

Tartu Ülikool
Loodus- ja täppisteaduste valdkond
Ökoloogia ja maateaduste instituut
Botaanika osakond

Marian Klaus

**MASINÕPPE MUDELITE RAKENDAMINE HARILIKU KUUSE (*PICEA
ABIES*) PEENJUURTE KASVU MÕÕTMISEKS ERINEVATEL
MULLATÜÜPIDEL ERINEVATES KLIIMATINGIMUSTES**

Bakalaureusetöö (12 EAP)

Bioloogia ja elustiku kaitse eriala

Juhendajad: Professor Ivika Ostonen-Märtin

Dr. Marili Sell

Tartu 2023

Infoleht

Masinõppe mudelite rakendamine hariliku kuuse (*Picea abies*) peenjuurte kasvu mõõtmiseks erinevatel mullatüüpidel erinevates kliimatingimustes

Kliimamuutused, näiteks temperatuuri tõus, mõjutavad puude kasvu. Mõjutatud on nii maapealsed kui -alused taime osad, millest viimase oluliseks osaks on peenjuured. Kuidas kliimamuutused Eesti puuliikide, näiteks hariliku kuuse (*Picea abies*), juurte kasvu ja talitlust muudavad, ei ole eriti hästi teada. Tänapäeval on tehisintellekti kasutades võimalik lihtsalt ja kiirelt analüüsida pildimaterjali ning õpetada masinõppe programme piltidelt peenjuuri tuvastama ja mõõtma. Käesolev töö viidi läbi kliimakambrites, kus manipuleeriti õhutemperatuuri ja -niiskust. Kuuse istikud kasvasid läbipaistvates pottides, tänu millele sai nutitelefoni juurte kasvumist pildistada. Töö eesmärk oli testida erinevate masinõppe mudelite võimekust hinnata kuuse peenjuurte projektsioonpindala erinevatel mullatüüpidel – orgaanilisel- ja mineraalmullal. Selgus, et puude peenjuured kasvasid kõige paremini orgaanilisel mullal, kuid õhutemperatuuri tõustes juurte pind vähenes. Kui mudeli treenimisel kasutada mõlemas mullas kasvanud taimede juurepilte, on juurte projektsioonpindala ligilähedane referentsile ehk mullatüübi spetsiifilisele mudelile.

Märksõnad: masinõpe, harilik kuusk, peenjuured, kliimamuutused, mineraalmuld, orgaaniline muld

CERCS teadusala kood: B270 Taimeökoloogia

The implementation of machine learning models to measure Norway Spruce (*Picea abies*) fine root growth on different soil types in different climate conditions

Climate change, such as rising air temperature, affects tree growth. It affects both above- and below-ground parts of the tree, of which the fine roots play an important part. There is a lack of information how exactly climate change affects the growth and functions of the roots of different Estonian tree species such as Norway spruce (*Picea abies*). Nowadays, using artificial intelligence, it is possible to easily and quickly analyse images and teach machine learning programs to measure and recognise fine roots on images. The present thesis was carried out in climate chambers with manipulated air temperature and -humidity. The spruce saplings were grown in transparent pots, which made it possible to take pictures of the root growth with a smartphone. The aim of this thesis was to test the ability

of different machine learning models to estimate the root projection area of spruce in different soil types – mineral- and organic soil. It turned out that the fine roots of the trees grew best on organic soil, however, the root area decreased with increased air temperature. The machine learning model that was trained on both soil types estimated the projection area of the roots almost as the reference, which was the soil type specific model.

Keywords: machine learning, Norway Spruce, fine roots, climate change, mineral soil, organic soil

CERCS research field code: B270 Plant ecology

Sisukord

Sissejuhatus.....	5
1. Teoreetiline ülevaade.....	7
1.1. Harilik kuusk ja kliimamuutused.....	7
1.2. Hariliku kuuse peenjuurestik.....	9
1.3. Juurte uurimise tehnoloogiad.....	11
2. Materjal ja metoodika.....	14
2.1. Eksperimendi kirjeldus.....	14
2.2. Peenjuurte pildistamine.....	15
2.3. Mudelite treenimine RootPainteris.....	16
2.4. Mudelite testimine.....	19
2.5. Statistiline analüüs.....	19
3. Tulemused.....	20
3.1. Treeningandmestik.....	20
3.2. Hariliku kuuse peenjuurte projektsioonpindala hindamine erinevate mudelitega..	21
3.2.1. Peenjuurte pindala hinnangud mineraalmullal tehtud piltidele.....	21
3.2.2. Peenjuurte pindala hinnangud orgaanilisel mullal tehtud piltidele.....	24
3.3. Õhutemperatuuri ja -niiskuse töötluste mõju hariliku kuuse peenjuurte kasvule...	27
4. Arutelu ja järeldused.....	28
4.1. Mudelite võimekus juure pindala hindamisel.....	28
4.2. Töötluste mõju.....	30
4.3. Probleemid RootPainteris.....	31
Kokkuvõte.....	32
Summary.....	33
Tänuavaldused.....	34
Kasutatud kirjandus.....	35

Sissejuhatus

Harilik kuusk (*Picea abies* L. Karst.) on hariliku männi ja arukase järel kolmas kõige tavalisem enamuspuliik Eesti metsades, moodustades peaaegu 19% kogu metsamaa pindalast (Valgepea jt, 2023). Harilik kuusk on Euroopas, sealhulgas ka Eestis, oluline puliik, mille puitu kasutatakse nii ehituseks kui ka paberitootmise toorainena (Farjon, 2010). Harilik kuusk kasvab hästi nii orgaanilistel kui mineraalmuldadel ning olgugi et peapuuliigina eelistab kuusk viljakaid kasvukohti, siis kasvukoha suhtes ei ole kuusk väga valiv ning kasvab ka männikutes ja kaasikutes teise rinde puuna (Lõhmus, 2004).

Taim kinnitub mulda juurtega. Lisaks sellele on juured olulised ka vee ja toitainete omastamiseks ning transpordiks maapealsetesse organitesse. Vee ja toitainete omastamise seisukohalt on peenjuured, milleks loetakse < 2 mm läbimõõduga juuri, juurestiku kõige olulisem osa. Peenjuurtesse võib kirjanduse andmeil kuluda kuni 75% puu aastasest netoprimaarproduktioonist (Finer jt, 2011). Peenjuured on lühiealised ja sisaldavad talituslikult erinevaid juuri, millest imijuured moodustavad ektomükoriisaseentega sümbioosi ning tagavad vee ja mineraalainete omastamise mullast. Seetõttu on kõige peenemat osa juurestikust eriti oluline, samas ka väga keeruline uurida, sest juured on plastilised, keskkonnamuutustele vastuvõtlikud ning mullas peidus. Juurte kohta on vähem andmeid kui maapealsete osade kohta, eelkõige kuna nende mõõtmiseks tuleb nad loomulikust kasvukeskkonnast eemaldada, mis võib juuri kahjustada.

Lisaks on juurte kasvu hindamine väga aja- ja ressursi kulukas (Hänninen, 1990; Rewald jt, 2020; Vamerali jt, 2011). Olgugi et mitukümmend aastat tagasi tulid turule minirisotronid (Lukac, 2012), millega sai juuri regulaarselt pildistada, siis pildidel annoteeriti juuri siiski käsitsi, mis erilist ajavõitu juureanalüüsile ei andnud. Viimaste aastate tehnoloogiline areng võimaldab peaaegu reaajas jälgida ja mõõta juurte kasvu. Andmete analüüsi tööprotsess on kiirem, kui kasutada masinõppe programme, mida õpetades suudab programm ise juuri heterogeenselt taustalt tuvastada ning mõõta juurte pindala ja pikkust (Bauer jt, 2022). Masinõppe programmi tulemus on küllaltki sarnane manuaalsele juurte annoteerimisele, kui katses on puud kasvanud ühel mullatüübil (Sell jt, 2022b). Oluline on teada saada, kas mullatüüpide erinevus mõjutab masinõppe programmide võimekust juuri analüüsida.

Töö eesmärk on testida erinevate masinõppe mudelite võimekust hinnata hariliku kuuse peenjuurte kasvu erinevatel mullatüüpidel (orgaanilisel ja mineraalmullal) erinevates kliimatingimustes. Töö hüpoteesid on järgnevad:

- 1) Hariliku kuuse peenjuurte kasvu ei saa erinevatel mullatüüpidel hinnata sama masinõppe mudeliga: orgaanilisel mullal kasvanud juurepiltidega väljatöötatud mudel ei määra juurte projektsioonpindala sama hästi mineraalmullal ja vastupidi.
- 2) Mudeli väljatöötamine eri mullatüüpide baasil tagab selle kasutatavuse liigispetsiifiliseks juurekasvu hindamiseks.
- 3) Kõrgema õhutemperatuuri ja madalama suhtelise õhuniiskuse tingimustes väheneb juurte kasv mõlemal mullatüübil.

1. Teoreetiline ülevaade

1.1. Harilik kuusk ja kliimamuutused

Harilik kuusk on laialt levinud Põhja-Euroopa boreaalsetes okasmetsades, kuid teda leidub ka Kesk-Euroopas (Skrøppa, 2003). Harilik kuusk eelistab pigem viljakaid muldi (Lõhmus, 2004), kuid saab tänu oma pindmisele juurestikule hakkama ka niiskematel kasvukohtadel. Kuigi kuusk ei ole väga valiv oma kasvukoha suhtes, kasvab enamasti puudest happelistel muldadel (Farjon, 2010). Näiteks esineb teda laanemetsades (sinilille, jänese kapsa, jänese kapsa-mustika kasvukohatüübid), palumetsades (pohla, mustika, jänese kapsa-pohla kasvukohatüübid), salumetsadest naadi kasvukohatüübis, soovikumetsadest angervaksa kasvukohatüübis ja loometsadest kastikuloo kasvukohatüübis (Lõhmus, 2004). Kaks kasvukohatüüpi, kus enamasti puuliigiks on tavaliselt kuusk, on näiteks jänese kapsa- ja jänese kapsa-kõdusoo kasvukohatüüp. Jänese kapsa kasvukohatüüp esineb tavaliselt küngastel või tasandikel ning mulla lähtekivimiks on karbonaativaene saviliiv või liivsavi-moreen. Sealne muld on hea dreneažiga ning värske. Jänese kapsa kasvukohatüübis esinevad tavaliselt leetunud ja näivleetunud mullad. Jänese kapsa-kõdusoo kasvukohatüüp esineb pikaajalise kuivendamisega siirdesoo muldadel. Muld on tavaliselt nõrgalt happeline ning värske kuni niiske (Laas & Becker, 2021).

Eestis kasvab suurem osa kuusikutest mineraalmuldadel ja üle 10% kasvab orgaanilistel kõdusoometsade (kuivendatud) muldadel (Valgepea jt, 2023). Orgaanilistel muldadel ehk turvas- ja turvastunud muldadel on õhuke kuni tüse orgaanilise aine kiht, mis on vastavalt üle 40 cm või alla 30 cm paksune. Orgaanilistel muldadel on mineraalosa sisaldus alla poole mullast ning nad hoiavad väga hästi vett. Selliste muldade kuivendamisel hakkab pika aja jooksul akumulunud orgaaniline aine lagunema ning muutunud vee- ja toitainete režiim toetab oluliselt puude kasvu paranemist (Skaggs jt, 2016).

Mineraalmullad on savi sisseuhtega mullad. Vastandina orgaanilisele mullale on mineraalmullas ülekaalus mineraalained. Üheks mineraalmulla tüübiks tüüpilistes jänese kapsa-kuusikutel on näivleetunud (kahkjad) mullad, mis on parasniisked ning happelised. Kahkjate muldade looduslikuks taimkatteks on hõreda alusmetsaga laanemetsad sealhulgas jänese kapsa- ja jänese kapsa-mustika kuusikud (Lõhmus, 2004). Kuusikute produktsioon on nendes kasvukohatüüpides ning nendel muldadel Eesti kõrgeim (Kõlli jt, 2018).


Kliima soojenemise suurenedes prognoositakse kuumalainete sageduse, intensiivsuse ja kestuse suurenemist. Ka põudade sagedus ja intensiivsus suureneb (Shukla jt, 2019), mis võib mõjutada liikide reaktsioone. Harilik kuusk on eriti haavatav suviste põudade suhtes ning ka pikema taastumisajaga kui harilik mänd (Aldea jt, 2022). Enamus kuuse juurtest on pindmises 20–40 cm mullakihis ning on selle tõttu keskkonnamuutuste poolt rohkem mõjutatud kui teised okaspuud (Puhe, 2003). Näiteks on kuusk oma pindmise juurestikuga tormihell, eriti orgaanilistel muldadel. Kuuskedel on üheks tähtsaimaks kahjuriks kuuse-kooreürask (*Ips typographus*), kes põhjustab puude kuivamist. Üraskite arvukus võib muutuda väga suureks kahjustatud (näiteks põua, tormi või tuule poolt) metsades. Põudade suurenemine on ka Eestis üraskite kahjustusi suurendanud (Kuuse-kooreürask, 2022).

Eestile ennustatakse kliimamudelite järgi tulevikus oluliselt soojemat ja niiskemat ilmastikku (Jaagus & Mändla, 2014). See, kuidas reageerivad kliimamuutustele Eesti metsapuud, pole veel täpselt selge. Atmosfääri ja lehe vahel olevad õhuniiskuse ja veeauru rõhu muutused mõjutavad kogu puu kasvu. Näiteks väheneb õhuniiskuse suurenemisel transpiratsioonivoog erinevatel Eestis kasvavatel puuliikidel, sealhulgas ka harilikul kuusel (Sell jt, 2022a). Taimestiku hooajalist aktiivsust kirjeldab taimede fenoloogia (Cleland jt, 2012). Fenoloogilise arengu ja kasvu vaheliste seoste uurimine on väga oluline, et mõista, kuidas ilmastik taimede kasvu maa peal ja -all mõjutab (Zohner jt, 2021). Viimase kolme kümnendi jooksul on puud järjest varem õide ja lehte puhkenud (Fu jt, 2014). Puu maapealsed ja -alused osad reageerivad muutuvatele tingimustele erinevalt (Kilpeläinen jt, 2019). Pungade puhkemine toimub kasvuperioodi alguses ning uute lehtede teke toimub ainult kasvuperioodil, samas kui juured kasvavad pidevalt terve aasta vältel ning neil võib kasvuperioodil mitu kasvupiiki olla (Niinemets & Ostonen, 2020). Kõige suurema ebamäärasusega on ökosüsteemide maa-aluse osa hinnangud, sealhulgas juurte kasvuga seotud hinnangud. Väga vähe teatakse juurte fenoloogiast ja seda, kuidas see võib kliima muutustele reageerida (Radville jt, 2016). Näiteks võib juurte vananemise algus nihkuda varasemaks, kui puud kasvavad kõrge suhtelise õhuniiskusega keskkonnas (Sell jt, 2022b). On oluline uurida juurte kasvudünaamikat ja vananemist, et mõista puude süsiniku ja toitainete ringlust ning seda mõjutavaid tegureid (Niinemets & Ostonen, 2020).

1.2. Hariliku kuuse peenjuurestik

Juurte klassifikatsioone on erinevaid. Traditsiooniliselt jagatakse puude juuri kaheks – peenjuured, mille diameeter on alla kahe millimeetri, ja jämedad juured (> 2 mm). Jämedad juured on puitunud, pikaealised ning nendest hargnevad peenemad külgsuured. Peenjuured on lühiealised ning uuenevad, surevad ja varisevad pidevalt. Samuti on nende kasv dünaamiline, muutes nende uurimise raskemaks. Peenjuured sisaldavad peenikesi puitunud sekundaarse struktuuriga juhtejuuri ning puitumata primaarse ehitusega imijuuri. Peenjuured moodustavad küll biomassist väikese osa, kuid enamuse juurepinnast (Ostonen, 1997). Seega on peenjuurtel väga tähtis roll toitainete omastamisel. Talituslikult eristuvad juuretipud kaheks – pikad, nii-öelda piiramatu kasvuga juured, millel on võimalik ka sekundaarne kasv, ja lühikesed piiratud kasvuga juured, millel sekundaarne kasv puudub või on piiratud. Seda nimetatakse heteroriisiaks (Kubiková, 1967). Peenjuuri saab veel omakorda jagada peeneteks puitunud ja sekundaarse ehitusega juhtejuurteks (transportjuured) ning primaarse ehitusega imi- ja kasvujuurteks (Joonis 1). Juhtejuured on tavaliselt pikad ja pikaealised, nende peamine ülesanne on toitainete transport ning nad ise eriti ei omasta vett ega toitaineid (Pregitzer jt, 2002). Juhtejuured kujunevad kasvujuurtest ning juure pikenenemisvõttes võib esineda ka juurekarvu. Juurekarvad suurendavad juure imavat pinda ning nad suudavad tungida ka peenetesse mulla kapillaaridesse, kuhu juured ise ei mahu. Tänu juurekarvadele suureneb juurte mineraalainete ja vee absorptsioon mullast.

Imijuurte peamiseks ülesandeks on puu varustamine mineraalainete ja veega (Persson, 1992) ning kasvujuurte ülesandeks on juurestiku laiendamine. Kasvujuurted on kiirekasvulised, teravatipulised ning juur ise on võrreldes imijuurtega jämedam. Imijuurte kasv on aeglane ja limiteeritud ning neil esineb esikoor, mis on imavate omadustega. Imijuured on tõmbi tipuga, lühikesed ja peenemad kui 0,5 mm. Nad moodustavad mullas elavate mükoriisaseentega sümbioosi ning sageli määrab just koloniseeriv seeneliik imijuure kuju ja kasvukiiruse (Ostonen jt, 2009). Hariliku kuuse imijuured on tavaliselt ektomükoriissed. Ektomükoriisse kolonisatsiooni puhul tungivad seenehüüfid juure esikoore rakkude vahele, kuid ei tungi nende sisse. Koloniseeriv seen saab taimelt assimilaate (4–20% süsinikust) ning taim saab seenelt vett, antibiootikume ja mineraalaineid (näiteks fosforit) (Clemmensen jt, 2013).



Joonis 1. Hariliku kuuse peenjuurte liigitus (kasvu-, imi- ja juhtejuured) orgaanilisel mullal.

Peenjuuri liigitatakse ka järkude põhiselt, kus esimene järk on juuretipp ning teine, kolmas jne juba edasised ülenevad harud (Guo jt, 2004; Pregitzer jt, 2002). Puudel on esimese kuni kolmanda järgu juured suure imamismõimega ja lühiealised (mõnest nädalast paari aastani), nende metaboolne aktiivsus ning hingamine on intensiivne ning nad on kõrge lämmastiku sisaldusega. Esimest ja teist järku juured vastavad enamasti talituslikult imijuurtele. Paljudel puuliikidel esineb kolmandat järku juurtes juba puitumist ning sellepärast loetakse neid juba üleminekuks juhtejuurtele. Alates viiendast järgust vastavad juured talituslikult juhtejuurtele, nende eluiga on pikem – mida jämedamad juured, seda kauem nad elavad (Guo jt, 2004).

Kõik taime juured moodustavad kokku juurestiku. Kuuse juurestik on pindmine ehk enamus täiskasvanud kuuse külguurtest on maapinna lähedal. Juurte üleüldiseks ülesandeks, peale toitainete omastamise, on taime kinnitamine mulda ning vee ja toitainete transportimine maapealsetesse organitesse. Samuti mõjutavad juured mulla abiootilisi ja biootilisi omadusi, näiteks veevarude ümberpaigutamist või elurikkust mullas (Centenaro jt, 2018). Hariliku kuuse juured moodustavad erinevatel andmetel umbes 12–25% puu kogumassist (Helmisaari jt, 2002; Ostonen, 1997). Mida vanem on puu, seda väiksem osakaal on juurestikul kogu puu biomassi suhtes (Helmisaari jt, 2002). Näiteks on istikute

peenjuurte osakaal umbes 60% kogu maa-alusest biomassist, kuid täiskasvanud puul kahaneb peenjuurte proportsioon 2–13%-ni (Brunner & Godbold, 2007; Helmisaari jt, 2002). Enamuse juurestiku biomassist moodustavad jämedad juured, mille osakaal suureneb puu vananedes ning peenjuurte osakaal väheneb vastavalt (Helmisaari jt, 2002).

Taimede juurte kohta on teaduskirjanduses oluliselt vähem andmeid võrreldes maapealse biomassi mõõtmistega. Neid on raskem mõõta ning uurida, sest juured kasvavad mullas, neid ei ole näha ning mõõtmiseks tuleb nad nende tavapärastest kasvukeskkonnast eemaldada (Hänninen, 1990; Rewald jt, 2020; Vamerali jt, 2011). Kuna juuri ei ole näha, on ka nende talitlust raskem uurida. Näiteks on imijuurte vananemise füsioloogilisi ja molekulaarseid mehhanisme väga vähe uuritud võrreldes puude lehtede vananemise uurimisega (Wojciechowska jt, 2020). Samas on juurte omadusi ja talituslikke iseärasusi, nagu näiteks nende eluiga, kasvu, massi ja muutumist mulla orgaaniliseks aineks, erakordselt oluline mõista just aineringete kirjeldamisel ja hindamisel. Peenjuurte vananemine ja suremine on palju keerulisem kui lehtedel erinevate hooajaliste kasvamisustrite tõttu. Juured lagunevad palju aeglasemalt kui lehed ning lämmastiku resorptsioon on juurtes madal (Niinemets & Ostonen, 2020). Selle tõttu pole ka palju andmeid võrsete ja juurte samaaegsetest fenoloogilistest vaatlustest ja mõõtmistest (Helmisaari jt, 2002 ; Zohner jt, 2021).

1.3. Juurte uurimise tehnoloogiad

Taimede juurte uurimismeetodeid on pidevalt arendatud ning arvestatud on ennekõike, et uued meetodid oleksid vähem juurte kasvu häirivad ning aeganõudvad, aga samas ka mitte liiga kallist tehnikat vajavad (Zohner jt, 2021). Tavaliselt on juurte mõõtmismeetodid olnud destruktiivsed ehk selleks, et juuri mõõta, kaevatakse juured mullast välja (Schuurman & Goedewaagen, 1965). Mittedestruktiivseks on loetud mitmesuguseid läbipaistva akna abil tehtavaid uuringuid, kus juurte kasvu pildistatakse ning analüüsitakse piltidelt. Näiteks on selliseks kliimakambri katsed, kus testitakse väga sageli erinevate keskkonnategurite mõju taimede kasvule, talitlusele ning protsesside kohanemisele muutunud keskkonnaga. Kliimakambrite eelis on kontrollitavad tingimused ning võimalus manipuleerida erinevaid tegureid ükshaaval või korraga. Samuti ei pea potikatsetes juuri nende kasvu mõõtmiseks mullast eemaldama, vältides sellega juurte kahjustamist. Teiseks variandiks on näiteks minirisotronide kasutamine. Minirisotronide meetod tähendab, et mulda sisestatakse läbipaistvad torud, mida mööda liigutatakse väikest kaamerat, mis

fikseeritakse korduvatel mõõtmistel sama koha peal, ning pildistatakse juuri. Hiljem mõõdetakse ja analüüsitakse piltidel olevaid juuri (Bauer jt, 2022). Samas on minirisotronide meetod endiselt ajakulukas ning spetsiaalne kaamera on kallis ja korduvate piltide tegemiseks peab proovialale naasma kindlate ajavahemike tagant. Lisaks on senini juuri mõõdetud sellistelt piltidelt manuaalselt, mis on väga ajamahukas ja rutiinne töö (Sell jt, 2022b).

Üheks uudsemaks ja kiiremaks viisiks piltidelt juurte tuvastamiseks ja mõõtmiseks on masinõppe meetodil põhinevate programmide kasutamine. Tänapäevaks on välja arendatud mitmeid erinevaid programme, mis suudavad juuri tuvastada ainult homogeenisel taustal ehk juured ei kasva mullal, vaid näiteks seemne idanemine laboris steriilsel meediumil (lahus, agar) või paberil. Teisalt on kättesaadavad kommertsiaalsed programmid, mis on arendatud ainult minirisotronide kaamera poolt tehtud piltide jaoks. Näiteks WinRhizo TRON või RhizoTrak, mille kasutamisel on pildi analüüsimiseks vaja ka inimest, kes käsitsi piltidelt juuri tuvastaks ja anoteeriks (Bauer jt, 2022).

Uuemad programmid, näiteks nagu RootPainter, suudavad juuri tuvastada ka heterogeenselt taustalt (Smith jt, 2022). RootPainter on tasuta tarkvara, mis on mõeldud konvolutsionaalsete närvivõrkude (CNN) treenimiseks. Programm töötab Google Colaboratory abil ehk läbi selle saadetakse andmed Google'i serveritesse, kus toimuvad arvutused. Programm on täielikult kättesaadav ka inimestele, kellel puudub kogemus programmeerimisega, tänu lihtsale graafilisele kasutajaliidesele (GUI). Lisaks on RootPainteril eeliseks see, et ta on laialdasemaks kasutamiseks mõeldud. Näiteks ei pea uurimine piirduma ainult juurtega, vaid võib uurida ka näiteks juuresõlmi, biopore või lehti (Smith jt, 2022). RootPainter tekitab peale juurte tuvastamist nendest binaarpildi, see tähendab, et juured on mustalt ja taust on valge. Binaarpilti on võimalik lihtsamini analüüsida, näiteks üks teine vabavara RhizoVision Explorer on võimeline arvutama lisaks juure projektsioonpindalale ka keskmise juure pikkuse, diameetri ja juuretippude arvu (Seethepalli jt, 2021).

Analüüsitavate juurepiltide tegemiseks on siiani kasutatud erinevaid võimalusi – kaameraid, skännereid, aga ka nutitelefone. Nutitelefone kasutamine annab sama täpseid tulemusi kui professionaalse kaamera kasutamine (Mohamed jt, 2017). Seega on nutitelefoni potentsiaalsetes pildistamises kuluefektiivsem, kui spetsiaalne kaamera puudub. Kuigi piltidele võib jääda peegeldusi, veepiisku, kriimustusi ja muid võõrkehi, suudavad tänapäevased masinõppe programmid õppida neid vältima (Sell jt, 2022b).

Selleks, et RootPainteriga juuri analüüsida, tuleb kõigepealt treenida masinõppe mudel. Laialdasemaks RootPainteri kasutamiseks on mõistlik kasutada juba varasemalt treenitud mudeleid. Kuna iga liigi juurestik on erinev, on igale liigile vaja eraldi mudelit (Han jt, 2021; Phenome Force, 2022). Selleks, et analüüsida juurte kasvu liigisiselt erinevatel mullatüüpidel, peab programm suutma juuri tuvastada erinevat tüüpi taustadelt. Teadaolevalt on RootPainteri programmiga analüüsitud juurte kasvu vaid sellistes katsetes, kus kõik taimed on kasvanud samal mullatüübil või siis on mudeli treenimiseks kasutatud pilte kõigilt erinevatel mullatüüpidelt (Alonso-Crespo jt, 2023; Bauer jt, 2022; Han jt, 2021, 2022; Sell jt, 2022b; Smith jt, 2022). Kui laialdasemaks kasutamiseks tahetakse teha igale liigile ainult üks välja treenitud mudel, siis tekib olukord, kus juuri analüüsitakse sellise mudeliga, mille treenimiseks pole kasutatud täpselt samasuguse taustaga juurepilte nagu analüüsis. Selle tõttu oleks oluline teada, kuidas erinevad mullatüübid mõjutavad RootPainteri võimekust juuri tuvastada.

2. Materjal ja metoodika

2.1. Eksperimendi kirjeldus

2022. aasta veebruarist kuni maini viidi läbi eksperiment kliimakambrites (Percival AR-95 HIL (Percival Scientific Inc., USA)) kolmeaastaste hariliku kuuse (*Picea abies*) istikutega. Taimed kasvasid läbipaistvates pottides (19 × 20 × 25 cm) kontrollitud tingimustega kasvukambrites kahel erineval mullatüübil (orgaaniline- ja mineraalmuld). Poti seinte paksus oli 0,6 cm ja see oli ühesugune kõigil pottidel. Orgaaniline muld ehk kuivendatud õhuke siirdesoomuld oli kogutud jänesekapsa-kõdusoo kuusikust ning mineraalmuld ehk gleistunud näivleetunud muld jänesekapsa kuusikust. Taimi kasteti kolm korda nädalas 60%-ni välivee mahutavusest. Kokku oli 36 taime, millest 18 kasvasid orgaanilisel mullal (taimed numbritega 1–18) ning 18 kasvasid mineraalmullal (numbritega 28–45). Esimene kamber sisaldas taimi numbritega 1–6 orgaaniliselt mullalt ja 28–33 mineraalmullalt. Teises kambris olid taimed 7–12 orgaaniliselt mullalt ja 34–39. Kolmandas kambris olid taimed 13–18 orgaaniliselt mullalt ja 40–45 mineraalmullalt. Kolmandast kambrist üks taim (numbriga 41) suri ära, seega oli eksperimendi lõpuks alles 35 taime.

Kasvukambri kontrollitavates tingimustes oli kolm erinevat õhutemperatuuri ja -niiskuse töötlust, millest esimeses ehk kontrollkambris oli tavapärane õhuniiskus ja -temperatuur, mis oli vastavuses Eesti loodusliku keskmisega aastal 2021 ehk päeval 18–27°C, öösel 13–18°C ning suhteline õhuniiskus oli päeval 65–75% ja öösel 90% (Tabel 1). Teises kambris oli õhutemperatuur kõrgendatud 3°C võrra ehk päeval 21–30°C, öösel 16–21°C ning 8% võrra madalam suhteline õhuniiskus ehk päeval 55–65% ja öösel 90%. Kolmandas kambris oli kõrgendatud temperatuur ehk päeval 21–30°C ja öösel 16–21°C ning tavapärane õhuniiskus, päeval 65–75% ja öösel 90%. Kambrite öö- ja päevarežiim vaheldus päeval kell 13.00 (suve aja järgi), seega kambrites oli valgus kell 13.00–05.00 ning öö ehk valgusetu aeg kell 05.00–13.00. Igas kambris oli valgusintensiivsus küllaltki konstantne (~600–800 $\mu\text{mol m}^{-2} \text{s}^{-1}$).

Tabel 1. Kliimakambrite ööpäevaringne seadistus ja keskkonna parameetrid kambrites.

Kamber 1 – Kontroll				Kamber 2 – Temp↑ & RH↓				Kamber 3 – Temp↑			
Kella- aeg	Valgus	Temp (°C)	RH (%)	Kella- aeg	Valgus	Temp (°C)	RH (%)	Kella- aeg	Valgus	Temp (°C)	RH (%)
13–19	Jah	18	75	13–19	Jah	21	65	13–19	Jah	21	75
19–22	Jah	23	70	19–22	Jah	26	60	19–22	Jah	26	70
22–01	Jah	27	65	22–01	Jah	30	55	22–01	Jah	30	65
01–05	Jah	20	75	01–05	Jah	23	65	01–05	Jah	23	75
05–08	Ei	13	90	05–08	Ei	16	90	05–08	Ei	16	90
08–13	Ei	18	90	08–13	Ei	21	90	08–13	Ei	21	90

RH – suhteline õhuniiskus, Temp – õhutemperatuur; Kontroll – tavaline temperatuur ja õhuniiskus; Temp↑ & RH↓ – kõrgendatud temperatuur (3°C võrra) ja madalam õhuniiskus (8% võrra); Temp↑ – kõrgendatud temperatuur (3°C võrra).

2.2. Peenjuurte pildistamine

Katses kasutatud pottide jaoks oli ehitatud alus. Ühte nurka asetus pott stabiilselt paigale ning kindlal kaugusel (~10,3 cm) oli koht telefoni (Samsung Galaxy s8+) jaoks (Joonis 2A). Kuna poti põhi oli riskülik, tehti alusele kaks telefoni fikseerimise kohta, et kõigilt neljalt küljelt sama resolutsiooniga pildid saada. Kahelt pikema küljega poti küljelt tehti pilt ühest fikseeritud asendist ning kahelt nii-öelda poti otsapoolelt tehti pilt teisest nutitelefoniga fikseeritud asendist. Kaamera kaugus oli varasemalt välja mõõdetud, suurendus 1:1 režiimil ning piltide eraldusvõime kontrollitud (3024 × 4032 pikslit) (Joonis 2). Selleks, et vältida klaasil peegeldusi, kasutasime musta plastikkarpi (Joonis 2B), kuhu sisse oli tehtud auk, läbi mille oli võimalik telefoni kaamerat opereerida.

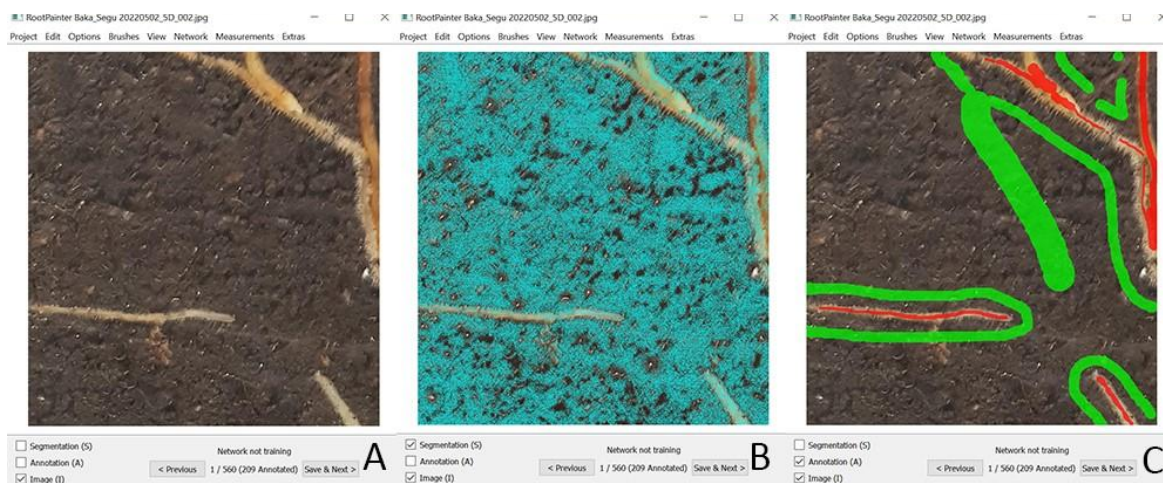


Joonis 2. Hariliku kuuse peenjuurte pildistamine nutitelefoni abil. A – nutitelefoni fikseeritud asetus alusel; B – plastikkarp, läbi mille telefoni pildistamise ajal opereeriti.

Käesoleva töö jaoks analüüsisin viimase pildistamise kampaania ajal ehk 02.05.2022 tehtud pilte. Pildistades tehti igast küljest mitu pilti, et vältida peegeldusi jms. Peale andmete korrastamist oli iga taime kohta neli pilti, see tähendab üks pilt igast küljest (A, B, C, D).

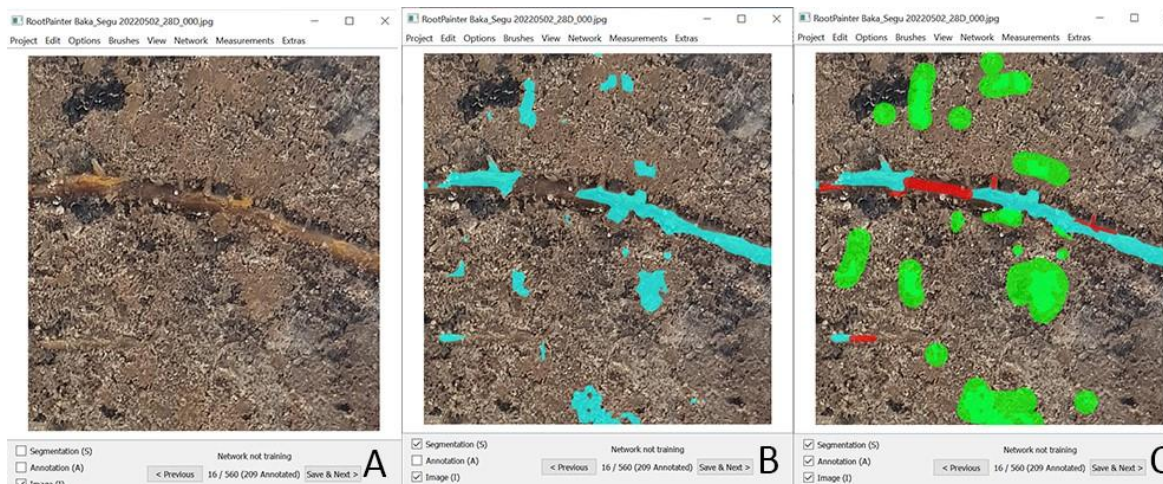
2.3. Mudelite treenimine RootPainteris

Esmalt treenisin välja segu mudeli (SEGUmudel), milleks kasutasin peenjuurte pilte nii mineraal- kui ka orgaanilisel mullal kasvavatelt istikutelt. Seega oli peenjuurte pilte kokku 140 (35 taime, 4 külge). Nendest piltidest tegin treeningpiltide andmestiku, kuhu RootPainter genereeris neli juhuslikku pildisegmenti iga pildi kohta, kokku 560. Pildisegment on etteantud suuruses väiksem (756×806 pikslit) osa algpildist, mille põhjal RootPainter õpib (Joonis 3A). RootPainter hakkab välja pakkuma alasid, mis on tema arvates juured. Alguses pakub programm peaaegu kogu pilti juureks, see on märgitud sinisega (Joonis 3B). Selleks, et programmile õpetada, kus asub juur ja kus taust, märkisin (anoteerisin) juured punasega, tausta rohelisega (Joonis 3C). Kuna taust on üsnagi sarnane, märkisin ainult osa taustast roheliseks.



Joonis 3. RootPainteris hariliku kuuse peenjuurte piltide treenimise alustamine orgaanilisel mullal (0 anoteeritud pilti). A – originaalne pildisegment; B – RootPainteri esimene pakkumine juurtest; C – pildile tehtud parandused (annotatsioonid), kus punane tähistab juurt, roheline tausta.

Alates umbes kümnendast pildisegmendi (Joonis 4A) annotatsioonist, kui programm suutis juba edukamalt tausta ja juuri eristada (Joonis 4B), parandasin ainult valepositiivseid ja valenegatiivseid (Joonis 4C). Seal, kus programm pakkus, et taust on juur ehk valepositiivne, parandasin rohelisega, ning seal, kus tegelikult oli veel juur, kuid programm seda ei tuvastanud (valenegatiivne), märkisin punasega.



Joonis 4. RootPainteris hariliku kuuse peenjuurte piltide treenimine mineraalmullal (16 anoteeritud pilti). A – originaalne pildisegment; B – RootPainteri arusaam juurte asukohast; C – pildile tehtud parandused (annotatsioonid), kus punane värv parandab valenegatiivseid ja roheline värv parandab valepositiivseid.

Nii treenisin 37% juurepiltide segmentidest. Järelikult tegin seda kokku 205 pildisegmendiga (Tabel 2). Peale seda treenisin samamoodi mineraalmulla mudeli (MINmudel), kus olid ainult mineraalmullal kasvavate taimede peenjuurte pildid. Kuna sellelt mullalt suri üks taim ära, oli seal kambris kokku 17 taime. Selle tõttu oli kokku 68 peenjuurte pilti, 272 pildisegmenti ning neist treenisin 100 pildisegmenti (37%). Viimaseks tegin orgaanilise mulla (ORGMudel) mudeli, kus olid ainult orgaanilisel mullal kasvavate istikute peenjuurte pildid – kokku 18 taime, 72 peenjuurte pilti, 288 pildisegmenti, treenisin 105 pilti (37%). Treenimisel jätsin mulla all olevad, kuid aimatavad peenjuured märkimata, et mitte õpetada programmile, et mõnel juhul võib mulda määrata juureks. Proovisin õpetada ka juurekarvade ja imijuurte võimalikult täpset tuvastamist, kuid juurekarvadel ma ei märkinud kindlasti kõiki juurekarvu, sest see oleks liiga ajakulukas olnud.

RootPainter teeb mingi kindla aja tagant, kui ta on piisavalt palju uut informatsiooni õppinud, uue mudeli. SEGUmudeli treenimiseks kulus mul kokku 12 tundi ja RootPainter tegi selle ajaga 29 mudelit, MINmudeli treenimiseks kulus 5 tundi ja mudeleid tuli kokku 12 ning ORGMudeli treenimiseks kulus 5 tundi ja mudeleid oli 19 (Tabel 2). Analüüsid kasutan kõige viimaseid ehk kõige rohkem õpetatud mudeleid.

Tabel 2. RootPainteris mudelite treenimiseks kasutatud pildisegmentide ja annotatsioonide hulk ning annoteerimiseks kulunud aeg.

Mudel	Taimed (nr)	Pildid	Segmendid	Annotatsioonid	Ajakulu	Mudelid
SEGU mudel	1–18, 28–40, 42–45	140	560	205	12 h	29
MIN mudel	28–40, 42–45	68	272	100	5 h	12
ORG mudel	1–18	72	288	105	5 h	19

SEGUmudel – nii orgaanilistel- kui mineraalmullal tehtud peenjuurte piltide peal treenitud mudel; MINmudel – ainult mineraalmullal tehtud peenjuurte piltide peal treenitud mudel; ORGMudel – ainult orgaanilisel mullal tehtud peenjuurte piltidel treenitud mudel; Taimed (nr) – mis numbriga taimed vastavatel muldadel kasvasid; Pildid – kasutatavate peenjuurte piltide koguarv; Segmendid – vastava mudeli treenimiseks kasutatavate pildisegmentide koguarv; Annotatsioonid – vastaval mudelil kokku annoteeritud piltide arv; Ajakulu – vastava mudeli treenimiseks kokku kulunud aeg tundides; Mudelid – vastava mudeli treenimisel RootPainteri poolt kokku tehtud mudelite arv.

2.4. Mudelite testimine

Mudeleid testiti erinevatel mullatüüpidel. SEGUmudelit (nii orgaanilisel- kui mineraalmullal kasvanud taimede juurepiltide peal treenitud mudel) kasutati eraldi ainult orgaanilisel mullal tehtud peenjuurte piltide analüüsimiseks ja eraldi ainult mineraalmullal tehtud peenjuurte piltide analüüsimiseks. Samamoodi kasutati ORGmudelit (orgaanilise mulla juurepiltidel treenitud mudel) mineraalmullal kasvanud taimede peenjuurte piltide mõõtmiseks ning vastupidi MINmudelit (mineraalmulla juurepiltidel treenitud mudel) orgaanilise mulla peenjuurte piltide mõõtmiseks. Kõik mõõdetud juure pindalad on väljendatud projektsioonpindalana (cm²), mis ei arvesta, et juur on silinder.

Mudelite võrdlemisel üksteise suhtes kasutasin referentsväärtusena samal mullatüübil välja töötatud mudelit ehk ORGmudel:ORGmudel ja MINmudel:MINmudel. Nii moodustus joonistele 1:1 joon (Joonised 6 ja 8), mille suhtes sain võrrelda vastavalt SEGUmudeli ja ORGmudeli ning SEGUmudeli ja MINmudeli väärtuseid.

2.5. Statistiline analüüs

Programm RootPainter võimaldab väljastada andmete õigsuse joonise, kus x-teljel on annoteeritud pildisegmentide arv ning y-teljel on õigsus. Õigsus näitab mitu protsenti antud pildisegmendist analüüsis RootPainter korrektselt ehk mitut protsenti pildist ei pidanud annoteerija parandama (Smith jt, 2022). Juurepindala (PA) tulemused väljastas RootPainter pikslites. Pildi suurus oli 3024 × 4032 pikslit ning kalibreerimiseks kasutasin millimeetripaberit. Pildi mõõtmeteks sain 9,6 × 13 cm, mille abil arvutasin juurte projektsioonpindala cm²-s.

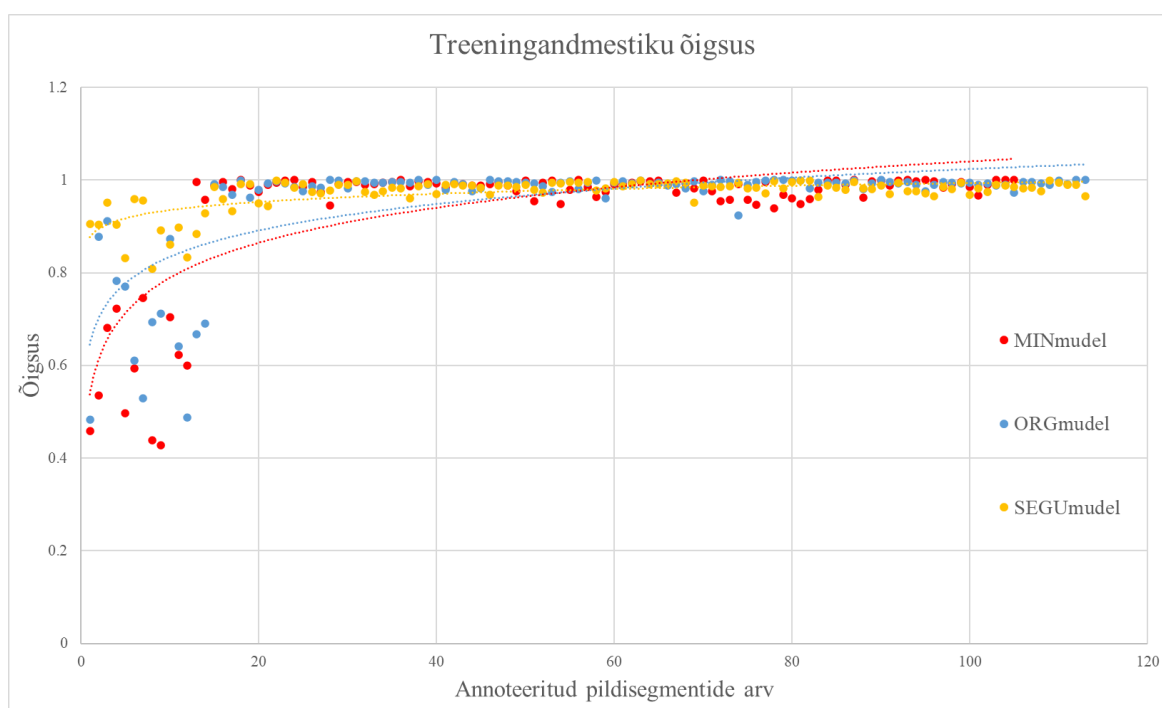
$$\frac{\text{pildi laius (cm)}}{\text{pildi laius (pikslites)}} \times \frac{\text{pildi kõrgus (cm)}}{\text{pildi kõrgus (pikslites)}} \times PA (\text{pikslites})$$

Andmete normaaljaotust kontrolliti Kolmogorov-Smirnov ja Shapiro-Wilk testidega. Erinevate mudelite (SEGUmudel, ORGmudel, MINmudel) ning keskkonnatingimuste (Kontroll, Temp & RH, Temp) mõju juurte projektsioonpindala hinnangutele analüüsiti ühefaktorilise dispersioonanalüüsiga. Kuuse peenjuure projektsioonpindala erinevusi töötluste vahel ning ka mudelite vahel kontrolliti Tukey testiga. Tulemused loeti statistiliselt oluliseks, kui P-väärtus oli väiksem kui 0,05 (P < 0,05). Andmeanalüüsiks kasutati statistikaprogrammi STATISTICA (versioon 7.1) ning joonised tehti Microsoft Excelis (versioon 2304).

3. Tulemused

3.1. Treeningandmestik

Kõik testitud mudelid saavutasid reaalsusele lähedase juurte ja mulla eristamise võimekuse 20. annotatsiooni juures (Joonis 5). Mudelid tegid esimese pakkumise juurtest (ei märkinud kogu tausta juureks) 11.–15. annotatsiooni juures, SEGUmudel 11. pildil, ORGmudel 15. pildil ja MINmudel 13. pildil. Iga järgneva 20 annotatsiooni treenimine parandas visuaalselt oluliselt mudeli juurte äratundmise võimekust. Jooniselt 5 on näha, et SEGUmudeli õigsus paranes võrreldes teiste mudelitega kõige varem.



Joonis 5. Treeningandmestiku õigsus RootPainteris kõigil treenitud mudelitel. ORGmudel – orgaanilise mulla juurepiltide peal õpetatud mudel; MINmudel – mineraalmulla juurepiltide peal õpetatud mudel; SEGUmudel – nii orgaanilise kui mineraalmulla juurepiltide peal õpetatud mudel.

3.2. Hariliku kuuse peenjuurte projektsioonpindala hindamine erinevate mudelitega

3.2.1. Peenjuurte pindala hinnangud mineraalmullal tehtud piltidele


Mineraalmullal tehtud piltidel oli kõikide töötluste MINmudeliga hinnatud keskmine peenjuurte projektsioonpindala (PA) $4,4 \pm 0,5 \text{ cm}^2$ (Tabel 3). ORGmudeli hinnangul oli samade piltide peenjuurte projektsioonpindalaks $9,6 \pm 0,7 \text{ cm}^2$ ja SEGUmudeli hinnangul $4,0 \pm 0,5 \text{ cm}^2$.

Tabel 3. Hariliku kuuse peenjuurte projektsioonpindala (PA) keskmiste hinnangud mineraalmullal tehtud peenjuurte piltidel erinevate mudelite poolt (referents ehk mullatüübile vastav mudel märgitud rohelisega). Ühe mudeli (SEGUmudel, MINmudel, ORGmudel) piires ei olnud töötluste vahel olulisi erinevusi. X ja Y iseloomustavad olulist erinevust mudelite juure PA hinnangute vahel.


Töötlus	SEGUmudel PA (cm²)	MINmudel PA (cm²)	ORGmudel PA (cm²)
Kontroll	$3,9 \pm 0,5 \text{ Y}$	$4,5 \pm 0,5 \text{ Y}$	$10,5 \pm 0,7 \text{ X}$
Temp & RH	$4,0 \pm 0,4 \text{ Y}$	$4,2 \pm 0,3 \text{ Y}$	$8,8 \pm 0,6 \text{ X}$
Temp	$4,0 \pm 0,5 \text{ Y}$	$4,5 \pm 0,5 \text{ Y}$	$9,4 \pm 0,6 \text{ X}$

RH – suhteline õhuniiskus, Temp – temperatuur; Kontroll – tavaline temperatuur ja õhuniiskus; Temp & RH – kõrgendatud temperatuur ja madalam suhteline õhuniiskus; Temp – kõrgendatud temperatuur ja tavaline suhteline õhuniiskus; ORGmudel – orgaanilise mulla juurepiltide peal õpetatud mudel; MINmudel – mineraalmulla juurepiltide peal õpetatud mudel; SEGUmudel – nii orgaanilise kui mineraalmulla juurepiltide peal õpetatud mudel.

SEGUmudeli ja MINmudeli hinnangul oli peenjuurte PA mineraalmullal tehtud piltidel peaaegu sama, samas kui ORGmudel hindas selle oluliselt kõrgemaks ($P < 0,05$) (Tabel 3; Joonis 6). PA ülehinnang oli ligi kahekordne (referentsväärtus oli MINmudeli hinnang) ning ei sõltunud töötlustest (Tabel 3, Joonis 6). Jooniselt 6 on näha, kuidas mineraalmullal tehtud juurepilte analüüsid varieeruvad ORGmudeli PA hinnangud tunduvalt rohkem kui teistel mudelitel. Jooniselt 7 on näha silmnähtavaid vigu RootPainteri töös, kui mineraalmulla pilte on analüüsitud ORGmudeliga.



Joonis 6. Mineraalmullal tehtud hariliku kuuse peenjuurte pildid. RH – suhteline õhuniiskus, Temp – õhutemperatuur; Kontroll – tavaline temperatuur ja õhuniiskus; Temp & RH – kõrgendatud temperatuur ja madalam suhteline õhuniiskus; Temp – kõrgendatud temperatuur ja tavaline suhteline õhuniiskus; ORGmudel – orgaanilise mulla juurepiltide peal õpetatud mudel; MINmudel – mineraalmulla juurepiltide peal õpetatud mudel; SEGUmudel – nii orgaanilise kui mineraalmulla juurepiltide peal õpetatud mudel.



Joonis 7. Näide erinevate mudelite hinnangutest mineraalmullal tehtud peenjuurte pildile taimel nr 32B. A – originaalpilt; B – ORGmudeli hinnang juurtest; C – SEGU mudeli hinnang juurtest; D – MINmudeli hinnang juurtest.

3.2.2. Peenjuurte pindala hinnangud orgaanilisel mullal tehtud piltidele

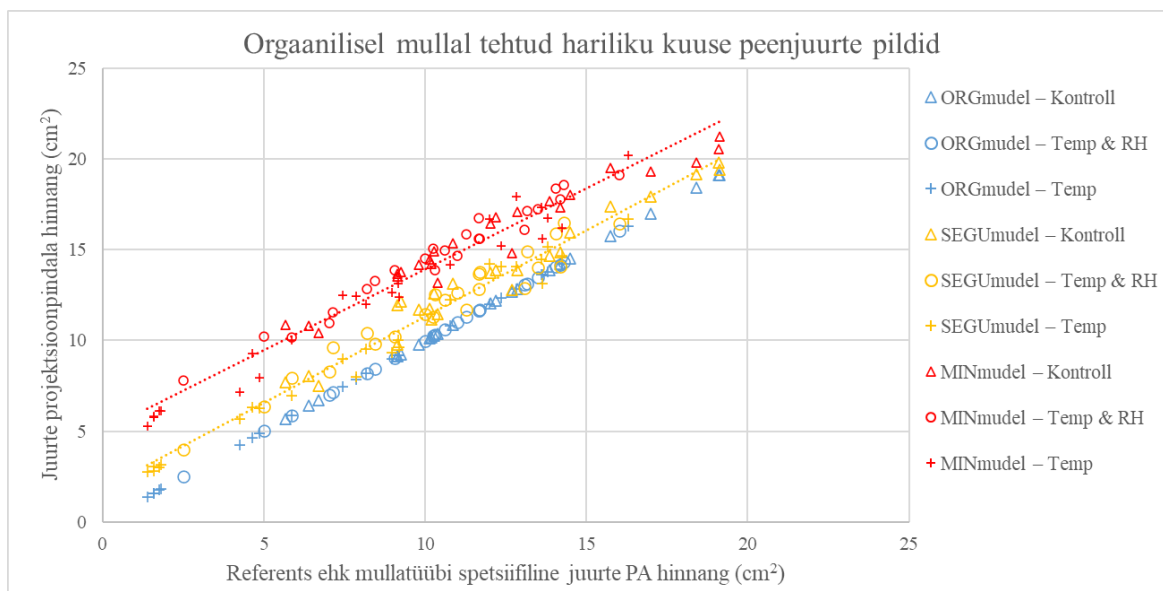
Orgaanilisel mullal kasvanud kuuse peenjuurte piltidel ORGmudeliga hinnatud keskmine peenjuurte projektsioonpindala (PA) varieerus $8,3 \pm 1,0$ kuni $12,1 \pm 0,8$ cm² sõltuvalt töötlustest (Tabel 4). SEGUmudeli hinnangul oli keskmine PA samadel juurepiltidel $9,3 \pm 0,9$ kuni $13,4 \pm 0,7$ cm² ning MINmudeli hinnangul $12,0 \pm 0,9$ kuni $15,8 \pm 0,6$ cm².

Tabel 4. Hariliku kuuse peenjuurte pindala (PA) keskmiste hinnangud orgaanilisel mullal tehtud peenjuurte piltidel erinevate mudelite poolt (referents märgitud rohelisega). a ja b iseloomustavad töötluste efekti olemasolu eri kambrite vahel; X ja Y iseloomustavad olulist erinevust mudelite juurte PA hinnangute vahel.

Töötlus	SEGUmudel PA (cm ²)	ORGmudel PA (cm ²)	MINmudel PA (cm ²)
Kontroll	$13,4 \pm 0,7$ aXY	$12,1 \pm 0,8$ aY	$15,8 \pm 0,6$ aX
Temp & RH	$11,8 \pm 0,6$ abY	$10,4 \pm 0,7$ abY	$14,7 \pm 0,6$ aX
Temp	$9,3 \pm 0,9$ bXY	$8,3 \pm 1,0$ bY	$12,0 \pm 0,9$ bX


RH – suhteline õhuniiskus, Temp – temperatuur; Kontroll – tavaline temperatuur ja õhuniiskus; Temp & RH – kõrgendatud temperatuur ja madalam suhteline õhuniiskus; Temp – kõrgendatud temperatuur ja tavaline suhteline õhuniiskus; ORGmudel – orgaanilise mulla juurepiltide peal õpetatud mudel; MINmudel – mineraalmulla juurepiltide peal õpetatud mudel; SEGUmudel – nii orgaanilise kui mineraalmulla juurepiltide peal õpetatud mudel.

Orgaanilisel mullal kasvanud kuuse peenjuurte PA hinnang oli nii ORGmudeli kui ka SEGUmudeliga analüüsides sarnane (Tabel 4, Joonis 8), samas kui MINmudeli PA hinnang oli oluliselt suurem kui referents ($P < 0,05$). MINmudel hindas võrreldes SEGUmudeliga PA väärtuseid oluliselt üle Temp & RH töötlustega kambris ($P < 0,05$), teistes töötlustes olid nende hinnangud sarnased. Seega olid ORGmudeli ja SEGUmudeli PA väärtused omavahel igas töötlustes sarnased, SEGUmudeli ja MINmudeli väärtused kahes töötlustes sarnased (Kontroll ja Temp), kuid ORGmudeli suhtes hindas MINmudel PA alati üle ($P < 0,05$) (Tabel 4).



Joonis 8. Orgaanilisel mullal tehtud hariliku kuuse peenjuurte pildid. RH – suhteline õhuniiskus, Temp – õhutemperatuur; Kontroll – tavaline temperatuur ja õhuniiskus; Temp & RH – kõrgendatud temperatuur ja madalam suhteline õhuniiskus; Temp – kõrgendatud temperatuur ja tavaline suhteline õhuniiskus; ORGmudel – orgaanilise mulla juurepiltide peal õpetatud mudel; MINmudel – mineraalmulla juurepiltide peal õpetatud mudel; SEGUmudel – nii orgaanilise kui mineraalmulla juurepiltide peal õpetatud mudel.

Joonisel 9 on esitatud fotod, millelt on näha, kuidas orgaanilisel mullal on ORGmudelil kõige vähem ja MINmudelil kõige rohkem valepositiivseid pakkumisi, SEGUmudel jääb vahepealseks.



Joonis 9. Näide erinevate mudelite hinnangust orgaanilisel mullal tehtud peenjuurte pildile taimel nr 32B. A – originaalpilt; B – MINmudeli hinnang juurtest; C – SEGUmudeli hinnang juurtest; D – ORGmudeli hinnang juurtest.

3.3. Õhutemperatuuri ja -niiskuse töötluste mõju hariliku kuuse peenjuurte kasvule

Mineraalmullal tehtud peenjuurte piltidel ei tulnud ühegi mudeli (SEGUmudel, MINmudel, ORGmudel) hinnangust välja, et kambri töötlus oleks mõjutanud PA väärtust ($P > 0,05$) (Tabel 3). Temperatuuri tõustes vähenesid orgaanilisel mullal kasvanud harilike kuuskede peenjuurte pindalad sõltumata sellest, millise mudeliga olid juurepildid analüüsitud ($P < 0,05$) (Tabel 4). Samuti tuli iga mudeli PA väärtustest välja, et kui õhutemperatuur tõusis samal ajal kui suhteline õhuniiskus vähenes, siis juurte PA ei muutunud. Suurenenud õhutemperatuuril ja vähenenud õhuniiskusel kasvanud kuuskede peenjuurte PA oli oluliselt suurem kui nendel kuuskedel, mis kasvasid vaid kõrgel õhutemperatuuril ($P < 0,05$), kuid seda näitasid vaid MINmudeliga analüüsitud pildid, SEGUmudeli ja MINmudeli PA väärtustes nende töötluste vahel erinevust ei olnud (Tabel 4). Võrreldes Tabeli 3 ja Tabeli 4 PA väärtuseid, on näha, et mineraalmullal kasvanud istikute PA keskmine referentsväärtus ($4,4 \text{ cm}^2$) on umbes poole väiksem kui orgaanilisel mullal kasvanud istikute oma ($10,3 \text{ cm}^2$).

4. Arutelu ja järeldused

Viimase paari aasta masinõppe areng ja arendatud programmid võimaldavad hinnata taimede juurte kasvu peaaegu reaajas ning töödelda väga suuri andmehulkasid. Bauer jt (2022) arvutasid välja, et selline automaatne analüüs RootPainteriga on ülimalt efektiivne, vähendades tööaega rohkem kui 98% võrreldes ajaga, mis kuluks manuaalselt juurte märkimiseks, eriti kui juurepiltide kogus võib ulatuda mitmetesse tuhandettesse piltidesse. Viimased uuringud on näidanud, et kallite juurte kasvu jälgida võimaldavate kaamerate asemel annab väga hea tulemuse ka tavaline nutitelefoniga kaamera (Mohamed jt, 2017; Sell jt, 2022b). Seega on nii ajakulu kui ka varustuse ostmiseks vajaliku ressursi mahukus juureuuringutes oluliselt langenud.

Tehnoloogia arenguga on oluline hinnata mitmeid meetoodilisi aspekte. Käesolevas töös loodud kolm erinevat mudelit võimaldavad hinnata, kuidas samal puuliigil, aga erinevate taustadega piltide alusel, moodustatud mudelid hindavad juurte projektsioonpindala erinevatel mullatüüpidel.

4.1. Mudelite võimekus juure pindala hindamisel

Juurte pindala hindama treenitud programmi RootPainteri väljastatud õigsuse graafikult on näha, kui kiiresti suudab programm piltidelt eristada juuri mulla osakekestest. Programm õppis juuri mullast eristama peale 20. pilti, kui teda treeniti kas orgaanilise või mineraalse mulla taustal. Kui treenimiseks kasutati pildisegmente mõlema mullatüübi taustadest (SEGUmudel), siis õppis masinõppe programm juuri mullast eristama veel kiiremini. Siiski olid kõikide mudelite esmased arusaamad juurtest üsna sarnased ning saavutati 11. kuni 15. pildiga. Tõenäoliselt mõjutab SEGUmudeli kiiremat õigsuse tõusu suurem varieeruvus piltidel olevate juurte kujus, värvis ning tausta erinevuses, aga ka annoteerija subjektiivses paranduste valikus. On võimalus, et SEGUmudeli puhul parandasin piltidelt rohkem objekte. Kuna SEGUmudelil oli rohkem algpilte (pildid olid nii mineraal- kui orgaaniliselt mullalt), oli ka treenimiseks vajalike pildisegmentide arv ja ajakulu suurem (Tabel 2). SEGUmudel oli tõhusam hindamaks erineval mullal kasvanud kuuse juurte PA-d, kuna sisendiks oli rohkem varieeruvaid pilte ja RootPainter genereeris rohkem mudeleid (igaüks neist uue lisainformatsiooniga) (Tabel 2).

Töö tulemusena tõestati esimene hüpotees ehk ei piisa, kui masinõppe mudel on loodud taimeliigi põhiselt. Selgus, et mullatüüp, mis moodustab pildi tausta ning mõjutab ka juurte kuju ja värvi, on väga oluline. Tõenäoliselt kasutab masin erinevate taustade ja juurte äratundmiseks tunnuseid, mis mullatüübiti kas erinevad ja/või puuduvad, vähendades spetsiifilise treeningu puudumisel mudeli võimekust eristada juuri ja mulda. Mineraalmullal treenitud mudel ei suutnud efektiivselt hinnata orgaanilisel mullal tehtud juurepilte ja vastupidi. Uuring, kus masinale õpetati taime kahjustusi, suutis programm neid lõpuks piltidelt tuvastada, kuid kohe kui sisendiks tulid uued pildid, vähenes masinõppe õigsus 60% (Mohanty jt. 2016). Tabelitest 3 ja 4 tuleb välja, et ORGmudeliga mineraalmullal (ja ka MINmudeliga orgaanilisel mullal) hinnatud peenjuurte piltide PA oli suurem kui mullatüübile vastava (referents) mudeli PA. Samas isegi kui erineva mulla taustaga loodud mudeliga hinnatud peenjuurte PA on referentsväärtusest selgelt erinev, tuli muudetud ilmastiku tegurite mõju mudeli hinnangust välja. Siiski ei ole võimalusel mõistlik kasutada oluliselt erineval mullal treenitud mudelit teistel mullatüüpidel kasvanud peenjuurte PA hindamiseks.

ORGmudeli PA hinnangud mineraalmullal olid väga varieeruvad (Joonis 6). Samas kui MINmudeli PA hinnangud orgaanilisel mullal ei varieerunud nii palju (Joonis 8). See võib tuleneda sellest, et mineraalmuld sisaldab oluliselt suuremas mahus mineraale, erinevas proportsioonis liiva ja saviosakesi. Mineraalmulla füüsikaline struktuur on teistsugune ning orgaanilise aine sisaldus väiksem. Mineraalmulla tihedus on suurem, samas kui orgaaniline muld on õhulisem, kobedam ja pole nii vastu klaasi, sest mulla struktuuride vahel on lasuvustiheduse erinevus (savi, liiva ja orgaanilise aine suhe on väga erinev). Orgaanilise mulla peenjuure piltide peal treenitud mudel (ORGmudel) eristab mõned mineraalmulla juurepiltide peal olevad poorid juureks. Vastu poti seinaga tekib vee pindpinevuse probleem ning mudel loeb veepiiskade poti seinaga pinnale kinnitunud osa mõnikord juureks, mida on eriti hästi näha ORGmudeli puhul, ehkki seda ei ole õpetatud. Seega ei sobi ORGmudel mineraalsel mullal tehtud peenjuurte piltidelt juurte PA hindamiseks. Paraku on ka vastupidi, MINmudel ei sobi orgaanilisel mullal tehtud peenjuurte piltidelt juurte PA hindamiseks, kuigi MINmudeli juurte PA hinnang orgaanilisel mullal tehtud piltidele (Joonis 9) on visuaalselt referentsile sarnasem kui ORGmudeli hinnang mineraalmullal tehtud piltidele (Joonis 7).

Mõlemal mullal treenitud mudel (SEGUmudel) sobib erinevatel mullatüüpidel tehtud piltidelt peenjuurte PA hindamiseks – see tulemus tõestab teise hüpoteesi õigeks, kuid eeldab siiski, et iga hinnatava mulla juurepilte on mudeli valmistamisel kasutatud. Seega on suuremahulistel katsetel SEGUmudel sobiv, kuid tõenäoliselt ei saavutata siiski nii täpselt tulemust kui mullatüübi põhise mudeliga. Seda, kui sarnased peavad mullatüübid olema, et juhuslik taimeliigi spetsiifiline mudel neid efektiivselt hinnata suudaks, ei ole veel teada. Võib oletada, et näiteks orgaaniline mudel suudab teisi tüüpi orgaanilisi mullatüüpe edukalt hinnata. Hinnates käesoleva töö orgaanilisel mullal kasvanud peenjuurte pilte Sell jt (2022b) töös kasvuturbal kasvanud peenjuurte piltidel välja töötatud mudeliga, oli tulemus väga sarnane (andmeid ei ole esitatud).

4.2. Tööluste mõju

Mineraalmullal kasvanud kuuse istikutel ei mõjutanud õhutemperatuuri tõus ega temperatuuri tõus koos madalama õhuniiskusega peenjuurte projektsioonpindala. See võib tuleneda sellest, et mineraalmullad puhverdavad keskkonnamõju paremini, sest näiteks mineraalmuldade veehoidmise võime on parem ning vesi võib leevendada temperatuuri tõusu mõju. Erinevate muldade reaktiivsus ilmastiku muutustele on erinev (Bradley-Cook jt, 2016).

Orgaanilisel mullal kasvanud kuuse peenjuurte keskmised PA väärtused olid ligikaudu poole suuremad kui mineraalmullal kasvanud kuuskedel (Tabelid 3 ja 4). Tuleb mõõnda ka juurte paremat nähtavust orgaanilise mulla taustal, mis võib mõjutada PA väärtust. Peenjuurte ning kõikide talituslikult erinevate rühmade nähtavus mineraalmuldadel oli halvem, sest mulla peened mineraalosalad (näiteks saviosakesed, tolm ja ibe) katavad juuri, liiguvad mullas kergesti veega ja muudavad nähtavuse halvemaks. Samas ei tähenda see, et juurte funktsionaalne jaotus oleks oluliselt erinev, ehkki seda tuleks tulevikus uurida.

Õhutemperatuuri kasvades vähenes orgaanilisel mullal kasvanud kuuskede peenjuurte PA. Varasemates töödes on leitud, et peenjuurte biomass sõltub aasta keskmisest õhutemperatuurist ja on suurem külmemas kliimas kasvavates metsades, seega võiks põhjapoolsetel laiuskraadidel soojem temperatuur peenjuurte kasvu hoopis soodustada (Pregitzer jt, 2000; Yuan jt, 2018). Käesoleva töö tulemused õhutemperatuuri tõusu soodsat mõju juurte kasvule ei näidanud. Põhjuseks võib olla see, et kliimakambrites manipuleeriti ainult õhutemperatuuri ja -niiskust, ent jätkati istikute kastmist. Looduses muutuvad

tavaliselt mitu keskkonnafaktorit samaaegselt. Nende muutumine ja koosmõju annab sageli erineva tulemuse võrreldes vaid üksikute faktorite manipuleerimise tulemustega. Sellele viitab ka selle töö tulemus, et kõrgem õhutemperatuur ja vähenenud õhuniiskus koosmõjus ei mõjutanud juurte PA väärtuseid võrreldes vaid kõrgema temperatuuri juurte PA-d vähendava mõjuga (Tabel 4).

Ainult MINmudeli hinnangust tuli välja, et suurenenud õhutemperatuuril ja vähenenud õhuniiskusel oli orgaanilisel mullal kasvanud kuuskede peenjuurte PA oluliselt suurem kui ainult kõrgendatud õhutemperatuuris kasvanud istikute peenjuurte PA. See võib olla mõjutatud sellest, et MINmudelil esines selgeid ülehinnanguid orgaanilisel mullal kasvanud juurte PA analüüsimisel. Seega ei osutunud kolmas hüpotees tõeseks, et kõrgema õhutemperatuuri ja madalama õhuniiskusega väheneb juurte kasv mõlemal mullatüübil.

4.3. Probleemid RootPainteris

Masinõppes võib üheks tekkivaks probleemiks olla subjektiivsus. Näiteks kui pildil on mulla mineraalosakestega kaetud juur, mis on inimsilmale veel juurena eristatav, siis masina võib see segadusse ajada, kui see juureks märkida. Siiski tuleks täpsemalt testida, millised on tehisintellekti jaoks lävendväärtused inimsilmale aimatavate juurte märkimisel ning kas osaliselt õhukese mullakihiga kaetud nii-öelda aimatavate juurte märkimine muudab RootPainteri täpsust. Samuti ei ole teada teiste sarnaste masinõppe uurimuste kohta, näiteks kui täpselt juuri märgiti, mis võib raskendada erinevate uuringute vahelisi võrdluseid. Lisaks võis ka minu õpetamine ajas muutuda. Võimalik, et SEGUmudel pole nii täpne kui on orgaanilise mulla mudel (ORGMudel), mille ma tegin viimasena, sest siis oskasin ise paremini hinnata juurte asukohta ning ka selgemat piiri tõmmata kuna ja kus märkida juurt või tausta. Subjektiivsust mõjutab ka treenitud pildisegmentide arv. Kuna kasutasin ainult 560, 272 ja 288 segmenti, millest treenisin 37%, siis võimalik, et pikema treenimise pealt tuleks veel täpsem mudel. Samuti märkides õpetamisfaasis juuri ja juurekarvu piksli kaupa annab RootPainter lõpuks ikka üldistava hinnangu juure pindalast (Smith jt, 2022). Tulevikus on plaanis hinnata ka mudelite suhtelist viga.

Piltidelt juurte tuvastamist raskendavad ka rohttaimede idanevad seemned, mis kasvukambris mõõtmiste käigus valgust võivad saada. Lisaks võib masina jaoks olla problemaatiline eristada vihmaussi või mõnda muud mullalooma. Sellekohased uurimused praegu veel puuduvad.

Kokkuvõte

Harilik kuusk (*Picea abies*) on Eestis üheks enamuspuuliigiks, kasvades nii mineraalsetel kui ka orgaanilistel muldadel. Pole veel täpselt teada, kuidas kliima muutused kuuse juurte kasvu mõjutavad, seega on oluline muuta juurte uurimismeetodeid võimalikult lihtsaks ja kättesaadavaks, et andmeid koguneks kiiremini ja rohkem. Juureuuringute ajakulu märgatavaks vähendamiseks saab kasutada masinõppet põhinevaid meetodeid. Käesolevas töös uuriti, kuidas erinevad mullatüübid mõjutavad masinõppe mudelite võimekust hinnata juurte projektsioonpindala (PA). Töö eesmärgiks oli teada saada, kas ainult ühel mullatüübil välja treenitud masinõppe mudel sobib peenjuurte PA hindamiseks erinevatel mullatüüpidel. Samuti uuriti kõrge temperatuuri ja vähenenud õhuniiskuse koosmõju peenjuurte kasvule mõlemal mullatüübil.

Käesolev töö viidi läbi 2022. aasta kevadel tehtud eksperimendis kliimakambrites, kus hariliku kuuse istikud kasvasid läbipaistvates pottides, kahel erineval mullal (orgaaniline ja mineraal). Kambrites manipuleeriti erinevaid keskkonnatingimusi (töötused: kontroll, kõrgendatud õhutemperatuur, kõrgendatud temperatuur koos õhuniiskuse vähenemisega). Testimiseks tehti kolm mudelit, millest esimese treenimiseks kasutati pilte mõlemal mullal kasvanud istikute juurtest (SEGUmudel), teise mudeli jaoks kasutati ainult mineraalmullal kasvanud taimede juurepilte (MINmudel) ja kolmanda mudeli jaoks kasutati ainult orgaanilisel mullal tehtud juurepilte (ORGmudel).

Leiti, et ainult ühel mullatüübil treenitud mudeli võimekus hinnata peenjuurte PA-d teist tüüpi mullal tehtud juurepiltidel on selgelt halvem. Kui mudeli treenimiseks kasutati juurepilte mõlemalt mullatüübilt (SEGUmudel), tõusis mudeli võimekus hinnata juurepindala suhteliselt ligilähedaselt mulla spetsiifilise mudeliga. Mineraalmullal kasvanud kuuskede peenjuurte PA ei olnud mõjutatud kõrgema õhutemperatuuri ega kõrgema õhuniiskuse ja vähenenud õhuniiskuse töötuses, kuid oli üldiselt väiksem võrreldes orgaanilisel mullal kasvanud kuuskede peenjuurte PA-ga. Orgaanilisel mullal kasvanud istikute juurte PA jäi samaks siis kui õhutemperatuur tõusis samal ajal kui õhuniiskus vähenes, kuid vähenes ainult kõrgendatud temperatuuriga töötuses.

Summary

The implementation of machine learning models to measure Norway Spruce (*Picea abies*) fine root growth on different soil types under different climate conditions

Norway spruce (*Picea abies*) is one of the dominating tree species in Estonia, growing mainly on mineral- but also on organic soils. There is a lack of information on how exactly climate change affects the fine root growth of Norway spruce. Therefore, it is important to make root research methods as simple and accessible as possible to encourage research. Machine learning methods can significantly increase the time and resource effectiveness of root research. This thesis studied how different soil types affect the ability of machine learning models to estimate fine root projection area (PA). We wanted to determine if a machine learning model trained on one soil type is suitable for evaluating the PA on different soil types. In addition, we analysed the fine root surface area changes with increased temperature and decreased air humidity on both soil types.

The experiment was carried out in the spring of 2022 in climate chambers with Norway spruce saplings growing in transparent pots on two different soil types (organic and mineral). The chambers had different treatments (control, increased air temperature, increased air temperature with decreased -humidity). Three models were made, of which the first one was trained using root images from plants growing on both mineral- and organic soils (SEGUmudel). The second model was trained using root images of plants growing only on mineral soil (MINmudel), and the last one used root images only of plants growing on organic soil (ORGmudel).

It was found that a model trained only on one soil type is not able to evaluate the pictures of roots growing on different soil types. If the model was trained using root pictures from both soil types (SEGUmudel), then it was able to estimate the root area quite accurately. Also, in this experiment we found that the root area of the plants growing on mineral soil was not affected by any treatments, but was overall smaller than the PA of the plants growing on organic soil. The increased temperature with decreased air humidity did not affect the fine root area of plants growing on organic soil. However, when only the temperature increased, the root area of those plants decreased.

Tänuavaldused

Soovin tänada oma juhendajaid Ivikat ja Marilit, kes andsid alati häid nõuandeid ja olid igas töö etapis abivalmid, oma pere ning kõiki, kes töö valmimisel moraalseks toeks olid. Suur tänu ka teistele, kes kliimakambri eksperimendiga seotud olid. See töö valmis Eesti Teadusagentuuri granti PRG916 toetusel.

Kasutatud kirjandus

Viitamisel ja kirjanduse loetelu vormistamisel on lähtutud APA stiili nõuetest.

- Aldea, J., Ruiz-Peinado, R., del Rio, M., Pretzsch, H., Heym, M., Brazaitis, G., Jansons, A., Metslaid, M., Barbeito, I., Bielak, K., Hysten, Gr., Holm, S.-O., Nothdurft, A., Sitko, R. & Löff, M. (2022). Timing and duration of drought modulate tree growth response in pure and mixed stands of Scots pine and Norway spruce. *Journal of Ecology*, *110*(11), 2673–2683. doi:10.1111/1365-2745.13978
- Alonso-Crespo, I. M., Weidlich, E. W., Temperton, V. M. & Delory, B. M. (2023). Assembly history modulates vertical root distribution in a grassland experiment. *Oikos*, *2023*(1), e08886. doi:10.1111/oik.08886
- Bauer, F. M., Lärm, L., Morandage, S., Lobet, G., Vanderborght, J., Vereecken, H. & Schnepf, A. (2022). Development and validation of a deep learning based automated minirhizotron image analysis pipeline. *Plant Phenomics*, *2022*(9), 1–14. doi:10.34133/2022/9758532
- Bradley-Cook, J. I., Petrenko, C. L., Friedland, A. J. & Virginia, R. A. (2016). Temperature sensitivity of mineral soil carbon decomposition in shrub and graminoid tundra, west Greenland. *Climate Change Responses*, *3*, 1–15. doi:10.1186/s40665-016-0016-1
- Brunner, I. & Godbold, D. L. (2007). Tree roots in a changing world. *Journal of forest research*, *12*(2), 78–82. doi:10.1007/s10310-006-0261-4
- Centenaro, G., Hudek, C., Zanella, A. & Crivellaro, A. (2018). Root-soil physical and biotic interactions with a focus on tree root systems: A review. *Applied Soil Ecology*, *123*, 318–327. doi:10.1016/j.apsoil.2017.09.017
- Cleland, E. E., Allen, J. M., Crimmins, T. M., Dunne, J. A., Pau, S., Travers, S. E., Zavaleta, E. S. & Wolkovich, E. M. (2012). Phenological tracking enables positive species responses to climate change. *Ecology*, *93*(8), 1765–1771. doi:10.1890/11-1912.1

- Clemmensen, K. E., Bahr, A., Ovaskainen, O., Dahlberg, A., Ekblad, A., Wallander, H., Stenlid, J., Finlay, R. D., Wardle, D. A. & Lindahl, B. (2013). Roots and associated fungi drive long-term carbon sequestration in boreal forest. *Science*, *339*(6127), 1615–1618. doi:10.1126/science.1231923
- Farjon, A. (2010). *A Handbook of the World's Conifers*. Leiden: Brill Academic Publishers.
- Finér, L., Ohashi, M., Noguchi, K. & Hirano, Y. (2011). Fine root production and turnover in forest ecosystems in relation to stand and environmental characteristics. *Forest Ecology and Management*, *262*(11), 2008–2023. doi:10.1016/j.foreco.2011.08.042
- Fu, Y. H., Piao, S., Op de Beeck, M., Cong, N., Zhao, H., Zhang, Y., Menzel, A. & Janssens, I. A. (2014). Recent spring phenology shifts in western Central Europe based on multiscale observations. *Global Ecology and Biogeography*, *23*(11), 1255–1263. doi:10.1111/geb.12210
- Guo, D. L., Mitchell, R. J. & Hendricks, J. J. (2004). Fine root branch orders respond differentially to carbon source-sink manipulations in a longleaf pine forest. *Oecologia*, *140*, 450–457. doi:10.1007/s00442-004-1596-1
- Han, E., Smith, A. G., Kemper, R., White, R., Kirkegaard, J. A., Thorup-Kristensen, K. & Athmann, M. (2021). Digging roots is easier with AI. *Journal of experimental botany*, *72*(13), 4680–4690. doi:10.1101/2020.12.01.397034
- Han, E., Kirkegaard, J. A., White, R., Smith, A. G., Thorup-Kristensen, K., Kautz, T. & Athmann, M. (2022). Deep learning with multisite data reveals the lasting effects of soil type, tillage and vegetation history on biopore genesis. *Geoderma*, *425*, 116072. doi:10.1016/j.geoderma.2022.116072
- Helmisaari, H. S., Makkonen, K., Kellomäki, S., Valtonen, E. & Mälkönen, E. (2002). Below- and above-ground biomass, production and nitrogen use in Scots pine stands in eastern Finland. *Forest ecology and management*, *165*(1–3), 317–326. doi:10.1016/S0378-1127(01)00648-X
- Hänninen, H. (1990). Modelling bud dormancy release in trees from cool and temperate regions. *Acta Forestalia Fennica*, *213*, 1–47. doi:10.14214/aff.7660
- Jaagus, J. & Mändla, K. (2014). Climate change scenarios for Estonia based on climate models from the IPCC Fourth Assessment Report. *Estonian Journal of Earth Sciences*, *63*(3) 166–180. doi:10.3176/earth.2014.15

- Kuuse-kooreürask (2022). *Keskkonnaportaal*. Kasutatud 20.05.2023, <https://keskkonnaportaal.ee/et/teemad/mets/kuuse-kooreürask>
- Kilpeläinen, J., Domisch, T., Lehto, T., Finér, L., Aphalo, P. J., Leinonen, I., Ryyppö, A. & Repo, T. (2019). Root and shoot phenology and root longevity of Norway spruce saplings grown at different soil temperatures. *Canadian Journal of Forest Research*, 49(11), 1441–1452. doi:10.1139/cjfr-2019-0190
- Kubíková, J. (1967). Contribution to the classification of root systems of woody plants. *Preslia*, 39, 236-243.
- Kõlli, R., Tõnutare, T. & Kõlli, T. (2018). Ülevaade: kahkjad ehk näivleetunud mullad Eestimaa muldkattes. *Agraarteadus*, 29(2), 95–105. doi:10.15159/jas.18.12
- Laas, E & Becker, H. (2021). Eesti metsakasvukohatüübid. Tartu: Eesti Maaülikool. Kasutatud 20.05.2023, <https://kasvukohatyybid.emu.ee/>
- Lukac, M. (2012). Fine Root Turnover. S. Mancuso (toim), *Measuring Roots: an updated approach* (lk 363–373). Berlin: Springer Nature. doi:10.1007/978-3-642-22067-8_18
- Lõhmus, E. (2004). *Eesti metsakasvukohatüübid*. Tartu: Eesti Loodusfoto.
- Mohamed, A., Monnier, Y., Mao, Z., Lobet, G., Maeght, J.L., Ramel, M. & Stokes, A. (2017). An evaluation of inexpensive methods for root image acquisition when using rhizotrons. *Plant Methods*, 13(1), 1–13. doi:10.1186/s13007-017-0160-z
- Mohanty, S. P., Hughes, D. P. & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in plant science*, 7, 1419. doi:10.3389/fpls.2016.01419
- Niinemets, Ü. & Ostonen, I. (2020). Plant organ senescence above-and belowground in trees: how to best salvage resources for new growth? *Tree Physiology*, 40(8), 981–986. doi:10.1093/treephys/tpaa060
- Persson, H. (1992). *Factors affecting fine root dynamics of trees*. *Suo*, 43, 163–172.
- Phenome Force. [Kasutajanimi]. (2022, 20. oktoober). *PhenomeForce 2022 – Abraham George Smith* [Video]. Youtube. <https://www.youtube.com/watch?v=73u73tBvRO4>.

- Pregitzer, K. S., King, J. S., Burton, A. J. & Brown, S. E. (2000). Responses of tree fine roots to temperature. *New Phytologist*, 147(1), 105–115. doi:10.1046/j.1469-8137.2000.00689.x
- Pregitzer, K. S., DeForest, J. L., Burton, A. J., Allen, M. F., Ruess, R. W. & Hendrick, R. L. (2002). Fine root architecture of nine North American trees. *Ecological Monographs*, 72(2), 293–309. doi:10.1890/0012-9615(2002)072[0293:FRAONN]2.0.CO;2
- Puhe, J. (2003). Growth and development of the root system of Norway spruce (*Picea abies*) in forest stands—a review. *Forest ecology and management*, 175(1–3), 253–273. doi:10.1016/S0378-1127(02)00134-2
- Ostonen, I. (1997). *Hariliku kuuse imijuurte ökomorfoloogia*. Magistritöö. Tartu Ülikool, taimeökoloogia ja ökofüsioloogia õppekava.
- Ostonen, I., Tedersoo, L., Suvi, T. & Lõhmus, K. (2009). Does a fungal species drive ectomycorrhizal root traits in *Alnus* spp.?. *Canadian Journal of Forest Research*, 39(10), 1787–1796. doi:10.1139/X09-093
- Radville, L., McCormack, M. L., Post, E. & Eissenstat, D. M. (2016). Root phenology in a changing climate. *Journal of Experimental Botany*, 67(12), 3617–3628. doi:10.1093/jxb/erw062
- Rewald, B., Seehra, L., Hadar, O., Sofer, A., Baykalov, P., Elmakies, M., Bodner, G., Zhou, K. & Lazarovitch, N. (2020). Enabling next level research on roots: Automatizing Minirhizotron Image Acquisition and Analysis (NextMR-IAA) for Research and Agricultural Management. *ATTRACT Final Conference*.
- Schuurman, J. J. & Goedewaagen, M. A. J. (1965). *Methods for the examination of root systems and roots*. Wageningen: Centre for agricultural publications and documentation.
- Seethepalli, A., Dhakal, K., Griffiths, M., Guo, H., Freschet, G. T. & York, L. M. (2021). RhizoVision Explorer: Open-source software for root image analysis and measurement standardization. *AoB plants*, 13(6), plab056. doi:10.1101/2021.04.11.439359

- Sell, M., Ostonen, I., Rohula-Okunev, G., Rusalepp, L., Rezapour, A. & Kupper, P. (2022a) Responses of fine root exudation, respiration and morphology in three early successional tree species to increased air humidity and different soil nitrogen sources. *Tree Physiology* 42(3):557–569. doi:10.1093/treephys/tpab118
- Sell, M., Smith, A. G., Burdun, I., Rohula-Okunev, G., Kupper, P. & Ostonen, I. (2022b). Assessing the fine root growth dynamics of Norway spruce manipulated by air humidity and soil nitrogen with deep learning segmentation of smartphone images. *Plant and Soil*, 480, 135–150. doi:10.1007/s11104-022-05565-4
- Shukla, P. R., Skea, J., Calvo Buendia, E., Masson-Delmotte, V., Pörtner, H.-O., Roberts, D. C., Zhai, P., Slade, R., Connors, S., van Diemen, R., Ferret, M., Haughey, E., Luz, S., Neogi, S., Pathak, M., Petzold, J., Portugal Pereira, J., Vyas, P., Huntley, ... Maley, J. (2019). Summary for policymakers. Climate Change and Land: an IPCC special report on climate change, desertification, land degradation, sustainable land management, food security, and greenhouse gas fluxes in terrestrial ecosystems.
- Skaggs, R. W., Tian, S., Chescheir, G. M., Amatya, D. M. & Youssef, M. A. (2016). Forest drainage. D. M. Amatya (toim), *Forest Hydrology: Processes, management and assessment* (lk 124–140). Boston: CABI. doi:10.1079/9781780646602.0124
- Skrøppa, T. (2003). *Technical guidelines for genetic conservation and use for Norway spruce (Picea abies)*. EUFORGEN, International Plant Genetic Resources Institute. Kasutatud 17.05.2023, https://www.euforgen.org/fileadmin//templates/euforgen.org/upload/Publications/Technical_guidelines/Technical_guidelines_Picea_abies.pdf
- Smith, A. G., Han, E., Petersen, J., Olsen, N. A. F., Giese, C., Athmann, M., Dresbøll, D.B. & Thorup-Kristensen, K. (2022). RootPainter: deep learning segmentation of biological images with corrective annotation. *New Phytologist*, 236(2), 774–791. doi:10.1111/nph.18387
- Zohner, C. M., Renner, S. S., Sebold, V. & Crowther, T. W. (2021). How changes in spring and autumn phenology translate into growth-experimental evidence of asymmetric effects. *Journal of Ecology*, 109(7), 2717–2728. doi:10.1111/1365-2745.13682

- Valgepea, M., Sirkas, F., Timmusk, T., Pärt, E., Suursild, E., Matson, T., Maamets, L., Raudsaar, M., Tetlov, E., Apuhtin, V., Veeroja, R., Tamm, U. & Laigu, R. (2023). Aastaraamat Mets 2021. *Keskkonnaaagentuur*, ISSN (e-väljaanne): 2382–7068. Kasutatud 20.05.2023, <https://keskkonnaportaal.ee/sites/default/files/Teemad/Mets/Mets2021.pdf>
- Vamerali, T., Bandiera, M. & Mosca, G. (2011). Minirhizotrons in modern root studies. S. Mancuso (toim). *Measuring Roots, An Updated Approach* (lk 341–361). Berlin: Springer Nature. doi:10.1007/978-3-642-22067-8_17
- Wojciechowska, N., Marzec-Schmidt, K., Kalemba, E. M., Ludwików, A. & Bagniewska-Zadworna, A. (2020). Seasonal senescence of leaves and roots of *Populus trichocarpa* — is the scenario the same or different? *Tree Physiology*, 40(8), 987–1000. doi:10.1093/treephys/tpaa019
- Yuan, Z. Y., Shi, X. R., Jiao, F. & Han, F. P. (2018). Changes in fine root biomass of *Picea abies* forests: predicting the potential impacts of climate change. *Journal of plant ecology*, 11(4), 595–603. doi:10.1093/jpe/rtx032

Lihtlitsents lõputöö reprodutseerimiseks ja üldsusele kättesaadavaks tegemiseks

Mina, Marian Klaus,

1. annan Tartu Ülikoolile tasuta loa (lihtlitsentsi) minu loodud teose “Juurte kasvu mõõtmine masinõppe abil”, mille juhendajad on Professor Ivika Ostonen-Märtin ja Dr. Marili Sell, reprodutseerimiseks eesmärgiga seda säilitada, sealhulgas lisada digitaalarhiivi DSpace kuni autoriõiguse kehtivuse lõppemiseni.
2. Annan Tartu Ülikoolile loa teha punktis 1 nimetatud teos üldsusele kättesaadavaks Tartu Ülikooli veebikeskkonna, sealhulgas digitaalarhiivi DSpace kaudu Creative Commons'i litsentsiga CC BY NC ND 4.0, mis lubab autorile viidates teost reprodutseerida, levitada ja üldsusele suunata ning keelab luua tuletatud teost ja kasutada teost ärieesmärgil, kuni autoriõiguse kehtivuse lõppemiseni.
3. Olen teadlik, et punktides 1 ja 2 nimetatud õigused jäävad alles ka autorile.
4. Kinnitan, et lihtlitsentsi andmisega ei riku ma teiste isikute intellektuaalomandi ega isikuandmete kaitse õigusaktidest tulenevaid õigusi.

Marian Klaus

25.05.2023