

TALLINNA TEHNIKAÜLIKOOL  
Infotehnoloogia teaduskond

Henri Tõnts 155245IAPB

**Tehisneurovõrkude treenimine vähese  
sisendmaterjali korral Eesti rahvarõivaste  
mustrite klassifitseerimise näitel**

Bakalaureusetöö

Juhendaja: Sten Mäses  
PhD

Tallinn 2020

## **Autorideklaratsioon**

Kinnitan, et olen koostanud antud lõputöö iseseisvalt ning seda ei ole kellegi teise poolt varem kaitsmisele esitatud. Kõik töö koostamisel kasutatud teiste autorite tööd, olulised seisukohad, kirjandusallikatest ja mujalt pärinevad andmed on töös viidatud.

Autor: Henri Tõnts

18.05.2021

## **Annotatsioon**

Käesoleva bakalaureusetöö eesmärgiks on hinnata, kuidas mõjutab vähese sisendmaterjaliga tehisneurovõrgu treenimist sisendmaterjalide kunstlik suurendamine. Praktilise näitena käsitletakse sisendmaterjalina Eesti rahvariiete mustrite klassifitseerimist.

Programmi lõpptulemuseks on treenitud tehisneurovõrgu mudelite komplekt, mille abil saab tuvastada erinevate Eesti rahvarõivaste päritolupiirkonda. Loodud programmi saab pakkuda nii Eesti Rahva Muuseumile, aitamaks tuvastada rahvarõivaste päritolupiirkonda kui ka mittetulundusühingule MTÜ Rahvarõivas, mille eesmärgiks on Eesti rahvarõivaste valmistamise ja kandmise ning rahvuslike käsitöötraditsioonide järjepidevuse säilitamine. Samuti võib programm huvi pakkuda ettevõtetele ja eraisikutele, kes on huvitatud antud valdkonnast.

Eesmärgi saavutamiseks treeniti töö käigus Eesti muuseumide infosüsteemist saadud materjalide abil tehisneurovõrgu mudel, kasutades kolme ImageAI Pythoni teegi poolt toetatud sügavõppe algoritmi (MobileNetV2, ResNet50, InceptionV3). Sisendmaterjalide kunstlikuks suurendamiseks kasutati Pythoni teeki Augmentor.

Lõputöö on kirjutatud eesti keeles ning sisaldab teksti 36 leheküljel, 5 peatükki, 20 joonist, 5 tabelit.

## **Abstract**

### **Training artificial neural networks with small datasets in the example of classifying Estonian traditional clothing patterns**

The purpose of this paper is to evaluate the effect of artificially increasing otherwise low input data for training artificial neural networks. As a practical example, classification of Estonian traditional clothing patterns is used.

The result of the program is a set of trained artificial neural network models, which can be used to identify the origin of Estonian traditional clothing. The program can be offered to the Estonian National Museum, to help identify the origin of Estonian traditional clothing, as well as to the non-profit organization Rahvarõivas, whose purpose is to preserve the making and wearing of Estonian traditional clothes and the consistency of national hand-crafting traditions. The program can also be of interest to companies and individuals interested in the mentioned subject.

To achieve this goal, a set of artificial neural network models was trained, using three of the deep learning algorithms supported by the Python library ImageAI (MobileNetV2, ResNet50 and InceptionV3). For the artificial increasing of input data, the Python library Augmentor was used.

The thesis is in Estonian and contains 36 pages of text, 5 chapters, 20 figures, 5 tables.

## Lühendite ja mõistete sõnastik

KNN	Konvolutsiooniline neurovõrgustik
Mudel	Tehisneurovõrgu sügavmudel
Algmaterjalide mudel	Algmaterjalide põhjal treenitud mudel
Rohkendatud mudel	Rohkendatud materjalide põhjal treenitud mudel
Rohk-tud	Rohkendatud
ERM	Eesti Rahva Muuseum
MTÜ RR	Mittetulundusühing Rahvarõivad
Laiendatud korrektsus	Tulemus, mille puhul pakkus mudel kujutise piirkonna nelja (regioonide puhul kahe) parima pakkumise seast.

## Sisukord

1 Sissejuhatus .....	10
2 Tehniline taust .....	11
2.1 ImageAI .....	11
2.1.1 Kohandatud kujutiste ennustumudeli treenimine.....	12
2.1.2 MobileNetV2.....	12
2.1.3 ResNet50 .....	12
2.1.4 InceptionV3 .....	12
2.1.5 DenseNet121 .....	13
2.2 Augmentor.....	13
2.2.1 Augmentori tööpõhimõte.....	14
2.2.2 Augmentori põhierisused.....	14
3 Neurovõrgu mudelite treenimine.....	16
3.1 Materjalide rohkendamis- ja treenimiskeskond.....	16
3.2 Algmaterjalid .....	17
3.2.1 Algmaterjalide jaotamine andmestusteks .....	18
3.2.2 Algmaterjalide rohkendamine .....	19
3.3 Mudelite treenimise ajad ja võrdlus.....	20
3.3.1 Valdade alusel klassifitseeritud mudelite treenimisaegade võrdlus .....	20
3.3.2 Maakondade alusel klassifitseeritud mudelite treenimisaegade võrdlus.....	21
3.3.3 Regioonide alusel klassifitseeritud mudelite treenimisaegade võrdlus .....	23
3.3.4 Mudelite treenimise järeldused.....	25
4 Treenitud mudelite testimine ja analüüsimine.....	26
4.1 Üldised tulemused ja tähelepanekud .....	26
4.2 Valdade alusel klassifitseeritud mudelite tulemused.....	28
4.2.1 Algoritmide tulemused .....	30
4.2.2 Täpseimate piirkondade pakkumised .....	32
4.3 Maakondade alusel klassifitseeritud mudelite tulemused .....	32
4.3.1 Algoritmide tulemused .....	34
4.3.2 Täpseimate piirkondade pakkumised .....	36

4.4 Regioonide alusel klassifitseeritud mudelite tulemused.....	37
4.4.1 Algoritmide tulemused .....	39
4.4.2 Täpseimate piirkondade pakkumised .....	41
4.5 Algmaterjalide mudelite tulemuste võrdlus rohkendatud mudelite tulemustega .	42
4.5.1 Valdade alusel klassifitseeritud mudelite tulemuste võrdlus.....	43
4.5.2 Maakondade alusel klassifitseeritud mudelite tulemuste võrdlus .....	44
4.5.3 Regioonide alusel klassifitseeritud mudelite tulemuste võrdlus .....	45
4.5.4 Saadud tulemuste analüüs.....	45
4.6 Järeldused .....	46
5 Kokkuvõte .....	47
Kasutatud kirjandus .....	48
Lisa 1 – Lihtlitsents lõputöö reprodutseerimiseks ja lõputöö üldsusele kättesaadavaks tegemiseks .....	49
Lisa 2 – Mudelite testimise tulemustest koostatud tabelid .....	50

## Jooniste loetelu

Joonis 1. Augmentori näidiskonveier [7]. .....	14
Joonis 2. Omavalitsused ja maakonnad nimedega [11].....	18
Joonis 3. Kujutiste näited: (a) ERM-ist pärit kujutis, (b) MTÜ RR-st pärit kujutis.....	26
Joonis 4. ERM kujutiste testimise tulemused.....	27
Joonis 5. MTÜ RR kujutiste testimise tulemused. ....	27
Joonis 6. ERM kujutiste testimise tulemused valdade alusel. ....	28
Joonis 7. MTÜ RR kujutiste testimise tulemused valdade alusel. ....	29
Joonis 8. Valdade puhul täpseima algoritmi, MobileNetV2 testimise tulemused.....	31
Joonis 9. ERM kujutiste testimisel täpseimalt pakutud valla, Saaremaa, tulemused. ....	32
Joonis 10. MTÜ RR kujutiste testimisel täpseimalt pakutud valla, Lääne-Nigula, tulemused.....	32
Joonis 11. ERM kujutiste testimise tulemused maakondade alusel. ....	33
Joonis 12. MTÜ RR kujutiste testimise tulemused maakondade alusel.....	34
Joonis 13. Maakondade puhul täpseimate algoritmide, InceptionV3 (vasakul pool) ja MobileNetV2 (paremal pool), testimise tulemused.....	35
Joonis 14. ERM kujutiste testimisel täpseimalt pakutud maakonna, Harju, tulemused. 36	
Joonis 15. MTÜ RR kujutiste testimisel täpseimalt pakutud maakondade, Harju (ülemised kaks rida) ja Pärnu (alumised kaks rida), tulemused. ....	37
Joonis 16. ERM kujutiste testimise tulemused regioonide alusel. ....	38
Joonis 17. MTÜ RR kujutiste testimise tulemused regioonide alusel.....	39
Joonis 18. Regioonide puhul täpseima algoritmi, ResNet50, testimise tulemused. ....	40
Joonis 19. ERM kujutiste testimisel täpseimalt pakutud regiooni, Põhja, tulemused. ...	41
Joonis 20. MTÜ RR kujutiste testimisel täpseimalt pakutud regiooni, Põhja, tulemused. ....	42



## **Tabelite loetelu**

Tabel 1. Algmaterjalide arvuline jaotus kategooriate vahel. ....	19
Tabel 2. Rohkendatud algmaterjalide arvuline jaotus kategooriate vahel. ....	19
Tabel 3. Valdade alusel klassifitseeritud mudelite treenimise ajad (hh:mm:ss).....	21
Tabel 4. Maakondade alusel klassifitseeritud mudelite treenimise ajad (hh:mm:ss). ....	22
Tabel 5. Regioonide alusel klassifitseeritud mudelite treenimise ajad (hh:mm:ss). ....	24

# 1 Sissejuhatus

Käesolevas lõputöös on kirjeldatud ja analüüsitud tehisneurovõrkude treenimist vähese sisendmaterjalidega Eesti rahvarõivaste mustrite klassifitseerimise näitel ja tehisneurovõrkude treenimise tulemusi. Lisaks on võrreldud eelmainitud tulemusi treenitud tehisneurovõrkudega, mille sisendmaterjal on algselt sama, kuid on töö käigus suurendatud.

Teema valik tulenes autori soovist implementeerida lahendus, mis kasutaks tehisneurovõrke rahvariiede tuvastamiseks. Eestis on kokku 108 erinevat kihelkonda ja igal kihelkonnal on omad eripärad ja mustrid, mis teevad need unikaalseks – seega oleks tehisneurovõrk suureks abiks aitamaks tuvastada eri piirkondade mustreid. Rahvarõivaste kohta pole pildilist materjali ajalooliselt lihtne leida ning seetõttu tuleb arvestada neurovõrkude mudelite treenimisel vähese sisendmaterjaliga. Antud töö uurib, kui täpsed on antud väheste sisendmaterjalide põhjal treenitud neurovõrgu mudelid ning kui palju muudab täpsust tehisneurovõrkude sisendmaterjalide tehislik rohkendamine.

Töö esimeses peatükis kirjeldab autor töö üldist tehnilist tausta ja selle kahte põhikomponenti – ImageAI ja Augmentor. ImageAI puhul on kirjeldatud nimetatud Pythoni teegi tööpõhimõtet, töös kasutatavat kohandatud kujutiste ennustumudeli treenimist ja selleks kasutatavate süvaõppe algoritme. Augmentori osas on kirjeldatud nimetatud Pythoni teegi tööpõhimõtet ja selle põhierisusi, mida on võimalik kasutada materjalide rohkendamiseks.

Töö teises peatükis kirjeldab autor neurovõrgu mudelite treenimist, täpsemalt treenimiskeskkonda ning algmaterjale, nende kogumist ja jaotamist klassifikaatoriteks. Lisaks on välja toodud mudelite treenimise ajad ja nende omavahelised võrdlused.

Töö kolmandas peatükis toob autor välja mudelite testimise tulemused valdade, maakondade ja regioonide piirkondades ning uurib tulemuste võimalikke. Lisaks näitab autor, kui palju on tulemused täpsemad rohkendatud materjali põhjal treenitud mudelite puhul ning miks see nii olla võib.

## 2 Tehniline taust

Viimasel paaril kümnendil toimunud hüppeline areng on võimaldanud masinõpet muuta fantaasiast reaalsuseks. Tänapäeval ei ole võimatu, et sisestatakse suur hulk andmeid programmi ning saadakse tulemuseks tehisintellekt, mis ennustab tulevikus esinevaid mustreid, tuvastab eksisteerivate andmete seast olulist infot ning paljudi muud.

Praegu eksisteeriva tehnoloogia puhul ei ole aga üht tsentraalset programmi, mis eelnimetatud kõikide andmetega efektiivselt suudaks. Tänaused tehisintellektid ja masinõppe mudelid on üldiselt spetsialiseeritud, tegeledes kindlat tüüpi andmetega spetsiifilise otstarbe jaoks, olgu selleks automatiseeritud klienditeenindus, automatiseeritud tootmine vabrikutes või aktsiahindade ennustamine.

Sellel eesmärgil on tehnoloogia arenenud piisavalt, et ka tavainimesed saavad oma koduarvutites tehisintellekte arendada ja masinõppe mudeleid treenida. Sellel eesmärgil on arendatud tarkvaratekke erinevates programmeerimiskeeltes, mis aitavad inimestel minimaalse vaevaga treenida omaenda masinõppe mudeleid, vajades selleks mõnel puhul ainult algmaterjale.

### 2.1 ImageAI

Üks eelkirjeldatud masinõppe teekidest on Moses ja John Olafenwa poolt arendatud ja hallatud ImageAI – vabavarana arendatud Pythoni teek, mis toetab nii kujutiste ennustust, objektide tuvastust (kujutisel ja videol) kui ka mõlema jaoks kohandatud mudeli treenimist. Toetatud on 4 erinevat masinõppe algoritmi kujutiste ennustuseks ja kolme erinevat masinõppe algoritmi objektituvastuseks. Teeki ennast arendatakse pidevalt ning on töö kirjutamise hetkel Tensorflow<sup>1</sup> masinõppe raamistikul põhinev, plaaniga juunist 2021 minna üle PyTorch<sup>2</sup> masinõppe raamistikule [1].

---

<sup>1</sup> <https://www.tensorflow.org/>

<sup>2</sup> <https://pytorch.org/>

### **2.1.1 Kohandatud kujutiste ennustumudeli treenimine**

Üks ImageAI põhiomadustest on võimalus treenida oma vajadustele vastavat kujutiste ennustumudelit, kasutades üht neljast toetatud sügavõppe algoritmist. Treenimiseks on vaja vähemalt kahte erinevat klassi või tüüpi kujutisi (näiteks mootorsõidukite tuvastamisel autod ja mootorrattad) ning igas klassis on suurima täpsuse saavutamiseks vaja vähemalt 500 kujutist, soovituslikult 1000 kujutist [2].

Treenimisprotsess tekitab JSON faili, kus on kirjas kujutiste klassifikatsioonid ning treenimiseks valitud sügavõppe algoritmi mudelid. Treenitud mudelid tekitatakse ainult juhul, kui mudelite täpsus testkujutistel on suurenenud. Kohandatud kujutiste ennustumudelite treenimiseks on toetatud neli erinevat sügavõppe algoritmi: MobileNetV2, ResNet50, InceptionV3 ja DenseNet121 [2].

### **2.1.2 MobileNetV2**

Google poolt arendatud MobileNets on 2017. aastal välja lastud TensorFlow'1 põhinev tehisenägemismudelite perekond, mille edasiarendus MobileNetV2 lasti välja aprillis 2018. Eelmise versiooniga võrreldes on MobileNetV2 puhul optimeeritud arhitektuuri klassifikatsiooni, objektide tuvastuse ja semantilise segmentatsiooni tarbeks [3].

### **2.1.3 ResNet50**

ResNet on jääköppimisvõrgustik, mille eesmärgiks on kergendada senisest tunduvalt sügavamate neurovõrkude treenimist. ResNeti põhimõtteks on kasutada ettesöötvaid neurovõrke ja „otsetee ühendusi“, mis sooritavad identiteedivastandusi, mille väljundid lisatakse pinukihtide väljunditele [4].

### **2.1.4 InceptionV3**

Inceptioni nimeline neurovõrgustiku kiht on osa 2014. aasta ImageNet Large Scale Visual Recognition Challenge (ILSVRC) jaoks loodud GoogLeNet neuroarhitektuurist. Inceptioni kiht koosneb 1x1, 3x3 ja 5x5 konvolutsiooni suurustest filtritest ning selle väljundi filtripangad liidetakse ainuväljundvektorisse, mis moodustab järgmise etapi sisendi [5].

InceptionV3 on edasiarendus varasematest GoogLeNet ja Inception v1 arhitektuuridest, mis kulutab eelnevate arhitektuuridega võrreldes vähem arvutusvõimsust. InceptionV3 arhitektuuris kasutatakse kontseptsioonidena nii faktoriseeritud, väiksemaid kui ka

asümmeetrilisi konvolutsioone, täiendavaid klassifikaatoreid ja võrgu suuruse vähendamist [6].

### 2.1.5 DenseNet121

DenseNet on konvolutsiooniline neurovõrgustik (KNN) , milles traditsioonilise KNN asemel, kus L arv kihtidel on L arv ühendusi (üks iga kihi ja sellest järgneva kihi vahel), on  $\frac{L(L+1)}{2}$  otsest ühendus. Igal kihil kasutatakse sisenditena eelmiste kihtide erisuskaarte ning kihi enda erisuskaarte kasutatakse sisenditena igas järgnevas kihis. „121“ notatsioon DenseNet121 arhitektuurinimes tähistab kihtide arvu ehk mudeli sügavust [7].

## 2.2 Augmentor

Mida rohkem AI tuvastama peab ja mida rohkem klassifikaatoreid mudel eristada suudab, seda rohkem peab olema algmaterjali mudeli treenimiseks, et saada täpsemaid mudeleid. Alati pole algmaterjali võimalik piisavas koguses leida, olgu see vähesese detailsuse, materjalide üldise ebasobivuse või nende täieliku puudumise tõttu. Selliste stsenaariumite puhul on edasiminemiseks kaks varianti – kas treenida mudeleid olemasoleva materjalide kogusega, või algmaterjalide kogust tehiskult suurendada. Selles töös käsitleb autor mõlemat varianti.

Algmaterjalide tehiskult suurendamiseks on võimalik kasutada Augmentori nimelist Pythoni teeki, mis on loodud eesmärgiga pakkuda kõrgelt kohandatavat ja põhjalikku kujutiste augmenteerimise teeki. Augmentori operatsioonid on tugevalt parameetrilised, lubades kujutiste loomisel täpset kontrolli. Augmentori rakendusliidese loomisel on võetud arvesse nii tüüpilisi augmentatsioonitehnikaid kirjandusest kui ka erinevaid tehnikaid, mida on avaldatud erinevatel võistluselementidega lehtedel nagu Kaggle<sup>1</sup> [7].


Augmentor on loodud vabavarana ning see on mõeldud olema sõltumatu nii platvormidest kui ka raamistikest, lubades paremat kontrolli augmentatsiooni üle [8].

---

<sup>1</sup> <https://www.kaggle.com/>

### 2.2.1 Augmentori tööpõhimõte

Augmentor alustab rohkendamist tühjast andmekonveierist, millele kasutaja lisab operatsioone vastavalt sellele, mis järjekorras ta soovib, et konveierist läbi käivatele kujutistele operatsioonid rakendatakse. Kasutaja saab samuti defineerida tõenäosuse, et vastav operatsioon kujutisel rakendatakse ning vahemiku, mille ulatuses operatsioon kujutist muuta võib. Viimase parameetri näiteks võib tuua kujutise võimaliku rotatsiooni -10...10 kraadini. Näidis Augmentori andmekonveierist on välja toodud joonisel 2. [7].



Joonis 1. Augmentori näidiskonveier [7].

Kui andmekonveier on genereeritud, liigutatakse kujutised (või kujutiste kogum) konveierist korduvalt läbi kuni on saavutatud kindlaks määratud arv kujutisi. Andmekonveieri stohhastilisus tähendab, et iga kord, kui kujutis konveierist läbi käib, genereeritakse erinevad kujutise andmed, mis lubab ka algselt väikesest andmekogumist genereerida potentsiaalselt massiivse koguse kujutisi [7].

### 2.2.2 Augmentori põhierisused

Augmentori põhierisusteks on kujutise perspektiivne kiivamine, elastiline moondamine, rotateerimine, nihkedeformeerimine, kärpimine ja peegeldamine [9].

Perspektiivse kiivamise puhul muundatakse kujutist nii, et kasutajale tunduks kujutist olevat teise nurga alt. Kujutist on võimalik kiivata vasakule, paremale, ettepoole, tahapoole või ühte kaheksast nurgast eelmainitud suundade vahel [9].

Elastiline moondamine lubab kasutajal kujutist moondada, säilitades kujutise originaalse küljesuhte. Parameetritena on võimalik sisestada moondatava ruudustiku suurus ja moondamise ulatus [9].

Rotatsiooni puhul on võimalik pilti pöörata juhuslikult 90, 180 või 270 kraadi igas suunas kujutist muud moodi moondamata. Valides rotatsioonikraadi, mis ei ole 90 moodul, pööratakse kujutist ette antud kraadide võrra. Tekkinud kujutist kärbitakse Augmentori poolt automaatselt, tagastades võimalikult suure ala kujutisest ja suumides pilti [9].

Nihkedeformeerimine kallutab kujutist piki üht selle külge ning võib toimuda kas  $x$ -telje või  $y$ -telje suunas. Samamoodi nagu rotatsiooni puhul, kärbitakse kujutist Augmentori poolt automaatselt, tagastades võimalikult suure ala kujutisest ja suumides pilti. Nihkedeformatsiooni saab rakendada juhusliku või fikseeritud arvuna ja juhuslikus või fikseeritud suunas [9].

Kärpimise puhul kärbitakse kujutis kas kujutise keskelt teatud protsendi suuruseks kujutiseks või kujutisel määratud asukohas ettemääratud dimensioonide suuruseks kujutiseks. Võimalik on veel kujutisel juhuslikult määratud asukohas ettemääratud suuruse kujutise kärpimine [9].

Kujutise peegeldamine võimaldab kujutist peegeldada  $x$ - või  $y$ -teljel või mõlemal korraga [9].

### 3 Neurovõrgu mudelite treenimine

Tehisneurovõrgu mudelite treenimiseks kasutatakse töös kolme neljast ImageAI poolt toetatud sügavõppe algoritmi – InceptionV3, MobileNetV2 ja ResNet50. DenseNet121 algoritm jäi tööst kõrvale tehniliste probleemide tõttu treenimise ülesseadmisel – erinevalt teistest algoritmidest ei käivitunud selle algoritmiga treenimine kordagi. Mudelite treenimisel olid kõikidel mudelitel ühised parameetrid – eksperimentide arv 100, ühe partii suurus 32 ja andmete rikastamine määratud tõseks. Ainus muutuv parameeter oli klassifikaatorite arv, mis muutus vastavalt saadaval olevate valdade, maakondade ja regioonide arvule.

Mudelite treenimine teostati kahes etapis – kõigepealt treeniti mudelid algmaterjalide baasil, seejärel taaskäivitati treenimiskeskond ning treeniti mudelid rohkendatud materjalide baasil. Mudelite treenimise ajal oli arvuti kasutuses igapäevaste tööprotsesside täitmiseks, suurendades treenimiseks vajaminevat aega, olenevalt käimasolevatest protsessidest, paarist minutist mitme päevani. Sellegipoolest oli arvuti samaaegselt täielikult kasutatav, näidates, et arvestades kuluva lisaajaga, on treenimine igapäevakasutuse kõrvalt praktiliselt teostatav.

Kokku on neurovõrgu mudelite treenimise tulemuseks 36 erinevat neurovõrgu mudelit. Igast kasutatud sügavõppe algoritmi abil on treenitud 12 erinevat mudelit, nendest omakorda neli mudelit iga piirkonna tüübi (vallad, maakonnad, regioonid) jaoks.

#### 3.1 Materjalide rohkendamise- ja treenimiskeskond

Käesolev töö on implementeeritud Pythoni programmeerimiskeeles ning on mõeldud töötama CUDA<sup>1</sup> platvormil. CUDA on Nvidia poolt loodud paralleelrehkenduste platvorm, mis võimaldab arvutil üldiseid rehkendusi teha graafikakaardi abil, kiirendades arvutusrakenduste tööd märkimisväärselt. CUDA-t võimaldavatel rakendustel on töömaht jaotatud järjestikuliseks osaks, mis on optimeeritud jooksa protsessoritel, ja arvutusrohkeks osaks, mis jookseb paralleelselt graafikakaardi tuhandetel tuumadel [10].

---

<sup>1</sup> <https://developer.nvidia.com/cuda-zone>



Käesolevas töös on kasutatud autori isiklikku arvutit, mille põhiosadeks on protsessor AMD Ryzen 5 5600X, graafikakaart Nvidia GeForce RTX 3070 (8GB muutmälu, 5888 CUDA tuuma) ja 2x8GB 3200MHz muutmälu. Materjalide rohkendamist ja treenimist on võimalik sooritada ilma graafikakaardita, paigaldades Tensorflow raamistiku versiooni 2.0.4, kuid see pikendab mõlema protsessi tööaega mitmekümnekordselt. Samuti on sellisel juhul vajalik protsessor, millel on iseseisev graafikaliides, mis eelnimetatud Ryzen protsessoril puudub.

Projekt on üleslaetud GitHubi, kus on detailsemalt kirjas projekti nõuded, vajalikud Pythoni teegid, olemasolevate Pythoni klasside kirjeldused, kujutiste rohkendamine, mudelite treenimine ja mudelite testimine. Materjalide rohkendamise, treenimise ja testimise jaoks on loodud eraldi klassid, vastavalt `augment.py`<sup>1</sup>, `training.py`<sup>2</sup>, ja `prediction.py`<sup>3</sup>.

## 3.2 Algmaterjalid

Mudelite treenimiseks vajalikud algmaterjalid on hangitud MTÜ Rahvarõivas kodulehelt<sup>4</sup>, mis pakub infot enamiku 108st Eestis asuva kihelkonna kohta. Kuigi enamjaolt on info tekstipõhine, on enamike kihelkondade juures teksti täiendamas Eesti Rahva Muuseumist või teistest Eesti Muuseumide Veebivärvast<sup>5</sup> olevatest muuseumitest pärit kujutisi ehetest, seelikutest, vöödest ja muudest rahvarõivaste hulka kuuluvatest rõivaesemetest. Piltide kasutamiseks töös on küsitud ja saadud luba ERMilt ja MTÜ Rahvarõivalt.

Kokku leidub MTÜ RR kodulehel töö koostamise ajal 7385 erinevat kujutist Eesti rahvarõivastest ja nende juurde kuuluvatest esemetest. Siinkohal tuleb märkida, et tegu ei ole täieliku kollektsiooniga kõikide Eesti kihelkondade rahvarõivastest. Kui mõnes kihelkonnas, näiteks Tartu-Maarja, on vähem pildilist informatsiooni rahvarõivaste kohta, siis mõnes kihelkonnas, eriti Kagu-Eesti kihelkondades nagu Setomaa, Põlva ja

---

<sup>1</sup> <https://github.com/htonts/rahvaroivas/blob/main/augment.py>

<sup>2</sup> <https://github.com/htonts/rahvaroivas/blob/main/training.py>

<sup>3</sup> <https://github.com/htonts/rahvaroivas/blob/main/prediction.py>

<sup>4</sup> <https://rahvaroiivad.ee/>


<sup>5</sup> <https://www.muis.ee/>

Kanepi, on pildilise informatsiooni arv puudulik. See tõstatab küsimuse, kui täpne on MTÜ RR poolt pakutud informatsioon ja kui väärtuslik on nende pakutud andmete põhjal mudelite treenimine. Sellegipoolest on Eesti rahvarõivastest koostatud materjalide osas kõige täiuslikum just nende pakutud andmebaas, seega on see töös kasutuses.

### 3.2.1 Algmaterjalide jaotamine andmestusteks

Mudelite treenimiseks on saadavalolevast materjalist koostatud kaks põhiandmestut – esimene andmestu sisaldab naiste seelikuid, kleite ja põllesid ning teine andmestu sisaldab eelnevale lisaks erinevaid vöösid, mida mehed ja naised rahvarõivastega koos kanda võisid. Valikud on tehtud eristatavate mustrite saadavuse alusel, olles saadavalolevast materjalist kõige erksamad ja eristatavamad.

Mõlemad andmestud jagunevad omakorda kolmeks, olles jaotatud valdade, maakondade ja regioonide alusel. Valdadeks jaotamisel on kasutatud Maaameti Geoportaalist [11] leiduvat skemaatilist ülevaatekaarti (joonis 3). Osade kihelkondade puhul, mis katavad mitut valda, näiteks Harju-Jaani kihelkond, mis katab Rae ja Raasiku valdasid, on kihelkonna materjalid teiseldataud mõlemasse valda. Sama kaardi alusel on algmaterjalid teiseldataud maakondade andmestutesse. Maakondadest on puudu Põlva maakond materjalide puudumise tõttu.



Joonis 2. Omavalitsused ja maakonnad nimedega [11].

Regioonide andmestute algmaterjalid on jaotatud MTÜ RR kodulehel asuva regioonikaardi alusel, mis jaotab Eesti riigi Põhja, Lõuna, Lääne ja Saarte regioonideks. Põhja regiooni kuuluvad Harju-, Rapla-, Järva-, Lääne-Viru- ja Ida-Virumaa, Lõuna regiooni kuuluvad Viljandi-, Valga-, Võru-, Põlva-, Tartu- ja Jõgevamaa, Lääne regiooni Pärnumaa ja Läänemaa ning Saarte piirkonda Hiiumaa ja Saaremaa.

Kokku on algmaterjalid jaotatud 47 vallaks (48 valda teist tüüpi andmestu puhul), 14 maakonnaks ja 4 regiooniks. Täpsem info on nähtav tabelis 1.

	<b>Vallad</b>	<b>Maakonnad</b>	<b>Regioonid</b>
<b>Seelikud, kleidid, põlled</b>	1568	1423	1395
<b>Seelikud, kleidid, põlled, vööd</b>	2416	2205	2183

Tabel 1. Algmaterjalide arvuline jaotus kategooriate vahel.

### 3.2.2 Algmaterjalide rohkendamine

Algmaterjalide rohkendamisel lähtus autor eelnevalt väljatoodud soovituselt ImageAI loojate poolt kasutada ~1000 treenimiskujutist ja ~200 testimiskujutist iga klassi kohta [2]. Peale rohkendamist on seega igas klassis vähemalt 1000 treenimiskujutist ja 200 testimiskujutist (rohkendatud kujutised + algmaterjal).

Rohkendamisparameetriteks on valitud päriselus esineda võivad moonutused, näiteks pildistamine nurga alt ja riideseme mitte sirgeks seadmine. Lisaks on kujutise suurus teisendatud resolutsioonile 224x224, sest ImageAI teisendab treenimisel kasutatud materjalid nimetatud suuruseks, olenemata kujutise eelnevast resolutsioonist, ning seega on võimalik vältida lisaressursside kulutamist treenimisel. Rohkendamata algmaterjale treenitakse algsuuruses.

Algmaterjalide rohkendamine võttis aega pool tundi, sellest 24 minutit treenimiskujutistele ja kuus minutit testimiskujutistele. Kokku rohkendati 11244 kujutist, nendest 6813 treenimiskujutist ja 4413 testimiskujutist. Täpsem info on nähtav tabelis 2.

	<b>Vallad</b>	<b>Maakonnad</b>	<b>Regioonid</b>
<b>Seelikud, kleidid, põlled</b>	57968	18223	6195
<b>Seelikud, kleidid, põlled, vööd</b>	60016	19005	6983

Tabel 2. Rohkendatud algmaterjalide arvuline jaotus kategooriate vahel.

### **3.3 Mudelite treenimise ajad ja võrdlus**

Ühe mudeli treenimine, olenevalt andmestust, sügavõppe algoritmist, materjalide piirkonnast ja kas materjale oli rohkendatud või mitte, võttis aega 22 minutist 9 tunnini.

Kõige vähem aega võttis esimese algandmestu baasil regioonide alusel klassifitseeritud mudelite treenimine, võttes aega umbes 22 minutit, olenemata sügavõppe algoritmist. Kõige rohkem võttis aega teise rohkendatud andmestu baasil valdade alusel klassifitseeritud mudelite treenimine, võttes ResNet50 sügavõppe algoritmi puhul aega 9 tundi ja 5 sekundit, kusjuures MobileNetV2 sügavõppe algoritmi puhul võttis sama mudeli treenimine ligi 20 minutit vähem.

Järgnevates alapeatükkides on mudelite treenimise ajad esitatud keskmistena kõikide sügavõppe algoritmide abil treenitud mudelite treenimisajast. Alapeatüki lõpus esitatud tabelites 3, 4 ja 5 on mudelite treenimise ajad detailsemalt kirjas.

#### **3.3.1 Valdade alusel klassifitseeritud mudelite treenimisaegade võrdlus**

Alustades võrdlust esimesest andmestust, võttis mudelite algmaterjalide põhjal treenimine aega keskmiselt 24 minutit ja 33 sekundit ning rohkendatud materjalide põhjal treenimine keskmiselt 8 tundi, 24 minutit ja 44 sekundit, võttes algmaterjalide põhjal treenimisest keskmiselt 20,6 korda rohkem aega. Algmaterjalide puhul võttis ühe mudeli treenimine aega keskmiselt 14,73 sekundit ning rohkendatud materjalide puhul keskmiselt 302,84 sekundit.

Ühe kujutise töötlemine võttis algmaterjalide puhul aega keskmiselt 930 millisekundit, kuid rohkendatud materjalide puhul keskmiselt 522 millisekundit, olles algmaterjalide ühe kujutise töötlemisest 78,2% kiirem.

Teise andmestu puhul võttis mudelite algmaterjalide põhjal treenimine aega keskmiselt 44 minutit ja 35 sekundit ning rohkendatud materjalide põhjal treenimine keskmiselt 9 tundi ja 5 sekundit, võttes algmaterjali põhjal treenimisest keskmiselt 12,0 korda rohkem aega. Algmaterjalide puhul võttis ühe mudeli treenimine aega keskmiselt 26,60 sekundit ning rohkendatud materjalide puhul keskmiselt 320,01 sekundit.

Ühe kujutise töötlemine võttis algmaterjalide puhul keskmiselt 1101 millisekundit ja rohkendatud materjalide puhul keskmiselt 531 millisekundit ehk keskmiselt 2,1 korda vähem aega.

Võrreldes ühe kujutise töötlemist algmaterjalide ja rohkendatud materjalide puhul, siis võtab teise andmestu puhul algmaterjalide ühe kujutise töötlemine esimesest andmestust keskmiselt 18,3% rohkem aega. Rohkendatud materjalide puhul on andmestute aegade vahe palju väiksem, teise andmestu puhul on ühe kujutise töötlus esimesest andmestust keskmiselt 1,7% aeglasem.

Võrreldes mudelite treenimist andmestute vahel, võttis algmaterjalide puhul teise andmestu treenimine keskmiselt 80,6% aega. Rohkendatud materjalide puhul oli vahe väiksem, teise andmestu treenimine võttis keskmiselt 5,7% rohkem aega.

	<b>InceptionV3</b>		<b>MobileNetV2</b>		<b>ResNet50</b>	
	<b>Originaal</b>	<b>Rohk-tud</b>	<b>Originaal</b>	<b>Rohk-tud</b>	<b>Originaal</b>	<b>Rohk-tud</b>
<b>Seelikud, kleidid, põlled</b>	24:36	8:24:03	24:15	8:12:55	24:48	8:37:14
<b>Seelikud, kleidid, põlled, vööd</b>	44:21	8:54:04	43:49	8:39:15	44:50	9:00:05

Tabel 3. Valdade alusel klassifitseeritud mudelite treenimise ajad (h:mm:ss).

### 3.3.2 Maakondade alusel klassifitseeritud mudelite treenimisaegade võrdlus

Võrreldes kõigepealt esimest andmestut, võttis mudelite algmaterjalide põhjal treenimine aega keskmiselt 22 minutit ja 57 sekundit ning rohkendatud materjalide põhjal treenimine keskmiselt 2 tundi, 40 minutit ja 59 sekundit, võttes algmaterjalide põhjal treenimisest keskmiselt 7,0 korda rohkem aega. Valdade alusel klassifitseeritud mudelite treenimisaegadest võttis mudelite treenimine algmaterjalide puhul keskmiselt 7,0% vähem aega ja rohkendatud materjalide puhul keskmiselt 3,1 korda vähem aega. Algmaterjalide puhul võttis ühe mudeli treenimine aega keskmiselt 13,77 sekundit ning rohkendatud materjalide puhul keskmiselt 96,59 sekundit.

Ühe kujutise töötlemine võttis algmaterjalide puhul aega keskmiselt 967 millisekundit ja rohkendatud materjalide puhul keskmiselt 530 millisekundit, võttes keskmiselt 54,8% algmaterjalide ühe kujutise töötlemise ajast. Valdade alusel klassifitseeritud mudelitega võrreldes võttis algmaterjalide puhul ühe kujutise töötlemine keskmiselt 4,0% rohkem aega ja rohkendatud materjalide puhul keskmiselt 1,5% rohkem aega.

Teise andmestu puhul võttis mudelite algmaterjalide põhjal treenimine aega keskmiselt 41 minutit ja 15 sekundit ning rohkendatud materjalide põhjal treenimine keskmiselt 2 tundi, 59 minutit ja 10 sekundit, võttes algmaterjali põhjal treenimisest keskmiselt 4,3 korda rohkem aega. Valdade alusel klassifitseeritud mudelite treenimisaegadest võttis mudelite treenimine algmaterjalide puhul keskmiselt 7,5% vähem aega ja rohkendatud materjalide puhul keskmiselt 2.82 korda vähem aega. Algmaterjalide puhul võttis ühe mudeli treenimine aega keskmiselt 24,75 sekundit ning rohkendatud materjalide puhul keskmiselt 107,5 sekundit.

Ühe kujutise töötlemine võttis algmaterjalide puhul keskmiselt 1122 millisekundit ja rohkendatud materjalide puhul keskmiselt 566 millisekundit ehk keskmiselt 98,2% vähem aega. Valdade alusel klassifitseeritud mudelitega võrreldes võttis algmaterjalide puhul ühe kujutise töötlemine keskmiselt 1,9% rohkem aega ja rohkendatud materjalide puhul keskmiselt 6,6% rohkem aega.

Ühe kujutise töötlemine algmaterjalide ja rohkendatud materjalide puhul võtab teise andmestu puhul algmaterjali ühe kujutise töötlemine esimesest andmestust keskmiselt 16,0% rohkem aega. Rohkendatud materjalide puhul on andmestute aegade vahe väiksem, teise andmestu puhul on ühe kujutise töötlus esimesest andmestust keskmiselt 6,8% aeglasem. Valdade alusel klassifitseeritud mudelitega võrreldes on algmaterjalide andmestute ühe kujutise töötlemise vahe keskmiselt 10,3% väiksem, kuid rohkendatud materjalide andmestute ühe kujutise töötlemise vahe keskmiselt 4,0 korda suurem.

Võrreldes mudelite treenimist andmestute vahel, võttis algmaterjalide puhul teise andmestu treenimine keskmiselt 79,7% rohkem aega. Rohkendatud materjalide puhul oli vahe väiksem, teise andmestu treenimine võttis keskmiselt 11,3% rohkem aega. Valdade alusel klassifitseeritud mudelitega võrreldes on algmaterjalide andmestute ühe mudeli treenimine keskmiselt 8,1% kiirem ja rohkendatud materjalide andmestute puhul keskmiselt 57,4% kiirem.

	InceptionV3		MobileNetV2		ResNet50	
	Originaal	Rohk-tud	Originaal	Rohk-tud	Originaal	Rohk-tud
<b>Seelikud, kleidid, põlled</b>	23:01	2:39:17	22:55	2:40:26	22:55	2:43:15
<b>Seelikud, kleidid, põlled, vööd</b>	41:28	3:00:28	40:46	2:56:41	41:31	3:00:20

Tabel 4. Maakondade alusel klassifitseeritud mudelite treenimise ajad (h:mm:ss).

### 3.3.3 Regioonide alusel klassifitseeritud mudelite treenimisaegade võrdlus

Esimese andmestu puhul võttis mudelite algmaterjalide põhjal treenimine aega keskmiselt 22 minutit ja 32 sekundit ning rohkendatud materjalide põhjal treenimine keskmiselt üks tund ja 14 sekundit, võttes algmaterjalide põhjal treenimisest keskmiselt 2,7 korda rohkem aega. Valdade alusel klassifitseeritud mudelite treenimisaegadest võttis mudelite treenimine algmaterjalide puhul keskmiselt 8,9% vähem aega ja rohkendatud materjalide puhul keskmiselt 8,4 korda vähem aega. Maakondade treenimisaegadega võrreldes on algmaterjalide treenimisaeg keskmiselt 1,8% väiksem ja rohkendatud materjalide treenimisaeg keskmiselt 2,7 korda väiksem. Algmaterjalide puhul võttis ühe mudeli treenimine aega keskmiselt 13,52 sekundit ning rohkendatud materjalide puhul keskmiselt 36,14 sekundit.

Ühe kujutise töötlemine võttis algmaterjalide puhul aega keskmiselt 969 millisekundit, kuid rohkendatud materjalide puhul keskmiselt 584 millisekundit, võttes keskmiselt 65,9% algmaterjalide ühe kujutise treenimise ajast. Valdade alusel klassifitseeritud mudelitega võrreldes võttis algmaterjalide puhul ühe kujutise töötlemine keskmiselt 4,2% rohkem aega ja rohkendatud materjalide puhul keskmiselt 11,9% rohkem aega. Maakondade alusel klassifitseeritud mudelitega võrreldes võttis algmaterjalide puhul ühe kujutise töötlemine keskmiselt 0,2% rohkem aega ja rohkendatud materjalide puhul keskmiselt 10,2% rohkem aega.

Teise andmestu puhul võttis mudelite algmaterjalide põhjal treenimine aega keskmiselt 42 minutit ja 15 sekundit ning rohkendatud materjalide põhjal treenimine keskmiselt üks tund, 18 minutit ja 51 sekundit, võttes algmaterjali põhjal treenimisest keskmiselt 93,1% rohkem aega. Valdade alusel klassifitseeritud mudelite treenimisaegadest võttis mudelite treenimine algmaterjalide puhul keskmiselt 8,6% vähem aega ja rohkendatud materjalide puhul keskmiselt 6,8 korda vähem aega. Maakondade treenimisaegadega võrreldes on algmaterjalide treenimisaeg keskmiselt 1,0% väiksem ja rohkendatud materjalide treenimisaeg keskmiselt 2,3 korda väiksem. Algmaterjalide puhul võttis ühe mudeli treenimine aega keskmiselt 24,5 sekundit ning rohkendatud materjalide puhul keskmiselt 47,31 sekundit.

Ühe kujutise töötlemine võttis algmaterjalide puhul keskmiselt 1134 millisekundit ja rohkendatud materjalide puhul keskmiselt 677 millisekundit ehk keskmiselt 67,5% algmaterjalide ühe kujutise töötlemise ajast. Valdade alusel klassifitseeritud mudelitega

võrreldes võttis algmaterjalide puhul ühe kujutise töötlemine keskmiselt 3,0% rohkem aega ja rohkendatud materjalide puhul keskmiselt 27,5% rohkem aega. Maakondade alusel klassifitseeritud mudelitega võrreldes võttis algmaterjalide puhul ühe kujutise töötlemine keskmiselt 1,1% rohkem aega ja rohkendatud materjalide puhul keskmiselt 19,6% rohkem aega.

Võrreldes ühe kujutise töötlemist algmaterjalide ja rohkendatud materjalide puhul, siis võtab teise andmestu puhul algmaterjalide ühe kujutise töötlemine esimesest andmestust keskmiselt 17,0% rohkem aega. Rohkendatud materjalide puhul on ühe kujutise töötlus esimesest andmestust keskmiselt 15,9% aeglasem. Valdade alusel klassifitseeritud mudelitega võrreldes on algmaterjalide andmestute ühe kujutise töötlemise vahe keskmiselt 3,6% väiksem, kuid rohkendatud materjalide andmestute ühe kujutise töötlemise vahe keskmiselt 4,0 korda suurem. Maakondade alusel klassifitseeritud mudelitega võrreldes on algmaterjalide andmestute ühe kujutise töötlemise vahe keskmiselt 6,5% suurem ja rohkendatud materjalide andmestute ühe kujutise töötlemise vahe keskmiselt 2,6 korda suurem.

Võrreldes mudelite treenimist andmestute vahel, võttis algmaterjalide puhul teise andmestu treenimine keskmiselt 81,2% rohkem aega. Rohkendatud materjalide puhul oli vahe väiksem, teise andmestu treenimine võttis keskmiselt 30,9% rohkem aega. Valdade alusel klassifitseeritud mudelitega võrreldes on algmaterjalide andmestute ühe mudeli treenimine keskmiselt 8,1% kiirem ja rohkendatud materjalide andmestute puhul keskmiselt 53,7% kiirem. Maakondade alusel klassifitseeritud mudelitega võrreldes võtab algmaterjalide andmestute ühe mudeli treenimine keskmiselt sama palju aega ja on rohkendatud materjalide andmestute puhul keskmiselt 57,4% kiirem.

	InceptionV3		MobileNetV2		ResNet50	
	Originaal	Rohk-tud	Originaal	Rohk-tud	Originaal	Rohk-tud
<b>Seelikud, kleidid, põlled</b>	22:46	1:00:34	22:15	59:27	22:33	1:00:42
<b>Seelikud, kleidid, põlled, vööd</b>	41:04	1:19:00	40:34	1:18:23	40:51	1:19:10

Tabel 5. Regioonide alusel klassifitseeritud mudelite treenimise ajad (h:mm:ss).



### **3.3.4 Mudelite treenimise järeldused**

Mudelite treenimisaegade võrdlusest on võimalik teha järgnevad järeldused:

Mudelite treenimise aeg suureneb treenimis- ja testimiskujutiste koguarvu suurenedes.

Mida rohkem kujutisi on treenimisel olevate materjalidena, seda efektiivsemad on algoritmid ühe kujutise töötlemise arvelt.

Sügavõppe algoritmidest on treenimisel kiireim MobileNetV2, järgnevad InceptionV3 ja ResNet50. DenseNet121 kohta hetkel andmed puuduvad.

## 4 Treenitud mudelite testimine ja analüüsimine

Treenitud mudelite testimiseks on kokku kogutud 42 erinevat kujutist Eesti rahvarõivastest. Kujutistest 21 on võetud Eesti Rahva Muuseumist ja teistest Eesti Muuseumide Veebiväravas olevatest muuseumitest ja on mudelite treenimisel kasutatud ImageAI poolt nende täpsuse testimiseks. Ülejäänud 21 kujutist, mis on pildid Eesti rahvarõivastest inimeste seljas, on võetud töödeldud kujul MTÜ Rahvarõivas kodulehelt.

Kujutiste valimisel üritas autor valida, kus võimalik, igast Eesti maakonnast vähemalt ühe kujutise. Testimiskujutiste seast on puudu Võru ja Põlva maakondade kujutised materjalide puudumise tõttu. Kujutiste näited on toodud välja joonisel 4.

Kasutatud kujutiste päritolu piirkonnad kattuvad peaaegu täielikult, olles ühe kujutise päritolu piirkonna võrra erinev, mis annab võrdlusmomendi ERM ja MTÜ RR kujutiste tuvastamisele. ERM testkujutiste puhul on unikaalse päritoluga rahvarõiva kujutis Tartu vallast ning MTÜ RR testkujutiste puhul on tegu Lääne-Nigula vallast pärit rahvarõivaga.

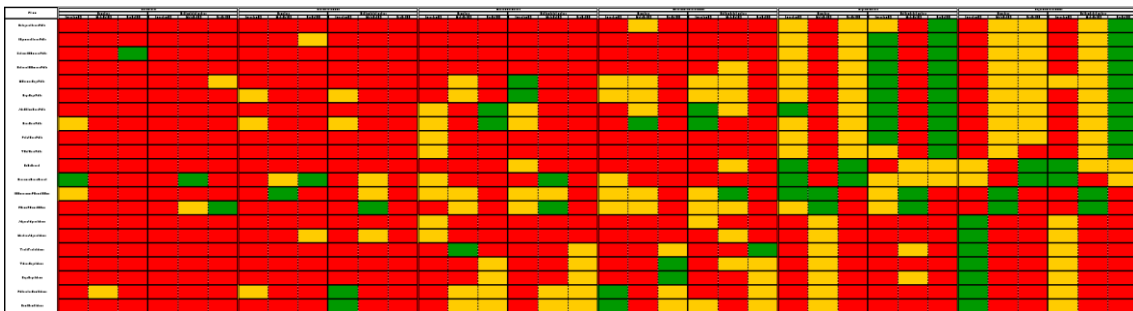


Joonis 3. Kujutiste näited: (a) ERM-ist pärit kujutis, (b) MTÜ RR-st pärit kujutis.

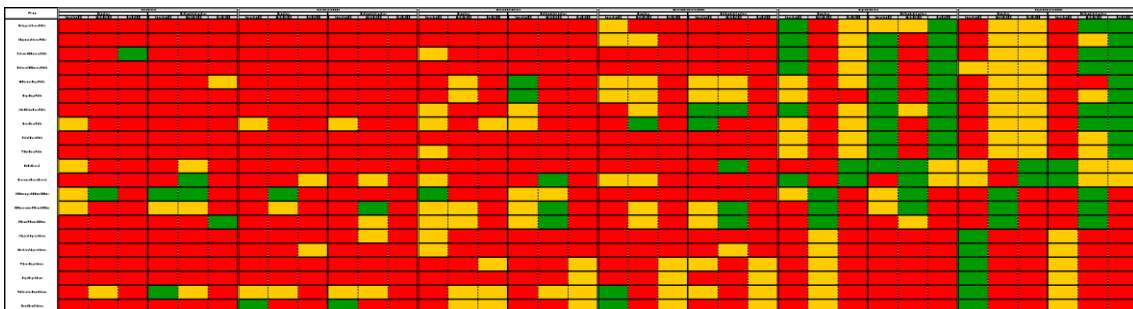
### 4.1 Üldised tulemused ja tähelepanekud

Kokku on 42 kujutise ja 36 mudeli peale 1512 testimistulemust, milles on välja toodud mudeli poolt neli kõige tõenäolisemat päritolu piirkonda kahe komakohalise täpsusega.

Mudelite testimise täpsemad tulemused on kirjas Exceli failis *MudeliteTestimiseTulemused.xlsx*<sup>1</sup>, kus tulemused on välja toodud värviskeemi abil. Roheline värv tähendab, et mudel pakkus korrektse piirkonna esimese pakkumisega; oranž värv tähendab, et mudel pakkus korrektse piirkonna nelja suurima tõenäosuse seast ja punane värv tähendab, et mudel ei pakkunud korrektset piirkonda. Regioonide puhul on värviskeem osaliselt muudetud regioonide arvu tõttu – regioonide puhul tähendab oranž värv, et mudel pakkus korrektse piirkonna esimese kahe pakkumise seast ja punane värv tähendab, et mudel ei pakkunud korrektset piirkonda esimese kahe pakkumisega. Värviskeemi on näha joonistel 5 ja 6 välja toodud testimise tulemustes.



Joonis 4. ERM kujutiste testimise tulemused.



Joonis 5. MTÜ RR kujutiste testimise tulemused.

Enne tulemuste ülevaadet peab täheldama, et ResNet50 süvaõppe algoritmi puhul oli tulemus iga pildi kohta täpselt sama, erinedes ainult mudelis endas, pakkudes iga kord kõige tõenäolisemal piirkonnal 100,0% tõenäosust ning teistel piirkondadel 0,0% tõenäosust. Tegu ei ole vormistusveaga – testides ilma vormistusega, mis ümardas tulemused kahele komakohale, pakkusid mudelid samasugust tulemust. Seega tuleb ResNet50 mudelite tulemuste analüüsil arvestada võimaliku möödatreenimisega.

<sup>1</sup> *MudeliteTestimiseTulemused.xlsx*



tulemust ehk 5,4% kõikidest valdade tulemustest ja MTÜ RR töödeldud kujutiste (joonis 8) testimisel 32 korrektset tulemust ehk 6,3% kõikidest valdade tulemustest.

Pild nimi	Valdkonnad						Valdkonnad/food					
	Algmaterjal			Rohkendatud materjal			Algmaterjal			Rohkendatud materjal		
	InceptionV3	MobileNetV2	ResNet50	InceptionV3	MobileNetV2	ResNet50	InceptionV3	MobileNetV2	ResNet50	InceptionV3	MobileNetV2	ResNet50
AlumisekorrusePild	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red
ÜlisesekorrusePild	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red
KõrvalisekorrusePild	Red	Red	Green	Red	Red	Red	Red	Red	Red	Red	Red	Red
RahvusekorrusePild	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red
MüüraPild	Red	Red	Red	Red	Red	Yellow	Red	Red	Red	Red	Red	Red
PlagiPild	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red
JätkuPild	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red
SaunPild	Yellow	Red	Red	Red	Red	Red	Yellow	Red	Red	Yellow	Red	Red
PõhikorrusePild	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red
TalustPild	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red
HuutPild	Yellow	Red	Red	Red	Yellow	Red	Red	Red	Red	Red	Red	Red
SaunakorrusePild	Red	Red	Red	Red	Green	Red	Red	Red	Yellow	Red	Yellow	Red
LõunepoolnePild	Yellow	Green	Red	Green	Green	Red	Red	Green	Red	Red	Red	Red
LõunepoolnePild	Yellow	Red	Red	Yellow	Yellow	Red	Red	Yellow	Red	Red	Green	Red
PõhikorrusePild	Red	Red	Red	Red	Red	Green	Red	Red	Red	Red	Yellow	Red
JätkuPild	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Yellow	Red
RohkendatudPild	Red	Red	Red	Red	Red	Red	Red	Red	Yellow	Red	Red	Red
TõrrePild	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red
ValgusPild	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red
PõhikorrusePild	Red	Yellow	Red	Green	Yellow	Red	Yellow	Yellow	Red	Yellow	Yellow	Red
VäljastPild	Red	Red	Red	Red	Red	Red	Green	Red	Red	Green	Red	Red

Joonis 7. MTÜ RR kujutiste testimise tulemused valdade alusel.

Vaadates algmaterjalide mudelite tulemusi, pakkusid mudelid esimese korruga õiget valda 8 korda ehk 1,6% kõikidest valdade tulemustest. Nende seas oli 4 ERM kujutist ja 4 MTÜ RR kujutist, ehk 0,8% kõikidest valdade tulemustest. Laiendatud korrektse tulemuse puhul pakkusid mudelid 28 korrektset tulemust ehk 5,6% kõikidest valdade tulemustest. Nende seas oli 13 ERM kujutist ehk 2,6% kõikidest valdade tulemustest ja 15 MTÜ RR kujutist ehk 3,0% kõikidest valdade tulemustest.

Vaadates rohkendatud mudelite tulemusi, pakkusid mudelid esimese korruga õiget valda 12 korda ehk 2,4% kõikidest rohkendatud materjalide mudelite valdade tulemustest. Nende seas oli 5 ERM kujutist ehk 1,0% kõikidest rohkendatud materjalide mudelite valdade tulemustest ja 7 MTÜ RR kujutist ehk 1,4% kõikidest rohkendatud materjalide mudelite valdade tulemustest. Laiendatud korrektse tulemuse puhul pakkusid mudelid 31 korrektset tulemust ehk 6,2% kõikidest rohkendatud materjalide mudelite valdade tulemustest. Nende seas oli 14 ERM kujutist ehk 2,6% kõikidest rohkendatud materjalide

mudelite valdade tulemustest ja 17 MTÜ RR kujutist ehk 3,4% kõikidest rohkendatud materjale mudelite valdade tulemustest.

#### **4.2.1 Algoritmide tulemused**

Süvaõppe algoritmide tulemusi võrreldes oli kõige täpsem MobileNetV2 8 korrektse tulemusega (joonis 9), mis on 40,0% kõikidest korrektsetest tulemustest. Sellele järgnesid InceptionV3 7 korrektse tulemusega (35,0%) ja ResNet50 5 korrektse tulemusega (25,0%).

ERM kujutiste testimisel said kõik algoritmid 3 korrektset tulemust ehk 33,0% ERM kujutiste tulemustest ja 15,0% kõikide korrektsete valdade tulemustest.

MTÜ RR töödeldud kujutiste testimisel oli täpsem algoritm MobileNetV2 5 korrektse tulemusega ehk 45,5% MTÜ RR kujutiste korrektsetest tulemustest ja 25,0% kõikide korrektsete valdade tulemustest. Sellele järgnesid InceptionV3 algoritm 4 korrektse tulemusega (36,4% MTÜ RR korrektsetest tulemustest ja 20,0% kõikidest korrektsetest valdade tulemustest) ja ResNet50 algoritm 2 korrektse tulemusega (18,2% MTÜ RR kujutistest, 10,0% kõikidest korrektsetest tulemustest).

Nelja täpseima piirkonnaga arvestades oli kõige täpsem algoritm jällegi MobileNetV2 24 korrektse tulemusega, mis on 40,7% kõikidest korrektsetest valdade tulemustest. Sellele algoritmile järgnevad InceptionV3 23 korrektse tulemusega (39,0% kõikidest korrektsetest tulemustest) ja ResNet50 12 korrektse tulemusega (20,3%).

Algmaterjalide mudelite puhul on täpseimad algoritmid MobileNetV2 ja ResNet50, pakkudes 3 korrektset tulemust ehk 5,1% kõikidest korrektsetest valdade tulemustest. ERM kujutiste puhul on täpsem algoritm ResNet50, pakkudes 2 korrektset tulemust ehk 10,0% kõikidest korrektsetest valdade tulemustest. MTÜ RR kujutiste puhul on täpsem algoritm MobileNetV2, pakkudes 2 korrektset tulemust ehk 10,0% kõikidest korrektsetest valdade tulemustest. Laiendatud täpsuse puhul on korrektseim algoritm InceptionV3, pakkudes 13 korrektset tulemust ehk 22,0% kõikidest korrektsetest valdade tulemustest.



## 4.2.2 Täpseimate piirkondade pakkumised

Testitud valdade seast pakkusid mudelid täpsemalt Lääne-Nigula ja Saaremaa valdasid, mõlemat pakkusid mudelid 4 korda korrektselt ehk 20% kõikidest korrektsetest tulemustest. ERM kujutiste seast pakkusid mudelid kõige täpsemalt Saaremaa valda (joonis 10), saades 3 korrektset tulemust ehk 33% ERM kujutiste korrektsetest tulemustest ja 15% kõikidest korrektsetest valdade tulemustest. MTÜ RR töödeldud kujutiste puhul pakkusid mudelid kõige täpsemini Lääne-Nigula valda 4 korrektse tulemusega (joonis 11), mis on 36,4% MTÜ RR korrektsetest tulemustest ja 20,0% kõikidest korrektsetest valdade tulemustest.

Pildi nimi	Valladelekkud						Valladelekkuvõud					
	Algmaterjal			Rohkendatud materjal			Algmaterjal			Rohkendatud materjal		
	InseptioonV1	ModiifitseerV2	ReaktorV3	InseptioonV1	ModiifitseerV2	ReaktorV3	InseptioonV1	ModiifitseerV2	ReaktorV3	InseptioonV1	ModiifitseerV2	ReaktorV3
SaaremaaSaaremaa	Green	Red	Red	Red	Green	Red	Red	Yellow	Green	Red	Yellow	Red

Joonis 9. ERM kujutiste testimisel täpsemalt pakutud valla, Saaremaa, tulemused.

Laiendatud korrektsusega tulemustes oli kõige korrektsemalt pakutud Põhja-Sakala valda 10 korrektse tulemusega ehk 16,9% kõikidest korrektsetest valdade tulemustest. Sellele järgnesid Saaremaa vald 8 korrektse tulemusega (13,6% kõikidest korrektsetest tulemustest) ning Lääneranna ja Pärnu vallad 7 tulemusega (11,9%).

Algmaterjalide mudelite tulemustes oli kõige korrektsemalt pakutud Kadrina, Lääne-Nigula ja Saaremaa valdu 2 korrektse tulemusega ehk 10,0% kõikidest korrektsetest valdade tulemustest. Laiendatud korrektsusega tulemustes oli kõige korrektsemalt pakutud Põhja-Sakala valda 5 korrektse tulemusega ehk 8,5% kõikidest korrektsetest valdade tulemustest.

Pildi nimi	Valladelekkud						Valladelekkuvõud					
	Algmaterjal			Rohkendatud materjal			Algmaterjal			Rohkendatud materjal		
	InseptioonV1	ModiifitseerV2	ReaktorV3	InseptioonV1	ModiifitseerV2	ReaktorV3	InseptioonV1	ModiifitseerV2	ReaktorV3	InseptioonV1	ModiifitseerV2	ReaktorV3
LäänemugulaLäänemugula	Yellow	Green	Red	Green	Red	Red	Red	Green	Red	Red	Red	Red

Joonis 10. MTÜ RR kujutiste testimisel täpsemalt pakutud valla, Lääne-Nigula, tulemused.

Rohkendatud mudelite tulemustes oli kõige korrektsemalt pakutud Pärnu valda 3 korrektse tulemusega ehk 15,0% kõikidest korrektsetest valdade tulemustest. Laiendatud korrektsusega tulemustes oli kõige korrektsemalt pakutud samuti Pärnu valda 7 korrektse tulemusega ehk 11,9% kõikidest korrektsetest valdade tulemustest.

## 4.3 Maakondade alusel klassifitseeritud mudelite tulemused

Arvestades mudeli testimisel esimest pakutud piirkonda korrektseks tulemuseks, pakkusid mudelid kokku 42 kujutise ja 504 testimistulemuse peale 31 korda kujutisele esimese korruga õiget maakonda ehk 6,2% tulemustest olid korrektsed. Nende seast olid 16 tulemust ERM kujutistest (joonis 12), ehk 48,4% korrektsetest tulemustest ja 3,2%



kõikidest maakondade tulemustest ning 15 tulemust MTÜ RR kujutistest (joonis 13), ehk 51,6% korrektsetest tulemustest ja 3,0% kõikidest maakondade tulemustest.

Kui arvestada korrektseks tulemust, kus on tegelik piirkond nelja suurima tõenäosuse seas, pakkusid mudelid kokku 153 korrektset tulemust ehk 43,6% kõikidest korrektsetest maakondade tulemustest. Nendest tulemustest 31 ehk 20,3% kõikidest korrektsetest tulemustest olid täpsed esimesel pakkumisel, 28 tulemust ehk 18,3% kõikidest korrektsetest tulemustest olid täpsed teisel pakkumisel, 49 tulemust ehk 32,0% kõikidest korrektsetest tulemustest olid täpsed kolmandal pakkumisel ja 45 tulemust ehk 29,4% kõikidest korrektsetest tulemustest olid täpsed neljandal pakkumisel. Nelja suurimat tõenäosust korrektseks arvestades oli ERM kujutiste (joonis 12) testimisel 79 korrektset tulemust ehk 15,7% kõikidest maakondade tulemustest ja MTÜ RR töödeldud kujutiste (joonis 13) testimisel 74 korrektset tulemust ehk 14,7% kõikidest valdade tulemustest.

Pildi nimi	Mokoonnõuvalised						Mokoonnõuvalised					
	Algnevõrgu			Rakendatud materjal			Algnevõrgu			Rakendatud materjal		
	IsoplaneV3	MobileNetV2	RuNet50	IsoplaneV3	MobileNetV2	RuNet50	IsoplaneV3	MobileNetV2	RuNet50	IsoplaneV3	MobileNetV2	RuNet50
AltagoodidvõrguPõhja	Red	Red	Red	Red	Red	Red	Yellow	Red	Red	Red	Red	Red
LõunavõrguPõhja	Red	Red	Red	Red	Red	Red	Yellow	Yellow	Red	Red	Red	Red
KidrikuvõrguPõhja	Yellow	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red
RakvereLõunavõrguPõhja	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red
MitajõevõrguPõhja	Red	Yellow	Red	Green	Red	Red	Yellow	Red	Red	Yellow	Red	Red
RuuhõõruvõrguPõhja	Red	Yellow	Red	Green	Red	Red	Yellow	Red	Red	Yellow	Red	Red
JõhivõrguPõhja	Yellow	Red	Red	Yellow	Red	Red	Red	Yellow	Red	Green	Red	Red
SaaremaaPõhja	Yellow	Red	Yellow	Yellow	Red	Red	Green	Red	Green	Red	Red	Red
PaidevõrguPõhja	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red
TõstevõrguPõhja	Yellow	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red
NiitväljavõrguPõhja	Red	Red	Red	Red	Red	Red	Red	Red	Red	Green	Red	Red
SaaremaaLõunavõrguPõhja	Yellow	Red	Red	Green	Red	Red	Yellow	Yellow	Red	Red	Red	Red
LõunavõrguLõunavõrguPõhja	Green	Red	Red	Yellow	Yellow	Red	Red	Red	Red	Red	Red	Red
LõunavõrguPõhja	Yellow	Yellow	Red	Yellow	Green	Red	Red	Yellow	Red	Yellow	Green	Red
PõhjaLõunavõrguPõhja	Yellow	Red	Red	Yellow	Green	Red	Red	Red	Red	Yellow	Red	Red
JõhivõrguLõunavõrguPõhja	Yellow	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red
MitajõevõrguLõunavõrguPõhja	Yellow	Red	Red	Red	Red	Red	Red	Red	Red	Yellow	Red	Red
TõstevõrguLõunavõrguPõhja	Red	Red	Yellow	Red	Red	Yellow	Red	Red	Yellow	Red	Red	Yellow
VõrguLõunavõrguPõhja	Red	Red	Red	Red	Red	Yellow	Red	Red	Yellow	Red	Red	Yellow
PõhjaLõunavõrguLõunavõrguPõhja	Red	Yellow	Yellow	Red	Red	Yellow	Green	Red	Yellow	Red	Red	Yellow
VõrguLõunavõrguLõunavõrguPõhja	Red	Yellow	Yellow	Red	Red	Yellow	Green	Red	Yellow	Red	Red	Yellow

Joonis 11. ERM kujutiste testimise tulemused maakondade alusel.

Vaadates algmaterjalide mudelite tulemusi, pakkusid mudelid esimese korraga õiget maakonda 11 korda ehk 2,2% kõikidest maakondade tulemustest. Nende seas oli 7 ERM kujutist ehk 1,4% kõikidest maakondade tulemustest ja 4 MTÜ RR kujutist ehk 0,8% kõikidest maakondade tulemustest. Laiendatud korrektse tulemuse puhul pakkusid mudelid 80 korrektset tulemust ehk 15,9% kõikidest maakondade tulemustest. Nende seas

oli 39 ERM kujutist ehk 7,7% kõikidest maakondade tulemustest ja 41 MTÜ RR kujutist ehk 8,2% kõikidest maakondade tulemustest.

Vaadates rohkendatud mudelite tulemusi, pakkusid mudelid esimese korraga õiget maakonda 20 korda ehk 4,0% kõikidest maakondade tulemustest. Nende seas oli 9 ERM kujutist ehk 1,8% kõikidest maakondade tulemustest ja 11 MTÜ RR kujutist ehk 2,2% kõikidest maakondade tulemustest. Laiendatud korrektse tulemuse puhul pakkusid mudelid 73 korrektset tulemust ehk 14,5% kõikidest maakondade tulemustest. Nende seas oli 40 ERM kujutist ehk 7,9% kõikidest maakondade tulemustest ja 33 MTÜ RR kujutist ehk 6,5% kõikidest maakondade tulemustest.

Pildisüsi	Maakonnad: Suvi						Maakonnad: Sügis					
	Algoritmid			Rohkendatud mudelid			Algoritmid			Rohkendatud mudelid		
	InceptionV3	MobileNetV2	ResNet50	InceptionV3	MobileNetV2	ResNet50	InceptionV3	MobileNetV2	ResNet50	InceptionV3	MobileNetV2	ResNet50
Ahrensloo	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red
Lõunapoolne	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red
Kidme	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red
Rakvere	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red
Mõisaküla	Red	Yellow	Red	Green	Red	Red	Yellow	Red	Red	Yellow	Red	Red
Põhja	Red	Yellow	Red	Green	Red	Red	Yellow	Red	Red	Yellow	Red	Red
Jõhvi	Yellow	Red	Green	Yellow	Red	Red	Red	Red	Green	Yellow	Red	Red
Saaremaa	Red	Red	Green	Yellow	Red	Red	Red	Red	Green	Red	Red	Red
Põhja-Eesti	Yellow	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red
Turu	Yellow	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red	Red
Hiiu	Red	Red	Red	Yellow	Red	Red	Red	Red	Red	Red	Yellow	Red
Saaremaa	Yellow	Red	Red	Red	Green	Red	Yellow	Red	Red	Red	Red	Red
Lääne-Eesti	Yellow	Red	Red	Yellow	Red	Red	Yellow	Red	Red	Yellow	Green	Red
Pärnu	Red	Yellow	Red	Yellow	Green	Red	Yellow	Red	Red	Yellow	Red	Red
Jõgeva	Yellow	Red	Red	Red	Red	Red	Red	Red	Red	Yellow	Red	Red
Märjamaa	Yellow	Red	Red	Red	Red	Red	Red	Red	Red	Red	Yellow	Red
Tartu	Red	Green	Red	Red	Red	Yellow	Red	Red	Yellow	Red	Red	Green
Tõre	Red	Red	Yellow	Red	Red	Yellow	Red	Red	Green	Red	Yellow	Red
Valga	Red	Red	Red	Red	Red	Red	Red	Red	Green	Red	Red	Yellow
Põhja-Viljandi	Red	Yellow	Red	Red	Yellow	Yellow	Green	Red	Yellow	Red	Red	Yellow
Viljandi	Red	Yellow	Red	Red	Red	Yellow	Green	Red	Yellow	Red	Red	Yellow

Joonis 12. MTÜ RR kujutiste testimise tulemused maakondade alusel.

### 4.3.1 Algoritmide tulemused

Süvaõppe algoritmide tulemusi võrreldes olid täpseimad InceptionV3 ja MobileNetV2 13 korrektse tulemusega (joonis 14), mis on 41,9% kõikidest korrektsetest tulemustest. ResNet50 tulemuseks oli 5 korrektset pakkumist (16,2% kõikidest korrektsetest maakondade tulemustest).



kõikidest korrektsetest maakondade tulemustest. MTÜ RR kujutiste puhul on täpsem algoritm InceptionV3, pakkudes 3 korrektset tulemust ehk 9,7% kõikidest korrektsetest maakondade tulemustest. Laiendatud täpsuse puhul on korrektsem algoritm InceptionV3, pakkudes 32 korrektset tulemust ehk 20,9% kõikidest korrektsetest maakondade tulemustest.

Rohkendatud mudelite puhul on täpsem algoritm MobileNetV2, pakkudes 10 korrektset tulemust ehk 32,3% kõikidest korrektsetest maakondade tulemustest. ERM kujutiste puhul on täpsem algoritm InceptionV3, pakkudes 4 korrektset tulemust ehk 12,9% kõikidest korrektsetest maakondade tulemustest. MTÜ RR kujutiste puhul on täpsem algoritm MobileNetV2, pakkudes 7 korrektset tulemust ehk 22,6% kõikidest korrektsetest maakondade tulemustest. Laiendatud täpsuse puhul on korrektsem algoritm InceptionV3, pakkudes 30 korrektset tulemust ehk 19,6% kõikidest korrektsetest maakondade tulemustest.

#### 4.3.2 Täpseimate piirkondade pakkumised

Testitud maakondade seast pakkusid mudelid täpsemalt Harju maakonda, mida pakuti 9 korda korrektselt ehk 29,0% kõikidest korrektsetest tulemustest. ERM kujutiste seast pakkusid mudelid kõige täpsemalt samuti Harju maakonda (joonis 15), saades 5 korrektset tulemust ehk 31,2% ERM kujutiste korrektsetest tulemustest ja 16,2% kõikidest korrektsetest maakondade tulemustest. MTÜ RR töödeldud kujutiste puhul pakkusid mudelid kõige täpsemini Harju ja Pärnu maakondi (joonis 16) 4 korrektset tulemusega, mis on 26,7% MTÜ RR korrektsetest tulemustest ja 12,9% kõikidest korrektsetest maakondade tulemustest.

Pildi nimi	Maakonnatäpsused						Maakonnatäpsused					
	Algmaterjal			Rohkendatud materjal			Algmaterjal			Rohkendatud materjal		
	InceptionV3	MobileNetV2	ResNet50	InceptionV3	MobileNetV2	ResNet50	InceptionV3	MobileNetV2	ResNet50	InceptionV3	MobileNetV2	ResNet50
Jätkemaarjupõlva	Yellow	Red	Green	Yellow	Red	Red	Red	Yellow	Red	Green	Yellow	Red
Saaremaa	Yellow	Red	Green	Yellow	Red	Red	Green	Red	Green	Red	Red	Red

Joonis 14. ERM kujutiste testimisel täpsemalt pakutud maakonna, Harju, tulemused.

Laiendatud korrektsusega tulemustes oli kõige korrektsemalt pakutud Viljandi ja Pärnu maakondi 29 korrektse tulemusega ehk 19,0% kõikidest korrektsetest maakondade tulemustest. Sellele järgnesid Harju maakond 21 korrektse tulemusega (13,7% kõikidest korrektsetest maakondade tulemustest) ja Valga maakond 17 korrektse tulemusega (11,1%).

Algmaterjalide mudelite tulemustes oli kõige korrektsemalt pakutud Harju ja Viljandi maakondi 4 korrektse tulemusega ehk 12,9% kõikidest korrektsetest maakondade tulemustest. Laiendatud korrektsusega tulemustes oli kõige korrektsemalt pakutud Viljandi maakonda 16 korrektse tulemusega ehk 27,1% kõikidest korrektsetest maakondade tulemustest.

Rohkendatud mudelite tulemustes oli kõige korrektsemalt pakutud Pärnu maakonda 6 korrektse tulemusega ehk 3,9% kõikidest korrektsetest valdade tulemustest. Laiendatud korrektsusega tulemustes oli kõige korrektsemalt pakutud samuti Pärnu valda 16 korrektse tulemusega ehk 10,5% kõikidest korrektsetest maakondade tulemustest.

Pild-nimi	Maakonnafotolüübid						Maakonnafotolüübid					
	Algmaterjal			Rohkendatud materjal			Algmaterjal			Rohkendatud materjal		
	Inoptiooniv3	MobileNetV2	ResNet50	Inoptiooniv3	MobileNetV2	ResNet50	Inoptiooniv3	MobileNetV2	ResNet50	Inoptiooniv3	MobileNetV2	ResNet50
Alammaterjalid	Yellow	Red	Red	Yellow	Red	Red	Red	Yellow	Red	Green	Green	Red
Sauekujutid	Yellow	Red	Yellow	Yellow	Red	Red	Red	Green	Red	Green	Red	Red
Laiendatud materjalid	Yellow	Yellow	Red	Yellow	Green	Red	Red	Yellow	Red	Yellow	Green	Red
Pärnu Pärnu	Yellow	Yellow	Red	Yellow	Green	Red	Red	Yellow	Red	Yellow	Green	Red

Joonis 15. MTÜ RR kujutiste testimisel täpsemalt pakutud maakondade, Harju (ülemised kaks rida) ja Pärnu (alumised kaks rida), tulemused.

#### 4.4 Regionide alusel klassifitseeritud mudelite tulemused

Arvestades mudeli testimisel esimest pakutud piirkonda korrektseks tulemuseks, pakkusid mudelid kokku 42 kujutise ja 504 testimistulemuse peale 119 korda kujutisele esimese korraga õiget regiooni ehk 23,6% tulemustest olid korrektsed. Nende seast olid 53 tulemust ERM kujutistest (joonis 17), ehk 44,5% korrektsetest tulemustest ja 10,5% kõikidest regioonide tulemustest ning 66 tulemust MTÜ RR kujutistest (joonis 18), ehk 55,5% korrektsetest tulemustest ja 13,1% kõikidest regioonide tulemustest.

Regioonide puhul tuleb laiendatud korrektset tulemust arvestada teistmoodi kui valdade ja maakondade puhul. Kuna regioonideks on valitud neli piirkonda, arvestame laiendatud korrektse tulemusena tulemust, kus testitud kujutise piirkond on esimese kahe mudeli poolt pakutud piirkonna seas. Eelnimetatud juhul pakkusid mudelid kokku 265 korrektset tulemust ehk 52,6% korrektseid tulemusi ning mudelid olid teisel pakkumisel täpsed 146 korral ehk 55,0% kõikidest korrektsetest tulemustest ja 29,0% kõikidest regioonide tulemustest. ERM kujutiste seas (joonis 17) oli 133 laiendatud korrektsusega tulemust ehk 26,4% kõikidest regioonide tulemustest ja MTÜ RR töödeldud kujutiste (joonis 18) testimisel 132 laiendatud korrektsusega tulemust ehk 26,2% kõikidest regioonide tulemustest.

Vaadates algmaterjalide mudelite tulemusi, pakkusid mudelid esimese korraga õiget regiooni 41 korda ehk 8,1% kõikidest regioonide tulemustest. Nende seas oli 19 ERM kujutist ehk 3,8% kõikidest regioonide tulemustest ja 22 MTÜ RR kujutist ehk 4,4% kõikidest regioonide tulemustest. Laiendatud korrektse tulemuse puhul pakkusid mudelid 133 korrektset tulemust ehk 26,4% kõikidest regioonide tulemustest. Nende seas oli 67 ERM kujutist ehk 13,3% kõikidest regioonide tulemustest ja 66 MTÜ RR kujutist ehk 13,1% kõikidest regioonide tulemustest.

Pild nimi	RegioonidEruilind						RegioonidEruilind					
	Algmaterjal			Rohkendatud materjal			Algmaterjal			Rohkendatud materjal		
	InceptionV3	MobileNetV2	ResNet50	InceptionV3	MobileNetV2	ResNet50	InceptionV3	MobileNetV2	ResNet50	InceptionV3	MobileNetV2	ResNet50
AhtrageodidivinePõhja	Yellow	Red	Yellow	Yellow	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
LõunageodidivinePõhja	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
KordinaalsädeinePõhja	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
RahvasteleolinePõhja	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
Mõjusaadepõhja	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
PuhtaPõhja	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
Jõudkandepõhja	Green	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
Seadepõhja	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
Paadepõhja	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
Talupõhja	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
Maandepõhja	Green	Red	Yellow	Green	Red	Green	Yellow	Red	Green	Yellow	Red	Green
Saadepõhja	Green	Red	Yellow	Green	Red	Green	Yellow	Red	Green	Yellow	Red	Green
Lõunageodidivine	Green	Red	Yellow	Green	Red	Green	Yellow	Red	Green	Yellow	Red	Green
PõhjaPõhja	Yellow	Green	Red	Yellow	Green	Red	Red	Green	Red	Yellow	Green	Red
Jõudkandepõhja	Red	Yellow	Red	Red	Yellow	Red	Green	Red	Yellow	Red	Yellow	Red
Muudatusepõhja	Red	Yellow	Red	Red	Yellow	Red	Red	Yellow	Red	Yellow	Red	Red
TammiPõhja	Red	Yellow	Red	Red	Yellow	Red	Green	Red	Yellow	Red	Yellow	Red
TõrrePõhja	Red	Yellow	Red	Red	Yellow	Red	Green	Red	Yellow	Red	Yellow	Red
VõlguPõhja	Red	Yellow	Red	Red	Yellow	Red	Green	Red	Yellow	Red	Yellow	Red
PõhjaPõhja	Red	Yellow	Red	Red	Yellow	Red	Green	Red	Yellow	Red	Yellow	Red
VõlguPõhja	Red	Yellow	Red	Red	Yellow	Red	Green	Red	Yellow	Red	Yellow	Red

Joonis 16. ERM kujutiste testimise tulemused regioonide alusel.

Vaadates rohkendatud mudelite tulemusi, pakkusid mudelid esimese korraga õiget regiooni 78 korda ehk 15,5% kõikidest regioonide tulemustest. Nende seas oli 34 ERM kujutist ehk 6,7% kõikidest regioonide tulemustest ja 44 MTÜ RR kujutist ehk 8,7% kõikidest regioonide tulemustest.

Pildisümbol	Regioonid: Tallinn						Regioonid: vallad/Võid					
	Algsuurust			Rohkemendatud suurust			Algsuurust			Rohkemendatud suurust		
	InceptionV3	MobileNetV2	ResNet50	InceptionV3	MobileNetV2	ResNet50	InceptionV3	MobileNetV2	ResNet50	InceptionV3	MobileNetV2	ResNet50
Alataguseid sümbol	Green	Red	Yellow	Yellow	Yellow	Green	Red	Yellow	Yellow	Red	Green	Green
Ligaseid sümbol	Green	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
Kadunud sümbol	Green	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Green	Green
Rakendatud sümbol	Green	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Green	Green
Mitmesuguseid sümbol	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Red	Green
Põhjalik sümbol	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
Jätkusuutlik sümbol	Green	Red	Yellow	Green	Yellow	Green	Red	Yellow	Yellow	Red	Green	Green
Suure sümbol	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Green	Green
Puudunud sümbol	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
Tuult sümbol	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
Misliinid	Red	Red	Green	Green	Green	Yellow	Red	Green	Green	Yellow	Yellow	Yellow
Suuremad suured	Green	Red	Green	Red	Green	Yellow	Red	Green	Green	Yellow	Yellow	Yellow
Lisandatud sümbol	Yellow	Green	Red	Yellow	Green	Red	Red	Green	Red	Red	Green	Red
Lisandatud sümbol	Red	Green	Red	Yellow	Green	Red	Red	Green	Red	Red	Green	Red
Põhjalik sümbol	Red	Green	Red	Red	Yellow	Red	Red	Green	Red	Red	Green	Red
Jätkusuutlik sümbol	Red	Yellow	Red	Red	Red	Red	Green	Red	Red	Yellow	Red	Red
Mitmesuguseid sümbol	Red	Yellow	Red	Red	Red	Red	Green	Red	Red	Yellow	Red	Red
Tõenäoliselt sümbol	Red	Yellow	Red	Red	Red	Red	Green	Red	Red	Yellow	Red	Red
Valge sümbol	Red	Yellow	Red	Red	Red	Red	Green	Red	Red	Yellow	Red	Red
Põhjalik sümbol	Red	Yellow	Red	Red	Red	Red	Green	Red	Red	Yellow	Red	Red
Võid sümbol	Red	Yellow	Red	Red	Red	Red	Green	Red	Red	Yellow	Red	Red

Joonis 17. MTÜ RR kujutiste testimise tulemused regioonide alusel.

Laiendatud korrektse tulemuse puhul pakkusid mudelid 132 korrektset tulemust ehk 52,4% kõikidest regioonide tulemustest. Nende seas oli 66 ERM kujutist ja 66 MTÜ RR kujutist ehk 13,1% kõikidest regioonide tulemustest.

#### 4.4.1 Algoritmide tulemused

Süvaõppe algoritmide tulemusi võrreldes oli täpsem ResNet50 48 korrektse tulemusega (joonis 19), mis on 40,3% kõikidest korrektsetest tulemustest. Järgnesid InceptionV3 45 korrektse tulemusega (37,8% kõikidest korrektsetest regioonide tulemustest) ja MobileNetV2 26 korrektse pakkumisega (21,8% kõikidest korrektsetest regioonide tulemustest).

ERM kujutiste testimisel oli täpsem ResNet50, saades kokku 24 korrektset tulemust, mis on 45,3% ERM kujutiste korrektsetest tulemustest ja 20,2% kõikidest korrektsetest regioonide tulemustest. Sellele järgnesid InceptionV3 21 korrektse tulemusega (39,6% ERM kujutiste korrektsetest tulemustest ja 17,6% kõikidest korrektsetest maakondade tulemustest) ja MobileNetV2 8 korrektse tulemusega (15,1% ERM kujutistest, 6,7% kõikidest korrektsetest tulemustest).

MTÜ RR töödeldud kujutiste testimisel olid täpseimad algoritmid InceptionV3 ja ResNet50 24 korrektse tulemusega ehk 36,4% MTÜ RR kujutiste korrektsetest tulemustest ja 20,2% kõikide korrektsete regioonide tulemustest. MobileNetV2 mudelid said 18 korrektset tulemust ehk 27,3% MTÜ RR kujutiste korrektsetest tulemustest ja 15,1% kõikide korrektsete regioonide tulemustest.

Pildi nimi	Eesti Rikva Muuseum				MTÜ Rakverelinn			
	RegioonidSeelikud		RegioonidSeelikudVõõd		RegioonidSeelikud		RegioonidSeelikudVõõd	
	Algmaterjal	Rohkendatud materjal	Algmaterjal	Rohkendatud materjal	Algmaterjal	Rohkendatud materjal	Algmaterjal	Rohkendatud materjal
Alutagusedsvirupõhja	Yellow	Green	Yellow	Green	Yellow	Green	Yellow	Green
Lüganusedsvirupõhja	Yellow	Green	Yellow	Green	Yellow	Green	Yellow	Green
Kadrinalõõnevirupõhja	Yellow	Green	Yellow	Green	Yellow	Green	Yellow	Green
Rakverelõõnevirupõhja	Yellow	Green	Yellow	Green	Yellow	Green	Yellow	Green
MisjamaoPõhjaPõhja	Yellow	Green	Yellow	Green	Yellow	Green	Yellow	Green
PõhjaPõhjaPõhja	Yellow	Green	Yellow	Green	Red	Green	Yellow	Green
JõelõõneHarjuPõhja	Yellow	Green	Yellow	Green	Yellow	Green	Yellow	Green
SõudeHarjuPõhja	Yellow	Green	Yellow	Green	Yellow	Green	Yellow	Green
PõhjaJõrvaPõhja	Yellow	Green	Yellow	Green	Yellow	Green	Yellow	Green
TüriJõrvaPõhja	Yellow	Green	Red	Green	Yellow	Green	Yellow	Green
HiivHiivSaared	Green	Yellow	Green	Yellow	Green	Yellow	Green	Yellow
SaaremaaSaareSaared	Green	Yellow	Green	Yellow	Green	Yellow	Green	Yellow
LõõneigufalLõõneLõõne	White	White	White	White	Red	Red	Red	Red
LõõnerannaPõhjaLõõne	Red	Red	Red	Red	Red	Red	Red	Red
PõhjaPõhjaLõõne	Red	Red	Red	Red	Red	Red	Red	Red
JõgevaJõgevalõõne	Red	Red	Red	Red	Red	Red	Red	Red
MuistveeJõgevalõõne	Red	Red	Red	Red	Red	Red	Red	Red
TartuTartulõõne	Red	Red	Red	Red	White	White	White	White
TõrvaValgalõõne	Red	Red	Red	Red	Red	Red	Red	Red
ValgaValgalõõne	Red	Red	Red	Red	Red	Red	Red	Red
PõhjaSaareViljandiLõõne	Red	Red	Red	Red	Red	Red	Red	Red
ViljandiViljandiLõõne	Red	Red	Red	Red	Red	Red	Red	Red

Joonis 18. Regioonide puhul täpseima algoritmi, ResNet50, testimise tulemused.

Kahe täpseima piirkonnaga arvestades oli kõige täpsem algoritm InceptionV3 92 korrektse tulemusega, mis on 34,7% kõikidest korrektsetest regioonide tulemustest. Sellele algoritmile järgnevad MobileNetV2 90 korrektse tulemusega (34,0% kõikidest korrektsetest regioonide tulemustest) ja ResNet50 83 korrektse tulemusega (31,3%).



Algmaterjalide mudelite puhul on täpsem algoritm InceptionV3, pakkudes 23 korrektset tulemust ehk 19,3% kõikidest korrektsetest regioonide tulemustest. ERM kujutiste puhul on täpsem algoritm InceptionV3, pakkudes 11 korrektset tulemust ehk 9,2% kõikidest korrektsetest regioonide tulemustest. MTÜ RR kujutiste puhul on täpsem algoritm InceptionV3, pakkudes 12 korrektset tulemust ehk 10,1% kõikidest korrektsetest regioonide tulemustest. Laiendatud täpsuse puhul on korrektseim algoritm ResNet50, pakkudes 46 korrektset tulemust ehk 17,4% kõikidest korrektsetest regioonide tulemustest.

Rohkendatud mudelite puhul on täpsem algoritm ResNet50, pakkudes 40 korrektset tulemust ehk 33,6% kõikidest korrektsetest regioonide tulemustest. ERM ja MTÜ RR kujutiste puhul on täpsem algoritm ResNet50, pakkudes 20 korrektset tulemust ehk 16,8% kõikidest korrektsetest regioonide tulemustest. Laiendatud täpsuse puhul on korrektseim algoritm ResNet50, pakkudes 48 korrektset tulemust ehk 18,1% kõikidest korrektsetest regioonide tulemustest.

#### 4.4.2 Täpseimate piirkondade pakkumised

Testitud regioonide seast pakkusid mudelid täpsemalt Põhja regiooni, mida pakuti 65 korda korrektset ehk 54,6% kõikidest korrektsetest tulemustest. ERM kujutiste seast pakkusid mudelid kõige täpsemalt samuti Põhja regiooni (joonis 20), saades 26 korrektset tulemust ehk 49,1% ERM kujutiste korrektsetest tulemustest ja 21,8% kõikidest korrektsetest maakondade tulemustest. MTÜ RR töödeldud kujutiste puhul pakkusid mudelid kõige täpsemini Põhja regiooni 39 korrektse tulemusega (joonis 21) , mis on 59,1% MTÜ RR korrektsetest tulemustest ja 32,8% kõikidest korrektsetest maakondade tulemustest.

Piltidena	Regioonidestiku						RegioonidestikuVõrk					
	Algmaterjal			Rohkendatud materjal			Algmaterjal			Rohkendatud materjal		
	InceptionV3	VGG16	ResNet50	InceptionV3	VGG16	ResNet50	InceptionV3	VGG16	ResNet50	InceptionV3	VGG16	ResNet50
AlidaguetidennuPõhja	Yellow	Red	Yellow	Yellow	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
LüpsmeedidennuPõhja	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
KadimeelidennuPõhja	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
RakvereidennuPõhja	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
VõrumaalidennuPõhja	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
RaplaidennuPõhja	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
Ida-HämeidennuPõhja	Green	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
SaaremaaPõhja	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
PärnimaalidennuPõhja	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
TartumaalidennuPõhja	Yellow	Red	Yellow	Yellow	Red	Green	Red	Yellow	Red	Red	Yellow	Green

Joonis 19. ERM kujutiste testimisel täpsemalt pakutud regiooni, Põhja, tulemused.

Laiendatud korrektsusega tulemustes oli kõige korrektsemalt pakutud Põhja regiooni 154 korrektse tulemusega ehk 58,1% kõikidest korrektsetest regioonide tulemustest. Sellele järgnesid Lõuna regioon 48 korrektse tulemusega (18,1% kõikidest korrektsetest regioonide tulemustest) ja Saarte regioon 36 korrektse tulemusega (13,6%).

Algmaterjalide mudelite tulemustes oli kõige korrektsemalt pakutud Lõuna regiooni 13 korrektse tulemusega ehk 10,9% kõikidest korrektsetest regioonide tulemustest. Laiendatud korrektsusega tulemustes oli kõige korrektsemalt pakutud Põhja regiooni 79 korrektse tulemusega ehk 29,8% kõikidest korrektsetest regioonide tulemustest.

Mudeli nimi	Regioonidelekkid						Regioonidelekkid					
	Algmaterjal		Rohkendatud materjal		Rohkendatud materjal		Algmaterjal		Rohkendatud materjal		Rohkendatud materjal	
	InceptioV1	ModulidV2	BankartV3	InceptioV1	ModulidV2	BankartV3	InceptioV1	ModulidV2	BankartV3	InceptioV1	ModulidV2	BankartV3
AlurakendaminePõhja	Green	Red	Yellow	Yellow	Yellow	Green	Red	Yellow	Yellow	Red	Green	Green
LõunaPõhja	Green	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
KademaPõhja	Green	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Green	Green
KõrrePõhja	Green	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Green	Green
MajandusPõhja	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Red	Green
ReaktiivPõhja	Yellow	Red	Red	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
EluPõhja	Green	Red	Yellow	Green	Yellow	Green	Red	Yellow	Yellow	Red	Green	Green
SaarePõhja	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Green	Green
IndustriaalPõhja	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green
TurismPõhja	Yellow	Red	Yellow	Green	Red	Green	Red	Yellow	Yellow	Red	Yellow	Green

Joonis 20. MTÜ RR kujutiste testimisel täpselt pakutud regiooni, Põhja, tulemused.

Rohkendatud mudelite tulemustes oli kõige korrektsemalt pakutud Põhja regiooni 59 korrektse tulemusega ehk 49,6% kõikidest korrektsetest regioonide tulemustest. Laiendatud korrektsusega tulemustes oli kõige korrektsemalt pakutud samuti Põhja regiooni 75 korrektse tulemusega ehk 28,3% kõikidest korrektsetest regioonide tulemustest.

#### 4.5 Algmaterjalide mudelite tulemuste võrdlus rohkendatud mudelite tulemustega

Lisaks eelnevatele tulemustele on veel välja arvatud tulemuste põhjal vastus küsimusele, kas rohkendatud materjalidel treenitud mudelid olid täpsemad kui algmaterjalidel treenitud mudelid? Väärtusteks oleval tulemused saadi rohkendatud materjalide põhjal treenitud mudelite korrektsete tulemuste lahutamisel algmaterjalide põhjal treenitud mudelite korrektsetest tulemustest. Positiivsed tulemused arvestati kui

„JAH“, võrdväärset ja negatiivset tulemust läksid kirja kui „EI“. Täpsemad tulemused on kirjas tabelis MudeliteTestimiseTulemused.xlsx<sup>1</sup>,

#### **4.5.1 Valdade alusel klassifitseeritud mudelite tulemuste võrdlus**

Vaadates ainult tulemusi, kus mudel pakkus esimese piirkonna korrektselt, on näha, et oli kolm valda, mille puhul olid rohkendatud mudelid täpsemad – Pärnu, Põhja-Sakala, ja Viljandi. Pärnu puhul on vahe suurim, kolme tulemuse võrra täpsem, sellele järgnesid Põhja-Sakala ja Viljandi, olles vastavalt kahe ja ühe tulemuse võrra täpsem.

ERM kujutiste puhul olid tulemused samad – kolm valda, mille puhul on rohkendatud mudelite tulemused täpsemad, ja need olid jällegi Pärnu, Põhja-Sakala ja Viljandi. Pärnu oli siinkohapeal samuti suurim, seekord kahe tulemuse võrra täpsem ja Põhja-Sakala ja Viljandi olid mõlemad ühe tulemuse võrra täpsemad.

MTÜ RR kujutiste puhul olid tulemused erinevad, nii valdade kui piirkondade osas. Siinkohal oli neli erinevat valda, mille puhul oli rohkendatud mudelid täpsemad – Lääneranna, Pärnu, Põhja-Sakala ja Saaremaa. Kõik neli valda olid ühe tulemuse võrra täpsemad algmaterjalide mudelite tulemustest.

Laiendatud korrektsuse puhul oli neli valda, mille puhul on rohkendatud mudelite tulemused täpsemad – Jõgeva, Märjamaa, Pärnu ja Viljandi. Siinkohal oli suurim vahe Pärnu valla puhul, kus rohkendatud mudelid olid seitsme tulemuse võrra täpsem algmaterjalide mudelitest. Järgnesid Märjamaa vald kahe tulemuse ning Jõgeva ja Viljandi vallad mõlemad ühe tulemusega.

ERM kujutiste laiendatud korrektsuse puhul olid kolme valla rohkendatud mudelite tulemused täpsemad, milleks olid Märjamaa, Pärnu ja Viljandi. Siingi oli suurim vahe Pärnu valla tulemustes, rohkendatud mudelid olid viie tulemuse võrra täpsemad, ja järgnesid Märjamaa ja Viljandi, mõlemad ühe tulemusega.

MTÜ RR kujutiste laiendatud korrektsuse puhul olid viie valla rohkendatud mudelite tulemused täpsemad – Jõgeva, Märjamaa, Pärnu, Põhja-Sakala ja Saaremaa. Siin olid

---

<sup>1</sup> <https://github.com/htonts/rahvaroivas/blob/main/testimistulemused/MudeliteTestimiseTulemused.xlsx>

vahed aga väiksemad, Pärnu valla tulemused olid kahe tulemuse võrra täpsemad ja ülejäänud valdade tulemused olid ühe tulemuse võrra täpsemad.

#### **4.5.2 Maakondade alusel klassifitseeritud mudelite tulemuste võrdlus**

Tulemuste seas, kus mudel pakkus esimese piirkonna korrektselt, oli viie maakonda, mille puhul olid rohkendatud mudelid täpsemad – Harju, Hiiu, Pärnu, Rapla ja Saare. Pärnu maakonna puhul oli vahe suurim, olles kuue tulemuse võrra täpsem algmaterjalide mudelite tulemustest. Sellele järgnesid Rapla maakond nelja tulemusega, Saare maakond kahe tulemusega, ning Harju ja Hiiu maakonnad ühe tulemusega.

ERM kujutiste puhul oli kolm maakonda, mille puhul olid rohkendatud mudelite tulemused täpsemad – Pärnu, Rapla ja Saare. Pärnu ja Rapla maakonnad olid kahe tulemuse võrra täpsemad ning Saare maakond oli ühe tulemuse võrra täpsem.

MTÜ RR kujutiste puhul on jällegi viis maakonda, mille puhul olid rohkendatud mudelite tulemused täpsemad - Harju, Hiiu, Pärnu, Rapla ja Saare. Pärnu maakonna puhul oli vahe suurim, olles nelja tulemuse võrra täpsem algmaterjalide mudelite tulemustest. Järgnesid Harju ja Rapla maakonnad kahe tulemusega ning Hiiu ja Saare maakonnad ühe tulemusega.

Laiendatud korrektsuse puhul oli kolm maakonda, mille puhul olid rohkendatud mudelite tulemused täpsemad – Hiiu, Pärnu ja Valga. Siinkohal olid Valga maakonna tulemuste vahe suurim, rohkendatud mudelitel oli viis täpsemat tulemust. Hiiu ja Pärnu maakondade puhul oli rohkendatud mudelitel kolm täpsemat tulemust.

ERM kujutiste laiendatud korrektsuse puhul olid nelja maakonna rohkendatud mudelite tulemused täpsemad, milleks olid Hiiu, Lääne-Viru, Pärnu ja Valga. Siingi on suurim vahe Valga maakonna tulemustes, rohkendatud mudelid olid kolme tulemuse võrra täpsemad. Järgnesid Hiiu maakond kahe tulemusega ning Lääne-Viru ja Pärnu maakonnad ühe tulemusega.

MTÜ RR kujutiste laiendatud korrektsuse puhul olid kolme maakonna rohkendatud mudelite tulemused täpsemad – Hiiu, Pärnu ja Valga. Pärnu ja Valga maakondade tulemused olid kahe tulemuse võrra täpsemad algmaterjalide mudelite tulemustest ja Hiiu maakonna tulemused olid ühe tulemuse võrra täpsemad.

### **4.5.3 Regioonide alusel klassifitseeritud mudelite tulemuste võrdlus**

Tulemuste seas, kus mudel pakkus esimese piirkonna korrektselt, oli üks regioon, mille puhul olid rohkendatud mudelid täpsemad, ning selleks oli Põhja regioon, ning see regioon oli ainsana täpsem ERM ja MTÜ RR kujutiste seas. Kõikide kujutiste puhul olid Põhja regiooni tulemused 53 tulemuse võrra täpsemad, ERM kujutiste puhul 24 tulemuse võrra täpsemad ja MTÜ RR kujutiste puhul 29 tulemuse võrra täpsemad.

Laiendatud korrektsuse ehk parima kahe pakkumise puhul oli kaks regiooni, mille puhul olid rohkendatud mudelite tulemused täpsemad – Lääne ja Saared. Saarte regiooni puhul oli suurem vahe, rohkendatud mudelid olid kuue tulemuse võrra täpsemad ning Lääne regiooni tulemused olid ühe tulemuse võrra täpsemad.

ERM kujutiste laiendatud korrektsuse puhul olid kahe regiooni rohkendatud mudelite tulemused täpsemad – Lõuna ja Saared. Mõlema regiooni puhul oli rohkendatud mudelid kahe tulemuse võrra täpsemad. MTÜ RR kujutiste laiendatud korrektsuse puhul olid kolme regiooni rohkendatud mudelite tulemused täpsemad – Lääne, Põhja ja Saared. Saarte regiooni puhul oli vahe suurim, rohkendatud mudelid olid nelja tulemuse võrra täpsemad ning Lääne ja Põhja regioonide tulemused on ühe tulemuse võrra täpsemad.

### **4.5.4 Saadud tulemuste analüüs**

Valdade osas oli algmaterjalide mudelite tulemuste võrdlemisel rohkendatud mudelite tulemustega kõige rohkem vahet Pärnu vallas, kus rohkendatud mudelid pakkusid nii täpseima pakkumise, kõikide pakkumiste, kõikide kujutiste, ERM kujutiste ja MTÜ RR kujutiste puhul rohkem korrektseid tulemusi. Kolme kõige rohkem paranenud tulemustega valdade seas olid veel Põhja-Sakala ja Viljandi. Laiendatud korrektsusega tulemuste puhul tuleb mainida Märjamaad, mille puhul tulemused paranesid nii ERM kui ka MTÜ RR kujutiste puhul.

Maakondade osas oli kõige rohkem vahet Pärnu maakonnas, kus rohkendatud mudelid pakkusid nii täpseima pakkumise, kõikide pakkumiste, kõikide kujutiste, ERM kujutiste kui ka MTÜ RR kujutiste puhul rohkem korrektseid tulemusi. Täpseima pakkumise puhul paranesid tulemused veel Rapla ja Saare maakondades ning laiendatud korrektsuse puhul nägid kõige rohkem tulemuste paranemist Hiiu ja Valga maakonnad.

Regioonide osas oli tulemuse paranemine eelnevatest piirkondadest erinev – kui täpseima pakkumise puhul paranesid tulemused ainult Põhja regioonis, nii kõikide, ERM kui MTÜ RR kujutiste puhul, siis laiendatud korrektsuse puhul oli kõikide kujutiste puhul tulemuste paranemist näha Lääne ja Saarte regioonis. ERM kujutiste laiendatud korrektsuse puhul paranesid tulemused Lõuna ja Saarte regioonis ning MTÜ RR kujutiste laiendatud korrektsuse puhul Lääne, Põhja ja Saarte regioonis.

## 4.6 Järeldused

Treenitud mudelid ei osutunud täpseteks üheski piirkonnas, nii algmaterjalide kui ka rohkendatud mudelite puhul. Laiendatud korrektsus aitas mudelite täpsust tõsta märkimisväärselt, kuid ainult regioonide mudelid ületasid sel puhul 50% täpsuse piiri ja sedagi mitte väga võimsalt (52,6% täpsus).

Rohkendatud mudelid ei aidanud täpsust märkimisväärselt, pakkudes suurenenud täpsust vähestes piirkondades (valdade puhul Pärnu ja Põhja-Sakala vallad, maakondade puhul Hiiu ja Pärnu maakonnad ning regioonide puhul Põhja regioon). Siinkohal võib märkida, et kuigi Augmentori abil saadi rohkendatud mudelite abil paremaid tulemusi, siis on näha, et seda ei saa üks-ühele teise konteksti ümber tõsta.

Et saada täpsemaid tulemusi, on tõenäoliselt vaja rohkem algmaterjale, seda mitte ainult arvuliselt, vaid ka klassifikaatorite arvult, sest valdade puhul on hetkel umbes 2/3 valdadest klassifitseeritud. Võib kontakteeruda ERM-iga või MTÜ RR-iga, et kas neil oleks võimalik koguda rohkem süsteemset ja/või masinloetavat materjali.

Lisaks rohkemale algmaterjalile oleks vaja mudelitel suuremat treenimismahtu. Bakalaureuse töö mahus ei ole võimalik pikaajalist treenimist teha, kuid tulevikus saab mudelite treenimismahtu suurendada mitte ainult rohkema algmaterjali arvelt, vaid ka mudeli treenimisel tehtud eksperimentide arvult. Samuti on võimalik võtta eksisteerivad mudelid aluseks ning neid edasi treenida. Treenimisaja lühendamiseks on võimalik kasutada Google Cloud virtuaalmasinat, mis pakub suuremat jõudlust kui koduarvutid.

Üks tuleviku paranduspunkt võib olla algmaterjali täpsem rohkendamine, kohendades rohkendusparameetreid sobivamaks ning leides parameetrid ja nende väärtused, mis pakuvad täpsemat tuvastust. Augmentor oli algselt mõeldud biomeditsiiniliste kujutiste rohkendamiseks, seega vajavad rahvarõivaste kujutised rohkem kohendamist.

## 5 Kokkuvõte

Käesolevas töös uuriti tehisneurovõrkude treenimist vähese sisendmaterjali korral Eesti rahvarõivaste mustrite klassifitseerimise näitel.

Kõigepealt kirjeldati töö tehnilist tausta, nimelt mudelite treenimise ja algmaterjalide rohkendamise tarkvarasid ja nende tööpõhimõtteid. Järgnevalt seati üles treenimiskeskond, klassifitseeriti ja rohkendati algmaterjalid ning treeniti mudelid nii algmaterjalide kui ka rohkendatud materjalide baasil. Seejärel testiti mudelite täpsust erinevate testkujutiste tuvastamisel, arvestades nii täpseimat pakkumist kui ka laiendatud korrektsust. Lõpuks võrreldi saadud tulemusi algmaterjalide mudelite ja rohkendatud mudelite vahel, et leida, kui palju mõjutas mudelite täpsust algmaterjalide rohkendamine.

Tulemused ei osutunud täpseks üheski piirkonnas, kuid laiendatud korrektsus tõstis mudelite täpsust märkimisväärselt. Seda aga ei suutnud rohkendatud mudelid, mille tulemuste alusel oli täpsuse suurenemist näha ainult vähestes piirkondades.

Lõpetuseks tuleb öelda, et kuigi mudelid ei olnud täpsed ja algmaterjali rohkendamine ei mõjutanud mudelite täpsust suures osas, on leitud informatsioonis potentsiaali edasiarenduseks. Tööga jätkamisel on soovituslik leida rohkem algmaterjali, kaasa arvatud hetkel puuduliku materjaliga piirkondades, ning siin võib abi otsida Eesti Rahva Muuseumilt või MTÜ Rahvarõivalt. Samuti on võimalik treenimismahtu suurendada mudelite rohkema treenimisega, mille aluseks saab võtta töö käigus loodud mudelid. Viimaseks tuleks Augmentori rohkendusparameetrid üle vaadata ning kohendada neid rahvarõivastele sobivamaks.

## Kasutatud kirjandus

- [1] M. Olafenwa, J. Olafenwa, "ImageAI, an open source python library built to empower developers to build applications and systems with self-contained Computer Vision capabilities," GitHub, Märts 2018---. [Võrgumaterjal]. Saadaval: <https://github.com/OlafenwaMoses/ImageAI>
- [2] M. Olafenwa, J. Olafenwa, "Official English Documentation for ImageAI!" ReadTheDocs. [Võrgumaterjal]. Saadaval: <https://imageai.readthedocs.io/en/latest/index.html>
- [3] J. Rodriguez. "The Evolution of Google's MobileNet Architectures to Improve Computer Vision Models," Medium, 16 Veebruar 2021. [Võrgumaterjal]. Saadaval: <https://medium.com/dataseries/the-evolution-of-googles-mobilenet-architectures-to-improve-computer-vision-models-ffb483ffcc0a>
- [4] K. He, X. Zhang, S. Ren and J. Sun, "Deep Residual Learning for Image Recognition," 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016, pp. 770-778, doi: 10.1109/CVPR.2016.90.
- [5] C. Szegedy et al., "Going deeper with convolutions," 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, USA, 2015, pp. 1-9, doi: 10.1109/CVPR.2015.7298594.
- [6] G. Huang, Z. Liu, L. Van Der Maaten and K. Q. Weinberger, "Densely Connected Convolutional Networks," 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 2017, pp. 2261-2269, doi: 10.1109/CVPR.2017.243.a
- [7] M. D. Bloice, C. Stocker, and A. Holzinger, "Augmentor: An Image Augmentation Library for Machine Learning," *The Journal of Open Source Software*, vol. 2, no. 19, p. 432, 2017.
- [8] M. D. Bloice, C. Stocker, A. Holzinger, "Augmentor: An Image Augmentation Library for Machine Learning," GitHub, Juuni 2017---. [Võrgumaterjal]. Saadaval: <https://github.com/mbloice/Augmentor>
- [9] M. D. Bloice, "Main Features -- Augmentor 0.2.6 documentation," ReadTheDocs, 2016---. [Võrgumaterjal]. Saadaval: <https://augmentor.readthedocs.io/en/master/userguide/mainfeatures.html>
- [10] "CUDA Zone | Nvidia Developer," Nvidia, n.d. [Võrgumaterjal]. Saadaval: <https://developer.nvidia.com/cuda-zone> [Kasutatud 25. aprill 2021]
- [11] "Haldus- ja asustusjaotus," Maaamet, Aprill 2021. [Võrgumaterjal]. Saadaval: <https://geoportaal.maaamet.ee/est/Ruumiandmed/Haldus-ja-asustusjaotus-p119.html> [Kasutatud 4. aprill 2021]



## **Lisa 1 – Lihtlitsents lõputöö reprodutseerimiseks ja lõputöö üldsusele kättesaadavaks tegemiseks<sup>1</sup>**

Mina, Henri Tõnts,

1. Annan Tallinna Tehnikaülikoolile tasuta loa (lihtlitsentsi) enda loodud teose „Tehisneurovõrgu treenimine vähese sisendmaterjali korral Eesti rahvariiete mustrite klassifitseerimise näitel“, mille juhendaja on Sten Mäses,
  - 1.1. reprodutseerimiseks lõputöö säilitamise ja elektroonse avaldamise eesmärgil, sh Tallinna Tehnikaülikooli raamatukogu digikogusse lisamise eesmärgil kuni autoriõiguse kehtivuse tähtaja lõppemiseni;
  - 1.2. üldsusele kättesaadavaks tegemiseks Tallinna Tehnikaülikooli veebikeskkonna kaudu, sealhulgas Tallinna Tehnikaülikooli raamatukogu digikogu kaudu kuni autoriõiguse kehtivuse tähtaja lõppemiseni.
2. Olen teadlik, et käesoleva lihtlitsentsi punktis 1 nimetatud õigused jäävad alles ka autorile.
3. Kinnitan, et lihtlitsentsi andmisega ei rikuta teiste isikute intellektuaalomandi ega isikuandmete kaitse seadusest ning muudest õigusaktidest tulenevaid õigusi.

18.05.2021

---

<sup>1</sup> Lihtlitsents ei kehti juurdepääsupiirangu kehtivuse ajal vastavalt üliõpilase taotlusele lõputööle juurdepääsupiirangu kehtestamiseks, mis on allkirjastatud teaduskonna dekaani poolt, välja arvatud ülikooli õigus lõputööd reprodutseerida üksnes säilitamise eesmärgil. Kui lõputöö on loonud kaks või enam isikut oma ühise loomingu tegevusega ning lõputöö kaas- või ühisautor(id) ei ole andnud lõputööd kaitsvale üliõpilasele kindlaksmääratud tähtjaks nõusolekut lõputöö reprodutseerimiseks ja avalikustamiseks vastavalt lihtlitsentsi punktidele 1.1. ja 1.2, siis lihtlitsents nimetatud tähtaja jooksul ei kehti.

## Lisa 2 – Mudelite testimise tulemustest koostatud tabelid

Legend tabelite jaoks: I = Mudel pakkus kujutise esimese korrektse pakkumisega, II = Mudel pakkus kujutise teise korrektse pakkumisega ja nii edasi. Ebatäpne = Mudel ei pakkunud kujutise piirkonda korrektselt. Korrektseid tulemusi = Mudeli poolt pakutud korrektsete tulemuste summa.

Vallad	I	II	III	IV	Ebatäpne	Korrektseid tulemusi
Alutaguse	0	0	0	0	24	0
Hiiu	0	1	0	1	22	2
Jõelähtme	0	0	0	0	24	0
Jõgeva	0	0	1	0	23	1
Kadrina	2	0	0	0	22	2
Lääne-Nigula	4	1	0	0	7	5
Lääneranna	2	5	0	0	17	7
Lüganuse	0	0	0	1	23	1
Mustvee	0	2	0	1	21	3
Märjamaa	0	0	2	0	22	2
Paide	0	0	0	0	24	0
Pärnu	3	0	0	4	17	7
Põhja-Sakala	2	7	0	1	14	10
Rakvere	0	0	0	0	24	0
Rapla	0	0	0	2	22	2
Saaremaa	4	1	2	1	16	8
Saue	0	2	0	4	18	6
Tartu	0	0	0	0	12	0
Tõrva	0	0	0	0	24	0
Türi	0	0	0	0	24	0
Valga	0	0	0	0	24	0
Viljandi	3	0	0	0	21	3
<b>Pakkumise kohta:</b>	20	19	5	15	445	

Lisa tabel 1. Kõik valdade tulemused.

Vallad	I	II	III	IV	Ebatäpne	Korrektseid tulemusi
Alutaguse	0	0	0	0	12	0
Hiiu	0	0	0	0	12	0
Jõelähtme	0	0	0	0	12	0
Jõgeva	0	0	0	0	12	0
Kadrina	1	0	0	0	11	1
Lääne-Nigula	0	0	0	0	0	0
Lääneranna	1	2	0	0	9	3
Lüganuse	0	0	0	1	11	1
Mustvee	0	1	0	1	10	2
Märjamaa	0	0	1	0	11	1
Paide	0	0	0	0	12	0
Pärnu	2	0	0	3	7	5
Põhja-Sakala	1	2	0	0	9	3
Rakvere	0	0	0	0	12	0
Rapla	0	0	0	2	10	2
Saaremaa	3	0	1	1	7	5
Saue	0	1	0	2	9	3
Tartu	0	0	0	0	12	0
Tõrva	0	0	0	0	12	0
Türi	0	0	0	0	12	0
Valga	0	0	0	0	12	0
Viljandi	1	0	0	0	11	1
<b>Pakkumise kohta:</b>	9	6	2	10	225	

Lisa tabel 2. ERM kujutiste valdade tulemused.

Vallad	I	II	III	IV	Ebatäpne	Korrektseid tulemusi
Alutaguse	0	0	0	0	12	0
Hiiu	0	1	0	1	10	2
Jõelähtme	0	0	0	0	12	0
Jõgeva	0	0	1	0	11	1
Kadrina	1	0	0	0	11	1
Lääne-Nigula	4	1	0	0	7	5
Lääneranna	1	3	0	0	8	4
Lüganuse	0	0	0	0	12	0
Mustvee	0	1	0	0	11	1
Märjamaa	0	0	1	0	11	1
Paide	0	0	0	0	12	0
Pärnu	1	0	0	1	10	2
Põhja-Sakala	1	5	0	1	5	7
Rakvere	0	0	0	0	12	0
Rapla	0	0	0	0	12	0
Saaremaa	1	1	1	0	9	3
Saue	0	1	0	2	9	3
Tartu	0	0	0	0	0	0
Tõrva	0	0	0	0	12	0
Türi	0	0	0	0	12	0
Valga	0	0	0	0	12	0
Viljandi	2	0	0	0	10	2
<b>Pakkumise kohta:</b>	11	13	3	5	220	

Lisa tabel 3. MTÜ RR kujutiste valdade tulemused.

Vallad	I	II	III	IV	Ebatäpne	Korrektseid tulemusi
Alutaguse	0	0	0	0	12	0
Hiiu	0	0	0	1	11	1
Jõelähtme	0	0	0	0	12	0
Jõgeva	0	0	0	0	12	0
Kadrina	2	0	0	0	10	2
Lääne-Nigula	2	1	0	0	3	3
Lääneranna	1	3	0	0	8	4
Lüganuse	0	0	0	1	11	1
Mustvee	0	2	0	0	10	2
Märjamaa	0	0	0	0	12	0
Paide	0	0	0	0	12	0
Pärnu	0	0	0	0	12	0
Põhja-Sakala	0	4	0	1	7	5
Rakvere	0	0	0	0	12	0
Rapla	0	0	0	1	11	1
Saaremaa	2	1	0	1	8	4
Saue	0	2	0	2	8	4
Tartu	0	0	0	0	6	0
Tõrva	0	0	0	0	12	0
Türi	0	0	0	0	12	0
Valga	0	0	0	0	12	0
Viljandi	1	0	0	0	11	1
<b>Pakkumise kohta:</b>	8	13	0	7	224	

Lisa tabel 4. Kõik valdade tulemused algmaterjalide mudelite osas.

Vallad	I	II	III	IV	Ebatäpne	Korrektseid tulemusi
Alutaguse	0	0	0	0	6	0
Hiiu	0	0	0	0	6	0
Jõelähtme	0	0	0	0	6	0
Jõgeva	0	0	0	0	6	0
Kadrina	1	0	0	0	5	1
Lääne-Nigula	0	0	0	0	0	0
Lääneranna	1	1	0	0	4	2
Lüganuse	0	0	0	1	5	1
Mustvee	0	1	0	0	5	1
Märjamaa	0	0	0	0	6	0
Paide	0	0	0	0	6	0
Pärnu	0	0	0	0	6	0
Põhja-Sakala	0	2	0	0	4	2
Rakvere	0	0	0	0	6	0
Rapla	0	0	0	1	5	1
Saaremaa	2	0	0	1	3	3
Saue	0	1	0	1	4	2
Tartu	0	0	0	0	6	0
Tõrva	0	0	0	0	6	0
Türi	0	0	0	0	6	0
Valga	0	0	0	0	6	0
Viljandi	0	0	0	0	6	0
<b>Pakkumise kohta:</b>	4	5	0	4	113	

Lisa tabel 5. ERM kujutiste valdade tulemused algmaterjalide mudelite osas.

Vallad	I	II	III	IV	Ebatäpne	Korrektseid tulemusi
Alutaguse	0	0	0	0	6	0
Hiiu	0	0	0	1	5	1
Jõelähtme	0	0	0	0	6	0
Jõgeva	0	0	0	0	6	0
Kadrina	1	0	0	0	5	1
Lääne-Nigula	2	1	0	0	3	3
Lääneranna	0	2	0	0	4	2
Lüganuse	0	0	0	0	6	0
Mustvee	0	1	0	0	5	1
Märjamaa	0	0	0	0	6	0
Paide	0	0	0	0	6	0
Pärnu	0	0	0	0	6	0
Põhja-Sakala	0	2	0	1	3	3
Rakvere	0	0	0	0	6	0
Rapla	0	0	0	0	6	0
Saaremaa	0	1	0	0	5	1
Saue	0	1	0	1	4	2
Tartu	0	0	0	0	0	0
Tõrva	0	0	0	0	6	0
Türi	0	0	0	0	6	0
Valga	0	0	0	0	6	0
Viljandi	1	0	0	0	5	1
<b>Pakkumise kohta:</b>	4	8	0	3	111	

Lisa tabel 6. MTÜ RR kujutiste valdade tulemused algmaterjalide mudelite osas.

Vallad	I	II	III	IV	Ebatäpne	Korrektseid tulemusi
Alutaguse	0	0	0	0	12	0
Hiiu	0	1	0	0	11	1
Jõelähtme	0	0	0	0	12	0
Jõgeva	0	0	1	0	11	1
Kadrina	0	0	0	0	12	0
Lääne-Nigula	2	0	0	0	4	2
Lääneranna	1	2	0	0	9	3
Lüganuse	0	0	0	0	12	0
Mustvee	0	0	0	1	11	1
Märjamaa	0	0	2	0	10	2
Paide	0	0	0	0	12	0
Pärnu	3	0	0	4	5	7
Põhja-Sakala	2	3	0	0	7	5
Rakvere	0	0	0	0	12	0
Rapla	0	0	0	1	11	1
Saaremaa	2	0	2	0	8	4
Saue	0	0	0	2	10	2
Tartu	0	0	0	0	6	0
Tõrva	0	0	0	0	12	0
Türi	0	0	0	0	12	0
Valga	0	0	0	0	12	0
Viljandi	2	0	0	0	10	2
<b>Pakkumise kohta:</b>	12	6	5	8	221	

Lisa tabel 7. Kõik valdade tulemused rohkendatud mudelite osas.



Vallad	I	II	III	IV	Ebatäpne	Korrektseid tulemusi
Alutaguse	0	0	0	0	6	0
Hiiu	0	0	0	0	6	0
Jõelähtme	0	0	0	0	6	0
Jõgeva	0	0	0	0	6	0
Kadrina	0	0	0	0	6	0
Lääne-Nigula	0	0	0	0	0	0
Lääneranna	0	1	0	0	5	1
Lüganuse	0	0	0	0	6	0
Mustvee	0	0	0	1	5	1
Märjamaa	0	0	1	0	5	1
Paide	0	0	0	0	6	0
Pärnu	2	0	0	3	1	5
Põhja-Sakala	1	0	0	0	5	1
Rakvere	0	0	0	0	6	0
Rapla	0	0	0	1	5	1
Saaremaa	1	0	1	0	4	2
Saue	0	0	0	1	5	1
Tartu	0	0	0	0	6	0
Tõrva	0	0	0	0	6	0
Türi	0	0	0	0	6	0
Valga	0	0	0	0	6	0
Viljandi	1	0	0	0	5	1
<b>Pakkumise kohta:</b>	5	1	2	6	112	

Lisa tabel 8. ERM kujutiste valdade rohkendatud mudelite tulemused rohkendatud mudelite osas.

Vallad	I	II	III	IV	Ebatäpne	Korrektseid tulemusi
Alutaguse	0	0	0	0	6	0
Hiiu	0	1	0	0	5	1
Jõelähtme	0	0	0	0	6	0
Jõgeva	0	0	1	0	5	1
Kadrina	0	0	0	0	6	0
Lääne-Nigula	2	0	0	0	4	2
Lääneranna	1	1	0	0	4	2
Lüganuse	0	0	0	0	6	0
Mustvee	0	0	0	0	6	0
Märjamaa	0	0	1	0	5	1
Paide	0	0	0	0	6	0
Pärnu	1	0	0	1	4	2
Põhja-Sakala	1	3	0	0	2	4
Rakvere	0	0	0	0	6	0
Rapla	0	0	0	0	6	0
Saaremaa	1	0	1	0	4	2
Saue	0	0	0	1	5	1
Tartu	0	0	0	0	0	0
Tõrva	0	0	0	0	6	0
Türi	0	0	0	0	6	0
Valga	0	0	0	0	6	0
Viljandi	1	0	0	0	5	1
<b>Pakkumise kohta:</b>	7	5	3	2	109	

Lisa tabel 9. MTÜ RR kujutiste valdade tulemused rohkendatud mudelite osas.

Maakonnad	I	II	III	IV	Ebatäpne pakkumine	Korrektseid tulemusi
Harju	9	4	5	3	27	21
Hiiu	1	0	1	1	21	3
Ida-Viru	0	0	0	4	44	4
Järva	0	0	2	1	45	3
Jõgeva	0	0	3	4	41	7
Lääne	1	0	2	0	9	3
Lääne-Viru	0	0	0	2	46	2
Pärnu	6	2	8	13	19	29
Rapla	4	9	10	1	24	24
Saare	2	4	0	1	17	7
Tartu	2	0	0	2	8	4
Valga	2	0	7	8	31	17
Viljandi	4	9	11	5	19	29
<b>Pakkumise kohta:</b>	31	28	49	45	351	

Lisa tabel 10. Kõikide kujutiste maakondade tulemused.

Maakonnad	I	II	III	IV	Ebatäpne pakkumine	Korrektseid tulemusi
Harju	5	1	3	2	13	11
Hiiu	0	0	1	1	10	2
Ida-Viru	0	0	-3	4	23	1
Järva	0	0	1	1	22	2
Jõgeva	0	0	2	2	20	4
Lääne	0	0	0	0	0	0
Lääne-Viru	0	0	0	1	23	1
Pärnu	2	2	3	8	9	15
Rapla	2	6	4	0	12	12
Saare	1	2	0	0	9	3
Tartu	2	0	0	2	8	4
Valga	2	0	3	4	15	9
Viljandi	2	4	6	3	9	15
<b>Pakkumise kohta:</b>	16	15	20	28	173	

Lisa tabel 11. ERM kujutiste maakondade tulemused.

Maakonnad	I	II	III	IV	Ebatäpne pakkumine	Korrektseid tulemusi
Harju	4	3	2	1	14	10
Hiiu	1	0	0	0	11	1
Ida-Viru	0	0	3	0	21	3
Järva	0	0	1	0	23	1
Jõgeva	0	0	1	2	21	3
Lääne	1	0	2	0	9	3
Lääne-Viru	0	0	0	1	23	1
Pärnu	4	0	5	5	10	14
Rapla	2	3	6	1	12	12
Saare	1	2	0	1	8	4
Tartu	0	0	0	0	0	0
Valga	0	0	4	4	16	8
Viljandi	2	5	5	2	10	14
<b>Pakkumise kohta:</b>	15	13	29	17	178	

Lisa tabel 12. MTÜ RR kujutiste maakondade tulemused.

Maakonnad	I	II	III	IV	Ebatäpne pakkumine	Korrektseid tulemusi
Harju	4	4	2	1	13	11
Hiiu	0	0	0	0	12	0
Ida-Viru	0	0	0	4	20	4
Järva	0	0	2	1	21	3
Jõgeva	0	0	0	4	20	4
Lääne	1	0	2	0	3	3
Lääne-Viru	0	0	0	1	23	1
Pärnu	0	0	3	10	11	13
Rapla	0	4	8	0	12	12
Saare	0	4	0	1	7	5
Tartu	1	0	0	1	4	2
Valga	1	0	2	3	18	6
Viljandi	4	4	7	1	8	16
<b>Pakkumise kohta:</b>	11	16	26	27	172	

Lisa tabel 13. Kõikide kujutiste maakondade tulemused algmaterjalide mudelite osas.

Maakonnad	I	II	III	IV	Ebatäpne pakkumine	Korrektseid tulemusi
Harju	3	1	1	1	6	6
Hiiu	0	0	0	0	6	0
Ida-Viru	0	0	0	1	11	1
Järva	0	0	1	1	10	2
Jõgeva	0	0	0	2	10	2
Lääne	0	0	0	0	0	0
Lääne-Viru	0	0	0	0	12	0
Pärnu	0	0	1	6	5	7
Rapla	0	2	4	0	6	6
Saare	0	2	0	0	4	2
Tartu	1	0	0	1	4	2
Valga	1	0	0	2	9	3
Viljandi	2	2	4	0	4	8
<b>Pakkumise kohta:</b>	7	7	11	14	87	

Lisa tabel 14. ERM kujutiste maakondade tulemused algmaterjalide mudelite osas.

Maakonnad	I	II	III	IV	Ebatäpne pakkumine	Korrektseid tulemusi
Harju	1	3	1	0	7	5
Hiiu	0	0	0	0	6	0
Ida-Viru	0	0	0	3	9	3
Järva	0	0	1	0	11	1
Jõgeva	0	0	0	2	10	2
Lääne	1	0	2	0	3	3
Lääne-Viru	0	0	0	1	11	1
Pärnu	0	0	2	4	6	6
Rapla	0	2	4	0	6	6
Saare	0	2	0	1	3	3
Tartu	0	0	0	0	0	0
Valga	0	0	2	1	9	3
Viljandi	2	2	3	1	4	8
<b>Pakkumise kohta:</b>	4	9	15	13	85	

Lisa tabel 15. MTÜ RR kujutiste maakondade tulemused algmaterjalide mudelite osas.

Maakonnad	I	II	III	IV	Ebatäpne pakkumine	Korrektseid tulemusi
Harju	5	0	3	2	14	10
Hiiu	1	0	1	1	9	3
Ida-Viru	0	0	0	0	24	0
Järva	0	0	0	0	24	0
Jõgeva	0	0	3	0	21	3
Lääne	0	0	0	0	6	0
Lääne-Viru	0	0	0	1	23	1
Pärnu	6	2	5	3	8	16
Rapla	4	5	2	1	12	12
Saare	2	0	0	0	10	2
Tartu	1	0	0	1	4	2
Valga	1	0	5	5	13	11
Viljandi	0	5	4	4	11	13
<b>Pakkumise kohta:</b>	20	12	23	18	179	

Lisa tabel 16. Kõikide kujutiste maakondade tulemused rohkendatud mudelite osas.

Maakonnad	I	II	III	IV	Ebatäpne pakkumine	Korrektseid tulemusi
Harju	2	0	2	1	7	5
Hiiu	0	0	1	1	4	2
Ida-Viru	0	0	-3	3	12	0
Järva	0	0	0	0	12	0
Jõgeva	0	0	2	0	10	2
Lääne	0	0	0	0	0	0
Lääne-Viru	0	0	0	1	11	1
Pärnu	2	2	2	2	4	8
Rapla	2	4	0	0	6	6
Saare	1	0	0	0	5	1
Tartu	1	0	0	1	4	2
Valga	1	0	3	2	6	6
Viljandi	0	2	2	3	5	7
<b>Pakkumise kohta:</b>	9	8	9	14	86	

Lisa tabel 17. ERM kujutiste maakondade tulemused rohkendatud mudelite osas.

Maakonnad	I	II	III	IV	Ebatäpne pakkumine	Korrektseid tulemusi
Harju	3	0	1	1	7	5
Hiiu	1	0	0	0	5	1
Ida-Viru	0	0	3	-3	12	0
Järva	0	0	0	0	12	0
Jõgeva	0	0	1	0	11	1
Lääne	0	0	0	0	6	0
Lääne-Viru	0	0	0	0	12	0
Pärnu	4	0	3	1	4	8
Rapla	2	1	2	1	6	6
Saare	1	0	0	0	5	1
Tartu	0	0	0	0	0	0
Valga	0	0	2	3	7	5
Viljandi	0	3	2	1	6	6
<b>Pakkumise kohta:</b>	11	4	14	4	93	

Lisa tabel 18. MTÜ RR kujutiste maakondade tulemused rohkendatud mudelite osas.

Regioonid	I	II	III	IV	Korrektseid tulemusi
Lõuna	16	32	67	53	48
Lääne	20	7	7	26	27
Põhja	65	89	49	25	154
Saared	18	18	8	4	36
<b>Pakkumise kohta:</b>	119	146	131	108	

Lisa tabel 19. Kõikide kujutiste regioonide tulemused.

Regioonid	I	II	III	IV	Korrektseid tulemusi
Lõuna	10	20	39	27	30
Lääne	9	3	2	10	12
Põhja	26	47	17	18	73
Saared	8	10	4	2	18
<b>Pakkumise kohta:</b>	53	80	62	57	

Lisa tabel 20. ERM kujutiste regioonide tulemused.

Regioonid	I	II	III	IV	Korrektseid tulemusi
Lõuna	6	12	28	26	18
Lääne	11	4	5	16	15
Põhja	39	42	32	7	81
Saared	10	8	4	2	18
<b>Pakkumise kohta:</b>	66	66	69	51	

Lisa tabel 21. MTÜ RR kujutiste regioonide tulemused.

Regioonid	I	II	III	IV	Korrektseid tulemusi
Lõuna	13	13	26	26	26
Lääne	11	2	6	11	13
Põhja	6	73	30	11	79
Saared	11	4	5	4	15
<b>Pakkumise kohta:</b>	41	92	67	52	

Lisa tabel 22. Kõikide kujutiste maakondade tulemused algmaterjalide mudelite osas.



Regioonid	I	II	III	IV	Korrektseid tulemusi
Lõuna	7	7	14	14	14
Lääne	5	1	2	4	6
Põhja	1	38	13	8	39
Saared	6	2	2	2	8
<b>Pakkumise kohta:</b>	19	48	31	28	

Lisa tabel 23. ERM kujutiste maakondade tulemused algmaterjalide mudelite osas.

Regioonid	I	II	III	IV	Korrektseid tulemusi
Lõuna	6	6	12	12	12
Lääne	6	1	4	7	7
Põhja	5	35	17	3	40
Saared	5	2	3	2	7
<b>Pakkumise kohta:</b>	22	44	36	24	

Lisa tabel 24. MTÜ RR kujutiste maakondade tulemused algmaterjalide mudelite osas.

Regioonid	I	II	III	IV	Korrektseid tulemusi
Lõuna	3	19	41	27	22
Lääne	9	5	1	15	14
Põhja	59	16	19	14	75
Saared	7	14	3	0	21
<b>Pakkumise kohta:</b>	78	54	64	56	

Lisa tabel 25. Kõikide kujutiste maakondade tulemused rohkendatud mudelite osas.

Regioonid	I	II	III	IV	Korrektseid tulemusi
Lõuna	3	13	25	13	16
Lääne	4	2	0	6	6
Põhja	25	9	4	10	34
Saared	2	8	2	0	10
<b>Pakkumise kohta:</b>	34	32	31	29	

Lisa tabel 26. ERM kujutiste maakondade tulemused rohkendatud mudelite osas.

Regioonid	I	II	III	IV	Korrektseid tulemusi
Lõuna	0	6	16	14	6
Lääne	5	3	1	9	8
Põhja	34	7	15	4	41
Saared	5	6	1	0	11
<b>Pakkumise kohta:</b>	44	22	33	27	

Lisa tabel 27. MTÜ RR kujutiste maakondade tulemused rohkendatud mudelite osas.

Vallad	I	II	III	IV	Ebat äpne	Korrektseid tulemusi	Laiendatud	Laiendatud tulemused
Alutaguse	EI	EI	EI	EI	EI	0	EI	0
Hiiu	EI	JAH	EI	EI	EI	0	EI	0
Jõelähtme	EI	EI	EI	EI	EI	0	EI	0
Jõgeva	EI	EI	JAH	EI	JAH	0	JAH	1
Kadrina	EI	EI	EI	EI	EI	-2	EI	-2
Lääne-Nigula	EI	EI	EI	EI	EI	0	EI	-1
Lääneranna	EI	EI	EI	EI	EI	0	EI	-1
Lüganuse	EI	EI	EI	EI	EI	0	EI	-1
Mustvee	EI	EI	EI	JAH	EI	0	EI	-1
Märjamaa	EI	EI	JAH	EI	JAH	0	JAH	2
Paide	EI	EI	EI	EI	EI	0	EI	0
Pärnu	JAH	EI	EI	JAH	JAH	3	JAH	7
Põhja-Sakala	JAH	EI	EI	EI	EI	2	EI	0
Rakvere	EI	EI	EI	EI	EI	0	EI	0
Rapla	EI	EI	EI	EI	EI	0	EI	0
Saaremaa	EI	EI	JAH	EI	EI	0	EI	0
Saue	EI	EI	EI	EI	EI	0	EI	-2
Tartu	EI	EI	EI	EI	EI	0	EI	0
Tõrva	EI	EI	EI	EI	EI	0	EI	0
Türi	EI	EI	EI	EI	EI	0	EI	0
Valga	EI	EI	EI	EI	EI	0	EI	0
Viljandi	JAH	EI	EI	EI	JAH	1	JAH	1
<b>Pakkumise kohta:</b>	3	1	3	2	4			

Lisa tabel 28. Kõikide kujutiste valdade tulemused - kas rohkendatud materjalidel treenitud mudelid olid täpsemad kui algmaterjalidel treenitud mudelid?

Maakonnad	I	II	III	IV	Ebatäpne pakkumine	Korrektseid tulemusi	Laiendatud	Laiendatud tulemused
Harju	JAH	EI	JAH	JAH	EI	1	EI	-1
Hiiu	JAH	EI	JAH	JAH	JAH	1	JAH	3
Ida-Viru	EI	EI	EI	EI	EI	0	EI	-4
Järva	EI	EI	EI	EI	EI	0	EI	-3
Jõgeva	EI	EI	JAH	EI	EI	0	EI	-1
Lääne	EI	EI	EI	EI	EI	-1	EI	-3
Lääne-Viru	EI	EI	EI	EI	EI	0	EI	0
Pärnu	JAH	JAH	JAH	EI	JAH	6	JAH	3
Rapla	JAH	JAH	EI	JAH	EI	4	EI	0
Saare	JAH	EI	EI	EI	EI	2	EI	-3
Tartu	EI	EI	EI	EI	EI	0	EI	0
Valga	EI	EI	JAH	JAH	JAH	0	JAH	5
Viljandi	EI	JAH	EI	JAH	EI	-4	EI	-3
<b>Pakkumise kohta:</b>	5	3	5	5	3			

Lisa tabel 29. Kõikide kujutiste maakondade tulemused - kas rohkendatud materjalidel treenitud mudelid olid täpsemad kui algmaterjalidel treenitud mudelid?

Regioonid	I	II	III	IV	Korrektseid tulemusi	Laiendatud	Laiendatud tulemused
Lõuna	EI	JAH	JAH	JAH	-10	EI	EI
Lääne	EI	JAH	EI	JAH	-2	JAH	EI
Põhja	JAH	EI	EI	JAH	53	EI	JAH
Saared	EI	JAH	EI	EI	-4	JAH	EI
<b>Pakkumise kohta:</b>	1	3	1	3			

Lisa tabel 30. Kõikide kujutiste regioonide tulemused - kas rohkendatud materjalidel treenitud mudelid olid täpsemad kui algmaterjalidel treenitud mudelid?

Vallad	I	II	III	IV	Ebatäpne	Korrektseid tulemusi	Laiendatud	Laiendatud tulemused
Alutaguse	EI	EI	EI	EI	EI	0	EI	0
Hiiu	EI	EI	EI	EI	EI	0	EI	0
Jõelähtme	EI	EI	EI	EI	EI	0	EI	0
Jõgeva	EI	EI	EI	EI	EI	0	EI	0
Kadrina	EI	EI	EI	EI	EI	-1	EI	-1
Lääne-Nigula	EI	EI	EI	EI	EI	0	EI	0
Lääneranna	EI	EI	EI	EI	EI	-1	EI	-1
Lüganuse	EI	EI	EI	EI	EI	0	EI	-1
Mustvee	EI	EI	EI	JAH	EI	0	EI	0
Märjamaa	EI	EI	JAH	EI	JAH	0	JAH	1
Paide	EI	EI	EI	EI	EI	0	EI	0
Pärnu	JAH	EI	EI	JAH	JAH	2	JAH	5
Põhja-Sakala	JAH	EI	EI	EI	EI	1	EI	-1
Rakvere	EI	EI	EI	EI	EI	0	EI	0
Rapla	EI	EI	EI	EI	EI	0	EI	0
Saaremaa	EI	EI	JAH	EI	EI	-1	EI	-1
Saue	EI	EI	EI	EI	EI	0	EI	-1
Tartu	EI	EI	EI	EI	EI	0	EI	0
Tõrva	EI	EI	EI	EI	EI	0	EI	0
Türi	EI	EI	EI	EI	EI	0	EI	0
Valga	EI	EI	EI	EI	EI	0	EI	0
Viljandi	JAH	EI	EI	EI	JAH	1	JAH	1
<b>Pakkumise kohta:</b>	3	0	2	2	3			

Lisa tabel 31. ERM kujutiste valdade tulemused - kas rohkendatud materjalidel treenitud mudelid olid täpsemad kui algmaterjalidel treenitud mudelid?

Maakonnad	I	II	III	IV	Ebatäpne pakkumine	Korrektseid tulemusi	Laiendatud	Laiendatud tulemused
Harju	EI	EI	JAH	EI	EI	-1	EI	-1
Hiiu	EI	EI	JAH	JAH	JAH	0	JAH	2
Ida-Viru	EI	EI	EI	JAH	EI	0	EI	-1
Järva	EI	EI	EI	EI	EI	0	EI	-2
Jõgeva	EI	EI	JAH	EI	EI	0	EI	0
Lääne	EI	EI	EI	EI	EI	0	EI	0
Lääne-Viru	EI	EI	EI	JAH	JAH	0	JAH	1
Pärnu	JAH	JAH	JAH	EI	JAH	2	JAH	1
Rapla	JAH	JAH	EI	EI	EI	2	EI	0
Saare	JAH	EI	EI	EI	EI	1	EI	-1
Tartu	EI	EI	EI	EI	EI	0	EI	0
Valga	EI	EI	JAH	EI	JAH	0	JAH	3
Viljandi	EI	EI	EI	JAH	EI	-2	EI	-1
<b>Pakkumise kohta:</b>	EI	EI	JAH	EI	EI			

Lisa tabel 32. ERM kujutiste maakondade tulemused - kas rohkendatud materjalidel treenitud mudelid olid täpsemad kui algmaterjalidel treenitud mudelid?

Regioonid	I	II	III	IV	Korrektseid tulemusi	Laiendatud	Laiendatud tulemused
Lõuna	EI	JAH	JAH	EI	-4	JAH	2
Lääne	EI	JAH	EI	JAH	-1	EI	0
Põhja	JAH	EI	EI	JAH	24	EI	-5
Saared	EI	JAH	EI	EI	-4	JAH	2
<b>Pakkumise kohta:</b>	1	3	1	2			

Lisa tabel 33. ERM kujutiste regioonide tulemused - kas rohkendatud materjalidel treenitud mudelid olid täpsemad kui algmaterjalidel treenitud mudelid?

Vallad	I	II	III	IV	Ebatäpne	Korrektseid tulemusi	Laiendatud	Laiendatud tulemused
Alutaguse	EI	EI	EI	EI	EI	0	EI	0
Hiiu	EI	JAH	EI	EI	EI	0	EI	0
Jõelähtme	EI	EI	EI	EI	EI	0	EI	0
Jõgeva	EI	EI	JAH	EI	JAH	0	JAH	1
Kadrina	EI	EI	EI	EI	EI	-1	EI	-1
Lääne-Nigula	EI	EI	EI	EI	EI	0	EI	-1
Lääneranna	JAH	EI	EI	EI	EI	1	EI	0
Lüganuse	EI	EI	EI	EI	EI	0	EI	0
Mustvee	EI	EI	EI	EI	EI	0	EI	-1
Märjamaa	EI	EI	JAH	EI	JAH	0	JAH	1
Paide	EI	EI	EI	EI	EI	0	EI	0
Pärnu	JAH	EI	EI	JAH	JAH	1	JAH	2
Põhja-Sakala	JAH	JAH	EI	EI	JAH	1	JAH	1
Rakvere	EI	EI	EI	EI	EI	0	EI	0
Rapla	EI	EI	EI	EI	EI	0	EI	0
Saaremaa	JAH	EI	JAH	EI	JAH	1	JAH	1
Saue	EI	EI	EI	EI	EI	0	EI	-1
Tartu	EI	EI	EI	EI	EI	0	EI	0
Tõrva	EI	EI	EI	EI	EI	0	EI	0
Türi	EI	EI	EI	EI	EI	0	EI	0
Valga	EI	EI	EI	EI	EI	0	EI	0
Viljandi	EI	EI	EI	EI	EI	0	EI	0
<b>Pakkumise kohta:</b>	4	2	3	1	5			

Lisa tabel 34. MTÜ RR kujutiste valdade tulemused - kas rohkendatud materjalidel treenitud mudelid olid täpsemad kui algmaterjalidel treenitud mudelid?

Maakonnad	I	II	III	IV	Ebatäpne pakkumine	Korrektseid tulemusi	Laiendatud	Laiendatud tulemused
Harju	JAH	EI	EI	JAH	EI	2	EI	0
Hiiu	JAH	EI	EI	EI	JAH	1	JAH	1
Ida-Viru	EI	EI	JAH	EI	EI	0	EI	-3
Järva	EI	EI	EI	EI	EI	0	EI	-1
Jõgeva	EI	EI	JAH	EI	EI	0	EI	-1
Lääne	EI	EI	EI	EI	EI	-1	EI	-3
Lääne-Viru	EI	EI	EI	EI	EI	0	EI	-1
Pärnu	JAH	EI	JAH	EI	JAH	4	JAH	2
Rapla	JAH	EI	EI	JAH	EI	2	EI	0
Saare	JAH	EI	EI	EI	EI	1	EI	-2
Tartu	EI	EI	EI	EI	EI	0	EI	0
Valga	EI	EI	EI	JAH	JAH	0	JAH	2
Viljandi	EI	JAH	EI	EI	EI	-2	EI	-2
<b>Pakkumise kohta:</b>	5	1	3	3	3			

Lisa tabel 35. MTÜ RR kujutiste maakondade tulemused - kas rohkendatud materjalidel treenitud mudelid olid täpsemad kui algmaterjalidel treenitud mudelid?

Regioonid	I	II	III	IV	Korrektseid tulemusi	Laiendatud	Laiendatud tulemused
Lõuna	EI	EI	JAH	JAH	-6	EI	-6
Lääne	EI	JAH	EI	JAH	-1	JAH	1
Põhja	JAH	EI	EI	JAH	29	JAH	1
Saared	EI	JAH	EI	EI	0	JAH	4
<b>Pakkumise kohta:</b>	1	2	1	3			

Lisa tabel 36. MTÜ RR kujutiste regioonide tulemused - kas rohkendatud materjalidel treenitud mudelid olid täpsemad kui algmaterjalidel treenitud mudelid?