

TARTU ÜLIKOOL
Arvutiteaduse instituut
Informaatika õppekava

Arnold Luich
**Inimeste loendamine autonoomsete droonide
ümb**
Bakalaureusetöö (9 EAP)

Juhendajad:
Kevin Post, nooremteadur
Huber Flores, PhD

Tartu 2025

Inimeste loendamine autonoomsete droonide ümber

Lühikokkuvõte:

Käesoleva bakalaureusetöö eesmärk oli arendada prototüüp inimeste loendamiseks siseruumides mobiilsel drooniplatvormil, kasutades masinõppe- ja arvutinägemismudeleid. Süsteem ühendab nelja termokaamerat, mitmesuguseid andureid ning ESP32-põhiseid mikrokontrollereid, mis koguvad reaajas andmeid ja edastavad need veebipõhisesse kasutajaliidesesse. Mudelite treenimiseks ja hindamiseks viidi läbi kolm erinevat katset: kontrollitud keskkonnas, reaalses kontoriruumis ning drooni liikumisega katsetingimustes. Tulemuste põhjal valiti välja kõige sobivamad mudelid, millest YOLOv9s paistis silma kõrge täpsusega reaajas tuvastamisel. Töö näitab, et energiatõhusate andurite ja termopildi-põhise arvutinägemise kombineerimine võimaldab luua mobiilse, täpse ja privaatsust säilitava inimeste loendamise süsteemi, pakkudes tavakaamerapõhiste lahendustele elujõulist alternatiivi.

Võtmesõnad: inimeste loendamine, droonid, masinõppe, arvutinägemine, termokaamerad

CERCS: P176 Tehisintellekt

People Counting Around Autonomous Drones

Abstract:

The goal of this bachelor's thesis was to develop a prototype for indoor people counting using a mobile drone platform based on machine learning and computer vision models. The system integrates four thermal cameras, various sensors, and ESP32-based microcontrollers that collect real-time data and transmit it to a web-based user interface. To train and evaluate the models, three different experiments were conducted: in a controlled environment, in a real office setting, and under conditions where the drone was in motion. Based on the results, the most suitable models were selected, with YOLOv9s standing out for its high accuracy in real-time detection. This work shows that combining energy-efficient sensors with thermal image-based computer vision enables a mobile, accurate, and privacy-friendly indoor people counting system, offering an alternative to traditional cameras.

Keywords: people counting, drones, machine learning, computer vision, thermal cameras

CERCS: P176 Artificial intelligence

Sisukord

Sissejuhatus	5
1. Varasemad tööd	6
1.1 Anduripõhised lähenemisviisid inimeste loendamiseks	6
1.1.1 Passiivsed infrapunaandurid (PIR).....	6
1.1.2 PIR-andurite kasutamise väljakutsed.....	7
1.1.3 Ultraheli kaugusandur.....	7
1.1.4 Ultraheli kaugusandurite kasutamise väljakutsed.....	8
1.1.5 PIR ja ultraheli kaugusandurite kombineeritud kasutamine.....	8
1.1.6 Termokaamerad.....	9
1.1.7 Närvivõrkudel põhinev inimeste loendamine termokaamera abil	9
1.1.8 Termokaamerate väljakutsed	10
1.2 Arvutinägemine inimeste tuvastamiseks	10
1.2.1 Arvutinägemine.....	10
1.2.2 Plussid ja miinused.....	11
1.2.3 Inimeste loendus termopildil	11
1.3 Inimeste loendamine droonidel	12
2. Inimeste arvu ennustamiseks kasutatud masinõppe- ja arvutinägemismudelid	14
2.1 Masinõppe andmete eeltöötlus.....	14
2.2 YOLO andmete eeltöötlus	15
2.3 Hindamismõddikud mudelite täpsuse analüüsiks.....	15
2.4 Treeningukeskkond.....	17
3. Prototüübi arendus ja andmete kogumine.....	18
3.1 Riistvaraline ülesehitus	18
3.1.1 Kontrollerid.....	18
3.1.2 Andurid	18
3.1.3 Seadmete paigutus	19
3.2 Andmete kogumise tarkvara arendamine	20
3.2.1 Arduino skriptid	21
3.2.2 Veebipõhine kasutajaliides andmete salvestamiseks.....	22
3.2.3 Kasutajaliides YOLO mudeli treeningandmete salvestamiseks.....	22
3.3 Eksperimentaalne seadistus ja andmete kogumine	23
3.3.1 Eksperimentaalse seadistuse kirjeldus	24

3.3.2 Katse 1: Kontrollitud katsekeskkond	24
3.3.3 Katse 2: Reaalne töökeskkond	24
3.3.4 Katse 3: Liikuv andurplatvorm	25
4. Tulemused	26
4.1 Täpsuse hindamine kontrollitud keskkonnas	26
4.2 Täpsuse hindamine reaalses töökeskkonnas staatilisel platvormil	28
4.3 Täpsuse hindamine reaalses keskkonnas liikaval andurplatvormil	31
5. Arutelu	32
5.1 Piirangud	32
5.2 Tuleviku töö suunad	32
6. Järeldus	33
Viited	34
Lisad	36
I. Augmentatsioonimeetodid	36
II. Masinõppemudelite tunnused ja parameetrid	37
III. Masinõppemudelite ja YOLO mudelite katsete tulemused kokkuvõetult	38
Litsents	40

Sissejuhatus

Inimeste loendamine ja jälgimine on oluline mitmetes valdkondades, sealhulgas turvalisuse tagamisel, siseruumide energiatarbimise optimeerimisel ning hädaolukordade koordineerimisel. Enamasti kasutatakse selleks statsionaarseid RGB-kaameraid, mille tõhus rakendamine nõuab aga keerukat seadistust ning märkimisväärset riistvaralist võimekust. Lisaks kaasnevad nende süsteemidega mitmed puudused, sealhulgas kõrge energiatarve ja privaatsusriskid [1].

Statsionaarsete seadmete puhul on sageli vajalik paigaldada mitu andurit erinevatesse asukohtadesse, et katta kogu jälgitav ala. Selline lahendus võib olla kulukas, kohmakas ja mitte eriti paindlik. Liikuvad seadmed, näiteks droonidele või robotitele paigaldatud andurid, pakuvad seevastu paindlikumat ja dünaamilisemat lähenemist, võimaldades saavutada suuremat katvust väiksema arvu seadmetega ning liikuda vastavalt vajadusele.

Üheks võimalikuks rakendusnäiteks on olemasolevate mobiilsete seadmete, näiteks koristusrobotite, kasutamine, millele on lisatud inimese tuvastamise võimekus. Need robotid võivad liikuda siseruumides, tuvastades inimeste viibimist eri alades. Kogutud andmete põhjal saab näiteks automaatselt reguleerida ventilatsioonisüsteeme, suunates rohkem värsket õhku sinna, kus viibib rohkem inimesi, või tuvastada ootamatu kohaloleku väljaspool tööaega.

Käesolev lõputöö uurib inimest tuvastava süsteemi võimalikkust maapealsetel droonidel, mis on sarnased tavapärasele koristusrobotitele. Droonidele paigaldatakse energiatarvikes andurid, sealhulgas passiivsed infrapunaandurid (PIR), ultraheli kaugusandurid ja termokaamerad, mis võimaldavad inimestele reageerida ilma vajaduseta olla pidevalt ühendatud vooluvõrku.

Töö eesmärk on arendada esmane prototüüpsüsteem, mis kogub andmeid ja tuvastab inimesi liikuvalt droonilt, luues aluse edasiseks autonoomse loendussüsteemi arenduseks.

Töö on üles ehitatud kuuele peatükile. Esimeses peatükis antakse ülevaade anduripõhistest süsteemidest inimeste loendamiseks ning tuuakse välja nende eelised ja piirangud. Teises peatükis kirjeldatakse inimeste loendamiseks kasutatud masinõppemudeleid ning andmete töötlemise protsesse. Kolmas peatükk kirjeldab prototüübi riistvaralisele ja tarkvaralisele arendusele ning andmete kogumisele kolmes erinevas keskkonnas. Neljandas peatükis analüüsitakse katsetulemuste alusel kasutatud mudelite täpsust. Viies peatükk käsitleb töö piiranguid ja arendusvõimalusi. Kuues peatükk sisaldab järeldusi.

Antud töö koostamisel on kasutatud generatiivse tehisintellekti rakendusi üksnes olemasoleva teksti toimetamiseks ja vormistamiseks.

1. Varasemad tööd

1.1 Anduripõhised lähenemisviisid inimeste loendamiseks

Inimeste loendamisel siseruumides on võimalik toetuda mitmele eri andurmodaliteedile. Traditsiooniliselt on põhiliselt kasutusel olnud kaamerapõhised lahendused, kuid privaatsusnõuded, kõrge energiatarve ja piiratus eri valgustingimustes on suurendanud huvi alternatiivsete andurpõhiste meetodite vastu. Käesolevas peatükis keskendutakse kolmele alternatiivsele andurtüübile: passiivsed infrapunaandurid (PIR), ultraheli kaugusanduri ja termokaamerad. Käsitletakse iga andurtüübi tööpõhimõtet, kasutusvõimalusi ja -piiranguid. Ühtlasi vaadeldakse mõningaid olemasolevaid lahendusi, mis kombineerivad antud andurtüüpe omavahel.

1.1.1 Passiivsed infrapunaandurid (PIR)

PIR-andur ehk passiivne infrapunaandur tuvastab infrapunakiirguse muutusi oma vaateväljas [2]. PIR-anduri tööd võimaldavad kaks kristallist andurelementi, mis on tundlikud kiirgusintensiivsuse muutumisele. Kui anduri vaatevälja siseneb infrapunakiirgust kiirgav objekt (näiteks inimene), siis sellelt objektilt pärinev infrapunakiirgus langeb esmalt ühele andurelemendile ja seejärel teisele, põhjustades temperatuurimuutuse langeb kiirgus esmalt ühele andurielemendile ja seejärel teisele, põhjustades ajutise erinevuse nende temperatuurides. See lühiajaline temperatuuride erinevus andurelementide vahel põhjustab kristallides elektripotentsiaali muutuse ja pinge kahe andurelemendi vahel, mida andur registreerib elektrisignaalina. Oluline on märkida, et PIR-andurid ei tuvasta juba vaateväljas paiknevaid staatilisi soojusallikaid, vaid reageerivad ainult kiirguse muutustele liikumise tagajärjel. Seetõttu sobivad PIR-andurid hästi liikumise, kuid mitte püsiva kohaloleku tuvastamiseks. Anduri väljund on binaarne, kas liikumine tuvastatud (väärtus 1) või mitte (väärtus 0).

Tänu oma töökindlusele ja madalale elektritarbimisele on PIR-andurid laialdaselt kasutusel turva- ja automaatikalahendustes. Tüüpiline PIR-andur tarbib puhkeolekus vaid mõnekümne mikroampri jagu voolu [3, 4], mis teeb neist sobiva valiku pidevalt töötavatesse ja akutoitel süsteemidesse. Neid kasutatakse sageli liikumise esmatuvastuseks, et ainult vajadusel käivitada suurema energiakuluga komponente, nagu kaamerad või valgustid. Ühes uuringus loodi turvasüsteem, mis kasutas PIR-andurit liikumise tuvastamiseks, muutes kogu lahenduse energiatõhusamaks [5]. Süsteem on üles ehitatud nii, et liikumise tuvastamisel saadab andur signaali, mille tulemusel lülitub sisse valgustus ning kaamera alustab videopildi salvestamist.

Selline lahendus võimaldab reageerida sissetungidele reaalsajas, säästes samal ajal energiat ja vähendades salvestusruumi kasutust, kuna salvestamine toimub vaid liikumise korral. Uuring kinnitab, et süsteemi saab edukalt rakendada reaalses keskkonnas, kus on oluline nii energiasäästlikkus kui ka töökindel sissetungi tuvastamine.

1.1.2 PIR-andurite kasutamise väljakutsed

Tänapäevases töökeskkonnas võivad PIR-andurite kasutamisega kaasneda mitmed probleemid [6].

Üheks peamiseks probleemiks on PIR-andurite piiratud tuvastusulatus – liikumine, mis toimub anduri vaateväljast väljaspool, võib jääda täielikult registreerimata. Lisaks edastavad need andurid vaid lihtsa binaarse signaali (kas liikumine on tuvastatud või mitte), mistõttu pole võimalik määrata inimeste arvu ega nende täpset asukohta ruumis.

Teiseks piiranguks on võimetus tuvastada passiivset kohalolekut. Näiteks kontorikeskkonnades, kus inimesed võivad pikalt liikumatult töötada, ei pruugi PIR-andurid nende kohalolekut üldse registreerida. Selline piirang võib viia olulise alahindamiseni ruumikasutuse tegeliku ulatuse hindamisel.

Lisaks tööpõhimõttest tulenevatele piirangutele võivad PIR-andurite tööd mõjutada ka väliskeskkonna tegurid. Tugev tuul ja väikeloomade liikumine võivad põhjustada valesignaale või vähendada andmete usaldusväärsust.

Kokkuvõtlikult võib öelda, et PIR-andurite kasutamisel sisekeskkonnas tuleb arvestada nii nende tehnoloogiliste piirangute kui ka keskkonnateguritest tingitud häiretega. Kuigi need andurid sobivad hästi lihtsate liikumiste tuvastamiseks, ei pruugi neist piisata keerukamate kohaloleku- ja liikumismustrite täpseks jälgimiseks.

1.1.3 Ultraheli kaugusandur

Ultraheli kaugusandur on seade, mis mõõdab objektide kaugust anduri suhtes. See töötab ultraheli põhimõttel, kus andur saadab välja kõrgsagedusliku helilaine ning mõõdab aega, mis kulub sellel objektilt tagasi peegeldumiseks. Selle aja põhjal arvutab seade välja objekti kauguse.

Kuigi ultraheli kaugusandurid on mõeldud eelkõige objektide kauguse mõõtmiseks, saab neid edukalt kasutada ka inimeste loendamiseks. Näiteks on kirjeldatud ultraheli kaugusanduritel põhinevat süsteemi, mis jälgib ruumi hõivatust [7]. Süsteem kasutab kahte strateegiliselt paigutatud ultraheli kaugusandurit, üks sisenemise ja teine väljumise tuvastamiseks. Selline seadistus võimaldab luua suunatudliku jälgimismehhanismi, mille abil on võimalik määrata

ruumis viibivate inimeste arv. Testimisel kõndis inimene korduvalt andurite eest läbi ning süsteem tuvastas iga läbimise korrektselt.

Kokkuvõttes on ultraheli kaugusandurid lihtsad, kuid tõhusad vahendid, mida saab peale kauguse mõõtmise kasutada ka ruumi hõivatuse ja inimeste liikumise jälgimiseks. Õigesti paigutatuna võimaldavad need andurid luua usaldusväärseid ja suunatundlikke loendamissüsteeme.

1.1.4 Ultraheli kaugusandurite kasutamise väljakutsed

On leitud, et ultraheli kaugusandurid suudavad usaldusväärset tuvastada üksikuid isikuid, kes läbivad ukseava ükshaaval [7]. Kuid täpsus langeb oluliselt olukordades, kus mitu inimest sisenevad või väljuvad samaaegselt, sellisel juhul kipub süsteem kogu gruppi käsitlema kui ühtainsat isikut.

Erinevate veatüüpide analüüsimisel on need jagatud kaheks peamiseks kategooriaks: tehnilised vead ja keskkonnateguritest põhjustatud vead [8]. Tehnilised vead on peamiselt seotud müraga ja nõrga signaaliga, mis raskendavad usaldusväärset tagasipõrkeaja mõõtmist. Samuti võivad objekti kaugus või ebasoodne nurk anduri suhtes vähendada kajasignaali tugevust, muutes mõõtmistulemused ebatäpseks või põhjustades mõõtmise ebaõnnestumise.

Keskkonnategurid, nagu temperatuur ja õhuniiskus, mõjutavad otseselt heli levimiskiirust. Eriti oluline on temperatuur, sest selle muutused mõjutavad helikiirust ning seeläbi ultraheli kaugusandurite mõõtetäpsust, kuna andurid arvutavad kaugust heli tagasipõrke aja põhjal.

Ultraheli kaugusandurid toimivad usaldusväärset lihtsates olukordades, näiteks kui üksikud isikud läbivad ukseava. Siiski väheneb nende täpsus märgatavalt keerukamates stsenaariumides, kus liigub korraga mitu inimest. Lisaks mõjutavad mõõtmistäpsust mitmed tehnilised ja keskkonnategurid, sealhulgas müra, signaali tugevus, objekti paigutus anduri suhtes ning keskkonnatingimused nagu temperatuur ja õhuniiskus.

1.1.5 PIR ja ultraheli kaugusandurite kombineeritud kasutamine

Kuna PIR-andur ei suuda piisava täpsusega tuvastada üksikuid objekte, on mõistlik seda kombineerida mõne teise tüüpi anduriga. Üheks näiteks on PIRUS-süsteem, milles kombineeriti PIR- ja ultraheli kaugusandureid inimeste loendamiseks [9]. Süsteemis oli üks PIR- ja üks ultraheli kaugusandur paigutatud ukseava lähedale, kus nende signaale töödeldi Arduino platvormi abil. Lahendus võimaldas eristada täiskasvanuid ja lapsi eelnevalt määratud kõrgusläve alusel ning tuvastada liikumissuunda. Katsetes saavutati 100% loendustäpsus olukorras, kus kuni kaks inimest sisenesid või lahkusid ruumist kuni ühe sekundilise ajavahega. Kui aga inimesi

liikus korraga rohkem kui kaks, langes täpsus 50% peale. Kahe erineva anduri kombineerimine oli põhjendatud, kuna need täiendavad teineteist, PIR-andur ei suuda täpselt määrata objektide kaugust ega liikumissuunda, samas kui ultrahelianduril on raskusi väikeste objektide, näiteks laste, tuvastamisega. Nende kooskasutamine parandas süsteemi üldist täpsust märgatavalt, aidates ühtlasi kompenseerida mõlema anduri puudusi.

See näide kinnitab, et PIR- ja ultraheli kaugusandurite kombinatsioon on kuluefektiivne ja praktiline lahendus inimeste loendamiseks siseruumides. Eriti olukordades, kus kaamerate kasutamine on piiratud privaatsusnõuete või rahaliste piirangute tõttu. Siiski tuleb arvestada, et kuigi süsteem toimib väga täpselt väikse hulga inimeste puhul, ei ole see suurema rahvahulga korral enam sama täpne.

1.1.6 Termokaamerad

Varasemates allikates on rõhutatud, et PIR- ja ultraheli kaugusandurite kasutamisel ei ole võimalik täpselt loendada mitut inimest korraga. Üheks võimalikuks lahenduseks antud piirangule on kaamerate kasutamine. Siiski ei ole tavakaamera sobilikud, kui eesmärgiks on säilitada jälgitavate isikute anonüümsus.

Selles kontekstis pakuvad sobiva alternatiivi termokaamerad. Termokaamerad on seadmed, mis tuvastavad ja visualiseerivad objektide poolt kiiratavat infrapunakiirgust, võimaldades tuvastada temperatuurierinevusi, mida inimsilm ei suuda eristada. Erinevalt tavakaamerateist ei salvesta termokaamerad kujutist, mille alusel oleks võimalik isikuid tuvastada näiteks näojoonte või muude visuaalsete tunnuste põhjal. Seetõttu kujutavad termokaamerad endast privaatsust säilitava tehnoloogiana olukordades, kus on vaja jälgida inimeste liikumist või kohalolekut, samas vältides otsest isikuandmete töötlemist.

Kokkuvõttes pakuvad termokaamerad tõhusat ja privaatsust säilitavat alternatiivi inimeste jälgimiseks olukordades, kus traditsioonilised andurid jäävad piirangutega hätta. Kuna termokaamerad tuvastavad ainult soojuskiirgust ega salvesta isikut tuvastavaid visuaalseid andmeid, sobivad need hästi lahendustesse, kus on oluline tagada nii täpsus kui ka isikuandmete kaitse.

1.1.7 Närvivõrkudel põhinev inimeste loendamine termokaamera abil

Närvivõrke on kasutatud inimeste loendamiseks madala resolutsiooniga MLX90640 termokaamera (32×24 pikslit) piltide põhjal [10]. Vastavas uuringus treeniti mudeleid enam kui

13000 kontorikeskkonnast pärit märgendatud kaadri põhjal. Mudel genereeris tiheduskaarte, mille alusel arvutati inimeste arv.

Keskmine absoluutne viga (MAE) oli vaid 0,28, mis tähendab, et mudeli ennustus erines tegelikust inimeste arvust keskmiselt vähem kui ühe inimese võrra. MAE on levinud täpsusnäitaja, mis näitab, kui palju ennustused keskmiselt tegelikust väärtusest erinevad.

Mudel töötas edukalt ka väikestes seadmetes, näiteks ESP32 ja Arduino Portenta H7, mis näitab, et lahendus sobib hästi kasutamiseks privaatsust ja mobiilsust nõudvates olukordades.

1.1.8 Termokaamerate väljakutsed

Termokaamerate kasutamisega tuleb arvestada teatud füüsikaliste ja praktiliste piirangutega [11]. Esiteks tuleb arvestada infrapunakiirguse füüsikaliste omadustega, see ei läbi klaasi ega vett, vaid peegeldub nende pindadelt. Seetõttu ei suuda termokaamerad tuvastada inimest, kes seisab klaasukse taga, samas kui tavaline kaamera suudab neid läbi klaasi näha.

Teiseks ei võimalda termokaamerad isikuid visuaalselt tuvastada, kuna salvestatakse ainult soojusjälgi, mitte inimeste näojooni ega muid isiku äratundmiseks vajalikke tunnuseid. Meie kasutusjuhtumi puhul on see aga pigem eelis, kuna eesmärgiks on inimeste arvu määramine anonüümselt, ilma neid isikuliselt tuvastamata.

Kokkuvõttes võib öelda, et termokaamerate peamine piirang on see, et nad ei näe läbi läbipaistvate materjalide. Lisaks ei suuda termokaamerad isikuid visuaalselt tuvastada, mis muudab need sobivamaks just selle lõputöö eesmärkide jaoks.

1.2 Arvutinägemine inimeste tuvastamiseks

Selles peatükis käsitletakse arvutinägemise tööpõhimõtteid, sealhulgas seda, kuidas arvutinägemist saab rakendada inimeste tuvastamiseks. Samuti antakse ülevaade selle tehnoloogia peamistest eelistest ja puudustest. Lisaks tutvustatakse varasemaid lähenemisviise ja uuringuid, kus on kasutatud arvutinägemist koos termopiltidega inimeste tuvastamiseks.

1.2.1 Arvutinägemine

Arvutinägemine (ingl k computer vision) on tehisintellekti (AI) valdkond, mille eesmärk on õpetada arvuteid ja süsteeme mõistma ning tõlgendama visuaalset teavet, nagu pildid, videod ja muud visuaalsed sisendid [12].

Arvutinägemine tugineb süvaõppele ja konvolutsioonilistele neurovõrkudele (CNN), mis võimaldavad arvutil iseseisvalt õppida visuaalsetest andmetest. Süvaõppe abil õpib arvuti

iseseisvalt visuaalsetest andmetest mustreid ja seoseid tuvastama ning pilte klassifitseerima. CNN-id toetavad seda protsessi, jagades pildid osadeks ja tuvastades kihiti järjest keerukamaid tunnuseid. Nii suudab arvutinägemine pilte tõlgendada sarnaselt inimnägemisele, sageli kiiremini ja täpsemalt [12]. Arvutinägemisel on laialdased rakendusvõimalused, ulatudes tervishoiust ja transpordist kuni jaekaubanduse, põllumajanduse, turvalisuse, tööstusautomaatika ning arvutimängudeni [13].

1.2.2 Plussid ja miinused

Ühe suurima eelisenä tagab arvutinägemine kõrge täpsuse, tänu masinõppe ja süvaõppe algoritmidele suudavad kaasaegsed süsteemid tuvastada ja klassifitseerida inimesi pildidel ning videotest väga suure täpsusega. Üks enim kasutatavaid meetodeid on YOLO (You Only Look Once), mis on reaajas objektituvastuse algoritm [14]. See võimaldab tuvastada ja lokaliseerida objekte pildidel ning videotest üheainsa närvivõrgu läbimisega. Lisaks suudavad arvutinägemise süsteemid analüüsida visuaalset teavet reaajas, võimaldades kohest reageerimist tuvastatud olukordadele, see on eriti oluline turvasüsteemides ja transpordis.

Siiski kaasnevad arvutinägemise rakendamisega ka teatud piirangud. Eriti keerukate süvaõppemudelite ja kõrge eraldusvõimega visuaalse teabe töötlemine nõuab märkimisväärset arvutusvõimsust ja energiakulu, mis võib osutuda probleemseks. Samuti eeldab suurte andmemahude töötlemine ja salvestamine võimekat riistvara, mis omakorda suurendab süsteemi kulukust ja keerukust.

1.2.3 Inimeste loendus termopildil

Inimeste tuvastamist termopildidel otsingu- ja päästemiisioonide toetamiseks on uuritud, kasutades YOLOv8 mudelit [15].


Uuringus koostati uus andmestik, mis sisaldas 17 148 halltoonis termopilti ja 90 882 märgendust, kogutud erinevatest keskkondadest. Mudelitena kasutati YOLOv8 erinevaid versioone, alates Nano-st kuni Extra Large-ni. Kõiki mudelid treeniti samal andmestikul.

Tulemused näitasid, et YOLOv8x saavutas kõrgeima täpsuse AP@50 oli 95%, täpsus 92,7% ja tundlikkus 87,9%. Isegi väikseim mudel, YOLOv8n, säilitas üle 91% täpsuse, mis teeb selle sobivaks madala ressursikasutusega seadmetele. Kõik mudelid näitasid kõrget täpsust ja usaldusväärsust, sobides hästi reaajas kasutamiseks.

See tõestab, et YOLOv8 mudelid on väga tõhusad inimeste tuvastamisel termopiltide abil ning sobivad kasutamiseks mitmesugustes keskkondades.

1.3 Inimeste loendamine droonidel

Maapealsete droonide kasutamine inimeste loendamisel ühendab endas mobiilsuse ja täpsed andurid, pakkudes kuluefektiivset ja paindlikku lahendust. Erinevalt statsionaarsetest süsteemidest suudavad droonid dünaamiliselt liikuda erinevates keskkondades, võimaldades tõhusamat inimeste tuvastamist piiratud aladega siseruumides, kuhu statsionaarsed andurid ei ulatu ja kus inimeste tuvastamiseks oleks vaja lisaandurid (vaata Joonis 1). Statsionaarsete andursüsteemide puhul määrab nende paigutus keskkonnas nende efektiivsust – piiratud vaatevälja tõttu tuleb need asetada strateegilistesse punktidesse, näiteks koridoride algusesse ja lõppu. Samuti tuleb vältida suuri füüsilisi takistusi, mis võivad nähtavust piirata. Seetõttu nõuab keerukate siseruumide katmine statsionaarsete süsteemidega mitmete andurite kasutamist. Paigutades inimeste tuvastamise andurid mobiilsele platvormile, näiteks droonile, saab sama ala katta vähesemate anduritega ja suurema paindlikkusega. Selline lähenemine võimaldab rahvahulkade jälgimist ka siis, kui droon täidab muid ülesandeid, nagu näiteks koristustööd, võimaldades mitme funktsiooni täitmist samaaegselt ja vähendades ühtlasi energiakulu.



Joonis 1. Siseruumides inimeste loenduseks võib kasutada nii statsionaarseid kui ka droonipõhiseid andursüsteeme. Droonil olevate andurite ulatus on märgitud punase alana, samas droonile ligipääsetav ala on märgitud halliga.

Siiski kaasnevad droonide kasutamisega ka tehnilised ja praktilised väljakutsed. Kitsastes ja rahvarohketes ruumides on vaja täpset navigatsioonisüsteemi ning tõhusat andurite

integreerimist, et tagada usaldusväärne andmekogumine ja vältida drooni kinnijäämist. Samuti tuleb arvestada droonide energiatarbimisega, kuna pidev liikumine ja andmete töötlemine nõuab märkimisväärseid ressursse.

YOLO-IHD nimelist reaajas inimeste tuvastamise süsteemi, mis on loodud spetsiaalselt sisetingimustes töötavatele droonidele, on tutvustatud ühes uuringus [16]. Tuvastamiseks kasutatakse RGB-kaameraga varustatud mehitamata õhusõidukeid (UAV), süsteem põhineb optimeeritud YOLOv7-tiny arhitektuuril. Uurimistöö keskendub visuaalsete tunnuste tuvastamisele RGB-piltidel, eesmärgiga parandada inimeste tuvastamis täpsust keerulistes siseruumides, nagu halva valgustuse või müraga keskkondades.

Käesolev lõputöö erineb nimetatud uurimistööst mitmes olulises aspektis. Esiteks kasutatakse RGB-kaamera asemel termokaamerat, mis võimaldab inimeste tuvastamist ka vähese valgustuse ja visuaalselt keerulistes tingimustes, pakkudes seeläbi suuremat töökindlust erinevates keskkondades. Lisaks on tuvastussüsteem integreeritud autonoomsetele maapealsetele droonidele, mis täidavad samaaegselt ka muid praktilisi ülesandeid, näiteks koristamist. Selline lähenemine suurendab drooni tööaja kasutegurit, kuna tuvastusfunktsioon töötab taustal ilma peamist ülesannet häirimata. Integreeritud lahendus muudab süsteemi energiasäästlikumaks ja sobivamaks olukordadesse, kus ressursid on piiratud ning statsionaarsete süsteemide kasutamine ei ole võimalik.

Kokkuvõttes näitab droonide kasutamine inimeste loendamisel suurt potentsiaali just keerukates ja dünaamilistes siseruumides, kus traditsioonilised lahendused tihti ebaõnnestuvad. Kuigi seni tehtud tööd on keskendunud peamiselt ainult inimeste tuvastamisele ja loendamisele, püüab käesolev lõputöö lahendada seda probleemi teisiti – integreerides inimeste loendamise olemasolevatesse süsteemidesse, mis täidavad ka muid ülesandeid. Selline lähenemine muudab süsteemi taskukohasemaks, tõhusamaks ning paremini sobivaks praktilisteks rakendusteks.

2. Inimeste arvu ennustamiseks kasutatud masinõppe- ja arvutinägemismudelid

Inimeste arvu ennustamiseks andurite andmete põhjal kasutati selles töös kahte erinevat lähenemist. Esimeses lähenemises rakendati erinevaid masinõppemeetodeid, mille eesmärk oli ennustada inimeste arvu andurite vaateväljas kogutud väärtuste alusel. Katsetatud mudelite hulka kuulusid lineaarne regressioon (`LinearRegression`), otsustuspuu regressioon (`DecisionTreeRegressor`), K-naabri regressioon (`KNeighborsRegressor`), toetavate vektorite regressioon (`SVR`), kus andmed standardiseeriti eelnevalt `StandardScaler`-i abil, samuti `Gradient Boosting Regressor` ja `Random Forest Regressor`. Kõik mainitud masinõppemudelid pärinevad Pythonis kasutatavast `scikit-learn` teegist. Mudelid valiti nende erinevate tööpõhimõtete ja võimekuse tõttu, võimaldades tuvastada sobivaim lähenemine antud probleemile.

Teise lähenemisena kasutati arvutinägemise meetodit, mille eesmärk oli tuvastada ja loendada inimesi termokaamera salvestatud termopiltidelt. Selleks katsetati mitmeid YOLO (`You Only Look Once`) objektituvastuse mudeli versioone, sealhulgas `YOLOv8n`, `YOLOv8s`, `YOLOv9s` ja `YOLOv9m`. YOLO on kaasaegne ja laialdaselt kasutatav sügavõppepõhine mudel, mis sobib hästi reaalajas objektide tuvastamiseks. `YOLOv8` kasutuselevõtt põhines varasematel teadustöödel, kus selle erinevaid versioone on edukalt rakendatud inimeste loendamiseks eri keskkondades. Lisaks hinnati uusima põlvkonna `YOLOv9` mudelite täpsust ja sobivust inimeste tuvastamise ülesannetes.

2.1 Masinõppe andmete eeltöötlus

Kogutud andmed koondati `Pandas` teegi abil ühtsesse `DataFrame`'i. Seejärel eemaldati kõik puuduvad väärtused (`NaN`), mis olid tekkinud ajutiste ühendusekatkestuste tõttu anduritega. Andmete juhuslikuks järjestamiseks kasutati `sample()` funktsiooni parameetritega `frac=1` ja `random_state=42`, et tagada reprodutseeritavus.

Anduritelt saadud andmed skaleeriti vahemikku 0 kuni 1, kasutades `MinMaxScaler` skaleerijat teegist `sklearn`. Andmelekkimise vältimiseks viidi `fit_transform()` läbi ainult treeningandmetel, samas kui testandmetele rakendati eelnevalt õpitud teisendust `transform()` abil.

Lõpetuseks jagati andmestik treening- ja valideerimiskogumiks, kus 80% andmetest kasutati mudeli treenimiseks ning 20% valideerimiseks, et hinnata mudeli täpsust.

2.2 YOLO andmete eeltöötlus

Selleks et YOLO mudel oleks võimeline tuvastama inimesi termopiltidel, viidi pildid esmalt tagasi kahemõõtmelisse kujule. Järgmisena normaliseeriti kõik piksliväärtused vahemikku 0–255, et standardiseerida intensiivsus edasiseks töötlemiseks ja visualiseerimiseks. Kuna selles lõputöös kasutatav YOLO mudel aktsepteerib ainult 640×640 pikslise resolutsiooniga sisendpilte, tuleb algsed 32×24 pikslised andmed esmalt skaleerida mõõtmetesse 320×240, säilitades kuvasuhte. Seejärel lisatakse kujutise üla- ja alla mustad äärealad, et muuta pilt ruudukujuliseks (320×320) ilma seda moonutamata. Lõpuks skaleeritakse pilt YOLO jaoks nõutud mõõtmetesse 640×640 pikslit.

Pärast termopiltide eelprotsessimist tuli need sildistada. Selleks kasutati skripti, mis tuvastas kuumad piirkonnad ja joonistas nende ümber kastid. Skript töötas hästi olukordades, kus pildil oli kuni kaks inimest. Rohkemate isikute korral tuli pildid käsitsi üle vaadata ja sildistada Roboflow veebiplatvormil, mis pakkus kasutajasõbralikku ja efektiivset töövahendit andmete märgendamiseks.

Mudeli üldistusvõime suurendamiseks ja andmestiku mitmekesistamiseks kasutati andmete augmentatsiooni teeki Albumentations, kust kasutati erinevaid meetodeid treeningpiltide modifitseerimiseks (vaata Lisades Tabel 5). Nende võtetega tekitatud treeningpiltides simuleerivad drooni liikumise ja erinevate vaatenurkade mõju, seeläbi suurendades mudeli üldistusvõimet ja täpsust.

Lõpuks jagati kogu andmestik juhuslikult kaheks 80% treeninguks ja 20% mudeli esmase täpsuse hindamiseks.

2.3 Hindamismõõdikud mudelite täpsuse analüüsiks

Selles alapeatükis kirjeldatakse, milliseid mõõdikuid kasutatakse käesolevas lõputöös loodud mudelite täpsuse hindamiseks.

RMSE: Mõõdab prognooside kõrvalekallet tegelikest väärtustest ja on tundlik suurte vigade suhtes. Selline tundlikkus on antud kontekstis oluline, kuna suuremad loendamisvead võivad mõjutada süsteemi üldist usaldusväärsust olulisemalt kui väiksemad kõrvalekalded. Kus \hat{y}_i tähistab i -nda andmepunkti ennustatud väärtust, kus y_i on vastav tegelik väärtus ning n on andmepunktide koguarv.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (1)$$

MAE: Näitab, kui suur on mudeli ennustuste keskmine kõrvalekalle tegelikest väärtustest absoluutväärtuses. Erinevalt RMSE-st ei karista MAE suuri vigu nii tugevalt. Kus \hat{y}_i tähistab i -nda andmepunkti ennustatud väärtust, kus y_i on vastav tegelik väärtus ning n on andmepunktide koguarv.

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

Accuracy (täpsus): Accuracy näitab, kui suur osa mudeli ennustustest jääb lubatud veapiiri $\varepsilon = 0,5$ sisse võrreldes tegelike väärtustega. Kus n on ennustuste arv, \hat{y}_i on ennustatud väärtus, y_i on tegelik väärtus ning ε on lubatud veapiir (nt 0,5). $\mathbb{I}(\cdot)$ on indikaatorfunktsioon, mis tagastab 1, kui tingimus on täidetud, ja 0 vastasel juhul.

$$\text{Accuracy} = \frac{1}{n} \sum_{i=1}^n \mathbb{I}(|\hat{y}_i - y_i| \leq \varepsilon) \quad (3)$$

R^2 : R^2 näitab, kui hästi mudel suudab selgitada andmete üldist varieeruvust. Siin tähistab y_i tegelikku väärtust i -nda andmepunkti kohta, \hat{y}_i on mudeli poolt ennustatud väärtus sama andmepunkti kohta, \bar{y} on tegelike väärtuste aritmeetiline keskmine ning n tähistab andmepunktide koguarvu.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

Precision (täpsus): Näitab, kui suur osa YOLO mudeli poolt tuvastatud objektidest olid tegelikult õiged sihtobjektid. Kus TP on tõelised positiivsed ning FP valepositiivsed tulemused.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (5)$$

Recall (tundlikkus): Tundlikkus näitab, kui palju tegelikult olemasolevatest sihtobjektidest (nt inimestest) YOLO mudel suutis ära tuvastada. Kus FN on valenegatiivsed tulemused.

$$\text{Recall} = \frac{TP}{TP + FN} \quad (6)$$

F1-skoor: F1-skoor on täpsuse(precision) ja tundlikkuse(recall) harmooniline keskmine, mis pakub tasakaalustatud hinnangut mudeli üldisele täpsusele ja suutlikkusele tuvastada positiivseid juhtumeid.

$$F_1 = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (7)$$

Keskmine täpsus (mAP₅₀₋₉₅): Mõõdab, kui hästi mudel suudab objekte tuvastada erinevatel täpsuslävenditel. See arvutatakse kasutades IoU (Intersection over Union) väärtusi vahemikus

0.50 kuni 0.95. IoU on mõõdik, mis näitab, kui hästi mudeli ennustatud objekt kattub tegeliku objektiga. Tulemuseks on näitaja, mis annab põhjaliku ülevaate mudeli tuvastusvõime täpsusest ja usaldusväärsusest erinevates olukordades. Kus AP (keskmine täpsus) mõõdab mudeli täpsust ühel kindlal IoU lävel, arvestades nii täpsust kui täielikkust.

$$\text{mAP}_{50-95} = \frac{1}{10} \sum_{i=0}^9 \text{AP}_{0.50+0.05i} \quad (8)$$

2.4 Treeningukeskkond

Uurimistöö käigus kasutati mudelite treenimiseks Google Colab'i keskkonda, mis võimaldas kasutada piisava jõudlusega graafikaprotsessoreid (GPU) ja tensorprotsessoreid (TPU). YOLO mudelite treenimiseks kasutati NVIDIA Tesla T4 GPU-d, samas kui masinõppemudelite treenimine viidi läbi v2-8 TPU abil, et tagada suurem kiirus ja efektiivsus suuremahuliste andmekogumite töötlemisel.

3. Prototüübi arendus ja andmete kogumine

Käesolev peatükk kirjeldab loodud süsteemi riist- ja tarkvaralist ülesehitust ning andmete kogumise protsessi kolmes erineva keerukusastmega keskkonnas. Eesmärk on luua usaldusväärne andmestik, mis võimaldab hinnata inimeste tuvastamise täpsust eri tüüpi mudelite abil.

3.1 Riistvaraline ülesehitus

Süsteemi riistvaraline osa koosneb ESP32-põhistest mikrokontrolleritest, erinevat tüüpi anduritest ning nende paigutusest droonile. Süsteemi disainimisel oli eesmärgiks saavutada 360-kraadine vaateväli, ja tagada andmete täpne kogumine reaajas ka drooni liikudes.

3.1.1 Kontrollerid

Katsetes kasutati M5Stacki ESP32-põhiseid mikrokontrollereid nende taskukohasuse, energiatõhususe ning hea laiendatavuse tõttu. Need võimaldavad hõlpsasti erinevate andurite lisamist, andmete töötlemist ja reaajas edastamist.

Kasutuses oli viis **M5StickC PLUS** seadet [17], mis põhinevad ESP32-PICO-D4 süsteemikiibil (240 MHz kahe tuumaga protsessor, 520 KB SRAM, 4 MB välmälu). Igal seadmel on sisseehitatud 1.14-tolline LCD-ekraan, 120 mAh aku ning andurid nagu 6-teljeline IMU ja mikrofoni. Täiendavate andurite ühendamise toimub GROVE-liidese kaudu. Reaajas andmeedastus toimus WebSocket-protokolli vahendusel üle sisseehitatud WiFi-ühenduse. Pikemaajaliseks tööks kasutati toiteallikana USB-C ühendust, mis ühendus aku droonile kinnitatud akupanga külge.

Lisaks kasutati üht **ATOM Lite** mikrokontrollerit [18], mis põhineb samuti ESP32-PICO-D4 kiibil. Tegemist on väiksema ja lihtsustatud seadmega, millel puudub ekraan ja aku, kuid mis sobib hästi olukordadesse, kus on tagatud väline toide ja visuaalne tagasiside pole vajalik. Seade sisaldab RGB-LEDi, nuppu ja GROVE-liidest, võimaldades kiiret prototüüpimist. ATOM Lite lisati süsteemi täienduseks, kuna katseteks ei olnud rohkem M5StickC PLUS seadmeid saadaval.

3.1.2 Andurid

Süsteemis kasutati kolme tüüpi andureid passiivsed infrapunaandurid (PIR), ultraheli kaugusandurid ja termokaamerad.

TMOS PIR Unit (STHS34PF80) on I2C-liidese kaudu töötav andur, mis suudab tuvastada inimeste kohalolekut, liikumist ja soojuskiirgust [19]. Seade eristab nii liikuvaid kui ka paigal seisvaid objekte ning selle vaateväli on 80 kraadi ning tuvastuskaugus üle 2 meetri.

Teise infrapunaandurina kasutati **PIR Motion Sensorit (AS312)**, mis tuvastab liikumist infrapunakiirguse muutuste põhjal ning annab binaarse väljundi [20]. See seade ei tuvasta paigal seisvaid objekte ega mõõda temperatuuri, töötab GROVE B-liidese kaudu ning selle vaateväli on alla 100 kraadi ja tuvastuskaugus võib ulatuda kuni 5 meetrini.

Kasutati kahte **RCWL-9620** tüüpi ultraheli kaugusandurit, mis ühenduvad I2C-liidese kaudu ning nende mõõteulatus on 2 cm kuni 450 cm, kuid praktikas osutus usaldusväärseks kauguseks kuni 200 cm [21].

Kasutati nelja **MLX90640** sensoril põhinevat termokaamerat: kaks tavalist I2C-ühendusega termokaamerat ning kaks spetsiaalselt M5StickC seadmetele loodud „Thermal Camera Hat“ versiooni [22]. Kõik neli termokaamerat töötavad lahutusvõimega 32×24 pikslit ning neil on 110° × 75° vaateväli.


Prototüübi ehitamise raames tuli integreerida samasse süsteemi mitu I2C-liidest kasutatavat andurit. Kuigi I2C-protokoll võimaldab mitme seadme ühendamist ühisele andmeliinile, eeldab antud protokoll, et igal seadmel oleks unikaalne aadress. Siiski on mitmel komponendil (näiteks termokaameratel) vaikimisi identne aadress, seega oli vaja nende kasutamiseks kasutada täiendavad komponendina **I2C Hub-i (PCA9548APW)**. I2C Hub võimaldas jagada I2C-liini kaheksaks eraldi kanaliks, mida sai tarkvaraliselt juhtida. See võimaldas ühendada mitu andurit ühe mikrokontrolleri külge, vähendades lisakontrollerite vajadust ja lihtsustades süsteemi arhitektuuri. Tulemuseks oli võimalus koguda sünkroniseeritud andmeid mitmelt andurilt ühe I2C-liidese kaudu [23].

3.1.3 Seadmete paigutus

Kõik seadmed paigutati 14 × 14,5 cm suurusele kastile (vaata Joonis 2). See mõõt valiti praktilistel kaalutlustel – kast oli piisavalt suur, et mahutada kõik vajalikud komponendid (sh andurid, mikrokontrolleri, toiteallika) kompaktselt ja turvaliselt, samas säilitades süsteemi mobiilsuse ning lihtsustades seadme paigaldust ja liigutamist katsekeskkonnas. Andurid kinnitati kasti ette, taha ja külgedele, et katta maksimaalselt laia vaatevälja ning minimeerida pimenurki, mis tagab täpsema tuvastamise igas suunas.

Tabel 1. Andurite paigutus droonil

Asukoht	Paigaldatud andurid
Eesmine külg (liikumise suund)	TMOS PIR Unit (STHS34PF80), Thermal Camera Unit (MLX90640), Ultrasonic Distance Unit I2C
Tagumine külg	Thermal Camera Unit (MLX90640), PIR Motion Sensor (AS312), Ultrasonic Distance Unit I2C
Külgedel (vasak ja parem)	2 × M5StickC Thermal Camera Hat (MLX90640), üks kummalgi küljel



Joonis 2. Andurite füüsiline paigutus droonil eestvaates.

Süsteemi ülesehituses oli andurite ühendus jaotatud mitme mikrokontrolli vahel (vaata Tabel 1). Peamine M5StickC PLUS oli ühendatud I2C Hubiga ning haldab eesmist TMOS PIR andurit, ja samuti eesmist ja tagumist termokaamerat. Ühtlasi vastutab peamine M5StickC PLUS kogutud andmete töötlemise ja reaajas edastamise eest. ATOM Lite on ühendatud tagumise PIR anduriga ja kogub selle andmeid. Eesmine ja tagumine ultraheli kaugusandur on kumbki ühendatud oma M5StickC PLUS kontrolleri, mis tagab nende sõltumatu töö. Külgmised M5StickC PLUS seadmed haldavad vastavalt kummalgi küljel asuvat termokaamerat.

3.2 Andmete kogumise tarkvara arendamine

Süsteemi toimimiseks ja andmete kogumiseks arendati vajalik tarkvara, mis hõlmas andurseadmete programmeerimist ning veebipõhise kasutajaliidese loomist. Mikrokontrolleritel

töötavad Arduino-põhised skriptid vastutavad anduritelte andmete kogumise, töötlemise ja edastamise eest. Andmed edastatakse reaajas WebSocket-protokolli kaudu JSON-formaadis kasutajaliidesse, kus need on visualiseeritavad ja salvestatavad edasiseks analüüsiks.

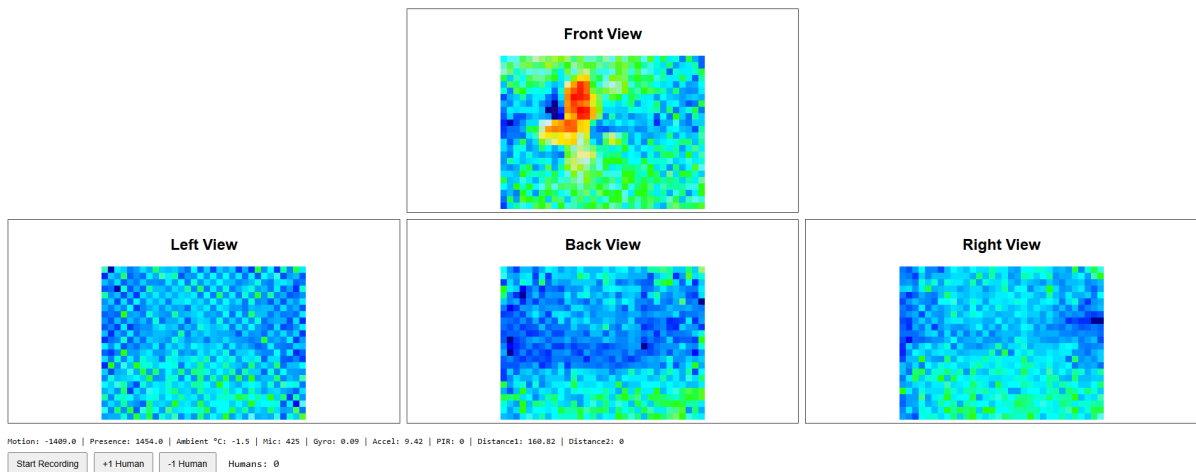
3.2.1 Arduino skriptid

Peamine M5StickC PLUS seade edastab mitmesuguseid sensoriandmeid, mis hõlmavad liikumise, kohaloleku ja temperatuuri väärtusi TMOS PIR-andurilt, helitaset sisseehitatud mikrofonist ning liikumise intensiivsust kiirendus- ja güroskoobianduritest. Lisaks saadetakse kahe termokaamera pildid, mis kujutavad temperatuuri jaotust 32×24 piksli resolutsiooniga. Edastatavate muutujate loetelu ja vastavad kirjeldused on esitatud Tabelis 2.

Tabel 2. M5StickC PLUS põhiseadme skripti saadetatavad andmed

Nimi	Kirjeldus
motion	Liikumisväärtus TMOS PIR-andurilt
presence	Kohaloleku väärtus TMOS PIR-andurilt
temperature	Temperatuur (°C), kogutud TMOS PIR-andurilt
mic	Helitugevuse tase, kogutud M5StickC PLUS sisseehitatud mikrofoniga
gyroMagnitude	Güroskoobi vektorväärtuse tugevus (liikumise intensiivsus), arvutatud kolme telje (x, y, z) väärtuste ruutjuurena, kogutud seadme sisseehitatud güroskoobilt
accelMagnitude	Kiirendusanduri vektorväärtuse tugevus, arvutatud samal viisil nagu güroskoobi puhul, kogutud sisseehitatud kiirendusandurilt
thermal1	Esikaamera termopildi 32×24 piksli temperatuuriväärtused
thermal2	Tagakaamera termopildi 32×24 piksli temperatuuriväärtused

Lisaks põhiseadmele edastavad teised mikrokontrollerid andmeid vastavalt neile ühendatud anduritele. Näiteks tagumise PIR-anduri väärtused saadetakse binaarse kujul, ultraheli kaugusandurid edastavad kaugusmõõtmisi ning külgmised termokaamerad termopilte. Kõik need andmed koondatakse reaajas WebSocketsi kaudu kasutajaliidesesse visualiseerimiseks ja töötlemiseks.



Joonis 3. Andmete kogumiseks loodud kasutajaliides

3.2.2 Veebipõhine kasutajaliides andmete salvestamiseks

Lõputöö raames loodi lihtne veebipõhine kasutajaliides andmeid reaajas visualiseerimiseks ja salvestamiseks (vaata Joonis 3). Rakendus on arendatud HTML-i ja JavaScripti abil ning suhtleb mikrokontrolleritega WebSocket-ühenduse kaudu.

Kasutajaliides võimaldab alustada ja peatada andmesalvestust. Salvestamise alustamisel talletatakse kõik WebSocketi kaudu saabuvad andmed CSV-vormingus faili, kuni kasutaja selle käsitsi peatab. Kasutaja saab määrata andurite vaateväljas viibinud inimeste arvu, kasutades selleks nuppe, millega on võimalik käsitsi loendust suurendada või vähendada. Sisestatud väärtused salvestatakse sünkroonitult koos andurandmetega samasse faili.


Selline lahendus võimaldas koguda ühtset ja ajaliselt sünkroniseeritud andmestikku erinevatelt mikrokontrolleritelt, samaaegselt registreerides tegelikku inimeste arvu, võimaldades andmete kasutamist nii masinõppemudelite treenimiseks kui ka süsteemi täpsuse hindamisel.

3.2.3 Kasutajaliides YOLO mudeli treeningandmete salvestamiseks

Lõputöö käigus töötati välja Pythoni-põhine kasutajaliides, mille eesmärk oli lihtsustada termopiltide kogumist ja märgistamist YOLO-mudeli treenimiseks. Rakendus kasutab OpenCV teeki reaajas kaamerapiltide kuvamiseks ning võimaldab kasutajal vajutada klaviatuuril R-klahvi, et salvestada andmed.

Kasutajaliidese loomise peamine eesmärk oli andmete kogumise ja töötlemise protsessi tõhustamine. See säästis märkimisväärselt aega, kuna võimaldas termopiltide reaajas salvestamist koos automaatse eeltöötlemisega, mis omakorda lihtsustas andmete ettevalmistamist mudeli treenimiseks.


Enne salvestamist läbivad termopildid mitme-etapilise eeltötluse, et need vastaksid vastavaks YOLO mudelite nõuetele. Töödeldud pildid ning automaatselt genereeritud objektivastusemärgendid salvestetakse eraldi failidena. Märgistamise automatiseerimiseks kasutatakse eelnevalt treenitud YOLOv8m mudelit, mis määrab pildidel inimeste asukohad. Mudeli poolt genereeritud märgendid salvestatakse koos pildiga ning neid saab vajadusel käsitsi korrigeerida. Selline poolautomaatne lähenemine kiirendab märgistamisprotsessi oluliselt. Kuigi mudel ei olnud veatu ja tegi teatud olukordades ebatäpseid ennustusi, vähendas see märgatavalt vajadust kõiki pilte käsitsi töödelda, muutes treeningandmestiku koostamise oluliselt tõhusamaks (vt Joonis 4).



Joonis 4. Kasutajaliides YOLO-mudeli andmete salvestamiseks. Kuvatud on nelja eri suunas asetseva termokaamera vaated, millest ühel on kuvatud ja märgistatud inimene

3.3 Eksperimentaalne seadistus ja andmete kogumine

Andmete kogumise eesmärk oli hinnata loodud süsteemi võimekust tuvastada ja loendada inimesi erinevates siseruumides esinevates olukordades. Katsed viidi läbi kolmes järjestikusel etapil, mis erinesid keerukusastme, inimeste paiknemise mustri ning süsteemi liikumisvõime poolest (vaata Joonis 5). Kõik katsed viidi läbi Tartu Ülikooli Delta keskuse ruumides.



Joonis 5. Andmete kogumiseks teostatud katsed

3.3.1 Eksperimentaalse seadistuse kirjeldus

Kõik andurid ja kontrollerid olid paigaldatud peatükis 3.1.3 kirjeldatud korpusesse, mis võimaldas seadme paigaldamist nii statsionaarselt kui ka liikumisvõimelise drooni peale. Seadme töösükkel oli määratud 0,5 Hz sagedusele ehk 2 kaadrit sekundis, mis määras andmete kogumise intervalli. Andmestik sisaldas nii andurväärtusi kui ka kasutajaliidese kaudu sisestatud tegelikku inimeste arvu, mida kasutati hiljem mudelite koolitamiseks ja täpsuse hindamiseks.

3.3.2 Katse 1: Kontrollitud katsekeskkond

Selle etapi eesmärk on koguda andmeid erineva suurusega inimrühmade kohta (0–5 inimest). Iga rühmasuuruse kohta tehakse eraldi salvestus, mis kestab viis minutit. Kokku salvestatakse 30 minutit andmeid. Rühmade eraldi salvestamine väldib andmestiku kallutatust ning tagab, et kõik rühmasuurused on ühtlaselt esindatud. Katsed toimuvad kontrollitud keskkonnas, kus osalejad liiguvad juhuslikult andurite vaateväljas: seistes paigal või liikudes eri kiiruse ja suunaga (sh lähenedes ja eemaldudes anduritest).

3.3.3 Katse 2: Reaalne töökeskkond

Teise katse eesmärk on koguda andmeid reaalses kontorikeskkonnas, kus inimeste arv samuti varieerub vahemikus 0 kuni 5. Erinevalt esimesest katses ei jaotata andmeid inimeste arvu alusel, keskendutakse andurite asukoha muutmisele ruumis. Iga mõõtmise kestab kolm minutit, pärast mida paigutatakse andurid juhuslikult uude kohta ruumis. Kokku tehakse viis mõõtmist erinevas asukohas, salvestades andmeid kokku 15 minutit. Selline lähenemine arvestab kontorikeskkonna potentsiaalseid häirivaid tegureid, nagu arvutid, laadijad ja muud soojusallikad, mis võivad mõjutada andurite töökindlust.

3.3.4 Katse 3: Liikuv andurplatvorm

Kolmanda katse eesmärk on valideerida mudelit liikuval andurplatvormil. Antud andmekogumine teostati teisest andmekogumisest erinevas kontoriruumis. Andurid paigaldati koristusdroomile, mis liikus ruumis ringi ja samal ajal tuvastas ruumis viibivate inimeste arvu. Andmeid kogutakse kokku kaheksa minuti jooksul. Liikuv droon lisab andmetele keerukust, kuna liikumine võib põhjustada pildi hägusust või muid häireid. Samas võimaldab see koguda andmeid olukordadest, kus inimesed liiguvad loomulikult vastavalt oma tavapärasele käitumismustrile. Selline seadistus aitab hinnata mudeli töökindlust reaalses ja muutlikus keskkonnas.

4. Tulemused

Selles peatükis käsitletakse uurimistöö käigus treenitud masinõppe- ja YOLO-mudeleid ning kirjeldatakse samm-sammult protsessi, mille abil valiti parim inimeste loendamise mudel. Eesmärgiks oli välja selgitada, millised mudelid sobivad kõige paremini erinevates siseruumides toimuvates olukordades usaldusväärseks loendamiseks. Protsess hõlmas nii masinõppemudeleid kui ka YOLO arvutinägemismudeleid, mida testiti kolmest katsest saadud andmestike põhjal.

Mudelite hindamine jagunes kolmeks järjestikuseks etapiks, kusjuures iga etapp vastas konkreetsele katseseadistusele: esmalt kontrollitud keskkond, seejärel reaalne töökeskkond ning lõpuks liikuv drooniplatvorm. Igas etapis treeniti ja testiti mitmeid mudeleid, et samm-sammult jõuda kõige täpsema ja töökindlama lahenduseni. Parima tulemuse saavutanud masinõppemudeli ja YOLO mudeli tulemused on esitatud kokkuvõtlikult Lisas II Tabelis 7 ja Tabelis 8.

4.1 Täpsuse hindamine kontrollitud keskkonnas

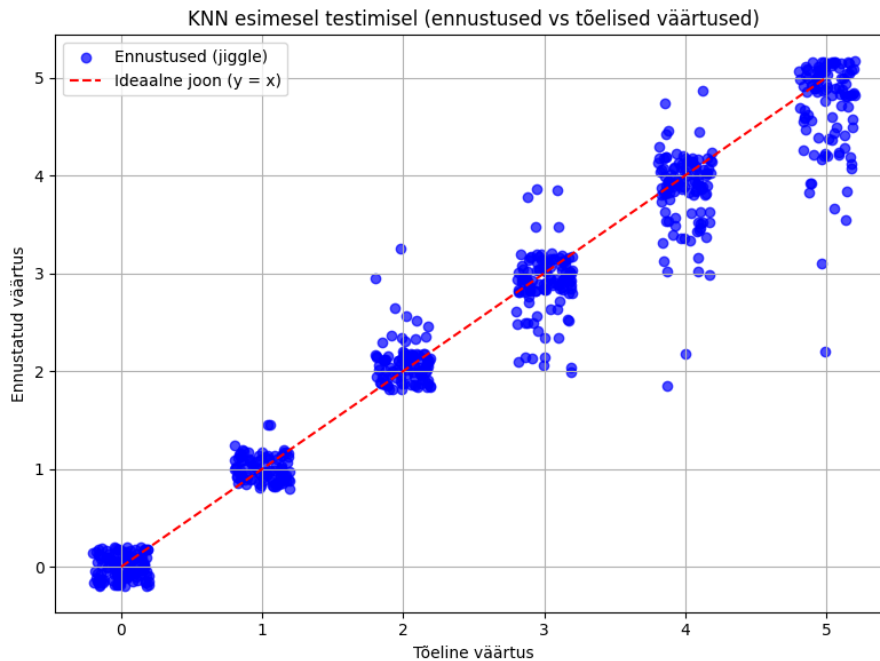
Järgnevalt esitatakse kontrollitud keskkonnas kogutud andmete põhjal saadud tulemusi. Masinõppemudelite tulemused on esitatud Tabelis 3. Kõiki masinõppemudeleid hinnati kasutades erinevaid sisendtunnuseid ja treeningparameetreid - parima tulemuse andnud kombinatsioonid on kirjeldatud Lisas Tabelis 6. YOLO mudelite tulemused on esitatud Tabelis 4. YOLO mudelite treenimiseks kasutati ühtselt järgmisi hüperparameetreid: epochide arv 50, pildisuurus 640 ja partiisuurus 16.

Tabel 3. Masinõppemudelite täpsus inimeste arvu ennustamisel

Nimi	RMSE	MAE	R ²	Accuracy
LinearRegression	0.48	0.37	0.92	73.24%
DecisionTreeRegressor	0.62	0.28	0.87	76.45%
KNeighborsRegressor	0.32	0.12	0.96	89.30%
SVR	0.56	0.42	0.90	66.51%
GradientBoostingRegressor	0.36	0.24	0.96	85.17%
RandomForestRegressor	0.41	0.26	0.94	80.43%

Masinõppemudelid: Parima tulemuse saavutas KNeighborsRegressor-mudel, mille RMSE oli 0,32, MAE vaid 0,12 ning täpsus 89,30%. Mudel kasutas sisendina termokaamera andmeid ning TMOS PIR-andurilt saadud liikumise ja temperatuuri väärtusi. Tänu headele tulemustele valiti see mudel edasiseks testimiseks järgmisesse etappi.

Joonis 6 näitab, et mudel saavutas üldiselt hea täpsuse, eriti väiksemate inimeste arvu korral, mis väljendub andmepunktide koondumises ideaalse joone $y=x$ ümber. Siiski on näha, et kui inimeste arv ületab kaks, suureneb ennustusviga. Võimalikuks põhjuseks võivad olla olukorrad, kus inimesed seisavad üksteisele väga lähedal või üksteise taga – sellistel juhtudel võivad inimesed termokaamera vaates sulanduda üheks objektiks, mis raskendab nende eristamist.



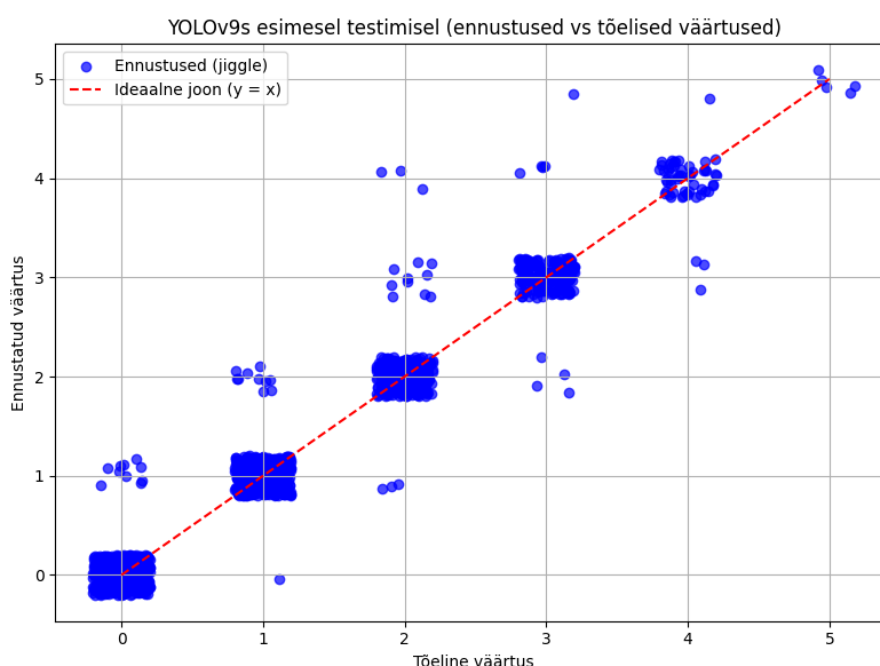
Joonis 6. KNN mudeli täpsus kontrollitud keskkonnas staatilisel platvormil

YOLO mudelid: Esialgsete tulemuste saamiseks võrreldi nelja erinevat YOLO-mudelit: YOLOv8n, YOLOv8s, YOLOv9s ja YOLOv9m. Parima tulemuse andis YOLOv9s, mille RMSE oli 0,21, MAE 0,04 ning $mAP@0.5:0.95 = 0,81$. Kuigi selle mudeli F1-skoor (0,96) oli madalam kui teistel võrreldud mudelitel, valiti YOLOv9s edasiseks testimiseks, kuna selle RMSE ja MAE väärtused olid parimad.

Joonis 6 illustreerib, et mudeli üldine täpsus on hea, kuid esineb juhuseid, kus ennustus ei vasta tegelikkusele. Need vead jäävad enamasti vahemikku ± 2 inimest, mis näitab, et mudel on praktilises kasutuses siiski piisavalt täpne.

Tabel 4. YOLO mudelite võrdlus

Nimi	Precision	Recall	F1	mAP@0.5:0.95	RMSE	MAE
YOLOv8n	0.9790	0.9629	0.9709	0.8084	0.34	0.08
YOLOv8s	0.9770	0.9617	0.9693	0.8116	0.30	0.07
YOLOv9s	0.9644	0.9644	0.9644	0.8133	0.21	0.04
YOLOv9m	0.9766	0.9569	0.9666	0.8064	0.32	0.06



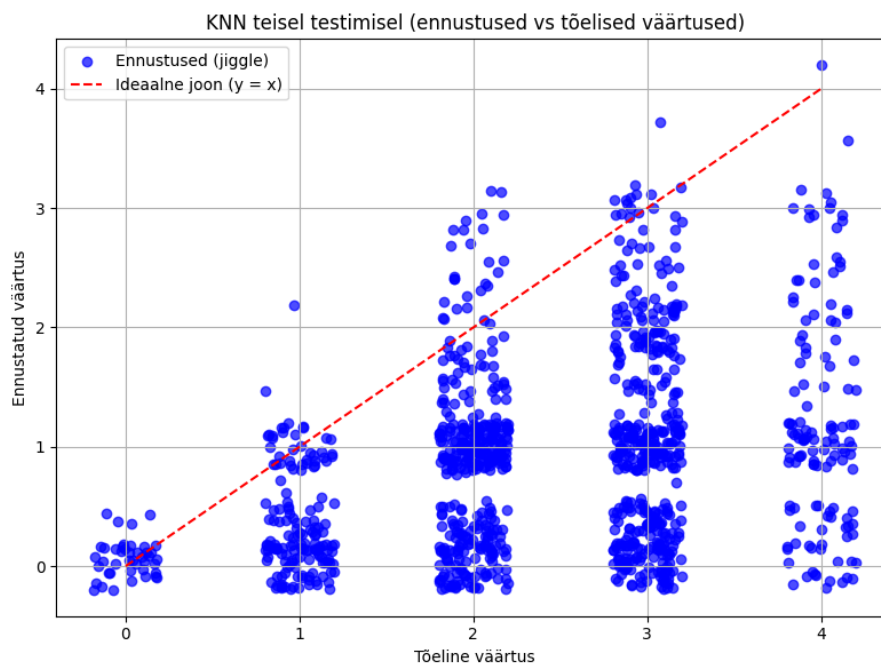
Joonis 7. YOLOv9s mudeli täpsus kontrollitud keskkonnas staatilisel platvormil

4.2 Täpsuse hindamine reaalses töökeskkonnas staatilisel platvormil

Teises etapis hinnati prototüübi toimivust kasutades parima tulemuse saavutanud masinõppemudelit (KNeighborsRegressor) kui ka parima täpsusega YOLO mudelit (YOLOv9s). Selle etapi eesmärk oli võrrelda neid kahte mudelit selgitamiseks, kumb neist üldistub paremini keerukamatesse ja vähem kontrollitud tingimustesse, olles seega sobivamad praktiliseks rakendamiseks reaalses keskkonnas.

KNeighborsRegressor täpsus: Teises katses langes KNN mudeli sooritus märgatavalt: Täpsus langes varasemast 89.30%-st 14,02% peale (RMSE=1,82, MAE=1,54 ning $R^2=-0,48$). Lisaks illustreerib Joonis 8, et mudel kaldub inimesi alaennustama – see tähendab, et ta ei suuda tuvastada kõiki inimesi pildil. Mõnel juhul on mudel eksinud isegi kuni nelja inimese võrra.

Selline tulemuste halvenemine viitab mudeli nõrgale üldistusvõimele ja kehvale sobivusele keerulisemates tingimustes.

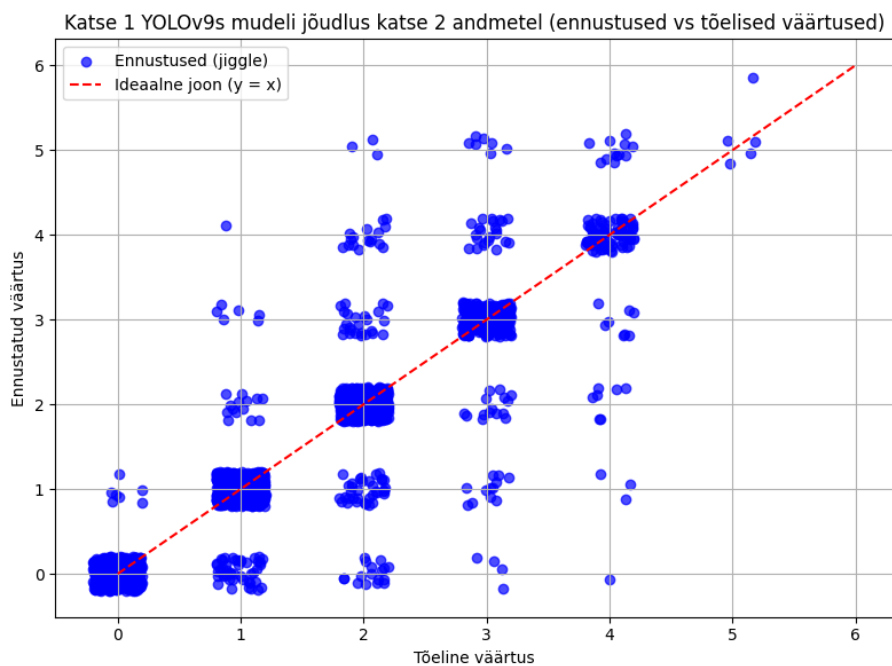


Joonis 8. KNN mudeli täpsus reaalses keskkonnas staatilisel platvormil

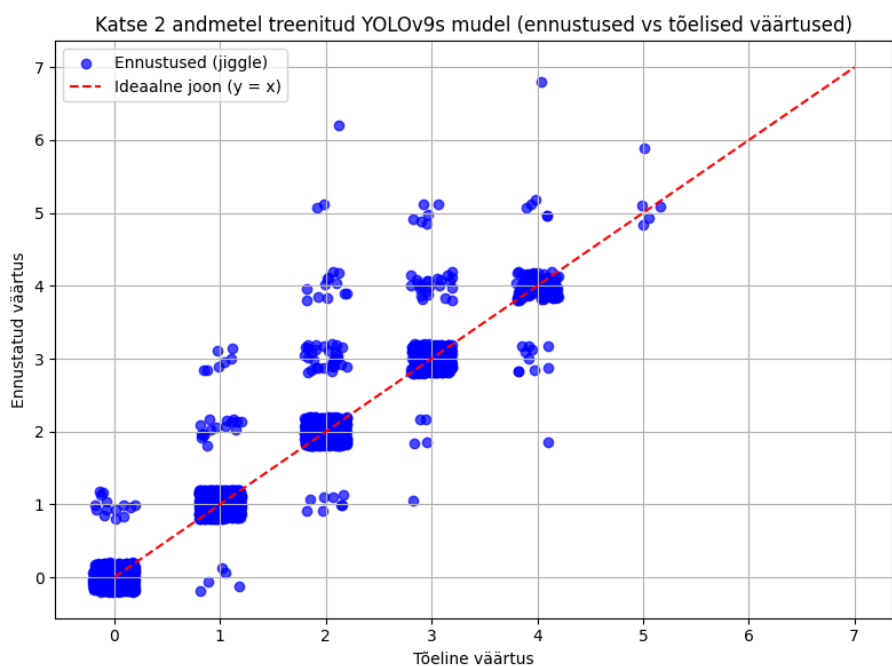
YOLO mudelite tulemused: Reaalses keskkonnas kogutud andmetel vähenes YOLOv9s mudeli täpsus võrreldes kontrollitud keskkonnaga, kuid langus ei olnud nii märgatav kui KNearestNeighbors mudelil. F1-skoor langes varasemalt 0,96 pealt 0,83 peale ning $mAP@0.5:0.95$ väärtus vähenes 0,81-lt 0,69-le. Samuti on märgata suurenemist RMSE ja MAE väärtustes – RMSE tõusis 0,21 pealt 0,50 peale ning MAE 0,04 pealt 0,16 peale. Kuigi mudel on keerulisemates tingimustes hakanud tegema suuremaid vigu, viitavad tulemused sellele, et tema üldine võime inimeste arvu tuvastada on säilinud. Täpsus ja tundlikkus on langenud vaid mõõdukalt, mis näitab, et YOLOv9s üldistub paremini kui KNeighborsRegressor.

Joonis 9 illustreerib samuti, et mudel on hakanud tegema suuremaid ennustusvigu. Siiski on positiivne, et mudeli üldine võime eristada inimeste arvu on säilinud, isegi kui täpsus on mõnevõrra langenud.

Kuna YOLOv9s on keerukates olukordades näidanud paremat täpsust kui KNeighborsRegressor, otsustati jätkata just selle mudeli kasutamisega prototüübi edasiarendamisel ja täiendava testimisega.



Joonis 9. YOLOv9s mudeli täpsus reaalses keskkonnas staatilisel platvormil



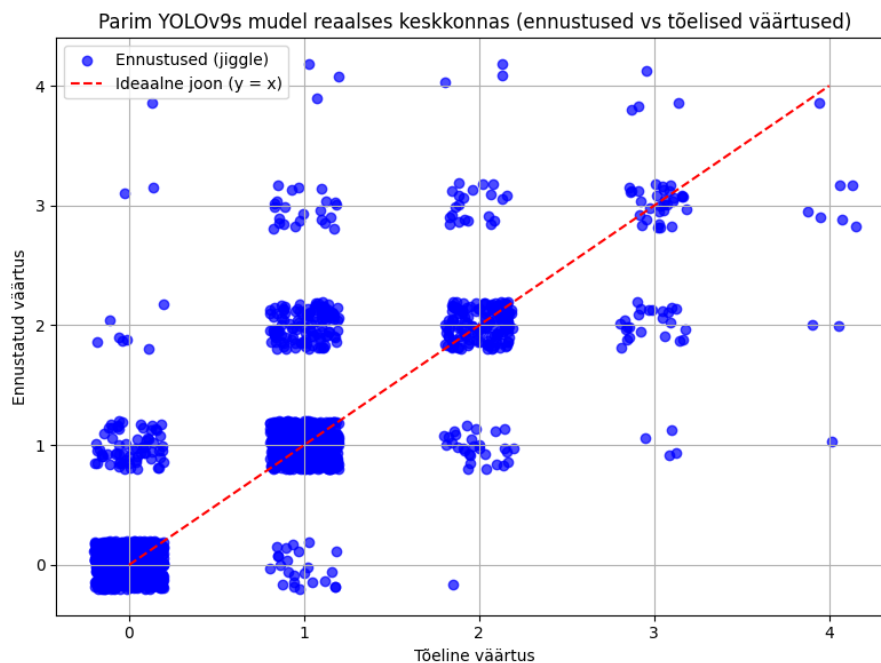
Joonis 10. YOLOv9s mudeli täpsus reaalses keskkonnas staatilisel platvormil pärast mudeli täiendavat treenimist

Kuna antud katse tulemused näitasid siiski YOLOv9s täpsuse langusele, siis viidi läbi mudeli täiendav treenimine kasutades sama katse käigus kogutud andmeid. See võimaldas mudelil paremini kohaneda just selle keskkonna iseärasustega. Pärast mudeli treenimist uute andmetega

teeb mudel vähem ja väiksemaid vigu: F1-skoor paranes 0,83 pealt 0,97-ni ning $mAP@0.5:0.95$ tõusis 0,69 pealt 0,83-ni. Seda kinnitab ka Joonis 10, kus varasemalt esinenud suured vead on vähenenud.

4.3 Täpsuse hindamine reaalses keskkonnas liikuvale andurplatvormil

Kolmanda katse eesmärk oli hinnata mudeli töökindlust liikuvast andurplatvormist kogutud andmete põhjal. Andmekogumine viidi läbi erinevas kontoriruumis kui varasemad katsed, et testida mudeli võimet üldistada uutes tingimustes. Andurid paigaldati koristusdroonile, mis liikus ruumis ringi vastavalt oma seesmisele koristusprogrammile, samal ajal tuvastades vaateväljas viibivate inimeste arvu. Andmeid koguti kaheksa minuti jooksul.



Joonis 11. YOLOv9s mudeli täpsus liikuvale platvormil reaalses keskkonnas

Inimeste tuvastamine liikuva drooni pealt on võrreldes varasemate katsetega siseruumides halvenenud, kuna drooni liikumine tekitab andmetes rohkem müra. F1-skoor langes 0,9742 pealt 0,8626 peale ning $mAP@0.5:0.95$ 0,83 pealt 0,71 peale. RMSE ja MAE väärtused sarnanevad varasema teise katse tulemustega, kus RMSE oli 0,50 ja MAE 0,16. See viitab, et kui mudelit edasi treenida mürarikkamate andmetega, on võimalik saavutada parem üldistusvõime ja täpsus.

Joonis 11 illustreerib YOLOv9s-mudeli ennustuste vastavust tegelikele väärtustele reaalses keskkonnas. Suuremate väärtuste juures on näha mõningast hajuvuse kasvu, kuid üldine korrelatsioon tegelike ja ennustatud väärtuste vahel püsib selgelt.

5. Arutelu

5.1 Piirangud

Uuringul ilmnes mitmeid piiranguid, mis võisid mõjutada süsteemi täpsust ja töökindlust.

Termokaamera resolutsioon: Kasutatud MLX90640 termokaamera madal resolutsioon (32×24 pikslit) seab piirangud süsteemi tuvastustäpsusele. Sellise resolutsiooniga on võimalik inimesi usaldusväärselt tuvastada kuni ligikaudu 4 meetri kauguselt. Suurematel distantsidel muutuvad kujutised liiga udusteks, mistõttu on raskendatud inimeste eristamine teistest soojusallikatest, nagu näiteks radiaatorid või muud seadmed. Kuigi madal resolutsioon vähendab visuaalset detailsust ja tuvastustäpsust, on selle eeliseks väga väike energiatarve, mis teeb seadme sobivaks autonoomsetele ja mobiilsetele platvormidele, kus energiatarve on oluline nõue.

Andmeedastuse stabiilsus: Süsteemi andmeid koguti mitme eraldiseisva M5StickC PLUS seadme abil, mis edastasid teavet individuaalselt WebSocketi kaudu. Kuna WebSocketi ühendus sõltub tugevalt võrgu kvaliteedist, mõjutas see negatiivselt andmete järjepidevust ja süsteemi töökindlust.

5.2 Tuleviku töö suunad

Töö tulemused pakuvad mitmeid suundi edasiseks arenduseks, mis aitaksid süsteemi muuta täpsemaks ja paremini kohandatavaks erinevates kasutuskeskkondades.

Testimine erinevates keskkondades: Tulevikus oleks soovitatav laiendada andmekogumist keskkondadesse, kus esinevad erinevad temperatuuritingimused ning olemasolevad soojusallikad (nt serveriruumid, tööstuslikud tööalad). See võimaldaks hinnata süsteemi toimivust keerulisemas soojusmaastikus ning parandada mudeli üldistamisvõimet.

Andurite ühendamise ühte keskseadmesse: Süsteemi arhitektuuri lihtsustamiseks ja töökindluse suurendamiseks võiks kõik andurid ühendada ühe võimsama mikroarvuti külge. See vähendaks paralleelselt töötavate seadmete arvu, alandaks võrgu koormust, vähendaks võimalikke andmeedastuse katkestusi ning muudaks süsteemi üldiselt stabiilsemaks ja hooldatavamaks.

6. Järeldus

Selles lõputöös töötati välja ja hinnati energiasäästlikel anduritel põhinevat inimeste tuvastamise ja loendamise süsteemi, mis on mõeldud autonoomsete maismaadroomide jaoks. Kasutusele võeti passiivne infrapunaandur (PIR), ultraheli kaugusandur ning termokaamera (MLX90640). Töö eesmärk oli luua lahendus, mis võimaldaks siseoludes anonüümselt tuvastada ja loendada inimesi, kasutades andureid, mida saab rakendada liikuvatel droonidel – ilma vajaduseta püsiva toiteühenduse järele – ning saavutada seejuures piisav täpsus süsteemi praktiliseks kasutamiseks.

Katsetused viidi läbi kontrollitud keskkonnas, kus hinnati erinevate masinõppe regressiooni- ja arvutinägemismudelite toimivust. Esialgsete andmete põhjal pakkusid regressioonimudelid paljulubavaid tulemusi, kuid keerulisemates olukordades – kus lisaks inimestele esines ka teisi soojusallikaid – langes nende täpsus märgatavalt. Kõige paremad tulemused saavutati arvutinägemise meetoditega, kus YOLOv9s objekti tuvastamise mudel võimaldas täpsemat ja usaldusväärsemat inimeste tuvastamist termokaamera andmete põhjal.

Tulemused näitavad, et YOLO mudelid pakkusid märgatavalt täpsemaid tuvastustulemusi võrreldes regressioonimudelitega. Arvestades arvutinägemise meetodite kõrgemat täpsust, on edasises arenduses põhjendatud keskenduda eelkõige termokaamera põhisele lahendusele, mis sobib hästi nii anonüümseks kui ka inimeste tuvastamiseks mobiilsetel platvormidel.

Tulevikutööna võiks keskenduda mudeli edasiarendamisele, et süsteem suudaks usaldusväärset toimida ka väljaspool kontorikeskkonda. Selleks oleks vajalik koguda täiendavaid andmeid erinevate temperatuurierinevustega keskkondadest, et parandada mudeli üldistamisvõimet ja vastupidavust muutuvates tingimustes.

Viited

- [1] Kouyoumdjieva S. T., Danielis P. ja Karlsson G. Survey of non-image-based approaches for counting people. *IEEE Communications Surveys & Tutorials* 22.2 (2019), lk 1305–1336.
- [2] Mukhopadhyay B., Srirangarajan S. ja Kar S. Modeling the analog response of passive infrared sensor. *Sensors and Actuators A: Physical* 279 (2018), lk 65–74.
- [3] STMicroelectronics. STHS34PF80: Low-power, high-sensitivity infrared (IR) sensor for presence and motion detection. <https://www.st.com/resource/en/datasheet/sths34pf80.pdf>. (09.05.2025). 2023.
- [4] Nanyang Senba Optical and Electronic Co., Ltd. Pyroelectric Infrared Radial Sensor. <https://forum.mysensors.org/assets/uploads/files/1494013712469-pir-as312.pdf>. (09.05.2025). n.d.
- [5] Chodon P., Adhikari D. M., Nepal G. C., Biswa R., Gyeltshen S. jt. Passive Infrared (PIR) Sensor Based Security System. *International Journal of Electrical, Electronics & Computer Systems* 14.2 (2013).
- [6] VergeSense. Common Problems With PIR Sensors in Today’s Workplace. Accessed: 2025-05-05. Juuni 2022. <https://www.vergesense.com/resources/blog/why-pir-sensors-are-no-longer-enough>.
- [7] Deichert M. F. jt. Ultrasonic Occupancy Monitor Visual and Auditory (2024).
- [8] Qiu Z., Lu Y. ja Qiu Z. Review of ultrasonic ranging methods and their current challenges. *Micromachines* 13.4 (2022), lk 520.
- [9] Drăgulinescu A.-M. C., Marcu I., Halunga S. ja Fratu O. Persons counting and monitoring system based on passive infrared sensors and ultrasonic sensors (PIRUS). *International Symposium on Pervasive Computing Paradigms for Mental Health*. Springer. 2015, lk 100–106.
- [10] Piechocki M., Kraft M., Pajchrowski T., Aszkowski P. ja Pieczynski D. Efficient people counting in thermal images: the benchmark of resource-constrained hardware. *IEEE Access* 10 (2022), lk 124835–124847.
- [11] Norden. Advantages and disadvantages of Thermal Imaging Camera. Accessed: 2025-05-07. 2025. <https://www.nordencommunication.com/en/blog/advantages-and-disadvantages-of-thermal-imaging-camera>.
- [12] IBM. Computer Vision – What is Computer Vision? | IBM. <https://www.ibm.com/think/topics/computer-vision>. (13.05.2025). 2025.

- [13] Labs B. T. What are some real-world applications of Computer Vision? Medium. (07.05.2025). 2024. <https://medium.com/@bosctechlabs/what-are-some-real-world-applications-of-computer-vision-2024-4879a740ff29>.
- [14] Redmon J., Divvala S., Girshick R. ja Farhadi A. You only look once: Unified, real-time object detection. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016, lk 779–788.
- [15] Rizk M. ja Bayad I. Human detection in thermal images using YOLOv8 for search and rescue missions. *2023 Seventh International Conference on Advances in Biomedical Engineering (ICABME)*. IEEE. 2023, lk 210–215.
- [16] Kucukayan G. ja Karacan H. Yolo-ihd: Improved real-time human detection system for indoor drones. *Sensors* 24.3 (2024), lk 922.
- [17] M5Stack. M5StickC PLUS Core Device - M5Stack Documentation. https://docs.m5stack.com/en/core/m5stickc_plus. (13.05.2025). 2025.
- [18] M5Stack. ATOM Lite Core Device - M5Stack Documentation. <https://docs.m5stack.com/en/core/ATOM%20Lite>. (13.05.2025). 2025.
- [19] M5Stack. UNIT TMOS PIR - M5Stack Documentation. <https://docs.m5stack.com/en/unit/UNIT-TMOS%20PIR>. (13.05.2025). 2025.
- [20] M5Stack. PIR Unit - M5Stack Documentation. <https://docs.m5stack.com/en/unit/PIR>. (13.05.2025). 2025.
- [21] M5Stack. ULTRASONIC I2C Unit - M5Stack Documentation. <https://docs.m5stack.com/en/unit/ULTRASONIC%20I2C>. (13.05.2025). 2025.
- [22] M5Stack. THERMAL Unit - M5Stack Documentation. <https://docs.m5stack.com/en/unit/THERMAL>. (13.05.2025). 2025.
- [23] M5Stack. PaHub v2.1 Unit - M5Stack Documentation. <https://docs.m5stack.com/en/unit/Unit-PaHub%20v2.1>. (13.05.2025). 2025.

Lisad

I. Augmentatsioonimeetodid

Tabel 5. Albumentations teegi põhjal kasutatud andmete augmentatsioonimeetodid

Meetod	Parameetrid	Kirjeldus
ShiftScaleRotate	shift_limit=0.05, scale_limit=0.05, rotate_limit=5, p=0.7	Simuleerib drooni liikumist ja kaamera vaatenurga muutusi.
HorizontalFlip	p=0.5	Peegeldab pilti horisontaalselt, suurendades vaatevariatiivsust.
MotionBlur	blur_limit=3, p=0.2	Simuleerib liikumisest tingitud hägusust.
GaussNoise	var_limit=(5.0, 20.0), p=0.2	Simuleerib andmekogumisest tekkivat müra.
RandomBrightness Contrast	brightness_limit=0.05, contrast_limit=0.05, p=0.3	Varieerib heledust ja kontrasti, jälgendades erinevaid valgustingimusi.

II. Masinõppemudelite tunnused ja parameetrid

Tabel 6. Parima tulemuse andnud masinõppemudelite tunnused ja treeningparameetrid

Nimi	Tunnused	Parameetrid
LinearRegression	motion, presence, ambient, gyroMagnitude, termokaamera	vaikeseaded
DecisionTreeRegressor	motion, presence, ambient, accelMagnitude, termokaamera	random_state=42
KNeighborsRegressor	motion, ambient, termokaamera	n_neighbors = [3, 5, 7], weights = ['uniform', 'distance'], p = [1, 2]
SVR	motion, presence, mic, gyroMagnitude, termokaamera	C = 1.0, kernel = 'rbf', epsilon = 0.1
GradientBoostingRegressor	motion, presence, ambient, termokaamera	n_estimators = [100, 200], max_depth = [3, 4, 5], learning_rate = [0.05, 0.1]
RandomForestRegressor	motion, presence, ambient, termokaamera	n_estimators = [100, 200], max_depth = [None, 10, 20]

III. Masinõppemudelite ja YOLO mudelite katsete tulemused kokkuvõetult

Tabel 7. YOLOv9s mudeli tulemused treening- ja testandmestike põhjal. *Treening* ja *Test* viitavad millise katse andmeid kasutati vastavalt mudeli treenimiseks ja testimiseks

Treening	Test	Nimi	Precision	Recall	F1	mAP@0.5:0.95	RMSE	MAE
1	1	YOLOv9s	0.9644	0.9644	0.9644	0.8133	0.21	0.04
1	2	YOLOv9s	0.8177	0.8450	0.8308	0.6947	0.50	0.16
2	2	YOLOv9s	0.9755	0.9724	0.9742	0.8310	0.34	0.08
2	3	YOLOv9s	0.8472	0.8783	0.8626	0.7137	0.54	0.22

Tabel 8. KNeighborsRegressor mudeli tulemused erinevate treening- ja testandmestike põhjal. *Treening* ja *Test* viitavad millise katse andmeid kasutati vastavalt mudeli treenimiseks ja testimiseks

Treening	Test	Mudel	RMSE	MAE	R^2	Accuracy
1	1	KNeighborsRegressor	0.32	0.12	0.96	89.30%
1	2	KNeighborsRegressor	1.82	1.54	-0.48	14.02%

IV. GitHub repositoorium

Valminud prototüübi tarkvaraline repositoorium asub lingil:

<https://github.com/ArnoldLuich/PeopleDetectionAndCounting>

Lihtlitsents lõputöö reprodutseerimiseks ja üldsusele kättesaadavaks tegemiseks

Mina, Arnold Luich,

1. annan Tartu Ülikoolile tasuta loa (lihtlitsentsi) minu loodud teose **Inimeste loendamine autonoomsete droonide ümber**, mille juhendajad on Kevin Post ja Huber Flores, reprodutseerimiseks eesmärgiga seda säilitada, sealhulgas lisada Tartu Ülikooli digitaalarhiivi kuni autoriõiguse kehtivuse lõppemiseni;

2. annan Tartu Ülikoolile loa teha punktis 1 nimetatud teos üldsusele kättesaadavaks Tartu Ülikooli veebikeskkonna, sealhulgas digitaalarhiivi kaudu Creative Commons'i litsentsiga CC BY NC ND 4.0, mis lubab autorile viidates teost reprodutseerida, levitada ja üldsusele suunata ning keelab luua tuletatud teost ja kasutada teost ärieesmärgil, kuni autoriõiguse kehtivuse lõppemiseni;

3. olen teadlik, et punktides 1 ja 2 nimetatud õigused jäävad alles ka autorile;

4. kinnitan, et lihtlitsentsi andmisega ei riku ma teiste isikute intellektuaalomandi ega isikuandmete kaitse õigusaktidest tulenevaid õigusi.

Arnold Luich

15.05.2025