

TARTU ÜLIKOOL
Arvutiteaduse instituut
Informaatika õppekava

Kelli Gagarina
Kaugseire põhine loodusliku rohumaa ja
põllumaa eristamine
Bakalaureusetöö (9 EAP)

Juhendajad:
Tiit Sepp, MSc
Joonas Ariva, MSc

Tartu 2025

Kaugseire põhine loodusliku rohumaa ja põllumaa eristamine

Lühikokkuvõte:

Töös arendati masinõppepõhist klassifitseerimismudelit, mis tuvastab põllumaad ja looduslikku rohumaad satelliitpiltidel aastatest 2008–2012, pakkudes ülevaadet maakattest. Töökäik hõlmas sobivate andmestike ja mudeli arhitektuuri valikut, andmete töötlemist ning klassifitseerimismudeli treenimist. Valminud mudel põhineb U-Net arhitektuuril ja treenitud Landsat 7 satelliidi andmete põhjal. Töös loodud mudel saavutas keskmise täpsuse 79%.

Võtmesõnad: sügavõpe, põllumajandus, kaugseire, maakate

CERCS: P176 Tehisintellekt, T181 Kaugseire

Remote sensing-based differentiation of natural grassland and cropland

Abstract:

This work focused on developing a machine learning-based classification model to identify cropland and natural grassland in satellite images from 2008 to 2012, providing an overview of land cover. The workflow included selecting appropriate datasets and model architecture, data preprocessing, and training the classification model. The final model was based on a U-Net architecture and trained using Landsat 7 satellite data. The model achieved an overall precision of 79%.

Keywords: deep learning, agriculture, remote sensing, land cover

CERCS: P176 Artificial intelligence, T181 Remote sensing

Sisukord

1. Sissejuhatus	4
2. Kasutatud mõisted ja terminid	6
3. Kirjanduslik ülevaade	7
3.1 Maakatte klassifitseerimine.....	7
3.2 Kaugseire andmed	8
3.2.1 Landsat 7 satelliit.....	9
3.2.2 WorldCover projekt.....	11
3.3 Sügavõpe	11
3.3.1 Semantiline segmenteerimine	12
3.3.2 U-Net närvivõrk	12
4. Metoodika	14
4.1 Andmete kogumine ja töötlus	14
4.1.1 Landsat 7 andmevoog	14
4.1.2 Märkendite eeltöötlus	16
4.1.3 Sensori rikke haldamine	16
4.2 Tulemuste hindamine	16
5. Tulemused.....	19
5.1 Mudeldamine.....	19
5.1.1 Võrdlusmudel	19
5.1.2 Eksperimendid	21
5.1.3 Põllumaa ja rohumaa klassifitseerimismudel	22
5.2 Võimalikud edasiarendused	24
6. Kokkuvõte.....	26
Viited	27
Lisad	31
Litsents	32

1. Sissejuhatus

Masinõppe rakendamine põllumajandussektoris on aastate jooksul näidanud märkimisväärseid tulemusi, aidates muuta põllumajanduspraktikaid tõhusamaks ja keskkonnasõbralikumaks (Kisliuk jt 2023). Masinõppemudeleid kasutatakse laialdaselt näiteks taimede haiguste ja liikide tuvastamisel ning saagikuse ennustamisel (Dhasmana jt 2024; Pearline jt 2019; Subramaniam ja Marimuthu 2024).

Üks oluline ülesanne põllumajandusandmete analüüsis on maakatte klassifitseerimine. Täpne ja usaldusväärne maakatte tuvastamine on oluline põllumaa monitoorimiseks ja võimaldab kujundada tõhusamat põllumajanduspoliitikat ning optimeerida ressursikasutust (Aplin 2004). Samuti on see oluline süsinikukrediidisüsteemide tõhusaks rakendamiseks.

Süsinikukrediidid pakuvad ettevõtetele, kelle tegevus eraldab õhku kasvahoonegaase, võimaluse kompenseerida oma süsinikujalajälge, investeerides keskkonnasäästlikesse põllumajanduspraktikatesse (Galea 2025).

Süsinikukrediitidega tegeleva Eesti põllumajandusettevõtte eAgronom esindaja Rosende (2022) sõnul on üheks süsinikuprogrammis osalemise nõudeks, et põllumaa peab olema pidevalt kasutuses põllumajandusmaana vähemalt viimase kolme kuni viie aasta jooksul. Selline kriteerium on seatud eesmärgiga välistada programmist need maad, mis on selle aja jooksul olnud näiteks looduslik rohumaa, soo või mets, ehk alad, mis seovad looduslikult süsinikku rohkem kui haritav põllumaa. Süsinikukrediidi loomiseks peab aga olema tõendatav, et säästlike põllumajanduspraktikate rakendamine toob kaasa süsinikdioksiidi sidumise atmosfäärist maapinda või selle eemaldamise õhust. Kuna süsinikukrediitide süsteemid on võrdlemisi uued, esineb piiratud hulgal lahendusi, mis võimaldaksid automaatselt ja täpselt tuvastada põldude ajaloolist kasutust.

Käesolev töö oli inspireeritud põllumajandusettevõtte eAgronom ja andmeteadusettevõtte STACC OÜ koostöös valminud projektist (edaspidi kui eAgronomi ja STACC OÜ projekt), mille eesmärk oli kontrollida põldude kümne aasta maakasutust süsinikuprogrammi jaoks. Kümneaastane periood võimaldas uurida maakasutust põhjalikumalt ja tuvastada pikaajalisi muutusi ja mustreid. Projekti käigus ilmnis, et üheks oluliseks väljakutseks on rohumaa ja põllumaa eristamine vanemate kaugseireandmete põhjal, täpsemalt aastate 2008 kuni 2012 andmetel. Ajaloolised satelliidipildid on sageli madalama kvaliteediga, mis muudab olemasolevate maakatte klassifitseerimise mudelite kasutamise keeruliseks.

Antud töö eesmärk oli lahendada see probleem, luues masinõppepõhise klassifitseerimismudeli, mis suudab eristada looduslikku rohumaad ja põllumaad vanemate satelliidipiltide põhjal.

Kirjandusliku ülevaate peatükis antakse ülevaade varasematest teadusuuringutest, tutvustatakse kasutatud andmestikke ning põhjendatakse töö eesmärgi saavutamiseks tehtud meetoodilisi valikuid. Käsitletakse maakatte klassifitseerimist, Landsat 7 missiooni, WorldCover projekti, sügavõpet ja semantilist segmenteerimist. Metoodika peatükis kirjeldatakse mudeli arendamise protsessi, sealhulgas andmete kogumist ja eeltöötlust. Samuti käsitletakse erinevate meetodite rakendamist mudeli sooritusvõime parandamiseks. Tulemuste peatükis tutvustatakse tehtud eksperimente, analüüsitakse välja töötatud mudeli täpsust ja üldist sooritust ning arutletakse edasiste arenduste üle.

2. Kasutatud mõisted ja terminid

ETM+ - *Enhanced Thematic Mapper Plus*

OLI - *Operational Land Imager*

MSI - *Multispectral Imager*

ESA - *European Space Agency*

USGS - *United States Geological Survey*

CLMS - *Copernicus Land Monitoring Service*

ReLU - *Rectified Linear Unit*

Spektriribad ¹ (ingl *sprectral bands*) - Lainepikkuste vahemikud elektromagnetkiirguse spektris.

Satelliitsensor (ingl *satellite sensor*) - Satelliidil paiknev seade, mis kogub andmeid maapinna ja atmosfääri kohta, näiteks piltide kujul (Mountford jt 2017).

Skaneerimisliini korrigeeriv seade (ingl *scan line corrector*) - Satelliidil paiknev seade, mis kõrvaldab kujutisel tekkiva siksakilise mustri, mille põhjustab satelliidi liikumine (USGS s.a.[a]).

¹ <https://ekitest.tripledev.ee/ww/search/unif/dlall/dsall/spektririba/1/est>

3. Kirjanduslik ülevaade

3.1 Maakatte klassifitseerimine

Maakatteks (ingl *land cover*) nimetatakse maapinna kattekihti. Selleks võivad olla näiteks metsad, põllumaad, veekogud või rohumaad (Campbell ja Wynne 2011). Siinses töös keskendutakse põllumaa ja loodusliku rohumaa eristamisele teistest maakatte tüüpidest.

Põllumaaks peetakse maa-ala, millel kasvatatakse põllumajanduskultuure (Eurostat s.a.). Sama allika kohaselt ei kuulu sinna hulka maa, mis on jäetud puhkama mitmeks aastaks enne, kui seda hakatakse hiljem uuesti harima. Puhkama jäetud põllumajandusmaad saab nimetada aga looduslikuks rohumaks (CLMS s.a.).

Aplin (2004) toob oma töös esile, et maakatte klassifitseerimine on oluline, peamiselt sellepärast, et see võimaldab jälgida keskkonnamuutusi, toetades säästvat maakasutust ja seeläbi aidates kaasa looduskeskkonna kaitsele. Samuti võimaldab see tõhusamat linnaplaneerimist ja põllumajanduse juhtimist, parandades ressursikasutust ja kliimamõjude mõistmist (Aplin 2004).

Lisaks laialdastele kasutusaladele kasutatakse maakatte andmeid ka spetsiifilisemates ülesannetes, näiteks üleujutuste riskianalüüsides (vt nt Belcore jt 2022) või, nagu käsitletud ka siinses töös, ajalooliste põllumajanduslike maakasutusmustrite verifitseerimisel.

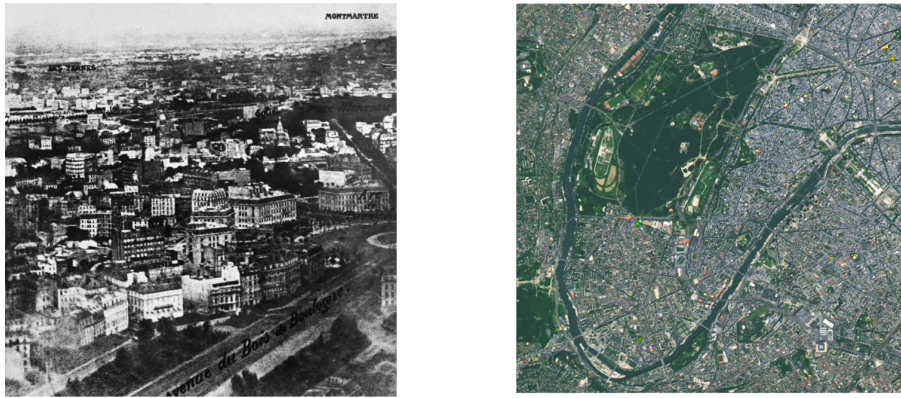
Loveland (2012) sõnul koostati esimesed maakatte kaardid maalt kogutud andmete ja aerofotode põhjal 1930. aastatel, kui kaardistamine tugines peamiselt aerofotode käsitsi tõlgendamisele, mis oli aja- ja töömahukas protsess. Oluline arenguhüpe toimus aga 1972. aastal, mil orbiidile saadeti esimene Landsat-satelliit. See võimaldas esmakordselt kasutada satelliitidelt saadud spektraalseid andmeid maakatte klassifitseerimiseks (Loveland 2012). Satelliitide arengu ja kaugseireandmete kättesaadavuse kasv tõid kaasa esimesed laiaulatuslikud projektid, näiteks 1990. aastal ilmunud Euroopa ulatuses koostatud maakatte kaart Corine Land Cover (Copernicus s.a.).

Tänapäeval toetavad kaugseire, tehnoloogia ja masinõppe areng üha täpsemate maakatte klassifitseerimismudelite väljatöötamist, millest suurem osa põhineb närvivõrkudel (Rafif jt 2024).

Kuigi teadustöid, mis keskenduvad konkreetselt rohumaa ja põllumaa eristamisele, leidub vähe, on rohumaa ja põllumaa sageli esitatud eraldi klassidena erinevates klassifitseerimissüsteemides (Jakubik jt 2023; Temenos jt 2023; Wu jt 2023).

3.2 Kaugseire andmed

Maakatte klassifitseerimise ülesannetes on olulisel kohal kvaliteetsed kaugseireandmed (Rwanga ja Ndambuki 2017). Chuvieco (2016) kirjelduse kohaselt tähendab kaugseire objektide omaduste mõõtmist ilma nendega otseselt kokku puutumata. Ajalooliselt peetakse esimesteks kaugseireandmeteks 1860. aastatel tehtud aerofotosid. Kaasaegne kaugseire sai alguse aga 1970. aastatel satelliitide kasutuselevõtuga (Chuvieco 2016). Joonisel 1 on võrdluseks kujutatud kõrvuti kaugseire algusaegade aerofoto ja tänapäevane satelliidipilt.



Joonis 1. Vasakul on kujutatud esimene säilinud aerofoto Pariisist (Tournachon 1866), paremal aga 2024. aastal Landsat 9 satelliidiga tehtud pilt samast linnast (Garrison 2024).

Järgnev materjal on refereeritud NASA Earthdata (s.a.) lehelt. Kaugseireandmeid kogutakse passiivsete ja aktiivsete satelliitsensoritega. Passiivsed sensorid mõõdavad looduslikku elektromagnetilist kiirgust, mida objektid peegeldavad või kiirgavad, sealhulgas kiirgust, mis ei ole inimesele nähtav, näiteks ultraviolet- ja infrapunakiirgus. Passiivsete sensorite hulka kuuluvad näiteks ETM+ ja OLI sensorid Landsat-satelliitide pardal ning MSI sensor Sentinel-2 satelliidil. Aktiivsed sensorid, näiteks radarid, kiirgavad ise elektromagnetilist signaali ja mõõdavad seejärel selle peegeldust. Suurem osa aktiivseid sensoreid kasutab mikrolaineid, mis võimaldavad andmete kogumist ka keerukates ilmastikutingimustes nagu pilvisus. Siinses töös keskendutakse passiivsete sensoritega kogutud andmetele, kuna need on antud ülesande jaoks sobivad, kergemini kättesaadavad ja lihtsamini töödeldavad.

Järgnev lõik tugineb NASA Earthdata (s.a.) lehele. Satelliitidelt saadud andmete omadusi saab kirjeldada nelja tüüpi lahutusvõime kaudu. Ruumiline lahutusvõime näitab, kui suurt ala maapinnal katab üks piksel pildil – mida väiksem on lahutusvõime, seda detailsem on pilt. Spektraalne lahutusvõime viitab sellele, kui paljudes ja kui kitsastes lainepikkustes andmeid kogutakse. Multispektraalsed sensorid koguvad andmeid tavaliselt 3–10 spektraalses ribas.

Radiomeetriline lahutusvõime näitab, kui täpselt suudab sensor mõõta elektromagnetilise kiirguse intensiivsust. Seda esitatakse üldjuhul bitides. Näiteks Landsat 7 EMT+ sensoril on 8-bitine radiomeetriline lahutusvõime, mis tähendab, et sensor saab eristada 256 erinevat kiirgusväärtust. Ajaline lahutusvõime kirjeldab, kui tihti satelliit sama piirkonda uuesti külastab. Väiksem ajaline lahutusvõime võimaldab paremini jäädvustada ajas toimuvaid muutusi.

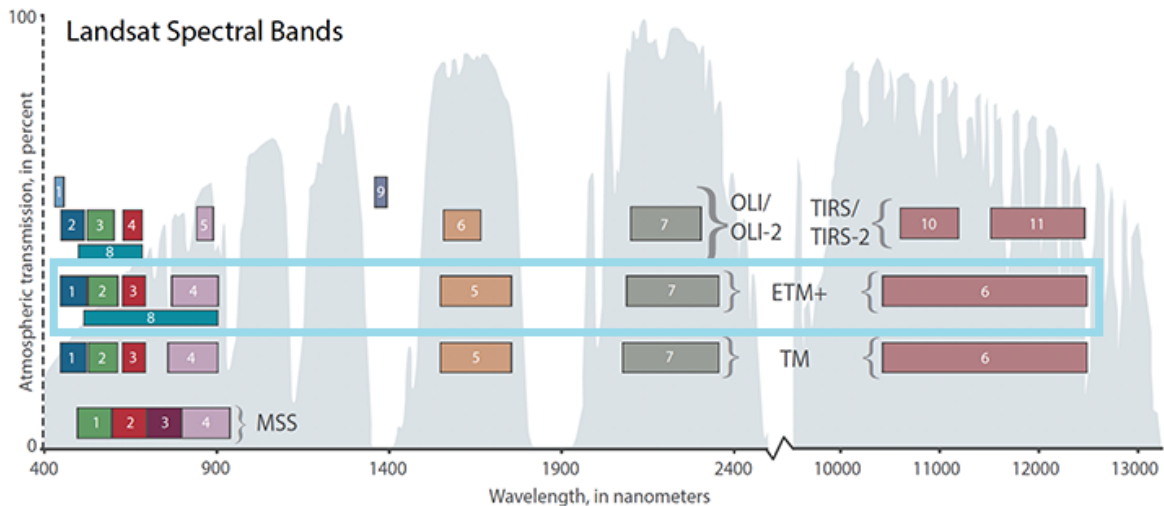
Selles töös kasutatakse Landsat 7 satelliidi andmeid, mille omadustest ja valiku põhjustest räägitakse täpsemalt järgmises peatükis.

3.2.1 Landsat 7 satelliit

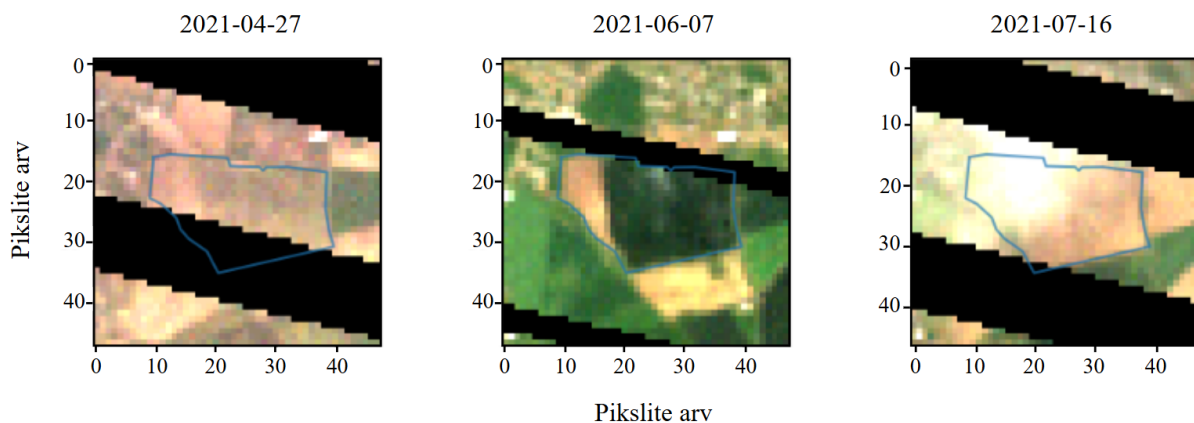
Mudeli loomiseks tuli koostada andmestik, mis koosneks satelliitpiltidest. Satelliidi kui andmeallika valik sellise andmestiku loomiseks lähtus kahest kriteeriumist: missiooni kestus ja andmete kättesaadavus. Kaugseireandmed pidid olema kättesaadavad vähemalt ajavahemikus 2008–2012 ning avalikult ligipääsetavad. Ainsaks kriteeriumitele vastavaks kandidaadiks osutus Landsat 7 satelliit, mille teadusmissioon algas 1999. aastal ja kestis kuni 2024. aasta jaanuarini, pakkudes seega suure hulga ajaloolisi andmeid. Samuti on Landsat 7 andmed avalikult kättesaadavad ning sisaldavad regulaarselt 16 päevase vahega tehtud pilte maast kogu missiooni vältel (USGS s.a.[a]).

Landsat 7-l oli paigaldatud ETM+ sensor, mis salvestas andmeid kaheksasse spektriribasse (USGS s.a.[a]), vaata joonis 2. Täpsem teave ETM+ sensori kanalite, lainepikkuste ja nende rakendusala kohta on esitatud tabelis 3 (vt lisa 1). Peale kaheksa põhilise kanali, on Landsat 7-l olemas ka pildi kvaliteeti hindav kanal (ingl *Quality Assessment Band*) (USGS s.a.[b]). Iga piksel selles kanalis sisaldab olulist teavet pildi kvaliteedi kohta, mis on kodeeritud bitipõhistesse täisarvudesse, kus iga bitt tähistab näitajaid nagu pilvkate, pilvede varjud, lume või jää olemasolu jms (USGS s.a.[d]).

Landsat 7 ETM+ andmed said 2003. aastal tugevalt kahjustada, kui skaneerimisliini korrigeeriv seade (ingl *scan line corrector*) lakkas töötamast (USGS s.a.[a]). Rike põhjustas ligikaudu 22% andmete puudumise, mis avaldus piltidel mustade triipudena (USGS s.a.[a]). Nagu näha ka joonisel 3, ei ole triipude asukoht kindlalt määratud. Töös kasutatud rikke mõju leevendamise viise kirjeldatakse metoodika peatükkides.



Joonis 2. Landsat satelliitide sensorite ribad ja nende lainepikkused (Rocchio ja Barsi 2020). Landsat 7 ETM+ sensori ribad on märgistatud joonisel helesinisega kastiga. Horisontaalteljel on esitatud lainepikkus nanomeetrites, vertikaalteljel näitab aga atmosfääri läbilaskvust protsentides. Kõrgemad atmosfääri läbilaskvuse väärtused tähistavad lainepikkusi, kus elektromagnetiline kiirgus läbib atmosfääri minimaalsete kadudega, võimaldades satelliitsensoritel koguda täpsemaid kaugseireandmeid.



Joonis 3. Näide sellest, kuidas sensori rike avaldub pildidel. Sinine piirjoon pildidel tähistab põllu kontuuri, mille otstarvet kirjeldatakse metoodika peatükkides 4.1 ja 4.2.

Kättesaadavad on Landsat 7 satelliidi kaks andmestikku – Level-1 ja Level-2 (USGS s.a.[c]). Peamine erinevus andmestike vahel seisneb selles, et Level-2 andmetele on lisaks rakendatud atmosfääri korrektsioonid. Need eemaldavad atmosfääri mõjudest (udu, õhukesed pilved) tekitatud moonutused peegeldunud kiirguse väärtustest. Tänu sellele kajastavad need andmed maapinna omadusi täpsemalt. Lähtudes Level-2 eelistest, kasutatakse just seda antud töö raames.

3.2.2 WorldCover projekt

Teine oluline töös kasutatud andmestik oli avalikult kättesaadav WordCover 2021 andmestik (Zanaga jt 2022). Zanaga jt (2022) loodud andmestik on esitatud kaardina, kus iga piksli väärtus tähistab kindlat maakatte tüüpi. See võimaldas luua klassifitseerimismudeli jaoks vajalikke märgendeid, seostades satelliidipiltide info konkreetsete klassidega.

WorldCover projekti raames töötati välja kaks andmestikku. Esimene andmestik avaldati 2021. aasta oktoobris ning see kajastab 2020. aasta maakasutust täpsusega 74.4% (ESA 2022). Aastal 2022 ilmus uus andmestik, mis kajastab 2021. aasta maakasutust ning oli loodud täiendatud algoritmiga, mis ESA (2022) poolt koostatud projekti dokumentatsiooni kohaselt liigitas korrektselt 76,7% maakattest. Kuna andmestiku aastavalik ei mõjutanud töö teisi aspekte, otsustati kasutada 2021. aasta andmeid.

Worldcover 2021 andmed on 10-meetrise ruumilise lahutusvõimega ning nende koostamiseks kasutati Sentinel-1 ja Sentinel-2 sateliitide andmeid. Andmestik kajastab kokku 11 erinevat maakasutustüübi klassi (ESA 2022), millest rohumaa ja põllumaa klassid ühilduvad kirjelduse kohaselt klassidega, mida tuvastatakse selles töös arendatud mudeli abil. WorldCover 2021 osutus käesoleva töö kirjutamise ajal tehtud otsingu põhjal kõige täpsemaks avalikult kättesaadavaks globaalseks maakatte andmestikuks.

3.3 Sügavõpe

Masinõppe (ingl *machine learning*) eesmärk on leida struktuure ja seoseid andmetes, et teha nende põhjal prognoose või otsuseid (Goodfellow jt 2016). Sügavõpe (ingl *deep learning*) on aga masinõppe haru, mis keskendub mitmekihiliste tehismärgivõrkude (ingl *artificial neural networks*) abil mustrite tuvastamisele andmehulkadest (LeCun jt 2015). Tehismärgivõrgud on inspireeritud inimese aju neuronite toimimisest ja püüavad matemaatiliste funktsioonide abil jäljendada neuronitevahelist infovahetust ja reaktsioone välistele stiimulitele (LeCun jt 2015).

Sügavõppe võime avastada peidetud ja mitte-linearseid seoseid teeb sellest võimsa tööriista, mida rakendatakse laialdaselt erinevates valdkondades, sealhulgas automaatses kõnetuvastuses, loomuliku keele töötlemises ning pildituvastuses (LeCun jt 2015). Samuti pakub sügavõpe võimalust paremini ekstraheerida teavet kaugseire andmetest, näidates häid tulemusi näiteks kaugseire piltide klassifitseerimisel (Huang jt 2018; Neupane jt 2021).

3.3.1 Semantiline segmenteerimine

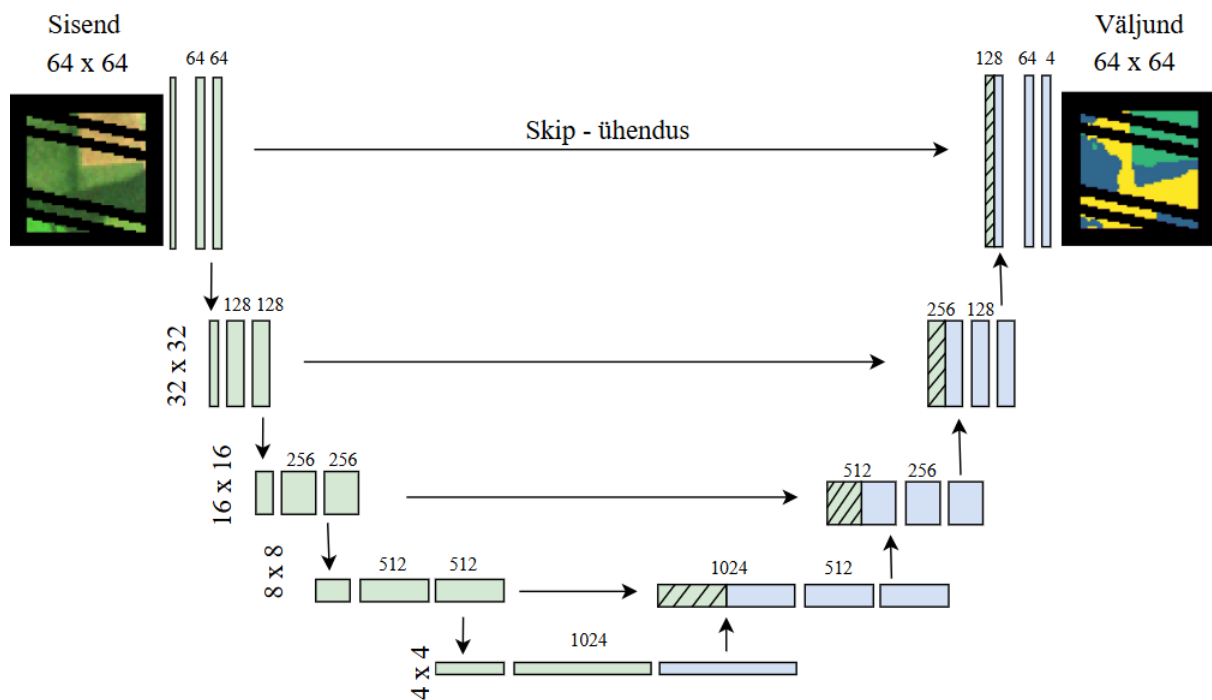
Selle töö raames lahendatav sügavõppe ülesanne on semantiline segmenteerimine (ingl *semantic segmentation*), mis kuulub masinnägemise valdkonda. Semantiline segmenteerimine seisneb iga pildi pikslile kindla klassi määramises, võimaldades detailsemat kujutiste tuvastamist võrreldes traditsioonilise objektituvastusega, mis märgendab pilti objektide või piirkondade tasemel (Spasev jt 2024).

Spasev jt (2024) toovad oma töös välja, et semantiline segmenteerimine on laialdaselt kasutusel kaugseirepiltide analüüsis, kuna see võimaldab täpselt esitada teavet kaugseirepiltidel kujutatavate omaduste ruumilisest jaotusest. Semantilise segmenteerimise ülesandeid kaugseirepiltidel lahendatakse üha enam sügavõppe abil, täpsemalt konvolutsiooniliste närvivõrkude ehk CNN-ide (*Convolutional Neural Network*) abil. Sellised mudelid tuvastavad tooraandmetest olulisi omaduste seoseid ning võtavad neid arvesse klassifitseerimisprotsessis (Gu jt 2022). Tuntumad sellised konvolutsioonilised närvivõrgud on näiteks U-Net ja DeepLabv3 (Spasev jt 2024).

3.3.2 U-Net närvivõrk

Siinse töö raames semantilise segmentatsiooni ülesande lahendamiseks oli valitud U-Net närvivõrk, mis oli esialgu arendatud biomeditsiinilise pilditöötamise jaoks (Ronneberger jt 2015). U-Net arhitektuuriga närvivõrgud on saavutanud häid tulemusi satelliidipiltidel objektide tuvastamisel, näiteks 2012. aasta Kaggle võistluse “Dstl Satellite Imagery Feature Detection” parimad lahendused põhinesid just U-Net arhitektuuril (Kaggle 2017). Arhitektuuri on edukalt rakendatud erinevates segmenteerimisülesannetes, nagu näiteks hoonete ja veekogude tuvastamine, kasutades nii silmale nähtavaid kui ka spektraalseid pildiandmeid (Jakubik jt 2023).

Ronneberger jt (2015) kirjeldavad oma töös mudeli võimekust õppida väikese andmemahulga pealt, säilitades kiire õppe- ja ennustamise kiiruse. Samas töös kirjeldatakse U-Net arhitektuuri sümmeetrilise U-kujulise struktuurina (vt joonis 4), kus protsessi esimeses pooles ehk kooderi osas (ingl *encoder*) toimub pildi omaduste eraldamine konvolutsioonikihtide abil (ingl *convolutional layers*) ning pildi suuruse vähendamine (ingl *downsampling*).



Joonis 4. U-Neti viietaseline arhitektuur, kus sisendpildi suurus on 64×64 pikslit. Vertikaalselt toodud mõõtmed (nt 32×32) tähistavad pildi mõõtmeid. Horisontaalselt iga sammu juures märgitud arvud näitavad kanalite arvu, mis tekivad pildilt omaduste eraldamisel konvolutsioonide abil.

Teises pooles ehk dekooderi (ingl *decoder*) osas toimub pildi mõõtmete taastamine transponeeritud konvolutsioonide (ingl *transposed convolution*) abil ning ruumiliste detailide taastamine skip-ühenduste (ingl *skip connections*) abil. Skip-ühendused viivad algse kõrgresolutsioonilise teabe otse dekooderiossa ja tagavad, et algse pildi servad ja tekstuurid säilivad, isegi kui sügavad kihid ei jäta neid meelde.

4. Metoodika

4.1 Andmete kogumine ja töötlus

Mudeli treenimiseks ja testimiseks oli vaja luua andmestik, mis sisaldaks satelliitpilte ja nendele vastavaid alustõe (ingl *ground truth*) märgendeid. Nii U-Net kui ka teised konvolutsioonilised närvivõrgud, mis täidavad semantilise segmenteerimise ülesandeid, vajavad treenimiseks andmestiku, kus igale pildi pikslile on määratud kindel klass alustõde märgendis (Csurka jt 2022). Käesoleva töö raames kasutati piltidena Landsat 7 2021. aasta satelliitpilte ning alustõde märgendeid koguti WorldCover 2021 andmestikust. Pildid ja märgendid hõlmasid kuue parasvöötmes asuva riigi (Eesti, Poola, Moldova, Rumeenia, Hispaania ja Ukraina) maalaasid. Kasutatud satelliitpiltide mõõtmed on 48×48 pikslit, kus iga piksel vastab 30×30 meetri suurusele maatükile. Sellest tulenevalt katab üks pilt ligikaudu 208 hektari suuruse ala.

Lisaks eelmainitud andmetele kasutati töös eAgronomi ja STACC OÜ projekti andmebaasist pärinevaid põllukujuandmeid, mida edaspidi töös nimetatakse geometriateks. Põllukujuandmeid kasutati mudeli lisatestimiseks, mida kirjeldatakse täpsemalt alapeatükis 4.2. Põllukujuandmete eeltöötlemine ja nende abil mudeli testimine viidi läbi eAgronomi ja STACC OÜ projekti jaoks loodud algoritmide ja tööriistade abil.

4.1.1 Landsat 7 andmevoog

Landsat 7 satelliidi pildid olid alla laetud Sentinel Hub Processing API² abil. Eelmainitud API (*Application Programming Interface*) võimaldab mugavalt pärida pilte konkreetse aja, suuruse, ribade ja koordinaatide põhjal.

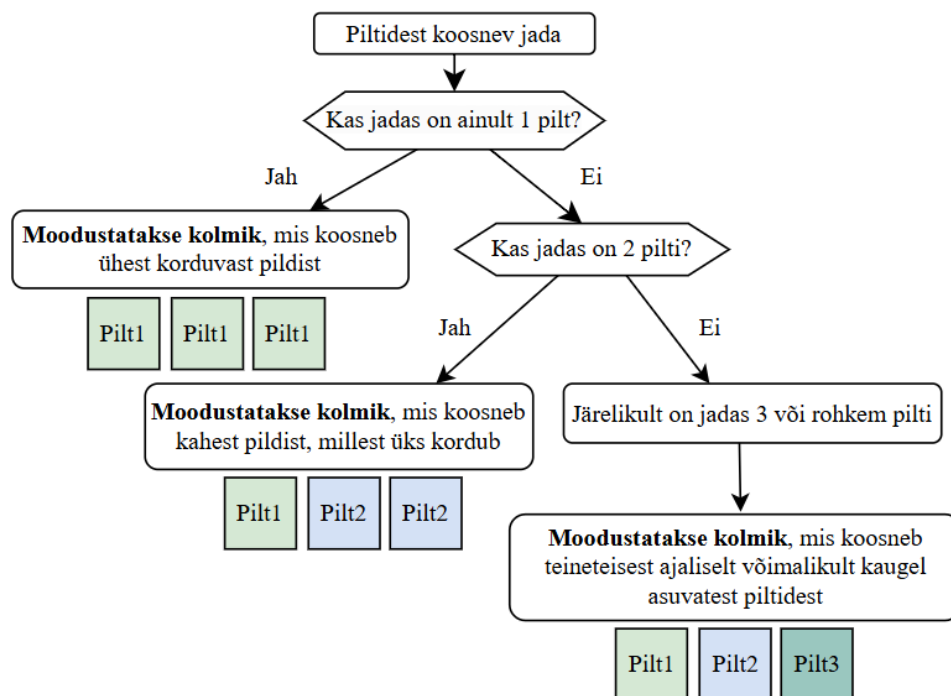
Esmalt tehti API kaudu päring konkreetse maa-ala kohta, määrates geograafilised koordinaadid, ajavahemiku, soovitud spektriribade loetelu ning väljundi mõõtmed. Ajavahemikuks oli valitud periood 1. märtsist 30. septembrini, et vältida pilte, kus ala oli kaetud lumega või liigselt pilvine. Päritavad spektriribad olid 1 kuni 5 ja 7 (vt lisa 1).

Päringu väljundiks olid kõik eelmainitud kriteeriumidele vastavad pildid, mille hulgast valiti seejärel välja kolm parimat. Kuna põllumaa on pidevalt töödeldud, on sellest peegeldav kiirgus tunduvalt erinev rohumaa omast, mis on ajas eeldatavalt stabiilne. Seega eri ajal tehtud piltidest

² <https://docs.sentinel-hub.com/api/latest/api/process/>

koosnev aegrida aitab teha mudelil neil vahet, nagu on näidanud Phan jt (2020). Käesolevas töös oli aegrea pikkuseks valitud kolm pilti, võttes eeskujuks Jakubik jt (2023) töö.

Parima aegrea koostamiseks oli loodud algoritm, mis otsib võimalikult head piltide kolmikut, kindlustades, et maatüki geomeetria ei ole kogu oma pindala ulatuses varjatud mustade triipudena. Esialgselt valitakse piltide jada, kus iga pildi pilviste pikslite on alla 40% ning mustade pikslite osakaal alla 50%. Kui tingimustele vastavad pildid puuduvad, jäetakse maatükk andmestikust välja. Vastasel juhul valitakse saadud jadast pildid, mille puhul on maatükk geomeetria sees nähtav (ala ei ole must ega pilvine) vähemalt 60% ulatuses. Kui sellised pildid on olemas, moodustatakse neist kolmik. Kui ei ole, koostatakse kolmik esialgselt jadast. Kolmiku koostamise protsess on kujutatud joonisel 5.



Joonis 5. Pildikolmiku koostamise protsessi illustreeriv puudiagramm.

Valitud pildid pannakse kokku ja salvestatakse GeoTIFF-failina, mis moodustab 18-kihilise objekti, kus iga kiht on 48 x 48 suurune kahemõõtmeline massiiv, mille iga element on piksli väärtus. Enne mudelile söötmist olid pildi ääred täidetud mustade pikslitega (ingl *padding*), et saavutada sisendi suurus 64 x 64 pikslit. See samm on vajalik, kuna kasutatud arhitektuur nõuab pildi suurust, mis on jagatav 32-ga, et tagada viietasandiline struktuur.

4.1.2 Märkendite eeltöötlus

Märkendite loomiseks kasutati WordCover 2021 andmestiku, mille andmed olid avalikult kättesaadavad Euroopa Kosmoseagentuuri veebilehel. Andmestik on jagatud 60 x 60 kraadi suurustesse plaatidesse, kus iga plaat katab 60 kraadi laiuse ja 60 kraadi pikkuse maa-ala. Need plaadid on omakorda jagatud 3 x 3 kraadi suurustesse alamplokkidesse. Valitud riikide andmete allalaadimiseks oli vaja tõmmata kolme plaadi andmed, mis olid salvestatud Cloud Optimized GeoTIFF (COG) formaadis (ESA 2022).

Maatükid olid välja lõigatud kasutades eAgronomi ja STACC OÜ projekti koodibaasis olevat tööriista, mis lõikas ja salvestas andmebaasi kindlatesse klassidesse kuuluvaid maatükke. Selleks, et mudel saaks eristada rohumaa ja põllumaa klasse, oli 11 WordCover klassist alles jäetud muutmata kujul klassid Rohumaa (ingl *Grassland*) ja Põllumaa (ing *Cropland*) vastavalt koodidega 30 ja 40. Ülejäänud klassid olid pandud kokku üheks klassiks, milleks on 'Muu'. Märkendi ääred olid samuti täidetud mustade pikslitega, et saavutada 64 x 64 piksline suurus.

4.1.3 Sensori rikke haldamine

Sensori rike avaldub mustade triipudena piltide peal ning triipude asukoht ei ole kindlalt määratud.

Kuna eesmärk oli anda mudelile sisendiks kolmest pildist koosnev aegrida, tuli vältida olukorda, kus konkreetne piksel oli näiteks kahe pildi peal hea ehk omas väärtust, mis ei ole must, kuid kolmanda pildi peal oli see must. Selline ebajärjekindlus võis halvendada mudeli klassifitseerimistulemusi.

Kirjeldatud olukorra vältimiseks kombineeriti kõikidel kolmel pildil esinevad mustad triibud ühtseks maskiks, mida rakendati igale aegrea pildile. Edasi nimetatakse seda protsessi mustade maskide kombineerimiseks.

4.2 Tulemuste hindamine

Mõõdikute arvutamiseks kasutati nelja põhiväärtust: tõeste positiivsete (TP, ingl *true positives*) arv, valepositiivsete (FP, ingl *false positives*) arv, tõeste negatiivsete (TN, ingl *true negatives*) arv ja valenegatiivsete (FN, ingl *false negatives*) arv.

Müller jt (2022) esitavad oma töös mitmeid mõõdikuid ja juhiseid semantilise segmentatsiooni mudelite hindamiseks. Autorid soovivad eelkõige kasutada IoU-d (*Intersection over Union*) ja Dice'i koefitsienti, arvutades need eraldi iga klassi jaoks juhul, kui tegemist on mitmeklassilise

klassifikatsiooniga. Edaspidi viidatakse Dice'i koefitsiendile kui F1-skoorile, kuna nende väärtused on antud ülesande hindamise kontekstis samad.

IoU mõõdab, kui hästi kattuvad mudeli ennustatud pikslid tegelike märgenditega ning annab seeläbi täpse hinnangu mudeli võimele objekte taustast eristada. IoU arvutatakse valemi (1) järgi.

$$IoU = \frac{TP}{TP + FP + FN} \quad (1)$$

F1 skoor, nagu näidatud valemis (4), kombineerib täpsuse ja saagise harmooniliseks keskmiseks, pakkudes tasakaalustatud mõõdikut mudeli üldise jõudluse hindamiseks.

Täpsus (ingl *precision*) ja saagis (ingl *recall*) on samuti olulised mõõdikud mudeli soorituse hindamisel. Täpsus mõõdab, kui suur osa mudeli poolt positiivseks klassifitseeritud juhtumitest on tegelikult õiged.

$$Täpsus = \frac{TP}{TP + FP} \quad (2)$$

Saagis (ingl *recall*) näitab aga, kui suur osa kõigist tegelikest positiivsetest juhtumitest on mudeli poolt õigesti tuvastatud. Saagis arvutatakse valemi (3) abil.

$$Saagis = \frac{TP}{TP + FN} \quad (3)$$

$$F1\text{-skoor} = 2 * \frac{Täpsus * Saagis}{Täpsus + Saagis} \quad (4)$$

Müller jt (2022) rõhutavad oma töös, et tulemuste hindamisel tuleks vältida meetrikaid, mis kaasavad arvutusse tõeseid negatiivseid näiteid, kuna need võivad moonutada tulemusi, eriti juhul, kui huvipakkuv ala (ROI, ingl *Region of Interest*) moodustab vaid väikese osa pildist võrreldes taustaga. Seetõttu ei kasutata käesolevas töös mudelite hindamisel meetrikaid, mis sõltuvad tõeste negatiivsete väärtuste osakaalust, nagu õigsus (ingl *accuracy*).

Tulemuste peatükis esitatakse ka segadusmaatriksid (ingl *confusion matrix*). Segadusmaatriks võrdleb ennustatud väärtusi tegelike väärtustega testandmestikus, kuvades tõeste positiivsete, valepositiivsete, tõeste negatiivsete ja valenegatiivsete arvu. Siinses töös on segadusmaatriksid esitatud normaliseeritud kujul, mis tähendab, et ennustatud väärtused on esitatud osakaaludena, mis võimaldab võrrelda tulemusi, arvestamata klasside esinemistsagedust testandmestikus. Tuleb märkida, et sagedusmaatriks selles töös ei kajasta kõigi klassifitseeritud pikslite jaotust, vaid

igale pildile omistatakse ainult üks klass, mis oli määratud vastavalt sellele, milline klass esines enim pildil paikneva põllu geomeetria sees. Selline lähenemine imiteerib praktilist kasutusjuhtu eAgronom ja STACC OÜ projektis, kus kogu sisendpildile määratakse vaid üks klass.

5. Tulemused

5.1 Mudeldamine

U-Net arhitektuur oli mugavalt kättesaadav PyTorch³ raamistikul põhineval Segmentation Models⁴ teeki abil (Iakubovskii 2019). Sama teek pakub erinevaid lisafunktsioone, nagu mugav mõõdikute arvutamine ning lai kooderite valik. Kõik eksperimentaalsed mudelid ja valmis mudel olid treenitud ühe 16 GB mälu GPU (ingl *graphics processing unit*) peal.

5.1.1 Võrdlusmudel

Antud töö raames võib esialgseks mudeliks ja edaspidiste eksperimentide jaoks võrdlusmudeliks pidada mudelit, mis oli treenitud 4000 pilt-märgend paari pealt, ilma mustade maskide kombineerimist. Mudel põhines Segmentation Models teegi U-Net arhitektuuril, kasutades treenimiseks vaikeparameetreid.

Mudel kasutas vaikimisi kodeerina ImageNet⁵ andmestikul eeltreenitud ResNet-34⁶ klassifitseerijat. Arhitektuur oli viietasandiline, kus dekodeerikanaliteks olid 256, 128, 64, 32, 16. Vastavalt töös kasutatud piltide suurusel oli dekodeerikanalid muudetud kujule 64, 32, 16, 8, 4 - sama arhitektuur on kujutatud ka joonisel 4. Normaliseerimiseks oli kasutusel Batch Normalization⁷, ruumilise eraldusvõime taastamiseks aga lähima naabri (ingl *nearest neighbor*) interpoleerimist. Aktivatsioonifunktsioonina oli kasutusel ReLU. Väljundkihis kasutati lõplike klasside tõenäosuste saamiseks Softmax-funktsiooni⁸.

Esialgne mudel oli testitud 500 pilt-märgend paari pealt. Mudeli tulemused on esitatud segadusmaatriksina joonisel 6 ning täpsemad hindamistulemused on toodud tabelis 1. Tabelis olevad meetrikad hindavad mudelit aga piksli tasemel.

Nagu segadusmaatriksil näha võib, suudab mudel rohumaad ja põllumaad mõningal määral eristada, kuid esineb eksimusi. Õigesti sai klassifitseeritud 92% rohumaadest ja 83% põllumaadest. Samuti võib näha, et märkimisväärne osa põllumaadest oli klassifitseeritud ekslikult rohumaana.

³ <https://pytorch.org/>

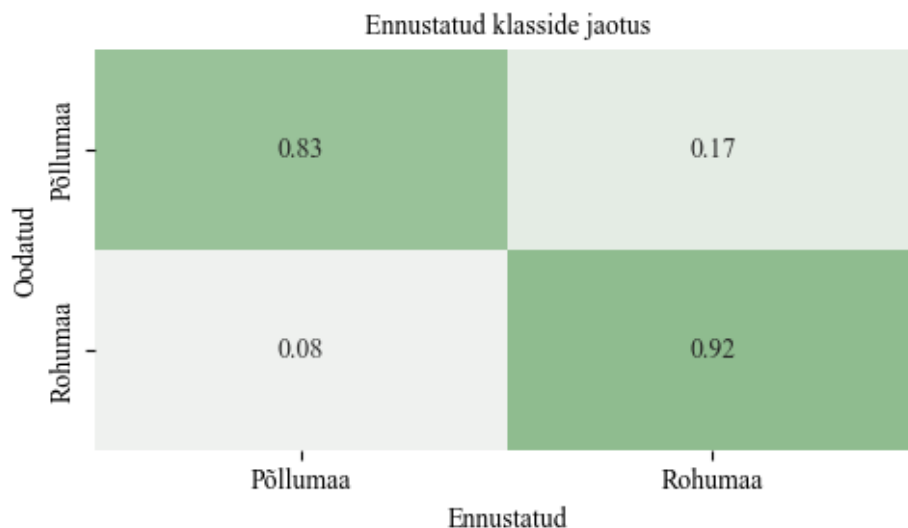
⁴ https://github.com/qubvel/segmentation_models

⁵ <https://www.image-net.org/index.php>

⁶ <https://pytorch.org/vision/main/models/generated/torchvision.models.resnet34.html>

⁷ <https://pytorch.org/docs/stable/generated/torch.nn.BatchNorm1d.html>

⁸ <https://pytorch.org/docs/stable/generated/torch.nn.Softmax.html>



Joonis 6. Esialgse mudeli segadusmaatriks.

Tabel 1. Tabel esialgse mudeli hindamistulemustega.

Klass	Meetrika			
	F1	IoU	Täpsus	Saagis
Rohumaa	0.75	0.60	0.78	0.73
Põllumaa	0.78	0.64	0.75	0.81
Muu	0.70	0.54	0.73	0.68

Esialgse mudeli keskmine täpsus klasside esinemissagedust arvestamata (ingl *macro averaged*) oli 0.75, keskmine saagis 0.74, keskmine F1-skoor 0.74 ja keskmine IoU 0.59. Madalam IoU viitab keerukustele segmentide täpsel eristamises. Põllumaa klassil oli kõrgeim F1 skoor ja saagis, kuid täpsus oli saagisest väiksem, mis viitab valepositiivsete esinemisele ehk põllumaaks klassifitseeritakse ka alasid, mis tegelikult seda ei ole. Rohumaa puhul oli täpsus kõrgem kui saagis, viidates osalisele alatu vastamisele.

Kokkuvõttes näitab mudel üldiselt head klassifikatsioonivõimet. Seda kinnitab võrdlus Jakubik jt (2023) töös valminud U-Neti mudeliga, mis oli treenitud USA andmetel 100 epohhi vältel. Mudel saavutas loodusliku rohumaa klassi puhul tuvastamise õigsuseks 0.6367 ja IoU skooriks 0.4578 ning põllumaa klassi puhul vastavalt 0.5294 ja 0.3599. Kuigi siinses töös ei ole õigsus mudeli hindamise peamine näitaja, võib võrdluse eesmärgil märkida, et võrdlusmudeli õigsus rohumaa klassi osas oli 0.84 ning põllumaa osas 0.89. Vaatamata sellele on mudelil raskusi ruumilise ja klasside vahelise eristamisega.

5.1.2 Eksperimendid

Esialgsed eksperimendid viidi läbi 5000 pildi ja märgendi paarist koosneva andmehulgaga, millest 4000 kasutati mudeli treenimiseks ning 500 testimiseks ja valideerimiseks. Sama andmehulk oli kasutusel ka võrdlusmudeli treenimiseks ja testimiseks, mis võimaldas võrrelda eksperimentide käigus saadud tulemusi võrdlusmudeliga. Samuti oli väiksel andmehulgal treenimine kiirem, võimaldades sooritada rohkem treenimise ja testimise iteratsioone.

Läbi viidud eksperimendid võib jagada kahte kategooriasse:

- mudeli sisendi muutmine;
- mudeli hüperparameetrite seadistamine.

Eksperimentide valik lähtus võrdlusmudeli meetrikatest ja nende põhjal tehtud järeldustest, varasemast kogemusest ning erialakirjanduses käsitletud lähenemistest.

Mudeli sisendi osas viidi läbi mitmed katsed. Näiteks testiti mudeli võimekust olukorras, kus sisendina on kasutusel ainult osa saadaval olevatest spektriribadest, milleks oli sinine, roheline, punane ja lähiinfrapuna. Eksperimendi eesmärk oli hinnata, kas vähendatud spektriline info on piisav segmentatsiooniks. Samuti viidi läbi eksperimente, mille eesmärk oli hinnata mitmekesise aegrea mõju mudeli võimekusele. Mudeli sisendiks olevad kolmikud moodustati selliselt, et pildid pärineksid teineteisest võimalikult kaugel olevatest ajahetkedest, isegi juhul, kui nende kvaliteet oli nendes ajahetkedes kehvem. Viidi läbi eraldi eksperimendid, millega püüti vähendada sensori rikke mõju mudeli võimekusele. Selleks katsetati mustade triipude täitmise algoritmi ja kolme pildi peal olevate triipude kombineerimist üheks maskiks. Prooviti ka valida ainult need pildid, mille puhul põllu geomeetria ei olnud mustade triipudena varjatud rohkem kui 40% võrra.


Mudeli hüperparameetrite osas katsetati erinevad kaofunktsioone (ingl *loss function*). Võrreldi ristentroopia (ingl *cross-entropy*) ja Dice kaofunktsiooni. Ristentroopia on levinud valik mitmeklassilise segmenteerimise ülesannetes, samas kui Dice kaofunktsioon on tihti sobivam olukordades, kus ruumiline täpsus on tähtis.

Võrdlusmudeli tulemusi parandasid järgmised täiendused:

- mustade maskide kombineerimine;
- Dice kaofunktsioon;
- aegrea pikendamine kvaliteedi loovutamiseks.

5.1.3 Põllumaa ja rohumaa klassifitseerimismudel

Rakendades eksperimentide käigus välja tulnud mudeli võimekust parandavaid täiendusi, oli treenitud lõplik põllumaa ja rohumaa klassifitseerimismudel. Treeningandmestik koosnes 8671 pildi ja vastava märgendi paaridest. Märgendite klasside jaotus treeningandmestikus enne mustade maskide rakendamist on kujutatud joonisel 7.

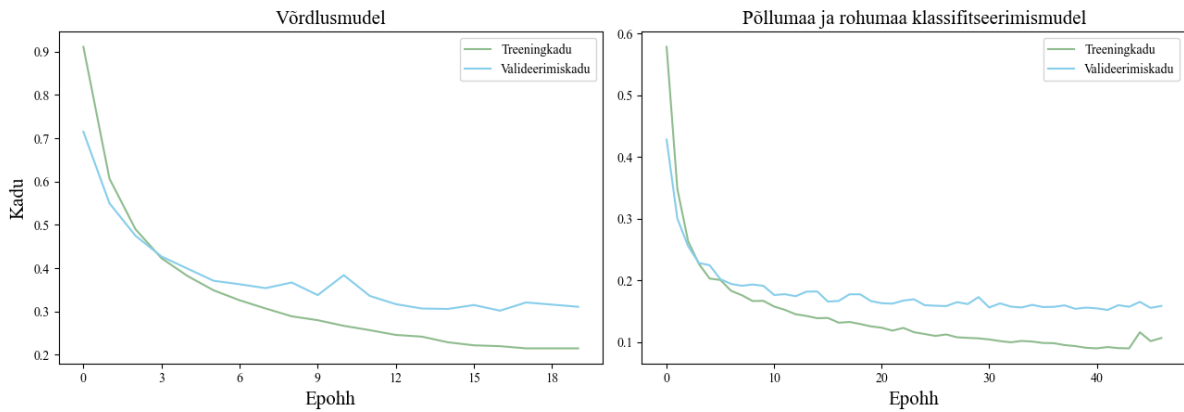


Joonis 7. Klasside jaotus treeningandmestikus.

Andmed olid jaotatud proportsioonis 80% treeninguks, 10% valideerimiseks ja 10% testimiseks. Valideerimis- ja testimishulgad sisaldasid kumbki ligikaudu 1000 näidet. Mudel oli treenitud 46 epohhi vältel. Epohhide arv kujunes varajase peatumise abil, kus treenimise protsess peatus juhul, kui kaofunktsiooni väärtus ei olnud viie järjestikuse epohhi vältel vähenenud.


Joonisel 8 on kujutatud võrdlusmudeli ning põllumaa ja rohumaa klassifitseerimismudeli õppimiskõverad, mis annavad ülevaate mõlema mudeli õppimisprotsessi käigust. Valmis põllumaa ja rohumaa klassifitseerimismudeli treenimiskadu väheneb pidevalt, samas kui valideerimiskadu stabiliseerub pärast esialgset langust. See viitab sellele, et mudel õppis edukalt ning suudab uutel andmetel üldistada ilma märgatava ülesobitamisetä (ingl *overfitting*). Võrdlusmudeli puhul aga langeb treeningukadu samuti stabiilselt, kuid valideerimiskadu hakkab juba varakult kõikuma ega parane edasise treenimisega märgatavalt. Sellest võib järeldada, et tehtud täiendused on parandanud mitte ainult mudeli täpsust, vaid ka õppeprotsessi efektiivsust.

Testimisandmestikus oli 493 põllumaa näidist ja 590 rohumaa näidist. Mudeli tulemused on esitatud segadusmaatriksina joonisel 10 ning täpsemad hindamistulemused on toodud tabelis



Joonis 8. Võrdlusumudeli ning põllumaa ja rohumaa klassifitseerimismudeli treening- ja valideerimiskadu epohhide vältel.

2. Segadusmaatriksi väärtused on saadud maatüki geometria sees enim esinenud klassi alusel. Geomeetria pindalade jaotus on kujutatud joonisel 9.




Joonis 9. Treeningandmestiku geomeetria pindalade jaotus.

Segadusmaatriksi põhjal oli 86% põllumaadest ja 95% rohumaadest klassifitseeritud korrektselt. Samas oli 13% põllumaadest määratud ekslikult rohumana. See viitab mudeli kalduvusele määrata ebakindlates olukordades klassiks rohumaa.

Valmis mudeli keskmine täpsus klasside esinemissagedust arvestamata (ingl *macro averaged*) oli 0.79, keskmine saagis 0.79, keskmine F1-skoor 0.79 ja keskmine IoU 0.66. Need tulemused näitavad, et mudel on võrdlusudeliga võrreldes paranenud – täpsus, saagis ja F1-skoor on suurenenud umbes 4–5%, IoU aga 7% võrra.

Tabeli põhjal saab täpsemalt hinnata klasside kaupa saadud tulemusi. Põllumaa klassi puhul oli võrdlusudeliga sarnaselt täpsus kõrgem kui saagis, mis viitab valepositiivsete esinemisele.



Joonis 10. Põllumaa ja rohumaa klassifitseerimismudeli segadusmaatriks.

Tabel 2. Tabel põllumaa ja rohumaa mudeli hindamistulemustega.

Klass	Meetrika			
	F1	IoU	Täpsus	Saagis
Rohumaa	0.81	0.69	0.84	0.79
Põllumaa	0.83	0.71	0.80	0.87
Muu	0.73	0.57	0.74	0.72

Mudel määras põllumaaks alasid, mis seda tegelikult ei olnud. Rohumaa puhul oli olukord vastupidine: saagis oli väiksem kui täpsus, mis näitab, et osa rohumaast jäi tuvastamata.

Kuigi üldmõõdikud viitavad heale tulemusele, ei lange need kokku segadusmaatriksiga. Seda saab põhjendada madalama IoU skooriga, mis viitab sellele, et kuigi mudel suudab klasse hästi määrata, ei suuda ta väga täpselt tuvastada klasside piire.

Tänu mudeli heale võimekusele sai see implementeeritud eAgronomi ja STACC OÜ projekti koodibaasi ning on kasutusel põllu ajaloolise maakasutuse tuvastamise protsessis.

5.2 Võimalikud edasiarendused

Valmis mudel näitab head üldist võimekust, kuid seda on võimalik arendada edasi. Lähtudes läbi viidud eksperimentidest ja tulemustest, saab välja tuua mitmeid suundi valmis mudeli edasiseks täiustamiseks. Esiteks võiks andmestikku laiendada nii mahu kui ka kvaliteedi poolest. Suurema andmehulga kasutamine aitab parandada mudeli suutlikkust eristada kahte klassi, kuna sama

modeli treenimine suuremal andmekogusel on ilma täiendavate muudatusteta andnud märgatavalt paremaid tulemusi.

Edasise täiustamise võimalusena võiks samuti kaaluda erinevate mudelite arhitektuuride katsetamist ja võrdlemist parima leidmiseks, nagu tegid oma uurimuses Khan jt (2023). Uurimuse autorid leidsid, et keerukamate arhitektuuridega UNet3+ ja Deeplabv3+ mudelid suutsid vilja klassifitseerimises saavutada paremaid tulemusi, võrreldes tavalise U-Net mudeliga.

Vaatamata pakutud edasiarendustele, on oluline meeles pidada, et antud mudeli eesmärk oli klassifitseerida ajaloolisi satelliitpilte. Maatüki jaoks huvipakkuv ajaperiood aga nihkub igal aastal edasi, mis võimaldab kasutada klassifitseerimiseks järjest uuemaid ja kvaliteetsemaid satelliidiandmeid. Seetõttu kaob edasiarenduste äriiline motivatsioon ära, välja arvatud juhul, kui süsinikukrediitide määramise regulatsioone muudetakse ning hakatakse nõudma ajas kaugemale ulatuvate aegridade kontrolli.

6. Kokkuvõte

Töö eesmärgiks oli luua klassifitseerimismudel, mis suudaks eristada loodusliku rohumaad ja põllumaad vanematel satelliidipiltidel, täpsemalt ajavahemikus 2008–2012. Lähtudes püstitatud eesmärgist valmis U-Net arhitektuuril põhinev klassifitseerimismudel, mis suudab tuvastada rohumaad ja põllumaad Landsat 7 satelliitpiltidel.

Töö käigus valiti sobivad ja avalikult kättesaadavad andmestikud, mille põhjal mudel treeniti. Andmete töötlemise käigus toimus andmete puhastamine, kombineerimine aegridadeks ja teiste pilditöötlustehnikate rakendamine Landsat 7 satelliidi sensori rikke mõju leevendamiseks. Mudeli arhitektuuriks valiti viietasemeline U-Net, mida kasutatakse laialdaselt semantilise segmenteerimise ülesannete lahendamiseks.

Treenitud U-Neti ehk põllumaa ja rohumaad klassifitseerimismudeli keskmine täpsus ja F1 skoor on mõlemad 0.79, mis tähendab üldiselt head võimekust klasside eristamisel. Mudel saavutas paremaid tulemusi just põllumaa tuvastamisel, rohumaad klassi maatükid jäid aga vähem märgatavaks, mida kajastab täpsusest väiksem saagis.

Valminud mudel sai implementeeritud eAgronomi ja STACC OÜ projekti. See toetab olemasolevat ajaloolise maakatte tuvastamise süsteemi ning muudab selle usaldusväärsemaks. Seeläbi aitab töö käigus valminud mudel kaasa keskkonnasõbralike põllumajanduspraktikate edendamisele.

Töö võimalikud edasiarendused hõlmavad andmestiku laiendamist ning erinevate semantilise segmentatsiooni mudelite arhitektuuride katsetamist, et leida töös püstitatud eesmärgi saavutamiseks sobivaim.

Viited

- Aplin P. (2004). Remote sensing: land cover. *Progress in Physical Geography* 28(2), lk 283–293. <https://doi.org/10.1191/0309133304pp413pr>.
- Belcore E., Piras M. ja Pezzoli A. (2022). Land Cover Classification from Very High-Resolution UAS Data for Flood Risk Mapping. *Sensors* 22(15), 5622. <https://doi.org/10.3390/s22155622>.
- Campbell J. B. ja Wynne R. H. (2011). Introduction to remote sensing. 5th Edition. Guilford Press. 667 lk kokku.
- Chuvieco E. (2016). Fundamentals of Satellite Remote Sensing, An Environmental Approach. 2nd Edition. CRC Press. 486 lk kokku. <https://doi.org/10.1201/b19478>.
- CLMS (s.a.). 3.2.1 Natural grassland. <https://land.copernicus.eu/content/corine-land-cover-nomenclature-guidelines/html/index-clc-321.html> (02.01.2025).
- Copernicus (s.a.). CORINE Land Cover. <https://land.copernicus.eu/en/products/corine-land-cover> (06.04.2025).
- Csurka G., Volpi R. ja Chidlovskii B. (2022). Semantic image segmentation: Two decades of research. *Foundations and Trends® in Computer Graphics and Vision* 14(1-2), lk 1–162. <https://doi.org/10.48550/arXiv.2302.06378>.
- Dhasmana G., Al-Jawahry H. M., Deepak A., Aravind K., Reddy R. A. ja Yadav K. (2024). Applying Convolutional Neural Networks for Disease Detection in Crop Images. *2024 7th International Conference on Contemporary Computing and Informatics (IC3I)*. Kõide 7, lk 1727–1732. <https://doi.org/10.1109/IC3I61595.2024.10828638>.
- ESA (2022). WorldCover product user manual: Version 2.0. https://esa-worldcover.s3.eu-central-1.amazonaws.com/v200/2021/docs/WorldCover_PUM_V2.0.pdf (02.01.2025).
- Eurostat (s.a.). Glossary: Cropland. <https://ec.europa.eu/eurostat/statistics-explained%20/index.php?title=Glossary: Cropland> (02.01.2025).
- Galea R. (veebuar 2025). Süsinikuprogrammide keerukus. eAgronom. <https://blog.eagronom.com/et/susiniuprogrammide-keerukus> (06.04.2025).
- Garrison M. (2024). NASA Earth Observatory image using Landsat data from the U.S. Geological Survey. NASA Earth Observatory. <https://earthobservatory.nasa.gov/images/153095/paris-olympics-from-above> (02.04.2025).
- Goodfellow I., Bengio Y. ja Courville A. (2016). Deep learning. MIT Press, lk 1–5.
- Gu X., Li S., Ren S., Zheng H., Fan C. ja Xu H. (2022). Adaptive enhanced swin transformer with U-net for remote sensing image segmentation. *Computers and Electrical Engineering* 102, 108223. <https://doi.org/10.1016/j.compeleceng.2022.108223>.

- Huang Y., Chen Z.-x., Tao Y., Huang X.-z. ja Gu X.-f. (2018). Agricultural remote sensing big data: Management and applications. *Journal of Integrative Agriculture* 17(9), lk 1915–1931. [https://doi.org/10.1016/S2095-3119\(17\)61859-8](https://doi.org/10.1016/S2095-3119(17)61859-8).
- Iakubovskii P. (2019). Segmentation Models Pytorch. https://github.com/qubvel/segmentation_models.pytorch. (20.11.2024).
- Jakubik J., Roy S., Phillips C., Fraccaro P., Godwin D., Zadrozny B., Szwarcman D., Gomes C., Nyirjesy G., Edwards B. jt (2023). Foundation models for generalist geospatial artificial intelligence. *arXiv preprint arXiv:2310.18660*. <https://doi.org/10.48550/arXiv.2310.18660>.
- Kaggle (2017). Dstl Satellite Imagery Feature Detection. <https://www.kaggle.com/competitions/dstl-satellite-imagery-feature-detection/leaderboard> (17.05.2024).
- Khan A. H., Zafar Z., Shahzad M., Berns K. ja Fraz M. M. (2023). Crop Type Classification using Multi-temporal Sentinel-2 Satellite Imagery: A Deep Semantic Segmentation Approach. *2023 International Conference on Robotics and Automation in Industry (ICRAI)*, lk 1–6. <https://doi.org/10.1109/ICRAI57502.2023.10089586>.
- Kisliuk B., Krause J. C., Meemken H., Saborío Morales J. C., Müller H. ja Hertzberg J. (2023). AI in current and future agriculture: an introductory overview. *KI-Künstliche Intelligenz* 37(2), lk 117–132. <https://doi.org/10.1007/s13218-023-00826-5>.
- LeCun Y., Bengio Y. ja Hinton G. (2015). Deep learning. *Nature* 521, lk 436–444. <https://doi.org/10.1038/nature14539>.
- Loveland T. R. (2012). History of land-cover mapping. *Remote Sensing of Land Use and Land Cover: Principles and Applications* 6, lk 13–22.
- Mountford G., Atkinson P., Dash J., Lankester T. ja Hubbard S. (2017). Sensitivity of Vegetation Phenological Parameters: From Satellite Sensors to Spatial Resolution and Temporal Compositing Period. *Sensitivity Analysis in Earth Observation Modelling*. Toim. Petropoulos G. P. ja Srivastava P. K. Elsevier, lk 75–90. <https://doi.org/10.1016/B978-0-12-803011-0.00004-5>.
- Müller D., Soto-Rey I. ja Kramer F. (2022). Towards a Guideline for Evaluation Metrics in Medical Image Segmentation. *BMC Research Notes* 15(1), lk 210. <https://doi.org/10.1186/s13104-022-06096-y>.
- NASA Earthdata (s.a.). Remote Sensing. <https://www.earthdata.nasa.gov/learn/earth-observation-data-basics/remote-sensing> (05.04.2025).

- Neupane B., Horanont T. ja Aryal J. (2021). Deep Learning-Based Semantic Segmentation of Urban Features in Satellite Images: A Review and Meta-Analysis. *Remote Sensing* 13(4), 808. <https://doi.org/10.3390/rs13040808>.
- Pearline A., Kumar S. ja Harini S. (2019). A study on plant recognition using conventional image processing and deep learning approaches. *Journal of Intelligent & Fuzzy Systems* 36(3), lk 1997–2004. <https://doi.org/10.3233/JIFS-169911>.
- Phan T. N., Kuch V. ja Lehnert L. W. (2020). Land Cover Classification using Google Earth Engine and Random Forest Classifier—The Role of Image Composition. *Remote Sensing* 12(15).2411. <https://doi.org/10.3390/rs12152411>.
- Rafif M. R., Leonardi M., Putra N. ja Gunawan A. (2024). Application Of Machine Learning Agriculture Between Developing And Developed Countries: A Systematic Literature Review. *2024 International Conference Automatics and Informatics (ICAI)*. IEEE, lk 478–482. <https://doi.org/10.1109/ICAI63388.2024.10851650>.
- Rocchio L. ja Barsi J. (2020). Landsat spectral band graphic showing the evolution of Landsat’s spectral bands from the first generation Multispectral Scanner System (MSS) to Landsat 9’s Operational Land Imager 2 (OLI-2). NASA. <https://landsat.gsfc.nasa.gov/wp-content/uploads/2020/08/Landsat-SpectralBands.png>.
- Ronneberger O., Fischer P. ja Brox T. (2015). U-net: Convolutional networks for biomedical image segmentation. *Medical image computing and computer-assisted intervention—MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III 18*. Springer International Publishing, lk 234–241. <https://doi.org/10.48550/arXiv.1505.04597>.
- Rosende J. (juuni 2022). A 6-step guide for farmers to get carbon credits in agriculture. eAgronom. <https://blog.eagronom.com/a-6-step-guide-for-farmers-to-get-carbon-credits-in-agriculture> (06.04.2025).
- Rwanga S. S. ja Ndambuki J. M. (2017). Accuracy assessment of land use/land cover classification using remote sensing and GIS. *International Journal of Geosciences* 8, lk 611–622. <https://doi.org/10.4236/ijg.2017.84033>.
- Spasev V., Dimitrovski I., Kitanovski I. ja Chorbev I. (2024). Semantic segmentation of remote sensing images: Definition, methods, datasets and applications. *ICT Innovations 2023. Learning: Humans, Theory, Machines, and Data*. Springer Nature Switzerland, lk 127–140. https://doi.org/10.1007/978-3-031-54321-0_9.

- Subramaniam L. K. ja Marimuthu R. (2024). Crop yield prediction using effective deep learning and dimensionality reduction approaches for Indian regional crops. *e-Prime - Advances in Electrical Engineering, Electronics and Energy* 8, 100611. <https://doi.org/10.1016/j.prime.2024.100611>.
- Zanaga D., Van De Kerchove R., Daems D., De Keersmaecker W., Brockmann C., Kirches G., Wevers J., Cartus O., Santoro M., Fritz S., Lesiv M., Herold M., Tsendbazar N.-E., Xu P., Ramoino F. ja Arino O. (2022). ESA WorldCover 10 m 2021 v200. Version v200. Zenodo. <https://doi.org/10.5281/zenodo.7254221>.
- Temenos A., Temenos N., Kaselimi M., Doulamis A. ja Doulamis N. (2023). Interpretable Deep Learning Framework for Land Use and Land Cover Classification in Remote Sensing Using SHAP. *IEEE Geoscience and Remote Sensing Letters* 20, lk 1–5. <https://doi.org/10.1109/LGRS.2023.3251652>.
- Tournachon G.-F. (1866). The Origins of Aerial Photography. <https://www.newyorker.com/culture/photo-booth/origins-aerial-photography> (02.04.2025).
- USGS (s.a.[a]). Landsat 7. <https://www.usgs.gov/landsat-missions/landsat-7> (07.12.2024).
- (s.a.[b]). Landsat Collection 2 Quality Assessment Bands. <https://www.usgs.gov/landsat-missions/landsat-collection-2-quality-assessment-bands> (07.12.2024).
 - (s.a.[c]). Landsat Surface Reflectance. <https://www.usgs.gov/landsat-missions/landsat-surface-reflectance> (18.12.2024).
 - (s.a.[d]). What are the best Landsat spectral bands for use in my research? <https://www.usgs.gov/faqs/what-are-best-landsat-spectral-bands-use-my-research> (07.12.2024).
- Wu N., Crusiol L. G. T., Liu G., Wuyun D. ja Han G. (2023). Comparing Machine Learning Algorithms for Pixel/Object-Based Classifications of Semi-Arid Grassland in Northern China Using Multisource Medium Resolution Imageries. *Remote Sensing* 15(3), 750. <https://doi.org/10.3390/rs15030750>.

Lisad

I. ETM+ sensori satelliitribad

Tabel 3. Satelliitribade lühikirjeldus (USGS s.a.[d])

Riba-värvusklass	Lainepikkus (nm)	Ruumiline lahutusvõime (m)	Rakendusala	Kasutamise antud töös
Ribalaius 1 – Sinine	450 – 520	30	Veekogude sügavuse kaardistamine, mulla eristamine taimestikust ja lehtpuude okaspuudest	Jah
Ribalaius 2 – Roheline	520 – 600	30	Taimede elujõulisuse hindamine, rõhutab taimestiku vegetatsiooni tipphetke	Jah
Ribalaius 3 – Punane	630 – 690	30	Taimestiku erinevate kasvuvormide tuvastamine	Jah
Ribalaius 4 – Lähifrapuna	770 – 900	30	Biomassi sisalduse hindamine ja rannajoonte tuvastamine	Jah
Ribalaius 5 – Lühilaine infrapuna	1550 – 1750	30	Pinnase ja taimestiku niiskusesisalduse mõõtmine	Jah
Ribalaius 6 – Termaalne	10400 – 12500	60	Termaalne kaardistamine ja niiskuse hindamine	Ei
Ribalaius 7 – Kesklaine infrapuna	2090 – 2350	30	Hüdrotermiliselt töödeldud kivimete ja maavarade ladestuste tuvastamine	Jah
Ribalaius 8 – Pankromaatiline	520 – 900	15	Teravam pildikvaliteet	Ei

Litsents

Lihtlitsents lõputöö reprodutseerimiseks ja üldsusele kättesaadavaks tegemiseks

Mina, Kelli Gagarina,

1. annan Tartu Ülikoolile tasuta loa (lihtlitsentsi) minu loodud teose „Kaugseire põhine loodusliku rohumaa ja põllumaa eristamine“, mille juhendajad on Tiit Sepp ja Joonas Ariva, reprodutseerimiseks eesmärgiga seda säilitada, sealhulgas lisada Tartu Ülikooli digitaalarhiivi kuni autoriõiguse kehtivuse lõppemiseni;
2. annan Tartu Ülikoolile loa teha punktis 1 nimetatud teos üldsusele kättesaadavaks Tartu Ülikooli veebikeskkonna, sealhulgas digitaalarhiivi 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.

Kelli Gagarina

15.05.2025