

TALLINNA TEHNIKAÜLIKOOL
Infotehnoloogia teaduskond

Jaagup Vaht 206498IACB

Veealuse video tausta lahutamine järelevalveta segmenteerimiseks

Bakalaureusetöö

Juhendaja: Elizaveta
Dubrovinskaya
PhD

Tallinn 2023

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: Jaagup Vaht

15.05.2023

Annotatsioon

Tausta lahutamine on oluline probleem arvutinägemises, kuna see võib hõlbustada mitmesuguseid ülesandeid, näiteks liikuvate objektide tuvastamist, jälgimist ja klassifitseerimist. Tausta lahutamine veealustes videotes sisaldab endas siiski palju probleeme, mis tulenevad veekeskkonna dünaamilisest ja keerulisest olemusest, näiteks lainetavatest objektidest, halbadest valgustustingimustest ja mittestatsionaarsest taustast.

Käesolevas töös tegeleme veealuse videote tausta lahutamise probleemiga, vaadates läbi olemasolevad meetodid, andmekogumid ja mõõdikud ning rakendades ja hinnates kuute algoritmi.

Töö raames viiakse läbi kirjanduse ülevaade, et analüüsida sarnastel teemadel tehtud uurimusi ning nende tulemusi, probleeme ja meetodikat.

Järgmiseks analüüsitakse saadalolevaid vabavaralisi andmekogumeid ja valitakse kõige sobivamad meie tööks: Luderick Seagrass ning Deepfish. Valitud andmekogumid konverteeritakse eksperimentide läbiviimiseks kohandatud formaati.

Kirjanduse ülevaatest tuleneb eksperimentides mudelite tõhususe hindamiseks kasutatud mõõdik *intersection over union*. Lisaks sellele mõõdikule on iga andmekogumi kohta välja toodud ka aeg, mis kulus mudeli rakendamiseks andmekogumile.

Töö eelviimases osas on välja ehitatud töövoog, mis võimaldab efektiivselt testida kuute valitud mudelit: *Gaussian Mixture Model* (edaspidi GMM), *K-nearest neighbours algorithm* (edaspidi KNN), *CouNT* (edaspidi CNT), *Global Motion-based Model* (edaspidi GMG), *Google Summer of Code* (edaspidi GSOC) ja *Local Singular Value Decomposition Binary Patterns* (edaspidi LSBP),

Töö viimases osas on teostatud ülevaade ning andmeanalüüs eri mudelite tõhususest ja ajakulust. Leitakse, et neli mudelit näitavad sarnaseid tulemusi (GMM, GSOC, LSBP ja KNN) ning nendest kaks (GMM, KNN) on näidanud paremat tulemuslikkust arvutusliku töömahu osas.

Kokkuvõttes annab see töö põhjaliku ülevaate olemasolevatest meetoditest tausta lahutamiseks ning ülevaate nende efektiivsusest veealuste videote puhul. Töö võib olla referentsiks teadlastele ning töötajatele paljudes valdkondades, sealhulgas mereökoloogia, veealuse robotika või mereseire valdkonnas.

Lõputöö on kirjutatud Eesti keeles ning sisaldab teksti 30 leheküljel, 6 peatükki, 18 joonist, 5 tabelit.

Abstract

Underwater video background subtraction for unsupervised segmentation

Background subtraction is an important problem in computer vision as it can facilitate a variety of tasks such as detecting, tracking and classifying moving objects. However, background subtraction in underwater video presents many problems due to the dynamic and complex nature of the aquatic environment, such as undulating objects, poor lighting conditions and non-stationary backgrounds.

In this work, we address the problem of background subtraction in underwater videos by reviewing existing methods, datasets and metrics, and by implementing and evaluating six algorithms.

A literature review is conducted to analyze studies on similar topics and their results, problems and methodology.

The next step is to analyse the available open source datasets and select the most suitable for our work: Luderick Seagrass and Deepfish. The selected datasets will be converted into a format adapted to the experiments.

From the literature review, we derive the metric used in the experiments to evaluate the effectiveness of the models, namely intersection over union. In addition to this metric, the time taken to apply the model to the dataset is reported for each dataset.

In the penultimate part of the paper, a workflow has been built to efficiently test six selected models: the Gaussian Mixture Model (hereafter GMM), the K-nearest neighbours algorithm (hereafter KNN), CouNT (hereafter CNT), the Global Motion-based Model (hereafter GMG), the Google Summer of Code model (hereafter GSOC) and the Local Singular Value Decomposition Binary Patterns model (hereafter LSBP),

In the last part of the paper, an overview and data analysis of the performance and time cost of the different models has been carried out. It is found that four models show similar

results (GMM, GSOC, LSBP and KNN) and two of them (GMM, KNN) have shown better performance in terms of computational workload.

In conclusion, this work provides a comprehensive overview of existing methods for background subtraction and insight into their effectiveness for underwater videos. The work can serve as a reference for researchers and practitioners in many fields, including marine ecology, underwater robotics or marine surveillance.

The thesis is in Estonian and contains 30 pages of text, 6 chapters, 18 figures, 5 tables.

Lühendite ja mõistete sõnastik

GMM	<i>Gaussian Mixture Model</i> , tausta lahutamise mudel
KNN	<i>K-nearest neighbours</i> , tausta lahutamise mudel
IoU	<i>Intersection over union</i> , tausta lahutamise mõõdik
GSOC	<i>Google Summer of Code</i> , tausta lahutamise mudel
GMG	<i>Global Motion-based Model</i> , tausta lahutamise mudel
CNT	<i>Count-based Nearest Neighbours</i> , tausta lahutamise mudel
LSBP	<i>Local Singular Value Decomposition Patterns</i> , tausta lahutamise mudel
<i>Bounding box</i>	piirjoonte abil määratud kast, mis ümbritseb objekti pildidel või videotes.
<i>precision</i>	mõõde, mis kirjeldab klassifitseerimise meetodi või mudeli suutlikkust leida õigeid positiivseid tulemusi
<i>recall</i>	kirjeldab mudeli suutlikkust leida kõik positiivsed tulemused
<i>F1 score</i>	Harmoniline keskmine <i>precision</i> ja <i>recall</i> mõõdikutest

Sisukord

1 Sissejuhatus	11
2 Eelnevad uurimused	13
3 Andmekogumid	15
3.1 Andmekogumite otsing ja nõuded.....	15
3.2 Andmekogumite eeltötlus.....	16
4 Kasutatud mudelid ja meetodika	19
4.1 Tausta lahutamise mudelid	19
4.2 Mõõdikud.....	19
4.3 Töövoog.....	21
5 Tulemused ja analüüs	25
5.1 Esmased testid	25
5.2 Testimine koos täpsete parameetrite ja filtritega.....	28
5.2.1 Kasutatud filtrid ja tehnikad	28
5.2.2 Tulemused filtrite rakendamisel	29
5.3 Anomaaliade analüüs.....	32
5.3.1 Deepfish andmekogumi anomaaliad	33
5.3.2 Luderick andmekogumi anomaaliad	34
5.4 Järeldused	39
6 Kokkuvõte	41
Kasutatud kirjandus	43
Lisa 1 – Lihtlitsents lõputöö reprodutseerimiseks ja lõputöö üldsusele kättesaadavaks tegemiseks	45
Lisa 2 – Luderick andmekogumi graafik kõigi mudelitega.....	46
Lisa 3 – Deepfish andmekogumi graafik kõigi mudelitega.....	47

Jooniste loetelu

Joonis 1 Kaadrid videost (Luderick andmekogum) ning tekitatud esiplaani kaadrid (paremal) [7].....	17
Joonis 2 Näide video kaadrist ning esiplaani maskist (Deepfish andmekogum) [8].....	17
Joonis 3 Näide IoU mõõdikust [16].....	20
Joonis 4 Üldine töövoog mudeli hindamisel	21
Joonis 5 Töövoos avanev valikuline aken (üleväl pool mudelid väljund, allpool tõene mask)	22
Joonis 6 OpenCV Mudelite testimise töövoog.....	23
Joonis 7 Mudelite esmase testimise kiiruse ja ajakulu suhted (Luderick andmekogum) 27	
Joonis 8 Näide tekitatud esiplaani maskist ilma filtrite rakendamiset.....	28
Joonis 9 Näide tekitatud esiplaani kaadrist koos filtrite rakendamisega.....	28
Joonis 10 Kulunud aja ja IoU skooride graafik filtritega mudeleid rakendades Luderick andmekogumile.	31
Joonis 11 Mudelite väljundid Deepfish andmekogumis.....	33
Joonis 12 Kaader anomaalia tekitanud videost.....	34
Joonis 13 Luderick andmekogumi IoU skoorid video järgi	35
Joonis 14 Video 8 Luderick andmekogumist	36
Joonis 15 Luderick andmekogumi video 19 tuvastatud esiplaan	37
Joonis 16 Luderick andmekogumi video 19 anoteeritud esiplaan.....	37
Joonis 17 Luderick andmekogum: kaader videost 19	38
Joonis 18 GMM mudeli esiplaan ning tõene esiplaan (Luderick andmekogumi video 12)	39

Tabelite loetelu

Tabel 1 OpenCV pakutavad tausta lahutamise mudelid.....	19
Tabel 2 OpenCV mudelite esmase testimise tulemused Luderick andmekogumi peal...	26
Tabel 3 OpenCV mudelite esmase testimise tulemused DeepFish andmekogumi peal..	26
Tabel 4 OpenCV mudelite rakendus koos filtritega Luderick andmekogumi peal	30
Tabel 5 OpenCV mudelite rakendus koos filtritega DeepFish andmekogumi peal	32

1 Sissejuhatus

Keskkonna jälgimine on tähtis, et täiendada meie teadmisi loodusest ning kaitsta planeeti ja sellel elavaid liike. See võimaldab jälgida inimeste mõju keskkonnale ning jälgida kliimamuutusi. Heade keskkonna jälgimise süsteemidega on võimalik seda teha minimaalse inimsekkumisega.

Veealuse keskkonna jälgimine on veelgi raskendatud, sest kogu süsteemi märkamatu ja hea töötamine peab toimuma vee all. Vee alla on raske jõuda selliste süsteemidega, mida oleks võimalik kasutada maa peal ning selle pärast on vaja leida häid viise, mis võimaldavad efektiivset keskkonna jälgimist ka veealuses keskkonnas.

Videopõhine keskkonna jälgimise süsteem on hea ja mittesekkuv süsteem, et aru saada, mis veealuses keskkonnas toimub. Neid eristab tavalisest video järelvalve süsteemist see, et liikumine on pidev, tekivad erinevad valguskonditsioonid ning neid mõjutab vee turbiidsus.

Keskkonna jälgimisel on tavaliselt huvi pakkuvateks objektideks liikuvad objektid ning sellepärast on vaja leida viise, kuidas eristada liikuvaid objekte taustast.

Üks viis, kuidas tuvastada videosüsteemides liikumist on kasutada tausta lahutamise algoritme. Nende algoritmide põhjal on välja töötatud mitmeid rakendusi, mis tegelevad liikumise tuvastamisega ja liikuvate objektide kuju ja asukoha tuvastamisega.

Bakalaureusetöö eesmärgiks on uurida millised algoritmid tausta eemaldamiseks on kõige tõhusamad veealuste videote puhul arvestades veealuse keskkonna eripärasid. Selle analüüsi teostamiseks on tööl neli osa.

Esimeseks osaks on kirjanduse ülevaade, et näha milliseid mõõdikuid selliste veealuste videosüsteemide puhul kasutatakse ning kuidas tausta lahutamise algoritmid sinna süsteemi sobituvad.

Teine osa on andmekogumite leidmine ja analüüsimiseks vajalikku formaati seadmine. Andmekogumi puhul on tähtis leida õige ning nõutele vastav kogum andmeid, millel on piisavalt anoteeritud infot kalade asukoha ja asendi kohta videos.

Kolmandas osas tutvustatakse kasutatavat töövoogu ning eri meetodikaid ja mudeleid, mis teemaga seonduvad.

Neljandas osas on läbi viidud uurimus ja analüüs eri tausta lahutamise mudelite efektiivsusest ja jõudlusest ning faktoritest, mis mõjutavad nende efektiivset tööd.

2 Eelnevad uurimused

Eelnevate uurimustöödega sarnasel teemal oli vaja tutvuda, et tuvastada milliseid mõõdikuid, meetodeid ja andmekogumeid on kasutatud ja millised võiks selle töö raames kasulikud olla. Enamike leitud uurimuste puhul oli veealuse video esiplaani tuvastus osa suuremast videosüsteemist.

Uurimuses [1] koostati süsteem kalade tuvastamiseks ja jälgimiseks veealus test videotest. Süsteemi esimeseks osaks oli liikuvate objektide tuvastamine. Selle süsteemi koostamisel testiti erinevaid meetodeid tausta lahutamiseks. Testitud tausta lahutamise mudelite hulka kuulusid: *Adaptive Gaussian Mixture Model* (GMM), *Kernel Density Estimation* (KDE), *Visual Background Extractor* (ViBe). Esimese kahe mudeli rakendamine toimus läbi OpenCV teegi [2] ning neid kasutati vaikeparameetritega. Viimase mudeli rakendus tehti uurimuse käigus ise.

Mõõdikutena olid eelmainitud uurimuse puhul kasutusel *precision* (näitab, kui kasulik on tuvastamine, ehk kas algoritm tuvastab rohkem tõeseid kalu, kui valesid), *recall* (näitab, kui palju päris kaladest õigesti tuvastati) ja *F1 score* (on harmooniline keskmine viimasest kahest mõõdikust). Selleks, et tuvastada, kas tuvastus on tõsipositiivne kasutati mõõdikut *intersection over union* (IoU).

See mõiste kirjeldab meetodit, mis arvutab kahe hulga kattuvuse või sarnasuse protsendi. Kala tuvastus loeti tõsipositiivseks, kui IoU mõõdik oli üle 50%. See protsent arvutati kala ümbritseva *bounding box*-i ja tausta lahutamise mudeli genereeritud *bounding box*-i vahel. Mõõdik on tausta lahutamise valdkonnas laialdaselt kasutatud [3] ning võeti seetõttu kasutusele ka käesolevas töös.

Sarnaselt eelmises uurimuses loodud videosüsteemile kasutati ka uurimuses [4] tausta lahutamise mudeleid, et tõsta kalade loetlemise süsteemi efektiivsust. Selleks testiti mitmeid mudeleid ning valituks osustusid kaks mudelit: liikuva keskmise algoritm ning *Adaptive Gaussian Mixture Model*. Nende kahe algoritmi väljundi järgi valitakse esiplaani tulemusse ainult pikslid, mis esinesid mõlema algoritmi väljundis. Lisaks

kasutati tulemuste parandamiseks pildi töötlemise tehnikaid nagu erosioon ja laiendamine.

Ülevaatlikus uurimuses [5] tuvastati, et peamised asjad, mis takistavad tausta lahutamise mudelite tööd veetaluses keskkonnas on valguse muutused, vee voolust tekkivad nähtused (tornid, hoovused), vee turbiidsus, vetikad (kasv kaamera läätsse peale) ning perioodilised liikumised (näiteks taimede liikumine koos lainetusega).

3 Andmekogumid

3.1 Andmekogumite otsing ja nõuded

Andmekogumi leidmise põhilised nõuded olid, et tegemist oleks veealuste videotega, oleks olemas eelnevalt annoteeritud andmed kalade asukoha ja asendi kohta videos ning, et kaamera oleks video vältel staatiline. Tabelis 1 on välja toodud leitud andmekogumid.

Tabel 1 Otsingust leitud andmekogumite kokkuvõte

Andmekogumi nimi	Kirjeldus
Fishtrac [6]	Veealused videod, mis on kogutud Hawaii saare vetes sukeldujate poolt. Sisaldab annotatsioone iga kaadri kohta. Puudub staatiline kaamera. Kaadri mõõtmed on 1920 ja 1080 pikslit.
Luderick Seagrass [7]	Kogutud Austraalia vetest kasutades staatilisi veealuseid kaameraid. Iga kaadri kohta on annoteeritud info kala asendi ja asukoha kohta. Kaadri mõõtmed on 1920 ja 1080 pikslit.
DeepFish [8]	Veealused videod (kaadrid), millel olemas täielik annotering kala asendi ja asukoha kohta. Kaadri mõõtmed on 1920 ja 1080 pikslit.
Brackish dataset [9]	Veealused videod, millel olemas erinevad liigid (kalad, krabid, krevetid ja muud). Annotatsioonides olemas info ainult kala asukoha kohta (<i>bounding box</i>). Kaadri mõõtmed on 1920 ja 1080 pikslit.
Dataset for Hierarchical Object Detection of Nordic Fish Species [10]	Staatilise kaameraga veealused videod Norrast. Annoteerimise puhul olemas ainult info kala asukoha kohta (<i>bounding box</i>). Kaadri mõõtmed on 1920 ja 1080 pikslit.

Leitud andmekogumitest vastasid paika pandud nõuetele kõige rohkem kaks andmekogumit: Luderick Seagrass [7] ja DeepFish [8].

Ülejäänud andmekogumite puhul esinesid puudused kas kaamera osas või annotatsioonide poolt. Kasutada andmekogumeid, kus on olemas vaid *bounding box*, oleks võimalik, kuid pakuks halvemat ülevaadet mudelite tõhususe kohta.

Mõlema valitud andmekogumi puhul oli tegemist staatiliste veealuste videotega, kus puudus enamjaolt kaamera liikumine. Lisaks oli annoteeritud andmetes täpne info kalade asukoha ja asendi kohta videos, mis võimaldas ideaalselt rakendada valitud *intersection over union* mõõdikut.


Luderick andmekogumis leidis mitu erinevat kogutud andmestiku, koos annotatsioonidega. Nendest valiti töö raames analüüsiks „Jack Evans A“ variant [7].

3.2 Andmekogumite eeltöötlus

Valitud andmekogumid olid saadaval piltide kujul, ehk iga video kaadri kohta oli pilt, mille nimi vastas videole ja selle kaadrile.

Esmase töötamise jaoks kirjutati Python-i skript, mis võttis need pildid ning vastavad andmed kala asukoha ja asendi kohta kaadris ning salvestas need videoformaadis.

Luderick Seagrass andmekogumi puhul olid annotatsiooni andmed antud „csv“ formaadis, seega tuli iga kaadri kohta otsida üles vastav info ning tekitada sellest mustvalge kaader, kus mustal taustale joonistatakse valge täidetud hulknurk vastavalt annotatsioonidest saadud andmetele. Joonisel 1 on näha tekitatud esiplaani kaader ning temale vastav video kaader.



Joonis 1 Kaadrid videost (Luderick andmekogum) ning tekitatud esiplaani kaadrid (paremal) [7]

Deepfish andmekogumi puhul kaasnes iga kaadriga vastav pilt, kus näidatud kala asend ja asukoht mustvalges formaadis. Selle andmekogumi puhul salvestati iga kaadri juures ka temale vastav annoteeritud esiplaani mask eri videosse. Joonisel 2 on näha esiplaani mask ja temale vastav video kaader



Joonis 2 Näide video kaadrist ning esiplaani maskist (Deepfish andmekogum) [8]

Selleks, et efektiivselt kasutada koostatud mudelite testimise töövoogu, salvestati iga andmekogumi videod ja esiplaani maskid vastavalt kaustadesse „videos“ ja „masks“, kus video nimi ning esiplaani maskidest koosneva video nimi on sama. Iga andmekogumi jaoks tehti eraldi kaust, kus paiknesid temale vastavad „videos“ ja „masks“ kaustad. Testimiseks kirjutatud skripti kasutamiseks tuleb anda skriptile info selle kohta, millistes kaustades paiknevad maskid ning videod.

4 Kasutatud mudelid ja meetodika

4.1 Tausta lahutamise mudelid

Töös testiti andmekogumi peal kõiki OpenCV [2] teegi pakutavaid mudeleid. Töö kirjutamise hetkel on OpenCV teegis võimalik kasutada kuute tausta lahutamise mudelit, mis on välja toodud tabelis 1.

OpenCV teegis on mudelid realiseeritud objektidena. Igast mudelist tuleb luua instants ja niimoodi iga video jaoks. Video sisselugemisel kaadrite kaupa kutsutakse iga mudeli peal leiduvat funktsiooni „*apply*“, mis rakendab selle mudeli antud kaadriale ning väljastab mudeli arvutatud esiplaani maski.

Tabel 2 OpenCV pakutavad tausta lahutamise mudelid

OpenCV klass	Mudel
„cv::BackgroundSubtractorMOG2“	<i>Gaussian Mixture Model</i> [11]
„cv::BackgroundSubtractorKNN“	K-lähima naabri algoritm [11]
„cv::bgsegm::BackgroundSubtractorCNT“	„ <i>CouNT</i> “ algoritm. [12]
„cv::bgsegm::BackgroundSubtractorGMG“	„ <i>Geometric Multi-Grid</i> “ algoritm [13]
„cv::bgsegm::BackgroundSubtractorLSBP“	„ <i>Local SVD Binary Pattern</i> “ [14]
„cv::bgsegm::BackgroundSubtractorGSOC“	„ <i>Google Summer of Code</i> “, raames implementeeritud edasiarendus LSBP algoritmist [15]


4.2 Mõõdikud

Mudelite efektiivsuse hindamiseks kasutati kahte mõõdikut, milleks olid *intersection over union* (edaspidi IoU) [3] ja ajaline kulu, mis mudeli rakendamisel tervele andmekogumile tekib.

Aja mõõtmine on vajalik, et saada ülevaade mudelite jõudluse vajadustest. Osade rakenduste jaoks ei ole aeg nii tähtis kui täpsus, samas kui teiste rakenduste puhul on ka ajakulu faktor. Juhul, kui mudelite täpsused on sarnased on hea näha ajakulu, et mudeleid võrrelda. Selle mõõdiku puhul pole selle töö raames tähtis, et aeg andmekogumi analüüsiks oleks võimalikult lühike ja täpselt mõõdetud vaid, et näha suhtelisi väärtusi eri mudelite rakendamise ajakulus samadele andmekogumitele.

Aega mõõdeti kasutades sisseehitatud Python-i teeki „time“, mis võimaldab saada programmil aja mingil hetkel programmis. Iga andmekogumi analüüsi alguses salvestakse alguse aeg ning andmekogumi analüüsi lõpus loetakse uuesti hetke aeg ning lahutatakse sellest algusaeg, et leida terve andmekogumi analüüsimiseks kulunud aeg.

IoU puhul on tegemist väärtusega, mis näitab kui palju kattuvad mudeli väljundi genereeritud esiplaan ning annoteeritud tõesed andmed. Näide on toodud joonisel 3, kus on punasega välja toodud ideaalne tulemus, ehk inimese poolt tuvastatud linna piirjooned ning sinisega välja toodud mingi mudeli väljund.



Joonis 3 Näide IoU mõõdikust [16]

Skriptis, mis kirjutati mudelite testimiseks on IoU mõõdik rakendatud eraldit funktsioonina, mis võtab sisendiks 2 esiplaani maski, mis on antud maatriksite kujul. Esimene nendest on annoteeritud andmete põhjal koostatud ning teine mudeli poolt genereeritud. Mõlemad maskid on mustvalged ehk ainukesed piksliväärtused, mis nendes leiduvad on „0“ või „1“ vastavalt musta ja valge puhul.

Kahe maski vahel tehtakse loogiline „JA“ tehe, et leida osad, kus nad kattuvad ning loogiline „või“ tehe et leida mõlema maski kombineeritud tulemuse ehk valged pikslid

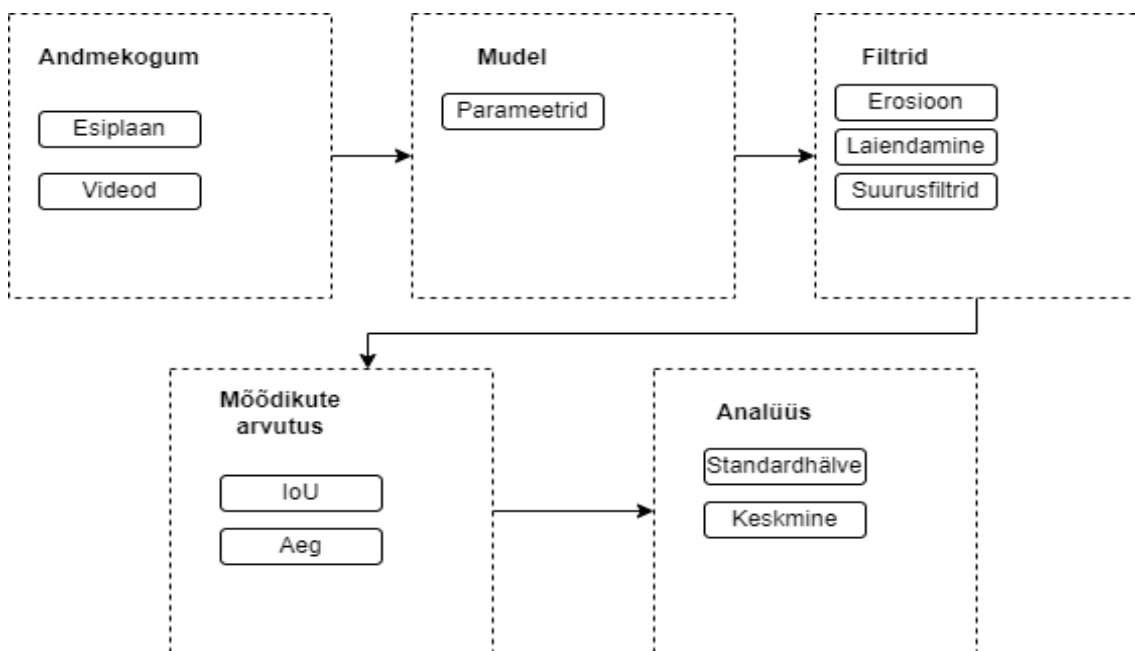
igast maskist. Ka need tulemused on sarnasel kujul kui maskid, maatriksid, milles leiduvad vaid binaarsed väärtused.

Seejärele, et muuta tekkinud maatriksid numbrilisteks väärtusteks summeeritakse mõlema tehte tulemuse maatriksi elemendid ja jagatakse kõikide õigesti tuvastatud valgete pikslite arv kõikide tuvastatud valgete pikslitega, mis leiduvad mõlemas maskis.

Nende loogiliste ja summeerimis tehete rakendamiseks maskidele kasutati Python-i „numpy“ teegi funktsioone „*logical_and*“, „*logical_or*“ ja „*sum*“ [17].

4.3 Töövoog

Mudelite lihtsustatud testimiseks valitud andmekogumite peal töötati välja Python-i skript¹, kus sisendiks on kaks kausta, kus esimeses on videod, mille peal mudelit rakendatakse ning teises on videofailid, mis on samanimelised, kuid koosnevad annoteeritud andmete põhjal koostatud esiplaani maskidest. Joonisel 4 on näidatud üldine töövoog, mida kasutati mudelite analüüsimiseks.




Joonis 4 Üldine töövoog mudeli hindamisel

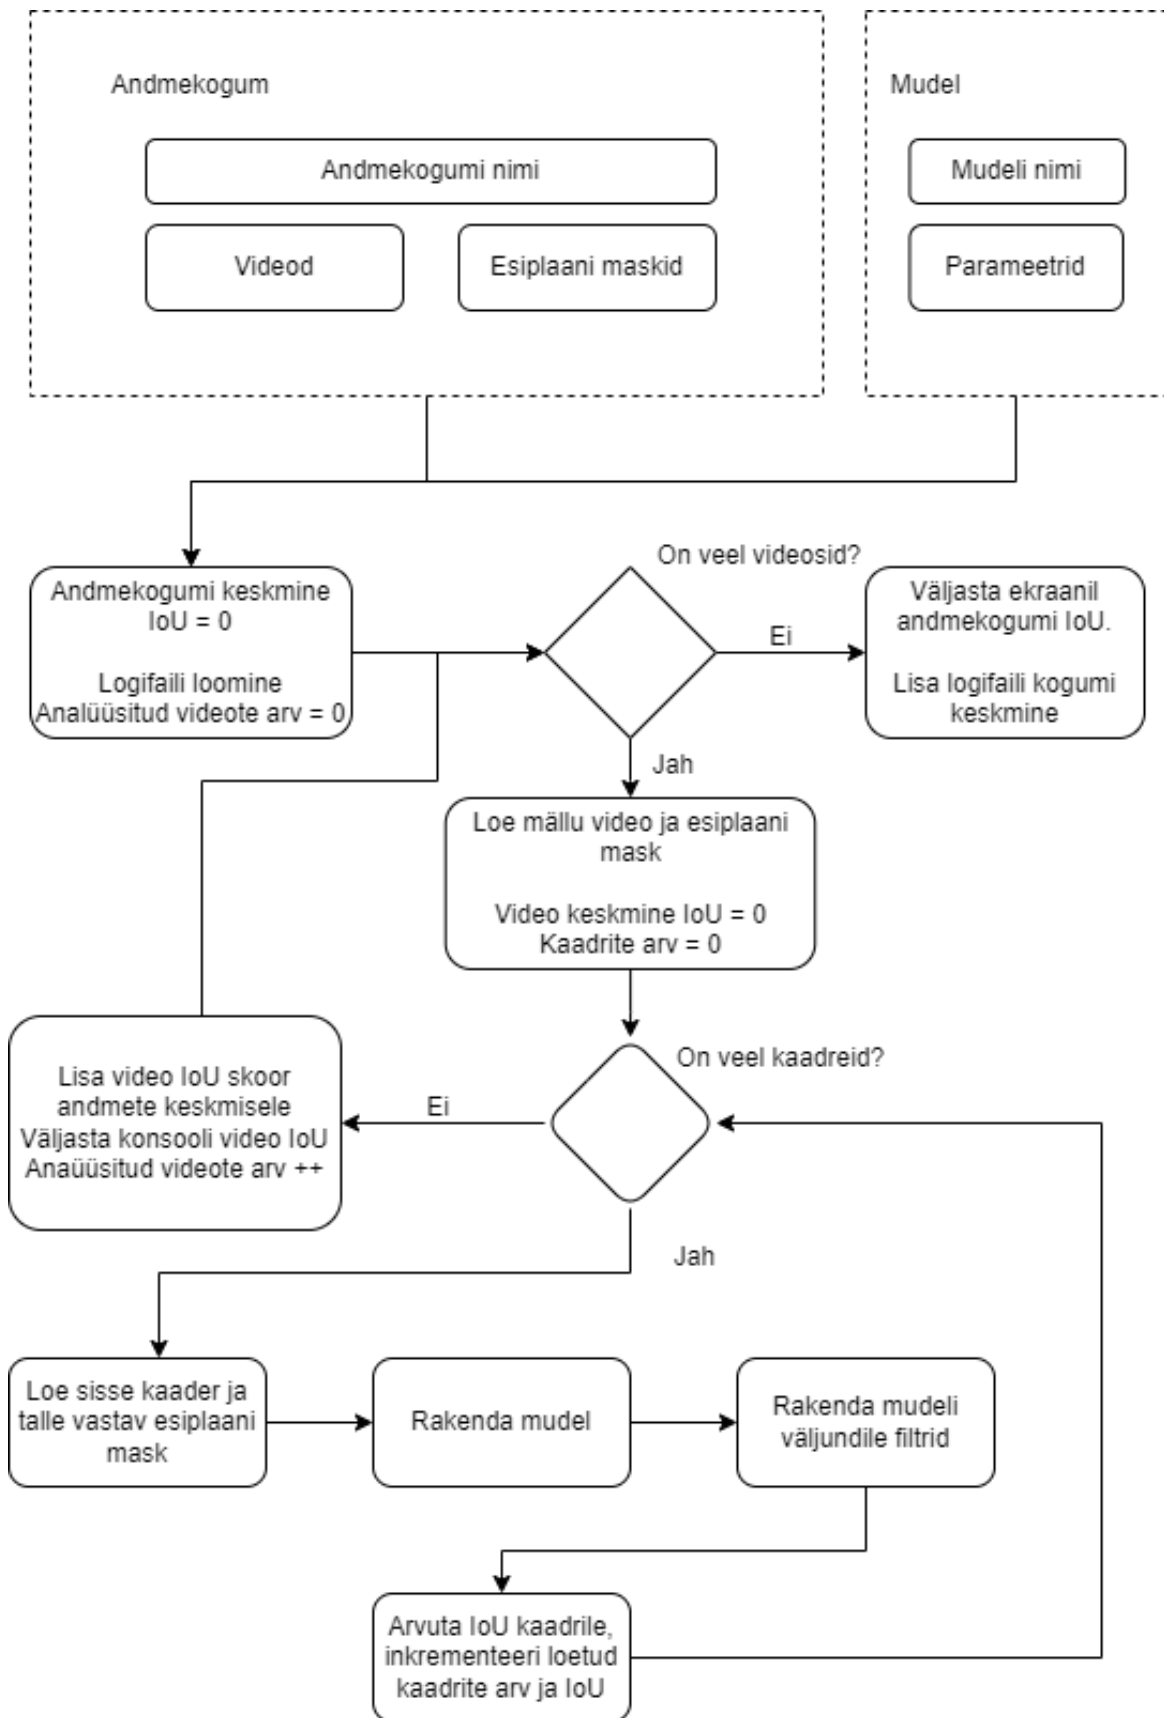
¹ <https://github.com/J-Vaht-98/backgroundSubtraction>

Järgmiseks itereeritakse läbi iga video ja talle vastava esiplaani maski videofaili ning rakendatakse talle mudel ning vajalikud morfoloogilised operatsioonid, arvutatakse IoU mõõdik, ning info iga video tulemuse kohta väljastatakse nii konsooli, kui ka ajatempliga nimetatud logifaili, mis luuakse iga kord kui funktsiooni kutsutakse. Samuti arvutab skript jooksvalt keskmist IoU mõõdikut terve andmekogumi kohta ning analüüsi alguses ja lõpus loetakse aeg ning siis lõpuajast algusaja lahutamise teel saadakse kogu analüüsile kulunud aeg.

Lisaks on skriptis olemas globaalne muutuja „vizualize“, mis võimaldab spetsifitseerida, kas kogu protsessi peaks visualiseerima. Kui muutuja on väärtusega „False“, siis jooksub skript lihtsalt mudelit ja ei ava ühtegi aken. Kui muutuja väärtus on „True“ siis avaneb aken, kus jooksevad vertikaalselt kõrvuti esiplaani mask ning mudeli tuvastatud mask. Seda avanevat võrdlusakent on võimalik näha joonisel 5. Veel on näidatud ka kaadri number ning selle kaadri kohta arvutatud IoU mõõdik. Seda oli vaja, et mudelite proovimise ajal saaks näha eri väljundeid ning, et oleks võimalik rakendada morfoloogilisi ja filtreerimise funktsioone suurema täpsusega. Kogu protsess on näidatud joonisel 6.



Joonis 5 Töövoos avanev valikuline aken (üleval pool mudelid väljund, allpool tõene mask)



Joonis 6 OpenCV Mudelite testimise töövoog

Selline töövoog sobis OpenCV poolt pakutavatele mudelitele esialgseks testimiseks, sest iga mudeli puhul on tema ülesehitus sarnane: esmalt loodakse instants mudelist ning siis iga kaadri puhul kutsutakse mudeli funktsiooni „*apply*“.

5 Tulemused ja analüüs

5.1 Esmased testid

Esialgne testimine vaatas mudelite rakendamiseks kuluvat aega andmekogumitele. Filtreerimist ega muid spetsiifilisi parameetreid testimisel enamjaolt ei kasutatud, kuna esmase testimise eesmärk oli hinnata ajakulu ja saavutatavat täpsust erinevate mudelite rakendamisel andmekogumitele.

Ainuke muutus mudelite initialiseerimisel oli GMG mudeli puhul, kus mudeli tööpõhimõtte tõttu oli vaja muuta mudelisisese ajaloo pikkuse parameetrit, mis on vaikimisi 120 kaadrit. Mudeli tööpõhimõte on luua 120 kaadri pikkune taustamudel ning selle järgi muutusi tuvastada, kuid kui analüüsitavas videos on vähem kui 120 kaadrit ei teki taustamudelit ning tulemus on alati 0. Kuna enamik videosid mõlemas andmekogumis on suhteliselt madala kaadrisagedusega ja ka suhteliselt lühikesed siis sobis vaikimisi parameeter vaid paari video puhul. GMG mudeli ajaloo pikkuseks seadistati 20% analüüsitava video kaadrite arvust, mis iga video puhul välja arvutati.

Esmasest testimisest ilmnas, et parima täpsuse ning ajakulu suhte pakuvad *Gaussian Mixture Model* ning KNN algoritm. *CouNT* ja GMG mudelite puhul ilmneb, et saavutatud täpsus on suhteliselt madal (alla 10% IoU) mõlema andmekogumi puhul. GSOC ja LSBP mudelite puhul on saavutatud täpsus hea, kuid ajakulu oluliselt suurem. LSBP mudelil kulus Luderick andmekogumi analüüsimisele 1108 sekundit, et saavutada vaid veidi parem täpsus kui KNN mudelil, millel kulus vaid 263 sekundit.

Esmase testimise parima täpsuse saavutas mõlemal andmekogumikul GMM mudel, saadest Luderick andmekogumi puhul IoU skooriks 18% ajaga 268 sekundit ning DeepFish andmekogumi puhul IoU skooriks 25% ajaga 17 sekundit. Sarnase ajakulu, kuid halvema täpsuse pakkus KNN mudel, mis saavutas Luderick andmekogumi puhul IoU skooriks 10,1% ajaga 263 sekundit ning DeepFish andmekogumi puhul IoU skooriks 15% 19 sekundiga.

Samuti olid head täpsused GSOC ja LSBP mudelitel. DeepFish andmekogumi puhul oli IoU skooriks mõlemal mudelil 24% ning ajakulu GSOC mudelil 756 sekundit ning LSBP mudelil 1108 sekundit.

Kulunud aeg, saavutatud IoU mõõdik ja mudeli nimi on väljatoodud tabelites 2 ja 3.

Tabel 3 OpenCV mudelite esmase testimise tulemused Luderick andmekogumi peal

Mudeli nimi	IoU	Kulunud aeg (s)
<i>Gaussian Mixture Model</i>	18%	268
K-lähima naabri algoritm	10,1%	263
<i>CouNT</i>	5,8%	152
GSOC	12%	756
LSBP	11,5%	1108
GMG	5,5%	727


Tabel 4 OpenCV mudelite esmase testimise tulemused DeepFish andmekogumi peal

Mudeli nimi	IoU	Kulunud aeg (s)
<i>Gaussian Mixture Model</i>	25%	17
K-lähima naabri algoritm	15%	19
<i>CouNT</i>	5%	12
GSOC	24%	78
LSBP	24%	88
GMG	7%	48

Tulemuste põhjal võib mudeli valik sõltuda rakenduse konkreetsetest nõuetest, nagu kasutatav andmekogum ja vajadus täpsuse versus kiiruse järele. Näiteks Luderick

andmekogumis olevad videod on pikemad, kui DeepFish andmekogumi omad ning iga mudeli puhul oli näha, et DeepFish andmekogumi puhul on IoU skoorid kõrgemad.

Joonisel 7 on välja toodud mudelite rakendamise ajakulu ja täpsuse graafik. Mudelite ajakulu ja täpsuse suhetest on näha, et GMM pakub kõige paremat täpsust olles seejuures suhteliselt madala ajakuluga. Madalama ajakulu ja võrdlemisi keskmise täpsusega on seejuures ka KNN mudel. Kõrgemate ajakulude ja keskmise täpsusega ilmnevad GSOC ja LSBP mudelid. Madalaima ajakulu saavutas CouNT mudel, kuid tehes seda suhteliselt halva täpsusega. Samuti oli halb täpsus GMG mudelil ning ka ajakulu suhteliselt kõrge.



Joonis 7 Mudelite esmase testimise kiiruse ja ajakulu suhted (Luderick andmekogum)

5.2 Testimine koos täpsete parameetrite ja filtritega

Teisese testimise jaoks kasutati mudeleid samade vaikumisi parameetritega kuid mudeli väljundile rakendati erosiooni, laiendamist ning suuruse järgi filtreerimist. Lisaks oli kasutusel tehnika, kus mudelit rakendatakse esialgu video esimeste kaadrite peal mitu korda, et tekkiv taustamudel oleks paremini määratletud.

Testimise eesmärk oli näha erinevate tausta lahutamise tehnikate ja filtrite rakendamise mõju mudelite IoU skooridele ning ajakulule.

5.2.1 Kasutatud filtrid ja tehnikad

Filtrite järjekord rakendamisel oli järgmine: erosioon, laiendamine, suuruse järgi filtratsioon ning seejärel jälle laiendamine. Joonisel 8 on näha mudeli väljund, kui ei ole rakendatud ühtegi filtrit. Joonisel 9 on sama kaader, kui need filtrid on rakendatud.



Joonis 8 Näide tekitatud esiplaani maskist ilma filtrite rakendamiseta



Joonis 9 Näide tekitatud esiplaani kaadrist koos filtrite rakendamisega

Sellise pilditöötuse meetodite järjekorra valimise põhjustas visuaalne ülevaade mudelite tööst, kus oli näha et iga andmekogumi põhjal on esialgsel mudeli väljundil terve hulk eraldiseisvaid piksleid ja väiksemaid pikslikogumeid, mis ei kuulu huvipakkuvatele objektidele. Erosiooni abil oli võimalik need eemaldada.

Pärast erosiooni rakendamist oli võimalik rakendada laiendamist. Laiendamine on üks pilditöötuse tehnikatest, mis võimaldab suurendada objektide piire või täita tühimikke. Selle abil saab täita ära huvipakkuvate objektide võimalikud kontuurid, mis jäid erosiooni või mõne muu protsessi käigus osaliselt või täielikult kaduma.

Erosiooni ja laiendamise protsessid on tavaliselt omavahel seotud. Erosioon eemaldab piirkondi objekti ümber ja teeb selle piiri siledamaks. Kuid mõnikord võib see protsess viia ka selleni, et objektide piirid muutuvad katkendlikuks või on lagunenu. Seetõttu on laiendamine järgmine samm, kuna see täidab ära kõik tühjad või kaotatud piirkonnad ja muudab objekti piirid taas sujuvamaks.

Laiendamise puhul on vaja jälgida valepositiivsete tekkimist, ehk seda, kui mingi mitte huvipakkuv piirkond esiplaanil laiendatakse. Seetõttu on vaja kohandada laiendamise ja erosiooni protsesse vastavalt olukorrale, et vältida müra tekkimist.

Peale morfoloogiliste filtrite rakendamist tehti suuruse järgi filtratsioon, kus kasutati OpenCV funktsioone „findContours“, mis tagastab esiplaanilt leitud kontuurid ja „contourArea“, mis leiab selle kontuuri pindala. Esiplaanilt eemaldati kontuurid, mille pindala on üle 2000 piksli.

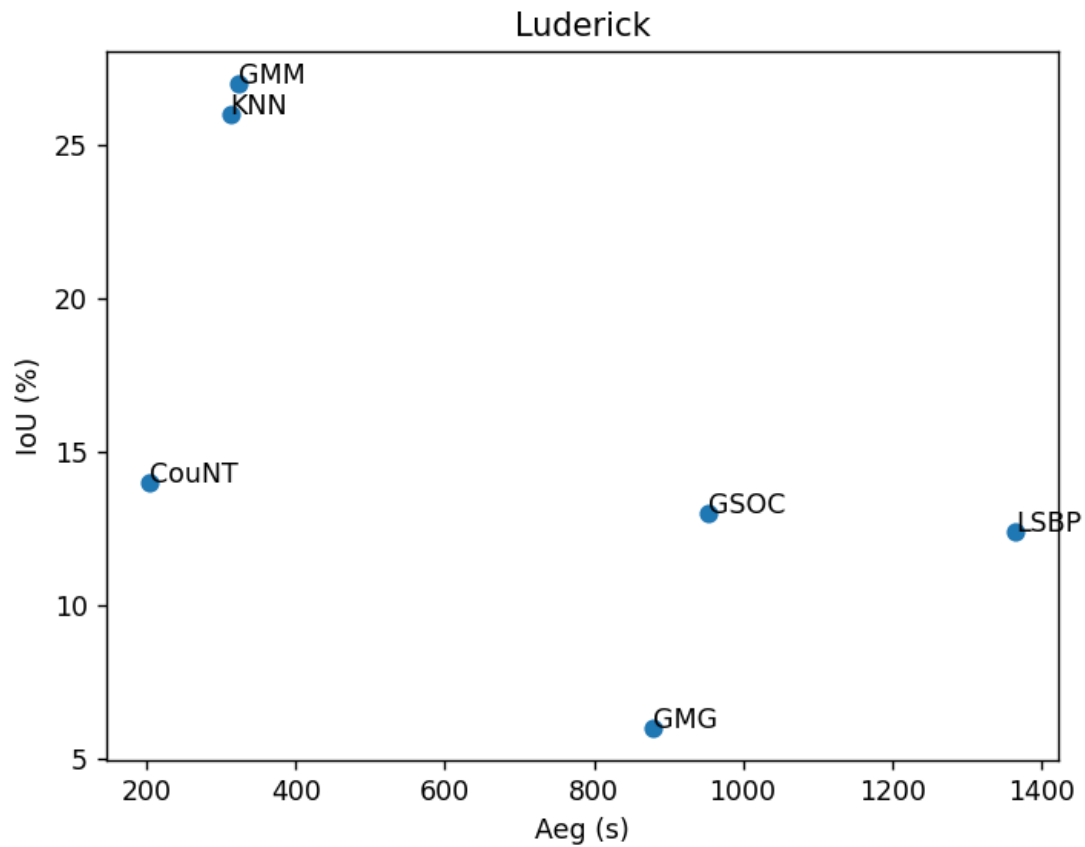
5.2.2 Tulemused filtrite rakendamisel

Tabelites 4 ja 5 on näha iga valitud mudeli ajakulu ning IoU skoor mõlema andmekogumi kohta kui seda on rakendatud eelmainitud filtritega. Lisaks on tabelites välja toodud ka ajakulu ning IoU muutus võrreldes esialgse testimisega, kus neid filtreid ei kasutatud.

Tabel 5 OpenCV mudelite rakendus koos filtritega Luderick andmekogumi peal

Mudeli nimi	IoU	Kulunud aeg (s)	IoU muutus	Aja muutus
GMM	27%	323	+9%	+55 s
KNN	26%	312	+11%	+49 s
<i>CouNT</i>	14%	204	+9%	+52 s
GSOC	13%	954	+1%	+198 s
LSBP	12,4%	1365	+0,9%	+257 s
GMG	6%	880	+1%	+153 s

Luderick andmekogumi puhul, kus on tegemist keskmiselt pikemate videotega oli näha suurimat muutust KNN mudeli täpsuses, kus IoU muutus oli +11%. Kõige väiksem aja muutus oli samuti mudeli KNN rakendamisel. Kõige parem täpsus kuulus GMM mudelile ja selleks oli 27%. Kõige madalam täpsus oli GMG mudelil ning selleks oli 6% ajaga 880 sekundit. Mudelitel GSOC ja LSBP, millel enne oli sarnane täpsus GMM mudeliga ei olnud rakendatud filtritega nii suurt kasvu täpsuses, vaid jäid valdavalt samasuguseks.



Joonis 10 Kulunud aja ja IoU skooride graafik filtritega mudeleid rakendades Luderick andmekogumile. Joonisel 10 on välja toodud suhted täpsuse ja ajakulu vahel mudelite rakendamisel Luderick andmekogumile. On näha, et KNN ja GMM mudelid on üsna sarnaste tulemustega ja kasutatud mudelitest parima IoU skoori ja ajakulu vahelise suhtega.

Tabel 6 OpenCV mudelite rakendus koos filtritega DeepFish andmekogumi peal

Mudeli nimi	IoU	Kulunud aeg (s)	IoU muutus	Aja muutus
GMM	34%	35	+ 9%	+18 s
KNN	29%	32	+ 14%	+13 s
<i>CouNT</i>	15%	18	+ 10%	+6 s
GSOC	29%	147	+ 5%	+ 69 s
LSBP	25%	183	+ 1%	+ 95 s
GMG	11%	119	+4%	+71 s

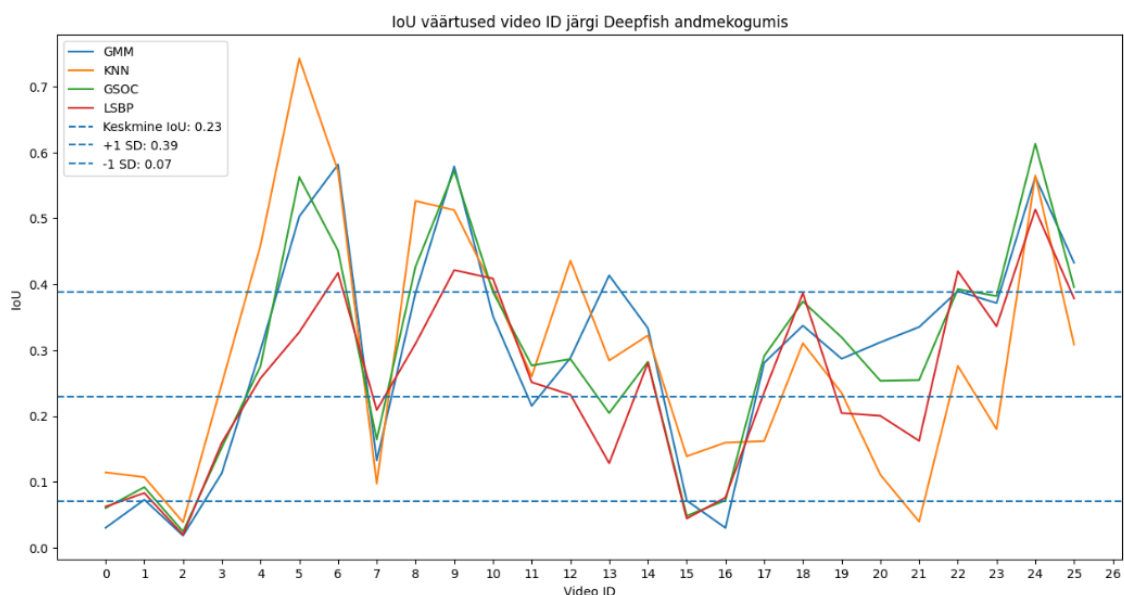
DeepFish andmekogumi puhul on näha sarnane trend. Kõikide mudelite täpsused tõusid ning tekkis ajaline lisa. Kõige suurema muutuse IoU skooris tegi KNN mudel. Kõige täpsemaks mudeliks oli GMM IoU skooriga 34%. Kõige madalam IoU skoori saavutas GMG mudel täpsusega 11%. Madalaim täpsuse kasv oli LSBP mudelil ning kõrgeim täpsuse kasv oli KNN mudelil.

5.3 Anomaaliate analüüs

Selle analüüsi idee oli vaadata üle filtritega rakendatud mudelite tulemused iga andmekogumis sisalduva video kohta, et näha, millistel tingimustel võib tekkida olukord mille tõttu mudeli väljund märgatavalt kannatab või paremaks läheb.

5.3.1 Deepfish andmekogumi anomaaliad

Deepfish andmekogumi IoU skooore videote järgi on võimalik näha joonisel 11. Loetavuse huvides on graafikult välja jäetud GMG ja CNT mudelite tulemused. Neid mudeleid kaasnev graafik on saadaval lisades (Lisa 3). Lisaks on graafikul kujutatud ka horisontaalne joon, mis näitab graafikul olevate mudelite keskmist ning ühe standardhälve suurust kaugust mõlemas suunas.



Joonis 11 Mudelite väljundid Deepfish andmekogumis

Graafikul jääb silma viienda video juures ilmnev tipp, kus kõik graafikul kujutatud mudelite väljundid peale LSBP mudeli oma on üle ühe standardhälve võrra suuremad. Video millel selline anomaalia tekib kujutab endas kahte kala, kes ujuvad üksteisest suhteliselt kaugel. Üks kala on kaamerale suhteliselt lähedal võttes enda alla suure osa ekraanist ning liikudes suhteliselt äkiliselt. Kaader sellest videost on näha joonisel 12.



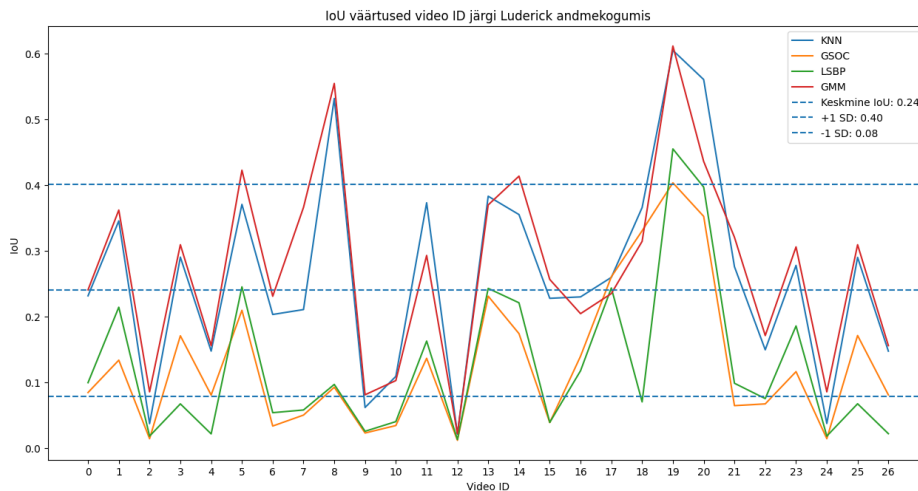
Joonis 12 Kaader anomaalia tekitanud videost

Sarnane anomaalia tekib ka andmekogumi eelviimase ja viimase video puhul, kus on näha täpsuste tõus iga video puhul. Vastavates videote näol on tegemist kahe videoga, kus üksainus kala ujub ühtlase tempo ja trajektooriga läbi kaamera vaatevälja.

Mudelite puhul suurim nähtav kollektiivne halb skoor on andmekogumi teise video puhul. Vastavas videos on näha olukord, kus kaamera vaateväljas on üksainus kala kes liigub tänu kaamera kaadrisageduse muutusele suhteliselt suure vahemiku väikse ajaga. Selle konkreetse video puhul on väga madal arv kaadreid (vaid 4), mis takistab mudelitel efektiivse taustamudeli loomist.

5.3.2 Luderick andmekogumi anomaaliad

Luderick andmekogumi IoU skoore videote kaupa on võimalik näha joonisel 13. Sarnaselt Deepfish andmekogumi graafikule joonisel 10 on graafikul näha vaid nelja mudeli tulemused: GMM, KNN, GSOC ja LSBP mudelid. Graafik kõikide mudelitega on näha lisades (Lisa 2).



Joonis 13 Luderick andmekogumi IoU skoorid video järgi

Andmekogumi puhul kuulusid absoluutselt parimad IoU skoorid KNN ja GMM mudelile. Nende kahe mudeli skoorid oli iga video puhul suhteliselt sarnased, kui üldiselt oli GMM mudel parem.

Suurimad muutused normist on näha videote 8 ja 19 puhul, kus KNN ja GMM mudelite puhul on saavutatud IoU skoor ligi 60%. Sama video puhul on ka kõigi teiste mudelite väljundid keskmisest suuremad.

Videot 8 andmekogumist vaadates on näha, et videos on vaid üks kala, kes liigub horisontaalselt läbi kaamera vaatevälja. Lisaks on video vältel tekkivad valgusmuutused minimaalsed ning filtrite rakendamise abil on võimalik nende muutuste efekt suuresti minimeerida. Joonisel 14 on välja toodud ka kaader sellest videost.




Joonis 14 Video 8 Luderick andmekogumist

Veel tekkisid suured kõikumised normist video 19 puhul, kus kõigi graafikul nähtavate mudelite skoorid olid normist ühe standarhälve võrra kõrgemad. Mudeli GMM tuvastud esiplaani kaader selle video puhul on näha jooniselt 15 ning temale vastav annoteeritud andmetega esiplaan jooniselt 16. Kaader päris videost on näha joonisel 17.

Videost ilmneb, et valgusolud olid video vältel ühtlased ning kalad liiguvad hajutatult ja järjepideva trajektooriga.

Olukorra teeb huvitavaks fakt, et mudel on tuvastanud videos lisaks kahele annoteeritud kalale ka kolmanda kala, mis on annoteeringus puudu. Sellised vead on kahjuks suurte andmekogumite töötlemisel paratamatud ning kui see kala sisalduks annoteeringus oleks selle video IoU skoor veel kõrgem.



Joonis 15 Luderick andmekogumi video 19 tuvastatud esiplaan




Joonis 16 Luderick andmekogumi video 19 annoteeritud esiplaan



Joonis 17 Luderick andmekogum: kaader videost 19

Mudelite halvimad skoorid olid Luderick andmekogumi video 12 puhul. Esineb ka teisi videosid, kus skoor on sama halb, kuid selles videos on kollektiivne keskmine väga madal. GMM mudeli tuvastatud esiplaani mask on joonisel 18 ülevalpool rohelist joont ning tõene esiplaan allpool rohelist joont.



Joonis 18 GMM mudeli esiplaan ning tõene esiplaan (Luderick andmekogumi video 12)

Video läbi vaadates on näha, et valesti tuvastatud esiplaani objektid ja seega ka madala IoU skoori põhjustab eelkõige kiire valguse muutus ning tugev vee voolamine, mis liigutab veekogu põhjas kasvavat rohtu. Seega tekkis kaks faktorit, mille koostöö tegi mudeli väljundi halvaks. Samas tuvastas mudel siiski videos oleva kala suhteliselt hea täpsusega, säilitades umbkaudselt tema kuju ja asukoha.

5.4 Järeldused

Andmekogumite analüüsist ilmneb, et kaks parimat mudelit veeluse video tausta lahutamiseks on GMM ja KNN mudelid. Mõlema mudeli on IoU skoorid on suhteliselt sarnased. KNN puhul oli algne ilma morfoloogiliste filtriteta testimisel skoor oluliselt madalam, kui GMM mudelil. Siiski, peale nende filtrite rakendamist olid mõlema mudeli täpsused sarnased.

Uurides faktoreid mis mõjutavad mudelite tööd ilmnes, et enim mõjutavad faktorid on video kaadrite arv ning valgusolude muutus videos. Mõlema mudeli väljundid olid peaaegu alati sarnased, ehk kui ühe täpsus langes või tõusis juhtus sama ka teisega.

Jõudluse poolelt on mõlemal mudelil ligikaudselt sama rakendamise aeg, mis on ka põhjus nende kahe mudeli kasutamiseks. Kui aeg ja arvutusressurss ei ole faktor videosüsteemi rakendamises tasuks kaaluda ka GSOC ja LSBP mudelite rakendamist, mis saavutasid samasuguse täpsuse, kuid kordades suurema ajakulu.

6 Kokkuvõte

Töö eesmärgiks oli uurida veealuse video tausta lahutamise algoritme. Selle eesmärgi saavutamiseks oli esmalt vaja leida sobilikud andmekogumid ning analüüsida sarnaseid uurimusi, et leida efektiivsed moodsid, mis defineeriks numbriliselt tausta lahutamise mudeli täpsust üle mingi andmekogumi. Eelnevate uurimuste tutvumise kaudu sai teada ka, millised faktorid mõjutavad enim tausta lahutamise mudeli tööd ja täpsust.

Andmekogumite otsingu käigus oli põhiliseks nõudeks leida üks või rohkem andmekogumit, milles oleks inimeste poolt ära annoteeritud andmed kala asukoha ja asendi kohta videos. Teisene nõue andmekogumile oli, et eelistatavalt oleks kaamera terve video vältel staatiline.

Andmekogumite otsingust ilmnisid kaks andmekogumit: Luderick Seagrass ja Deepfish. Mõlemas andmekogumis oli olemas annoteeritud andmed kala asukoha ja asendi kohta ning annoteeritud kaadreid leidis piisavalt. Selleks, et mudeleid rakendada tuli saadud andmestikud ümber muundada formaati, kus tekib kaks videot: üks originaalne video, millele saab rakendada tausta lahutamist ning üks video, mis koosneb annoteeritud andmete põhjal koostatud esiplaanist.

Tekkinud videote järgi sai rakendada valitud moodsikut IoU (*intersection over union*), mis näitab efektiivselt, kui palju mudeli tuvastatud pikslitest kuuluvad päriselt huvipakkuvale objektile.

Tausta lahutamise mudelid, mida testiti koosnesid OpenCV teegi lahendusest. Kuna nende rakendamise ülesehitus on suhteliselt sarnane, siis kirjutati Python-i skript, milles sai kõiki mudeleid järjest jooksutada.

Esimese testimise puhul testiti kõiki mudeleid vaikimisi parameetritega, et hinnata nende rakendamise aja ja saavutatava IoU skoori suhet. Teises testimise etapis rakendati mudelitele lisaks ka pilditöötamise algoritme nagu erosioon ja laiendamine ning hinnati, kui palju ajakulu ja täpsust nad lisavad.

Selle järgselt hinnati mudelite täpsust iga andmekogumi iga video puhul, et välja tuua olukorrad, mis oluliselt mõjutavad mudeli täpsust. Nendeks faktoriteks ilmnisid

peamiselt video kaadrite arv ning valgusolude muutus. Hea IoU skoor saavutati enamasti videote puhul, kus objekti liikumine oli võrdlemisi kiire ja sirgjoonelise trajektooriga.

Andmeanalüüsi käigus selgusid parimateks mudeliteks jõudluse ja hea täpsuse tõttu *Gaussian Mixture Model* ning KNN algoritm. Sarnaseid täpsusi, kuid mitmekordse ajakuluga, saavutasid ka mudelid GSOC ja LSBP.

Töö pakub ulatusliku ja võrdleva ülevaate veealuse video tausta lahutamise meetoditest, andmekogumitest ja mõõdikutest. Antud töö võimaldab tulevikus valida sobivaimaid tausta lahutamise meetodeid veealuse keskkonna jaoks. Selle eesmärgiks polnud proovida kõiki võimalikke tausta lahutamise meetodeid, vaid testida ja tuvastada limitatsioone olemasolevatel meetoditel, kui neid kasutatakse veealuse video peal. Edasiarenduseks võimaldab loodud algoritm testida suuremat mudelite hulka või välja arendada täpsemaid mudeleid veealuse video tausta lahutamiseks.

Kasutatud kirjandus

- [1] V. Shevchenko, T. Eerola and A. Kaarna, "Fish Detection from Low Visibility Underwater Videos," 2018 24th International Conference on Pattern Recognition (ICPR), Beijing, China, 2018, pp. 1971-1976, doi: 10.1109/ICPR.2018.8546183.
- [2] „OpenCV dokumentatsioon,“ [Võrgumaterjal]. Saadaval: <https://docs.opencv.org/4.x/>. [Kasutatud 4 5 2023].
- [3] „Generalized Intersection over Union“ [Võrgumaterjal]. Saadaval: <https://giou.stanford.edu/>. [Kasutatud 1 5 2023].
- [4] Spampinato, Concetto, et al. „Detecting, Tracking and Counting Fish in Low Quality Unconstrained Underwater Videos.“ *VISAPP (2) 2008*.514-519 (2008): 1.
- [5] Garcia-Garcia, Belmar, Thierry Bouwmans and Alberto Jorge Rosales Silva. „Background subtraction in real applications: Challenges, current models and future directions,“ *Computer Science Review* 35 (2020): 100204.
- [6] Mandel, Travis, et al. „Detection confidence driven multi-object tracking to recover reliable tracks from unreliable detections.“ *Pattern Recognition* 135 (2023): 109107.
- [7] E. M. Ditria, R. M. Connolly, E. L. Jinks ja S. Lopez-Marcano, „Annotated video footage for automated identification and counting of fish in unconstrained marine environments,“ 2021. [Võrgumaterjal]. Saadaval: <https://doi.pangaea.de/10.1594/PANGAEA.926930>. [Kasutatud 1 5 2023].
- [8] Saleh, A., Laradji, I. H., Konovalov, D. A., Bradley, M., Vazquez, D., & Sheaves, M. (2020). A realistic fish-habitat dataset to evaluate algorithms for underwater visual analysis. *Scientific Reports*, 10(1), 14671. DOI: <https://doi.org/10.1038/s41598-020-71639-x>.
- [9] Pedersen, Malte, et al. „BrackishMOT: The Brackish Multi-Object Tracking Dataset.“ *Image Analysis: 23rd Scandinavian Conference, SCIA 2023*, Sirkka, Finland, April 18-21, 2023, Proceedings, Part I. Cham: Springer Nature, Switzerland, 2023.
- [10] Kalhagen, Espen; Olsen, Ørjan (2020), “Dataset for Hierarchical Object Detection of Nordic Fish Species”, Mendeley Data, V1, doi: 10.17632/b4kcw9r32n.1
- [11] Zivkovic, Zoran ja Ferdinand Van Der Heijden. „Efficient adaptive density estimation per image pixel for the task of background subtraction.“ *Pattern recognition letters* 27.7 (2006): 773-780.
- [12] S. Zeevi. [Võrgumaterjal]. Saadaval: <https://github.com/sagiz/BackgroundSubtractorCNT>. [Kasutatud 14 5 2023].
- [13] Godbehere, Andrew B., Akihiro Matsukawa and Ken Goldberg, „Visual tracking of human visitors under variable-lighting conditions for a responsive audio art installation.“ 2012 American Control Conference (ACC). IEEE, 2012.

- [14] Guo, Lili, Dan Xu, and Zhenping Qiang. „Background subtraction using local SVD binary pattern.“ Proceedings of the IEEE conference on computer vision and pattern recognition workshops. 2016.
- [15] Google, „Improvement of the background subtraction algorithm,“ 2017. [Võrgumaterjal]. Saadaval: <https://summerofcode.withgoogle.com/archive/2017/projects/6453014550282240>. [Kasutatud 1 5 2023].
- [16] „Intersection over Union (IoU) in Object Detection & Segmentation,“ [Võrgumaterjal]. Saadaval: <https://learnopencv.com/intersection-over-union-iou-in-object-detection-and-segmentation/>. [Kasutatud 12 5 2023].
- [17] „Numpy dokumentatsioon,“ [Võrgumaterjal]. Saadaval: <https://numpy.org/>. [Kasutatud 1 5 2023].
- [18] Zivkovic, Zoran. „Improved adaptive Gaussian mixture model for background subtraction“ Proceedings of the 17th International Conference on Pattern Recognition, 2004. ICPR 2004 .. Vol. 2. IEEE, 2004.

Lisa 1 – Lihtlitsents lõputöö reprodutseerimiseks ja lõputöö üldsusele kättesaadavaks tegemiseks¹

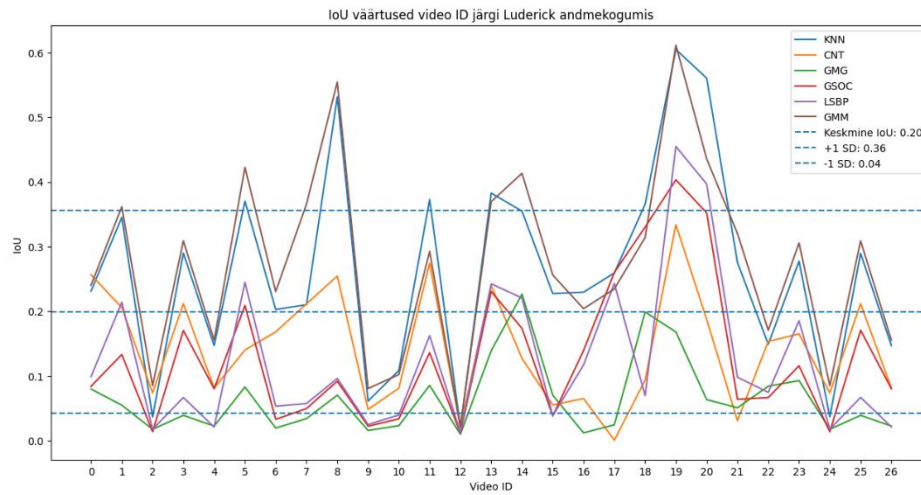
Mina, Jaagup Vaht

1. Annan Tallinna Tehnikaülikoolile tasuta loa (lihtlitsentsi) enda loodud teose „Veealuse video tausta lahutamise järelvalveta segmenteerimiseks“, mille juhendaja on Elizaveta Dubrovinskaya
 - 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.

15.05.2023

¹ Lihtlitsents ei kehti juurdepääsupiirangu kehtivuse ajal vastavalt üliõpilase taotlusele lõputööle juurdepääsupiirangu kehtes tamiseks, 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 loomingulise 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 – Luderick andmekogumi graafik kõigi mudelitega



Lisa 3 – Deepfish andmekogumi graafik kõigi mudelitega

