljivost niža na vrhu i sredini padine, prvi uzorci na tim lokacijama su bili koncentriraniji zbog dužeg vremena koje je bilo potrebno da se aplicirana voda procijedi. Navedeno je rezultiralo da se većina bromida isprala na početku mjerenja na vrhu i sredini padine. Također, sadržaj vode u kolonama uzetim na vrhu i sredini padine bio je veći nego na dnu padine što je rezultiralo ujednačenijim tokom, odnosno isprekidano navodnjavanje nije bilo toliko izraženo kao na dnu padine. Upravo zbog najveće hidrauličke vodljivosti na dnu padine, tok vode je bio i najbrži što je uzrokovalo najviše srednje vrijednosti mase ispranih bromida. Navedeno je u skladu s prijašnjim istraživanjima gdje su ustanovili da isprekidani tok povećava ispiranje otopljenih tvari u odnosu na ujednačeniji tok (Glæsner i sur., 2018).

Razlike u masi ispranih bromida u kolonama uzetim na dnu padine rezultat su fizikalno-kemijskih i hidrauličkih karakteristika tla (Durner i Flühler, 2005). Na dnu padine utvrđena je najveća poroznost tla kao i hidraulička vodljivost stoga se i aplicirana kišnica najbrže procijeđuje. Međutim, razlika u procijeđenim volumenima aplicirane kišnice između vrha, sredine i dna padine nije vidljiva zbog toga što je vrijeme između dva uzorkovanja bilo dovoljno da se procijedi čak i u kolonama uzetih s vrha i sredine padine koji su imali niže vrijednosti

hidrauličke vodljivosti. Ipak, masa ispranih bromida pokazuje statistički signifikantne razlike ovisno o položaju na padini gdje su uzete kolone s neporušenim tlom. Također, prijašnja istraživanja na navedenoj lokaciji pokazala su slične rezultate, odnosno drugačiji izotopski sastav vode tla i infiltraciju ovisno o poziciji (Kovač i sur., 2022). Nadalje, utvrđeno je da će se na dnu padine više otopljenih tvari isprati na veće dubine što može rezultirati i drugačijom distribucijom oborina duž padine. Na dnu padine se može očekivati više vode koja će dospjeti u tlo direktno precipitacijom ili površinskim i potpovršinskim otjecanjem što može uzrokovati brži transport otopljenih tvari. Uz navedeno, na dnu padine je prisutan i dublji rahliji horizont uslijed erozije tla (Filipović i sur., 2022; Herbrich i sur., 2017) što također uzrokuje veću hidrauličku vodljivost.

5.3.4. Identifikacija i kvantifikacija preferencijalnog toka upotrebom briljantno plavog bojila

Heterogenost rezultata upućuje na razlike čak i na istim pozicijama na padini što znači da postoji i razlika u toku vode. Preferencijalni tok je utvrđen već u prvih nekoliko centimetara gdje je vidljivo da pojedini dijelovi tla nisu ravnomjerno obojani (Slike 4.3.4.1. – 4.3.4.9.), a u pojedinim kolonama utvrđen je i dublje (npr. Slike 4.3.4.2., 4.3.4.3., 4.3.4.5., 4.3.4.6. i 4.3.4.9.). S obzirom da su kolone s neporušenim tlom uzimane u prvom horizontu tla, veliki utjecaj na preferencijalni tok ima korijen biljaka kao i fauna tla (Gerke, 2006; Sander i Gerke, 2009). Korijenje biljaka (u ovom slučaju pretežno trave) uglavnom su prisutni do dubine 15 – 20 cm te utječu na povezanost pora što direktno utječe i na preferencijalne tokove (Vereecken i sur., 2019). Prva i druga replikacija uzorkovana na sredini padine prikazuje slabiju povezanost pora što je i u skladu s niže procijenjenim vrijednostima hidrauličke vodljivosti u saturiranim uvjetima. S druge strane, na dnu padine utvrđena je veća povezanost pora na drugoj te posebice trećoj replikaciji što je uzrokovalo i veće vrijednosti hidrauličke vodljivosti pri saturiranim uvjetima. Nadalje, na prvoj replikaciji na vrhu padine (Slika 4.3.4.1., 1a) vidljiva je promjena u propusnosti što je rezultiralo horizontalnim obojenjem na sredini kolone. Slično obojenje vidljivo je i na Slici 4.3.4.6., odnosno na trećoj replikaciji na sredini padine. Promjena propusnosti tla koja je rezultirala horizontalnim obojenjem u koloni tla upućuje na pojavu preferencijalnog lateralnog toka u prirodnim uvjetima na padini. Nadalje, na Slici 4.3.4.3. koja prikazuje treću replikaciju na vrhu padine vidljiv je utjecaj prisutnosti flore na preferencijalni tok gdje je obojenje jasno pratilo korijen, posebice na 1a, 1b, 2a i 2b. S druge strane, na drugoj replikaciji na sredini padine (Slika 4.3.4.5.) vidljivo je obojenje koje je nastalo kao posljedica aktivnosti faune tla na dubini od 13 do 18 cm. Na nekim kolonama (Slika 4.3.4.3. 3b) i 4.3.4.8.

3b)) utvrđena je eksperimentalna pogreška, odnosno tok uz stijenke kolone iako je aplicirano ljepilo i kvarcni pijesak kako bi se to izbjeglo.

5.4. Numeričko modeliranje

Pri izradi simulacija korištena su hidraulička svojstva tla procjenjena HYPROP i WP4C sustavima. Upotreba navedenih sustava pokazala se pouzdana i u mnogim prijašnjih istraživanjima (Domúnguez-Niño i sur., 2020; Haghverdi i sur., 2018; Singh i Verdi, 2024). U Poglavlju 4.4. prikazani su rezultati numeričkog modeliranja najprije za istraživanja provedena na kolonama s neporušenim tlom. Pri simulacijama senzorskih mjerenja volumetrijske vlage tla na kolonama uzetim na svim pozicijama na padini model dvostruke poroznosti pokazao se statistički pouzdanijim u usporedbi s modelom dvostruke propusnosti. Model dvostruke propusnosti općenito je pokazivao uniformnije vrijednosti, odnosno procesi vlaženja i sušenja tla između navodnjavanja nisu bili toliko izraženi kao kod modela dvostruke poroznosti, ali i stvarnih mjerenja senzorima. Arora i sur. (2012) u svom su istraživanju naveli procjenjenu nesigurnost upotrebom modela dvostruke propusnosti u kolonama s tlom. Iz tog razloga je za daljne simulacije isteka iz kolona korišten model dvostruke poroznosti, a njegovu pouzdanost dokazali su i statistički parametri pri čemu su se vrijednosti *RMSE* kretale između 1,06 i 2,35 cm, dok su vrijednosti R^2 bile 0,99 za sva mjerenja. Prosječno najveće vrijednosti u modelu dvostruke poroznosti za simulacije kolona tla zabilježene su na vrhu padine što je u skladu s procjenjenim hidrauličkim svojstvima tla s obzirom da je θ_S na vrhu padine procjenjen na 0,506 $cm^3\ cm^{-3}$ (Tablica 4.3.1.1.). Ipak, θ_S na dnu padine je čak i veći te iznosi 0,511 $cm^3\ cm^{-3}$. Međutim, izmjerene KSAT vrijednosti su bile vrlo visoke na dnu padine (187,7 cm dan^{-1}) što je rezultiralo bržim procjeđivanjem vode kroz kolonu. Tijekom provedbe pokusa je primijećeno da se aplicirana kišnica na kolonama s dna padine procijedila u vrlo kratkom vremenu, odnosno u periodu kraćem od 15 minuta kolika je bila vremenska rezolucija mjerenja. Navedeno je moglo prouzročiti da senzori ne zabilježe glavninu toka, odnosno sam početak ponovnog vlaženja tla što rezultira nižim izmjerenim vrijednostima volumetrijske vlage tla nego što su one zaista i bile. Nadalje su na rezultatima s istih kolona provedene simulacije isteka te je statističkim analizama potvrđena visoka pouzdanost simulacije i stvarnih mjerenja.

Numeričko modeliranje također je provedeno i na podacima prikupljenim na terenu. Na početku su simulirane izmjerene vrijednosti volumetrijske vlage tla na vrhu i dnu padine gdje su izabrana tri ključna perioda, odnosno proces sušenja tla, ponovnog vlaženja te saturacije. S obzirom da se radi o 1D modelu, isti se pokazao boljim u simuliranju toka na kolonama s neporušenim tlom nego na terenskim podacima. Razlog toga je što su kolone ograničene samo na vertikalni tok, dok se na terenu javljaju i drugi tokovi, posebice na terenima na nagibu.

Iz rezultata je jasno vidljivo da model pokazuje najmanju pouzdanost pri procjeni toka vode u periodu vlaženja što se zapravo javlja zbog ograničenosti 1D modela. Naime, navedeni model ne uzima u obzir izmjerene vrijednosti površinskog otjecanja i/ili potpovršinskih tokova koji se javljaju u stvarnim uvjetima na terenu. U modelu voda ulazi u tlo samo u obliku oborina, dok je u stvarnosti prisutno i površinsko otjecanje i potpovršinsko procjeđivanje koje će rezultirati porastom vlage u senzorima koje u modelu izostaje. Navedeni nedostatak nije toliko izražen u periodima sušenja i saturacije tla, te su simulacije pokazale bolju pouzdanost. Nepouzdanost simulacija je u skladu s prethodnim istraživanjima Krevha i sur. (2023c) koji su na istoj istraživanoj padini utvrdili heterogenost u sadržaju vlage duž padine, a što je posebice bilo naglašeno pri izradi simulacija u periodima ponovnog vlaženja tla. Nadalje, sličan problem se pojavio i na dubini od 80 cm, međutim u ovom slučaju zbog ograničenosti modela nedostaje lateralni doprinos vode koji se javlja u stvarnim uvjetima na terenu. Model je i u ovom slučaju pokazao najmanju podudarnost u uvjetima vlaženja, dok nedostatak modela nije toliko izražen tijekom sušenja i saturacije tla. Nadalje, kao što je navedeno u rezultatima, s obzirom da je utvrđeno da je proces vlaženja tla pokazao najmanju pouzdanost, simulacije isteka iz nevagajućih tlačnih pasivnih lizimetara provedene su od tog događaja. S obzirom da je statističkim analizama utvrđena niža pouzdanost modela, provedena je inverzna optimizacija hidrauličke vodljivosti. Osim u ovakvim slučajevima, inverzno modeliranje nerijetko se koristi i pri procjeni određenih parametara zbog nemogućnosti direktnog određivanja. Tako su primjerice da Silva Júnior i sur. (2013) inverznim modeliranjem odredili saturiranu hidrauličku vodljivost u HYDRUS-1D modelu prema podacima prikupljenim mjerenjem infiltracije tla, a Vogeler i sur. (2019) su koristili inverzno modeliranje kako bi procijenili hidrauličku vodljivost na većim dubinama. S druge strane, inverzna optimizacija hidrauličke vodljivosti može se koristiti i pri modeliranju terenskih uvjeta na lokacijama s kompleksnom hidrologijom gdje su prisutne velike heterogenosti na malim udaljenostima. S obzirom da je tijekom modeliranja korišten HYDURS-1D koji simulira tok vode u jednoj dimenziji bilo je potrebno optimizirati hidrauličku vodljivost da bi isteci bili sličniji onim u stvarnim uvjetima gdje dio vode otječe površinskim i potpovršinskim putem. Nakon optimizacije, model se pokazao pouzdanijim što je u skladu i s prijašnjim istraživanjima (Ali i sur., 2019; Kovač i sur., 2022; Krevh i sur., 2023a; Magdić, 2021). Međutim, Zhao i sur. (2024) upozoravaju na određene ograničenosti 1D modela u procijeni preferencijalnih tokova. Stoga se zaključuje da, iako su korišteni kompleksni modeli za kvantifikaciju neravnotežnih i preferencijalnih tokova u tlu koji su rezultirali statistički pouzdanim simulacijama, dodatan uvid u kompleksnu hidrologiju padine stekao bi se upotrebom HYDRUS 2D/3D modela.

6. ZAKLJUČCI

1. Provedenim istraživanjima utvrđeno je da unimodalne funkcije za procjenu hidrauličkih svojstava tla zaista nisu dovoljno prilagođene heterogenim tlima. S obzirom da su padinska tla posebno zahtjevna u procjeni svojstava tla zbog velike heterogenosti koja se javlja čak i na malim udaljenostima procjena hidrauličkih svojstava zahtjeva kompleksnije modele. Utvrđivanje najpouzdanijeg modela za procjenu hidrauličkih svojstava tla provedena je usporedbom Fredlund-Xingovog, Brooks-Coreyjevog, Kosugijevog i van Genuchtenovog unimodalnog i bimodalnog modela te je statističkim analizama (*RMSE_θ*, *RMSE_K*, *AICc*) utvrđeno da za većinu svojstava upravo kompleksniji van Genuchtenov bimodalni model pokazuje najveću pouzdanost u usporedbi s drugim modelima.

2. Analizom prostornih i vremenskih dinamika vodnog režima tla istraživane padine utvrđene su lokalne heterogenosti i pojavnost preferencijalnih tokova koji su utjecali na hidrologiju cijele padine. Provedenim pokusima i mjerenjima i na terenu i u laboratoriju utvrđene su razlike ne samo ovisno o položaju na padini nego čak i između replikacija na istim pozicijama. Volumeni prikupljeni u nevagajućim tlačnim pasivnim lizimetrima pokazali su razlike ovisno o poziciji na padini, ali su se razlike javile i između replikacija na istim pozicijama što upućuje na pojavnost preferencijalnog toka. Najizraženija takva razlika je zabilježena na dnu padine gdje su u pojedinim mjesecima na jednoj replikaciji zabilježeni maksimalni volumeni u usporedbi sa svim pozicijama na padini, dok su na drugoj replikaciji kroz gotovo cijeli period istraživanja izmjereni najmanji volumeni. Razlike između replikacija pri mjerenju potpovršinskog procjeđivanja su u pojedinim mjesecima bile posebice izražene što upućuje na pojavnost lateralnog preferencijalnog toka, ponovno na malim udaljenostima i istim pozicijama na padini. Senzorska mjerenja volumetrijske vlage tla, ali i vodnog potencijala tla na terenu također pokazuju razlike i između vrha i dna padine i između različitih dubina. Izražene razlike su vidljive i unutar jednog profila tla do 100 cm gdje je više puta utvrđen brži odgovor i veća oscilacija mjerenja senzorima s većih dubina nego s manjih što upućuje i na utjecaj površinskog otjecanja i lateralnog preferencijalnog toka. Primjenom briljantno plavog bojila vizualno su najuočljivije razlike, odnosno preferencijalni tokovi u tlu te su na pojedinim mjestima jasno vidljive promjene u hidrauličkoj vodljivosti koje se očituju promjenom smjera toka vode.

3. Primjenom kompleksnijih numeričkih modela dvostruke poroznosti i dvostruke propusnosti simulirani su tokovi u tlu. Simulacijom volumetrijske vlage tla na kolonama s neporušenim tlom uzorkovanim na vrhu, sredini i dnu padine utvrđena je veća pouzdanost modela dvostruke poroznosti. Modelom dvostruke propusnosti razlike između sušenja i vlaženja između dva navodnjavanja nisu bile izražene kao u modelu dvostruke poroznosti i u stvarnim mjerenjima. Statističkim analizama je utvrđena veća pouzdanost modela dvostruke poroznosti. Ipak, modeliranjem procesa sušenja, vlaženja i saturacije na terenu, navedeni model nije bio pouzdan za simulacije ponovnog vlaženja tla te je bila potrebna optimizacija hidrauličke vodljivosti čime se osigurala veća pouzdanost modela. Međutim, s obzirom da se radi o HYDRUS-1D modelu, simulacije kolona su pokazale veću pouzdanost jer se u njima pratio prvenstveno vertikalni tok vode. S druge strane, na terenu, osim oborina koje određuju dostupnu količinu vode za infiltraciju, javljaju se i lateralni tokovi, evapotranspiracija, te površinsko otjecanje što sve utječe na vodnu bilancu. Stoga bi se na ovakvim lokacijama preporučilo koristiti još kompleksnije modele kao što je na primjer HYDRUS-3D.

7. LITERATURA

(DVWK) D.V. für W. und K. (1995). Teil I: Mechanische Belastbarkeit. U: Gefügestabilität ackerbaulich genutzter Mineralböden, Bonn, Germany, str. 234

Abu-hashim M., Lilienthal H., Schnug E., Kucher D.E. M.E.S. (2022). Tempo-Spatial Variations in Soil Hydraulic Properties under Long-Term Organic Farming. Land 11 (10)

Ahmad T., Pandey A.C., Kumar A., Tirkey A. (2023). Understanding the role of surface runoff in potential flood inundation in the Kashmir valley, Western Himalayas. Phys Chem Earth 131 (October): 1–8. doi:10.1016/j.pce.2023.103423

Akaike H. (1974). A New Look at the Statistical Model Identification. IEEE Trans Automat Contr 19 (6): 716–723. doi:10.1109/TAC.1974.1100705

Ali A., Biggs A.J.W., Šimůnek J., Bennett J.M. (2019). A pH-Based Pedotransfer Function for Scaling Saturated Hydraulic Conductivity Reduction: Improved Estimation of Hydraulic Dynamics in HYDRUS. Vadose Zo J 18 (1). doi:10.2136/vzj2019.07.0072

Anderson A.E., Weiler M., Alila Y., Hudson R.O. (2009). Subsurface flow velocities in a hillslope with lateral preferential flow. Water Resour Res 45 (11). doi:10.1029/2008WR007121

Ankenbauer K.J., Loheide S.P. (2017). The effects of soil organic matter on soil water retention and plant water use in a meadow of the Sierra Nevada, CA. Hydrol Process 31 (4): 891–901. doi:10.1002/hyp.11070

Apollonio C., Petroselli A., Tauro F., Cecconi M., Biscarini C., Zarotti C., Grimaldi S. (2021). Hillslope erosion mitigation: An experimental proof of a nature-based solution. Sustain 13 (11). doi:10.3390/su13116058

Arora B., Mohanty B.P., McGuire J.T. (2012). Uncertainty in dual permeability model parameters for structured soils. Water Resour Res 48 (1): 1–47. doi:10.1029/2011WR010500

Bachmair S., Weiler M. (2012). Hillslope characteristics as controls of subsurface flow variability. Hydrol Earth Syst Sci 16 (10): 3699–3715. doi:10.5194/hess-16-3699-2012

Bandini P., Sathiskumar S. (2009). Effects of Silt Content and Void Ratio on the Saturated Hydraulic Conductivity and Compressibility of Sand-Silt Mixtures. J Geotech Geoenvironmental Eng 135 (12): 1976–1980. doi:10.1061/(asce)gt.1943-5606.0000177

Basset C., Abou Najm M., Ghezzehei T., Hao X., Daccache A. (2023). How does soil

structure affect water infiltration? A meta-data systematic review. Soil Tillage Res 226 (June 2022). doi:10.1016/j.still.2022.105577

Bátková K., Miháliková M., Matula S. (2020). Hydraulic properties of a cultivated soil in temperate continental climate determined by mini disk infiltrometer. Water (Switzerland) 12 (3): 1–21. doi:10.3390/w12030843

Bayad M., Chau H.W., Trolove S., Moir J., Condron L., Bouray M. (2020). The relationship between soil moisture and soil water repellency persistence in hydrophobic soils. Water (Switzerland) 12 (9): 1–12. doi:10.3390/W12092322

Bayad M., Chau H.W., Trolove S., Moir J., Condron L., El Gharous M. (2022). Surface runoff and losses of phosphorus from hydrophobic pastoral soils. Agric Ecosyst Environ 324 (February): 1–8. doi:10.1016/j.agee.2021.107690

Beck-Broichsitter S., Gerke H.H., Leue M., von Jeetze P.J., Horn R. (2020). Anisotropy of unsaturated soil hydraulic properties of eroded Luvisol after conversion to hayfield comparing alfalfa and grass plots. Soil Tillage Res 198 (April 2019): 104553. doi:10.1016/j.still.2019.104553

Bell G.E., Koh K. (2011). Nutrient and Pesticide Losses Caused by Simulated Rainfall and Sprinkler Irrigation. USGA Turfgrass Environ Res Online 10 (2): 1–10

Berisso F.E., Schjønning P., Lamandé M., Weisskopf P., Stettler M., Keller T. (2012). Wheel traffic effect on air-filled porosity and air permeability in a soil catena across the wheel rut. Agrociencia 16 (3): 310–317. doi:10.31285/agro.16.689

Bero N.J., Ruark M.D., Lowery B. (2016). Bromide and chloride tracer application to determine sufficiency of plot size and well depth placement to capture preferential flow and solute leaching. Geoderma 262: 94–100. doi:10.1016/j.geoderma.2015.08.001

Bezerra-Coelho C.R., Zhuang L., Barbosa M.C., Soto M.A., Van Genuchten M.T. (2018). Further tests of the HYPROP evaporation method for estimating the unsaturated soil hydraulic properties. J Hydrol Hydromechanics 66 (2): 161–169. doi:10.1515/johh-2017-0046

Blok C., Baumgarten A., Baas R., Wever G., Lohr D. (2019). Analytical methods used with soilless substrates, Second Edi. Izdanje, Soilless Culture: Theory and Practice Theory and Practice. Elsevier B.V., 509–564 str. doi:10.1016/B978-0-444-63696-6.00011-6

Bogunovic I., Filipovic L., Filipovic V., Kisic I. (2023). Agricultural Soil Degradation in Croatia. Handb Environ Chem 121: 1–34. doi:10.1007/698_2022_919

Bogunovic I., Pereira P., Kisic I., Sajko K., Sraka M. (2018). Tillage management impacts on soil compaction, erosion and crop yield in Stagnosols (Croatia). Catena 160 (January): 376–384. doi:10.1016/j.catena.2017.10.009

Brady N., Weil R. (2016). Nature and Properties of Soils, The 15th Edition. Pearson Educ 375–376

Brindt N., Parlange J.Y., Steenhuis T.S. (2023). Unstable preferential flow in porous media. Encycl Soils Environ Second Ed 5: V5-314-V5-320. doi:10.1016/B978-0-12-822974-3.00160-9

Brooks R.H. C.A.T. (1964). Hydraulic properties of porous media. Hydrol Pap 3: 1–27

Campbell G., Campbell C., Cobos D., Crawford L.B., Rivera L., Chambers C. (2015). Operation Manual for HYPROP

Cárceles Rodríguez B., Durán-Zuazo V.H., Soriano Rodríguez M., García-Tejero I.F., Gálvez Ruiz B., Cuadros Tavira S. (2022). Conservation Agriculture as a Sustainable System for Soil Health: A Review. Soil Syst 6 (4): 1–37. doi:10.3390/soilsystems6040087

Chen C., Zou X., Singh A.K., Zhu X., Zhang W., Yang B., Jiang X., Liu W. (2021). Effects of hillslope position on soil water infiltration and preferential flow in tropical forest in southwest China. J Environ Manage 299 (August): 113672. doi:10.1016/j.jenvman.2021.113672

Chen Y., Song M., Dong M. (2002). Soil properties along a hillslope modified by wind erosion in the Ordos Plateau (semi-arid China). Geoderma 106 (3–4): 331–340. doi:10.1016/S0016-7061(01)00132-X

Cheremisinoff N.P. (1997). Principles of Hydrogeology. Groundw Remediat Treat Technol 85–126. doi:10.1016/b978-081551411-4.50005-3

Coblinski J.A., Favaretto N., Goularte G.D., Dieckow J., Moraes A. de, Souza L.C. de P. (2019). Water, Soil and Nutrients Losses by Runoff at Hillslope Scale in Agricultural and Pasture Production in Southern Brazil. J Agric Sci 11 (6): 160. doi:10.5539/jas.v11n6p160

da Silva Júnior J.J., Colombo A., da Silva E.L., Scalco M.S. (2013). Determination of hydraulic conductivity using the inverse problem of the hydrus-1d software.

Dahlke H.E., Easton Z.M., Lyon S.W., Todd Walter M., Destouni G., Steenhuis T.S. (2012). Dissecting the variable source area concept - Subsurface flow pathways and water

mixing processes in a hillslope. J Hydrol 420–421: 125–141. doi:10.1016/j.jhydrol.2011.11.052

Darcy H. (1865). Les fontaines publiques de la ville de Dijon : exposition et application des principes à suivre et des formules. Gallica 343

Deandreis B.P. (2022). Climate Change Threatens Steep- Slope Agriculture 1–6

Decagon Devices Inc. (2016). Mini Disc Infiltrometer (August): 1–20

Defterdarović J., Filipović L., Kranjčec F., Ondrašek G., Kikić D., Novosel A., Mustać I., Krevh V., Magdić I., Rubinić V., Bogunović I., Dugan I., Čopec 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. Sustain 13 (12): 1–20. doi:10.3390/su13126688

Defterdarović J., Filipović L., Ondrašek G., Bogunović I., Dugan I., Phogat V., He H., Rashti M.R., Tavakkoli E., Baumgartl T., Baghbani A., McLaren T.I., Filipović V. (2024). Impact of Hillslope Agriculture on Soil Compaction and Seasonal Water Dynamics in a Temperate Vineyard. Land 13 (5): 1–18. doi:10.3390/land13050588

Defterdarović J., Krevh V., Filipović L., Kovač Z., Phogat V., He H., Baumgartl T., Filipović V. (2023). Using Dye and Bromide Tracers to Identify Preferential Water Flow in Agricultural Hillslope Soil under Controlled Conditions. Water 15 (12): 2178. doi:10.3390/w15122178

Deng B., Wang J. (2017). Saturated-unsaturated groundwater modeling using 3D Richards equation with a coordinate transform of nonorthogonal grids. Appl Math Model 50: 39–52. doi:10.1016/j.apm.2017.05.021

Doerr S.H., Shakesby R.A., Walsh R.P.D. (2000). Soil water repellency: Its causes, characteristics and hydro-geomorphological significance. Earth Sci Rev 51 (1–4): 33–65. doi:10.1016/S0012-8252(00)00011-8

Domúnguez-Niño J.M., Arbat G., Raij-Hoffman I., Kisekka I., Girona J., Casadesús J. (2020). Parameterization of soil hydraulic parameters for HYDRUS-3D simulation of soil water dynamics in a drip-irrigated orchard. Water (Switzerland) 12 (7). doi:10.3390/W12071858

Dugan I., Pereira P., Barcelo D., Bogunovic I. (2024). Conservation practices reverse soil degradation in Mediterranean fig orchards. Geoderma Reg 36 (December 2023): e00750. doi:10.1016/j.geodrs.2023.e00750

Durner W. (2017). HYPROP-FIT User ' s Manual (July): 1–68

Durner W., Flühler H. (2005). Soil Hydraulic Properties. Encycl Hydrol Sci 1–17. doi:10.1002/0470848944.hsa077c

Dusek J., Dohnal M., Snehota M., Sobotkova M., Ray C., Vogel T. (2015). Transport of bromide and pesticides through an undisturbed soil column: A modeling study with global optimization analysis. J Contam Hydrol 175–176: 1–16. doi:10.1016/j.jconhyd.2015.02.002

Dusek J., Vogel T. (2019). Modeling travel time distributions of preferential subsurface runoff, deep percolation and transpiration at a montane forest hillslope site. Water (Switzerland) 11 (11). doi:10.3390/w11112396

Ehrhardt A., Koszinski S., Gerke H.H. (2023). A Field Experiment for Tracing Lateral Subsurface Flow in a Post-Glacial Hummocky Arable Soil Landscape. Water (Switzerland) 15 (6). doi:10.3390/w15061248

Epstein E., Grant W.J. (1973). Soil Crust Formation as Affected by Raindrop Impact 195–201. doi:10.1007/978-3-642-65523-4_20

Evans R.G. (2000). The Art of Protecting Grapevines From Low Temperature Injury. Proc ASEV 50th Anniv Meet June 19-23 60–72

Everts C.J., Kanwar R.S. (1990). Estimating preferential flow to a subsurface drain with tracers. Trans Am Soc Agric Eng 33 (2): 451–457. doi:10.13031/2013.31350

Fan L., Lehmann P., Or D. (2016). Effects of soil spatial variability at the hillslope and catchment scales on characteristics of rainfall-induced landslides. Water Resour Res. doi:10.1002/2015WR017758

Fang S., Shen P., Qi X., Zhao F., Gu Y., Huang J., Li Y. (2023). The distribution of Van Genuchten model parameters on soil-water characteristic curves in Chinese Loess Plateau and new predicting method on unsaturated permeability coefficient of loess. PLoS One 18 (1 January): 1–43. doi:10.1371/journal.pone.0278307

FAO. (2022). Food and Agriculture Organization of the United Nations strategy on Climate Change 2022-2031 1–50

FAOSTAT. (2020). Land use in agriculture by the numbers. Food Agric Organ United Nations

Fariborzi H., SABZEVARI T., Mohammad pour R. (2021). Estimation of subsurface flow of hillslopes using of SCS and Nash models. Water Resour Eng 14 (50): 17–30.

doi:10.30495/wej.2021.26286.2273

Feddes R.A., Kowalik P.J. Z.H. (1978). Simulation of Field Water Use and Crop Yield. Simul Monogr Cent Agric Publ Doc Wageningen, Netherlands

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 Zo J 18 (1): 1–14. doi:10.2136/vzj2018.09.0174

Filipović V., Defterdarović J., Krevh V., Filipović L., Ondrašek G., Kranjčec F., Magdić I., Rubinić V., Stipičević S., Mustać I., Kovačić M.B., He H., Haghverdi A., Gerke H.H. (2022). Estimation of stagnosol hydraulic properties and water flow using uni-and bimodal porosity models in erosion-affected hillslope vineyard soils. Agronomy 12 (1): 1–19. doi:10.3390/agronomy12010033

Filipović V., Defterdarović J., Šimůnek J., Filipović L., Ondrašek G., Romić D., Bogunović I., Mustać I., Ćurić J., Kodešová R. (2020). Estimation of vineyard soil structure and preferential flow using dye tracer, X-ray tomography, and numerical simulations. Geoderma 380. doi:10.1016/j.geoderma.2020.114699

Filipović V., Gerke H.H., Filipović L., Sommer M. (2018). Quantifying Subsurface Lateral Flow along Sloping Horizon Boundaries in Soil Profiles of a Hummocky Ground Moraine. Vadose Zo J 17 (1): 1–12. doi:10.2136/vzj2017.05.0106

Fredlund D.G., Anqing Xing. (1994). Equations for the soil-water characteristic curve. Can Geotech J 31 (4): 521–532. doi:10.1139/t94-061

Gao J., Bai Y., Cui H., Zhang Y. (2020). The effect of different crops and slopes on runoff and soil erosion. Water Pract Technol 15 (3): 773–780. doi:10.2166/wpt.2020.061

Gärdenäs A.I., Šimůnek J., Jarvis N., van Genuchten M.T. (2006). Two-dimensional modelling of preferential water flow and pesticide transport from a tile-drained field. J Hydrol 329 (3–4): 647–660. doi:10.1016/j.jhydrol.2006.03.021

GDA-Empfehlung E2-7. (2015). Nachweis der Gleitsicherheit von Abdichtungssystemen. Dostupno na: http://www.gdaonline.de

Gerke H.H. (2006). Preferential flow descriptions for structured soils. J Plant Nutr Soil Sci 169 (3): 382–400. doi:10.1002/jpln.200521955

Gerke H.H., Dusek J., Vogel T., Köhne J.M. (2007). Two-Dimensional Dual-Permeability Analyses of a Bromide Tracer Experiment on a Tile-Drained Field. Vadose Zo J 6 (3): 651–667. doi:10.2136/vzj2007.0033

Gerke H.H., van Genuchten M.T. (1993). A dual-porosity model for simulating the preferential movement of water and solutes in structured porous media. Water Resour Res 29 (2): 305–319. doi:10.1029/92WR02339

Gerke H.H., Van Genuchten M.T. (1996). Macroscopic representation of structural geometry for simulating water and solute movement in dual-porosity media. Adv Water Resour 19 (6): 343–357. doi:10.1016/0309-1708(96)00012-7

GHANBARIAN-ALAVIJEH B., LIAGHAT A., HUANG G.H., VAN GENUCHTEN M.T. (2010). Estimation of the van Genuchten Soil Water Retention Properties from Soil Textural Data. Pedosphere 20 (4): 456–465. doi:10.1016/S1002-0160(10)60035-5

Glæsner N., Diamantopoulos E., Magid J., Kjaergaard C., Gerke H.H. (2018). Modeling Solute Mass Exchange between Pore Regions in Slurry-Injected Soil Columns during Intermittent Irrigation. Vadose Zo J 17 (1): 1–10. doi:10.2136/vzj2018.01.0006

Gómez-Guerrero A., Doane T. (2018). The Response of Forest Ecosystems to Climate Change 185–206. doi:10.1016/b978-0-444-63865-6.00007-7

Gonzalez J.M. (2018). Runoff and losses of nutrients and herbicides under long-term conservation practices (no-till and crop rotation) in the U.S. Midwest: A variable intensity simulated rainfall approach. Int Soil Water Conserv Res 6 (4): 265–274. doi:10.1016/j.iswcr.2018.07.005

GOVERS G., VANDAELE K., DESMET P., POESEN J., BUNTE K. (1994). The role of tillage in soil redistribution on hillslopes. Eur J Soil Sci 45 (4): 469–478. doi:10.1111/j.1365-2389.1994.tb00532.x

Govindaraju R.S., Goyal A. (2022). Rainfall and infiltration. Rainfall Model Meas Appl 367–396. doi:10.1016/B978-0-12-822544-8.00007-X

Gumuła-Kawęcka A., Szymkiewicz A., Angulo-jaramillo R., Šim J. (2017). Numerical simulation of infiltration and groundwater recharge using the Hydrus for Modflow package and the BEST model of soil hydraulic properties 19 (2007): 2136

Guo L., Lin H. (2018). Addressing Two Bottlenecks to Advance the Understanding of Preferential Flow in Soils, 1. Izdanje, Advances in Agronomy. Elsevier Inc., 61–117 str. doi:10.1016/bs.agron.2017.10.002

Hadas A. (1964). Deviations from Darcy's law for the flow of water in unsaturated soils. Isr J Agric Res 14 (4): 159–168

Haggard B.E., Moore Jr. P.A. B.K.R. (2005). Effect of slope on runoff from a small variable

slope box-plot. J Environ Hydrol 13: 8

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 (Switzerland) 12 (3): 16–23. doi:10.3390/w12030900

Haghverdi A., Öztürk H.S., Durner W. (2018). Measurement and estimation of the soil water retention curve using the evaporation method and the pseudo continuous pedotransfer function. J Hydrol 563: 251–259. doi:10.1016/j.jhydrol.2018.06.007

Hallema D.W., Moussa R., Sun G., McNulty S.G. (2016). Surface storm flow prediction on hillslopes based on topography and hydrologic connectivity. Ecol Process 5 (1): 1–13. doi:10.1186/s13717-016-0057-1

Harabinová S., Kotrasová K., Kormaníková E., Hegedüsová I. (2021). Analysis of Slope Stability. Civ Environ Eng 17 (1): 192–199. doi:10.2478/cee-2021-0020

Hartmann A., Semenova E., Weiler M., Blume T. (2020). Field observations of soil hydrological flow path evolution over 10 millennia. Hydrol Earth Syst Sci 24 (6): 3271–3288. doi:10.5194/hess-24-3271-2020

Hendrickx J.M.H., Flury M. (2001). Uniform and preferential flow mechanisms in the vadose zone. Concept Model flow Transp Fract vadose Zo Washington, DC (January 2001): 149–187

Herbrich M., Gerke H.H., Bens O., Sommer M. (2017). Water balance and leaching of dissolved organic and inorganic carbon of eroded Luvisols using high precision weighing lysimeters. Soil Tillage Res 165: 144–160. doi:10.1016/j.still.2016.08.003

Hohenbrink T.L., Jackisch C., Durner W., Germer K., Iden S.C., Leuther F., Metzger J.C., Naseri M., Peters A. (2023). Soil water retention and hydraulic conductivity measured in a wide saturation range. Earth Syst Sci Data Discuss [preprint] (March): 1–20

Huang Y., Evaristo J., Li Z. (2019). Multiple tracers reveal different groundwater recharge mechanisms in deep loess deposits. Geoderma 353 (January): 204–212. doi:10.1016/j.geoderma.2019.06.041

Imig A., Shajari F., Augustin L., Einsiedl F., Rein A. (2023). Improved Lumped-Parameter and Numerical Modeling of Unsaturated Water Flow and Stable Water Isotopes. Groundwater 61 (3): 389–401. doi:10.1111/gwat.13244

Indoria A.K., Sharma K.L., Reddy K.S. (2020). Hydraulic properties of soil under warming

climate, Climate Change and Soil Interactions. LTD, 473–508 str. doi:10.1016/B978-0-12-818032-7.00018-7

Ingrao C., Strippoli R., Lagioia G., Huisingh D. (2023). Water scarcity in agriculture: An overview of causes, impacts and approaches for reducing the risks. Heliyon 9 (8): e18507. doi:10.1016/j.heliyon.2023.e18507

ISO - ISO 10390:2005 - Soil quality — Determination of pH. (bez dat.). Dostupno na: https://www.iso.org/standard/40879.html [Pristupljeno 29. lipanj 2022.]

ISO - ISO 11265:1994/Cor 1:1996 - Soil quality — Determination of the specific electrical conductivity — Technical Corrigendum 1. (bez dat.). Dostupno na: https://www.iso.org/standard/26684.html [Pristupljeno 29. lipanj 2022.]

ISO - ISO 11277:1998 - Soil quality — Determination of particle size distribution in mineral soil material — Method by sieving and sedimentation. (bez dat.). Dostupno na: https://www.iso.org/standard/19255.html [Pristupljeno 29. lipanj 2022.]

ISO - ISO 11464:1994 - Soil quality — Pretreatment of samples for physico-chemical analyses. (bez dat.). Dostupno na: https://www.iso.org/standard/19415.html [Pristupljeno 29. lipanj 2022.]

ISO - ISO 14235:1998 - Soil quality — Determination of organic carbon by sulfochromic oxidation. (bez dat.). Dostupno na: https://www.iso.org/standard/23140.html [Pristupljeno 29. lipanj 2022.]

IUSS Working Group WRB. (2022). International Soil Classification System for Naming Soils and Creating Legends for Soil Maps, 4th Izdanje. Vienna, Austria

Jabro J.D., Stevens W.B. (2022). Soil-water characteristic curves and their estimated hydraulic parameters in no-tilled and conventionally tilled soils. Soil Tillage Res 219 (May): 1–7. doi:10.1016/j.still.2022.105342

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. Eur J Soil Sci 58 (3): 523–546. doi:10.1111/j.1365-2389.2007.00915.x

John K., Ofem K.I., Isong I.A., Umeobi E.C., Heung B. (2023). Detailed investigation of soil properties and elemental concentration variation along a hillslope landscape using multivariate approaches. J Earth Syst Sci 132 (3). doi:10.1007/s12040-023-02124-y

Jones A., Panagos P., Barcelo S., Bouraoui F., Bosco C., Dewitte O., Gardi C., Hervás J., Hiederer R., Jeffery S., Montanarella L., Penizek V., Toth G., Van Den Eeckhaut M.,

Van Liedekerke M., Verheijen F.G.A., Yigini Y., Erhard M., Lukewille A., Petersen J., Marmo L., Olazabal C., Strassburger T., Viestova E. (2012). State of Soil in Europe. doi:10.2788/77361

Jourgholami M., Karami S., Tavankar F., Lo Monaco A., Picchio R. (2021). Effects of slope gradient on runoff and sediment yield on machine-induced compacted soil in temperate forests. Forests 12 (1): 1–19. doi:10.3390/f12010049

Jungk A., Claassen N. (1997). Ion Diffusion in the Soil-Root System. Adv Agron 61 (C): 53–110. doi:10.1016/S0065-2113(08)60662-8

Kaizer Hassan M.S., Loo V.H. (2023). Effect of 3D geometric variation on slope stability for sandy slopes. Int J Geotech Eng 17 (3): 271–282. doi:10.1080/19386362.2023.2227498

Kampf S.K. (2011). Variability and persistence of hillslope initial conditions: A continuous perspective on subsurface flow response to rain events. J Hydrol 404 (3–4): 176–185. doi:10.1016/j.jhydrol.2011.04.028

Karbout N., Moussa M., Brahim N., Bol R., Bounina H. (2018). Effect of Combined Application of Mineral Fertilizer in Soil Hydraulic Properties. Adv Sci Technol Innov 269–272. doi:10.1007/978-3-030-01665-4_62

Kargas G., Londra P., Anastasatou M., Moustakas N. (2020). The effect of soil iron on the estimation of soil water content using dielectric sensors. Water (Switzerland) 12 (2): 1–14. doi:10.3390/w12020598

Khaerudin D.N. (2017). Infiltration Rate for Rainfall and Runoff Process with Bulk Density Soil and Slope Variation in Laboratory Experiment Acquisition of Spatial and Temporal Characteristics of Shallow Groundwater Movement Based on Long - Term Temperature Time Series in the K 1–6

Kodešová R., Němeček K., Kodeš V., Žigová A. (2012). Using Dye Tracer for Visualization of Preferential Flow at Macro- and Microscales. Vadose Zo J 11 (1). doi:10.2136/vzj2011.0088

Kodešová R., Němeček K., Žigová A., Nikodem A., Fér M. (2015). Using dye tracer for visualizing roots impact on soil structure and soil porous system. Biol 70 (11): 1439–1443. doi:10.1515/biolog-2015-0166

Kodešová R., Šimůnek J., Nikodem A., Jirků V. (2010). Estimation of the Dual-Permeability Model Parameters using Tension Disk Infiltrometer and Guelph Permeameter. Vadose

Zo J 9 (2): 213–225. doi:10.2136/vzj2009.0069

Köhne J.M., Mohanty B.P., Šimůnek J. (2006). Inverse Dual-Permeability Modeling of Preferential Water Flow in a Soil Column and Implications for Field-Scale Solute Transport. Vadose Zo J 5 (1): 59–76. doi:10.2136/vzj2005.0008

Kosugi K. (1996). Lognormal distribution model for unsaturated soil hydraulic properties. Water Resour Res 32 (9): 2697–2703. doi:10.1029/96WR01776

Kovač Z., Krevh V., Filipović L., Defterdarović J., Balaž B.I., Filipović V. (2023). Estimation of Precipitation Fraction in the Soil Water of the Hillslope Vineyard Using Stable Isotopes of Water. Water (Switzerland) 15 (5). doi:10.3390/w15050988

Kovač Z., Krevh V., Filipović L., Defterdarović J., Buškulić P., Han L., Filipović V. (2022). Utilizing stable water isotopes (δ2H and δ18O) to study soil-water origin in a sloped vineyard: first results. Rud Geol Naft Zb 37 (3): 1–14. doi:10.17794/rgn.2022.3.1

Krevh V., Filipović L., Defterdarović J., Bogunović I., Zhang Y., Kovač Z., Barton A., Filipović V. (2023a). Investigating Near-Surface Hydrologic Connectivity in a Grass-Covered Inter-Row Area of a Hillslope Vineyard Using Field Monitoring and Numerical Simulations. Land 12 (5). doi:10.3390/land12051095

Krevh V., Filipović V., Filipović L., Mateković V., Petošić D., Mustać I., Ondrašek G., Bogunović I., Kovač Z., Pereira P., Sasidharan S., He H., Groh J., Stumpp C., Brunetti G. (2022). Modeling seasonal soil moisture dynamics in gley soils in relation to groundwater table oscillations in eastern Croatia. CATENA 211: 105987. doi:10.1016/J.CATENA.2021.105987

Krevh V., Groh J., Filipović L., Gerke H.H., Defterdarović J., Thompson S., Sraka M., Bogunović I., Kovač Z., Robinson N., Baumgartl T., Filipović V. (2023b). Soil–Water Dynamics Investigation at Agricultural Hillslope with High-Precision Weighing Lysimeters and Soil–Water Collection Systems. Water (Switzerland) 15 (13). doi:10.3390/w15132398

Krevh V., Groh J., Weihermüller L., Filipović L., Defterdarović J., Kovač Z., Magdić I., Lazarević B., Baumgartl T., Filipović V. (2023c). Investigation of Hillslope Vineyard Soil Water Dynamics Using Field Measurements and Numerical Modeling. Water (Switzerland) 15 (4): 1–17. doi:10.3390/w15040820

Kumar N., Kumar Arvind, Marwein B.M., Verma D.K.I.J., Kumar Agam, Ramamoorthy D. (2021). Agricultural activities causing water pollution and its mitigation – a review. https://www.researchgate.net/publication/350276392_agricultural_activities_causing_w

ater_pollution_and_its_mitigation_-a_review. Int J Mod Agric 10 (1 SE-): 590–609

Kumar S., Ojha R. (2023). Modeling Soil Hydraulic Properties Using Dynamic Variability of Soil Pore Size Distribution. Sustain 15 (13). doi:10.3390/su151310133

Lázaro R., Gascón C., Rubio C. (2023). Runoff and soil loss in biocrusts and physical crusts from the Tabernas Desert (southeast Spain) according to rainfall intensity. Front Microbiol 14 (May): 1–16. doi:10.3389/fmicb.2023.1171096

Leue M., Uteau-Puschmann D., Peth S., Nellesen J., Kodešová R., Gerke H.H. (2019). Separation of Soil Macropore Types in Three-Dimensional X-Ray Computed Tomography Images Based on Pore Geometry Characteristics. Vadose Zo J 18 (1): 1–13. doi:10.2136/vzj2018.09.0170

Li M., Yao J., Cheng J. (2020). Study on the preferential flow characteristics under different precipitation amounts in simian mountain grassland of china. Water (Switzerland) 12 (12): 1–12. doi:10.3390/w12123489

Li X.Y., González A., Solé-Benet A. (2005). Laboratory methods for the estimation of infiltration rate of soil crusts in the Tabernas Desert badlands. Catena 60 (3): 255–266. doi:10.1016/j.catena.2004.12.004

Lima I.B., Boëchat I.G., Fernandes M.D., Monteiro J.A.F., Rivaroli L., Gücker B. (2023). Glyphosate pollution of surface runoff, stream water, and drinking water resources in Southeast Brazil. Environ Sci Pollut Res 30 (10): 27030–27040. doi:10.1007/s11356-022-24167-2

Lipovetsky T., Zhuang L., Teixeira W.G., Boyd A., May Pontedeiro E., Moriconi L., Alves J.L.D., Couto P., van Genuchten M.T. (2020). HYPROP measurements of the unsaturated hydraulic properties of a carbonate rock sample. J Hydrol. doi:10.1016/j.jhydrol.2020.125706

Liu R., Pan Y., Bao H., Liang S., Jiang Y., Tu H., Nong J., Huang W. (2020). Variations in soil physico-chemical properties along slope position gradient in secondary vegetation of the hilly region, Guilin, southwest China. Sustain 12 (4): 1–16. doi:10.3390/su12041303

Liu X., Tang Y., Cheng X., Jia Z., Li C., Ma S., Zhai L., Zhang B., Zhang J. (2021). Comparison of changes in soil moisture content following rainfall in different subtropical plantations of the yangtze river delta region. Water (Switzerland) 13 (7). doi:10.3390/w13070914

Liu Y., Cui Z., Huang Z., López-Vicente M., Wu G.L. (2019). Influence of soil moisture and plant roots on the soil infiltration capacity at different stages in arid grasslands of China. Catena 182 (January 2018). doi:10.1016/j.catena.2019.104147

Liu Y., Wang P., Gojenko B., Yu J., Wei L., Luo D., Xiao T. (2021). A review of water pollution arising from agriculture and mining activities in Central Asia: Facts, causes and effects. Environ Pollut 291: 118209. doi:10.1016/J.ENVPOL.2021.118209

Lobb D.A. (2008). Soil Movement by Tillage and Other Agricultural Activities. Encycl Ecol Five-Volume Set (cm): 3295–3303. doi:10.1016/B978-008045405-4.00832-6

Luna Juncal M.J., Masino P., Bertone E., Stewart R.A. (2023). Towards nutrient neutrality: A review of agricultural runoff mitigation strategies and the development of a decision-making framework. Sci Total Environ 874 (May): 1–72. doi:10.1016/j.scitotenv.2023.162408

Luo L., Lin H., Halleck P. (2008). Quantifying Soil Structure and Preferential Flow in Intact Soil Using X-ray Computed Tomography. Soil Sci Soc Am J 72 (4): 1058–1069. doi:10.2136/sssaj2007.0179

Lutz W., Kc S. (2010). Dimensions of global population projections: What do we know about future population trends and structures? Philos Trans R Soc B Biol Sci 365 (1554): 2779–2791. doi:10.1098/rstb.2010.0133

Magdić I. (2021). Modeliranje toka i retencije vode na obronačnom pseudogleju u uvjetima uzgoja vinove loze. Sveučilište u Zagrebu

Magdić I., Safner T., Rubinić V., Rutić F., Husnjak S., Filipović V. (2022). Effect of slope position on soil properties and soil moisture regime of Stagnosol in the vineyard. J Hydrol Hydromechanics 70 (1): 62–73. doi:10.2478/johh-2021-0037

Marzen M., Iserloh T. (2021). Processes of raindrop splash and effects on soil erosion. Precip Earth Surf Responses Process (0): 351–371. doi:10.1016/B978-0-12-822699-5.00013-6

Mashalaba L., Galleguillos M., Seguel O., Poblete-Olivares J. (2020). Predicting spatial variability of selected soil properties using digital soil mapping in a rainfed vineyard of central Chile. Geoderma Reg 22: e00289. doi:10.1016/j.geodrs.2020.e00289

Mbarki Y., Gumiere S.J., Celicourt P., Brédy J. (2023). Study of the effect of the compaction level on the hydrodynamic properties of loamy sand soil in an agricultural context. Front Water 5. doi:10.3389/frwa.2023.1255495

Meshkat M., Amanian N., Talebi A., Kiani-Harchegani M., Rodrigo-Comino J. (2019). Effects of roughness coefficients and complex hillslope morphology on runoffvariables under laboratory conditions. Water (Switzerland) 11 (12): 11–12. doi:10.3390/w11122550

Misman N.A., Sharif M.F., Chowdhury A.J.K., Azizan N.H. (2023). Water pollution and the assessment of water quality parameters: a review. Desalin Water Treat 294: 79–88. doi:10.5004/dwt.2023.29433

Molotoks A., Stehfest E., Doelman J., Albanito F., Fitton N., Dawson T.P., Smith P. (2018). Global projections of future cropland expansion to 2050 and direct impacts on biodiversity and carbon storage. Glob Chang Biol 24 (12): 5895–5908. doi:10.1111/gcb.14459

Morbidelli R., Saltalippi C., Flammini A., Govindaraju R.S. (2018). Role of slope on infiltration: A review. J Hydrol 557 (January): 878–886. doi:10.1016/j.jhydrol.2018.01.019

Müller K., Stenger R., Rahman A. (2006). Herbicide loss in surface runoff from a pastoral hillslope in the Pukemanga catchment (New Zealand): Role of pre-event soil water content. Agric Ecosyst Environ 112 (4): 381–390. doi:10.1016/j.agee.2005.08.027

Naik A.P., Ghosh B., Pekkat S. (2019). Estimating soil hydraulic properties using mini disk infiltrometer. ISH J Hydraul Eng 25 (1): 62–70. doi:10.1080/09715010.2018.1471363

Nimmo J.R. (2021). The processes of preferential flow in the unsaturated zone. Soil Sci Soc Am J 85 (1): 1–27. doi:10.1002/saj2.20143

Nimmo J.R. (2009). Vadose Water. (Likens G.E.B.T.-E. of I.W., ur), Academic Press, Oxford, str. 766–777. doi:https://doi.org/10.1016/B978-012370626-3.00014-4

Nisha K., Upadhyay G., Patel B., Sihag N., Choudhary S., Rani V. (2023). Analysis of soil compaction induced beneath the working depth due to tilling action of different active tillage machinery. Spanish J Agric Res 21 (4): 1–22. doi:10.5424/sjar/2023214-20351

O'Geen A.T. (2013). Soil Water Dynamics: What Are The Relationship Between Soil Moisture Storage, Soil Water Flow, and Soil Properties? Nat Educ Knowl 4 (5): 1–9

Ondrašek G., Petošić D., Tomić F., Mustać I., Filipović V., Petek M., Lazarević B. B.M. (2015). Voda u agroekosustavima. Sveučilište u Zagrebu, Zagreb

Or D., Lehmann P. (2019). Surface Evaporative Capacitance: How Soil Type and Rainfall Characteristics Affect Global-Scale Surface Evaporation. Water Resour Res. doi:10.1029/2018WR024050

Pagliai M. (1992). CHANGES OF PORE SYSTEM FOLLOWING SOIL COMPACTION M. Pagliai Istituto Sperimentale per lo Studio e la Difesa del Suolo, MiPA. Piazza D'Azeglio 30, 50121 Firenze, Italy

Pham T.A., Hashemi A., Sutman M., Medero G.M. (2023). Effect of temperature on the soil–water retention characteristics in unsaturated soils: Analytical and experimental approaches. Soils Found 63 (3): 101301. doi:10.1016/j.sandf.2023.101301

Phi S., Clarke W., Li L. (2013). Laboratory and numerical investigations of hillslope soil saturation development and runoff generation over rainfall events. J Hydrol 493: 1–15. doi:10.1016/j.jhydrol.2013.04.009

Phillips J.D. (2021). Selection and landscape evolution, Landscape Evolution. 227–268 str. doi:10.1016/b978-0-12-821725-2.00008-9

Pietrzak D., Kania J., Kmiecik E., Wator K. (2019). Identification of transport parameters of chlorides in different soils on the basis of column studies. Geologos 25 (3): 225–229. doi:10.2478/logos-2019-0024

Popović Z., Cerdà A. (2023). Soil water repellency and plant cover: A state-of-knowledge review. Catena 229 (August): 1–9. doi:10.1016/j.catena.2023.107213

Poulsen T.G., Li T., Lu T., Chen H. (2022). Local-scale evaporation and water loss distribution in surface soil as related to near-surface wind conditions and surface geometry. Eur J Soil Sci 73 (1): 1–15. doi:10.1111/ejss.13199

Qian F., Cheng D., Ding W., Huang J., Liu J. (2016). Hydraulic characteristics and sediment generation on slope erosion in the Three Gorges Reservoir Area, China. J Hydrol Hydromechanics 64 (3): 237–245. doi:10.1515/johh-2016-0029

Rad S.M., Ray A.K., Barghi S. (2022). Water Pollution and Agriculture Pesticide. Clean Technol 4 (4): 1088–1102. doi:10.3390/cleantechnol4040066

Radinja M., Vidmar I., Atanasova N., Mikoš M., Šraj M. (2019). Determination of spatial and temporal variability of soil hydraulic conductivity for urban runoff modelling. Water (Switzerland) 11 (5). doi:10.3390/w11050941

Ramesh T., Bolan N.S., Kirkham M.B., Wijesekara H., Kanchikerimath M., Srinivasa Rao C., Sandeep S., Rinklebe J., Ok Y.S., Choudhury B.U., Wang H., Tang C., Wang X., Song Z., Freeman O.W. (2019). Soil organic carbon dynamics: Impact of land use changes and management practices: A review. Adv Agron 156: 1–107. doi:10.1016/bs.agron.2019.02.001

Ramke H.G. (2018). Collection of Surface Runoff and Drainage of Landfill Top Cover Systems, Solid Waste Landfilling: Concepts, Processes, Technologies. Elsevier Inc., 373–416 str. doi:10.1016/B978-0-12-407721-8.00019-X

Rasul H., Earon R., Olofsson B. (2018). Detecting Seasonal Flow Pathways in Road Structures Using Tracer Tests and ERT. Water Air Soil Pollut 229 (11). doi:10.1007/s11270-018-4008-6

Rawls W.J., Pachepsky Y.A., Ritchie J.C., Sobecki T.M., Bloodworth H. (2003). Effect of soil organic carbon on soil water retention. Geoderma 116 (1–2): 61–76. doi:10.1016/S0016-7061(03)00094-6

Robinson D.A., Thomas A., Reinsch S., Lebron I., Feeney C.J., Maskell L.C., Wood C.M., Seaton F.M., Emmett B.A., Cosby B.J. (2022). Analytical modelling of soil porosity and bulk density across the soil organic matter and land-use continuum. Sci Rep 12 (1): 1–14. doi:10.1038/s41598-022-11099-7

Sander T., Gerke H.H. (2009). Modelling field-data of preferential flow in paddy soil induced by earthworm burrows. J Contam Hydrol 104 (1–4): 126–136. doi:10.1016/j.jconhyd.2008.11.003

Sander T., Gerke H.H. (2007). Preferential Flow Patterns in Paddy Fields Using a Dye Tracer. Vadose Zo J 6 (1): 105–115. doi:10.2136/vzj2006.0035

SAS Institute Inc. (2020). SAS Enterprise Guide 8 . 3 : Guía del usuario 564

Sasakova N., Gregova G., Takacova D., Mojzisova J., Papajova I., Venglovsky J., Szaboova T., Kovacova S. (2018). Pollution of Surface and Ground Water by Sources Related to Agricultural Activities. Front Sustain Food Syst 2 (July). doi:10.3389/fsufs.2018.00042

Scherrer S., Naef F., Fach A.O., Cordery I. (2007). Formation of runoff at the hillslope scale during intense precipitation. Hydrol Earth Syst Sci 11 (2): 907–922. doi:10.5194/hess-11-907-2007

Schindler U.G., 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: 1–7. doi:10.18174/odjar.v3i1.15763

Schowalter T.D. (2011). Insect Ecology: An Ecosystem Approach. Insect Ecol An Ecosyst Approach 1–633. doi:10.1016/C2009-0-60945-4

Schroeder R., Fleige H., Hoffmann C., Vogel H.J., Horn R. (2022). Mechanical Soil Database—Part I: Impact of Bulk Density and Organic Matter on Precompression

Stress and Consequences for Saturated Hydraulic Conductivity. Front Environ Sci 10 (February): 1–15. doi:10.3389/fenvs.2022.793625

Schwen A., Bodner G., Scholl P., Buchan G.D., Loiskandl W. (2011). Temporal dynamics of soil hydraulic properties and the water-conducting porosity under different tillage. Soil Tillage Res 113 (2): 89–98. doi:10.1016/j.still.2011.02.005

Šimůnek J., Brunetti G., Jacques D., van Genuchten M.T., Šejna M. (2024). Developments and applications of the HYDRUS computer software packages since 2016. Vadose Zo J 23 (4): 1–29. doi:10.1002/vzj2.20310

Šimůnek J., Jarvis N.J., Van Genuchten M.T., Gärdenäs A. (2003). Review and comparison of models for describing non-equilibrium and preferential flow and transport in the vadose zone. J Hydrol 272 (1–4): 14–35. doi:10.1016/S0022-1694(02)00252-4

Simunek J., van Genuchten M.T. (2007). Chapter 22: Contaminant transport in the unsaturated zone: theory and modelling. Handb Groundw Eng 22.1-22.38

Šimůnek J., Van Genuchten M.T., Šejna M. (2008). Modeling subsurface water flow and solute transport with HYDRUS and related numerical software packages. Proc Int Work Numer Model Hydrodyn Water Resour - Numer Model Hydrodyn Water Resour 95–114. doi:10.1201/9781482288513-8

Singh A., Haghverdi A., Öztürk H.S., Durner W. (2021). Developing pseudo continuous pedotransfer functions for international soils measured with the evaporation method and the hyprop system: Ii. the soil hydraulic conductivity curve. Water (Switzerland) 13 (6): 1–14. doi:10.3390/w13060878

Singh A., Verdi A. (2024). Estimating the soil water retention curve by the HYPROP-WP4C system, HYPROP-based PCNN-PTF and inverse modeling using HYDRUS-1D. J Hydrol 639 (July): 131657. doi:10.1016/j.jhydrol.2024.131657

Soracco C.G., Villarreal R., Melani E.M., Oderiz J.A., Salazar M.P., Otero M.F., Irizar A.B., Lozano L.A. (2019). Hydraulic conductivity and pore connectivity. Effects of conventional and no-till systems determined using a simple laboratory device. Geoderma 337: 1236–1244. doi:10.1016/J.GEODERMA.2018.10.045

Steenhuis T.S., Parlange J.Y., Kim Y.J., DiCarlo D.A., Selker J.S., Nektarios P.A., Barry D.A., Stagnitti F. (2004). Unstable Flow. Encycl Soils Environ 4: 197–201. doi:10.1016/B0-12-348530-4/00433-1

Striegler R.K., Allen R.A., Harris J.L., Smeda R.J., Bergmeier E.A., Cotta J. (2015). Ozark

Mountain Vineyard Sustainability Assessment Workbook. A Self-Assessment Manag Pract 1–76

Stumpp C., Maloszewski P. (2010). Quantification of preferential flow and flow heterogeneities in an unsaturated soil planted with different crops using the environmental isotope δ18O. J Hydrol 394 (3–4): 407–415. doi:10.1016/j.jhydrol.2010.09.014

Tan X., Shao D., Liu H. (2014). Simulating soil water regime in lowland paddy fields under different water managements using HYDRUS-1D. Agric Water Manag 132: 69–78. doi:10.1016/j.agwat.2013.10.009

Tarolli P., Pijl A., Cucchiaro S., Wei W. (2021). Slope instabilities in steep cultivation systems: Process classification and opportunities from remote sensing. L Degrad Dev 32 (3): 1368–1388. doi:10.1002/ldr.3798

Telak L.J., Bogunovic I. (2020). Tillage-induced impacts on the soil properties, soil water erosion, and loss of nutrients in the Vineyard (Central Croatia). J Cent Eur Agric 21 (3): 589–601. doi:10.5513/JCEA01/21.3.2810

Tichavský R., Ballesteros-Cánovas J.A., Šilhán K., Tolasz R., Stoffel M. (2019). Dry Spells and Extreme Precipitation are The Main Trigger of Landslides in Central Europe. Sci Rep 9 (1): 1–10. doi:10.1038/s41598-019-51148-2

UMS. (2017). Manual KSAT 1–40

Upadhyay S., Raghubanshi A.S. (2020). Determinants of soil carbon dynamics in urban ecosystems, Urban Ecology: Emerging Patterns and Social-Ecological Systems. Elsevier Inc., 299–314 str. doi:10.1016/B978-0-12-820730-7.00016-1

Vaezi A.R., Ahmadi M., Cerdà A. (2017). Contribution of raindrop impact to the change of soil physical properties and water erosion under semi-arid rainfalls. Sci Total Environ 583 (April): 382–392. doi:10.1016/j.scitotenv.2017.01.078

Van Der Veeke S., Koomans R., Limburg H. (2020). Using a gamma-ray spectrometer for soil moisture monitoring: Development of the the gamma Soil Moisture Sensor (gSMS). 2020 IEEE Int Work Metrol Agric For MetroAgriFor 2020 - Proc 185–190. doi:10.1109/MetroAgriFor50201.2020.9277560

Van Dijk D., Houba V.J.G. (1999). Wageningen Evaluating Programmes for Analytical Laboratories (WEPAL). Arh Hig Rada Toksikol 50 (1): 31–36

van Genuchten M.T. (1980). A Closed-form Equation for Predicting the Hydraulic

Conductivity of Unsaturated Soils. Soil Sci Soc Am J 44 (5): 892–898. doi:10.2136/sssaj1980.03615995004400050002x

van J., Le P., Hensley M. (2011). Soil Indicators of Hillslope Hydrology. Princ Appl Assess Soil Sci. doi:10.5772/28724

Varela M.E., Benito E., de Blas E. (2005). Impact of wildfires on surface water repellency in soils of northwest Spain. Hydrol Process 19 (18): 3649–3657. doi:10.1002/hyp.5850

Védère C., Lebrun M., Honvault N., Aubertin M.L., Girardin C., Garnier P., Dignac M.F., Houben D., Rumpel C. (2022). How does soil water status influence the fate of soil organic matter? A review of processes across scales. Earth-Science Rev 234 (November): 1–8. doi:10.1016/j.earscirev.2022.104214

Vereecken H., Weihermüller L., Assouline S., Šimůnek J., Verhoef A., Herbst M., Archer N., Mohanty B., Montzka C., Vanderborght J., Balsamo G., Bechtold M., Boone A., Chadburn S., Cuntz M., Decharme B., Ducharne A., Ek M., Garrigues S., Goergen K., Ingwersen J., Kollet S., Lawrence D.M., Li Q., Or D., Swenson S., Vrese P., Walko R., Wu Y., Xue Y. (2019). Infiltration from the Pedon to Global Grid Scales: An Overview and Outlook for Land Surface Modeling. Vadose Zo J 18 (1): 1–53. doi:10.2136/vzj2018.10.0191

Vogeler I., Carrick S., Cichota R., Lilburne L. (2019). Estimation of soil subsurface hydraulic conductivity based on inverse modelling and soil morphology. J Hydrol 574 (April): 373–382. doi:10.1016/j.jhydrol.2019.04.002

Volpe E., Gariano S.L., Ardizzone F., Fiorucci F., Salciarini D. (2022). A Heuristic Method to Evaluate the Effect of Soil Tillage on Slope Stability: A Pilot Case in Central Italy. Land 11 (6). doi:10.3390/land11060912

Wang W., Straffelini E., Pijl A., Tarolli P. (2022). Sustainable water resource management in steep-slope agriculture. Geogr Sustain 3 (3): 214–219. doi:10.1016/j.geosus.2022.07.001

Wang W., Straffelini E., Tarolli P. (2024). 44% of steep slope cropland in Europe vulnerable to drought. Geogr Sustain 5 (1): 89–95. doi:10.1016/j.geosus.2023.12.001

Wang X., Li Y., Wang Y., Liu C. (2018). Performance of HYDRUS-1D for simulating water movement in water-repellent soils. Can J Soil Sci 98 (3): 407–420. doi:10.1139/cjss-2017-0116

Wang Y., Zhang B., Banwart S.A. (2017). Reduced Subsurface Lateral Flow in Agroforestry

System Is Balanced by Increased Water Retention Capacity: Rainfall Simulation and Model Validation. Adv Agron 142: 73–97. doi:10.1016/bs.agron.2016.10.005

Wang Y., Zhang Z., Zhang J., Liang X., Liu X., Zeng Y. (2021). Effect of surface rills on soil redistribution by tillage erosion on a steep hillslope. Geomorphology 380: 107637. doi:10.1016/j.geomorph.2021.107637

Way T.R., Lamba J., Srivastava P. (2011). A method for installing zero-tension pan and wick lysimeters in soil. Appl Eng Agric 27 (5): 747–755. doi:10.13031/2013.39571

Wu B., Qi S. (2021). Effects of underlay on hill-slope surface runoff process of cupressus funebris endl. Plantations in southwestern china. Forests 12 (5). doi:10.3390/f12050644

Wu S., Chen L., Wang N., Zhang J., Wang S., Bagarello V., Ferro V. (2021). Variable scale effects on hillslope soil erosion during rainfall-runoff processes. Catena 207 (December): 1–9. doi:10.1016/j.catena.2021.105606

Wysocka-Czubaszek A., Czubaszek R. (2014). Tillage erosion: The principles, controlling factors and main implications for future research. J Ecol Eng 15 (4): 150–159. doi:10.12911/22998993.1125470

Yeom S., Sjoblom K. (2016). Structural soil crust development from raindrop impacts using two-dimensional discrete element method. Comput Geosci 97 (December): 49–57. doi:10.1016/j.cageo.2016.09.004

Yost J.L., Hartemink A.E. (2019). Soil organic carbon in sandy soils: A review. Adv Agron 158: 217–310. doi:10.1016/bs.agron.2019.07.004

Zhang J.H., Jia L.Z., Wang Y., Zhang Z.H. (2017). Tillage Erosion Effect on Soil Hydrological Properties in a Hilly Landscape. J Hydrol Eng 22 (9). doi:10.1061/(asce)he.1943-5584.0001565

Zhang R. (1997). Determination of Soil Sorptivity and Hydraulic Conductivity from the Disk Infiltrometer. Soil Sci Soc Am J 61 (4): 1024–1030. doi:10.2136/sssaj1997.03615995006100040005x

Zhang Y., Cao Z., Hou F., Cheng J. (2021). Characterizing preferential flow paths in texturally similar soils under different land uses by combining drainage and dye-staining methods. Water (Switzerland) 13 (2). doi:10.3390/w13020219

Zhang Y., Zhang Z., Ma Z., Chen J., Akbar J., Zhang S., Che C., Zhang M., Cerdà A. (2018). A review of preferential water flow in soil science. Can J Soil Sci 98 (4): 604–618. doi:10.1139/cjss-2018-0046

Zhang Z.B., Zhou H., Zhao Q.G., Lin H., Peng X. (2014). Characteristics of cracks in two paddy soils and their impacts on preferential flow. Geoderma 228–229: 114–121. doi:10.1016/j.geoderma.2013.07.026

Zhao S.Y., Jia Y.W., Gong J.G., Niu C.W., Su H.D., Gan Y. De, Liu H. (2020). Spatial variability of preferential flow and infiltration redistribution along a rocky-mountain Hillslope, Northern China. Water (Switzerland) 12 (4). doi:10.3390/W12041102

Zhao X., Zhang W., Feng Y., Mo Q., Su Y., Njoroge B., Qu C., Gan X., Liu X. (2022). Soil organic carbon primarily control the soil moisture characteristic during forest restoration in subtropical China. Front Ecol Evol 10 (October): 1–12. doi:10.3389/fevo.2022.1003532

Zhao Y., Yi J., Yao R., Li F., Hill R.L., Gerke H.H. (2024). Dimensionality and scales of preferential flow in soils of Shale Hills hillslope simulated using HYDRUS. Vadose Zo J 23 (4): 1–24. doi:10.1002/vzj2.20367

Zhou T., Levintal E., Brunetti G., Jordan S., Harter T., Kisekka I., Šimůnek J., Dahlke H.E. (2023). Estimating the impact of vadose zone heterogeneity on agricultural managed aquifer recharge: A combined experimental and modeling study. Water Res 247 (April). doi:10.1016/j.watres.2023.120781

Zhu P., Zhang G., Yang Y., Wang C., Chen S., Wan Y. (2023). Infiltration properties affected by slope position on cropped hillslopes. Geoderma 432 (April): 1–30. doi:10.1016/j.geoderma.2023.116379

8. ŽIVOTOPIS

Jasmina Defterdarović rođena je 03. veljače 1996. u Zagrebu. Srednjoškolsko obrazovanje završava 2014. godine kada upisuje i preddiplomski studij Agroekologije na Agronomskom fakultetu Sveučilišta u Zagrebu. Studij završava 2017. godine obranom završnog rada „Povijesni pregled proizvodnje biogoriva“ pod mentorstvom prof. dr. sc. Nevena Voće. Diplomski studij Agroekologije upisuje 2017. godine na istom Fakultetu te završava 2019. s velikom pohvalom (*Magna cum laude*) i obranom diplomskog rada naslova „Kvantifikacija poroznog sustava neporušenog tla primjenom različitih metoda“ pod mentorstvom izv. prof. dr. sc. Vilima Filipovića. Dobitnica je Rektorove nagrade za timski znanstveni i umjetnički rad pod naslovom „Primjena eksperimentalnih i numeričkih metoda za procjenu transporta nitrata i pesticida na tlima urbanih površina“. Na Zavodu za melioracije zapošljava se 2020. godine kao asistent (doktorand) u sklopu projekta Hrvatske zaklade za znanost te upisuje poslijediplomski studij Poljoprivrednih znanosti. Rezultate svojih istraživanja izlaže na brojnim domaćim i međunarodnim konferencijama te se usavršava na raznim radionicama i tečajevima. Sudjelovala je u izradi 15 radova kao koautorica i tri znanstvena rada kao prva autorica. Uključena je u nastavu na Fakultetu na preddiplomskom i diplomskom studiju održavanjem vježbi. Članica je društava *European Geosciences Union, Soil Science Society of America, American Society of Agronomy i Crop Science Society of America*.

Popis publikacija:

1. **Defterdarović J.**, Filipović L., Kranjčec F., Ondrašek G., Kikić D., Novosel A., Mustać I., Krevh V., Magdić I., Rubinić V., Bogunović I., Dugan I., Čopec 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. Sustain 13 (12): 1–20. doi:10.3390/su13126688
2. **Defterdarović J.**, Krevh V., Filipović L., Kovač Z., Phogat V., He H., Baumgartl T., Filipović V. (2023). Using Dye and Bromide Tracers to Identify Preferential Water Flow in Agricultural Hillslope Soil under Controlled Conditions. Water 15 (12): 2178. doi:10.3390/w15122178
3. **Defterdarović J.**, Filipović L., Ondrašek G., Bogunović I., Dugan I., Phogat V., He H., Rashti M.R., Tavakkoli E., Baumgartl T., Baghbani A., McLaren T.I., Filipović V. (2024). Impact of Hillslope Agriculture on Soil Compaction and Seasonal Water Dynamics in a Temperate Vineyard. Land 13 (5): 1–18. doi:10.3390/land13050588
4. Filipović V., **Defterdarović J.**, Šimůnek J., Filipović L., Ondrašek G., Romić D., Bogunović I., Mustać I., Ćurić J., Kodešová R. (2020). Estimation of vineyard soil structure and preferential flow using dye tracer, X-ray tomography, and numerical

simulations. Geoderma 380. doi:10.1016/j.geoderma.2020.114699

5. Filipović V., **Defterdarović J.**, Krevh V., Filipović L., Ondrašek G., Kranjčec F., Magdić I., Rubinić V., Stipičević S., Mustać I., Kovačić M.B., He H., Haghverdi A., Gerke H.H. (2022). Estimation of stagnosol hydraulic properties and water flow using uni-and bimodal porosity models in erosion-affected hillslope vineyard soils. Agronomy 12 (1): 1–19. doi:10.3390/agronomy12010033
6. Kovač Z., Krevh V., Filipović L., **Defterdarović J.**, Buškulić P., Han L., Filipović V. (2022). Utilizing stable water isotopes (δ2H and δ18O) to study soil-water origin in a sloped vineyard: first results. Rud Geol Naft Zb 37 (3): 1–14. doi:10.17794/rgn.2022.3.1
7. Bogunovic I., Dugan I., Pereira P., Filipovic V., Filipovic L., Krevh V., **Defterdarovic J.**, Matisic M., Kisic I. (2023). Effects of Biochar and Cattle Manure under Different Tillage Management on Soil Properties and Crop Growth in Croatia. Agric 13 (11): 1–14. doi:10.3390/agriculture13112128
8. Bogunović I., Hrelja I., Kisić I., Dugan I., Krevh V., **Defterdarović J.**, Filipović V., Filipović L., Pereira P. (2023). Straw Mulch Effect on Soil and Water Loss in Different Growth Phases of Maize Sown on Stagnosols in Croatia. Land 12 (4). doi:10.3390/land12040765
9. Dugan I., Pereira P., **Defterdarovic J.**, Filipovic L., Filipovic V., Bogunovic I. (2023). Straw Mulch Application Enhanced Soil Properties and Reduced Diffuse Pollution at a Steep Vineyard in Istria (Croatia). Land 12 (9): 1–21. doi:10.3390/land12091691
10. Filipović L., **Defterdarović J.**, Chen R., Krevh V., Gerke H.H., Baumgartl T., Kovač Z., Ondrašek G., Ružičić S., He H., Dusek J., Filipović V. (2023). Leached Copper Correlation with Dissolved Organic Carbon in Sloped Vineyard Soil. Water (Switzerland) 15 (4). doi:10.3390/w15040800
11. Filipović L., Krevh V., Chen R., **Defterdarović J.**, Kovač Z., Mustać I., Bogunović I., He H., Baumgartl T., Gerke H.H., Toor G.S., Filipović V. (2023). Quantification of Intra- vs. Inter-Row Leaching of Major Plant Nutrients in Sloping Vineyard Soils. Water (Switzerland) 15 (4). doi:10.3390/w15040759
12. Kovač Z., Krevh V., Filipović L., **Defterdarović J.**, Balaž B.I., Filipović V. (2023). Estimation of Precipitation Fraction in the Soil Water of the Hillslope Vineyard Using Stable Isotopes of Water. Water (Switzerland) 15 (5). doi:10.3390/w15050988
13. Krevh V., Filipović L., **Defterdarović J.**, Bogunović I., Zhang Y., Kovač Z., Barton A., Filipović V. (2023). Investigating Near-Surface Hydrologic Connectivity in a Grass-Covered Inter-Row Area of a Hillslope Vineyard Using Field Monitoring and Numerical Simulations. Land 12 (5). doi:10.3390/land12051095
14. Krevh V., Filipović L., Petošić D., Mustać I., Bogunović I., Butorac J., Kisić I.,

Defterdarović J., Nakić Z., Kovač Z., Pereira P., He H., Chen R., Toor G.S., Versini A., Baumgartl T., Filipović V. (2023). Long-term analysis of soil water regime and nitrate dynamics at agricultural experimental site: Field-scale monitoring and numerical modeling using HYDRUS-1D. Agric Water Manag 275 (January). doi:10.1016/j.agwat.2022.108039

15. Krevh V., Groh J., Filipović L., Gerke H.H., **Defterdarović J.**, Thompson S., Sraka M., Bogunović I., Kovač Z., Robinson N., Baumgartl T., Filipović V. (2023). Soil–Water Dynamics Investigation at Agricultural Hillslope with High-Precision Weighing Lysimeters and Soil–Water Collection Systems. Water (Switzerland) 15 (13). doi:10.3390/w15132398
16. Krevh V., Groh J., Weihermüller L., Filipović L., **Defterdarović J.**, Kovač Z., Magdić I., Lazarević B., Baumgartl T., Filipović V. (2023). Investigation of Hillslope Vineyard Soil Water Dynamics Using Field Measurements and Numerical Modeling. Water (Switzerland) 15 (4): 1–17. doi:10.3390/w15040820
17. Mustać I., Petošić D., Begić H.B., Filipović V., **Defterdarović J.**, Krevh V., Filipović L. (2023). Procjena pogodnosti dreniranog poljoprivrednog zemljišta istočne Hrvatske za potrebe navodnjavanja 31–42
18. Ondrasek G., Horvatinec J., Kovačić M.B., Reljić M., Vinceković M., Rathod S., Bandumula N., Dharavath R., Rashid M.I., Panfilova O., Kodikara K.A.S., **Defterdarović J.**, Krevh V., Filipović V., Filipović L., Čop T., Njavro M. (2023). Land Resources in Organic Agriculture: Trends and Challenges in the Twenty-First Century from Global to Croatian Contexts. Agronomy 13 (6): 1–17. doi:10.3390/agronomy13061544

9. PRILOZI

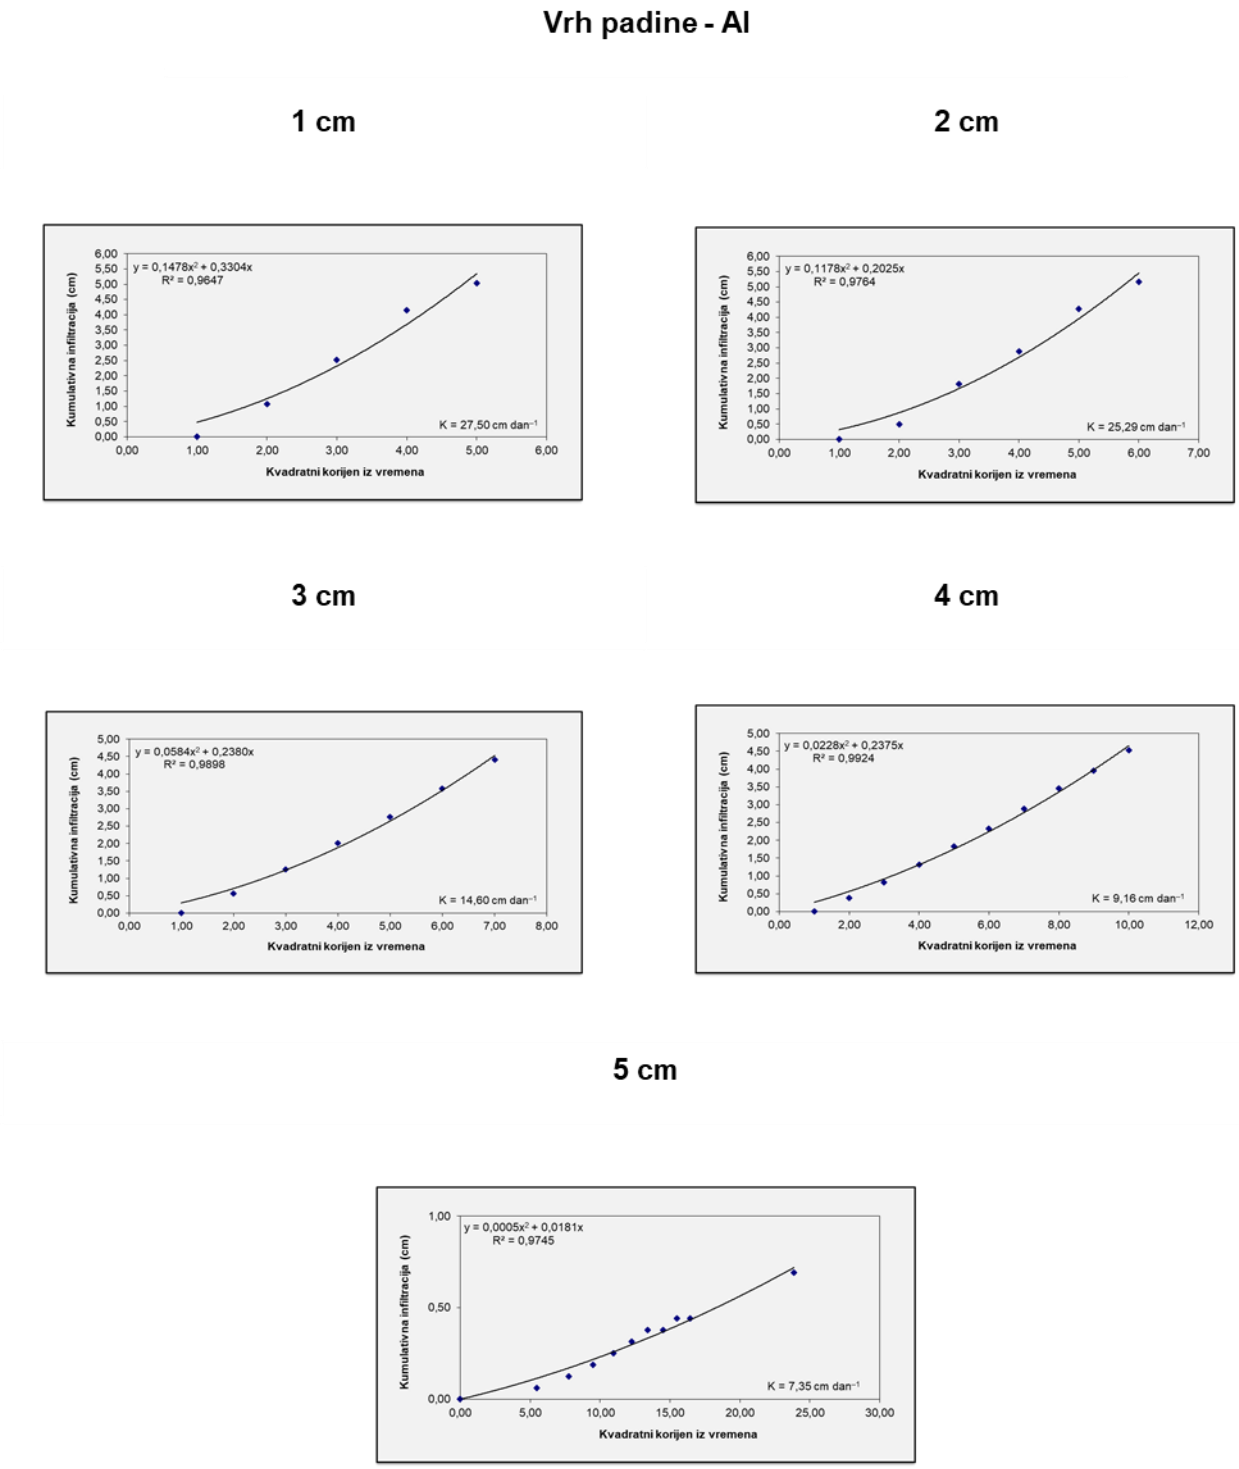

Slika 9.1. Infiltracijska sposobnost tla izmjerena mini disk infiltrometrom pri različitim usisima (1, 2, 3, 4 i 5 cm) na vrhu padine (prva replikacija – AI).

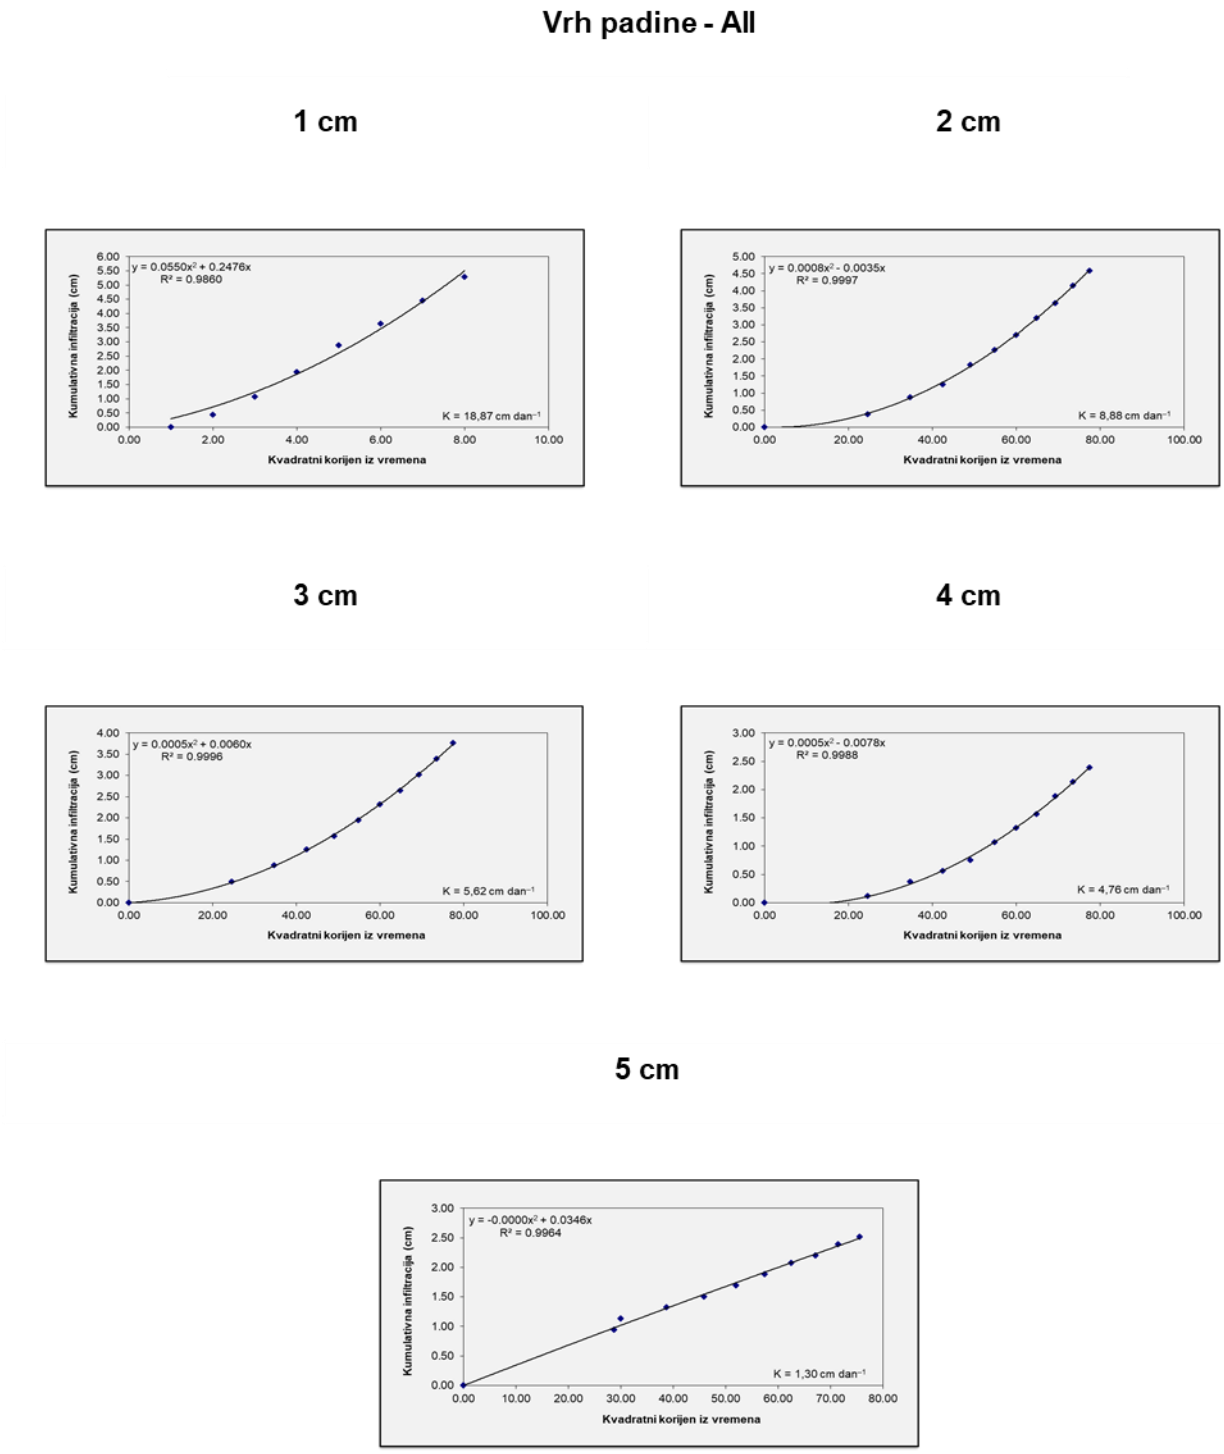

Slika 9.2. Infiltracijska sposobnost tla izmjerena mini disk infiltrometrom pri različitim usisima (1, 2, 3, 4 i 5 cm) na vrhu padine (druga replikacija – AII).

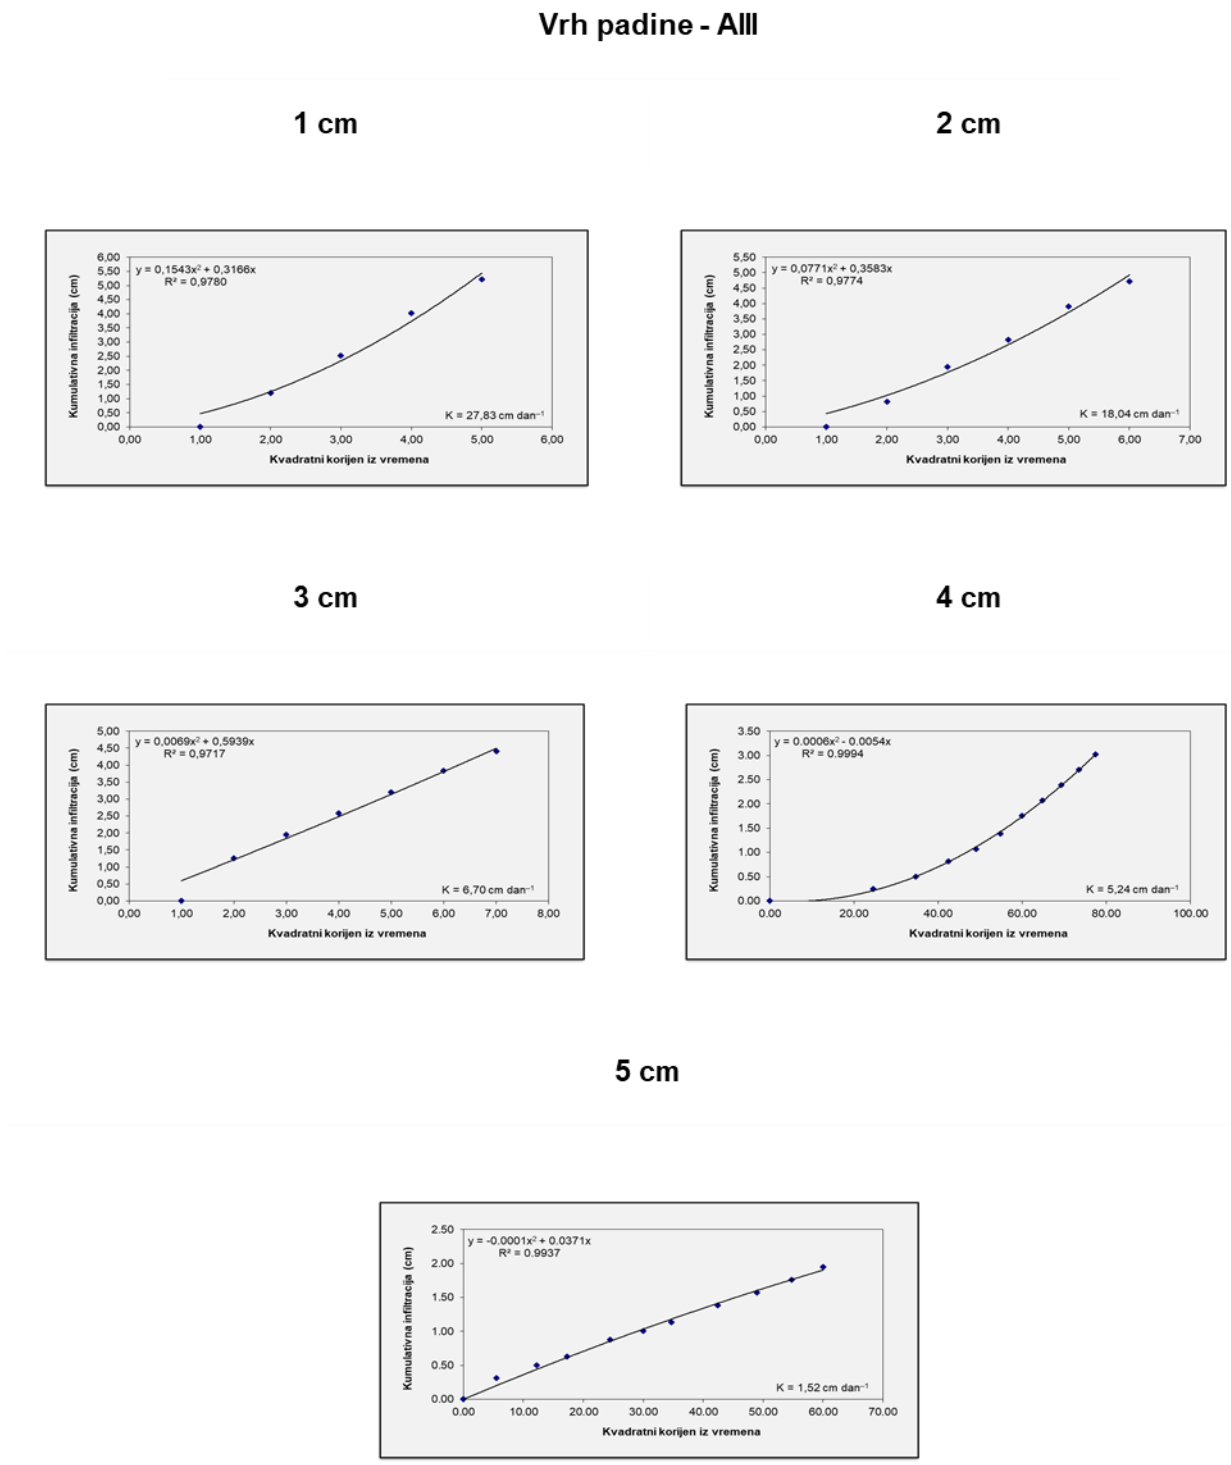

Slika 9.3. Infiltracijska sposobnost tla izmjerena mini disk infiltrometrom pri različitim usisima (1, 2, 3, 4 i 5 cm) na vrhu padine (treća replikacija – AIII).

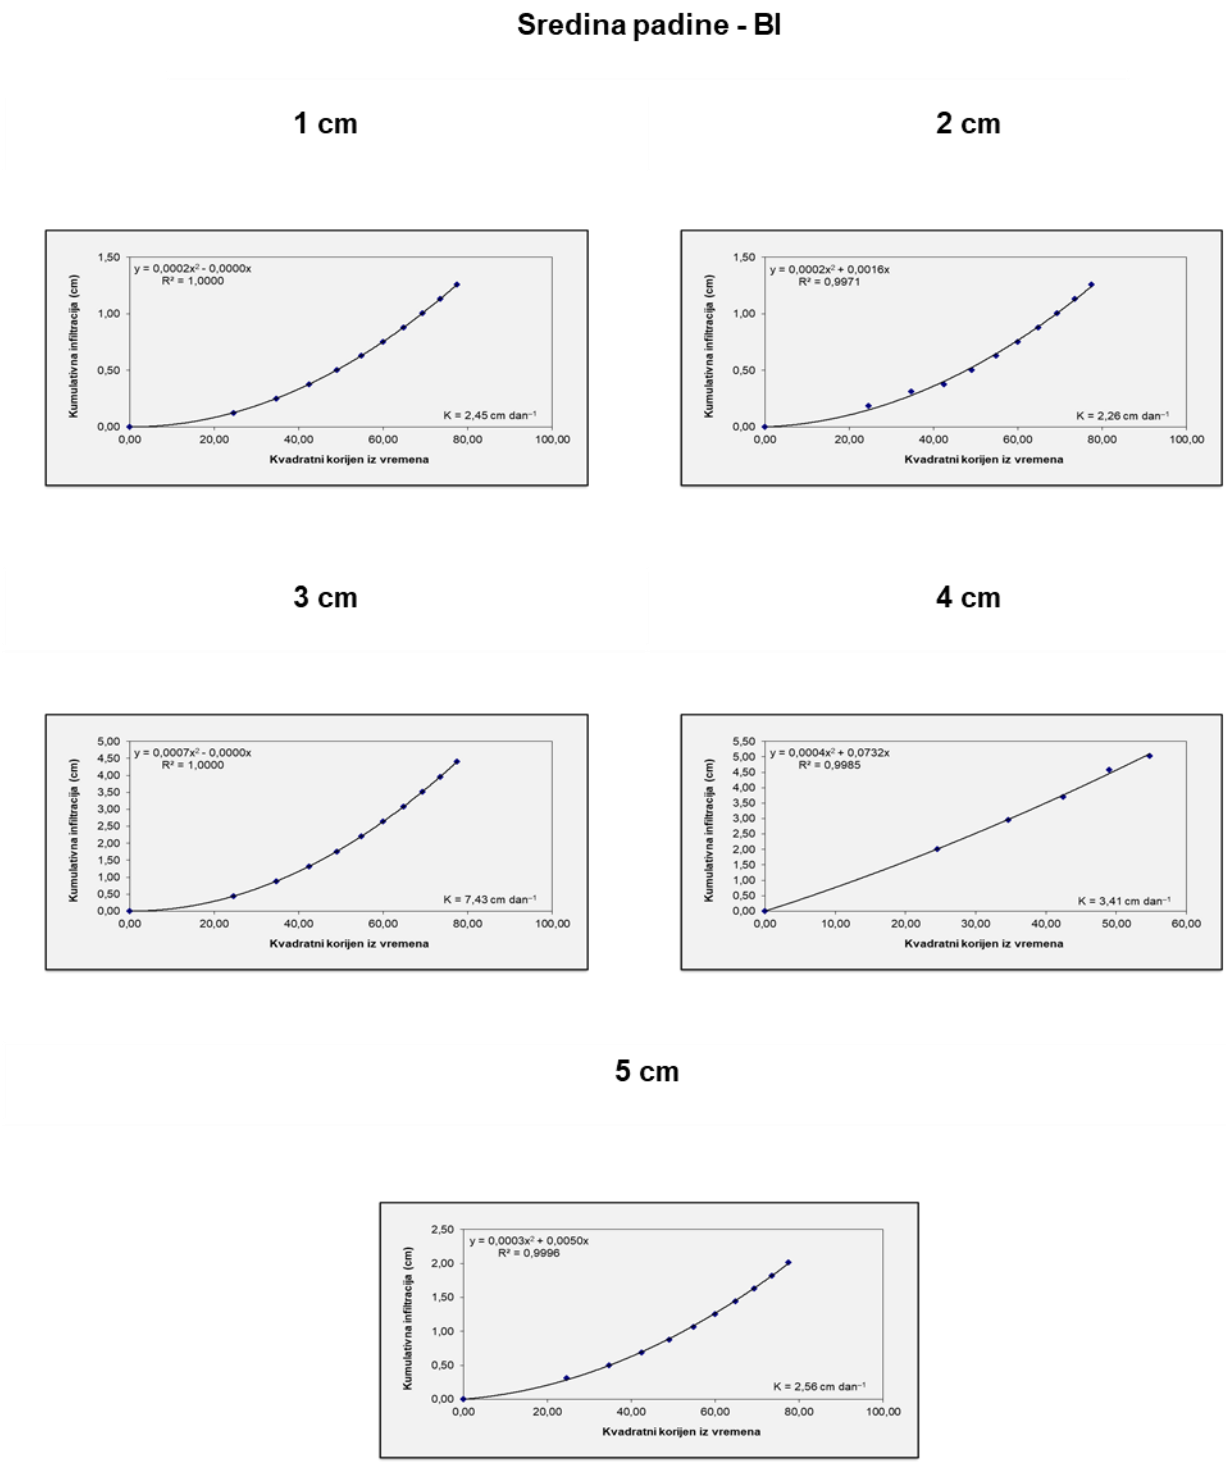

Slika 9.4. Infiltracijska sposobnost tla izmjerena mini disk infiltrometrom pri različitim usisima (1, 2, 3, 4 i 5 cm) na sredini padine (prva replikacija – BI).

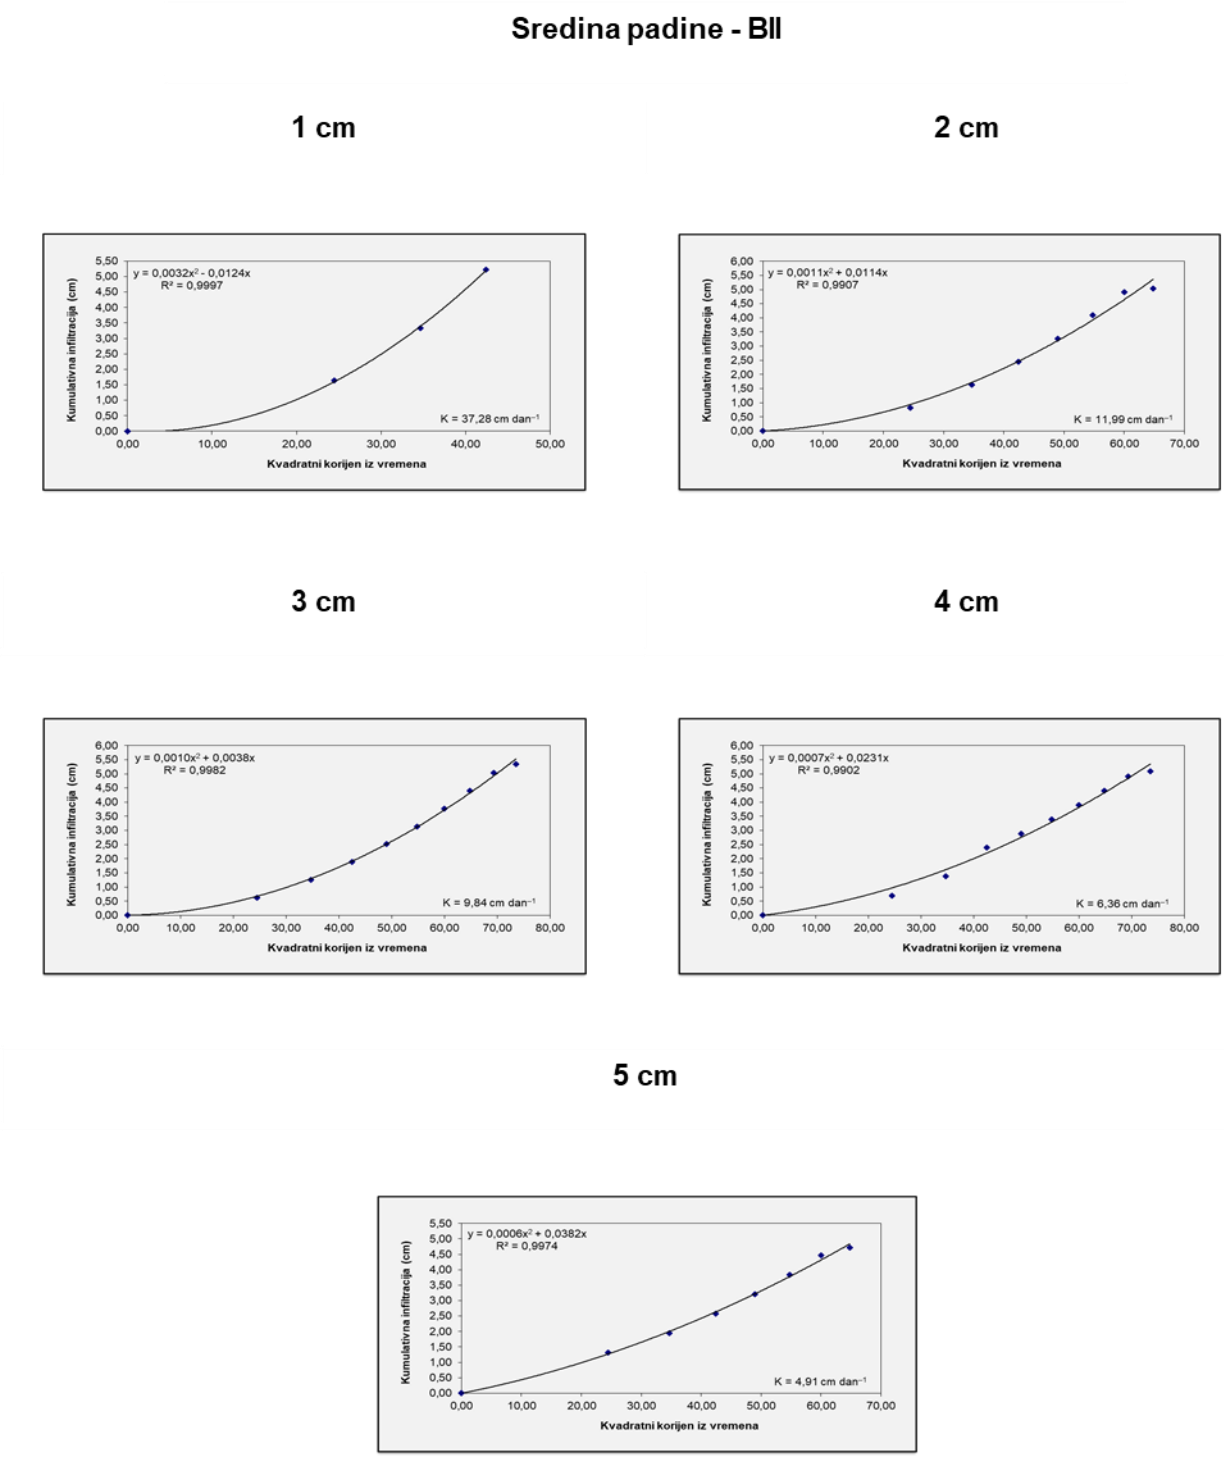

Slika 9.5. Infiltracijska sposobnost tla izmjerena mini disk infiltrometrom pri različitim usisima (1, 2, 3, 4 i 5 cm) na sredini padine (druga replikacija – BII).

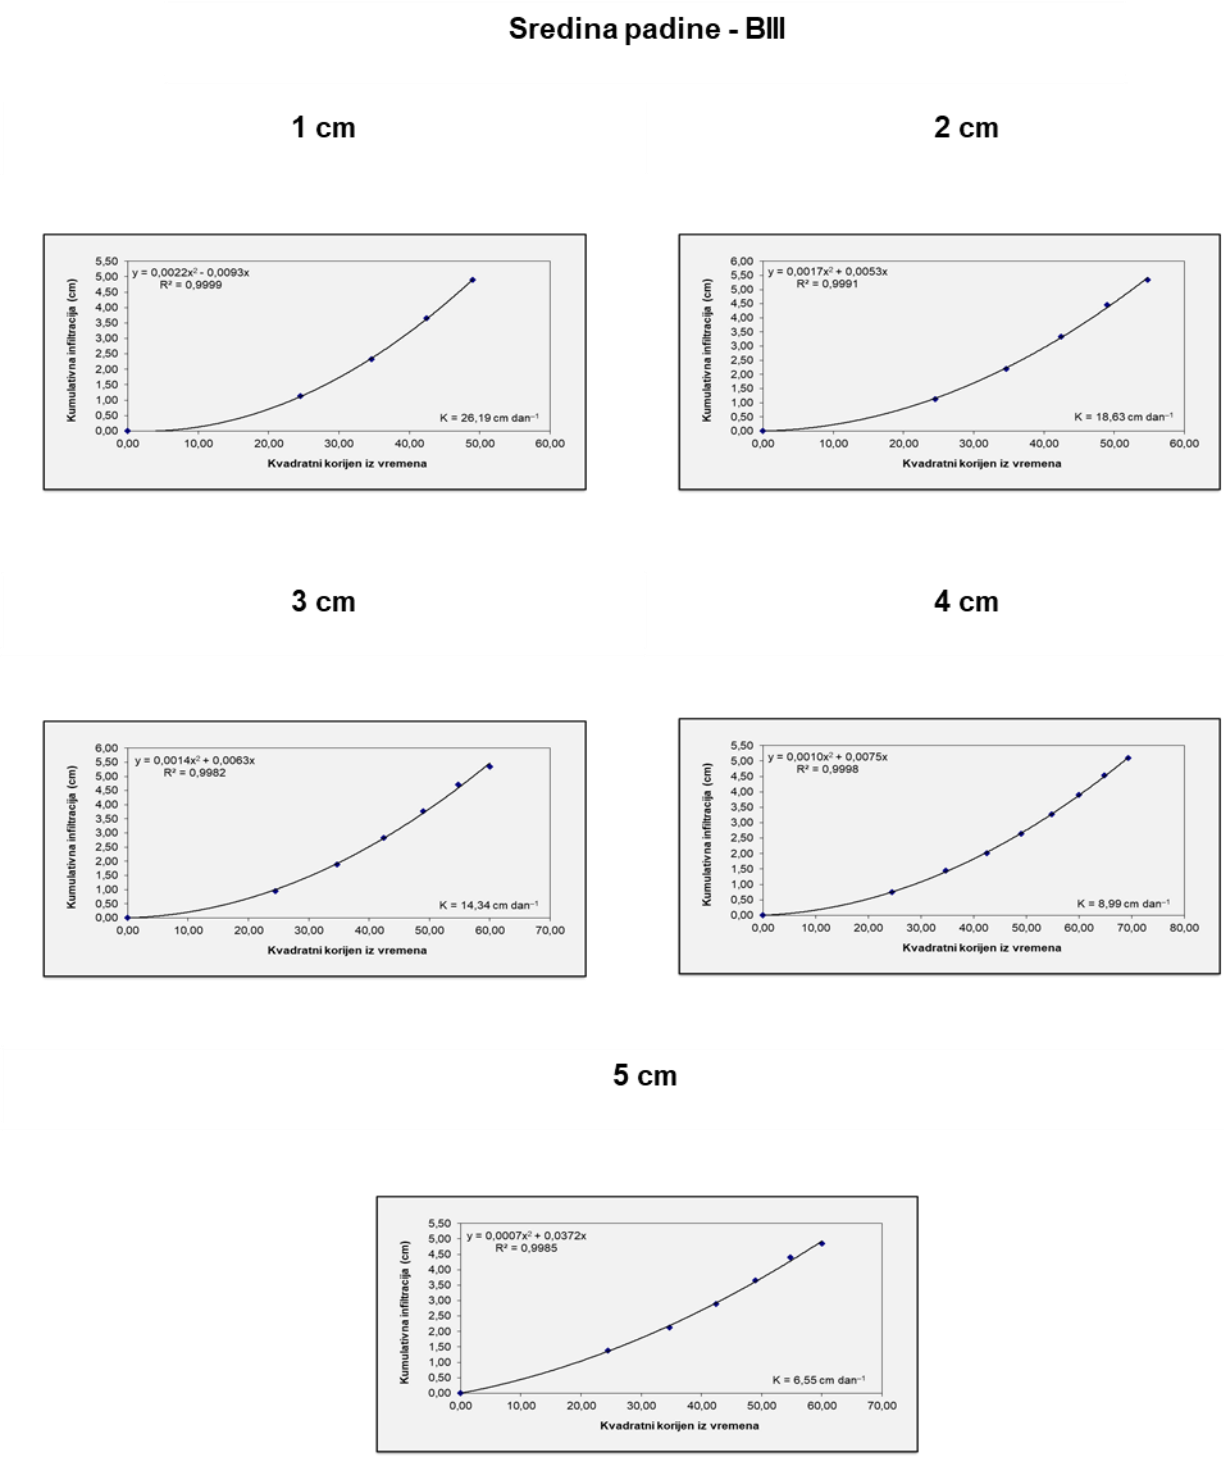

Slika 9.6. Infiltracijska sposobnost tla izmjerena mini disk infiltrometrom pri različitim usisima (1, 2, 3, 4 i 5 cm) na sredini padine (treća replikacija – BIII).

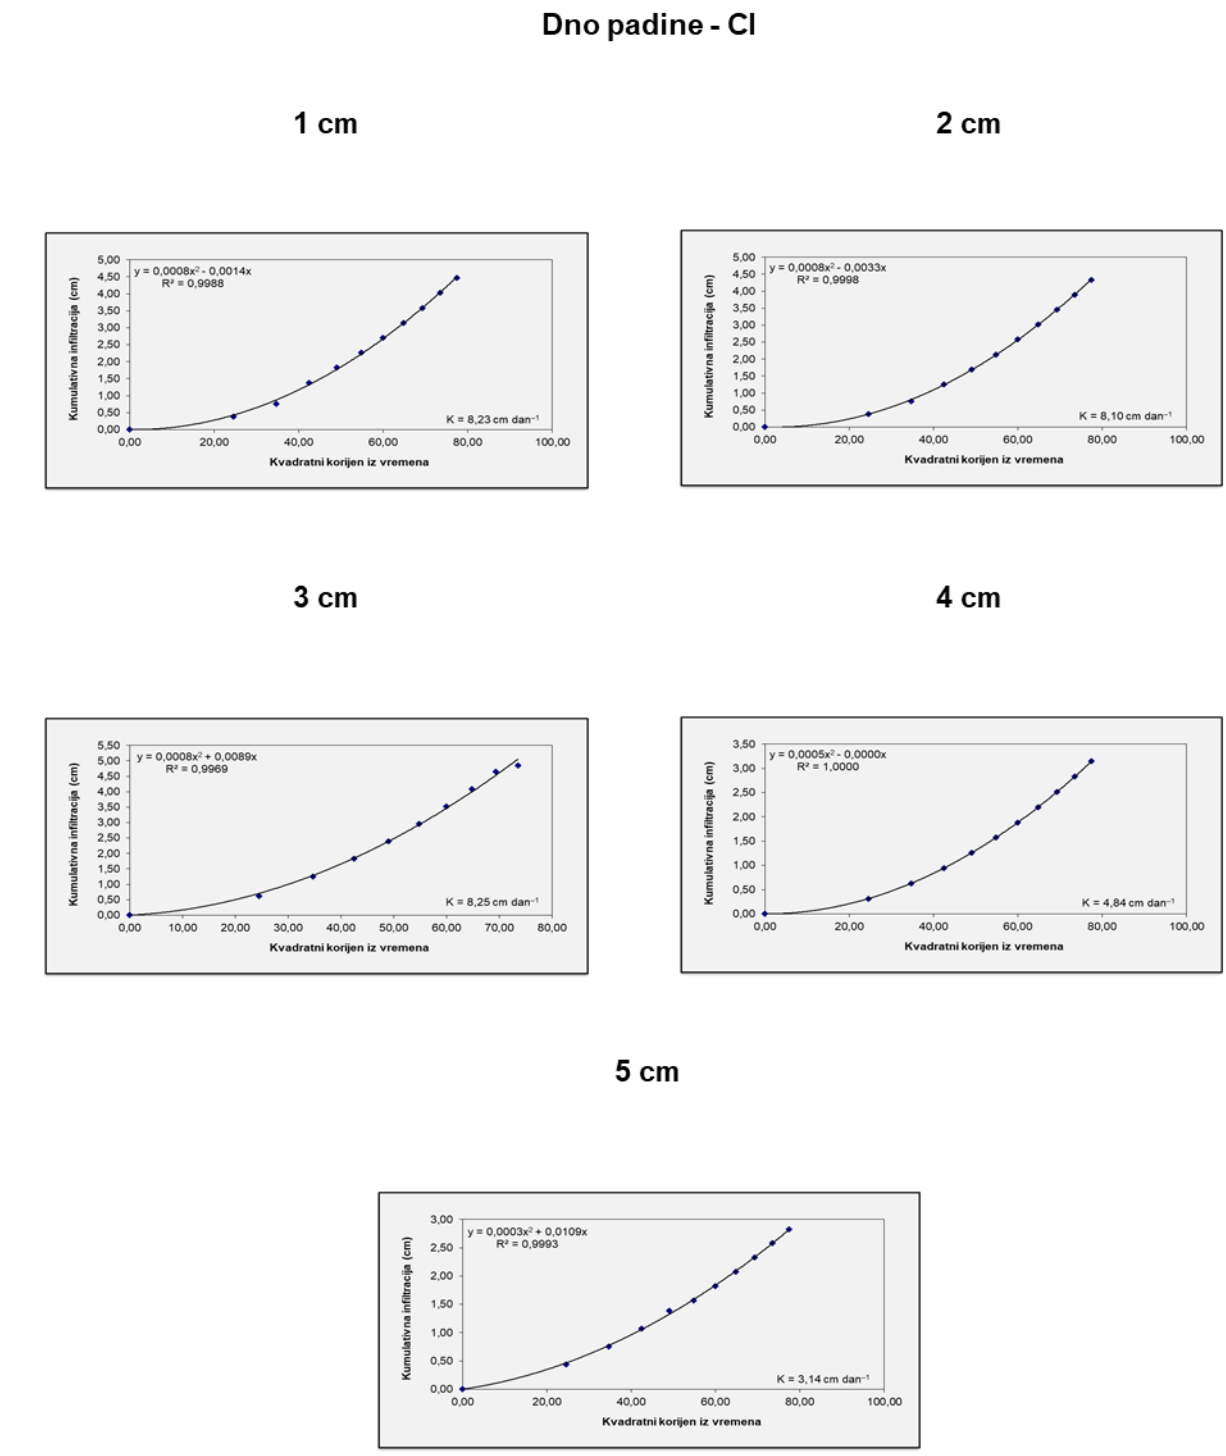

Slika 9.7. Infiltracijska sposobnost tla izmjerena mini disk infiltrometrom pri različitim usisima (1, 2, 3, 4 i 5 cm) na sredini padine (prva replikacija – CI).

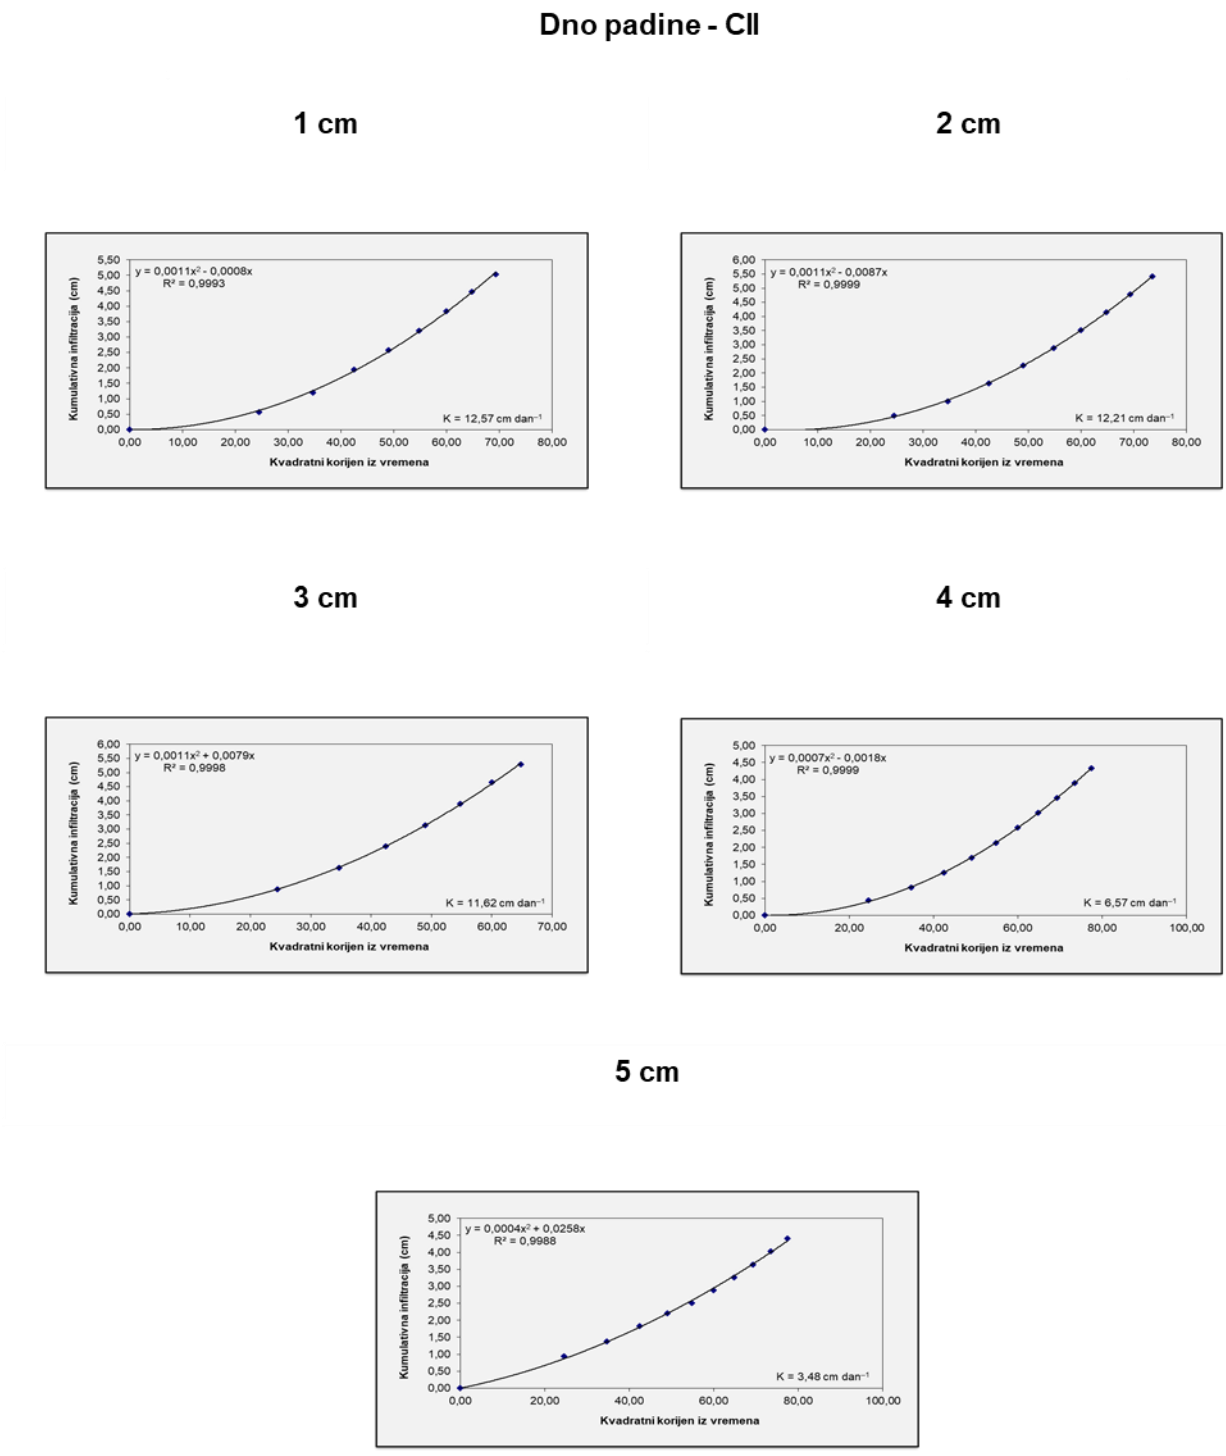

Slika 9.8. Infiltracijska sposobnost tla izmjerena mini disk infiltrometrom pri različitim usisima (1, 2, 3, 4 i 5 cm) na sredini padine (druga replikacija – CII).

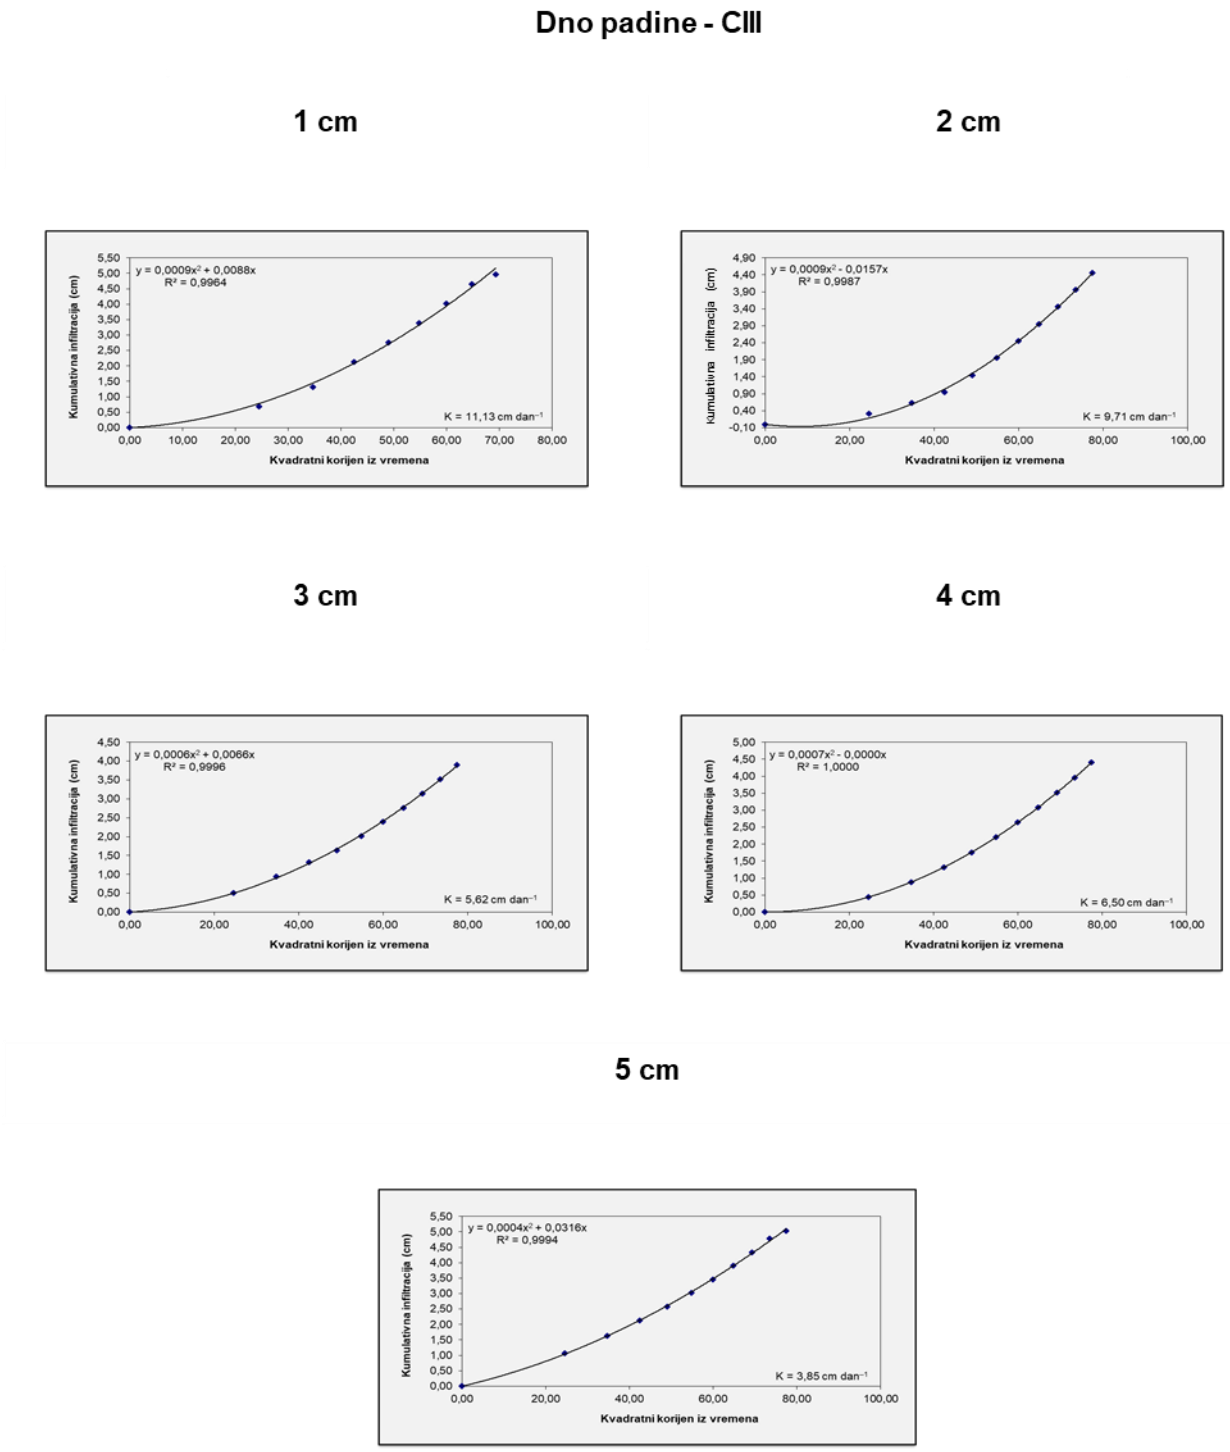

Slika 9.9. Infiltracijska sposobnost tla izmjerena mini disk infiltrometrom pri različitim usisima (1, 2, 3, 4 i 5 cm) na sredini padine (treća replikacija – CIII).

Iz Slike 9.10. jasno je vidljivo drastično smanjenje u poroznosti tla uslijed kompakcije. Propusnost tla za zrak i vodu se smanjila uslijed smanjenja makropora.

a) b)

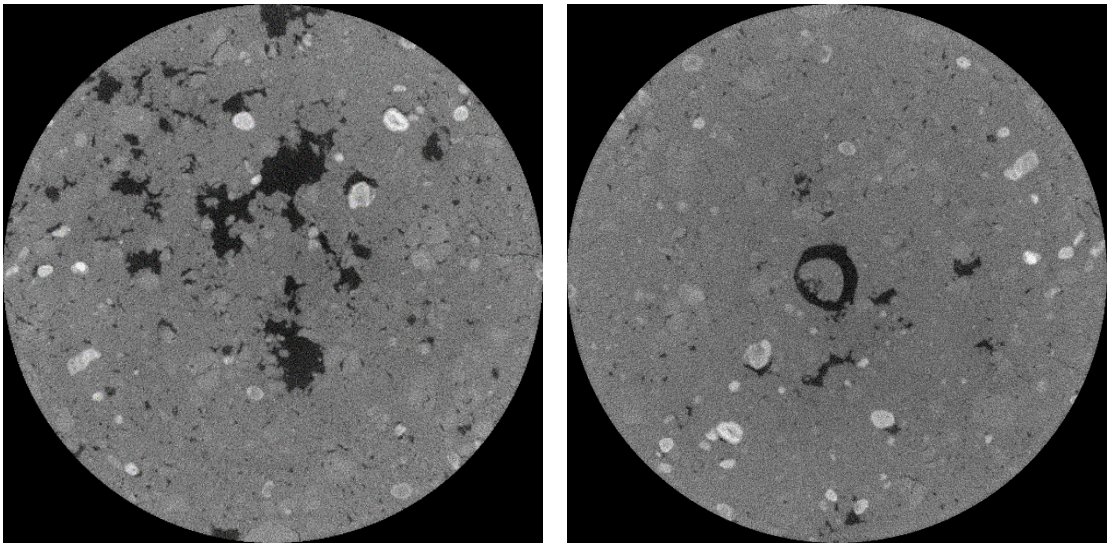

Slika 9.10. Snimke izgleda poroznog sustava na istraživanoj lokaciji snimljenog pomoću kompjutorske tomografije (CT) prije (a) i poslije (b) kompakcije tla.