

TARTU ÜLIKOOL
Arvutiteaduse instituut
Informaatika õppekava

Külli Lokko

**Meiobentose hulka kuuluvate organismide
automaatne tuvastamine masinõppe
meetoditega**

Bakalaureusetöö (9 EAP)

Juhendaja:
Ljubov Jaanuska, PhD

Tartu 2025

Meiobentose hulka kuuluvate organismide automaatne tuvastamine masinõppe meetoditega

Lühikokkuvõte:

Bakalaureusetöö eesmärgiks oli automatiseerida masinõppe meetoditega meiobentose tuvastamine ja identifitseerimine mikrofotodelt. Meiobentos – veekogu põhjasetetes elavad mikroskoopilised organismid – mängib olulist rolli veekogu energia- ja ainerings ja hõlmab paljusid erinevaid organismirühmi. Nende organismide käsitsi loendamine ja määramine on väga töö- ja ajakulukas protsess ning eeldab põhjalikku väljaõpet. Seega on vajadus automatiseerimise järele suur, kuna hõlbustaks oluliselt nii arvukuse, taksonoomilise koosseisu kui biomassi hindamist ja seeläbi ka ökoloogiliste seoste ning aineringe uurimist.

Bakalaureusetöö esimene oluline etapp oli märgendatud andmebaasi loomine, kuna varasemast selliseid meiobentose andmekogusid ei leitud. Mikrofotodel märgiti käsitsi ära organismide asukohad ja kuuluvus vastavatesse rühmadesse, et tagada kvaliteetne treeningmaterjal mudelite õpetamiseks.

Edasi treeniti kaks objektituvastusmudelit (Faster R-CNN ja YOLO11), mis tuvastavad mikrofotodelt automaatselt kõik meiobentose esindajad ja identifitseerivad millisesse taksonisse organism kuulub. Parimad treenitud mudelid osutusid tuvastusvõimekuselt vähemalt sama headeks kui senised veehõljumi jaoks treenitud mudelid, eksides sõltumatutel testandmetel arvukuse hindamisel vaid ~3,7% võrra. Õige taksoni määramisel olid treenitud mudelid pisut ebatäpsemad: nii taksoni kui asukoha fotol tuvastas parim Faster R-CNN mudel õigesti 86,3% juhtudest ja YOLO11 mudel 80,7% juhtudest.

Võtmesõnad: meiobentos, konvolutsioonilised närvivõrgud, masinõpe, pildituvastus

CERCS: P176 Tehisintellekt, B260 Hüdrobioloogia, mere-bioloogia, veeökoloogia, limnoloogia

Automatic recognition of meiobenthos using machine learning

Abstract:

The objective of the bachelor's thesis was to automate the detection and identification of meiobenthos in micrographs using machine learning methods. Meiobenthos consists of many different groups of microscopic organisms living in the aquatic sediments. In aquatic environments, meiobenthos plays an important role in energy flow and nutrient cycles. Counting and identifying these organisms manually is very labor-intensive and time-consuming, and requires extensive training. Therefore, there is a clear need for automation, which would greatly facilitate abundance and biomass estimation, taxonomic composition assessment, and the study of the ecological relationships and nutrient cycles.

First, an annotated database of micrographs was created as part of the thesis. To ensure high-quality training data, each meiobenthic organism in the images was manually annotated. Prior to this work, no comparable dataset was publicly available.

Next, models were trained using two object detection models (Faster R-CNN and YOLO11) to automatically detect all meiobenthic organisms in the images and to identify their taxonomic group. The detection performance of the best models was comparable to that of existing models trained on plankton datasets, achieving an error rate of only 3.7% in abundance estimation on the test set. The models performed slightly less well in identifying the correct organism group (taxon). The best Faster R-CNN model correctly identified both the location and taxonomic group of organisms in 86.3% of cases while the YOLO11 model identified both correctly in 80.7% of cases.

Keywords: meiobenthos, convolutional neural networks, machine learning, image recognition

CERCS: P176 Artificial intelligence, B260 Hydrobiology, marine biology, aquatic ecology, limnology

Sisukord

Sissejuhatus	5
1. Meiobentos ning mikroorganismide automaatne tuvastamine	6
2. Metoodika	11
2.1 Andmestik	11
2.2 Masinõppe alusmudeli valik	13
2.3 Faster R-CNN	14
2.4 YOLO	15
2.5 Programmi koostamine	16
2.7 Mudelite treenimine	17
2.8 Mudelite testimine	19
3. Tulemused	21
3.1 Treenimisel saadud parimad mudelid	21
3.2 Mudelite rakendamine testandmestikul	24
3.3 Mikroskoobi suurenduse mõju organismide tuvastamisele	29
3.4 Valitud alusmudelite rakendatavus meiobentose automaatseks tuvastamiseks	31
3.5 Meiobentose tuvastamise automatiseerimine	32
Kokkuvõte	34
Viidatud kirjandus	35
Lisad	39

Sissejuhatus

Väikesed veekogu põhjal ja setetes elavad organismid ehk meiobentos on väga mitmekesine ja ökoloogiliselt oluline kooslus (Giere, 2009). Seni pole meiobentose organismide tuvastamise automatiseerimist kuigivõrd proovitud. Sellegipoolest on vajadus automaatse tuvastamise ja identifitseerimise järele suur, kuna kiirendaks ja kergendaks oluliselt nii arvukuse, taksonoomilise koosseisu kui biomassi hindamist ja seeläbi ka ökoloogiliste seoste, aineringe uurimist. Erinevalt makrobentosest ei ole meiobentose tuvastamisel masinõppe meetodeid teadaolevalt varem kasutatud.

Bakalaureusetöö eesmärk on välja pakkuda potentsiaalselt rakendatavaid masinõppe mudeleid, mis võimaldaksid automaatselt tuvastada ja määrata meiobentose organisme mikrofotodelt ning arendada süsteemi, mis lihtsustaks meiobentose proovide analüüsi. Selleks koostas autor unikaalse, seni puudunud suuremahulise märgendatud andmebaasi mikrofotodest. Andmestiku põhjal treniiti ja võrreldi erinevaid masinõppemudeleid, et hinnata nende sobivust kõrgemate taksonite (peamiselt hõimkondade tasemel) tuvastamiseks.

Bakalaureusetöö koosneb kolmest peatükist. Esimeses peatükis antakse ülevaade meiobentose olemusest, olulisusest ja uuritusest võrreldes planktoni ehk veehõljumi ja makrobentosega. Kuna meiobentose tuvastamiseks kujutistelt ei ole seni masinõpet kasutatud, analüüsitakse masinõppe rakendamise hetkeseisu võimalikult sarnaste objektide puhul: suuruse osas osaliselt kattuva planktoni ja elupaiga poolest sarnase makrobentose puhul.

Teises peatükis antakse ülevaade töös kasutatud andmetest ja metoodikast. Esmalt kirjeldatakse andmestiku loomist ja selle aluseks olevat materjali (meiobentose proove). Seejärel selgitatakse, mille alusel valiti edasiseks testimiseks masinõppe mudelid ning antakse neist ülevaade. Edasi kirjeldatakse meiobentost tuvastavate mudelite trenimise ja hindamise programmide koostamist ning mudelite trenimist ja testimist.

Kolmandas peatükis tutvustatakse parimaid trenitud mudeleid ja nende testandmestikul rakendamise tulemusi. Mõõdikute alusel võrreldakse meiobentose tuvastamiseks trenitud parimaid mudeleid planktonit või makrobentost tuvastavate mudelitega ning arutletakse võimalike viiside üle kuidas jõuda veel paremate mudeliteni. Tulemuste alusel pakutakse välja ka põhimõtteline skeem proovidest meiobentose automaatseks tuvastamiseks.

Lisades tuuakse näide mudelite ennustuste (tuvastuste) visualiseerimisprogrammi genereeritud tulemuste raportist ning antakse täpsem ülevaade, kuidas kasutati käesolevas töös tehisintellekti programmikoodi loomisel.

1. Meiobentos ning mikroorganismide automaatne tuvastamine

Bentos ehk veekogu põhjaelustik jagatakse suuruse järgi erinevatesse kategooriatesse. Meiobentose moodustavad veekogude põhjasetetes elavad mikroskoopilised organismid, kes mahuvad läbi 500µm silmasuurusega sõelast, kuid jäävad pidama 44 µm silmasuurusega sõelale (Giere, 2009). Taksonoomiliselt on meiobentos väga mitmekesine (tabel 1). Protistidest kuuluvad meiobentose hulka näiteks foraminifeerid, tsiliaadid ja kodaamööbid; hulkraksetest organismidest näiteks ümarussid, keriloomad, lameussid, loimurid, väikesed vähilised (mõned vesikirbulised, aerjalalised, karpvähilised) ja ripskõhtsed (Giere, 2009) (joonis 1).

Tabel 1. Antud töös kasutatud organismirühmad koos nende taksonoomilise kuuluvusega (hõimkond ja klass). Jutumärkides on organismirühma kohta kasutatavad levinud nimetused.

Organismirühm	Hõimkond	Klass
Protistid	Foraminifeerid (<i>Foraminifera</i>)	
	Tsiliaadid (<i>Ciliophora</i>)	
	Amööbilaadsed (<i>Amoebozoa</i>)	
		Kodaamööbid (<i>Tubulinea</i>), " <i>Testacea</i> "
Hulkraksed	Ümarussid (<i>Nematoda</i>)	
	Keriloomad (<i>Rotifera</i>)	
	Lameussid (<i>Platyhelminthes</i>)	
		Ripsussid (<i>Rhabditophora</i>), " <i>Turbellaria</i> "
	Rõngussid (<i>Annelida</i>)	
	Loimurid (<i>Tardigrada</i>)	
	Lülijalgsete (<i>Arthropoda</i>)	
		Ämblikulaadsed (<i>Arachnida</i>)
		Aerjalgsed (<i>Maxillopoda</i>)
		Karpvähilised (<i>Ostracoda</i>)
		Putukad (<i>Insecta</i>)
	Ripskõhtsed (<i>Gastrotricha</i>)	
	Limused (<i>Mollusca</i>)	

Eesti mererandade ja järvede niiskest kaldaliivast – kitsast spetsiifilisest elupaigast – on leitud meiobentose hulka kuuluvaid organisme 156 taksonist, 12 erinevast hõimkonnast, kusjuures Saadjärves esines neist 80 taksonit (Lokko jt, 2014). Arvukamad ja ka liigirikkamad meiobentose esindajad on ümarussid (nii meres kui magevees), keriloomad (magevees), aga ka lülijalgsete (sh mikroskoopilised vähid) (Giere, 2009). Keriloomade enam kui 2000 liigist (Segers, 2007) umbes 1000 on bentilise eluviisiga ja moodustavad magevee meiobentose ühe

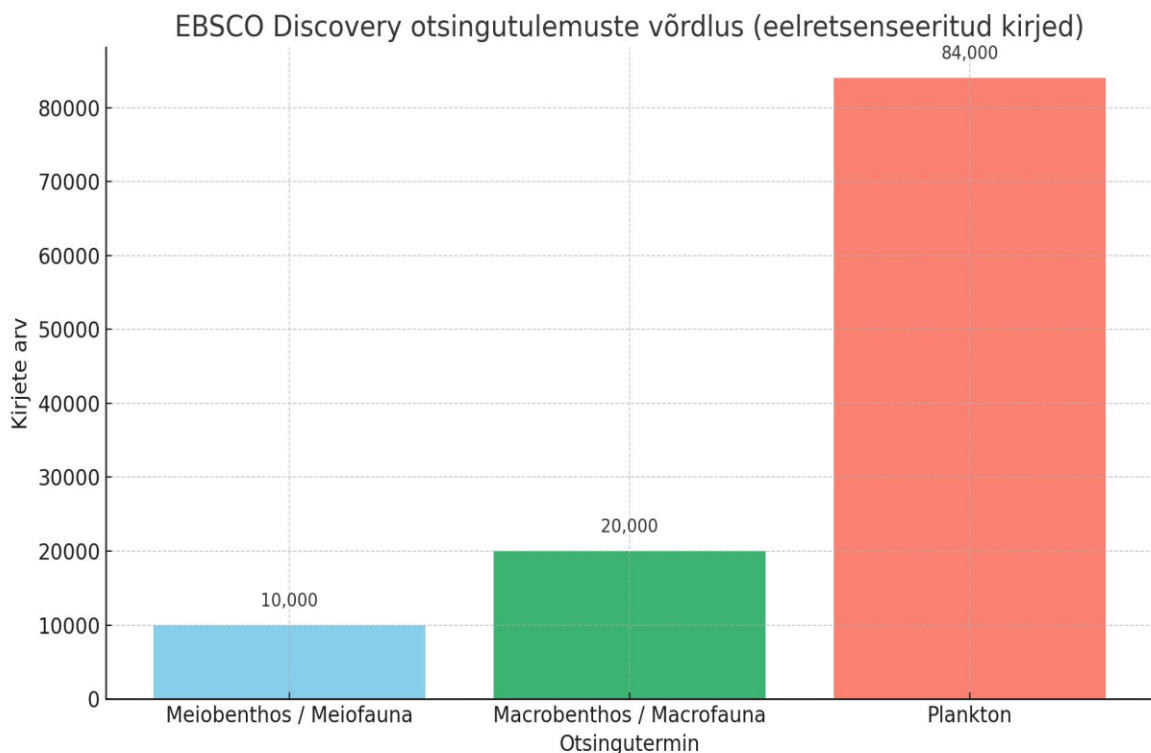
olulisima rühma, kuigi tavaliselt domineerivad ümarussid nii arvukuselt kui biomassi poolest (Giere, 2009). Meiobentose arvukus võib ulatuda sadade isenditeni ruutsentimeetri kohta (Giere, 2009, Lokko ja Virro, 2014).



Joonis 1. Näiteid mere meiobentose esindajatest (Cerca jt, 2018).

Meiobentosel on oluline roll veekogude aine- ja energiaringes. Meiofauna (meiobentose loomorganismid) on veekogude põhjas vahelülks tootjate ja kõrgemate troofiliste tasemete vahel ning on tähtis süsinikuringes (van der Heijden jt, 2020). Meiofauna mõjutab oma elutegevusega setete keemilisi omadusi ning otseselt või kaudselt ökosüsteemi teenuseid nagu sette stabiilsus, jääkainete ja saasteainete lagundamine (Schratzberger ja Ingels, 2018). Meiofauna on toiduks paljudele suurematele organismidele. Näiteks on leitud, et Läänemeres võib lestade ja väikese mudila noorte isendite toidust suurema osa moodustada meiofauna (Aarnio, 2001).

Vaatamata olulisusele energia- ja aineringes ning suurele mitmekesisusele ja arvukusele, on meiobentos saanud seni vähem tähelepanu võrreldes planktoni ja makrobentosega. EBSCO Discovery otsing „meiobenthos OR meiofauna“ annab umbes poole vähem vasteid kui „macrobenthos OR macrofauna“ ja üle kaheksa korra vähem vasteid kui otsing „plankton“, eelretsenseeritud kirjeid vastavalt pisut üle 10000, 20000 ja ligi 84000 (joonis 2). Küllap on põhjuseks see, et meiobentose proovide analüüsimine ehk organismide loendamine ja määramine on väga töö- ja ajakulukas protsess ning eeldab põhjalikku väljaõpet. Ka meiobentose biomassi hindamine on keerukas ning töömahukas protseduur (Baguley jt, 2004) ning tihti eeldab taksonoomilise koosseisu kvantitatiivset analüüsi. Seetõttu on juba pikalt otsitud viise, kuidas kasvõi osaliselt seda tööd automatiseerida. Näiteks pakkus Thomsen 1991. aastal välja poolautomaatse pildianalüüsi meetodi meiofauna loendamiseks ja biomassi hindamiseks (Thomsen, 1991). Ka Baguley jt (2004) on toonud välja, et organismide automaatset identifitseerimist võimaldav tarkvara aitaks oluliselt kaasa ökoloogiliste seoste uurimisel. Samuti võimaldab meiobentose tuvastamine pildi- või videoandmetelt kasutada samu isendeid hiljem täpsemates taksonoomilistes analüüsid, kuna pildistamine ei kahjusta kogutud isendeid (Baguley jt, 2004).



Joonis 2. EBSCO Discovery otsing: Plankton, meiobentos, makrobentos võrdlus.

Meiobentose puhul pole organismide automaatset tuvastamist teadaolevalt kuigi palju rakendatud. Küll aga on proovitud automaatselt tuvastada ja identifitseerida makrobentose esindajaid konvolutsioonilist närvivõrku kasutava süvaõppe mudeliga Faster R-CNN (Martin jt, 2023). Planktoni ehk veehõljumi automaatne tuvastamine on seevastu saanud palju rohkem tähelepanu. Koos kaamerapõhiste andmekogumisviiside levikuga on kasvanud vajadus organismide automaatseks tuvastamiseks pildi- ja videoandmetest (Luo jt, 2018). Nii on juba mõnda aega rakendatud mitmesuguseid erinevaid meetodeid planktoni automaatseks tuvastamiseks. Eerola jt (2024) on teinud põhjaliku ülevaate planktoni automaatse tuvastamise hetkeseisust, seni kasutatud meetoditest ning kitsaskohtadest. Planktoni automaatseks tuvastamiseks on seni põhiliselt kasutatud juhendatud masinõpet: taksonoomilise rühma jaoks käsitsi määratud spetsiifilisi tunnuseid (ingl *feature engineering*) koos masinõppe algoritmidega (näiteks: tugivektorklassifitseerija või otsustusmets) ning viimasel ajal konvolutsioonilisi närvivõrke, mis ei vaja eraldi spetsiifiliste tunnuste kindlaksmääramist, vaid mis tulevad need piltidelt ise (Eerola jt, 2024). Hiljuti on lisandunud ka juhendamata õpet rakendavad meetodid (Pastore jt, 2023) ja meetodid poolautomaatseks piltide märgendamiseks (Ciranni jt, 2024), mis võiks lahendada treening- ja testandmete vähesuse probleemi. Siiski on seni juhendamata õpet planktoni automaatsel tuvastamisel vähe kasutatud (Ciranni jt, 2024) ja juhendatud õppe korral on tuvastamise täpsus olnud suurem (Orenstein jt, 2020).

Luo jt (2018) näitasid, et konvolutsiooniliste närvivõrkude kasutamisel on võimalik saavutada küllalt suur täpsus, haruldaste organismirühmade väljajätmisel isegi üle 90%. Kuna meiobentose ja planktoni esindajad on osaliselt kattuva suurusega ja on isegi liike, kes võivad esineda nii meiobentose kui planktoni koosseisus, võib loota, et planktoni automaatsel tuvastamisel ja identifitseerimisel häid tulemusi andnud meetodid võivad töötada ka meiobentose jaoks.

Eerola jt (2024) toovad välja probleemkohad, mis esinevad planktoni automaatsel identifitseerimisel:

- märgendatud treeningandmete vähesus,
- võimalikud ebatäpsused olemasolevates märgendatud treeningandmetes ja pildikvaliteedi ning suuruse varieeruvus,
- mõningate taksonite visuaalne sarnasus,
- taksonite väga ebavõrdne esinemissagedus,
- treeningandmetes mitteesinevate taksonite esinemisvõimalus.

Kõik need väljatoodud probleemid võivad esineda ka meiobentose puhul ja on isegi teravamad. Kui planktoni jaoks on hõlpsalt leitavad ja vabalt kasutatavad pildiandmestikud olemas (näiteks Kaggle-Plankton (PlanktonSet-1.0) (Cowen jt, 2015), WHOI-Plankton (Sosik jt, 2022)), siis meiobentose jaoks sarnaseid avalikke andmestikke ei leidu. Lisaks esineb setetest võetud proovides rohkelt setteosakesi ja lagunevat orgaanilist materjali, mis jääb koos meiobentose organismidega kaamera vaatevälja ning muudab pildiandmed mürarohkeks.

2. Metoodika

Selles peatükis antakse ülevaade andmestikust ja kirjeldatakse selle koostamist. Edasi kirjeldatakse masinõppe alusmudeli valiku põhimõtteid ning tutvustatakse valitud alusmudeleid. Samuti kirjeldatakse mudelite treenimiseks programmi koostamist, mõõdikute valikut mudelite headuse hindamiseks ning antakse ülevaade mudelite treenimisest ja testimisest.

2.1 Andmestik

Mikroorganismide proovid on kogutud aastatel 2008 ja 2010-2013 veekogude liivasest kaldavööndist hõlmates nii bentost kui spetsiifilist elustikku psammonit (kuigi esineb spetsiifilisi psammoni liike, kattuvad taksonid kõrgematel taksonoomilistel tasemetel). Proovid on kogutud järgmistest järvedest ja Läänemere lahtedest: Männiku järv, Saadjärv, Verevi järv, Võrtsjärv, Keibu laht, Tallinna laht, Narva laht, Kõiguste laht. Proovide kogumise ja töötlemise metoodika on detailselt kirjeldatud Lokko jt 2014. aasta artiklis (Lokko jt, 2014).

Bakalaureusetöös kasutatud meiobentose mikrofotod on tehtud valgusmikroskoobile monteeritud digikaameraga. Enamus fotodest on tehtud kasutades 160-kordset suurendust, mõned fotod on tehtud suurendusega 100 ja üksikud suurema suurendusega. 160-kordne suurendus on piisav, et eristada väiksemaid detaile ning vähemalt mõne rühma puhul määrata (tulevikus) organism perekonna tasemeni, samas mahuvad sellise suurenduse puhul veel ka suuremad organismid enam-vähem tervenisti mikroskoobi vaatevälja. 100-kordne suurendus on tihti kasutusel meiobentose (ja ka planktoni) arvukuse määramisel: organismide loendamisel loenduskambris. Väikese mahuga loenduskambrit saaks kasutada veel ka mõnevõrra suurema suurendusega kui 100-kordne suurendus.


Enamik fotosid andmestikus on suurusega 3648×2736 pikslit, kuid esineb ka teistsuguse mõõduga pilte. Need on tehtud kas teise kaamera või mikroskoobiga. Fotode suuruse valikul võeti eeskujuks Kaggle-Plankton andmestik (PlanktonSet-1.0) (Cowen jt, 2015), kus piltide mõõtmed olid samuti üsna suured – 2448×2448 pikslit.

Käesoleva töö raames loodud meiobentose andmestikus on autor käsitsi märgendanud kokku 2790 fotot. Neist 2250 kuuluvad treeningandmestikku ja 540 valideerimisandmestikku. Ühel fotol võib olla üks või mitu meiobentose organismi. Kui ühest isendist on mitu fotot (näiteks erinevate tasandite, valgustuse või nurkadega), siis on kõik selle isendi fotod kas ainult treening- või ainult valideerimisandmetes. See tagab mudeli objektiivse hindamise ning vastab

Kuhni ja Johnsoni (2013) soovitudele kasutada mudeli hindamiseks ainult andmeid, mis ei osale treenimises.

Lisaks on loodud testandmestik, mis sisaldab 584 fotot, mida ei ole kasutatud ei treening- ega valideerimisandmestikus. Nende hulgas on pilte, mis on tehtud nii suurema (800-kordne suurendus, 24 fotot) kui ka väiksema (100-kordne suurendus, 69 fotot) mikroskoobi suurendusega. Selline valik võimaldab hinnata, kui hästi automaattuvastusmudelid suudavad toime tulla erineva suurendusega piltidega.

Meiofauna organismid on märgendatud tööriistaga VGG Image Annotator (Dutta ja Zisserman, 2019) ning salvestatud COCO-andmeformaadis (joonis 3).



Joonis 3. VGG Image Annotator tööriistaga märgendatud foto (keriloom ja ümaruss).

Treening- ja valideerimisandmed on märgendatud kahe erineva märgenduskeemi alusel. Esimene skeem sisaldab kümnet objektiklassi (tabel 2): ümarussid, keriloomad, kodaamööbid, tsiliaadid, ripsussid, rõngussid (väheharjasussid), lüljalgsed (kahetiivaliste vastsed, mikroskoopilised vähid, ämblikulaadsed), ripskõhtsed, loimurid ja limused (karbid). Teises märgenduskeemis on kasutusel ainult üks objektiklass: meiofauna.

Kahe erineva skeemi kasutamine võimaldab uurida kahte peamist küsimust:

- Kas automaattuvastus suudab eristada meiobentose esindajaid taustmürast?
- Kas automaattuvastus suudab liigendada meiobentose esindajaid taksonite kaupa?

Tabel 2. Fotode arv treening- ja valideerimisandmetes, kus vastav organismirühm on esindatud, objektiklasside kaupa.

Objektiklass	Fotode arv treeningandmetes	Fotode arv valideerimisandmetes
nematode (ümarussid)	546	164
rotifer (keriloomad)	780	187
testacea (kodaamööbid)	616	111
ciliate (tsiliaadid)	244	48
turbellarians (ripsussid)	21	11
annelida (rõngussid)	65	22
arthropoda (lüljalgsed)	128	41
gastrotricha (ripskõhtsed)	22	8
tardigrada (loimurid)	120	17
mollusca (limused)	5	1

Kõik fotod ja märgendusruudud (ingl *bounding boxes*) on identsed mõlemas andmekomplektis, erinevus on vaid märgendis. Fotodel esineb ka mikroskoopilisi vetikaid, keda piisavate ekspertteadmiste puudumise tõttu käesolevas töös organismina ei märgendatud, kuigi meiobentose hulka võib lugeda ka vastavasse suurusvahemikku kuuluvaid mikrovetikaid.

Lõputöö käigus autori poolt loodud ja käsitsi märgendatud meiobentose andmebaas on avalikustatud Kaggle platvormil: <https://www.kaggle.com/datasets/kyllilokko/meiobenthos-dataset>, kust see on kättesaadav kasutamiseks edasistes teadustöodes ja mudelite treenimiseks.

2.2 Masinõppe alusmudeli valik

Meiobentose arvukuse hindamisel (mida oleks eriti tarvilik automatiseerida) jääb proovide analüüsimise käigus tavalise valgusmikroskoobi vaatevälja tihti korraga rohkem kui üks organism. Nii on ka käesolevas töös kasutatud andmestiku mikrofotodel sageli mitu organismi.

Seega olid masinõppe mudeli valikus eelkõige need mudelid, mis võimaldavad ühelt pildilt tuvastada ja identifitseerida mitut objekti.

Planktoni tuvastamisel on saanud populaarseks erinevate konvolutsioonilisi närvivõrke kasutavate meetodite rakendamine (Eerola jt, 2024). Konvolutsiooniline närvivõrk (CNN, ingl *convolutional neural network*) on tehisnärvivõrk eelkõige visuaalsete, aga ka keele- ja audioandmete analüüsimiseks, mis koosneb tüüpiliselt erinevatest kihtidest, sh konvolutsioonilistest ja ahenduskihtidest (ingl *pooling layer*) (LeCun jt, 2015).

Konvolutsioonilistes kihtides rakendatakse konvolutsioonilisi filtreid (ingl *convolutional filters*), mille abil luuakse sisendandmete põhjal tunnuskaardid (ingl *feature maps*) (LeCun jt, 2015). Seejärel rakendatakse aktivatsioonifunktsiooni, milleks on tüüpiliselt mittenegatiivne lineaarfunktsioon (ingl *rectified linear unit*, ReLU), mis tagastab negatiivse sisendi korral nulli: $f(z) = \max(z, 0)$ (LeCun jt, 2015). Ahenduskihtides liidetakse omavahel semantiliselt sarnased tunnused, et vähendada andmestiku mõõtmeid ning tuua esile olulisimad tunnused (LeCun jt, 2015).

Masinõppe alusmudeli valikul olid olulisteks argumentideks varem sarnasel andmestikul edukas kasutamine ja hea täpsus. Eerola jt (2024) toovad oma planktoni tuvastamise ülevaateartiklis välja R-CNN ja YOLO (*You Only Look Once*) kui objektituvastusmudelid, mis üheaegselt tuvastavad objekti asukoha ja klassi. Faster R-CNN on R-CNN edasiarendus (Ren jt, 2017), mida on küllalt heade tulemustega rakendatud makrobentose tuvastamiseks (Martin jt, 2023). Ka YOLO on katsetatud makrobentose tuvastamisel (Zhang jt, 2022). Zhang jt (2022) töös leiti isegi, et vaadeldud YOLO versioonid olid täpsemad kui Faster R-CNN (mAP50-95¹ alusel). Seega sai meiobentose automaatseks tuvastamiseks ja identifitseerimiseks valitud Faster R-CNN ja YOLO.

2.3 Faster R-CNN

Faster R-CNN (*Faster Region-based Convolutional Neural Network*) on konvolutsioonilistel närvivõrkudel põhinev populaarne objektituvastusmudel. Faster R-CNN on kaheastmeline: esmalt võtab (objekti) esinemispiirkonna ettepanekute võrk (RPN – *regional proposal network*) sisendiks terve sisendpildi ning tagastab võimalikud objektide asukohad ja seejärel identifitseeritakse, millisesse objektiklassi objekt (ristkülikukujuline ala, mille RPN tagastas)

¹ mAP50-95 on mõõdik, mis näitab mudeli headust üle erinevate tuvastamise keerukuse tasemetega; arvutatakse kui keskmine väärtus üle mudeli keskmiste täpsuste, IoU (objekti ennustatud ja tegeliku esinemise asukoha ristküliku (*bounding box*) kattuvus) lävenditel 0.50 kuni 0.95 docs.ultralytics.com/guides/yolo-performance-metrics (12.03.2025).

kuulub (Ren jt, 2017). RPN on konvolutsiooniline närvivõrk, mis tuvastab samaaegselt nii objekti piirid (ristkülikukujulise ala pildil, kus objekt võiks asuda) kui ka tõenäosuse (*objectness score*), et tuvastatud ristkülik sisaldab mingisugust objektiklassi (Ren jt, 2017). Võrreldes eelkäijate Fast R-CNN ja R-CNN'ga on Faster R-CNN oluliselt kiirem ja parema täpsusega (Ren jt, 2017). R-CNN puhul loodi esmalt esinemispiirkondade ettepanekud (ingl *region proposal*) ja seejärel rakendati tunnuste leidmiseks CNN-i iga esinemispiirkonna jaoks eraldi (iga esinemispiirkonna kohta oma tunnuskaart) ning selle järel identifitseeriti objektiklass kasutades klassi-spetsiifilist tugivektorklassifitseerijat (Girshick jt, 2014). Fast R-CNN puhul luuakse kogu sisendpildi kohta üks jagatud tunnuskaart, mis teeb mudeli treenimise ja rakendamise palju kiiremaks (Girshick, 2015). Faster R-CNN puhul on objektide esinemispiirkondade tuvastamise ajakulu peaaegu olematu, kuna objekti esinemispiirkondi tuvastav RPN ja objekte identifitseeriv närvivõrk jagavad sama tunnuskaarti (Ren jt, 2017).

2.4 YOLO

Nagu Faster R-CNN, põhineb ka YOLO konvolutsioonilistel närvivõrkudel. Erinevalt Faster R-CNN-st on YOLO aga lihtsama ülesehitusega: üksainus närvivõrk tuvastab üheaegselt kus objektid kujutisel asuvad ja millisesse klassi need kuuluvad (Redmon jt, 2016). Redmon jt (2016) selgitavad, et YOLO jagab sisendpildi ruudustikeks ning kui objekti kese satub mingisse ruutu, siis see ruut nõ vastutab selle objekti identifitseerimise eest. Samas teised ruudud võivad siis seda objekti nõ ignoreerida (Alif ja Hussain, 2024). Mudeli treenimise ja testimise ajal näeb YOLO korraga tervet sisendpilti ning võtab iga objekti märgendusruudu ennustusel arvesse kogu pilti, seetõttu teeb YOLO palju vähem tausta objektideks pakkumise vigu kui näiteks Fast R-CNN (Redmon jt, 2016). Lihtne ülesehitus teeb YOLO kiireks, võimaldades isegi reaalajas pildituvastust, kuid täpsuse poolest (YOLO esimene versioon) jääb Fast ja Faster R-CNN-le alla (Redmon jt, 2016). YOLO mudeleid on pidevalt edasi arendatud ja leidub terve rida pisut erineva fookusega (kiirus, täpsus, kasutatavus mürarohkete või objektirohkete kujutistega) arendatud versioone (Alif ja Hussain, 2024). Hetkeseisuga on kõige uuemad YOLO versioonid YOLO11 ja YOLO12².

² <https://docs.ultralytics.com/models/> (20.03.2025)

2.5 Programmi koostamine

Programmi koostamiseks valiti Pythoni masinõppe raamistik PyTorch (Paszke jt, 2019) ja teek TorchVision³, kuna nende puhul oli palju häid programmi koodi näiteid ja tutvustavaid videoid Faster R-CNN ja YOLO kohta.

Meiobentose automaatse tuvastamise lahendust alustati mudelist Faster R-CNN. Mudeli treenimise ja testimise programmi koostamise lähtekohaks oli Faster R-CNN näidiskood A. Singla GitHub'i repositooriumist⁴. Selle näidiskoodiga said tehtud esimesed katsetused mudeli treenimisel käesoleva töö andmestikku kuuluvate fotodega. Pärast mõningaid katsetusi Faster R-CNN tundmaõppimiseks järgnes programmi täiustamine ChatGPT (OpenAI, 2024) abil. Vestlusroboti abil sai parandatud tulemuste logimist, lisatud treenitud mudelite õigsuse (ingl *accuracy*), täpsuse (ingl *precision*), saagise (ingl *recall*), F1-skoori, mAP50⁵ ja mAP50-95 arvutamine ning treenitud mudeli rakendamise visualiseerimine (Lisa I). Juturoboti abi kasutades oli sisendiks enamasti terve programmi kood, kuna nii oli kindel, et juturobot võtab vastamisel arvesse ka koodis vahepeal (peale viimast vestlust) tehtud muudatusi.

Faster R-CNN puhul valiti mudeli selgrooks (ingl *backbone*) 50 kihti sügav eeltreenitud närvivõrk ResNet-50 (He jt, 2016). ResNet-50 on parema täpsusega kui näiteks VGG-16⁶ (mõõdetuna top-1 ja top-5 veana⁷) ja vaid pisut kehvema täpsusega kui sügavamad jääkvõrgud (ingl *residual network*), kuid see-eest nõuab palju vähem arvutusressurssi kui ResNet-101 või ResNet-152 (He jt, 2016).

Kui Faster R-CNN'i kasutatav mudeli treenimise programm sai üldjoontes valmis, siis kasutati ChatGPT (OpenAI, 2024) abi, et luua selle põhjal analoogne YOLO programm ning abi-programm, mis aitab COCO formaadis märgendid transformeerida YOLO jaoks sobivasse formaati (Lisa I). Esialgu sai YOLO versiooniks valitud 8 (YOLOv8⁸), aga kuna uuem versioon YOLO11 lubas paremat täpsust ja mudeli treenimise kiirust⁹ ning versiooni vahetamine osutus

³ <https://github.com/pytorch/vision> (17.03.2025)

⁴ <https://github.com/AarohiSingla/Faster-R-CNN-on-custom-dataset-Using-Pytorch/blob/main/sol.ipynb> (15.01.2025)

⁵ mAP50 näitab mudeli headust arvestades ainult nõ lihtsamaid tuvastusi; arvutatakse kui keskmine väärtus üle mudeli keskmiste täpsuste, IoU lävendil 0.50 docs.ultralytics.com/guides/yolo-performance-metrics (12.03.2025).

⁶ pildituvastamises sagedasti kasutatav 16 konvolutsioonikihiga närvivõrk, *Visual Geometry Group* <https://medium.com/@siddheshb008/vgg-net-architecture-explained-71179310050f> (17.03.2025)

⁷ top-1 viga näitab mitmel protsendil juhtudest mudeli kõrgeima usaldushinnanguga ennustus objektiklassi kohta on vale. Top-5 viga näitab mitmel protsendil juhtudest ei olnud õige märgend mudeli pakutud viie kõrgeima usaldushinnanguga pakkumise hulgas.

⁸ <https://docs.ultralytics.com/models/yolov8/> (17.03.2025)

⁹ <https://docs.ultralytics.com/models/yolo11/> (17.03.2025)

väga lihtsaks, jäigi lõpuks kasutusele YOLO11. Eeltreenitud mudeliks valiti keskmise parameetrite arvuga YOLO11m¹⁰, mis on heaks kompromissiks täpsuse ja arvutuskoormuse vahel. Mudeli treenimisel seati pildi suuruseks 1024x1024 pikslit, et saavutada suurem täpsus (YOLO teeb treenimisel kõik pildid ühesuuruseks, valida saab etteantud suuruste vahel, 640x640 pikslit on keskmine).

2.6 Mudeli headuse mõõdikud

Treenitud mudelite hindamiseks kasutati masinõppe teegist *Scikit* (Pedregosa jt., 2011) järgmisi mõõdikute funktsioone:

- *accuracy_score* - õigsus (tõeste tuvastuste osakaal kõigist, nii klassi kuuluvateks kui mittekuuluvateks tuvastatutest) ainult Faster R-CNN mudelitele,
- *precision_score* - täpsus (tõeste klassi kuuluvateks tuvastuste osakaal kõigisse sellesse klassi kuuluvateks tuvastatud objektidest),
- *recall_score* - saagis (kõigist selle klassi objektidest õigesti ülesleitud objektide osakaal),
- *f1_score* - F1-skoor (kombineerib täpsuse ja saagise).

Samuti on treenitud mudelite hindamiseks lisatud mõõdikute mAP50 ja mAP50-95 arvutamine. Neid mõõdikuid kasutatakse tihti pildituvastusel mudelite täpsuse hindamisel ja võrdlemisel, näiteks võrreldakse Zhang jt (2022) artiklis mAP50-95 alusel muuhulgas erinevate YOLO versioonidega ja Faster R-CNN'ga treenitud mudelite täpsust.

2.7 Mudelite treenimine

Mudelite treenimise täiustamiseks kasutati ChatGPT (OpenAI, 2024) abi (Lisa I). Sisendiks oli esialgu kogu senine mudeli treenimise kood ning selle alusel andis ChatGPT (OpenAI, 2024) soovitusi kuidas koodi muuta, et parema mudelini jõuda. Soovitustega tutvumise järel sai välja valitud mõni, mis tundus suurema potentsiaaliga ja seejuures lihtsalt rakendatav ja mitte liialt keerukas. Valitud soovitude alusel andis juturobot täiustatud programmi (Lisa I), millega veel paremaid mudeleid treenida.

Treenimisprogrammi koostamise faasis kasutati sülearvuti arvutusvõimsust. Kui treenimisprogramm sai valmis, toimus mudelite treenimine Google Colab¹¹ keskkonnas, kus

¹⁰ <https://github.com/ultralytics/ultralytics> (17.03.2025)

¹¹ <https://colab.research.google.com/> (16.03.2025)

oli võimalik graafikaprotsessori (*NVIDIA Tesla T4*) abil mudeleid oluliselt kiiremini treenida. Ületreenimise vältimiseks jätkus mudeli treenimine kuni Faster R-CNN puhul kadu (epohhi järgmiste kadude keskmine: klassifitseerimiskadu, regressioonikadu, objektsuskaotus ja piirdekasti (ingl *bounding box*) regressioonikadu RPN-is) enam ei vähenenud ja YOLO puhul mAP50, mAP50-95 väärtused enam ei kasvanud ja kadu (ingl *distribution focal loss*) enam ei kahanenud.

Kuna meiobentos sisaldab erineva esinemissagedusega liike ja kõrgemaidki taksoneid, sealhulgas haruldasi, siis kõikide organismirühmade aktsepteeritava täpsusega identifitseerimist ei ole bakalaureusetöö raames realistlik saavutada. Planktoni automaatsel identifitseerimisel on mudeli täpsuse tõstmiseks haruldased liigid lihtsalt välja jäetud (näiteks: Luo jt, 2018), kuid selline lähenemine alahindab üldist arvukust. Lahendusena jagatakse käesolevas töös ülesanne kaheks: esmalt tuvastab üks mudel kõik organismid ja seejärel teine mudel identifitseerib organismide rühmad (joonis 4).

Esmalt treeniti võimalikult hea mudel meiobentose tuvastamiseks - mudel, mille eesmärgiks on tuvastada fotolt kõik meiofauna organismid ja seejuures mitte pakkuda organismiks muid objekte (õietolmu, lagunevat orgaanikat, liivaterasid jne). Selleks lisati Faster R-CNN mudeli treenimiseks selle treeningandmetesse 250 fotot mitteloomorganismist. Need fotod saadi treeningfotodest väljalõikamisel, nii et väljalõigatud osale ei jääks ühtki organismi. YOLO mudeli treenimisel organismideta taustafotosid treeningandmetesse ei lisatud, kuna YOLO peaks valepositiivseid ennustusi tegema (ehk antud juhul tausta organismina tuvastama) vähem kui teised objektituvastusmudelid (Redmon jt, 2016).

Meiobentose rühmi tuvastavate mudelite treenimiseks olid esimeste katsetuste ajal kaasatud kõik 10 rühma (tabel 2), sealhulgas rühmad, mille esindajaid oli vaid mõnel üksikul fotol. Ebaühtlase esindatusega rühmadega treenides on keeruline jõuda hea täpsusega mudelini (Buda jt, 2018). Selleks, et vaatamata alaesindatud objektiklassidele treenida võimalikult häid mudeleid, kasutatakse kõige sagedamini alaesindatud objektiklasside näidete (andmete) arvu suurendamist ja üldiselt aitabki see meetod hästi mudeli täpsust tõsta (Buda jt, 2018). Eerola jt (2024) viitavad oma planktoni automaatse tuvastamise ülevaates, et tüüpiliselt tõstetakse alaesindatud objektiklasside andmete hulka rikastatud (ingl *augmented*) andmetega: mitte lihtsalt identsete duplikaatidega, vaid töödeldud (näiteks peegelpilti pandud) duplikaatidega. Kuna käesoleva töö andmestikus esines karpe (objektiklass *mollusca*) vaid mõni üksik, siis jäi see klass lõplikust rühmi tuvastavast mudelist välja. Allesjäänud üheksast rühmast kolme

haruldasema puhul kasutati treeningandmete rikastamist pööratud ja/või peegelpilti pandud fotodega (tabel 3).

Tabel 3. Fotode arv treeningandmetes objektiklasside (taksonite) kaupa peale harvem-esinevamate objektiklasside andmete rikastamist pööratud ja peegelpilti pandud fotodega (paksus kirjas on objektiklassid, mille puhul andmeid rikastati).

Objektiklass	Fotode arv treeningandmetes
nematode (ümarussid)	551
rotifer (keriloomad)	806
testacea (kodaamööbid)	626
ciliate (tsiliaadid)	262
turbellarians (ripsussid)	122
annelida (rõngussid)	129
arthropoda (lüljalgsed)	128
gastrotricha (ripskõhtsed)	132
tardigrada (loimurid)	120

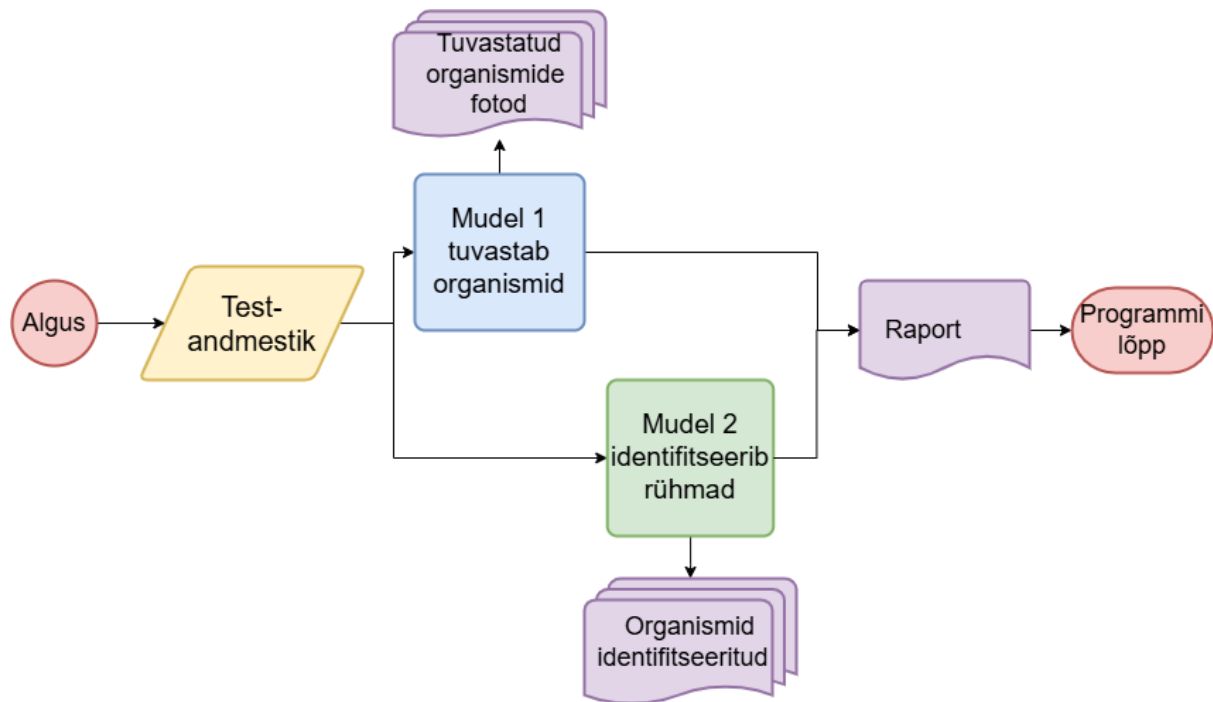
Ripskõhtseid ja ripsusse sisaldavad esialgsed fotod pöörati paremale 90, 180 ja 270 kraadi võrra ja pandi peegelpilti ning tulemusena saadud fotod lisati treeningandmetesse. Rõngusse sisaldavatest fotodest tekitati lisaks ainult peegelpildid. Saadud uues treeningandmestikus oli küll jätkuvalt kolm oluliselt rohkem esindatud objektiklassi (keriloomad, kodaamööbid ja ümarussid), kuid erinevus objektiklasside esindatuses vähenes oluliselt. Seda rikastatud treeningandmestikku kasutati edaspidi nii Faster R-CNN kui YOLO mudelite treenimisel.

2.8 Mudelite testimine

Kui meiobentose tuvastamise ja identifitseerimise mudelid said treenitud, hinnati treenitud mudeleid, kasutades märgendatud valideerimisandmestikku. Faster R-CNN puhul hinnati treenitud mudelid selleks eraldi koostatud valideerimisprogrammiga. YOLO puhul oli mõõdikute arvutamine osa mudelite treenimise programmist. Seejärel valiti F1-skoori, mAP50 ja mAP50-95 väärtuse alusel välja parimad mudelid.

Edasi katsetati valitud mudeleid märgendamata testandmestikul. Esmalt rakendati mudelit, mis tuvastab meiobentose organismid, seejärel rakendati sama testandmestiku peal teist mudelit,

mis identifitseerib organismide taksonid (joonis 4). Sarnane programm mudelite rakendamiseks testandmetel koostati ChatGPT (OpenAI, 2024) abil nii Faster R-CNN kui YOLO jaoks (Lisa D).



Joonis 4. Meiobentose automaatse tuvastamise skeem. Sisendiks on märgendamata test-andmestik, millele rakendatakse esimest mudelit (Mudel 1), mis tuvastab sisendfotodelt organismid. Mudel 2 identifitseerib organismide taksonid. Mõlemate mudelite tulemuste kohta genereeritakse ühine raport.

Kui üheksat objektiklassi (organismirühma) tuvastavate mudelite headus jäi loodetust tagasihoidlikumaks ja tulemused viitasid, et kõige probleemsemaks osutus ripskõhtsete (*Gastrotricha*) identifitseerimine, siis eemaldati selle rühma esindajate fotod treenimis-andmetest ning treeniti Faster R-CNN ja YOLO mudelid kaheksa rühma identifitseerimiseks: ümarussid, keriloomad, kodaamööbid, tsiliaadid, ripsussid, rõngussid, lüliljalgsed, loimurid.

3. Tulemused

Selles peatükis tutvustatakse esmalt parimate treenitud mudelite headust valideerimis- andmestikul valitud mõõdikute põhjal ja seejärel nende mudelite testandmestikul rakendamise tulemusi. Saadud tulemusi võrreldakse kirjanduse põhjal plankoni ja makrobentose jaoks treenitud mudelitega ning hinnatakse valitud alusmudelite Faster R-CNN ja YOLO rakedatavust meiobentose automaatseks tuvastamiseks ja antakse soovitusi veelgi paremate mudelite treenimiseks. Tulemuste põhjal pakutakse välja põhimõtteline süsteem meiobentose tuvastamise automatiseerimiseks.

3.1 Treenimisel saadud parimad mudelid

Mõlema valitud masinõppe alusmudeliga õnnestus treenida küllalt head mudelid meiobentose esindajate tuvastamiseks. Valideerimisandmestikul saadud tulemuste põhjal parimate fotolt ainult meiobentose hulka kuuluvaid organisme tuvastavate mudelite (edaspidi mudel 1) F1-skoor oli üle 0,9 ning mAP50 üle 94% (tabel 4). Seejuures F1-skoor oli kõrgem Faster R-CNN mudeli puhul, aga mAP50-90 väärtus YOLO mudeli puhul. F1-skoori alusel saadi parim Faster R-CNN mudel 1 treenimise 28. epohhi järel (joonis 5) ning parim YOLO mudel 1 pärast 196 epohhi (joonised 6 ja 7).

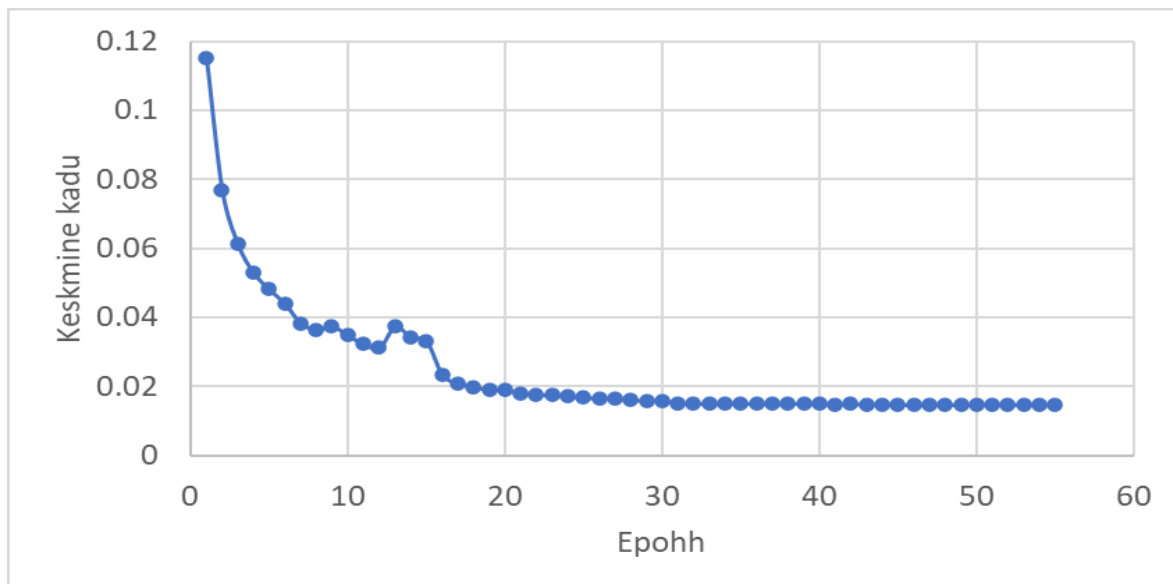
Tabel 4. Parimate treenitud Faster R-CNN ja YOLO11 mudelite mõõdikute väärtused (mudel 1 - tuvastab vaid organismid, mudel 2 - identifitseerib organismide rühmad, sulgudes mudeli objektiklasside arv). YOLO puhul mudeli õigsust ei arvatud.

Mudel	Epohhi nr	Õigsus	Täpsus	Saagis	F1 skoor	mAP50	mAP50-95
Faster R-CNN mudel 1	28	0.8518	0.9018	0.9389	0.92	0.9475	0.7544
YOLO mudel 1	196	-	0.9226	0.8805	0.9009	0.9518	0.8009
Faster R-CNN mudel 2 (9 klassi)	11	0.7348	0.6475	0.7198	0.6769	0.8127	0.6137
YOLO mudel 2 (9 klassi)	74	-	0.8092	0.7537	0.7804	0.8390	0.6963
Faster R-CNN mudel 2 (8 klassi)	22	0.767	0.7123	0.7788	0.7401	0.903	0.7262
YOLO mudel 2 (8 klassi)	89	-	0.8253	0.8317	0.8288	0.8702	0.7252


Parimate organismirühmi identifitseerivate mudelite (edaspidi mudel 2) F1-skoor jäi oluliselt väiksemaks: parimal üheksat taksonit tuvastaval Faster R-CNN mudelil alla 0,7 ja YOLO mudeli puhul 0,78 (tabel 4).

Oluline on märkida, et enamiku objektiklasside tuvastamise F1-skoor jäi vahemikku 0,71–0,94. Suurimaks väljakutseks osutus ripskõhtsete tuvastamine, mille F1-skoor oli vaid 0,32. Kasutatud andmestikus oli ripskõhtseid küllaltki vähe ja väiksemate kasutatud suurenduste juures (100 ja 160 korda) ei ole nende iseloomulikud tunnused (keha katvad ripsmed ja ogakesed) fotodelt hästi näha. Kuigi enamikel fotodel on ripskõhtsed iseloomuliku kehakuju ja -asendiga ning näha on ka kaht jätket keha lõpus (nn varbad), paistavad nad küllalt sarnased mõningate keriloomade ja ripsloomadega (tsiliaatidega). Ilmselt seetõttu ei õnnestunudki treenida paremat Faster R-CNN mudelit, mis oleks ka seda rühma suutnud tuvastada vähegi arvestatava täpsusega. Niisiis eemaldati ka ripskõhtsed mudel 2 treeningandmetest ja treeniti uued Faster R-CNN ja YOLO mudelid, mis tuvastaksid ülejäänud organismirühmi paremini.

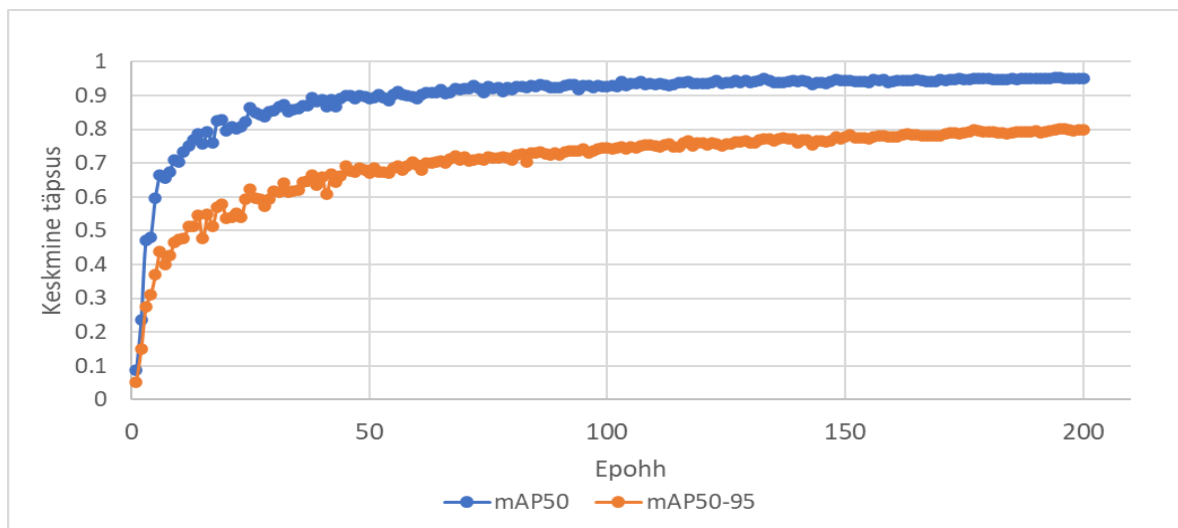
Pärast ripskõhtsete eemaldamist olid kaheksale objektiklassile treenitud mudelite F1-skoorid kõrgemad, samuti parenesid mAP50 ja mAP50–95 väärtused (tabel 4). Ripskõhtsete eemaldamine mõjutas mudelite täpsust eriti Faster R-CNN puhul, võrreldes YOLO mudelitega.



Joonis 5. Keskmine kadu Faster R-CNN organisme tuvastava mudeli (mudel 1) treenimisel.



Joonis 6. Kadu (ingl *distribution focal loss*) YOLO11 organisme tuvastava mudeli (mudel 1) treenimisel.



Joonis 7. mAP50 ja mAP50-95 väärtused YOLO11 organisme tuvastava mudeli (mudel 1) treenimisel.

Võrreldes sarnaste uuringutega olid meiobentose tuvastamise saagis ja mAP50 väärtused kõrgemad. Näiteks Zhang jt (2024) poolt veelustel piltidel meduuside tuvastamiseks välja töötatud JF-YOLO närvivõrk (põhineb YOLO versioonil 4) saavutas saagise 85,74% ja mAP50 väärtuse 92,67%. Zhang jt (2024) töös käsitletud meduuside tuvastamine on olemuselt võrdlemisi sarnane käesoleva töö mudel 1 ülesandele: mõlemal juhul on mudelil vaja fotolt tuvastada organismid, kuid mitte klassifitseerida mõnda täpsemasse rühma. Käesolevas töös treenitud mudel 1 F1-skoorid on samas vahemikus kui planktoni andmestikel treenitud erinevate sügavõppe mudelite F1-skoorid Lumini ja Nanni (2019) töös. Erinevalt käesolevast

tööst, ei ole Lumini ja Nanni (2019) kasutatud andmestikes ühel fotol rohkem kui ühe organismirühma esindaja ja nende treenitud mudelite ülesandeks oli klassifitseerida sisendpilt mingi rühma esindaja pildiks. Eerola jt (2024) toovad oma ülevaateartiklis välja planktoni andmestikel treenitud mudelite õigsuse väärtused 24 uurimistööst: nendes uurimistöodes varieeruvad mudelite õigsuse väärtused 58,8 ja 98,6% vahel. Käesolevas töös treenitud mudelite õigsused jäid samasse vahemikku kui planktoni andmestikel treenitud mudelite tulemused planktoni tuvastamisel. Tasub veel märkida, et Eerola jt (2024) ülevaateartiklis väljatoodud uurimistöodes olid mudelid treenitud andmestikel, kus iga pilt kujutab ühte organismi ja seega on nende töödes tegu pigem objekti klassifitseerivate mudelitega, mis tuvastavad ainult objekti (pildi) klassi, erinevalt käesolevast tööst, kus treenitud mudelid tuvastavad nii objekti asukohta kui klassi.

Objektituvastusmudelit Faster R-CNN on varem rakendatud makrobentose tuvastamiseks (Martin jt, 2023). Martin jt (2023) töös treeniti mudelid tuvastama 11 objektiklassi, mis on küllaltki sarnane käesoleva töö objektiklasside arvule ja kuigi treeningandmete hulk oli suurem ning käsitletud organismid erinevad käesolevast tööst, võib nende tööd pidada leitud uurimistööst kõige võrreldavamaks Faster R-CNN mudelite headuse osas. Martin jt töös olid treenitud mudelite parimad keskmised täpsused ja saagised vastavalt 0.57 ja 0.52 (Martin jt, 2023), mis on oluliselt madalamad käesolevas töös treenitud üheksat ja kaheksat objektiklassi identifitseerivatest mudelitest (mudelid 2, tabel 4). Arvestades, et Martin jt (2023) töös üheteistkümnest rühmast nelja puhul olid mudelite täpsused ja saagised väärtusega 0, oleks tõenäoliselt ka nende töö puhul saanud haruldaste rühmade väljajätmisel paremaid mudeleid treenida.

Ka YOLO üht versioonidest on rakendatud makrobentose tuvastamiseks. Spetsiaalselt merebentose tuvastamiseks väljatöötatud YoloXT parim mAP50-95 väärtus oli Zhang jt (2022) töös 70,9%, mis on pisut parem kui käesolevas töös üheksa objektiklassi identifitseerimiseks treenitud parim YOLO mudel 2, kuid madalam kui YOLO mudel 1 ja kaheksat objektiklassi identifitseeriv YOLO mudel 2 (tabel 4).

3.2 Mudelite rakendamine testandmestikul

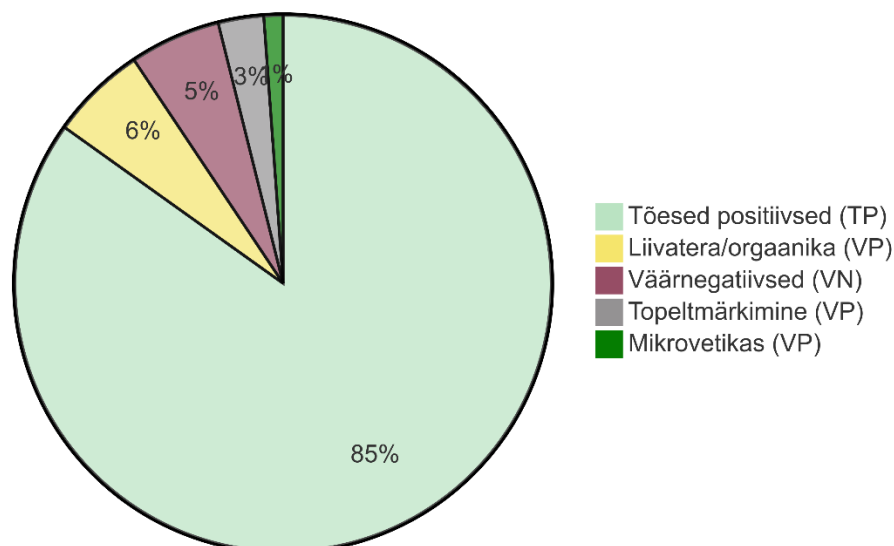
Meiobentose tuvastamist jätkati F1-skoori põhjal valitud Faster R-CNN mudeliga, mis oli treenitud 28 epohhi jooksul. Testandmetel rakendamisel tuvastas see mudel 1 tõeselt (ingl *true positives*) 589 meiobentose esindajat andmestikus realselt esinevast 627-st organismist (tabel 5). Tuvastamata jäi 38 organismi (väärnegatiivsed, ingl *false negatives*). Valepositiivseid

tuvastusi oli kokku 67 (joonis 8), neist 40 korral pakkus mudel organismiks liivatera või lagunevat orgaanikat, kaheksal korral tuvastas mudel mikrovetika ja 19 korral märgiti (tuvastati) üks ja sama organism mitmel korral (edaspidi topeltmärgimine). Treening- ja valideerimisandmestikus polnud mikrovetikad piisavate ekspertteadmiste puudumise tõttu organismidena märgendatud, kuigi ka neid võib meiobentose hulka arvestada.

Tabel 5. Parimate Faster R-CNN ja YOLO11 mudelite testandmetel rakendamise tulemused.

Mudel	Testandmetes organisme kokku	Õige klass ja asukoht	Tuvastamata organismid	Muu objekt organismiks tuvastatud	Topeltmärgimised	Vale objekti-klass
Faster R-CNN mudel 1	627	589	38	42	19	-
Faster R-CNN mudel 2 (9 klassi)	627	524	41	65	56	82
Faster R-CNN mudel 2 (8 klassi)	627	541	35	56	49	58
YOLO mudel 1	627	552	75	42	10	-
YOLO mudel 2 (9 klassi)	627	468	101	38	21	67
YOLO mudel 2 (8 klassi)	627	506	76	38	12	50

Üheksa objektiklassiga andmestiku puhul jäi mõlemal närvivõrgul (nii YOLO kui Faster R-CNN) rohkem organisme tuvastamata/identifitseerimata kui 1-klassilise andmestikuga tuvastusmudelite puhul (tabel 5). Kui objektiklasside arvu vähendati kaheksani, suurenes tuvastatud ja identifitseeritud organismide arv. Parim 8-klassilise andmestikuga Faster R-CNN mudel tuvastas õigesti nii organismirühma kui asukoha fotol ligikaudu 86,3% juhtudest, samas kui parim YOLO11 mudel saavutas tulemuseks umbes 80,7%. Faster R-CNN puhul esines sagedamini topeltmärgimisi, eriti ümarusside ja kahetiivaliste vastsete puhul, mistõttu hinnati organismide koguarvu testfotodel sageli tegelikust suuremaks.



Joonis 8. Faster R-CNN mudeli tuvastustulemused testandmetel (meiobentos)

Nagu eelnevalt välja toodud, oli üheksat objektiklassi tuvastavatel mudelitel kõige enam raskusi ripskõhtsete õige tuvastamisega. Need mudelid kippusid ka teisi organisme ripskõhtseteks pakkuma (nii YOLO kui Faster R-CNN mudelid), märkides testandmetel enam kui 20 organismi ripskõhtseteks, kuigi tegelikult oli ripskõhtne vaid ühel fotol. Õigesti tuvastamisel keerukuselt järgmiseks rühmaks osutusid lüljalgsed (*Arthropoda*). Parimatel Faster R-CNN objektiklasse identifitseerivatel mudelitel oli selle rühma F1-skoor ligikaudu 0,71. Ka YOLO mudelitel oli raskusi lüljalgsete identifitseerimisel: üheksat objektiklassi tuvastav YOLO tuvastas õigesti testfotodest vaid viis lüljalgset 28-st (enamus jäi mudelil leidmata). Kaheksat objektiklassi identifitseeriv YOLO sai paremini hakkama ja identifitseeris õigesti 15 lüljalgset. Treeningandmetes ei ole lüljalgsed vähemesindatud rühmade hulgas, neid oli rohkemal fotodel kui loimureid (*Tardigrada*), kelle tuvastamisega said mudelid hästi hakkama (kaheksat objektiklassi sisaldava Faster R-CNN mudel 2 F1-skoor loimurite kohta oli isegi ~0,97). Aga erinevalt loimuritest sisaldab lüljalgsete rühm väga erineva välimuse ja suurusega organisme, ka kasutatud andmestikus: näiteks aerjalalised, kahetiivaliste vastsed ja vesilestad on kõik väga erineva välimusega. See ilmselt teeb keeruliseks lüljalgsete rühma korrektselt identifitseerivate mudelite treenimise.

Suurema osa topeltmärkimistest võib jagada kahte kategooriasse:


1) pika kehaga ja/või suhteliselt suured organismid (ümarussid, kahetiivaliste vastsed), kelle puhul üks tuvastusruut sisaldas kogu või suuremat osa organismist ja teine (või teised) väiksemaid osi organismist (joonis 9);

2) organismid, kelle puhul oli mitu tuvastusruutu peaaegu kattuvalt samas kohas (joonis 10).



Joonis 9. Treenitud mudel on ühe ümarussi kohta teinud kaks tuvastusruutu, üks neist sisaldab vaid poolt organismist.

Ka Martin jt (2023) treenitud Faster R-CNN mudelitel oli raskusi haruldasemate rühmade tuvastamisega ning samuti esines topeltmärkimisi. Kahjuks ei pakkunud nemad paremate tulemusteni jõudmisel välja midagi peale treeningandmete lisamise, muuhulgas ka andmete rikastamise abil. Martin jt (2023) töös toodud näidete topeltmärkimised olid sarnased joonisel 9 ja 10 toodud näidetele.



Joonis 10. Treenitud mudel on teinud kaks tuvastust fotol (väljalõige testfotost) peaaegu samas kohas, üks neist väär. Pildil on ogadega keriloom (objektiklass *rotifera*).



Joonis 11. Treenitud mudel on teinud kaks tuvastust fotol (väljalõige testfotost) peaaegu samas kohas, mõlemad on õigesti tuvastatud organismid (ümaruss ja keriloom).

Topeltmärkimiste, kus pika kehaga organism on tuvastatud nii tervikuna kui ka lisaks tuvastatud organismina mingi selle osa (joonis 9), vähendamiseks kõige tõhusam viis on ilmselt treeningandmete täiendamine võimalikult erinevates asendites ja kehakujuga näidetega. Topeltmärkimiste teise nimetatud kategooria puhul, kus mudel on tuvastanud sama organismi peaaegu samast asukohast pildil mitu korda, saaks tulemuste parandamiseks rakendada kattuvate tuvastuste väljafiltreerimist, jättes alles vaid kõrgeima usaldusväärsusega tuvastuse. Näiteks kui mudel ennustab rohkem kui 80-90% kattuvusega mitu objekti (nagu joonisel 10), siis tõenäoliselt on tegemist topeltmärkimisega ja ennustatud asukohas on pildil vaid üks organism. Samas võib sellisel väljafiltreerimisel olla oht, et filtreeritakse välja mõni ennustus, kus tegelikult ongi samas asukohas mitu organismi (joonis 11). Siiski, joonisel 11 on tuvastusruudud nii erineva suurusega, et kui välja filtreerida vaid need tuvastused, kus tuvastusruudud on samaaegselt nii enam-vähem sama suurusega kui samas asukohas, jääks joonisel 11 näidatud organismide tuvastused korrektselt alles.

Muude objektide organismiks tuvastamist aitaks vähendada, kui tõsta arvesse minevate tuvastuste usaldusväärsuse piirväärtust (hetkel on 0,5 - kui mudeli tuvastuse usaldusväärsus on alla 0,5, siis jäetakse see tuvastus arvesse võtmata). Kuna YOLO mudelite puhul oli madalama usaldusväärsusega korrektseid tuvastusi rohkem ja samas vähem muude objektide organismiks

tuvastamisi, siis oleks piirväärtuse tõstmist mõistlik proovida eelkõige Faster R-CNN mudelite rakendamisel.

3.3 Mikroskoobi suurenduse mõju organismide tuvastamisele

Mikroskoobi suurendus mõjutas oluliselt organismide tuvastamist. Selle kontrollimiseks oli testandmestikku lisatud mikroskoobi 800-kordse ja 100-kordse suurendusega pildid (valdav enamus fotosid treening- ja valideerimisandmetes olid pildistatud mikroskoobi 160-kordse suurendusega). Mudelite tulemused testandmestikul jagati fotode suurenduse (800×, 100×, 160×) järgi kolme kategooriasse:

- 800-kordse suurendusega fotodel tuvastas Faster R-CNN mudel kõik 24 organismi õigesti, kuid kahel juhul tuvastas organismi topelt, pidades teisel korral organismiks vaid osa tegelikust isendist. YOLO mudel tuvastas ühe organismi topelt ja jättis kaks leidmata.
- 100-kordse suurendusega piltide puhul jäi Faster R-CNN mudelil 73-st organismist tuvastamata 10. YOLO mudel jättis leidmata 20 organismi ja üks märgiti topelt.
- 160-kordse suurendusega piltide puhul (enamik fotosid) tuvastas Faster R-CNN mudel õigesti 504 organismi 530-st ehk umbes 95,1% ning märkis 17 organismi topelt ja 40 juhul tuvastas ekslikult organismina liivatera, mikrovetika või laguneva orgaanika. YOLO mudel tuvastas samadelt fotodelt 477 organismi, mis moodustab umbes 90% kõigist meiobentose esindajatest testandmestikus.

Kui 800-kordse suurendusega fotodelt suutsid kõik testandmetel rakendatud mudelid enamuse organisme üles leida, siis õige rühma määramine osutus keeruliseks. Kumbki testitud Faster R-CNN mudel ei suutnud fotodel esinevast 24 organismist õigesse rühma identifitseerida rohkem kui kaks ümarussi. Suurema suurenduse korral ei saanud õige objektiklassi identifitseerimisega paremini hakkama ka YOLO mudelid, aga lisaks jäi nendel mudelitel ka osa organismidest üles leidmata, eriti kaheksa objektiklassiga YOLO mudelil (24 organismist leidis üles vaid 8 ja neist vaid kolm tuvastas õige rühma esindajatena). Sarnaselt vaid organisme tuvastavatele mudelitele jäi ka eri organismirühmi identifitseerivatel mudelitel 100-kordse suurendusega tehtud fotodelt rohkem organisme leidmata ja õigesti klassifitseerimata kui 160-kordse suurendusega fotodelt (tabel 6). Samuti jäi Faster R-CNN mudelitel vähem organisme leidmata kui YOLO mudelitel, kuid topeltmärgimisi esines rohkem.

Tabel 6. Parimate Faster R-CNN ja YOLO11 mudelite tulemused 100-kordse ja 160-kordse suurendusega pildistatud testfotodel rakendamisel.

Mudel	Testandmetes organisme kokku	Suurendus	Õige klass ja asukoht	Tuvastamata organismid	Topeltmärkimised	Vale klass
Faster R-CNN mudel 2 (9 klassi)	73	100	47	10	8	21
Faster R-CNN mudel 2 (8 klassi)	73	100	54	8	6	14
YOLO mudel 2 (9 klassi)	73	100	40	23	3	13
YOLO mudel 2 (8 klassi)	73	100	48	15	2	11
Faster R-CNN mudel 2 (9 klassi)	530	160	470	27	26	37
Faster R-CNN mudel 2 (8 klassi)	530	160	489	25	41	32
YOLO mudel 2 (9 klassi)	530	160	428	71	16	36
YOLO mudel 2 (8 klassi)	530	160	452	45	10	32

Ripskõhtsete andmestikust eemaldamise järel treenitud mudelid leidsid üles ja identifitseerisid õige rühma esindajana rohkem organisme nii 100 kui 160-kordse suurenduse korral. Kui üldiselt ripskõhtsete andmestikust eemaldamise järel treenitud mudelid eksisid vähem objektiklassi määramisel ja märkisid vähem organisme topelt, esines mingil põhjusel 160-kordse suurendusega fotodel Faster R-CNN 8 klassiga puhul oluliselt rohkem topeltmärkimisi kui Faster R-CNN 9 klassiga puhul.

3.4 Valitud alusmodelite rakendatavus meiobentose automaatseks tuvastamiseks

Mõlemad valitud alusmodelid osutusid sobivateks mikrofotodelt meiobentose organismide automaatseks tuvastamiseks, kuna nii Faster R-CNN kui YOLO puhul õnnestus treenida mudel, mis tuvastas õigesti (ehk organism oligi mudeli tuvastatud asukohas) vastavalt kas ligi 94% või 88% organismidest. Kuigi Faster R-CNN parim mudel tuvastas suurema osa organismidest kui YOLO mudel, on automatiseerimisel oluline ka topeltmärkimiste ja muude vigade hulk. Kui rakendada masinõpet meiobentose proovidest organismide arvu hindamisel, on oluline saada reaalsele võimalikult lähedane arvukuse hinnang. Faster R-CNN mudeli rohkemate topeltmärkimiste tõttu osutusid mõlema alusmodeliga treenitud parimad meiobentost tuvastavad modelid selles osas võrdseteks: Faster R-CNN mudel hindas arvukust samavõrra üle kui YOLO mudel alahindas. Sellegipoolest eksisid arvukuse hindamisel mõlemad modelid vaid ~3,7% võrra.

Ka inimene teeb proovidest organisme loendades ja identifitseerides vigu. Planktiliste ainuraksete dinoflagellaatide fotodelt tuvastamisel suutsid eksperdid (merebioloogid, veeõitsengute spetsialistid) tuvastada õige liigi vaid keskmiselt 72% täpsusega, konkreetselt dinoflagellaatide eksperdid aga 84-95% täpsusega (Culverhouse jt, 2003). Kuigi Culverhouse jt (2003) töös oli ekspertidel pisut teistsugune ülesanne - tuvastada mikrofotodelt konkreetne liik, mitte vaid organismi esinemine - demonstreerib nende töö sellegipoolest, et ka inimesed, isegi eksperdid, ei suuda kuigi täpselt organisme tuvastada. Veel mõnevõrra keerulisema tuvastusülesande puhul, kus tuli leida kambriised (*Foraminifera*, üherakulised planktilised või bentilised organismid) setteosakeste vahelt, oli inimesest tuvastajate täpsus veelgi madalam: ekspertidel 63% ja algajatel 53% (Mitra jt, 2019). Vaid organismi tuvastamine mikroskoobi all loenduskambris, sobivalt ettevalmistatud proovist (nagu kirjeldatud Lokko jt (2014) artikli meetoodika osas), ei ole meiobentose eksperdile üldjuhul keeruline, kuid näiteks väsimuse korral võib sellegipoolest eksimusi esineda. Ka antud töö raames mudelite testandmetel rakendamise tulemusi kontrollides ilmnes mõne foto puhul, et inimesel oleks liivaterade ja detriidi vahele sattunud organism tuvastamata jäänud. Nendel paaril juhul töötas treenitud mudel inimesest paremini ja tuvastas organismi. Niisiis võib parimaid treenitud mudeleid (Faster R-CNN ja YOLO) meiobentose arvukuse hindamiseks juba piisavalt heaks pidada.

Organismirühmade identifitseerimisel jäid parimad modelid mõnevõrra kehvemaks, aga kui arvestada vaid 160-kordse suurendusega tehtud testfotodel saadud tulemusi, siis parim Faster R-CNN mudel (kaheksa objektiklassiga andmestikul treenitud mudel) tuvastas õigesti ~ 92% organismidest ja parim YOLO mudel ~ 85% organismidest, mis mõlemad on paremad

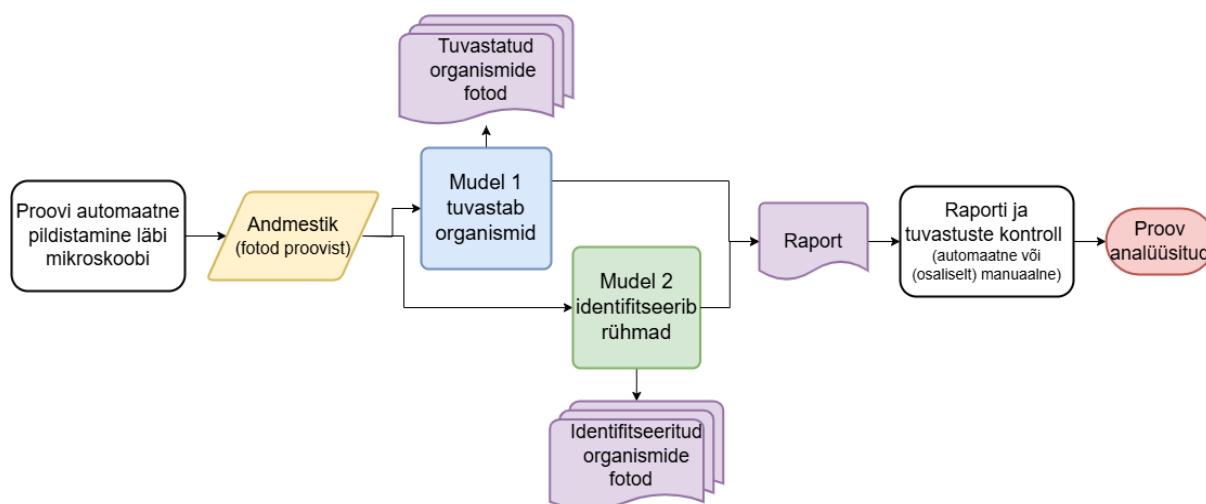
Culverhouse jt (2003) ning Mitra jt (2019) töödes leitud inimesest määrajate tulemused. Siiski, ka ainult organismirühma identifitseerimine ei ole enamasti samavõrd keeruline kui tuvastusülesanded nendes töödes. Kui käesoleva töö treeningandmetele lisada veel märgendatud mikrofotosid, eriti haruldasemate ja välimuselt rohkem varieeruvate rühmade kohta, saaks kindlasti paremad mudelid treenida, mis oleksid vähemalt sama head kui ekspert. Ka juba treenitud mudelite tulemuslikkust saaks parandada, kui välja filtreerida pea täielikult kattuvad tuvastused (nagu joonisel 10) ja pildistamisel kasutada 160-kordsele suurendusele võimalikult lähedast (ideaalis sama) mikroskoobi suurendust. Samuti tuleb silmas pidada, et tavalise valgusmikroskoobiga pildistatud fotodel treenitud mudelid ei pruugi samavõrd hästi töötada mõne teistsuguse mikroskoobiga või pildistamismeetodiga tehtud fotodel, nagu toovad välja ka Eerola jt (2024).

Tulemustest ilmneb, et käesolevas töös kasutatud kahe mudeli süsteem võimaldab täpsemat arvukuse hinnangut olukorras, kus proovides võib esineda väga haruldasi või ka senitundmatuid organismirühmi ja organisme. Potentsiaalselt aitab kahe mudeli rakendamine need organismid (fotod) ka välja tuua, et kasutaja need üle vaataks ja lisaks vajadusel eksperdi hinnangu. Selline kahe mudeli rakendamine oleks potentsiaalseks lahenduseks Eerola jt (2024) nimetatud tundmatute (treeningandmetes mittesisalduvate) organismide tuvastamise probleemile. Nimelt kipuvad CNN-põhised mudelid tuvastama tundmatuid objekte mõne mudelile tuntud objektiklassi esindajana ja ka kõrge usaldusväarsuse hinnanguga (Eerola jt, 2024). Käesolevas töös kasutatud testandmed sisaldasid mõningaid liike (näiteks keriloomade liike), mida treeningandmetes ei esinenud, kuigi vastav rühm, kuhu liik kuulub, oli siiski esindatud. Vähemalt mõlema tuvastusmudeli puhul ei paistnud nende tuvastamine raskusi tekitavat. Kuna tuvastusmudelid treeniti tuvastama vaid organisme, mitte nende täpsemat kuuluvust ja treeningandmed sisaldasid kõiki kümme organismirühma, siis ilmselt on nende mudelite puhul objekti tuvastamisel oluliseks tunnused, mis on ühised kõigile või suuremale osale meiobentose suurusklassi kuuluvatele organismidele. Sellele viitavad ka tuvastusmudeli poolt meiobentosena (organismina) tuvastatud mikrovetikad, mis treeningandmetes ei olnud organismina märgendatud, aga millest enamuse märkis Faster R-CNN mudel meiobentoseks ja osad neist ka YOLO mudel.

3.5 Meiobentose tuvastamise automatiseerimine

Tulemustele tuginedes saab välja pakkuda põhimõttelise süsteemi (joonis 12) meiobentose tuvastamise automatiseerimiseks (proovide automaatne kvantitatiivne analüüs):

1. Kui veekogu põhjasettest võetud proov on analüüsiks ettevalmistatud, kantakse proov (või kindel arv alamproove, kui proovi maht on suur) sobiva suurusega loenduskambrisse.
2. Loenduskambrit liigutatakse automaatselt aeglaselt edasi ning iga mõne hetke järel pildistatakse läbi mikroskoobi, nii et fotod kataksid kogu loenduskambri, aga ei kattuks.
3. Saadud fotodel rakendatakse kahte treenitud masinõppemudelit, millest üks (mudel 1) võimaldab hinnata kogu arvukust ja teine identifitseerib, millisesse rühma organism kuulub (mudel 2).
4. Kui mudelid on töö lõpetanud, on kasutajale genereeritud visualiseeritud tuvastustega fotod ja tulemuste raport, kus on välja toodud ka etteantud piirist madalama usaldusväärsusega tuvastused (näide lisas II), aga kuhu võib lisaks ka välja tuua näiteks teatud määrast rohkem kattuvad organismina tuvastatud alad.
5. Tulemuste (raporti põhjal) automaatne või manuaalne kontroll, vajadusel parandamine ning leitud organismide ja/või rühma kaupa organismide arvukuse proovis arvutamine.



Joonis 12. Süsteem meiobentose proovide kvantitatiivse analüüsi automatiseerimiseks.

Loenduskambri (õigemini esemelaua) automaatse liigutamise süsteeme on ka olemas¹², kuid sellise süsteemi loomine ei tohiks olla kuigi keeruline ka konkreetse loenduskambri ja mikroskoobi jaoks, kui sobiv valmislahendus puudub. Selline süsteem vajaks vaid mõnda mikromootorit ning kontrolleri, mis juhiks mikromootorite tööd nii, et loenduskamber liiguks mikroskoobi esemelaual aeglaselt edasi, kattes liikumisega kogu loenduskambri põhja otsast otsani. Vajadusel saab sobiva suurusega loenduskambri ka ise valmistada.

¹² näiteks motoriseeritud esemelaud 8MTF - Motorized XY Scanning Stage https://www.standa.lt/products/catalog/motorised_positioners?item=311 (02.05.2025), või Piori motoriseeritud esemelaud <https://www.prior.com/imaging-components/motorized-stages> (02.05.2025)

Kokkuvõte

Bakalaureusetöö eesmärgiks oli leida mõni masinõppe mudel, millel oleks hea potentsiaal usaldusväärset ja täpselt mikrofotodelt meiobentose organisme automaatselt tuvastada ja identifitseerida. Töö teiseks eesmärgiks oli välja pakkuda põhimõtteline süsteem meiobentose tuvastamise automatiseerimiseks.

Meiobentose tuvastamiseks sobivate masinõppemudelite hindamiseks koostati mikrofotodest andmestik, mis jagati märgendatud treening- ja valideerimisandmeteks ning märgendamata testandmeteks. Kirjanduse ja andmete iseloomu põhjal valiti välja kaks masinõppemudelit: Faster R-CNN ja YOLO. Nende alusmudelitega trenniti treeningandmetel mudelid, mis tuvastavad meiobentose organismid ja identifitseerivad millisesse rühma organism kuulub. Mudelite treenimise, hindamise, ennustuste visualiseerimise ja märgendite konverteerimise programmide koostamisel kasutati tehisintellekti abi.

Haruldaste liikide ja organismirühmade arvessevõtmiseks tuvastusvõimekuses kaotamata trenniti kaks eraldi mudelit mõlema alusmudeliga: mudel 1 tuvastas organismide olemasolu sõltumata nende taksonist ning mudel 2 määras ka organismide taksonoomilise kuuluvuse. Parimad mudelid 1 eksisid testandmetel organismide arvu hindamisel vaid ~3,7% võrra. Kusjuures Faster R-CNN mudel pisut ülehindas ja YOLO mudel alahindas organismide arvu fotodel. Seega võib juba mõlema alusmudeliga trennitud mudeleid kasutada meiobentose arvukuse hindamiseks mikrofotodelt, kui kasutada treeningandmetele võimalikult lähedast mikroskoobi suurendust. Treeningandmetest erineva mikroskoobi suurendusega pildistatud testandmetel osutusid mudelid märgatavalt kehvemaks. Õige taksonoomilise kuuluvuse määramine osutus pisut raskemaks ülesandeks, aga peale kahe haruldase rühma eemaldamist suutsid Faster R-CNN mudel ja YOLO mudel tuvastada ülejäänud kaheksa taksoni esindajad testfotodelt õigesti vastavalt 86,3% ja 80,7% juhtudest. Tulemuste peatükis on võrreldud käesolevas töös trennitud mudelite headust seniste makrobentost ja planktonit tuvastavate masinõppemudelitega ja välja toodud, et käesolevas töös meiobentose tuvastamiseks trennitud mudelid ei jää alla seni makrobentose ja planktoni tuvastamiseks trennitud mudelitele. Seega osutusid nii Faster R-CNN kui YOLO sobivateks mikrofotodelt automaatselt tuvastamiseks ja identifitseerimiseks.

Tulemuste peatükis kirjeldati ka väljapakutud süsteemi meiobentose tuvastamise automatiseerimiseks, alustades analüüsiks ettevalmistatud, loenduskambrisse kantud proovidest. Samuti pakuti välja viise, mis võiksid meiobentose automaatse tuvastamise täpsust veelgi tõsta.

Viidatud kirjandus

- Aarnio, K. (2001). *The role of meiofauna in benthic foodwebs of the northern Baltic Sea*. Åbo: Åbo Akademi University Press.
- Alif, M. A. R., & Hussain, M. (2024). YOLOv1 to YOLOv10: A comprehensive review of YOLO variants and their application in the agricultural domain. <https://arxiv.org/html/2406.10139v1> (20.03.2025)
- Baguley, J. G., Hyde, L. J. ja Montagna, P. A. (2004). A semi-automated digital microphotographic approach to measure meiofaunal biomass. *Limnology and Oceanography: Methods*, 2(6), 181–190. doi:[10.4319/lom.2004.2.181](https://doi.org/10.4319/lom.2004.2.181)
- Buda, M., Maki, A. ja Mazurowski, M. A. (2018). A systematic study of the class imbalance problem in convolutional neural networks. *Neural Networks*, 106, 249–259. doi:[10.1016/j.neunet.2018.07.011](https://doi.org/10.1016/j.neunet.2018.07.011)
- Cerca, J., Purschke, G. ja Struck, T. H. (2018). Marine connectivity dynamics: clarifying cosmopolitan distributions of marine interstitial invertebrates and the meiofauna paradox. *Marine Biology*, 165(8), 123. doi:[10.1007/s00227-018-3383-2](https://doi.org/10.1007/s00227-018-3383-2)
- Ciranni, M., Murino, V., Odone, F. ja Pastore, V. P. (2024). Computer vision and deep learning meet plankton: Milestones and future directions. *Image and Vision Computing*, 143. doi:[10.1016/j.imavis.2024.104934](https://doi.org/10.1016/j.imavis.2024.104934)
- Cowen, R. K., Sponaugle, S., Robinson, K.L., Luo, J., Oregon State University ja Hatfield Marine Science Center (2015). PlanktonSet 1.0: Plankton imagery data collected from F.G. Walton Smith in Straits of Florida from 2014-06-03 to 2014-06-06 and used in the 2015 National Data Science Bowl (NODC Accession 0127422). NOAA National Centers for Environmental Information. Dataset. doi:[10.7289/V5D21VJD](https://doi.org/10.7289/V5D21VJD) (15.03.2025)
- Culverhouse, P. F., Williams, R., Reguera, B., Herry, V. ja González-Gil, S. (2003). Do experts make mistakes? : A comparison of human and machine identification of dinoflagellates. *Marine Ecology Progress Series*, 247, 17–25.
- Dutta A. ja Andrew Zisserman A. (2019). The VIA Annotation Software for Images, Audio and Video. In Proceedings of the 27th ACM International Conference on Multimedia (MM '19), October 21–25, 2019, Nice, France. ACM, New York, NY, USA, 2276–2279. doi:[10.1145/3343031.3350535](https://doi.org/10.1145/3343031.3350535).

- Eerola, T., Batrakhonov, D., Barazandeh, N. V., Kraft, K., Haraguchi, L., Lensu, L., Suikkanen, S., Seppälä, J., Tamminen, T. ja Kälviäinen, H. (2024). Survey of automatic plankton image recognition: challenges, existing solutions and future perspectives. *Artificial Intelligence Review: An International Science and Engineering Journal*, 57(5). doi:[10.1007/s10462-024-10745-y](https://doi.org/10.1007/s10462-024-10745-y)
- Giere, O. (2009). *Meiobenthology: The microscopic motile fauna of aquatic sediments*. Springer-Verlag Berlin Heidelberg.
- Girshick, R., Donahue, J., Darrell, T. ja Malik, J. (2014). Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation. *2014 IEEE Conference on Computer Vision and Pattern Recognition*, Columbus, OH, USA, 580-587. doi:[10.1109/CVPR.2014.81](https://doi.org/10.1109/CVPR.2014.81)
- Girshick, R. (2015). Fast R-CNN. *2015 IEEE International Conference on Computer Vision (ICCV)*, Santiago, Chile, 1440–1448. doi:[10.1109/ICCV.2015.169](https://doi.org/10.1109/ICCV.2015.169)
- He, K., Zhang, X., Ren, S. ja Sun, J. (2016). Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 770–778. doi:[10.1109/CVPR.2016.90](https://doi.org/10.1109/CVPR.2016.90)
- Kuhn, M. ja Johnson, K. (2013). *Applied Predictive Modeling*. Springer
- LeCun, Y., Bengio, Y. ja Hinton, G. (2015). Deep learning. *Nature: International Weekly Journal of Science*, 521(7553), 436–444. doi:[10.1038/nature14539](https://doi.org/10.1038/nature14539)
- Lokko, K. ja Virro, T. (2014). The structure of psammic rotifer communities in two boreal lakes with different trophic conditions: Lake Võrtsjärv and Lake Saadjärv (Estonia). *Oceanological and Hydrobiological Studies*, 43(1), 49–55. doi:[10.2478/s13545-014-0116-0](https://doi.org/10.2478/s13545-014-0116-0)
- Lokko, K., Virro, T. ja Kotta, J. (2014). Taxonomic composition of zoopsammon in fresh and brackish waters of Estonia, a Baltic province ecoregion of Europe. *Estonian Journal of Ecology*, 63(4), 242–261. doi:[10.3176/eco.2014.4.04](https://doi.org/10.3176/eco.2014.4.04)
- Lumini, A. ja Nanni, L. (2019). Deep learning and transfer learning features for plankton classification. *Ecological Informatics*, 51, 33–43. <https://doi.org/10.1016/j.ecoinf.2019.02.007>
- Luo, J. Y., Guigand, C., Cowen, R. K., Irisson, J.-O., Graham, B., Sarafraz, A. ja Mader, C. (2018). Automated plankton image analysis using convolutional neural networks. *Limnology and Oceanography: Methods*, 16(12), 814–827. doi:[10.1002/lom3.10285](https://doi.org/10.1002/lom3.10285)

Martin, A., Blettery, J., Rosset, N. ja Gousseau, Y. (2023). Using deep-learning for automatic identification of images of marine benthic macro-invertebrate bycatch: A proof of concept. *Cybium*, 47(3), 335–341. doi:[10.26028/cybium/2023-021](https://doi.org/10.26028/cybium/2023-021)

Mitra, R., Marchitto, T. M., Ge, Q., Zhong, B., Kanakiya, B., Cook, M. S., Fehrenbacher, J. S., Ortiz, J. D., Tripathi, A. ja Lobaton, E. (2019). Automated species-level identification of planktic foraminifera using convolutional neural networks, with comparison to human performance. *Marine Micropaleontology*, 147, 16–24. doi:[10.1016/j.marmicro.2019.01.005](https://doi.org/10.1016/j.marmicro.2019.01.005)

OpenAI. (2024). ChatGPT (March 2024 version) [Large language model].
<https://chat.openai.com/>

Orenstein, E.C., Kenitz, K.M., Roberts, P.L.D., Franks, P.J.S., Jaffe, J.S. ja Barton, A.D. (2020). Semi- and fully supervised quantification techniques to improve population estimates from machine classifiers. *Limnology and Oceanography, Methods*, 18(3), 739-753.
doi:[10.1002/lom3.10399](https://doi.org/10.1002/lom3.10399)

Pastore, V. P., Ciranni, M., Bianco, S., Fung, J. C., Murino, V. ja Odone, F. (2023). Efficient unsupervised learning of biological images with compressed deep features. *Image & Vision Computing*, 137, N.PAG. doi:[10.1016/j.imavis.2023.104764](https://doi.org/10.1016/j.imavis.2023.104764)

Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., Chintala, S., jt (2019). PyTorch: An Imperative Style, High-Performance Deep Learning Library. *Advances in Neural Information Processing Systems*, 32, 8026-8037. doi:[10.48550/arXiv.1912.01703](https://doi.org/10.48550/arXiv.1912.01703)

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M. ja Duchesnay, É. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825-2830.

Redmon, J., Divvala, S., Girshick, R. ja Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 779–788. doi:[10.1109/CVPR.2016.91](https://doi.org/10.1109/CVPR.2016.91)

Ren, S., He, K., Girshick, R. ja Sun, J. (2017). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1137–1149. doi:[10.1109/TPAMI.2016.2577031](https://doi.org/10.1109/TPAMI.2016.2577031)

Schratzberger, M. ja Ingels, J. (2018). Meiofauna matters: The roles of meiofauna in benthic ecosystems. *Journal of Experimental Marine Biology and Ecology*, 502, 12–25.

doi:[10.1016/j.jembe.2017.01.007](https://doi.org/10.1016/j.jembe.2017.01.007)

Segers, H. (2007). Annotated checklist of the rotifers (Phylum Rotifera), with notes on nomenclature, taxonomy and distribution. *Zootaxa*, 1564, 1–104.

doi:[10.11646/zootaxa.1564.1.1](https://doi.org/10.11646/zootaxa.1564.1.1)

Sosik, H.M., Peacock, E.E. ja Brownlee, E.F. (2022). WHOI-plankton: annotated plankton images - dataset for developing and evaluating classification methods.

<https://hdl.handle.net/10.1575/1912/7341> (10.03.2025)

Thomsen, L. (1991). Treatment and splitting of samples for bacteria and meiofauna biomass determinations by means of a semi-automatic image analysis system. *Marine Ecology Progress Series*, 71(3), 301–306.

van der Heijden, L. H., Lebreton, B., Asmus, R. M., Asmus, H., Niquil, N., Haraldsson, M., Pacella, S. R., Graeve, M., Rzeznik-Orignac, J. ja Saint-Béat, B. (2020). Quantitative food web modeling unravels the importance of the microphytobenthos-meiofauna pathway for a high trophic transfer by meiofauna in soft-bottom intertidal food webs. *Ecological Modelling*, 430. doi:[10.1016/j.ecolmodel.2020.109129](https://doi.org/10.1016/j.ecolmodel.2020.109129)

Zhang, J., Yongpan, W., Xianchong, X., Yong, L., Lyu, L. ja Wu, Q. (2022). YoloXT: A object detection algorithm for marine benthos. *Ecological Informatics*, 72.

doi:[10.1016/j.ecoinf.2022.101923](https://doi.org/10.1016/j.ecoinf.2022.101923)

Zhang, W., Rui, F., Xiao, C., Li, H. ja Li, Y. (2024). JF-YOLO: the jellyfish bloom detector based on deep learning. *Multimedia Tools and Applications*, 83(3), 7097–7117.

doi:[10.1007/s11042-023-15465-z](https://doi.org/10.1007/s11042-023-15465-z)

Lisad

I. ChatGPT abil Faster R-CNN ja YOLO programmi arendamine

Avalikus GitHub repositooriumis https://github.com/kyllilokko/Meiobenthos_autodetection on mudelite treenimiseks ja mõõdikute arvutamiseks kasutatud programmid, samuti mudelite tulemuste visualiseerimise ja raporti koostamise programm ning märgendite konverteerimise programm. Samas repositooriumis on vestlusroboti abil Faster R-CNN ja YOLO11 programmi arendamise sisendid (promptid) ja vestlusroboti vastused, failis ChatGPT vestlused.pdf.

II. Näide tulemuste raportist

Treenitud mudelite rakendamise programm (*visualize_predictions.py*) genereerib raporti mudelite rakendamise tulemustest iga sisendiks olnud pildi kohta. Alljärgnevalt on toodud näide YOLO mudelite rakendamise tulemuste raportist (MS Excel failist esimesed 20 rida).

Image File Name	Model 1: Detected Organisms	Model 1: Alert (Score < 0.75)	Model 2: Detected Organisms	Model 2: Alert (Score < 0.75)
30181351.JPG	meiofauna		Testacea	
30181449-40x10.JPG	meiofauna		gastrotricha	
SJV_Copepoda_4633 - Copy.jpg	meiofauna		arthropoda	
SNC12809_no_animals.JPG	meiofauna		None	
SNC12810_no_animals.JPG	None		None	
SNC12883_no_animal.JPG	meiofauna		ciliate	
SNC12893_no_animals.JPG	meiofauna		Testacea, ciliate	0.52
SNC12924_no_animals.JPG	meiofauna		Testacea	
SNC12976_no_animals.JPG	None		None	
SNC13014_no_animals.JPG	meiofauna		None	
SNC13051_no_animals.JPG	meiofauna		Testacea	
SNC13389-40x20.JPG	meiofauna		gastrotricha	

SNC13407-40x20.JPG	meiofauna		nematode, gastrotricha	0.56
SNC13410-40x20.JPG	meiofauna		gastrotricha	
SNC13431-40x20.JPG	meiofauna		turbellarians	0.56
SNC13497-40x20.JPG	meiofauna		arthropoda, gastrotricha	0.56
SNC13554-40x20.JPG	meiofauna		gastrotricha	
SNC13556_40x20.JPG	meiofauna		gastrotricha	
SNC13659.JPG	meiofauna		gastrotricha	0.59

III. Litsents

Lihtlitsents lõputöö reprodutseerimiseks ja üldsusele kättesaadavaks tegemiseks

Mina, Külli Lokko,

1. annan Tartu Ülikoolile tasuta loa (lihtlitsentsi) minu loodud teose
“Meiobentose hulka kuuluvate organismide automaatne tuvastamine masinõppe meetoditega”,
mille juhendaja on Ljubov Jaanuska,
reprodutseerimiseks eesmärgiga seda säilitada, sealhulgas lisada digitaalarhiivi DSpace kuni autoriõiguse kehtivuse lõppemiseni.
2. Annan Tartu Ülikoolile loa teha punktis 1 nimetatud teos üldsusele kättesaadavaks Tartu Ülikooli veebikeskkonna, sealhulgas digitaalarhiivi DSpace kaudu Creative Commons'i litsentsiga CC BY NC ND 3.0, mis lubab autorile viidates teost reprodutseerida, levitada ja üldsusele suunata ning keelab luua tuletatud teost ja kasutada teost ärieesmärgil, kuni autoriõiguse kehtivuse lõppemiseni.
3. Olen teadlik, et punktides 1 ja 2 nimetatud õigused jäävad alles ka autorile.
4. Kinnitan, et lihtlitsentsi andmisega ei riku ma teiste isikute intellektuaalomandi ega isikuandmete kaitse õigusaktidest tulenevaid õigusi.

Külli Lokko

11.05.2025