

TALLINNA TEHNIKAÜLIKOOL  
Infotehnoloogia teaduskond

Einar Kivisalu  
163551IAPM

**NÄOTUVASTUSE 2D/3D BIOMEETRIA  
ANALÜÜS JA INFORMATSIOONIKASVU  
UURIMINE**

Magistritöö

Juhendaja: Sven Nõmm  
Ph.D

Tallinn 2019

## **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: Einar Kivisalu

07.05.2019

## **Annotatsioon**

### **Näotuvastuse 2D/3D biomeetria analüüs ja informatsioonikasvu uurimine**

Inimeste tuvastamisel on nägude tuvastamine üks paljudest võimalustest ning sellel on palju võimalikke rakendusalasid nagu näiteks (automaatne) turvakontroll, automaatsed läbipääsusüsteemid, jälgimissüsteemid jne. Käesoleva lõputöö eesmärk on uurida kolmemõõtmelise näotuvastuse võimalusi erinevate algoritmide abil, samuti hinnata informatsiooni kasvu 3D andmete teisendamisel kahemõõtmeliseks. Nägude andmebaas, mida käesolevas töös on uuritud, on kogutud ja töödeldud töö autori poolt. Näotuvastuse alusandmetena on kasutatud Microsoft Kinect seadme poolt skanneeritud nägude kolmemõõtmeliste punktide pilve. Kogu andmete töötlus alates Kinecti skanneerimisprogrammist kuni tulemusi ja graafikuid väljastavate skriptideni on töö autori poolt kirjutatud.

Töö tulemusena on võrreldud erinevaid algoritme (SVM, KNN, juhuslik mets, otsustuspuu, Gaussi naiivne Bayes ja mitmekihiline närvivõrk), võrreldud nende tuvastustäpsust ning võrreldud erinevate meetodite kasutamisel saadud tunnuste parameetreid paremaks nägude tuvastamiseks. Parim tuvastustäpsus saavutati KNN ja juhusliku metsa meetodiga, ulatudes kuni 99%-ni.

Lõputöö on kirjutatud eesti keeles ning sisaldab teksti 71 leheküljel, 7 peatükki, 30 joonist, 10 tabelit.

## **Abstract**

### **Human Face 2D/3D Biometry Analysis and Face Recognition Information Gain**

A facial recognition is one of possibilities to recognize persons and is mostly used for security purposes, though there is increasing interest in other areas of use. Facial recognition techniques are quickly evolving with new approaches such as 3-D modelling, helping to overcome issues with existing techniques.

The aim of this thesis is to present Microsoft Kinect v2 sensor for person identification and compare different algorithms for feature selection and classification. Feature selection has been routinely used as a preprocessing step to remove irrelevant features. In this thesis Fisher score, Gini Impurity and Information Gain algorithms are compared for feature selection.

Classifiers compared are KNN, Decision Tree, Random Forest, SVM, Gaussian Naive Bayes and Multilayer Perceptron. The use of KNN and Random forest gave the best accuracy results in predicting faces and gave predictability almost 99%.

The thesis is in Estonian and contains 71 pages of text, 7 chapters, 30 figures, 10 tables.

## Lühendite ja mõistete sõnastik

2D	Kahemõõtmeline (kujutis)
3D	Kolmemõõtmeline (kujutis)
SDK	<i>Software Development Kit</i> Tarkvara arenduspakett
RGB	Kolmevärviline kujutis
CMOS	Pooljuhtstruktuuriga pildisensor, aktiivpikselsensor.
LBP	<i>Local Binary Pattern</i> , Lokaalne kahendmuster
KNN	<i>k-nearest neighbors algorithm</i> , k-lähima naabri algoritm.
SVM	<i>Support Vector Machine</i> , tugivektorklassifitseerija
CSV	<i>Comma Separated Value</i> , komaga eraldatud andmete failiformaat
CANDIDE-3	Parameetiline inimese näomudel, koosneb polügonidest ja punktidest
LDA	<i>Linear Discriminant Analysis</i> , Lineaarne diskriminantanalüüs
ICP	<i>Iterative Closest Point</i> , iteratiivse lähimpunkti meetod
CNP	<i>Closest Normal Points</i> , lähima normaalpunkti meetod
PCA	<i>Principle Component Analysis</i> , Põhiosade analüüs e. peakomponentide analüüs.
SIFT	<i>scale invariant feature transform</i>

## Sisukord

Autorideklaratsioon .....	2
Annotatsioon.....	3
Abstract.....	4
Human Face 2D/3D Biometry Analysis and Face Recognition Information Gain .....	4
Lühendite ja mõistete sõnastik .....	5
Sisukord.....	6
Jooniste loetelu .....	9
Tabelite loetelu .....	12
1 Sissejuhatus .....	13
1.1 Probleem.....	13
1.2 Eesmärk .....	14
1.3 Ülevaade tööst .....	15
2 Taust ja kirjanduse ülevaade.....	15
2.1 Sarnased tööd.....	19
2.2 Näotuvastus .....	22
2.3 Masinõppe metodoloogia .....	23
3 Biomeetria analüüs ja andmete eeltöötlus .....	24
3.1 Kolmemõõtmelised näo esitusviisid.....	24
3.2 Microsoft Kinect abil mudelite andmebaasi loomine.....	24
3.3 Näokujutiste skanneerimine .....	25
3.4 Andmete edasine töötlemine .....	26
4 Tunnuste eraldamine ja klassifitseerimine .....	30

4.1 Parimate tunnuste e klassi diskriminandi leidmine .....	30
4.1 Gini lisand e. ebapuhtus (ingl k. Gini Impurity).....	32
4.2 Informatsioonikasv .....	32
5 Töö tulemused .....	33
5.1 Tunnuste valimine .....	33
5.2 Klassifitseerimine .....	37
5.3 Andmestiku jagamine test- ja treeningandmeteks .....	37
5.4 Klassifitseerijate hindamine .....	38
5.5 KNN, K-lähima naabri meetodil klassifitseerimine .....	39
5.6 SVM, tugivektorklassifitseerija (ingl. k. <i>Support vector machine</i> ).....	42
5.7 Otsustuspuu (ingl. k. Decision Tree).....	45
5.8 Otsustusmetsa e. juhusliku metsa (ingl k. Random Forest) meetod.....	49
5.9 Naiivne Bayes.....	55
5.10 Mitmekihilised närvivõrgud (ingl. k. Multilayer perceptron) .....	58
6 Järeldused tehtud tööst .....	61
7 Kokkuvõte .....	64
8 Kasutatud kirjandus .....	65
Lisa 1 – KNN algoritmi kasutades saadud tuvastustäpsus (klassifitseerimisõigsus) 30 tunnuse puhul.....	72
Lisa 2 – SVM algoritmi kasutades saadud tuvastustäpsus (klassifitseerimisõigsus) 30 tunnuse puhul.....	75
Lisa 3 – Otsustuspuu algoritmi kasutades saadud tuvastustäpsus (klassifitseerimisõigsus) 30 tunnuse puhul.....	78
Lisa 4 – Juhusliku metsa algoritmi kasutades saadud tuvastustäpsus (klassifitseerimisõigsus) 30 tunnuse puhul.....	81
Lisa 5 – Gaussi naiivse Bayes algoritmi kasutades saadud tuvastustäpsus (klassifitseerimisõigsus) 30 tunnuse puhul.....	84

Lisa 6 – Mitmekihiliste närvivõrkude algoritmi kasutades saadud tuvastustäpsus (klassifitseerimisõigsus) 30 tunnuse puhul.....	87
Lisa 7 – Töös kasutatud tunnused ja nende asukoht joonisel 5.....	90



## Jooniste loetelu

Joonis 1. Radiaalsete lõigete kasutamine 3D näotuvastamisel erinevate näoilmete puhul [21]. .....	23
Joonis 2. Candide-3 näomudel (a) kolmnurkvõrgustik. (b) näokujutisega sünkroniseeritud mudel [23]. .....	25
Joonis 3. Kinect'i poolt tuvastatud 1347 näopunkti.....	27
Joonis 4. Kinect SDK poolt tuvastatud nimeliste punktide asukohad.....	27
Joonis 5. Delauney triangulatsiooni põhimõttel moodustatud võrgustik punktide vahepunktide vahel.....	29
Joonis 6 Fisher skoori, Gini indeksi ja entroopia võrdlemine klassifitseerimise tunnuste valimiseks (3D eukleidilistel kaugustel põhinevad tunnused) .....	34
Joonis 7 Fisher skoori, Gini indeksi ja entroopia võrdlemine klassifitseerimise tunnuste valimiseks (3D kolmnurkade tipunurkadel põhinevad tunnused).....	34
Joonis 8. <i>Gini Impurity</i> järgi leitud oluliseimad tunnused 3D otsevaate puhul.....	36
Joonis 9. Informatsioonikasvu järgi leitud oluliseimad tunnused 3D otsevaate puhul. .	36
Joonis 10. <i>Gini Impurity</i> järgi leitud oluliseimad tunnused 2D külgvaate puhul.....	36
Joonis 11. Informatsioonikasvu järgi leitud oluliseimad tunnused 2D külgvaate puhul.	37
Joonis 12 K-lähima naabri puhul saavutatud tuvastustäpsus, tunnuste valik põhineb <i>Gini Impurity</i> -1.....	39
Joonis 13 K-lähima naabri puhul saavutatud tuvastustäpsus, tunnuste valik põhineb informatsioonikasvul .....	40
Joonis 14. K-lähima naabri meetodil saavutatud klassifitseerimisõigsus, tunnuste valik põhineb Fisher skooril. ....	40
Joonis 15. SVM puhul saavutatud tuvastustäpsus, tunnuste valik põhineb <i>Gini Impurity</i> -1. ....	43

Joonis 16. SVM puhul saavutatud tuvastustäpsus, tunnuste valik põhineb Informatsioonikasvul.....	43
Joonis 17. SVM puhul saavutatud tuvastustäpsus, tunnuste valik põhineb Fisher skooril. ....	44
Joonis 18. Otsustuspuu puhul saavutatud tuvastustäpsus, tunnuste valik põhineb <i>Gini Impurity</i> -l.....	46
Joonis 19. Otsustuspuu puhul saavutatud tuvastustäpsus, tunnuste valik põhineb informatsioonikasvul. ....	47
Joonis 20. Otsustuspuu puhul saavutatud tuvastustäpsus, tunnuste valik põhineb Fisher skooril.....	47
Joonis 21. Juhusliku metsa (Random Forest) puhul saavutatud tuvastustäpsus, tunnuste valik põhineb <i>Gini Impurity</i> -l.....	50
Joonis 22. Juhusliku metsa (Random Forest) puhul saavutatud tuvastustäpsus, tunnuste valik põhineb informatsioonikasvul. ....	50
Joonis 23. Juhusliku metsa (Random Forest) puhul saavutatud tuvastustäpsus, tunnuste valik põhineb Fisher skooril. ....	51
Joonis 24. Ekraanipilt informatsioonikasvu meetodil valitud 6 parima tunnuse järgi klassifitseerimisel saavutatud tulemustega.....	53
Joonis 25. Gaussi naiivse Bayes meetodil puhul saavutatud tuvastustäpsus, tunnuste valik põhineb <i>Gini Impurity</i> -l.....	55
Joonis 26. Gaussi naiivse Bayes meetodil puhul saavutatud tuvastustäpsus, tunnuste valik põhineb informatsioonikasvul. ....	56
Joonis 27. Gaussi naiivse Bayes meetodil puhul saavutatud tuvastustäpsus, tunnuste valik põhineb Fisher skooril. ....	56
Joonis 28. Mitmekihiliste närvivõrkude meetodi puhul saavutatud tuvastustäpsus, tunnuste valik põhineb <i>Gini Impurity</i> -l. ....	58
Joonis 29. Mitmekihiliste närvivõrkude meetodi puhul saavutatud tuvastustäpsus, tunnuste valik põhineb informatsioonikasvul.....	59

Joonis 30. Mitmekihiliste närvivõrkude meetodi puhul saavutatud tuvastustäpsus, tunnuste valik põhineb Fisher skooril..... 59

## Tabelite loetelu

Tabel 1 Mõningad 3D näotuvastuses kasutatavad seadmed [4].	17
Tabel 2 Mõningad olulisemad 3D näotuvastuse alased tööd [4].	21
Tabel 3. Pingeritta seatud Fisher skoori, Gini indeksi ja entroopia väärtused (pingerea esimesed 20).	35
Tabel 4. KNN algoritmi kasutades saadud tuvastustäpsus (klassifitseerimisõigsus) esimese 6 tunnuse puhul (siin ja edaspidi 100% =1,0).	41
Tabel 5. SVM algoritmi kasutades saadud tuvastustäpsus (klassifitseerimisõigsus) esimese 6 tunnuse puhul.	44
Tabel 6. Otsustuspuu algoritmi kasutades saadud tuvastustäpsus (klassifitseerimisõigsus) esimese 6 tunnuse puhul.	48
Tabel 7. Juhusliku metsa algoritmi kasutades saadud tuvastustäpsus (klassifitseerimisõigsus) esimese 6 tunnuse puhul.	51
Tabel 8. Juhusliku metsa algoritmi kasutades saadud eksimismatriks informatsioonikasvu meetodil leitud 6 parima tunnuse kasutamisel.	54
Tabel 9. Gaussi naiivse Bayes algoritmi kasutades saadud tuvastustäpsus (klassifitseerimisõigsus) esimese 6 tunnuse puhul.	57
Tabel 10. Mitmekihiliste närvivõrkude algoritmi kasutades saadud tuvastustäpsus (klassifitseerimisõigsus) esimese 6 tunnuse puhul.	60

# 1 Sissejuhatus

Isikutuvastamise süsteemid on järjest enam levimas paljudesse igapäevastesse valdkondadesse turva- ja jälgimissüsteemides alates mobiiltelefonidest kuni piiriületuspunktide ja massiürituste automaatse skriininguni. Sellepärast on tehisintellekti valdkonnana kujutiste analüüs ja nendest arusaamine viimasel ajal muutunud oluliseks ja kiiresti arenevaks uurimissuunaks.

Erinevate näotuvastusprogrammide hulgas leidub nii kahe- kui ka kolmemõõtmelise kujutise uurimise skeeme. Antud magistritöös püütakse võrrelda 3D punktipilvel põhinevat näotuvastust 2D punktipilve omaga ning välja selgitada kas ja milline on informatsioonikasv ruumilise ja tasapinnalise kujutise tuvastamise vahel.

## 1.1 Probleem

Tehnoloogia areng nii riist- kui tarkvara poolelt on teinud võimalikuks teoreetiliste uurimuste praktilisse ellu viimise. Kuigi isikute tuvastamine ja äratundmine on inimese jaoks elementaarne igapäevaoskus, siis samasuguste tehissüsteemide ehitamine on senini aktiivne uurimisobjekt. Microsoft Kinecti kaamera on oma odava hinna ja vabalt kasutatava SDK juures teinud laialdaselt võimalikuks masinnägemise kasutamise erinevate viiside uurimise ja ka nende rakendamise igapäevaelus.

Masinõpe põhineb algoritmidel, mis suudavad olemasolevatest andmetest õppida ja seejärel teha nendel andmetel põhinevaid järeldusi.

Kahemõõtmelised kujutised 3D subjektidest (nägudest) võivad erineda kardinaalselt, sõltudes nii valgusoludest kui ka jälgitava subjekti asendist (Zhao et. al 2003).

Peaaegu kõikides nägude andmebaasides on näod otsevaates. Seetõttu on kahemõõtmelise kujutise puhul vajalik transformeerida kujutis otsevaatesse, mis omakorda tähendab märgatavaid moonutusi saadud kujutisel.

3D punktipilvede puhul on oluline välja selgitada millised tunnused on inimese näo tuvastamise juures olulised ning milliste meetoditega neid tunnuseid on kõige parem välja selgitada.

Sellest, milline on pea asend (otse, kallutatud, pööratud) sõltub tuvastamisprotsessi täpsus ning selle tööga püütakse välja selgitada, millised kujutise omadused ja millisel määral mõjutavad tuvastamise täpsust 2D ja 3D kujutiste puhul ning kas ja kuidas on need omavahel seotud. Informatsioonikasv, mida 3D kujutise kahemõõtmeliseks taandamine enesega kaasa toob, võib põhjustada samuti tuvastamise täpsuse muutumist ja selle määra uurimine erinevate meetoditega ongi antud töö üks põhiline uurimisprobleem.

Käesoleva töö oodatavaks tulemuseks on leida, kas ja kui suur on kolmemõõtmelise kujutise kasutamise otstarbekus võrreldes kahemõõtmelise ja millised parameetrid ja tunnused mõjutavad isiku tuvastamise täpsust.

## 1.2 Eesmärk

Näotuvastuse protsess koosneb üldjuhul järgmistest alametappidest:

- Näokujutise leidmine;
- Kujutise segmenteerimine ja normaliseerimine;
- Näo äratundmine ja verifitseerimine.

Käesolevas töös keskendutakse Microsoft Kinect seadme poolt saadud 3D kujutise edasisele töötlemisele ja analüüsile, eeldusel, et varasemalt on Kinecti poolt esimesed etapid sooritatud ehk näokujutis leitud ja segmenteeritud. Uuritakse erinevaid meetodeid, mis võimaldavad isikutuvastamist ning andmekadusid, mis tekkivad kolmemõõtmelise kujutise taandamisel kahemõõtmeliseks. Informatsioonikasvu ja tuvastustäpsuse probleemid näotuvastuse 3D kujutiste taandamisel kahte dimensiooni ei ole praeguse ni kahjuks eriti uuritud ning seda lünka püüabki antud töö täita.

Selle töö alusel saab anda hinnanguid, millised eelised on erinevatel klassifitseerimise tunnuste väljaselgitamise meetoditel ning klassifitseerimise algoritmidel 3D näotuvastusel ning millistel tingimustel on otstarbekas ühe või teise meetodi ja algoritmi kasutamine või nende omavaheline kombineerimine.

## 1.3 Ülevaade tööst

Töö olemus koosneb järgmistest osadest:

- Programmi kirjutamine, mis võimaldaks eraldada ja salvestada Kinecti poolt skanneeritud punktipilvest vajalikud näopunktid kasutades Microsoft Kinecti SDK-d.
- Normaliseerida näokujutis ja konstrueerida mudel, mille järgi saab välja selgitada näotuvastamisel kasutatavad tunnused.
- Selgitada välja tunnused, mille kasutamine on otstarbekaim, kasutades selleks Fisher skoori, informatsioonikasvu jt. meetodeid.
- Eraldada treening- ja testandmestik.
- Erinevate masinõppe meetoditega – Otsustuspuu, juhuslik mets (Random Forest), SVM, KNN jt. – tuvastada testandmestikust objekte ja määrata tuvastamistäpsus ning uurida erinevate tunnuste kasutamisel saadavaid tulemusi.
- Hinnata 3D kujutise taandamisel kahemõõtmeliseks saadavat informatsioonikasvu.

Aadressil <https://sites.google.com/site/3dtunnusteklassifikatsioon> asuvad antud tööga seotud mõningad täiendavad tabelleid ja joonised.

## 2 Taust ja kirjanduse ülevaade

Kolmemõõtmelise näokujutise tuvastamine on muutunud suhteliselt populaarseks uurimisvaldkonnaks tänu ulatuslikele kasutusvõimalustele biomeetrias ja turvalahendustes. 2D näotuvastuse lahendusi on uuritud paljude teadlaste poolt juba palju aastaid ja on selgunud, et ideaaltingimustest erinevad olukorrad nagu näiteks muudatused valgustuses ja pea asendis mõjutavalt tugevalt kahemõõtmelise kujutise tuvastamise kvaliteeti. Nendest piirangutest on vabad 3D andmed, mis sisaldavad uue kvaliteedina sügavusandmeid [1].

Võrreldes kahemõõtmelise kujutise tuvastamise algoritmidega, mis põhinevad kujutise halltooni heleduse või värviskaala omadustel, on 3D üldjoontes vähemtundlikud valgustingimuste, peasendite, näoilmete ja meigi suhtes. 3D näotuvastuse põhilised eelised on:

- 1) Saadav kujund ja sellega kaasnevad 3D näokujutise omadused on võimalik saada sõltumatult valgustustingimustest.
- 2) Peaasend kolmemõõtmelisel näokujutisel on kergesti korrigeeritav ja kasutatav edasiste sõltumatute peaasendite tuletamistel.
- 3) Kolmemõõtmelised näoandmed on palju vähem mõjutatud naha värvitoonist, kasutatud kosmeetikast ja teistest analoogsetest valguse peegeldumist mõjutavatest faktoritest. [2].

Enne sügavuskaamerate praegust leviulatust oli põhiliseks uuringute tegemist takistavaks teguriks 3D skanneerimisseadmete kõrge hinnatase. Koos hinna alanemisega on muutunud sügavuskaamerad ka oma mõõtmetelt oluliselt väiksemateks. Uue vahendina on saanud sügavuskaamerad inimese ja arvuti vaheliseks sisendseadmeks, eriti paistab välja Microsoft Kinect. Peale Microsoft Kinecti SDK avalikkusele avamist, on teadlased ja arendajad välja töötanud ja kasutusele võtnud väga palju uusi vahendeid sügavusmõõdikutega seadmetele. Kogu sellealane tehnoloogia on praegu tormilise arengu ajajärgus [3]. Tabelis 1 on ära toodud mõningaid levinuimaid 3D näotuvastuses kasutatavaid sügavuskaameraid.



Tabel 1 Mõningad 3D näotuvastuses kasutatavad seadmed [4].

Sensor	Sensori tüüp	Resolutsioon	Töökaugus	Hind (\$)
Minolta Sensors [Min et al., 2014b]	3D Laser Scanning	0.041-0.22	~ 2.5	25000
3dMDface [Min et al., 2014b]	Vision Cameras	<0.2	— —	10k - 20k
CyberWare 3030RGB/PS [Min et al., 2014b]	Low-Intensity Laser Light Source	0.08 - 0.3	0.35	~ 72000
Inspeck Mega Capturer II [Hiremath and Manjunatha, 2013]	Structured-Light	0.7	1.1	?
Kinect [Min et al., 2014b]	IR laser Emitter	~ 1.5 - 50	0.5 - 4.5	149.99
SoftKinetic DS325 [Mracek et al., 2014]	Diffused Laser	14 at 1 m distance	0.15-1	259
Structure [Gutfeter and Pacut, 2015]	IR Structured Light	0.5 - 30	3.5	379
PrimeSense Carmine [Min et al., 2012]	IR Light Source	0.1 - 1.2	3.5	?

Kuigi tehnoloogilised täiustused kujutise hõlvamise ja edastamise valdkonnas on aidanud erinevaid mürategureid nõrgendada, siis näo (osalise) katmise puhul on tegemist automaatse näotuvastuse jaoks tõsise väljakutsega [4]. Näo katmine võib olla nii tahtlik kui ka tahtmatu. Erinevad aksessuaarid, nagu mütsid, sallid, (päikese)prillid, juuksed jne on igapäevaelus üsna tavalised varjamisfaktorid, neid saavad edukalt kasutada nii pangaröövlid kui tavalised poevargad. Religioosete näokatete, meditsiiniliste kaitsemaskide, ehituskiivrite jne puhul on aga tegemist tavapäraste ja igapäevaste piirangutega [5].

Kolmemõõtmeliste näokujutiste uurimiseks on erinevad autorid kasutanud nii kõrge lahutusvõimega seadmetel saadud FRGC v2.0 ja Bosphorus [6], York, GavabDB, Binghamton University, Texas-3D, UMB-DB ja 3D-RMA andmebaase, kui ka odavamate seadmetega tehtud CurtinFaces, NASK-StructureFacebase, BIWI Kinect Head Pose Dataset, UWA Kinect dataset, FaceWareHouse ja EURECOM dataset [7].

Kahjuks ei ole need tööd autorile kättesaadavad, samuti on need antud töö skoobile raskesti sobivad, kuna kirjelduse järgi sisaldavad kolmemõõtmelisi (köver)pindasid, selmet tuvastatud punkte.

Sügavussensoritega kaamerad, mida sageli kutsutakse ka RGBD kaamerateks, on võimelised edastama 3D kujutisi kaadrisagedusega 30-60 kaadrit sekundis, kusjuures edastaval kujutisel on suhteliselt madal resolutsioon ja kõrge müratase. Weronika Gutfeter ja Andrzej Pacut on oma töös [3] uurinud meetodeid, mis võimaldaksid mobiilsete seadmete andmeid uurida, kuigi ainult staatilises kontekstis. Nad on transformeerinud 3D andmeid lokaalseteks pindadeks ning seejärel ühtse pikkusega vektoriteks. Tunnuste maatriksid arvatati välja erinevate kujutiste jaoks, et neid oleks võimalik kasutada edaspidi põhiosade analüüsil (PCA). Seejärel arvatati välja vead ja võrreldi tulemusi nendega, mis olid saavutatud statsionaarsetel seadmetel. Oma töös jõudsid nad järeldusele, et mobiilsete seadmete paljude kaadrite summaarsel töötlemisel on võimalik jõuda tulemuseni, mis on võrreldav statsionaarsete seadmetega kontrollitud laboritingimustes saadavaga.

Mõningad autorid [8] nimetavad eraldi juhtumina ruumilise tuvastamise puhul ka 2,5D mudelite tuvastamist. 2,5D nimetatakse näo tasapinnalist kujutist, kui igal punktil on täiendavalt Z ehk sügavusmõõde.

Näotuvastust klassifitseeritakse terviklikuks (holistic), iseloomulike detailide (ingl k. feature-based) põhiliseks ja hübriidmeetoditeks [9].

Põhiosade analüüsil (*principle component analysis* - PCA) [10] ja lähimatel normaalpunktidel (*closest normal points* - CNP) [11] põhinevad meetodid kuuluvad tervikliku kategooria meetodite hulka. Iseloomulike detailide meetodite kasutamisel uuritakse väiksemaid näopiirkondi ja/või detaile nende klassifitseerimiseks. Hübriidmeetodite puhul uuritakse nii tervet näokujutist, kui ka väiksemaid piirkondi (detaile). Detailipõhised uurimismeetodid töötavad paremini näoilmete ja peasendite uurimisel, kujundite kaarte kasutatakse 3D näotuvastuses kombineerides SIFT (*scale*

*invariant feature transform*) sobitusraamistikke koos 2D näotuvastusega. Li et al [12] laiendas SIFT laadseid sobituvusskeeme 3D näokujundist moodustatud võrgustikuga (mesh) ja pakkus välja kolmemõõtmeliste võtmepunktide alusel moodustatud kõverate kasutamist koos kujundikaartidega.

3D andmete taandamist kahemõõtmeliseks ja seejuures tekkivat andmekadu on uuritud oluliselt vähem ja enamus selle valdkonna uuringutest jäävad hoopis geoinformaatika valdkonda. Kolmemõõtmelist loodust on inimkond osanud kahemõõtmelistel kaartidel kujutada juba muistsest Babülooniast saadik [13].

Kui me vaatleme inimese nägu kui tahket keha, siis on võimalik ühildada erinevaid mõõdistusi iteratiivse lähimpunkti meetodiga (ingl. k Iterative Closest Point - ICP). Oma algsel kujul on näokujutiste võrdlemisel kasutatav ICP suhteliselt aeglane ja näoilmete muutuste suhtes invariantne, kuid seda on võimalik modifitseerida näo tunnuspunktide kogumiga opereerimiseks. Seda algoritmi kasutatakse enamuses meetoditest, et mõnes etapis teostada nägude joondamist kolmemõõtmelises ruumis. Oma töös [14] Queirolo et al. soovivad kasutada *Simulated Annealing* (SA) nimelist meetodikat, et mõõta ja võrrelda pindade sarnasusi. Kolmemõõtmelise näotuvastuse puhul on klassikalisest 2D näotuvastusest eristavaks nähtuseks teave näo pinnakõveruste kohta.

Paljud lähenemisviisid võrdlevad näopinnal leiduvaid kõveraid nagu näiteks ninaotsast radiaalselt lähtuvad kõverad [15] või geodesiaalsed samakõrgus(sügavus)jooned [16].

Teine lähenemisviis seisneb näopinnal iseloomulike tunnuspunktide leidmises. Mõningates artiklites [17] on ära toodud ka liitalgoritmid, mis kombineerivad hästituntud 2D meetodeid 3D tunnuste töötlusega.

## **2.1 Sarnased tööd**

Tong Jia et. al. [18] annavad hinnangu Kinecti kaamera kasutamise võimalusele näotuvastuses. Oma töös tutvustavad nad riistvara ning näotuvastuse algoritmide kasutamist ja analüüsivad nägude äratundmise määra. Lühidalt võrdlevad nad ka 2D ja 3D näotuvastuse eeliseid ja puuduseid ning jõuavad järeldusele, et läbiviidud eksperimendid andsid häid tulemusi.

Zhuoran Wu et. al. [19] uurivad oma töös 3D punktipilve kujutise normaliseerimist, st. pea asendist tingitud häiringute kõrvaldamist. Edasi uurivad nad nägude tuvastamiseks

Bayesi klassifikaatorite kasutamist ning jõuavad järeldusele, et nende poolt uuritud meetodid on sobivad inimeste kiireks tuvastamiseks.

Silverstein ja Snyder [20] uurivad oma töös Kinecti kaamera kasutamist inimeste tuvastamiseks haigla tingimustes kiiritusravi seanssidele pääsemisel. Nemed kasutavad oma töös 31 näol tuvastatud punkti ning moodustavad nende punktide vahele 465 vektorit. Oluline on see, et nad kasutavad Kinecti poolt pakutavaid nimelisi punkte, kuid jätavad neist 4 tükki valikust välja. Samuti uurivad nad oma töös erinevaid valgustustingimusi ning peasendeid.

Kasutades optimeeritud parameetreid tuvastusalgoritmide jaoks saavutavad nad tuvastustäpsuseks üle 96%, kuid see on saavutatud suhteliselt pikaajase katsealuse skanneerimise sessiooniga, mis ulatub ligikaudu 30 sekundini. Oma töös jõuavad nad järeldusele, et väljatöötatud süsteem on piisavalt täpne, lihtne ja kuluefektiivne, kui edaspidi suudetaks andmete kogumine ja töötlemine saavutada lühema ajaga.

Väga olulise tähelepanekuna märgivad nad ära, et objekti valgustingimused omavad olulist osa tuvastamise protsessis. Vähese valguse tingimustes väheneb tuvastusprotsessi täpsus oluliselt. Samuti märgivad nad ära, et näiteks prillide valguspeegeldused võivad põhjustada näopunktide ebatõest määramist. Samamoodi võivad mõningaid häireid põhjustada kaela ümber asetsevad kraed ning sallid ja sama kehtib ka mõningate soengutüüpide puhul.

Tabelis 2 on toodud veel mitmeid olulisi 3D näotuvastuse alaseid töid.

Tabel 2 Mõningad olulisemad 3D näotuvastuse alased tööd [4].

Author	Type	Feature Extraction	Classifier	Dataset	$\alpha$
[Gordon, 1991]	3D	Distance Measures	Euclidean Distance	8 subjects (23 scans)	97.00
[Tanaka et al., 1998]	3D	Curvature features	Fisher Spherical Approximation	37 subjects	100
[Chua et al., 2000]	3D	Point Signature Comparison	Ranked vote	6 subjects (24 scans)	100
[Moreno et al., 2003]	3D	Geometric statistics	Euclidean Distance	GavabDB	78.00
[Min et al., 2012]	2.5D	L2 Distances	Euclidean Distance	20 subjects	100
[Naveen and Moni, 2015]	2.5D	DWT + DCT	Euclidean Distance	FRAV3D	96
[Tang et al., 2015]	3D	Principal Curvatures + LNP	Weighted Sparse Representation	FRGC	93.33
[Cardia Neto and Marana, 2015]	2.5D	3D-LBP+HAOG	SVM	Eurecom	~98
[Bondi et al., 2015]	2.5D	SIFT an Curvatures	RANSAC + Distance and Saliency Metric	Kinect Sequences (16 subjects)	100
[Chang et al., 2003]	MM	PCA	Mahalanobis Distance	366 subjects (676 scans)	98.8
[Tsalakanidou et al., 2003]	MM	Eigenfaces	Euclidean Distance	XM2VTS	98.75
[Mian et al., 2007]	MM	3D-SFR and 2D-SIFT	Modified ICP	FRGC	98.31
[Mian et al., 2008]	MM	Tensor Representation + 2D SIFT	4 Different Similarity Measurements	FRGC	98.6
[Li et al., 2013]	MM	-	SRC	CurtinFaces	96.7
[Hiremath and Manjunatha, 2013]	MM	Gabor Features	Nearest Neighbor	Texas 3D, Bosphorus and CASIA 3D	99.5
[Ajmera et al., 2014]	MM	SURF	Nearest Neighbor	Eurocom and CurtinFaces	89.28 and 98.07
[Mracek et al., 2014]	MM	Gabor/Gauss-Laguerre features	Correlation Metric	Kinect, Kinectic Dataset, FRGC	<89
[Elaiwat et al., 2015]	MM	Curvelet Coefficients	Cosine Distance	FRGC, BU-3DFE, Bosphorus	99.2, 95.1, 91
[Naveen et al., 2015]	MM	mLBP	Euclidean Distance	FRAV3D	<91.88
[Krishnan and Naveen, 2015]	MM	Saliency + Entropy + HOG	Tree Bagger	FRAV3D, CurtinFaces	92
[Dai et al., 2015]	MM	ELMDP/Gabor features	Nearest Neighbor	CurtinFaces	~95
[Hayat et al., 2015]	MM	Riemannian manifold	SVM	BIWI Kinect, CurtinFaces, UWA Kinect	94.737

## 2.2 Näotuvastus

Kolmemõõtmelise näo tuvastamise juures on viimane etapp tunnuste eristamine (*feature extraction*) ja neid kasutades identifitseerimine. Selleks on välja pakutud erinevaid algoritme, mis kõik kasutavad kolmemõõtmelist andmestikku. Mõned lähenemised kasutavad 2D nägude tuvastamise mooduseid, neid samal ajal laiendades 3D nägude tuvastamiseks ja analüüsiks. Nii näiteks 'omapindade' (ingl k. *eigen surface*) meetodi puhul iga kolmemõõtmeline nägu konverteeritakse vektorkujule ja põhiosade analüüsi (PCA) lähenemisel arvutatakse näokujutise vektorite kovariandi maatriksi omaväärtused ja omavektorid. Seejärel valitakse välja K suurimat omaväärtust ja vastavat omavektorit tunnuste (punktidevahelised kaugused) väljaselgitamisel. Näo tuvastamiseks projitseeritakse leitav nägu kovariantmaatriksi valitud omavektoreid kasutades omadusruumi (ingl k. *feature space*) [2].

*Fischer Face* näotuvastuse lähenemist kasutatakse edukalt paljudes 2D tuvastusalgoritmides. See algoritm põhineb lineaarsel diskriminantanalüüsil (ingl k. *Linear Discriminant Analysis*, LDA), mis eraldab tunnused, et maksimeerida klassidevahelise hajuvusmaatriksi (ingl k. *scatter matrix*) determinant samaaegselt klassisisese hajuvusmaatriksi minimeerimisega [2].

Kõverustel põhinevaid tunnuseid kasutatakse samuti 3D näotuvastusel. Need tunnused on näoasendite suhtes põhimõtteliselt muutumatud. Näopunktil asetsev kõver iseloomustab kahemõõtmelise kõvera segunemist selles punktis asetseva näopinna lõikejoonega. Kuigi erinevaid tasandeid saab defineerida, et ristata näopunktiga, omavad kaks kõverat minimaalse ja maksimaalse kõverusega erilist tähtsust, kuna teiste kõverate kõverusi saab neid kasutades välja arvutada. Teisisõnu tähendab see, et mingit lokaalset näopiirkonda saab kirjelda kahe, minimaalse ja maksimaalse kõveraga [2].

Samuti on olemas algoritmide grupp, mis põhineb näoprofiilidel. Selle lähenemise puhul „lõigatakse“ näopinna erinevata tasapindadega ja saadakse tulemusena 2D kõverad, mida saab kasutada tunnuste väljaeraldamiseks ja nägude tuvastamiseks. Sagedasti kasutav on radiaalsete kõverate kasutamine, kus kõverad koonduvad nina otspunktis (vt. joonis 1). Sellisel juhul näoilmed ja -asendid mõjutavad ainult radiaalsete kõverate mõningaid osasid ning sellest tulenevalt on see meetod sobilik kasutamiseks ka erinevate näoilmete puhul. [21]



Joonis 1. Radiaalsete lõigete kasutamine 3D näotuvastamisel erinevate näoilmete puhul [21].

### **2.3 Masinõppe metodoloogia**

Masinõppe puhul on jaguneb töövoog põhimõtteliselt neljaks sammuks:

- Eeltöötlus
- Tunnuste eraldamine
- Mõõtmete vähendamine (*dimensionality reduction*)
- Klassifitseerimine või regressioon

## 3 Biomeetria analüüs ja andmete eeltöötlus

### 3.1 Kolmemõõtmelised näo esitusviisid

Kolmemõõtmelist näokujutist esitakse enamasti X, Y ja Z väärtuseid omavate punktide pilvena. Punkt pilves on suur kogumik 3D punkte näopinnalt, mis on genereeritud 3D skannerite poolt. Punktidest moodustatakse võrgustik, kus 3D võrgusilmad võivad olla kolmnurksed või suurema nurkade arvuga polügonid. Kolmedimensiooniliste punktide pilvest 3D pindadeks konverteerimiseks on välja töötatud mitmeid algoritme, nagu näiteks Delauney (Delone) triangulatsioon [2] jt. meetodid.

Erinevad peasendid (pööratud, kallutatud) kolmemõõtmelises ruumis on probleemiks, mida saab hõlpsasti lahendada kasutades 3D näoandmestikku. Siiski saavad 3D näoandmetel põhinevad meetodid sageli väiksema tuvastamistulemuse kui kahemõõtmeliste halltoonidel põhinevate näokujutiste (fotode) tuvastamise algoritmid. Kuna inimese peasend fotol võib olla erinev, siis näoasendi variatsioonide rohkus on üks enim väljakutseid pakkuv ülesanne. Kuigi enamus näotuvastuse tehnikaid suudab saavutada väga hea tulemuse, kui nägu on otsevaates, langevad tulemused oluliselt kui inimene ei vaata otse kaamerasse [2].

Kui kahemõõtmelise kujutise (ruumi) puhul on pea asendi muudatused mittelineaarsed, siis kolmemõõtmelises ruumis on need lineaarsed.

### 3.2 Microsoft Kinect abil mudelite andmebaasi loomine

3D näomudelite uurimiseks oli kõigepealt vaja luua andmebaas, kuna sobivaid andmebaase ei õnnestunud erinevatel põhjustel leida või hankida.


Kinecti kaamera on võimeline samaaegselt saada nii 2D kui ka 3D informatsiooni ühelt RGB kaameralt ja kahelt 3D sügavussensorilt. Sügavussensorid koosnevad infrapuna laserprojektorist ja monokroomsest CMOS sensorist. Kinecti seade saab infot objekti tekstuuri ja väljanägemise kohta RGB kaameralt ja kaugusinformatsiooni sügavussensoritelt. Toorandmeid töötleb Kinect edasi järgnevate protseduuridega [2]:

1. Pea lokaliseerimine ja näo jälgimine;
2. Peasendi ja näotunnuste arvutamine;



3. Silmade jälgimine;
4. Pilgu hindamine;
5. Peegelduste tabamine.

Kinect SDK näojälgimise osa põhineb sisseehitatud CANDIDE-3 mudelil. CANDIDE-3 mudel (vt. Joonis 2) sisaldab 113 võrgustiku sõlmpunkti ja 168 pinda ning tal on võrreldes varasemate mudelitega oluliselt parendatud suu ja silmade modelleerimine [22]



Joonis 2. Candide-3 näomudel (a) kolmnurkvõrgustik. (b) näokujutisega sünkroniseeritud mudel [23].

Käesolevas töös on kasutatud ainult Kinect SDK poolt töödeldud 3D mõõdistuspunkte, RGB kahemõõtmelisi kujutisi ei ole kasutatud. Kuna Kinecti SDK väljastab erinevalt CANDIDE-3 mudelist 1347 mõõdistuspunkti, siis salvestati need edasiseks töötluks täies mahus.

### 3.3 Näokujutiste skanneerimine

Mudelite andmebaasi loomiseks koostas töö autor MS Kinect v2 SDK-d kasutades programmi, mille abil loodi katseisikutest andmebaas, kus on igast isikust erinev arv (100-600) erinevate näoilmete ja peasenditega kujutist. Programm koostati keeles C# Visual Studio 2017 keskkonnas.

Näokujutiste salvestamiseks paigaldati Kinecti kaamera u. 160 cm kõrgusele ja 0,7-1,5m kaugusele katseisikust. Katseisikud (26 isikut) olid erinevast soost ja vanusest (8-65a) europiidse rassi esindajad. Iga isiku kohta näoandmete kogumiseks kulus „puhast“ skanneerimise aega ca 3x15 sekundit.

Andmebaasi loomisel oli eesmärgiks imiteerida erinevaid reaalelulisi olukordasid, seepärast paluti katseisikutel kujutada kolme erinevat näoilmet - neutraalne, rõõmus ja kurb. Reaalselt soovitud emotsioone ei õnnestunud sageli esile manada ja nii võib öelda, et tegelikult on tegu mitte reaalsest emotsioonidest põhjustatud näoilmetega, vaid neid imiteerivate grimassidega. Sellest hoolimata annavad need ilmed väga suure varieeruvuse iga katseisiku andmetes. Kui eesmärgiks oleks olnud saada kujutised nä. „laboritingimustes“ ja ilma erinevate näoilmeteta, oleks ühe isiku lõikes olnud varieeruvused palju väiksemad.

Skanneerimise käigus ei palutud katsealustel pead spetsiaalselt kallutada ega pöörata, samutas ei palutud pead ka mingis kindlas asendis hoida. Kui katsealusel olid prillid, siis prille ei eemaldatud, samuti ei kõrvaldatud ka igasuguseid muid aksessuaare.


Katseks kulunud aeg oli iga isiku puhul veidi erinev ja seega ka igast isikust saadud kujutiste arv on erinev. Erinevad olid ka üldvalgustuse tingimused erinevatel sessioonidel, kuid vältimaks päikesest tekkiva interferentsi mõju, on kõik skaneeringud teostatud sisetingimustes ilma otsese päikesevalguseta ruumis. Spetsiaalset suunatud valgustust katsete tegemisel ei kasutatud.

Kujutised koosnevad kolmemõõtmelistest SDK poolt tuvastatud näo 1347st kindelpunktist (joonis 3). Andmed salvestati edasiseks tötluseks ja uurimiseks .csv failidesse.

Algselt salvestati iga näoilme (või näoilme seeria) kohta eraldi fail, edasisel töötlemisel liideti failid kokku ja iga näo kohta jäi kehtima ainult üks identifitseeritav klassitunnus, mis tähendab seda, et edasise töötlu juures ei eristu see, milline näoilme inimesel konkreetse punktihulga salvestamisel oli.

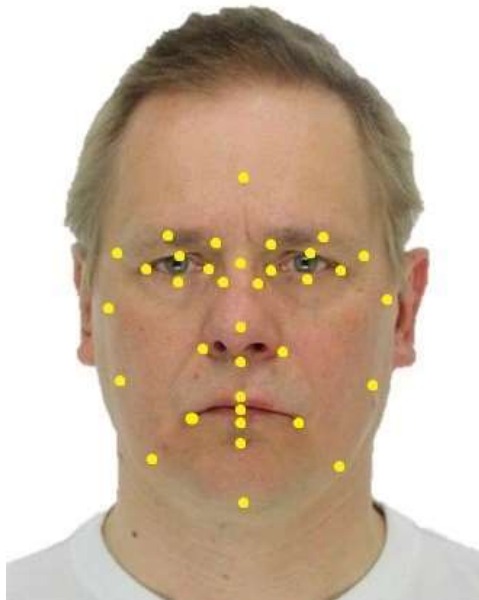
### **3.4 Andmete edasine töötlemine**

1347-st tuvastatud 3D punktist võeti edasiseks uurimiseks Kinect SDK poolt tuvastatud spetsiifilised nimelised 35 punkti, mis paiknevad näo väga iseloomulikes asukohtades, nagu ninaots, suu- ja silmanurgad jne (vt joonis 4). Kõik edasised töötluused ja arvutused tehti Python 3.6 keeles. Kasutusel olid andmepaketid 'scikit learn', 'skfeature', 'numpy', 'matplotlib', 'pandas' jt.



Joonis 3. Kinect'i poolt tuvastatud 1347 näopunkti.

Peasendist (kallutatus ja pööratus) tingitud andmete erinevuse ühtlustamiseks arvutati punktidele uued koordinaadid, neid „keerates“ ümber pea kujuteldavate  $x$ ,  $y$  ja  $z$  telgjoonte kasutades rotatsioonimaatriksit. Rotatsioonimaatriksi aluseks võeti silmade välisnurkades tuvastatud punktid, eeldades, et need on inimesel sümmeetrilised näo telgjoone suhtes, st. paiknevad ühel kõrgusel ja kaugusel. Selle tegevuse tulemusel saadi uued kolmemõõtmelised kujutised, mille puhul saab öelda, et tegu on pea otsevaatega.



Joonis 4. Kinect SDK poolt tuvastatud nimeliste punktide asukohad.

Lisaks näo otsevaatele loodi ka 90 kraadi keeratud vaade e. näoprofiil.

Andmete töötlemiseks projitseeriti punktide vahele Delauney triangulatsiooni põhimõtetel võrgustik. Nii moodustus punktide vaheline virtuaalsetest kolmnurkadest võre (vt joonis 5), mille tipunurki ja servapikkuseid kasutati edasises andmetöötluses.

Kolmnurkade unikaalsete servapikkuste ja nurkade arvutamine.

$$p_1 = (x_1, y_1, z_1); p_2 = (x_2, y_2, z_2) \quad (1)$$

Punktidevaheliste vektorite arvutamine 3D ruumis:

$$|\vec{v}_{12}| = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2 + (z_2 - z_1)^2} \quad (2)$$

Selle valemi puhul on tegu eukleidiliste kauguste leidmisega kolmemõõtmelises ruumis objektide sarnasuse leidmiseks.


Kolmnurga tipunurkade nurkade arvutamine 3D ruumis:

$$\cos(\angle ABC) = \frac{(\vec{A}-\vec{B}) \cdot (\vec{C}-\vec{B})}{|\vec{A}-\vec{B}| |\vec{C}-\vec{B}|} \quad (3)$$

Selle valemi puhul on tegu koosinussarnasuse leidmisega kolmemõõtmelises ruumis objektide sarnasuse leidmiseks.

Nii nagu kolmemõõtmelise ruumi puhul, arvutati ka kahemõõtmelise kujundi puhul kolmnurkade tipunurgad ja külgede pikkused. Kahemõõtmelise ruumi puhul kasutati ainult kahte koordinaati, kolmas e. sügavusmõõde (z-koordinaat) jäeti arvutamisel kõrvale. Kolmemõõtmelises ruumis on näo otsevaade ja külgprofiil samade kolmnurkade andmetega, kuid kahemõõtmelises ruumis on samade 3D ja 2D punktide vahele moodustatud kolmnurkadel erinevad andmed.

Külgvaate puhul on kasutatud kõiki punkte, nii neid, mis on “otse nähtavad”, kui ka neid, mis jäävad “varjatud küljele”.



Joonis 5. Delauney triangulatsiooni põhimõttel moodustatud võrgustik punktide vahepunktide vahel

Edasiseks uurimiseks leiti moodustatud kolmnurkade kõigest külgede pikkustest ja tipunurkadest 281 tunnust, neist 98 on tippudevahelised kaugused ja 183 kolmnurga nurgatippude nurgad. Töös kasutatud tunnuste numeratsioon on ära toodud lisis 7.

Analoogselt kolmemõõtmeliste vektoritega arvatati peale kujutise kahemõõtmeliseks taandamist ka 2D punktipilve andmetest tulenevad tunnused.

## 4 Tunnuste eraldamine ja klassifitseerimine

Moodustatud tunnuste kogumiku põhjal toimub edasine nägude tuvastamine ehk meid huvitava eksemplari õigesse klassi paigutamine (klassifitseerimine).

### 4.1 Parimate tunnuste e klassi diskriminandi leidmine

Liiga suur sisendandmete olemasolu ei ole klassifitseerimisel tavaliselt hea. See suurendab oluliselt andmetöötuseks kuluvat aega ja kogu protsessi keerukust. Lisaks sellele kipuvad paljude ebaoluliste ja liiaste andmete juures õppimismeetodid üle õppima, muutuvad vähem efektiivseteks ning raskemini tõlgendavateks [24].

Seega on tunnuste valimise põhjused järgmised:

- **Vähendab üleõppimist:** Mida vähem on üleliigseid andmeid, seda väiksem on võimalus teha müra mõjutatud otsuseid.
- **Suurendab täpsust:** Vähem eksitavad andmed suurendavad modelleerimise täpsust.
- **Vähendab õppimise aega:** Väiksem andmehulk tähendab algoritmi kiiremat õppimist.

Levinud tee probleemi lahendamiseks on tunnuste väljavalimine, mis tähendab tunnuste arvu vähendamist sisendandmete hulgas. Seda kasutatakse vähendamaks arvutuste hinda ning ebaoluliste ja liiaste tunnuste eemaldamiseks suuremõõtmeliste andmete juures.

Klassifitseerimiseks kasutatavate tunnuste väljavalimise meetodeid saab jagada kolmeks põhirühmaks:

- Filtermudelid, mille puhul on olemas matemaatiline kriteerium hindamiseks tunnuseid või tunnuste alamhulkasid. Põhilised filtermudelid:
  - **Gini indeks.** Kasutatakse enamasti selleks, et hinnata diskriminantmäära eraldiseisval tunnusel. Tavaliselt kasutatakse kategooriapõhistel väärtuste hindamisel, kuid saab kasutada ka üldistatud numbriliste väärtuste puhul.
  - **Entroopia.** Klassipõhine entroopia mõõt on seotud konkreetse atribuudi väärtuse fikseerimisest tuleneva informatsioonikasvu (information gain)

mõistega. Entroopia mõõtmisel saavutatakse sarnane tulemus nagu Gini indeksi kasutamisel, kuid see põhineb informatsiooniteoreetilistel põhimõtetel.

Entroopia määr näitab andmetes olevat ebakindlust, lisandeid ja häiritust. Entroopia tasemest sõltub otsustuspuude andmete jagunemine ja sellest tuleneb kuidas otsustuspuu puhul toimub jagunemine.

$$E(v_i) = - \sum_{j=1}^k p_j \log_2(p_j) \quad (3)$$

$v_i$  on konkreetse tunnuse atribuudi võimalikud väärtused,  $p_j$  tähistab andmete fraktsiooni, mis sisaldavad  $v_i$  atribuudi väärtuseid, mis kuuluvad klassi  $j \in \{1, \dots, k\}$

Mida suurem on entroopia väärtus, seda suurem on erinevate klasside segatus. Väärtus 0 näitab täielikku eraldatust ja järelikult ka suurimat diskriminatiivset jõudu.

- **Fisher'i skoor** on algupäraselt mõeldud numbriliste atribuutide jaoks, et hinnata keskmist klassidevahelist erinevust keskmisest klassisisisest erinevusest. Mida suurem on Fisher'i skoor, seda suurem on atribuudi diskrimineeriv jõud ehk eristusvõime.

$$F = \frac{\sum_{j=1}^k p_j (\mu_j - \mu)^2}{\sum_{j=1}^k p_j \sigma_j^2} \quad (4)$$

$\mu_j$  on keskmine,  $\sigma_j$  standardhälve  $j$  klassi kuuluvatel punktidel.  $p_j$  on murdosa andmepunktidest, mis kuuluvad klassi  $j$ .  $\mu$  on globaalne keskmine kogu andmepunktidest.

Valemi lugeja hindab keskmist klassidevahelist erinevust, seevastu nimetaja hindab keskmist klassisisest erinevust.

- Fisheri lineaarset diskriminanti saab vaadelda kui Fisher skoori'i üldistust, kus moodustatud tunnused vastavad algsete tunnuste lineaarsetele kombinatsioonidele, mitte algsetele tunnuste alamhulkadele.

- Ümbrismudelid (ingl.k. wrapper models) on suutelised tunnuste valikut töö käigus optimeerima ning nende põhistrateegia põhineb iteratiivsel tunnuste hulga täpsustamisel tunnuste samaaegsel edukal lisandamisel.
- Manusmudelid (ingl.k. embedded models) põhinevad ideel, et paljude klassifikatsioonivormide lahendustel on olemas näpunäited või lisainformatsioon kõige olulisemate kasutatavate tunnuste kohta. See tähendab seda, et klassifitseerimise probleemi lahendusse on kaasatud teadmised omaduste endi kohta [25].

Muude filtripõhiste tunnuste väljavalimise meetodite juures on Fisher skoori kasutamine tulenevalt selle üldisest heast jõudlusest üks kõige laiemini levinud kriteeriume kontrollitud (ingl k. supervised) tunnuste välja valimiseks [24].

#### 4.1 Gini lisand e. ebapuhtus (ingl k. Gini Impurity)

Gini lisand on ebakorrekse klassifitseerimise mõõt iga klassi jaoks. Seda algoritmi kasutatakse klassifitseerimise puude juures ning see näitab kui tihti juhuslikult valitud element saab valesti määratud kui ta määratakse juhuslikult klasside esinemise sageduse järgi (valem 5).

$$G(S) = 1 - \sum_{j=1}^k p_j^2 \quad (5)$$

kus  $p_i$  on klassi  $j$  kuuluv kogumi osatähtsus.

#### 4.2 Informatsioonikasv

Informatsioonikasv mõõdab, kui suur on infohulk, mida tunnus annab meile klassi kohta ja ta on peamine näitaja otsustuspuude algoritmides puude konstrueerimisel. Otsustuspuude algoritmid on suunatud alati informatsioonikasvu suurendamisele ning suurima informatsioonikasvuga atribuute kasutatakse testimisel, otsustuspuu jagunemisel esimesena e. otsustuspuu loomist alustatakse suurima infoväärtusega atribuutidest. Informatsioonikasv näitab kui palju „infot“ annab tunnus meile vastava klassi kohta.

Põhimõtteliselt on oodatav informatsioonikasv informatsiooni entroopia muutus eelnevast olekust uude olekusse ehk näitab meile kui oluline on tunnusvektori antud



atribuut. Lihtsustatult saab öelda, et kui informatsioonikasv on 0, siis kaks olekut on identsed.

$$\text{Informatsioonikasv} = \text{entroopia(algne)} - [\text{kaalutud keskmine}] * \text{entroopia(järeltulija)}$$

Otsustuspuude puhul on ID3 algoritm algne tuumikalgoritm. Selle algoritmi puhul kasutataksegi informatsioonikasvu sõlmede jagunemise kriteeriumina. Kui kõik sõlmed on puhtad või informatsioonikasv ei ole nullist suurem, siis puu lõpetatakse. ID3-ga ei saa väga head resultaati, kui andmetes on liiga palju detaile või müra. ID3 algoritmi edasiarendus on C4.5 algoritm, mille puhul kasutatakse sõlmede jagunemise kriteeriumina normaliseeritud informatsioonikasvu. Kui jagatavate üksuste hulk jääb alla kindlaks määratud piiri, siis puu lõpetatakse.

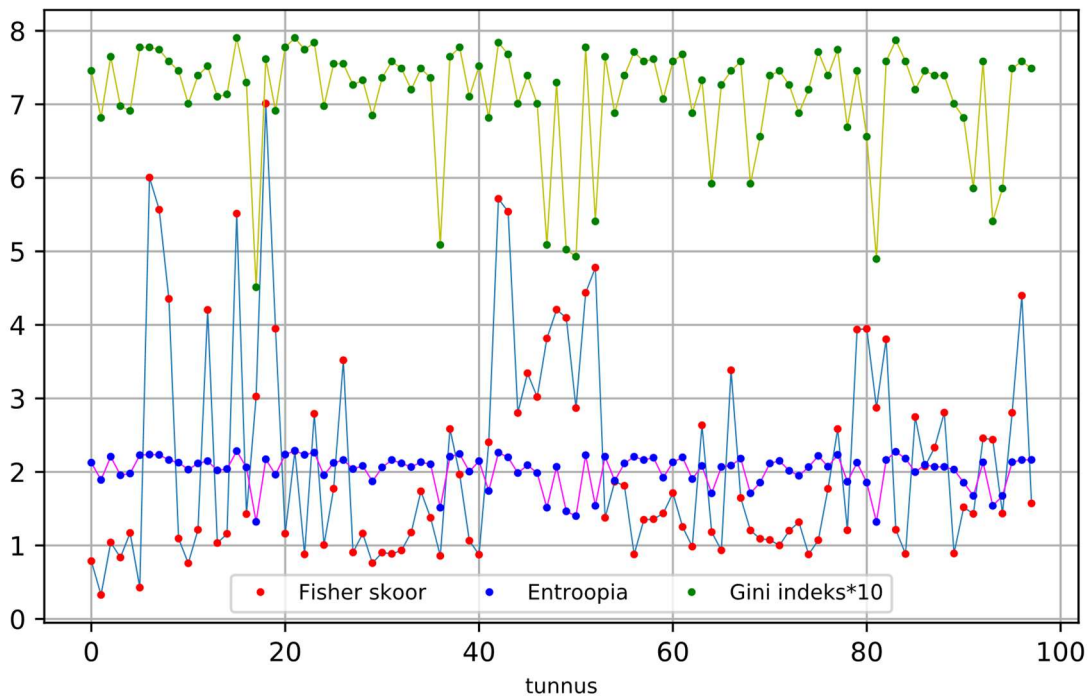
## 5 Töö tulemused

### 5.1 Tunnuste valimine


Käesolevas töös kasutati tunnuste valimiseks algselt filtermudeleid (Gini indeks, entroopia ja Fisher skoor). Gini indeksi ja entroopia arvutamine üle terve andmekogumiku iga tunnuse kohta ei andnud häid tulemusi, kuna paljud tunnused on erinevatel eksemplaridel väga sanased ning klassi sees on varieeruvus väga suur.

Tabelis 3 on tunnused seatud vastavalt kas kahanevasse (Fisher skoor) või kasvavasse (Gini indeks ja entroopia) pingeritta. Antud pingeridade alusel on toimusid esialgsed klassifitseerimise eksperimendid.

Esialgsed tunnuste diskrimineerivaid parameetreid kajastavad joonised 6 ja 7.



Joonis 6 Fisher skoori, Gini indeksi ja entroopia võrdlemine klassifitseerimise tunnuste valimiseks (3D eukleidilistel kaugustel põhinevad tunnused)




Joonis 7 Fisher skoori, Gini indeksi ja entroopia võrdlemine klassifitseerimise tunnuste valimiseks (3D kolmnurkade tipunurkadel põhinevad tunnused)

Tabel 3. Pingeritta seatud Fisher skoori, Gini indeksi ja entroopia väärtused (pingerea esimesed 20).


Tunnused ja nende väärtused, pingerida Fisher skoori järgi				Tunnused ja nende väärtused, pingerida <b>Gini indeksi</b> järgi				Tunnused ja nende väärtused, pingerida <b>entroopia</b> järgi			
Nr	Fisher skoor	Gini indeks	En-troopia	Nr	Fisher skoor	<b>Gini indeks</b>	En-troopia	Nr	Fisher skoor	Gini indeks	<b>En-troopia</b>
18	7,0111	0,7616	2,1729	17	3,0264	0,4512	1,3215	81	2,8724	0,4896	1,3200
120	6,4238	0,7840	2,2628	81	2,8724	0,4896	1,3200	17	3,0264	0,4512	1,3215
180	6,0951	0,7776	2,2366	50	2,8685	0,4928	1,4000	262	1,5746	0,4960	1,3542
172	6,0099	0,7648	2,1812	262	1,5746	0,4960	1,3542	50	2,8685	0,4928	1,4000
6	6,0042	0,7776	2,2366	175	4,6434	0,5024	1,4644	261	1,2653	0,5536	1,4337
42	5,7159	0,7840	2,2628	173	4,3744	0,5024	1,4644	175	4,6434	0,5024	1,4644
119	5,5935	0,7456	2,1503	49	4,0956	0,5024	1,4644	173	4,3744	0,5024	1,4644
7	5,5674	0,7744	2,2333	260	1,1880	0,5088	1,5142	49	4,0956	0,5024	1,4644
43	5,5402	0,7680	2,1991	184	4,1387	0,5088	1,5142	152	1,4642	0,5760	1,4717
112	5,5167	0,7616	2,1729	47	3,8159	0,5088	1,5142	206	0,7787	0,5440	1,4937
15	5,5139	0,7904	2,2841	36	0,8584	0,5088	1,5142	260	1,1880	0,5088	1,5142
170	5,3795	0,7840	2,2628	208	0,9604	0,5120	1,5444	184	4,1387	0,5088	1,5142
239	5,1607	0,7456	2,1264	93	2,4386	0,5408	1,5395	47	3,8159	0,5088	1,5142
166	5,1466	0,7904	2,2841	52	4,7796	0,5408	1,5395	36	0,8584	0,5088	1,5142
183	5,1038	0,6624	1,8205	206	0,7787	0,5440	1,4937	218	0,8701	0,6048	1,5196
240	5,1018	0,7584	2,1632	261	1,2653	0,5536	1,4337	93	2,4386	0,5408	1,5395
161	4,9701	0,7776	2,2415	152	1,4642	0,5760	1,4717	52	4,7796	0,5408	1,5395
241	4,9155	0,7136	2,0113	280	1,4301	0,5824	1,6451	208	0,9604	0,5120	1,5444
52	4,7796	0,5408	1,5395	94	1,4340	0,5856	1,6753	193	0,2834	0,6240	1,6136
162	4,7378	0,7744	2,2333	91	1,4302	0,5856	1,6753	280	1,4301	0,5824	1,6451

Et klassifitseerimise etapis tulid tulemused üldise Gini indeksi ja üldise entroopia arvutamise järgi oodatust halvemad ja vastukäivad, siis osutus vajalikuks katsetada teisi meetodeid parimate klassifitseerimise tunnuste valimiseks ja esialgsed tulemused jäeti kõrvale.


Selleks arvutati *Gini Impurity* (Joonised 8 ja 10) ning informatsioonikasvu (Joonised 9 ja 10) alusel valitud tunnused.



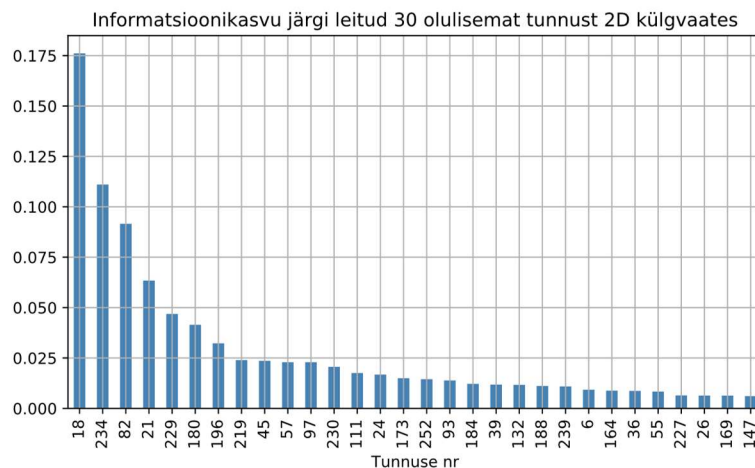
Joonis 8. Gini Impurity järgi leitud olulisemad tunnused 3D otsevaate puhul



Joonis 9. Informatsioonikasvu järgi leitud olulisemad tunnused 3D otsevaate puhul.



Joonis 10. Gini Impurity järgi leitud olulisemad tunnused 2D külgaate puhul.



Joonis 11. Informatsioonikasvu järgi leitud olulisemad tunnused 2D külgvaate puhul.

## 5.2 Klassifitseerimine

Tuvastamisülesanded e. klassifitseerimine on üks laiemalt levinud masinõppe probleeme ja ülesanne ise jaguneb reeglina kahte faasi:

**Treeningfaas:** luuakse treeningmudel treeningandmete põhjal. Kõik masinõppe algoritmid vajavad treenimist, et nad suudaksid andmeid klassifitseerida ja seejärel ennustatavaid andmeid väljastada. Treenimise sisu on programmile kindlaks määratud klassidega (märgendatud) sisu etteandmine ja selle tulemusel saab programm tundmatutele andmetele omapoolsed klassimärgendid lisada.

**Testimisfaas:** kasutatakse loodud treeningmudelit, et määrata kindlaks klassitähis ühele või rohkematele seninägemata testandmetele.

Käesolevas töös klassifitseeriti kuni 30 tunnuse järgi, kuna rohkemate tunnuste järgi klassifitseerimine ei andnud märgatavat täpsuse kasvu ja ei olnud ka töö eesmärgiks. Tunnuste arvu kasvades suurenes klassifitseerimiseks kuluv aeg oluliselt.

## 5.3 Andmestiku jagamine test- ja treeningandmeteks

Klassifitseerija treenimiseks ja testimiseks jagatakse andmed kaheks. Treeningandmete osa on mõeldud klassifitseerija treenimiseks ning testandmed klassifitseerija hindamiseks. Treeningandmed moodustasid kolmveerandi (75%) andmete üldmahust, ülejäänud üks neljandik jäi testimiseks. Edaspidi kasutatud tabelite ja graafikute juures

on kasutatud kogu aeg samasid andmeid, st. andmed on jagatud ja segatud treening- ja testosaks täpselt ühtemoodi.

## 5.4 Klassifitseerijate hindamine

Õigusus (Accuracy)  $ACC = \frac{TP+TN}{P+N}$  e. *õigsus* =  $\frac{\text{Õigesti klassifitseeritud näited}}{\text{kõik näited}}$

- TP -tõeselt positiivne
- TN – Tõeselt negatiivne
- FP – valepositiivne
- FN – valenegatiivne

Kasutatakse ka mitmeid teisi hindamisviise nagu eksimismatriks (ingl k. Confusion matrix), F1 skoor, F-beeta skoor, ROC kurvid, täpsuse (ingl k. precision) hindamine jne.

Klassifitseerimisel kasutati erinevate tunnuste valimise meetodite hindamiseks nii otsevaates 3D andmeid kui ka profiilis 3D andmeid, samuti tasapinnale taandatud otse- ja külgvaateid.

Joonistel ja tabelis on tuvastamistäpsus määratud viiel erineval algoritmi põhisel:

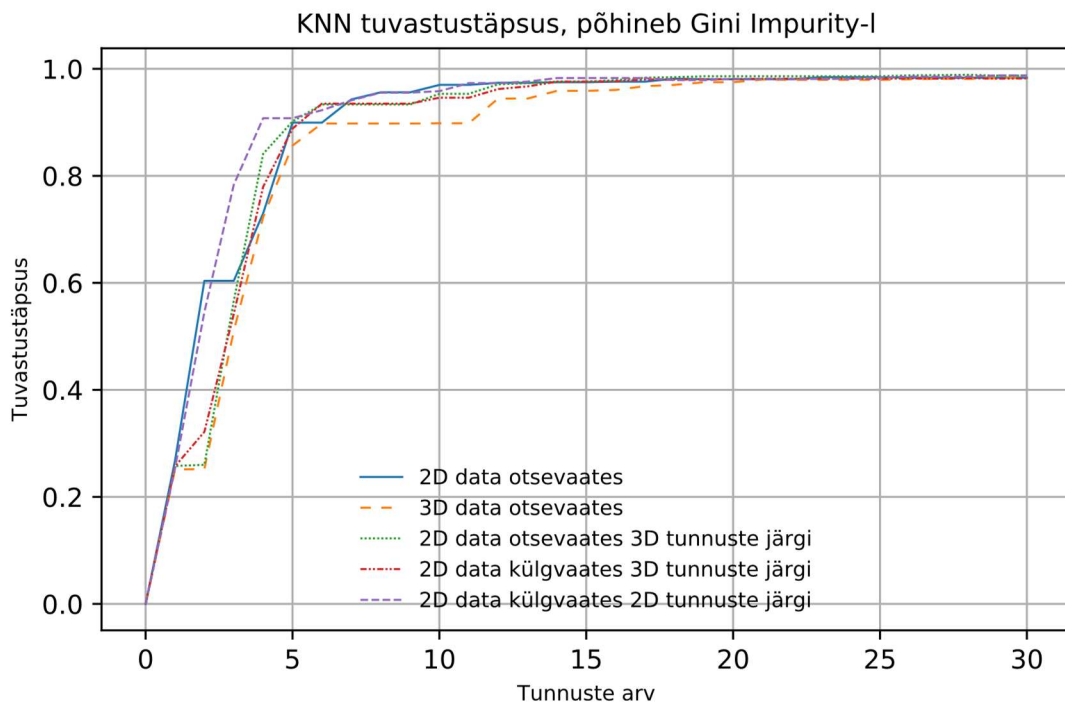
- 3D andmed otsevaates;
- 2D andmed otsevaates, kusjuures on kasutatud sama tunnuste pingerida, nagu 3D andmete juures;
- 2D andmed 90 kraadi pööratud vaate puhul, kusjuures on kasutatud sama tunnuste pingerida, nagu 3D andmete juures;
- 2D andmed otsevaates;
- 2D andmed 90 kraadi pööratud vaate puhul, tunnuste pingerida on määratud samade andmete järgi.

Kõikidel juhtudel on parimate tunnuste pingerida määratud nii Fisher skoori, *Gini Impurity* kui ka informatsioonikasvu järgi.

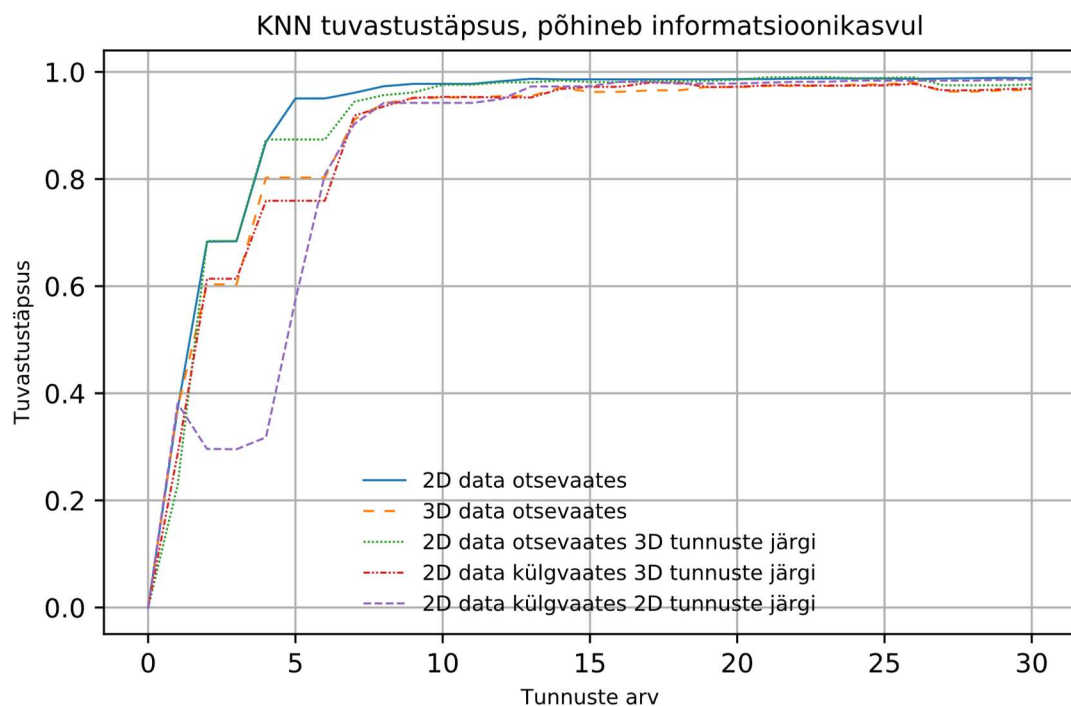
## 5.5 KNN, K-lähima naabri meetodil klassifitseerimine

Antud meetodi puhul ei looda sisendandmetest üldist mudelit, vaid kasutatakse lähedaste andmetega treeningandmestiku punkte, et ennustada testitava kogumi väärtust. Põhimõtteliselt leitakse treeningandmete hulgast  $k$  lähimat objekti, misjärel loetakse kokku objektide klassid ja valituks osutub klass, mis saab kõige rohkem „häälid“. Meetodit kasutatakse pigem väiksema dimensionaalsusega andmete puhul.

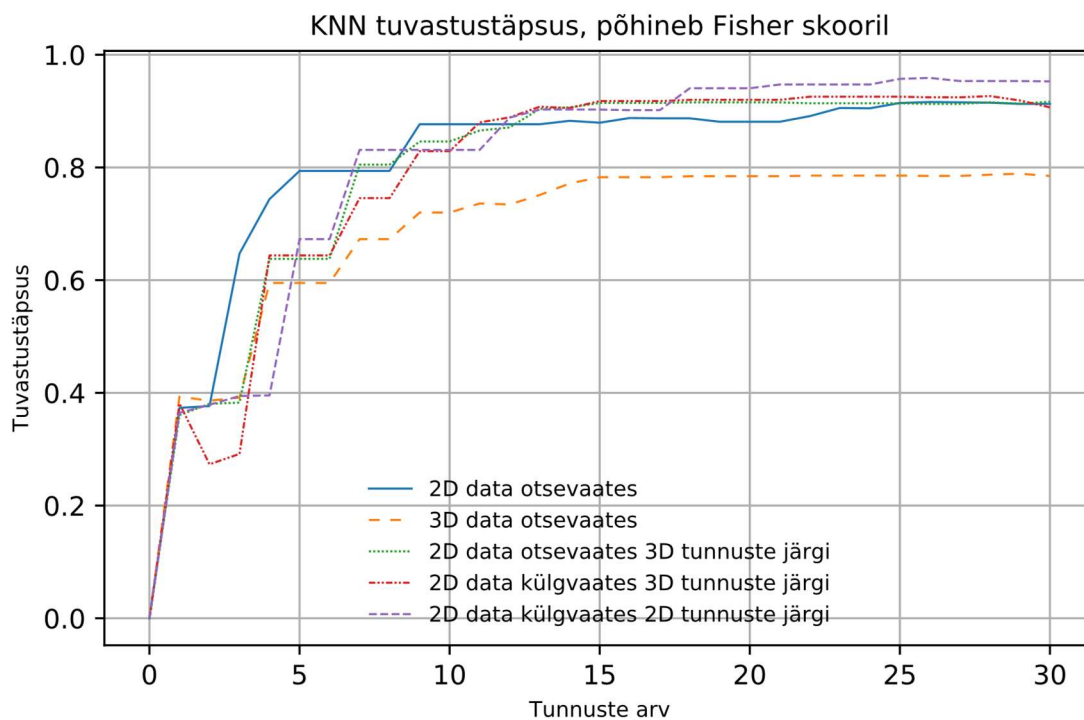
Käesolevas töös määrati naabrite arvaks 3, kuna see andis eksperimentaalselt parima (täpseima) tulemuse. Naabritevahelist kaugust määrati eukleidilise kauguse järgi. Joonistel 12-14 ning tabelis 4 on ära toodud klassifitseerimise õigsuse (täpsuse) tulemused. Tabeli 4 täielikum versioon (30 tunnuse järgi määramine) on ära toodud lisas 1.



Joonis 12 K-lähima naabri puhul saavutatud tuvastustäpsus, tunnuste valik põhineb *Gini Impurity*-l



Joonis 13 K-lähima naabri puhul saavutatud tuvastustäpsus, tunnuste valik põhineb informatsioonikasvul



Joonis 14. K-lähima naabri meetodil saavutatud klassifitseerimisõigsus, tunnuste valik põhineb Fisher skooril.



Tabel 4. KNN algoritmi kasutades saadud tuvastustäpsus (klassifitseerimisõigsus) esimese 6 tunnuse puhul (siin ja edaspidi 100% =1,0).

	<b>3D Fisher skoor, 3D andmed</b>	<b>3D Fisher skoor, 2D andmed</b>	<b>3D Fisher skoor, 2D andmed, 90° profiil</b>	<b>2D Fisher skoor, 2D andmed</b>	<b>2D Fisher skoor, 2D andmed, 90° profiil</b>
0	0,3933	0,3606	0,3811	0,3733	0,3644
1	0,3861	0,3806	0,2733	0,3767	0,3789
2	0,3917	0,3828	0,2917	0,6472	0,3944
3	0,5950	0,6378	0,6439	0,7439	0,3956
4	0,5950	0,6378	0,6439	0,7939	0,6728
5	0,5950	0,6378	0,6439	0,7939	0,6728
	<b>3D Gini, 3D andmed</b>	<b>3D Gini, 2D andmed</b>	<b>3D Gini, 2D andmed, 90° profiil</b>	<b>2D Gini, 2D andmed</b>	<b>2D Gini, 2D andmed, 90° profiil</b>
0	0,2511	0,2578	0,2572	0,2678	0,2533
1	0,2522	0,2600	0,3217	0,6039	0,5456
2	0,5100	0,5661	0,5417	0,6039	0,7833
3	0,7228	0,8411	0,7794	0,7300	0,9078
4	0,8567	0,9017	0,8883	0,8994	0,9078
5	0,8978	0,9333	0,9350	0,8994	0,9228
	<b>3D informatsiooni-kasv, 3D andmed</b>	<b>3D informatsiooni-kasv, 2D andmed</b>	<b>3D informatsiooni-kasv, 2D andmed, 90° profiil</b>	<b>2D informatsiooni-kasv, 2D andmed</b>	<b>2D informatsiooni-kasv, 2D andmed, 90° profiil</b>
0	0,3722	0,2283	0,2867	0,3700	0,3811
1	0,6033	0,6844	0,6139	0,6833	0,2961
2	0,6033	0,6844	0,6139	0,6839	0,2956
3	0,8028	0,8739	0,7594	0,8694	0,3178
4	0,8028	0,8739	0,7594	0,9506	0,5744
5	0,8028	0,8739	0,7594	0,9506	0,8083

Tulemustest on näha, et nägude tuvastamistäpsus e. klassifitseerimisõigsus (ingl k. accuracy) kasvab kõigi tunnuse määramise meetoditega juba viie tunnusega väga kiiresti, ulatudes parimal juhul 95%, misjärel edasine kasv ulatub kuni 0,99ni ehk ligikaudu 99%-ni 30 tunnuse puhul klasside informatsioonikasvu ja *Gini impurity* järgi ning kuni 0,95%-ni Fisher skoori alusel määratud tunnustega.


Kõige paremad tulemused saavutati 30 parima tunnuse puhul tasapinnaliseks taandatud profiilvaate andmete puhul. Ka otsevaates 2D andmestiku puhul on tuvastamistäpsus mõnevõrra parem kui 3D tunnuste puhul.

## **5.6 SVM, tugivektorklassifitseerija (ingl. k. *Support vector machine*)**


SVM mudel põhineb objekti kujutamisel vektorruumis, kusjuures üritatakse leida parimat klassi eristavat lineaarset eraldajat. Mitmemõõtmelises ruumis on eraldajaks hüperatasand (ingl. k. hyperplane), mis jagab sisendpunktid hulkadeks. Kuna meetod sobib nii binaarsete kui ka mitmeklassiliste ülesannete lahendamiseks, siis kuulub ta põhimõtteliselt antud töö jaoks sobivate meetodite hulka.

Käesolevas töös on kasutatud algoritmis *Radial Basis Function* (RBF) tuuma parameetritega  $C=1$  ja  $\gamma = 'scale'$ .


Joonisetal 15-17 ning tabelis 4 on ära toodud klassifitseerimise õigsuse (täpsuse) tulemused. Tabeli 4 täielikum versioon (30 tunnuse järgi määramine) on ära toodud lisas 2.



Joonis 15. SVM puhul saavutatud tuvastustäpsus, tunnuste valik põhineb *Gini Impurity*-l.



Joonis 16. SVM puhul saavutatud tuvastustäpsus, tunnuste valik põhineb Informatsioonikasvul.



Joonis 17. SVM puhul saavutatud tuvastustäpsus, tunnuste valik põhineb Fisher skooril.

Tabel 5. SVM algoritmi kasutades saadud tuvastustäpsus (klassifitseerimisõigsus) esimese 6 tunnuse puhul.

	3D Fisher skoor, 3D andmed	3D Fisher skoor, 2D andmed	3D Fisher skoor, 2D andmed, 90° profiil	2D Fisher skoor, 2D andmed	2D Fisher skoor, 2D andmed, 90° profiil
0	0,4672	0,4678	0,4800	0,4817	0,4822
1	0,4178	0,4417	0,2850	0,3950	0,4422
2	0,4028	0,4233	0,2656	0,4133	0,4400
3	0,4178	0,4400	0,2672	0,4789	0,4383
4	0,4094	0,4317	0,2661	0,4456	0,5167
5	0,4056	0,4278	0,2678	0,4256	0,5144
	<b>3D Gini,</b>	<b>3D Gini,</b>	<b>3D Gini,</b>	<b>2D Gini,</b>	<b>2D Gini,</b>

	3D andmed	2D andmed	2D andmed, 90° profiil	2D andmed	2D andmed, 90° profiil
0	0,3450	0,3778	0,3739	0,3850	0,3733
1	0,2833	0,3311	0,2761	0,4122	0,3528
2	0,3144	0,3311	0,3906	0,3883	0,4111
3	0,3956	0,4239	0,4583	0,3883	0,5150
4	0,4533	0,4967	0,5206	0,5233	0,4722
5	0,5517	0,6344	0,6106	0,5078	0,4656
	3D informatsiooni- kasv, 3D andmed	3D informatsiooni- kasv, 2D andmed	3D informatsiooni- kasv, 2D andmed, 90° profiil	2D informatsiooni- kasv, 2D andmed	2D informatsiooni- kasv, 2D andmed, 90° profiil
0	0,4911	0,3122	0,3778	0,4694	0,4800
1	0,4772	0,5533	0,5550	0,6578	0,3233
2	0,4161	0,4122	0,4606	0,5350	0,2928
3	0,4289	0,4528	0,4672	0,6417	0,2850
4	0,4089	0,4094	0,4544	0,7261	0,3728
5	0,4000	0,3789	0,4506	0,6911	0,4122

SVM algoritmi kasutamise tulemustest selgub, et nägude tuvastamistäpsus kasvab aeglaselt, ulatudes maksimaalselt ~0,70ni ehk ligikaudu 70% 30 tunnuse puhul klasside informatsioonikasvu järgi tunnuseid valides. Võrreldes SVM algoritmi puhul saavutatud tuvastustäpsust teiste algoritmidega, on tuvastustäpsus oluliselt halvem ja ei ole seetõttu antud andmestiku puhul hea valik klassifitseerimiseks.

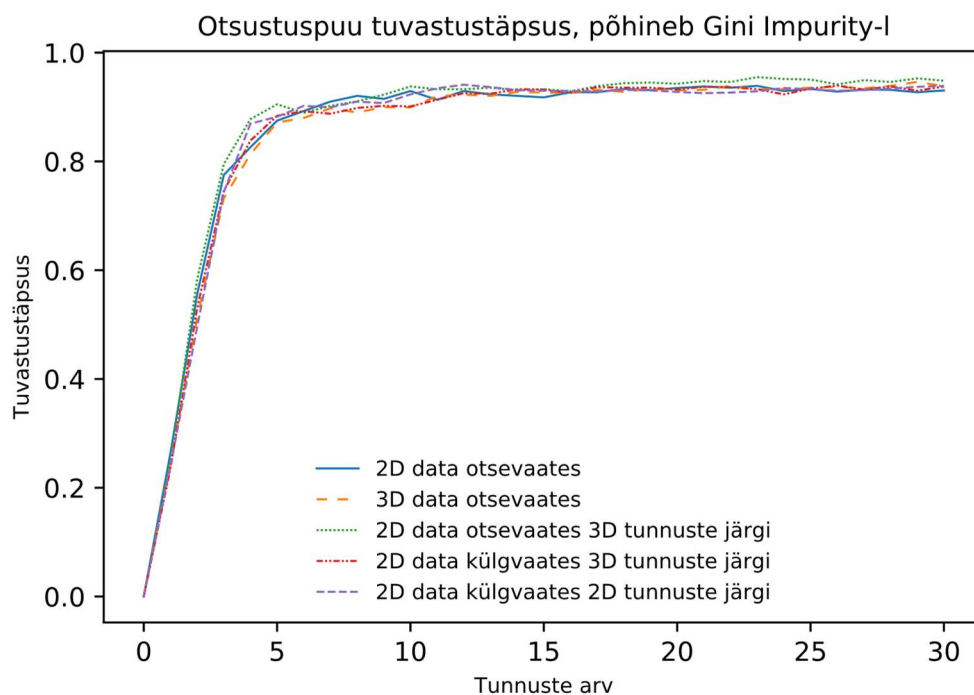
## 5.7 Otsustuspuu (ingl. k. Decision Tree)

Otsustuspuu meetodi puhul on klassifitseerija esitatav puuna, mille tippudeks on tunnused ja kaarteks võimalikud väärtused. Otsustuspuu eelisteks teiste meetodite ees on kasutamise lihtsus klassifitseerimisel, samuti ei jää nad teistele meetoditele klassifitseerimistäpsuselt oluliselt alla. Otsustuspude puhul on kasutusel parimate tunnuste leidmiseks entroopia hindamine ehk informatsioonikasvu määramine.

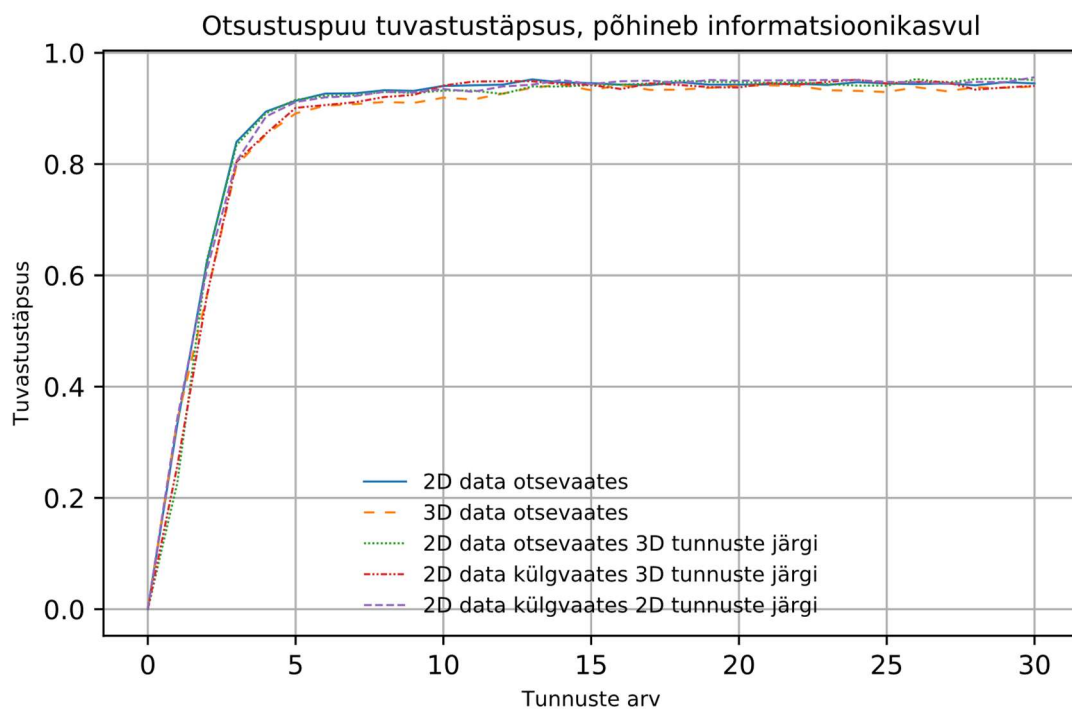
Alternatiivina entroopia hindamisele puu tipus võib kasutada mitme klassi puhul ka Gini indeksit. Otsustuspuu puhul on oht ületreenimiseks (ingl. k. overfitting), millest tuleneb, et ei ole võimalik teha üldistavaid otsuseid õppimisel mittekasutatud tunnuste kombinatsioonidega objekti kohta.

Käesolevas töös kasutati meetodi sisese jagunemiskriteeriumina nii Gini indeksit kui ka entroopiat (informatsioonikasvu). Olulist resultatiivset vahet ühe või teise kriteeriumi kasutamisel ei olnud võimalik täheldada, allpooljärgnevad andmed on saadud kasutades Gini indeksit. Puu sügavust ei ole määratud, st. on lastud puul niikaua laieneda, kuni kõik tipud on „puhtad“ või sisaldavad edasiseks jagunemiseks alla kahe näidise.


Joonistel 18-20 ning tabelis 5 on ära toodud klassifitseerimise õigsuse (täpsuse) tulemused. Tabeli 5 täielikum versioon (30 tunnuse järgi määramine) on ära toodud lisas 3.



Joonis 18. Otsustuspuu puhul saavutatud tuvastustäpsus, tunnuste valik põhineb *Gini Impurity*-l.



Joonis 19. Otsustuspuu puhul saavutatud tuvastustäpsus, tunnuste valik põhineb informatsioonikasvul.



Joonis 20. Otsustuspuu puhul saavutatud tuvastustäpsus, tunnuste valik põhineb Fisher skooril

Tabel 6. Otsustuspuu algoritmi kasutades saadud tuvastustäpsus (klassifitseerimisõigsus) esimese 6 tunnuse puhul.

	<b>3D Fisher skoor, 3D andmed</b>	<b>3D Fisher skoor, 2D andmed</b>	<b>3D Fisher skoor, 2D andmed, 90° profiil</b>	<b>2D Fisher skoor, 2D andmed</b>	<b>2D Fisher skoor, 2D andmed, 90° profiil</b>
0	0,3450	0,3467	0,3439	0,3561	0,3433
1	0,5033	0,6850	0,6578	0,6039	0,5733
2	0,6250	0,7739	0,7644	0,7322	0,7439
3	0,6356	0,7828	0,7661	0,7767	0,7439
4	0,6294	0,8050	0,8106	0,7833	0,7839
5	0,6811	0,8250	0,8389	0,7928	0,7961
	<b>3D Gini, 3D andmed</b>	<b>3D Gini, 2D andmed</b>	<b>3D Gini, 2D andmed, 90° profiil</b>	<b>2D Gini, 2D andmed</b>	<b>2D Gini, 2D andmed, 90° profiil</b>
0	0,2456	0,2489	0,2356	0,2633	0,2400
1	0,5111	0,5828	0,5300	0,5550	0,4950
2	0,7322	0,7950	0,7456	0,7750	0,7433
3	0,8133	0,8778	0,8383	0,8261	0,8694
4	0,8717	0,9050	0,8839	0,8750	0,8822
	<b>3D informatsiooni-kasv, 3D andmed</b>	<b>3D informatsiooni-kasv, 2D andmed</b>	<b>3D informatsiooni-kasv, 2D andmed, 90° profiil</b>	<b>2D informatsiooni-kasv, 2D andmed</b>	<b>2D informatsiooni-kasv, 2D andmed, 90° profiil</b>
0	0,3411	0,2278	0,2583	0,3328	0,3439
1	0,5639	0,6278	0,5639	0,6244	0,6111
2	0,7978	0,8339	0,8039	0,8400	0,8050
3	0,8533	0,8917	0,8550	0,8944	0,8856
4	0,8911	0,9156	0,9011	0,9139	0,9117
5	0,9050	0,9228	0,9061	0,9267	0,9200



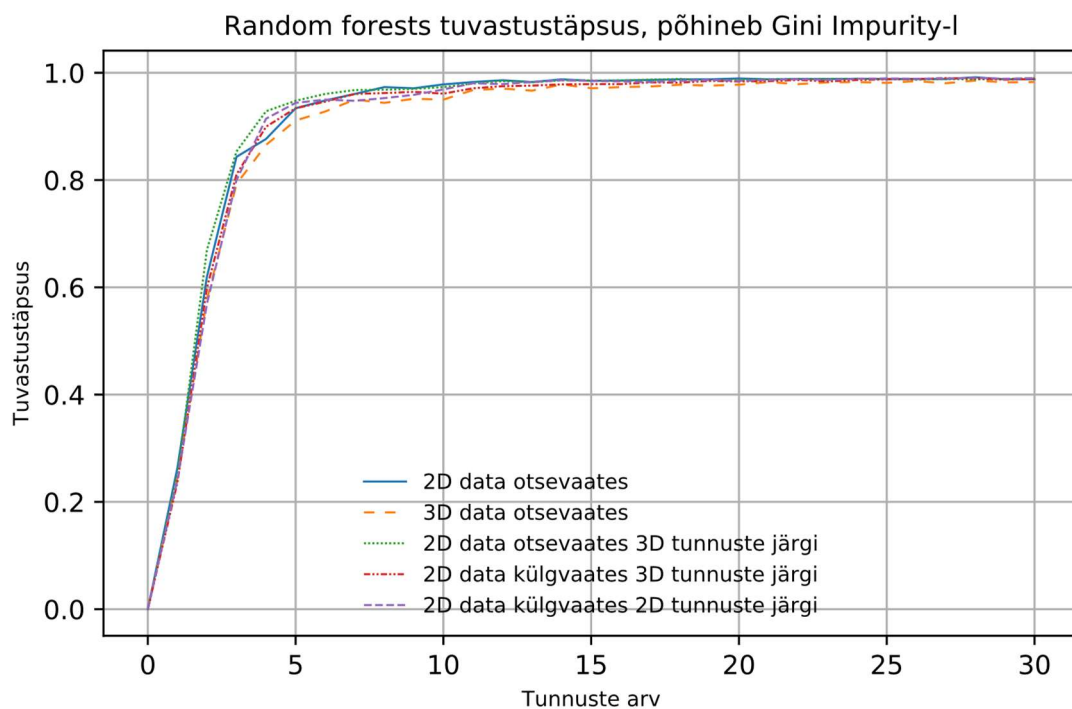
Tulemustest on näha, et nägude tuvastamistäpsus kasvab kõigi tunnuse määramise meetoditega juba kolme kuni viie tunnusega väga kiiresti, misjärel tuvastustäpsus kasvab edasi suhteliselt aeglaselt, ulatudes ~0,93-0,95ni ehk ligikaudu 93-95%-ni 30 tunnuse puhul informatsioonikasvu või *Gini impurity*-t kasutades. Veidi väiksem on tuvastustäpsus Fisher skoori alusel järjestatud tunnustega. On täheldatav, et kuigi tunnuste määramine toimus 3D andmestiku alusel, on tasapinnale taandatud samade tunnuste alusel klassifitseerimistäpsus oluliselt parem, eriti hästi paistab see silma Fisher skoori puhul.

## **5.8 Otsustusmetsa e. juhusliku metsa (ingl k. Random Forest) meetod**

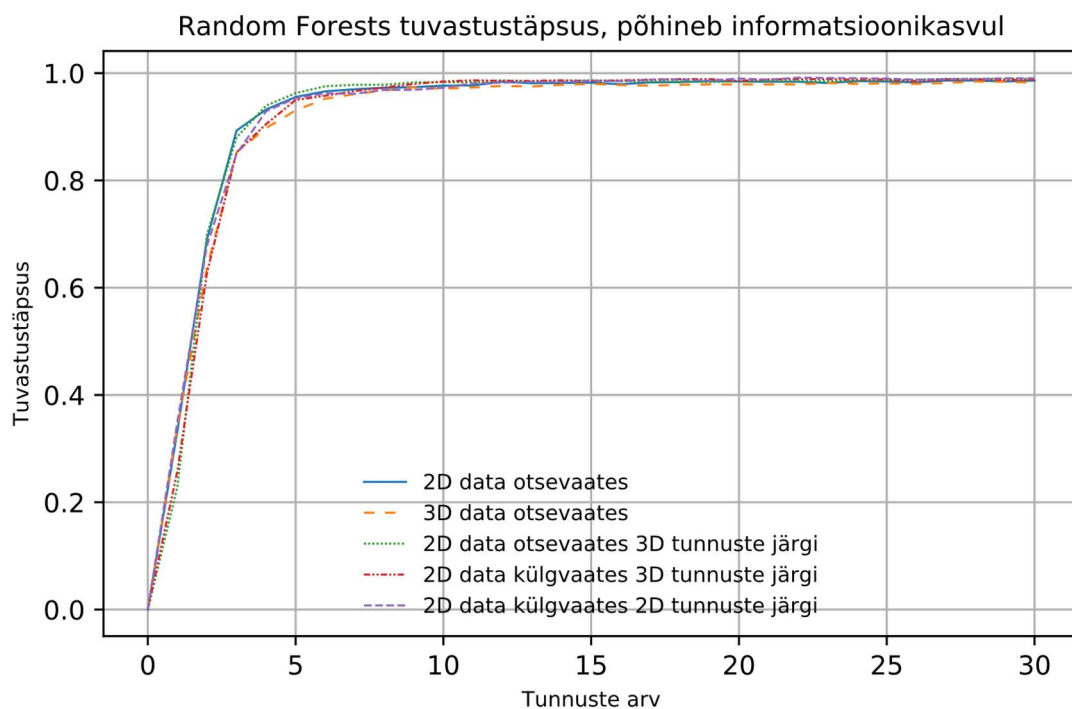
Juhusliku metsa algoritm on oma olemuselt otsustuspuu edasiarendus, mille puhul koostatakse palju otsustuspuud ja vaadatakse kõigi puude ennustusi. Kasutatakse juhuslikku valikut, mille eeliseks on parem toimetulek ebaühtlase sisuga treeningandmetega. Mudeli puhul on iga puu omaette sõltumatu mudel ja juhusliku metsa koondmudel ei sõltu nii palju treeningandmetest kui eraldiseisev otsustuspuu.

Käesolevas töös on juhusliku metsa puude arvuks võetud 100. Puude arvu suurendamine ei andnud täpsemat tulemust, küll aga kasvas oluliselt arvutusteks kulunud aeg. Testides arvutusi väiksema puude arvuga hakkas tulemuse täpsus vähenema, kui puude arv vähenes alla 10, siis hakkas tulemus lähenema üksiku otsustuspuu täpsusele. Samamoodi nagu eelmises e. otsustuspuu meetodis on meetodi sisese jagunemiskriteeriumina kasutatud Gini indeksit, kuid puude sügavus on piiratud 10-ga.

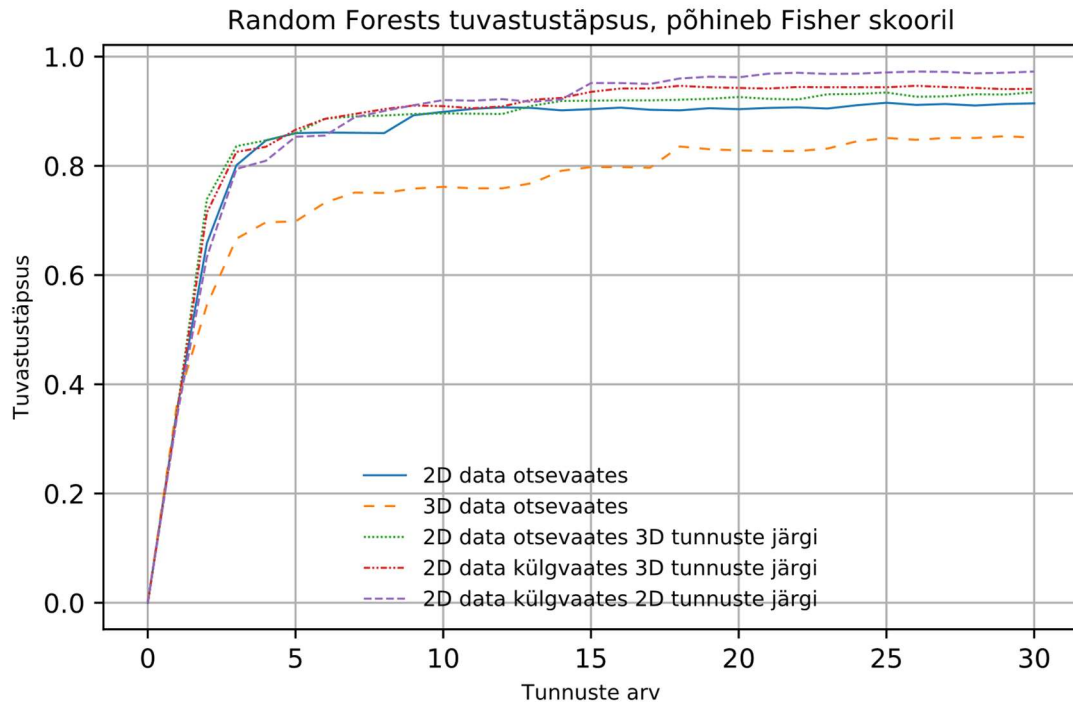
Joonistel 21-23 ning tabelis 6 on ära toodud klassifitseerimise õigsuse (täpsuse) tulemused. Tabeli 6 täielikum versioon (30 tunnuse järgi määramine) on ära toodud lisa 4.



Joonis 21. Juhusliku metsa (Random Forest) puhul saavutatud tuvastustäpsus, tunnuste valik põhineb *Gini Impurity-I*.



Joonis 22. Juhusliku metsa (Random Forest) puhul saavutatud tuvastustäpsus, tunnuste valik põhineb informatsioonikasvul.



Joonis 23. Juhusliku metsa (Random Forest) puhul saavutatud tuvastustäpsus, tunnuste valik põhineb Fisher skooril.

Tabel 7. Juhusliku metsa algoritmi kasutades saadud tuvastustäpsus (klassifitseerimisõigsus) esimese 6 tunnuse puhul.

	3D Fisher skoor, 3D andmed	3D Fisher skoor, 2D andmed	3D Fisher skoor, 2D andmed, 90° profiil	2D Fisher skoor, 2D andmed	2D Fisher skoor, 2D andmed, 90° profiil
0	0,3678	0,3539	0,3500	0,3567	0,3439
1	0,5450	0,7389	0,7144	0,6583	0,6328
2	0,6667	0,8361	0,8256	0,8011	0,7944
3	0,6967	0,8467	0,8350	0,8467	0,8094
4	0,6983	0,8594	0,8661	0,8600	0,8533
5	0,7328	0,8867	0,8861	0,8611	0,8556
	3D Gini,	3D Gini,	3D Gini,	2D Gini,	2D Gini,

	<b>3D andmed</b>	<b>2D andmed</b>	<b>2D andmed, 90° profiil</b>	<b>2D andmed</b>	<b>2D andmed, 90° profiil</b>
0	0,2461	0,2489	0,2361	0,2633	0,2406
1	0,5772	0,6700	0,5989	0,6200	0,5694
2	0,7928	0,8533	0,8106	0,8433	0,8000
3	0,8656	0,9283	0,8994	0,8767	0,9144
4	0,9111	0,9478	0,9339	0,9339	0,9439
5	0,9278	0,9606	0,9461	0,9483	0,9500
	<b>3D informatsiooni- kasv, 3D andmed</b>	<b>3D informatsiooni- kasv, 2D andmed</b>	<b>3D informatsiooni- kasv, 2D andmed, 90° profiil</b>	<b>2D informatsiooni- kasv, 2D andmed</b>	<b>2D informatsiooni- kasv, 2D andmed, 90° profiil</b>
0	0,3411	0,3539	0,2583	0,3328	0,3500
1	0,6361	0,7389	0,6272	0,6900	0,6783
2	0,8522	0,8361	0,8522	0,8928	0,8494
3	0,8978	0,8467	0,9050	0,9322	0,9289
4	0,9306	0,8594	0,9500	0,9556	0,9533
5	0,9522	0,8867	0,9578	0,9661	0,9622

		precision	recall	f1-score	support
	0	0.96	0.98	0.97	112
	1	0.85	0.38	0.52	29
	2	0.98	1.00	0.99	41
	3	0.97	1.00	0.98	56
	4	1.00	1.00	1.00	61
	5	0.91	0.86	0.89	73
	6	1.00	1.00	1.00	41
	7	0.89	0.98	0.93	50
	8	0.95	1.00	0.98	41
	9	0.91	0.84	0.87	37
	10	0.96	1.00	0.98	52
	11	1.00	0.89	0.94	35
	12	0.91	0.98	0.95	65
	13	0.93	0.95	0.94	39
	14	0.97	1.00	0.99	36
	15	1.00	1.00	1.00	25
	16	0.93	0.93	0.93	159
	17	0.98	1.00	0.99	49
	18	1.00	0.94	0.97	62
	19	1.00	0.93	0.96	27
	20	0.89	0.98	0.93	42
	21	0.85	0.83	0.84	81
	22	1.00	1.00	1.00	26
	23	0.95	0.91	0.93	23
	24	0.95	0.98	0.96	267
	25	0.98	0.98	0.98	271
micro	avg	0.95	0.95	0.95	1800
macro	avg	0.95	0.94	0.94	1800
weighted	avg	0.95	0.95	0.95	1800

Joonis 24. Ekraanipilt informatsioonikasvu meetodil valitud 6 parima tunnuse järgi klassifitseerimisel saavutatud tulemustega.

Rohkem tulemusi on leitavad: <https://sites.google.com/site/3dtunnusteklassifikatsioon>

Tabel 8. Juhusliku metsa algoritmi kasutades saadud eksimismaatriksi informatsioonikasvu meetodil leitud 6 parima tunnuse kasutamisel.

	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	All	
0	110	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	1	112
1	0	11	0	0	0	0	0	0	0	0	2	1	0	1	0	0	3	1	0	0	0	6	0	1	2	1	29	
2	0	0	41	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	41
3	0	0	0	56	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	56
4	0	0	0	0	61	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	61
5	1	0	0	0	0	63	0	0	1	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	5	2	73
6	0	0	0	0	0	0	41	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	41
7	0	1	0	0	0	0	0	49	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	50
8	0	0	0	0	0	0	0	0	41	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	41
9	1	0	0	0	0	0	0	0	0	31	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	4	0	37
10	0	0	0	0	0	0	0	0	0	0	52	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	52
11	0	0	0	0	0	0	0	0	0	0	0	31	0	0	0	0	3	0	0	0	1	0	0	0	0	0	0	35
12	0	0	0	0	0	0	0	0	0	0	0	0	64	0	0	0	0	0	0	0	0	1	0	0	0	0	0	65
13	0	0	0	0	0	0	0	0	0	0	0	0	0	37	1	0	0	0	0	0	1	0	0	0	0	0	0	39
14	0	0	0	0	0	0	0	0	0	0	0	0	0	0	36	0	0	0	0	0	0	0	0	0	0	0	0	36
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	25	0	0	0	0	0	0	0	0	0	0	0	25
16	2	0	0	2	0	3	0	1	0	0	0	0	0	0	0	0	148	0	0	0	1	1	0	0	1	0	159	
17	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	49	0	0	0	0	0	0	0	0	0	49
18	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	58	0	2	0	0	0	0	0	0	62
19	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	25	0	0	0	0	0	0	0	27
20	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	41	0	0	0	0	0	0	42
21	0	0	0	0	0	3	0	1	1	1	0	0	5	0	0	0	1	0	0	0	0	67	0	0	2	0	81	
22	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	26	0	0	0	26	
23	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	21	0	1	23	
24	0	1	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	3	0	0	262	0	267	
25	1	0	1	0	0	0	0	0	0	0	1	0	0	0	0	0	2	0	0	0	0	0	0	0	1	265	271	
All	115	13	42	58	61	69	41	55	43	34	54	31	70	40	37	25	159	50	58	25	46	79	26	22	277	270	1800	

Tulemustest on näha, et nägude tuvastamistäpsuse graafik sarnaneb otsustuspuu tulemustele, kuid on märgatavalt parem, mis on seletatav sellega, et juhuslik mets on otsustuspuu edasiarendus, koondades endas paljude otsustuspuude andmeid. 30 tunnuse puhul kasvas tuvastustäpsus ligikaudu 99%-ni, mis andis kõigist kasutatud algoritmidest täpseima tulemuse.

Tabelis 8 on esitatud eksimismaatriks (ingl k. Confusion Matrix) 26 katseisiku kohta, kusjuures tuvastustäpsus 95.22% on saavutatud kasutades informatsioonikasvu meetodil leitud 6 tunnust 3D otsevaates andmete kohta. Joonisel 24 on toodud sama arvutuse kohta mõningad peamised statistilised parameetrid.

Peaegu samale tuvastustäpsusele küündisid ka K-lähima naabri algoritmi tulemused.

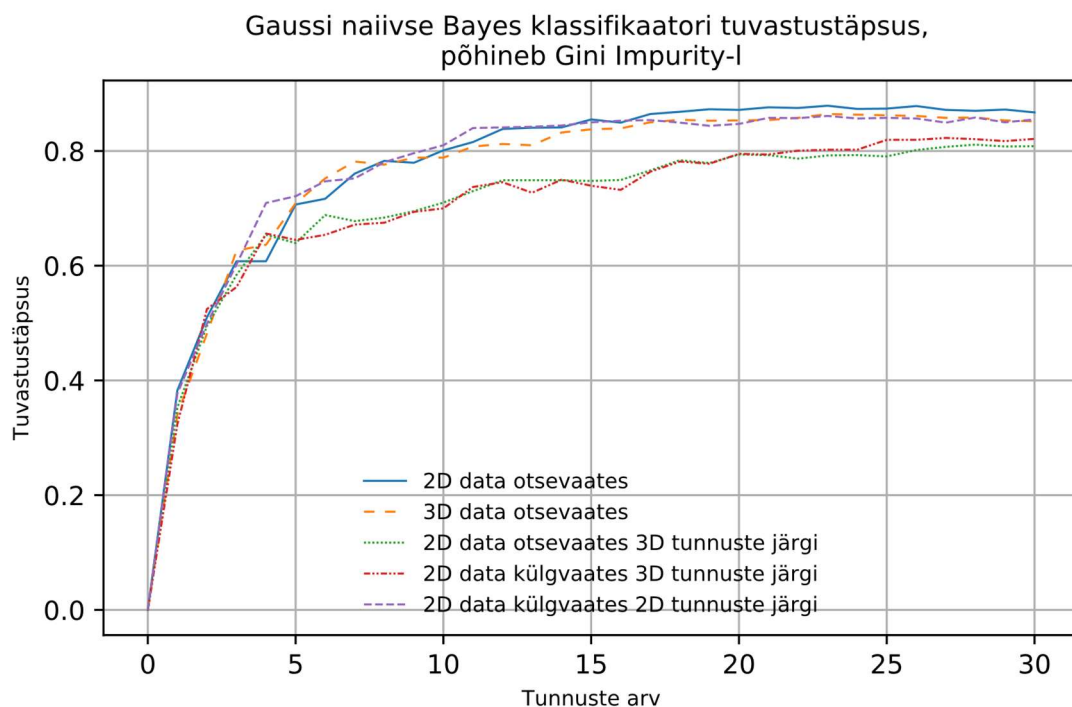
Ka selle algoritmi juures oli parim tuvastustäpsus 90 kraadise 2D profiilvaate andmete puhul.

## 5.9 Naiivne Bayes


Naiivne Bayes mudel on tõenäosuslik mudel, mille eelduseks on see, et põhjuse tagajärjed on kõik üksteisest sõltumatud ning tagajärgede alusel on võimalik leida põhjuse tõenäosus. Selle mudeliga ei saa me teada täpset tõenäosust, aga saame teada milline tõenäosus on kõige suurem. Mudel töötab suhteliselt hästi ka väheste treeningandmete puhul ja paremini töötab ta siis, kui ennustatavaid klasse ei ole eriti palju.

Käeolevas töös on kasutatud Gaussi ehk normaaljaotusega naiivset Bayes algoritmi, mille puhul klasside varasemaid tõenäosuseid määratud ei ole.


Joonistel 25-27 ning tabelis 7 on ära toodud klassifitseerimise õigsuse (täpsuse) tulemused. Tabeli 7 täielikum versioon (30 tunnuse järgi määramine) on ära toodud lisas 5.



Joonis 25. Gaussi naiivse Bayes meetodil puhul saavutatud tuvastustäpsus, tunnuste valik põhineb *Gini Impurity*-l.



Joonis 26. Gaussi naiivse Bayes meetodil puhul saavutatud tuvastustäpsus, tunnuste valik põhineb informatsioonikasvul.



Joonis 27. Gaussi naiivse Bayes meetodil puhul saavutatud tuvastustäpsus, tunnuste valik põhineb Fisher skooril.



Tabel 9. Gaussi naiivse Bayes algoritmi kasutades saadud tuvastustäpsus (klassifitseerimisõigsus) esimese 6 tunnuse puhul.

	<b>3D Fisher skoor, 3D andmed</b>	<b>3D Fisher skoor, 2D andmed</b>	<b>3D Fisher skoor, 2D andmed, 90° profiil</b>	<b>2D Fisher skoor, 2D andmed</b>	<b>2D Fisher skoor, 2D andmed, 90° profiil</b>
0	0,4861	0,4406	0,4661	0,4839	0,4717
1	0,4800	0,4972	0,6261	0,4972	0,5428
2	0,5261	0,5011	0,6417	0,5233	0,5711
3	0,5044	0,5139	0,6439	0,5317	0,5767
4	0,4928	0,5572	0,6494	0,5422	0,6239
5	0,5017	0,5783	0,6517	0,5367	0,6283
	<b>3D Gini, 3D andmed</b>	<b>3D Gini, 2D andmed</b>	<b>3D Gini, 2D andmed, 90° profiil</b>	<b>2D Gini, 2D andmed</b>	<b>2D Gini, 2D andmed, 90° profiil</b>
0	0,3406	0,3528	0,3239	0,3828	0,3772
1	0,4817	0,4950	0,5244	0,5100	0,4989
2	0,6261	0,5839	0,5628	0,6078	0,6022
3	0,6367	0,6539	0,6561	0,6078	0,7094
4	0,7089	0,6394	0,6450	0,7067	0,7211
5	0,7522	0,6883	0,6539	0,7167	0,7472
	<b>3D informatsiooni- kasv, 3D andmed</b>	<b>3D informatsiooni- kasv, 2D andmed</b>	<b>3D informatsiooni- kasv, 2D andmed, 90° profiil</b>	<b>2D informatsiooni- kasv, 2D andmed</b>	<b>2D informatsiooni- kasv, 2D andmed, 90° profiil</b>
0	0,4844	0,2606	0,3439	0,4511	0,4661
1	0,6067	0,5633	0,4911	0,6161	0,6039
2	0,6589	0,5622	0,5700	0,7067	0,6544
3	0,7228	0,6633	0,5811	0,7661	0,7100
4	0,7594	0,7278	0,6567	0,7856	0,7472
5	0,7650	0,7311	0,7028	0,8061	0,8006

Tulemustest on näha, et nägude tuvastamistäpsus kasvab kõigi tunnuse määramise meetoditega juba kahe kuni nelja tunnusega väga kiiresti, misjärel edasine tuvastustäpsus


kasvab aeglaselt, ulatudes maksimaalselt ~0,86ni ehk ligikaudu 86%-ni 30 tunnuse puhul informatsioonikasvu või *Gini Impurity* meetodil määratud tunnuseid kasutades. Oluliselt väiksem on tuvastustäpsus Fisher skoori järgi määratud tunnustega. Ka selle meetodi puhul on selgelt täheldatav, et tasapinnale taandatud tunnuste alusel klassifitseerimistäpsus parem. Kuigi tuvastustäpsus on võrreldes SVM algoritmiga tuntuvalt parem, ei küündi see ülejäänud algoritmide tasemele.

## 5.10 Mitmekihilised närvivõrgud (ingl. k. Multilayer perceptron)


Mitmekihiliste närvivõrkude puhul koostatakse mittelineaarne mudel, mille puhul on sisendi ja väljundi vahel täiendav kiht otsustuspunkte. Põhimõtteliselt on tegu otsesuunatud närvivõrguga, mille igas kihis paikneva neuroni väljundiga on seotud järgmise kihi iga neuroni üks sisend.

Käesolevas töös on määratud neuronite arvaks 50 ja maksimaalseks korduste arvaks 2000. Kaalude optimeerimiseks on kasutatud stohhastilist (juhuslikku) gradientpõhist optimeerijat ('adam'), mis on mõeldud töötama suhteliselt suurte andmemassiividega, kus treeningandmestikus on tuhandeid näidiseid.


Joonistel 28-30 ning tabelis 8 on ära toodud klassifitseerimise õigsuse (täpsuse) tulemused. Tabeli 8 täielikum versioon (30 tunnuse järgi määramine) on ära toodud lisas 6.



Joonis 28. Mitmekihiliste närvivõrkude meetodi puhul saavutatud tuvastustäpsus, tunnuste valik põhineb *Gini Impurity*-l.



Joonis 29. Mitmekihiliste närvivõrkude meetodi puhul saavutatud tuvastustäpsus, tunnuste valik põhineb informatsioonikasvul.



Joonis 30. Mitmekihiliste närvivõrkude meetodi puhul saavutatud tuvastustäpsus, tunnuste valik põhineb Fisher skooril.

Tabel 10. Mitmekihiliste närvivõrkude algoritmi kasutades saadud tuvastustäpsus (klassifitseerimisõigsus) esimese 6 tunnuse puhul.

	<b>3D Fisher skoor, 3D andmed</b>	<b>3D Fisher skoor, 2D andmed</b>	<b>3D Fisher skoor, 2D andmed, 90° profiil</b>	<b>2D Fisher skoor, 2D andmed</b>	<b>2D Fisher skoor, 2D andmed, 90° profiil</b>
0	0,1506	0,1506	0,1506	0,4239	0,4550
1	0,1694	0,4206	0,1483	0,4311	0,4239
2	0,4389	0,4317	0,1506	0,5039	0,4256
3	0,4706	0,4856	0,3250	0,5228	0,4400
4	0,4772	0,4878	0,3711	0,5228	0,5578
5	0,4761	0,4861	0,3128	0,6083	0,5894
	<b>3D Gini, 3D andmed</b>	<b>3D Gini, 2D andmed</b>	<b>3D Gini, 2D andmed, 90° profiil</b>	<b>2D Gini, 2D andmed</b>	<b>2D Gini, 2D andmed, 90° profiil</b>
0	0,1483	0,1544	0,1483	0,3833	0,1483
1	0,1506	0,1656	0,1506	0,4756	0,3528
2	0,3350	0,3144	0,2683	0,4739	0,4094
3	0,4683	0,5172	0,4633	0,5411	0,6222
4	0,5600	0,6283	0,6228	0,6217	0,5694
5	0,6706	0,7400	0,7544	0,6928	0,6428
	<b>3D Fisher skoor, 3D andmed</b>	<b>3D Fisher skoor, 2D andmed</b>	<b>3D Fisher skoor, 2D andmed, 90° profiil</b>	<b>2D Fisher skoor, 2D andmed</b>	<b>2D Fisher skoor, 2D andmed, 90° profiil</b>
0	0,1506	0,1506	0,1506	0,4239	0,4550
1	0,1694	0,4206	0,1483	0,4311	0,4239
2	0,4389	0,4317	0,1506	0,5039	0,4256
3	0,4706	0,4856	0,3250	0,5228	0,4400
4	0,4772	0,4878	0,3711	0,5228	0,5578
5	0,4761	0,4861	0,3128	0,6083	0,5894

Tulemustest on näha, et nägude tuvastamistäpsus kasvab kõigi tunnuse määramise meetodite puhul suurte kõikumistega, ulatudes maksimaalselt 93%-ni 30 tunnuse puhul. Kuna mitmekihiliste närvivõrkude puhul on väga oluline valida sisendparameetrid õigesti, siis on kindlasti oluline hoolikalt analüüsida andmete koosseisu, mille alusel saab häälestada algoritmi kasutamise parameetreid. Tõenäoliselt on algoritmi parameetrite puuduliku häälestamise tõttu tulemused kõikumavad ja ei saavutanud oodatud täpsust.

## 6 Järeldused tehtud tööst

Käesolev töö põhines Microsoft Kinect kaamera poolt skaneeritava kujutise edasisel töötlusel. Praktilises elus on Kinecti kaamerat statsionaarses asendis piisavalt mugav käsitleda ja skanneerimine toimub suhteliselt kiiresti. See võimaldab kaamerat kasutada väga erinevates asukohtades ja tuvastatavatele inimestele mugavalt või isegi vähemärgatavalt.

Töös kasutati 98 kauguspõhist ja 183 nurgapõhist inimese näol tuvastatud kindelpunktidest tuletatud klassifitseerimise tunnust. Püüdes välja selgitada, millised on parimad tunnused klassifitseerimiseks, andsid erinevad algoritmid erinevaid tulemusi. Nii ei pruukinud ühe algoritmi poolt väga heade parameetritega tunnuseks määratu teise algoritmi järgi olla sugugi parimate hulgas. Seega ei saa teha väga kindlaid järeldusi selle kohta, millised näopunktid ja neist moodustatud tunnused on olulisemad kui teised. Samuti oli oluliseimateks tunnusteks määratute hulgas nii kauguspõhiseid kui ka nurgapõhiseid tunnuseid. Informatsioonikasvu meetoditel leitud parimate tunnuste hulgas oli proportsionaalsest osakaalust veidi suurem nurgapõhiste tunnuste osatähtsus, kuid vahe ei olnud eriti oluline. Profiilvaadete puhul oli mõnevõrra suurem kauguspõhiste tunnuste osakaal.

Mõneti üllatavalt selgus tööd tehes, et 3D punktipilvest kahemõõtmeliseks taandatud andmete puhul oli tasapinnaliselt paiknevate andmete klassifitseerimistäpsus mõningatel juhtudel parem. Võrreldes kahe- ja kolmemõõtmelisi tuvastustäpsuseid ning uurides erinevatel meetoditel määratud parimaid tunnuseid klassifitseerimiseks, võis järeldada, et kolmanda e. sügavusmõõtme lisamine andmetele võis põhjustada kohatist üleõppimist,

kuna nende andmete varieeruvus on osade tunnuste puhul suurem. Üldiselt andsid klassifitseerimisel pisut parema tuvastustäpsuse külgsuunas 2D tasapinnale taandatud tunnused.

Võrreldes erinevaid klassifitseerimiseks kasutatud algoritme, siis andsid käesolevas töös kõige parema tuvastustäpsuse juhusliku metsa algoritmi järgi klassifitseerimised, ulatudes informatsioonikasvu ja *Gini Impurity* meetoditel määratud 30 parima tunnuse juures 99%-ni, mida võib pidada väga heaks tuvastustäpsuseks. Edasine tunnuste arvu suurendamine ei andnud paremat tuvastustäpsust.

Peaaegu sama hea tuvastustäpsuse saavutas K-lähima naabri algoritm, mille täpsus ulatus samuti kohati üle 98%. Oma kiiruselt ületas K-lähima naabri algoritm juhusliku metsa oma tunduvalt.

Kõige madalama tuvastustäpsuse saavutas SVM algoritm. Samuti andis mitmekihiliste närvivõrkude meetod ebaühtlaseid tulemusi, mis tulenes tõenäoliselt kasutatud parameetrite ebapiisavast eelvalikust.

Informatsioonikasvu uurimise puhul on tegu logaritmilise funktsiooniga ning sellest tulenevalt on selle arvutustehte hind kõrgem. Informatsioonikasvu entroopia arvutamiseks kulus aega keskmiselt kaks korda rohkem, kui *Gini Impurity* arvutamisel ning ligikaudu 1,7 korda rohkem, kui Fisher skoori arvutamisel. Praktilises elus ei ole ajavahe oluliselt märgatav, töö käigus mõõdeti seda kõrvaltegevusena, ja mitteolulisena ei ole kajastatud.

Visuaalselt vaadeldes tunduvad inimeste näod üsna sümmeetrilised, kuid ühel ja teisel pool näo sümmeetriatasapinda olevad tunnused ei ole päris võrdsed, samuti ei pruugi nad asetseada ka väga lähedastikku olulisemate tunnuste pingereas.

Uurides algoritmide poolt klassifitseerimise jaoks parimateks tunnustatud tunnuseid ja nende moodustamiseks kasutatud algpunkte selgus, et nende tunnuste hulgas oli väga vähe neid, mille puhul oli tegu suunurkade ja ülahuule punktide moodustatutega. See tuleneb arvatavasti lähteandmetes kasutatud inimeste erinevatest näoilmetest. Kui me vaatleme inimesi visuaalselt, siis jälgides näoilmeid, võib täheldada, et just suunurkade asend on esmane, mis erinevate emotsioonide puhul muutub. Kuna suunurkade ja

ülahuule punktide asukohad on varieeruvad, siis pigem tekitab nende punktide kaasamine andmetesse müra ja on otstarbekas välja jätta.

Antud töö alusel saab järeldada, et MS Kinecti kaameraga on võimalik saavutada väga hea tuvastustäpsus sõltumata inimeste erinevatest näoilmetest ja asenditest.

## 7 Kokkuvõte

Käesoleva magistritöö eesmärgiks oli hinnata kolmemõõtmelise näotuvastuse võimalusi erinevate algoritmide abil ja hinnata nende algoritmide sobivust 3D punktidest koosneva andmestiku puhul, hinnata algoritmide tuvastustäpsust ning seda, millised tunnused on näotuvastamisel oluliseimad. Võrreldi ka kolmemõõtmelisest ruumist tasapinnaliseks taandatud punktidest moodustatud tunnuste eristusvõimet algsetega ning algoritmide tuvastustäpsust samadel tingimustel.

Kuna antud töös osalenud katseisikutel paluti esile manada erinevaid näoilmeid ja -asendeid, et saada reaalelule lähedasemaid andmeid, siis põhjustas see tõenäoliselt suuremaid klassisiseseid variatsioone kui neutraalse näoilmega olemine. See aga omakorda raskendas tunnuste võrdlemist ja klassifitseerimist. Samuti võis klassifitseerimist raskendada Kinecti punktide määramise ebatäpsus sõltuvalt erinevatest valgustustingimustest.

Töö tulemusena selgus, et parim tulemus oli võimalik saavutada juhusliku metsa algoritmiga, mille puhul ulatus tuvastustäpsus sõltuvalt valitud tunnustest ca 99%. Head tulemused oli võimalik saavutada ka K-lähima naabri meetodiga. Saavutatud tuvastustäpsus on üsna kõrge ja võrreldav kirjanduses ilmunud analoogsete uurimustega.

Tunnuste võrdlemiseks kasutati Fisher skoori, *Gini Impurity*-t ja informatsioonikasvu, mille puhul selgus, et ligikaudu võrdseid tulemusi andsid *Gini Impurity* ja informatsioonikasvu kasutamine. Mõneti tagasihoidlikumaks jäid tulemused Fisher skoori kasutamisel.

Antud töö tulemusena selgus, et Microsoft Kinect kaameraga on võimalik saavutada väga häid tuvastustäpsuse tulemusi ning töö tulemusi on ka reaalses elus võimalik rakendada, kui selleks luua uuritud meetoditel ja juba olemasolevatel komponentidel põhinev programm.



## 8 Kasutatud kirjandus

- [1] S. Soltanpour and Q. M. J. Wu, „Multiscale depth local derivative pattern for sparse representation based 3D face recognition,“ %1 *2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, Banff, 2017.
- [2] F. Dornaika, *Advances in Face Image Analysis:: Theory and applications*, Bentham Science Publisher, 2016.
- [3] W. Gutfeter and A. Pacut, „Face 3D biometrics goes mobile: Searching for applications of portable depth sensor in face recognition,“ %1 *IEEE 2nd International Conference on Cybernetics (CYBCONF)*, Gdynia, 2015.
- [4] Li, YueLong, Li Meng, JuFu Feng and JiGang Wu, „Downsampling sparse representation and discriminant information aided occluded face recognition,“ *Science China Information Sciences*, kd. 57, nr 3, pp. 1-8, 2014.
- [5] Min,R., N.Kose and J.L.Dugelay, „KinectFaceDB: A kinect database for face recognition,“ *IEEE Transactions on Systems, Man, and Cybernetics*, kd. 44 (11), pp. 1534-1548, 2014.
- [6] A. Savran, N. Alyüz, H. Dibeklioglu, O. Çeliktutan, B. Gökberk, B. Sankur, and L. Akarun, „Bosphorus database for 3d face analysis,“ *Biometrics and Identity Management, ser. Lecture Notes in Computer Science*, B. Schouten, N. Juul, A. Drygajlo, and M. Tistarelli, kd. 5372, pp. 47-56, 2008.
- [7] Min, R., A.Hadid and J-L. Dugelay, „Efficient detection of occlusion prior to robust face recognitio,“ *The Scientific World Journal*, kd. 10, 2014.
- [8] J.C.Monteiro, T.Freitas, J.S.Cardoso, „Multimodal Hierarchical Face Recognition using Information from 2.5D Images,“ *U.Porto Journal of Engineering*, kd. 2:2, pp. 39-54, 2016.

- [9] W.Zhao, R.Chellappa, P.J.Phillips and A. Rosenfeld, „Face recognition: A literature survey,“ *ACM computing surveys (CSUR)*, kd. 35, nr 4, p. 399–458, 2003.
- [10] T.Russ, C.Boehnen and T.Peters, „3D face recognition using 3D alignment for PCA,“ *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, kd. 2, p. 1391–1398, 2006.
- [11] H.Mohammadzade and D.Hatzinakos, „Iterative closest normal point for 3D face recognition,“ *IEEE transactions on pattern analysis and machine intelligence*, vol. 35, no. 2, p. 381–397, 2013.
- [12] H.Li, D.Huang, J.-M.Morvan, Y.Wang, and L.Chen, „Towards 3D face recognition in the real: A registration-free approach using finegrained matching of 3D keypoint descriptors,“ *International Journal of Computer Vision*, kd. 112, nr 2, p. 128–142, 2015.
- [13] Edited by J. B. Harley and David Woodward, *The History of Cartography, Volume 1, Cartography in Prehistoric, Ancient, and Medieval Europe and the Mediterranean*, University of Chicago Press, 1987.
- [14] C. Queirolo, L. Silva, O. Bellon, and M. Pamplona Segundo, „3d face recognition using simulated annealing and the surface interpenetration measure,“ *Pattern Analysis and Machine Intelligence, IEEE Transactions*, kd. 32, nr 2, p. 206–219, Feb 2010.
- [15] C. Samir, A. Srivastava, and M. Daoudi, „3d face recognition using shapes of facial curves,“ %1 in *Acoustics, Speech and Signal Processing, 2006. ICASSP 2006 Proceedings. 2006 IEEE International Conference*, 2006.
- [16] F. ter Haar and R. Veltkamp, „3d face recognition using facial contour curves,“ %1 *Shape Modeling and Applications, 2008. SMI 2008. IEEE International Conference*, 2008.
- [17] L. Spreeuwens, „Fast and accurate 3d face recognition,“ *International Journal of Computer Vision*, kd. 93, nr 3, pp. 389-414, 2011.

- [18] T. Jia, Y. Zhang, R. Liu and H. Wang, „Face authentication method based on Kinect device,“ %1 *2016 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER)*, Chengdu, 2016.
- [19] Zhuoran Wu, Zhenjie Hou and Jian Zhang, „Research on the 3D face recognition based on multi-class classifier with depth and point cloud data,“ %1 *2016 IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC)*, Xi'an, 2016.
- [20] Silverstein, Evan; Snyder, Michael., „Implementation of Facial Recognition with Microsoft Kinect v2 Sensor for Patient Verification,“ *Medical physics*, kd. 44, 03 2017.
- [21] H.Drira, B.Ben Amor, A.Srivastava, M.Daoudi and R.Slama, „3D face recognition under expressions, occlusions and pose variations,“ *IEEE Trans. Pattern Anal. Mach. Intell*, kd. 3, nr 9, pp. 2270-2283, 2013.
- [22] P. K. M. K. G. S. Václav Snášel, Toim., *Soft Computing in Industrial Applications: Proceedings of the 17th Online World Conference on Soft Computing in Industrial Applications*, Springer, 2014.
- [23] Terissi, Lucas & Cerda, Mauricio & Gómez, Juan & Hitschfeld, Nancy & Girau, Bernard, „A comprehensive system for facial animation of generic 3D head models driven by speech,“ *EURASIP Journal on Audio, Speech, and Music Processing*, kd. 5, 2013.
- [24] Quanquan Gu, Zhenhui Li, Jiawei Han, *Generalized Fisher Score for Feature Selection*, 2012.
- [25] C. C. Aggarwal, *Data Mining, The Textbook*, New York: Springer, IBM T.J. Watson Research Center, 2015.
- [26] Jinjin Zhang ; Di Huang ; Yunhong Wang ; Jia Sun, „Lock3DFace: A large-scale database of low-cost Kinect 3D faces,“ %1 *Biometrics (ICB), 2016 International Conference*, 2016.

- [27] Yaser Saleh, Eran Edirisinghe, „3D face reconstruction and recognition using the overfeat network,“ %1 *Information and Communication Systems (ICICS), 2017 8th International Conference*, 4-6 April 2017.
- [28] G. Gordon, „Face recognition based on depth maps and surface curvature,“ %1 *In Geometric Methods in Computer Vision - Proceedings of the Society of Photo-Optical Instrumentation Engineers (SPIE)*, 1991.
- [29] Tanaka, H.T., M.Ikeda and H.Chiaki, „Curvature-based face surface recognition using spherical correlation. Principal directions for curved object recognition,“ %1 *Third IEEE International Conference on Automatic Face and Gesture Recognition*, 1998.
- [30] Chin-Seng, Chua, Han Feng and Ho Yeong-Khing, „3D human face recognition using point signature,“ %1 *Fourth IEEE International Conference on Automatic Face and Gesture Recognition*, 2000.
- [31] Moreno, Ana Belén, Angel Sánchez, José Fco. Vélez and Fco. Javier Díaz, „Face recognition using 3d surface-extracted descriptors,“ %1 *Irish Machine Vision and Image Processing Conference*, University of Ulster - Northern Ireland, 3-5 September 2003.
- [32] Min,R., J.Choi, G.Medioni and J.L.Dugelay, „Real-time 3D face identification from a depth camera,“ %1 *21st International Conference on Pattern Recognition (ICPR)*, 2012.
- [33] Naveen,S. and R.S.Moni, „A robust novel method for face recognition from 2D depth images using DWT and DCT fusion,“ %1 *Procedia Computer Science: Proceedings of the International Conference on Information and Communication Technologies*, Kochi, India, 2015.
- [34] Tang, Y., X. Sun, D. Huang, J. M. Morvan, Y. Wang and L. Chen., „3D face recognition with asymptotic cones based principal curvatures,“ %1 *2015 International Conference on Biometrics (ICB)*, 2015.

- [35] Neto, João Baptista Cardia and Aparecido Nilceu Marana, „3DLBP and HAOG fusion for face recognition utilizing Kinect as a 3D scanner,“ %1 *30th Annual ACM Symposium on Applied Computing*, 2015.
- [36] Bondi, E., P. Pala, S. Berretti and A. Del Bimbo, „Reconstructing high-resolution face models from Kinect depth sequences acquired in uncooperative contexts,“ %1 *11th IEEE International Conference and Workshops on Automatic Face and Gesture Recognition (FG)*, 2015.
- [37] Chang, Kyong I., Kevin W. Bowyer and Patrick J. Flynn, „Face recognition using 2D and 3D facial data,“ %1 *Paper presented at ACM Workshop on Multimodal User Authentication*, 2003.
- [38] Tsalakanidou, F., D. Tzovaras and M. G. Strintzis, „Use of depth and colour eigenfaces for face recognition,“ *Pattern Recognition Letters*, kd. 24, pp. 1427-1435, 2003.
- [39] Mian, A., M. Bennamoun and R. Owens, „An efficient multimodal 2D-3D hybrid approach to automatic face recognition,“ *IEEE Transactions on Pattern Analysis and Machine Intelligence*, kd. 29 (11), pp. 1927-1943, 2007.
- [40] Mian, Ajmal S., Mohammed Bennamoun and Robyn Owens, „Keypoint detection and local feature matching for textured 3D face recognition,“ *International Journal of Computer Vision*, kd. 79, nr 1, pp. 1-12, 2008.
- [41] Li, B.Y.L., A.S. Mian, W. Liu and A. Krishna, „Using Kinect for face recognition under varying poses, expressions, illumination and disguise,“ *2013 IEEE Workshop on Applications of Computer Vision (WACV)*, pp. 186-192, 2013.
- [42] Hiremath, P.S. and Manjunatha Hiremath, „3D face recognition based on depth and intensity gabor features using symbolic PCA and AdaBoost,“ *International Journal of Signal Processing, Image Processing and Pattern Recognition*, kd. 6 (5), pp. 1-12, 2013.

- [43] Ajmera, Rahul, Aditya Nigam and Phalguni Gupta, „3D face recognition using kinect,“ *Proceedings of the 2014 Indian Conference on Computer Vision Graphics and Image Processing*, p. Article No. 76, 2014.
- [44] Mráček, Štěpán, Martin Dražanský, Radim Dvořák, Ivo Provazník and Jan Vana, „3D face recognition on low-cost depth sensors,“ *International Conference of the Biometrics Special Interest Group (BIOSIG)*, pp. 1-4, 2014.
- [45] Elaiwat, S., M. Bennamoun, F. Boussaid and A. El-Sallam, „A curvelet-based approach for textured 3D face recognition,“ *Pattern Recognition*, kd. 48 (4), pp. 1235-1246, 2015.
- [46] Naveen, S., S.S. Nair and R. S. Moni, „3D face recognition using optimised directional faces and fourier transform,“ *2015 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, pp. 1856-1861, 2015.
- [47] Krishnan, Poornima and S.Naveen, „RGB-D face recognition system verification using kinect and FRAV3D databases,“ *Procedia Computer Science: Proceedings of the International Conference on Information and Communication Technologies*, kd. 46, pp. 1653-1660, 3-5 December 2014.
- [48] Dai, X., S.Yin, P.Ouyang, L.Liu and S.Wei, „A multi-modal 2D + 3D face recognition method with a novel local feature descriptor,“ *IEEE Winter Conference on Applications of Computer Vision*, pp. 657-662, 2015.
- [49] Hayat, Munawar, Mohammed Bennamoun and Amar A. El-Sallam, „An RGB–D based image set classification for robust face recognition from Kinect data,“ *Neurocomputing*, kd. 171, pp. 889-900, 2016.
- [50] W. Zhao, R. Chellappa, A. Rosenfeld, P.J. Phillips, „Face Recognition: A Literature Survey,“ *ACM Computing Surveys*, pp. 399-458, 2003.

[51] Yaser Saleh, Eran Edirisinghe, „3D face reconstruction and recognition using the overfeat network,“ *Information and Communication Systems (ICICS), 2017 8th International Conference*, 4-6 April 2017.

**Lisa 1 – KNN algoritmi kasutades saadud tuvastustäpsus  
(klassifitseerimisõigsus) 30 tunnuse puhul**

	3D Fisher skoor, 3D andmed	3D Fisher skoor, 2D andmed	3D Fisher skoor, 2D andmed, 90° profiil	2D Fisher skoor, 2D andmed	2D Fisher skoor, 2D andmed, 90° profiil
0	0,3933	0,3606	0,3811	0,3733	0,3644
1	0,3861	0,3806	0,2733	0,3767	0,3789
2	0,3917	0,3828	0,2917	0,6472	0,3944
3	0,5950	0,6378	0,6439	0,7439	0,3956
4	0,5950	0,6378	0,6439	0,7939	0,6728
5	0,5950	0,6378	0,6439	0,7939	0,6728
6	0,6728	0,8050	0,7456	0,7939	0,8311
7	0,6728	0,8050	0,7456	0,7939	0,8311
8	0,7200	0,8461	0,8289	0,8767	0,8311
9	0,7200	0,8461	0,8289	0,8767	0,8311
10	0,7361	0,8656	0,8800	0,8767	0,8311
11	0,7344	0,8711	0,8889	0,8767	0,8883
12	0,7511	0,9039	0,9078	0,8767	0,9028
13	0,7717	0,9067	0,9056	0,8828	0,9028
14	0,7828	0,9144	0,9178	0,8794	0,9028
15	0,7828	0,9144	0,9178	0,8878	0,9017
16	0,7828	0,9144	0,9178	0,8872	0,9017
17	0,7844	0,9156	0,9200	0,8872	0,9406
18	0,7844	0,9156	0,9200	0,8811	0,9406
19	0,7844	0,9156	0,9200	0,8811	0,9406
20	0,7844	0,9156	0,9200	0,8811	0,9472
21	0,7856	0,9139	0,9256	0,8911	0,9472
22	0,7856	0,9139	0,9256	0,9056	0,9472
23	0,7856	0,9139	0,9256	0,9050	0,9472
24	0,7856	0,9139	0,9256	0,9144	0,9572
25	0,7850	0,9128	0,9244	0,9161	0,9589
26	0,7850	0,9128	0,9244	0,9156	0,9533
27	0,7872	0,9156	0,9267	0,9150	0,9533
28	0,7889	0,9133	0,9189	0,9128	0,9533
29	0,7850	0,9167	0,9067	0,9128	0,9528



	<b>3D Gini, 3D andmed</b>	<b>3D Gini, 2D andmed</b>	<b>3D Gini, 2D andmed, 90° profiil</b>	<b>2D Gini, 2D andmed</b>	<b>2D Entroopia, 2D andmed, 90° profiil</b>
0	0,2511	0,2578	0,2572	0,2678	0,2533
1	0,2522	0,2600	0,3217	0,6039	0,5456
2	0,5100	0,5661	0,5417	0,6039	0,7833
3	0,7228	0,8411	0,7794	0,7300	0,9078
4	0,8567	0,9017	0,8883	0,8994	0,9078
5	0,8978	0,9333	0,9350	0,8994	0,9228
6	0,8978	0,9333	0,9350	0,9428	0,9411
7	0,8978	0,9333	0,9350	0,9561	0,9556
8	0,8978	0,9333	0,9350	0,9561	0,9556
9	0,8983	0,9533	0,9461	0,9700	0,9583
10	0,8983	0,9533	0,9461	0,9700	0,9733
11	0,9444	0,9711	0,9622	0,9739	0,9733
12	0,9444	0,9733	0,9672	0,9739	0,9761
13	0,9589	0,9761	0,9761	0,9750	0,9828
14	0,9589	0,9761	0,9761	0,9750	0,9828
15	0,9606	0,9789	0,9767	0,9761	0,9828
16	0,9678	0,9833	0,9800	0,9761	0,9828
17	0,9700	0,9844	0,9800	0,9817	0,9789
18	0,9750	0,9861	0,9806	0,9806	0,9789
19	0,9750	0,9861	0,9806	0,9806	0,9811
20	0,9800	0,9861	0,9817	0,9806	0,9811
21	0,9794	0,9861	0,9817	0,9806	0,9811
22	0,9794	0,9861	0,9817	0,9844	0,9811
23	0,9794	0,9861	0,9817	0,9844	0,9817
24	0,9794	0,9861	0,9817	0,9844	0,9833
25	0,9806	0,9878	0,9822	0,9833	0,9856
26	0,9817	0,9883	0,9817	0,9833	0,9856
27	0,9811	0,9889	0,9828	0,9833	0,9856
28	0,9828	0,9872	0,9817	0,9833	0,9878
29	0,9833	0,9872	0,9822	0,9833	0,9878

	<b>3D informatsiooni- kasv, 3D andmed</b>	<b>3D informatsiooni- kasv, 2D andmed</b>	<b>3D informatsiooni- kasv, 2D andmed, 90° profiil</b>	<b>2D informatsiooni- kasv, 2D andmed</b>	<b>2D informatsiooni- kasv, 2D andmed, 90° profiil</b>
0	0,3722	0,2283	0,2867	0,3700	0,3811
1	0,6033	0,6844	0,6139	0,6833	0,2961
2	0,6033	0,6844	0,6139	0,6839	0,2956
3	0,8028	0,8739	0,7594	0,8694	0,3178
4	0,8028	0,8739	0,7594	0,9506	0,5744
5	0,8028	0,8739	0,7594	0,9506	0,8083
6	0,9111	0,9444	0,9183	0,9611	0,9028
7	0,9411	0,9567	0,9356	0,9733	0,9422
8	0,9511	0,9617	0,9517	0,9778	0,9422
9	0,9522	0,9761	0,9533	0,9778	0,9422
10	0,9522	0,9761	0,9533	0,9778	0,9422
11	0,9550	0,9806	0,9522	0,9828	0,9494
12	0,9550	0,9806	0,9522	0,9872	0,9728
13	0,9706	0,9839	0,9683	0,9861	0,9728
14	0,9628	0,9811	0,9722	0,9861	0,9733
15	0,9628	0,9811	0,9722	0,9861	0,9817
16	0,9656	0,9828	0,9800	0,9861	0,9817
17	0,9656	0,9828	0,9800	0,9861	0,9783
18	0,9722	0,9833	0,9717	0,9861	0,9783
19	0,9717	0,9856	0,9722	0,9867	0,9783
20	0,9739	0,9900	0,9750	0,9867	0,9800
21	0,9739	0,9900	0,9750	0,9878	0,9817
22	0,9739	0,9906	0,9744	0,9878	0,9817
23	0,9761	0,9883	0,9744	0,9878	0,9839
24	0,9767	0,9889	0,9750	0,9878	0,9839
25	0,9806	0,9900	0,9778	0,9872	0,9839
26	0,9633	0,9750	0,9656	0,9878	0,9839
27	0,9633	0,9750	0,9656	0,9883	0,9839
28	0,9656	0,9750	0,9678	0,9889	0,9856
29	0,9667	0,9767	0,9689	0,9883	0,9856

**Lisa 2 – SVM algoritmi kasutades saadud tuvastustäpsus  
(klassifitseerimisõigsus) 30 tunnuse puhul**

	3D Fisher skoor, 3D andmed	3D Fisher skoor, 2D andmed	3D Fisher skoor, 2D andmed, 90° profiil	2D Fisher skoor, 2D andmed	2D Fisher skoor, 2D andmed, 90° profiil
0	0,4672	0,4678	0,4800	0,4817	0,4822
1	0,4178	0,4417	0,2850	0,3950	0,4422
2	0,4028	0,4233	0,2656	0,4133	0,4400
3	0,4178	0,4400	0,2672	0,4789	0,4383
4	0,4094	0,4317	0,2661	0,4456	0,5167
5	0,4056	0,4278	0,2678	0,4256	0,5144
6	0,4089	0,4561	0,2922	0,4117	0,4894
7	0,4083	0,4522	0,2844	0,4028	0,4839
8	0,4128	0,4694	0,3867	0,4750	0,4806
9	0,4122	0,4661	0,3867	0,4606	0,4822
10	0,4228	0,4983	0,4489	0,4583	0,4828
11	0,4206	0,5411	0,4544	0,4561	0,5144
12	0,4461	0,5872	0,4917	0,4528	0,5228
13	0,4494	0,5867	0,5000	0,5067	0,5189
14	0,4233	0,5467	0,5056	0,5122	0,5150
15	0,4211	0,5289	0,5039	0,5200	0,5311
16	0,4183	0,5172	0,5017	0,5211	0,5267
17	0,4183	0,5261	0,5028	0,5194	0,5983
18	0,4172	0,5217	0,5006	0,5167	0,5983
19	0,4167	0,5183	0,4978	0,5150	0,5972
20	0,4150	0,5139	0,4972	0,5133	0,5989
21	0,4194	0,5028	0,5078	0,5244	0,5978
22	0,4183	0,5017	0,5072	0,5506	0,5956
23	0,4172	0,4994	0,5056	0,5539	0,5950
24	0,4161	0,4978	0,5056	0,5694	0,6000
25	0,4194	0,5022	0,5072	0,5711	0,5883
26	0,4183	0,4989	0,5067	0,5756	0,5744
27	0,4189	0,5044	0,5139	0,5856	0,5733
28	0,4211	0,5050	0,5161	0,5894	0,5706
29	0,4206	0,5228	0,5200	0,5861	0,5672

	<b>3D Gini, 3D andmed</b>	<b>3D Gini, 2D andmed</b>	<b>3D Gini, 2D andmed, 90° profiil</b>	<b>2D Gini, 2D andmed</b>	<b>2D Entroopia, 2D andmed, 90° profiil</b>
0	0,3450	0,3778	0,3739	0,3850	0,3733
1	0,2833	0,3311	0,2761	0,4122	0,3528
2	0,3144	0,3311	0,3906	0,3883	0,4111
3	0,3956	0,4239	0,4583	0,3883	0,5150
4	0,4533	0,4967	0,5206	0,5233	0,4722
5	0,5517	0,6344	0,6106	0,5078	0,4656
6	0,4889	0,5694	0,5906	0,5839	0,4889
7	0,4811	0,5467	0,5694	0,6289	0,5033
8	0,4733	0,5300	0,5606	0,6089	0,4944
9	0,4733	0,5494	0,5722	0,6067	0,4917
10	0,4617	0,5394	0,5583	0,5967	0,5172
11	0,4711	0,5683	0,5811	0,6011	0,5156
12	0,4694	0,5622	0,5739	0,5933	0,5639
13	0,4733	0,5933	0,5728	0,5817	0,5622
14	0,4633	0,5906	0,5644	0,5756	0,5511
15	0,4656	0,5917	0,5639	0,6206	0,5522
16	0,4828	0,6767	0,6050	0,6072	0,5428
17	0,4833	0,6678	0,6067	0,6239	0,5444
18	0,5506	0,6761	0,6300	0,6022	0,5528
19	0,5422	0,6628	0,6233	0,5844	0,5889
20	0,5411	0,6544	0,6278	0,5706	0,5817
21	0,5406	0,6544	0,6239	0,5628	0,5733
22	0,5361	0,6500	0,6167	0,5833	0,5722
23	0,5294	0,6478	0,6078	0,5750	0,6150
24	0,5300	0,6428	0,6050	0,6506	0,6161
25	0,5378	0,6567	0,6272	0,6867	0,6306
26	0,5444	0,6594	0,6394	0,6806	0,6278
27	0,5467	0,6600	0,6411	0,6733	0,6261
28	0,5628	0,6783	0,6439	0,6722	0,6206
29	0,5639	0,6822	0,6428	0,6500	0,6183

	<b>3D informatsiooni- kasv, 3D andmed</b>	<b>3D informatsiooni- kasv, 2D andmed</b>	<b>3D informatsiooni- kasv, 2D andmed, 90° profiil</b>	<b>2D informatsiooni- kasv, 2D andmed</b>	<b>2D informatsiooni- kasv, 2D andmed, 90° profiil</b>
0	0,4911	0,3122	0,3778	0,4694	0,4800
1	0,4772	0,5533	0,5550	0,6578	0,3233
2	0,4161	0,4122	0,4606	0,5350	0,2928
3	0,4289	0,4528	0,4672	0,6417	0,2850
4	0,4089	0,4094	0,4544	0,7261	0,3728
5	0,4000	0,3789	0,4506	0,6911	0,4122
6	0,4272	0,4494	0,5111	0,7211	0,4117
7	0,4350	0,4439	0,5100	0,7361	0,4156
8	0,4383	0,4389	0,5150	0,7606	0,4111
9	0,4400	0,4861	0,5189	0,7450	0,4094
10	0,4267	0,4772	0,5100	0,7322	0,4061
11	0,4628	0,5078	0,5394	0,7011	0,4100
12	0,4556	0,4956	0,5333	0,7006	0,5339
13	0,4472	0,4839	0,5728	0,6978	0,5272
14	0,5467	0,6111	0,6206	0,6767	0,6200
15	0,5372	0,6006	0,6172	0,6644	0,5917
16	0,5600	0,6200	0,6744	0,6533	0,5844
17	0,5556	0,6061	0,6628	0,6794	0,5828
18	0,5300	0,5567	0,6728	0,6711	0,5739
19	0,5300	0,5761	0,6700	0,6739	0,5739
20	0,4878	0,4972	0,6100	0,6639	0,5833
21	0,4733	0,4956	0,6083	0,6856	0,5867
22	0,4722	0,4894	0,6183	0,6522	0,5778
23	0,4772	0,5339	0,6194	0,6467	0,5650
24	0,4800	0,5311	0,6217	0,6544	0,5572
25	0,5067	0,5389	0,6289	0,6517	0,5528
26	0,5317	0,5883	0,6989	0,6583	0,5567
27	0,5194	0,5839	0,6928	0,6578	0,5522
28	0,4972	0,5756	0,6961	0,6911	0,5628
29	0,5383	0,5872	0,6894	0,7022	0,5789

**Lisa 3 – Otsustuspuu algoritmi kasutades saadud  
tuvastustäpsus (klassifitseerimisõigsus) 30 tunnuse puhul**

	3D Fisher skoor, 3D andmed	3D Fisher skoor, 2D andmed	3D Fisher skoor, 2D andmed, 90° profiil	2D Fisher skoor, 2D andmed	2D Fisher skoor, 2D andmed, 90° profiil
0	0,3450	0,3467	0,3439	0,3561	0,3433
1	0,5033	0,6850	0,6578	0,6039	0,5733
2	0,6250	0,7739	0,7644	0,7322	0,7439
3	0,6356	0,7828	0,7661	0,7767	0,7439
4	0,6294	0,8050	0,8106	0,7833	0,7839
5	0,6811	0,8250	0,8389	0,7928	0,7961
6	0,6900	0,8272	0,8478	0,8050	0,8317
7	0,6917	0,8456	0,8533	0,7922	0,8517
8	0,7000	0,8344	0,8500	0,8217	0,8461
9	0,7100	0,8433	0,8539	0,8539	0,8544
10	0,6967	0,8478	0,8544	0,8522	0,8594
11	0,7022	0,8422	0,8528	0,8589	0,8594
12	0,7178	0,8617	0,8633	0,8606	0,8628
13	0,7317	0,8767	0,8672	0,8494	0,8683
14	0,7250	0,8650	0,9028	0,8600	0,8900
15	0,7322	0,8722	0,8933	0,8594	0,8939
16	0,7439	0,8717	0,8950	0,8594	0,8867
17	0,7678	0,8800	0,9039	0,8628	0,9122
18	0,7700	0,8683	0,9056	0,8639	0,9111
19	0,7589	0,8700	0,9044	0,8667	0,9078
20	0,7689	0,8756	0,9028	0,8628	0,9189
21	0,7667	0,8711	0,9006	0,8683	0,9228
22	0,7789	0,8878	0,9056	0,8656	0,9272
23	0,7972	0,8683	0,9050	0,8578	0,9206
24	0,7894	0,8744	0,9017	0,8672	0,9189
25	0,7961	0,8761	0,8994	0,8683	0,9167
26	0,7917	0,8822	0,9033	0,8711	0,9194
27	0,7989	0,8844	0,8933	0,8711	0,9189
28	0,7956	0,8800	0,8944	0,8600	0,9233
29	0,7900	0,8783	0,8989	0,8700	0,9289

	<b>3D Gini, 3D andmed</b>	<b>3D Gini, 2D andmed</b>	<b>3D Gini, 2D andmed, 90° profiil</b>	<b>2D Gini, 2D andmed</b>	<b>2D Entroopia, 2D andmed, 90° profiil</b>
0	0,2456	0,2489	0,2356	0,2633	0,2400
1	0,5111	0,5828	0,5300	0,5550	0,4950
2	0,7322	0,7950	0,7456	0,7750	0,7433
3	0,8133	0,8778	0,8383	0,8261	0,8694
4	0,8717	0,9050	0,8839	0,8750	0,8822
5	0,8800	0,8894	0,8922	0,8928	0,9022
6	0,8978	0,9022	0,8878	0,9100	0,8994
7	0,8900	0,9106	0,8983	0,9206	0,9100
8	0,9000	0,9228	0,9022	0,9150	0,9072
9	0,8994	0,9378	0,9011	0,9294	0,9233
10	0,9200	0,9328	0,9133	0,9133	0,9344
11	0,9228	0,9328	0,9256	0,9294	0,9411
12	0,9206	0,9356	0,9244	0,9233	0,9367
13	0,9278	0,9306	0,9328	0,9206	0,9311
14	0,9267	0,9328	0,9322	0,9178	0,9300
15	0,9261	0,9289	0,9261	0,9272	0,9294
16	0,9317	0,9383	0,9367	0,9272	0,9289
17	0,9278	0,9439	0,9356	0,9333	0,9317
18	0,9339	0,9450	0,9356	0,9311	0,9306
19	0,9306	0,9428	0,9322	0,9350	0,9278
20	0,9317	0,9478	0,9372	0,9378	0,9256
21	0,9389	0,9461	0,9367	0,9356	0,9267
22	0,9322	0,9550	0,9328	0,9389	0,9289
23	0,9333	0,9517	0,9233	0,9294	0,9350
24	0,9356	0,9506	0,9339	0,9333	0,9328
25	0,9372	0,9417	0,9394	0,9283	0,9300
26	0,9344	0,9494	0,9322	0,9322	0,9311
27	0,9389	0,9461	0,9378	0,9317	0,9339
28	0,9461	0,9528	0,9300	0,9272	0,9372
29	0,9383	0,9483	0,9378	0,9306	0,9389

	<b>3D informatsiooni- kasv, 3D andmed</b>	<b>3D informatsiooni- kasv, 2D andmed</b>	<b>3D informatsiooni- kasv, 2D andmed, 90° profiil</b>	<b>2D informatsiooni- kasv, 2D andmed</b>	<b>2D informatsiooni- kasv, 2D andmed, 90° profiil</b>
0	0,3411	0,2278	0,2583	0,3328	0,3439
1	0,5639	0,6278	0,5639	0,6244	0,6111
2	0,7978	0,8339	0,8039	0,8400	0,8050
3	0,8533	0,8917	0,8550	0,8944	0,8856
4	0,8911	0,9156	0,9011	0,9139	0,9117
5	0,9050	0,9228	0,9061	0,9267	0,9200
6	0,9078	0,9239	0,9111	0,9272	0,9222
7	0,9117	0,9300	0,9206	0,9328	0,9300
8	0,9100	0,9278	0,9244	0,9317	0,9289
9	0,9194	0,9322	0,9411	0,9406	0,9350
10	0,9161	0,9322	0,9483	0,9417	0,9300
11	0,9267	0,9261	0,9489	0,9428	0,9394
12	0,9372	0,9394	0,9489	0,9522	0,9428
13	0,9428	0,9394	0,9439	0,9467	0,9511
14	0,9328	0,9422	0,9422	0,9456	0,9439
15	0,9422	0,9428	0,9350	0,9428	0,9489
16	0,9333	0,9450	0,9450	0,9422	0,9500
17	0,9339	0,9500	0,9422	0,9472	0,9461
18	0,9372	0,9478	0,9383	0,9428	0,9511
19	0,9406	0,9472	0,9378	0,9428	0,9500
20	0,9417	0,9461	0,9456	0,9433	0,9506
21	0,9406	0,9472	0,9428	0,9444	0,9506
22	0,9328	0,9439	0,9478	0,9422	0,9511
23	0,9317	0,9411	0,9517	0,9472	0,9511
24	0,9294	0,9411	0,9450	0,9450	0,9478
25	0,9383	0,9528	0,9478	0,9439	0,9472
26	0,9311	0,9461	0,9478	0,9450	0,9444
27	0,9378	0,9528	0,9339	0,9417	0,9478
28	0,9372	0,9539	0,9378	0,9472	0,9472
29	0,9394	0,9511	0,9406	0,9450	0,9561



**Lisa 4 – Juhusliku metsa algoritmi kasutades saadud  
tuvastustäpsus (klassifitseerimisõigsus) 30 tunnuse puhul**

	<b>3D Fisher skoor, 3D andmed</b>	<b>3D Fisher skoor, 2D andmed</b>	<b>3D Fisher skoor, 2D andmed, 90° profiil</b>	<b>2D Fisher skoor, 2D andmed</b>	<b>2D Fisher skoor, 2D andmed, 90° profiil</b>
0	0,3678	0,3539	0,3500	0,3567	0,3439
1	0,5450	0,7389	0,7144	0,6583	0,6328
2	0,6667	0,8361	0,8256	0,8011	0,7944
3	0,6967	0,8467	0,8350	0,8467	0,8094
4	0,6983	0,8594	0,8661	0,8600	0,8533
5	0,7328	0,8867	0,8861	0,8611	0,8556
6	0,7511	0,8906	0,8950	0,8606	0,8889
7	0,7506	0,8922	0,9039	0,8600	0,9006
8	0,7583	0,8950	0,9106	0,8928	0,9111
9	0,7617	0,8961	0,9094	0,8989	0,9206
10	0,7589	0,8956	0,9056	0,9044	0,9194
11	0,7589	0,8950	0,9089	0,9072	0,9222
12	0,7683	0,9100	0,9211	0,9061	0,9172
13	0,7911	0,9189	0,9244	0,9017	0,9217
14	0,7978	0,9194	0,9356	0,9039	0,9517
15	0,7978	0,9200	0,9417	0,9067	0,9517
16	0,7967	0,9200	0,9417	0,9028	0,9500
17	0,8356	0,9211	0,9467	0,9017	0,9600
18	0,8306	0,9228	0,9439	0,9056	0,9633
19	0,8283	0,9261	0,9428	0,9039	0,9622
20	0,8272	0,9228	0,9417	0,9061	0,9689
21	0,8272	0,9217	0,9444	0,9072	0,9706
22	0,8317	0,9311	0,9439	0,9050	0,9683
23	0,8450	0,9317	0,9439	0,9111	0,9689
24	0,8511	0,9344	0,9439	0,9156	0,9711
25	0,8478	0,9267	0,9467	0,9117	0,9728
26	0,8511	0,9272	0,9444	0,9133	0,9722
27	0,8511	0,9311	0,9428	0,9106	0,9694
28	0,8544	0,9306	0,9406	0,9133	0,9706
29	0,8517	0,9350	0,9411	0,9144	0,9728

	<b>3D Gini, 3D andmed</b>	<b>3D Gini, 2D andmed</b>	<b>3D Gini, 2D andmed, 90° profiil</b>	<b>2D Gini, 2D andmed</b>	<b>2D Gini, 2D andmed, 90° profiil</b>
0	0,2461	0,2489	0,2361	0,2633	0,2406
1	0,5772	0,6700	0,5989	0,6200	0,5694
2	0,7928	0,8533	0,8106	0,8433	0,8000
3	0,8656	0,9283	0,8994	0,8767	0,9144
4	0,9111	0,9478	0,9339	0,9339	0,9439
5	0,9278	0,9606	0,9461	0,9483	0,9500
6	0,9500	0,9678	0,9606	0,9606	0,9478
7	0,9439	0,9683	0,9622	0,9733	0,9528
8	0,9517	0,9700	0,9644	0,9711	0,9589
9	0,9500	0,9733	0,9611	0,9783	0,9689
10	0,9678	0,9800	0,9711	0,9828	0,9806
11	0,9706	0,9844	0,9750	0,9861	0,9789
12	0,9667	0,9822	0,9761	0,9828	0,9828
13	0,9783	0,9861	0,9783	0,9878	0,9861
14	0,9711	0,9856	0,9789	0,9850	0,9850
15	0,9733	0,9856	0,9789	0,9856	0,9839
16	0,9744	0,9872	0,9822	0,9867	0,9828
17	0,9778	0,9883	0,9817	0,9878	0,9850
18	0,9761	0,9850	0,9850	0,9878	0,9867
19	0,9778	0,9872	0,9839	0,9894	0,9850
20	0,9828	0,9878	0,9844	0,9878	0,9867
21	0,9789	0,9883	0,9867	0,9883	0,9883
22	0,9822	0,9883	0,9839	0,9883	0,9867
23	0,9828	0,9889	0,9867	0,9889	0,9889
24	0,9811	0,9883	0,9878	0,9883	0,9894
25	0,9844	0,9872	0,9883	0,9883	0,9889
26	0,9806	0,9883	0,9900	0,9883	0,9894
27	0,9856	0,9878	0,9894	0,9917	0,9906
28	0,9822	0,9883	0,9872	0,9878	0,9889
29	0,9828	0,9900	0,9883	0,9878	0,9900

	<b>3D informatsiooni- kasv, 3D andmed</b>	<b>3D informatsiooni- kasv, 2D andmed</b>	<b>3D informatsiooni- kasv, 2D andmed, 90° profiil</b>	<b>2D informatsiooni- kasv, 2D andmed</b>	<b>2D informatsiooni- kasv, 2D andmed, 90° profiil</b>
0	0,3411	0,3539	0,2583	0,3328	0,3500
1	0,6361	0,7389	0,6272	0,6900	0,6783
2	0,8522	0,8361	0,8522	0,8928	0,8494
3	0,8978	0,8467	0,9050	0,9322	0,9289
4	0,9306	0,8594	0,9500	0,9556	0,9533
5	0,9522	0,8867	0,9578	0,9661	0,9622
6	0,9611	0,8906	0,9667	0,9700	0,9617
7	0,9678	0,8922	0,9733	0,9728	0,9689
8	0,9733	0,8950	0,9800	0,9739	0,9689
9	0,9711	0,8961	0,9844	0,9767	0,9728
10	0,9733	0,8956	0,9867	0,9772	0,9811
11	0,9761	0,8950	0,9856	0,9839	0,9822
12	0,9750	0,9100	0,9856	0,9811	0,9839
13	0,9783	0,9189	0,9867	0,9817	0,9833
14	0,9800	0,9194	0,9850	0,9822	0,9861
15	0,9778	0,9200	0,9867	0,9794	0,9850
16	0,9767	0,9200	0,9878	0,9828	0,9878
17	0,9783	0,9211	0,9889	0,9833	0,9883
18	0,9789	0,9228	0,9889	0,9850	0,9861
19	0,9789	0,9261	0,9856	0,9844	0,9900
20	0,9789	0,9228	0,9883	0,9839	0,9878
21	0,9789	0,9217	0,9889	0,9839	0,9917
22	0,9817	0,9311	0,9889	0,9817	0,9911
23	0,9800	0,9317	0,9878	0,9850	0,9906
24	0,9811	0,9344	0,9883	0,9844	0,9900
25	0,9800	0,9267	0,9850	0,9828	0,9878
26	0,9817	0,9272	0,9883	0,9861	0,9889
27	0,9844	0,9311	0,9883	0,9861	0,9889
28	0,9839	0,9306	0,9872	0,9844	0,9906
29	0,9822	0,9350	0,9878	0,9861	0,9906

**Lisa 5 – Gaussi naiivse Bayes algoritmi kasutades saadud  
tuvastustäpsus (klassifitseerimisõigsus) 30 tunnuse puhul**

	3D Fisher skoor, 3D andmed	3D Fisher skoor, 2D andmed	3D Fisher skoor, 2D andmed, 90° profiil	2D Fisher skoor, 2D andmed	2D Fisher skoor, 2D andmed, 90° profiil
0	0,4861	0,4406	0,4661	0,4839	0,4717
1	0,4800	0,4972	0,6261	0,4972	0,5428
2	0,5261	0,5011	0,6417	0,5233	0,5711
3	0,5044	0,5139	0,6439	0,5317	0,5767
4	0,4928	0,5572	0,6494	0,5422	0,6239
5	0,5017	0,5783	0,6517	0,5367	0,6283
6	0,5067	0,5994	0,6350	0,5550	0,6728
7	0,5017	0,6267	0,6322	0,5533	0,6722
8	0,5206	0,6222	0,6606	0,6256	0,6989
9	0,5367	0,6344	0,6594	0,6267	0,7100
10	0,5311	0,6100	0,6617	0,6278	0,7094
11	0,5233	0,6256	0,6567	0,6417	0,7078
12	0,5483	0,6517	0,6867	0,6644	0,7033
13	0,5522	0,6556	0,6783	0,6733	0,7017
14	0,5472	0,6656	0,7122	0,6728	0,7517
15	0,5478	0,6594	0,7067	0,6733	0,7461
16	0,5522	0,6583	0,7122	0,6722	0,7494
17	0,5567	0,6722	0,7111	0,6689	0,7739
18	0,5606	0,6761	0,7089	0,6622	0,7750
19	0,5611	0,6744	0,7050	0,6589	0,7717
20	0,5689	0,6778	0,7072	0,6622	0,7778
21	0,5656	0,6694	0,7011	0,6517	0,7883
22	0,5672	0,6683	0,7000	0,6650	0,7894
23	0,5778	0,6733	0,7056	0,6678	0,7867
24	0,5761	0,6689	0,7039	0,6767	0,7856
25	0,5761	0,6678	0,6994	0,6750	0,7811
26	0,5833	0,6711	0,7033	0,6722	0,7828
27	0,5917	0,6789	0,7061	0,6750	0,7828
28	0,5928	0,6856	0,7011	0,6778	0,7822
29	0,5917	0,6861	0,6922	0,6767	0,7750

	<b>3D Gini, 3D andmed</b>	<b>3D Gini, 2D andmed</b>	<b>3D Gini, 2D andmed, 90° profiil</b>	<b>2D Gini, 2D andmed</b>	<b>2D Gini, 2D andmed, 90° profiil</b>
0	0,3406	0,3528	0,3239	0,3828	0,3772
1	0,4817	0,4950	0,5244	0,5100	0,4989
2	0,6261	0,5839	0,5628	0,6078	0,6022
3	0,6367	0,6539	0,6561	0,6078	0,7094
4	0,7089	0,6394	0,6450	0,7067	0,7211
5	0,7522	0,6883	0,6539	0,7167	0,7472
6	0,7817	0,6778	0,6717	0,7606	0,7522
7	0,7761	0,6839	0,6750	0,7828	0,7806
8	0,7883	0,6950	0,6939	0,7794	0,7961
9	0,7883	0,7100	0,7000	0,8011	0,8100
10	0,8078	0,7300	0,7372	0,8156	0,8400
11	0,8122	0,7489	0,7456	0,8383	0,8411
12	0,8100	0,7489	0,7272	0,8406	0,8422
13	0,8322	0,7489	0,7500	0,8411	0,8444
14	0,8378	0,7478	0,7394	0,8550	0,8500
15	0,8394	0,7494	0,7322	0,8494	0,8528
16	0,8500	0,7661	0,7639	0,8644	0,8539
17	0,8544	0,7839	0,7817	0,8683	0,8494
18	0,8528	0,7789	0,7778	0,8728	0,8439
19	0,8533	0,7939	0,7950	0,8717	0,8472
20	0,8539	0,7928	0,7939	0,8761	0,8578
21	0,8578	0,7867	0,8006	0,8750	0,8572
22	0,8644	0,7922	0,8022	0,8789	0,8611
23	0,8633	0,7928	0,8022	0,8733	0,8567
24	0,8622	0,7906	0,8194	0,8739	0,8578
25	0,8611	0,8017	0,8194	0,8783	0,8567
26	0,8578	0,8072	0,8228	0,8717	0,8494
27	0,8583	0,8111	0,8206	0,8700	0,8583
28	0,8533	0,8078	0,8172	0,8722	0,8500
29	0,8517	0,8083	0,8211	0,8672	0,8550

	<b>3D informatsiooni- kasv, 3D andmed</b>	<b>3D informatsiooni- kasv, 2D andmed</b>	<b>3D informatsiooni- kasv, 2D andmed, 90° profiil</b>	<b>2D informatsiooni- kasv, 2D andmed</b>	<b>2D informatsiooni- kasv, 2D andmed, 90° profiil</b>
0	0,4844	0,2606	0,3439	0,4511	0,4661
1	0,6067	0,5633	0,4911	0,6161	0,6039
2	0,6589	0,5622	0,5700	0,7067	0,6544
3	0,7228	0,6633	0,5811	0,7661	0,7100
4	0,7594	0,7278	0,6567	0,7856	0,7472
5	0,7650	0,7311	0,7028	0,8061	0,8006
6	0,7594	0,7439	0,7206	0,8183	0,7939
7	0,7911	0,7683	0,7306	0,8444	0,8089
8	0,8089	0,7683	0,7311	0,8394	0,8183
9	0,8106	0,7811	0,7544	0,8444	0,8222
10	0,8144	0,7856	0,7828	0,8394	0,8350
11	0,8128	0,7789	0,7833	0,8278	0,8289
12	0,8128	0,7844	0,7839	0,8161	0,8367
13	0,8094	0,7794	0,7867	0,8017	0,8406
14	0,8133	0,7789	0,7583	0,8078	0,8461
15	0,8167	0,7833	0,7783	0,8217	0,8489
16	0,8094	0,7906	0,8044	0,8339	0,8511
17	0,8178	0,7861	0,7928	0,8389	0,8489
18	0,8078	0,7856	0,7889	0,8328	0,8467
19	0,8033	0,7789	0,7822	0,8339	0,8450
20	0,8033	0,7900	0,7967	0,8394	0,8494
21	0,7972	0,7867	0,7972	0,8372	0,8656
22	0,8078	0,7806	0,7944	0,8378	0,8644
23	0,8022	0,7783	0,7900	0,8367	0,8694
24	0,8000	0,7833	0,7850	0,8389	0,8678
25	0,7978	0,7828	0,7883	0,8389	0,8633
26	0,7950	0,7933	0,7889	0,8444	0,8672
27	0,7956	0,7878	0,7883	0,8389	0,8611
28	0,7817	0,7872	0,7828	0,8383	0,8606
29	0,7906	0,7906	0,7867	0,8389	0,8572

**Lisa 6 – Mitmekihiliste nÄrvivõrkude algoritmi kasutades  
saadud tuvastustÄpsus (klassifitseerimisõigsus) 30 tunnuse  
puhul**

	3D Fisher skoor, 3D andmed	3D Fisher skoor, 2D andmed	3D Fisher skoor, 2D andmed, 90° profiil	2D Fisher skoor, 2D andmed	2D Fisher skoor, 2D andmed, 90° profiil
0	0,1506	0,1506	0,1506	0,4239	0,4550
1	0,1694	0,4206	0,1483	0,4311	0,4239
2	0,4389	0,4317	0,1506	0,5039	0,4256
3	0,4706	0,4856	0,3250	0,5228	0,4400
4	0,4772	0,4878	0,3711	0,5228	0,5578
5	0,4761	0,4861	0,3128	0,6083	0,5894
6	0,5911	0,6378	0,4167	0,5444	0,5606
7	0,5656	0,6467	0,4517	0,5556	0,5956
8	0,5650	0,6450	0,6011	0,7294	0,6428
9	0,5822	0,6983	0,5844	0,7606	0,6267
10	0,6194	0,7522	0,6633	0,7383	0,5806
11	0,6617	0,7561	0,7039	0,7522	0,6900
12	0,6739	0,7933	0,7672	0,7306	0,7128
13	0,6622	0,7750	0,7861	0,7378	0,7633
14	0,6550	0,8083	0,8167	0,7789	0,7556
15	0,6572	0,8028	0,8389	0,7272	0,8011
16	0,6572	0,8028	0,8106	0,7611	0,7867
17	0,5928	0,7678	0,8094	0,7978	0,7978
18	0,6467	0,7933	0,8372	0,7622	0,8494
19	0,6556	0,7850	0,8233	0,7739	0,8350
20	0,6428	0,7544	0,8139	0,7783	0,8378
21	0,6139	0,7583	0,8406	0,7567	0,8511
22	0,6294	0,7828	0,7839	0,7689	0,8606
23	0,6344	0,7900	0,8772	0,8300	0,8678
24	0,6472	0,7822	0,8183	0,8006	0,8750
25	0,6217	0,7900	0,7794	0,7678	0,8556
26	0,6444	0,8072	0,8383	0,7350	0,8533
27	0,6711	0,8278	0,8639	0,7878	0,8406
28	0,6789	0,8111	0,8544	0,7917	0,8394
29	0,6661	0,8339	0,8500	0,8000	0,8322

	<b>3D Gini, 3D andmed</b>	<b>3D Gini, 2D andmed</b>	<b>3D Gini, 2D andmed, 90° profiil</b>	<b>2D Gini, 2D andmed</b>	<b>2D Gini, 2D andmed, 90° profiil</b>
0	0,1483	0,1544	0,1483	0,3833	0,1483
1	0,1506	0,1656	0,1506	0,4756	0,3528
2	0,3350	0,3144	0,2683	0,4739	0,4094
3	0,4683	0,5172	0,4633	0,5411	0,6222
4	0,5600	0,6283	0,6228	0,6217	0,5694
5	0,6706	0,7400	0,7544	0,6928	0,6428
6	0,6756	0,7717	0,7261	0,7206	0,8000
7	0,6994	0,7383	0,7617	0,8128	0,8517
8	0,6494	0,7078	0,7311	0,7983	0,8383
9	0,6667	0,8300	0,7300	0,8278	0,7950
10	0,6550	0,7961	0,7794	0,8222	0,8250
11	0,7367	0,8700	0,8111	0,8189	0,8728
12	0,6900	0,8733	0,8978	0,8539	0,8583
13	0,7572	0,8789	0,8089	0,8861	0,8278
14	0,7778	0,9100	0,8428	0,8994	0,8511
15	0,8017	0,9039	0,8822	0,9128	0,8739
16	0,8089	0,9072	0,8994	0,8789	0,8922
17	0,8650	0,9311	0,9406	0,9039	0,8706
18	0,8589	0,9250	0,9072	0,8978	0,8944
19	0,8739	0,9272	0,9156	0,9183	0,8961
20	0,8956	0,9356	0,9311	0,9228	0,8967
21	0,8717	0,9294	0,9306	0,8822	0,8944
22	0,8789	0,9033	0,9261	0,9272	0,8678
23	0,8783	0,9422	0,9139	0,8867	0,8733
24	0,8828	0,9439	0,9117	0,8989	0,8850
25	0,9028	0,9400	0,9378	0,8922	0,9400
26	0,9117	0,9394	0,9356	0,9161	0,9172
27	0,9061	0,9350	0,9594	0,9267	0,9300
28	0,8933	0,9667	0,9450	0,8833	0,9494
29	0,8978	0,9122	0,9472	0,8939	0,9339



	<b>3D informatsiooni- kasv, 3D andmed</b>	<b>3D informatsiooni- kasv, 2D andmed</b>	<b>3D informatsiooni- kasv, 2D andmed, 90° profiil</b>	<b>2D informatsiooni- kasv, 2D andmed</b>	<b>2D informatsiooni- kasv, 2D andmed, 90° profiil</b>
0	0,1506	0,1506	0,3156	0,4272	0,1506
1	0,4606	0,5633	0,4950	0,5450	0,3033
2	0,2006	0,5383	0,4872	0,5378	0,2261
3	0,4172	0,4422	0,5050	0,6867	0,5122
4	0,5822	0,6961	0,5478	0,7256	0,4689
5	0,5728	0,6344	0,5467	0,7383	0,5767
6	0,6250	0,6667	0,6700	0,7733	0,6411
7	0,7717	0,7233	0,6861	0,8122	0,7339
8	0,7683	0,7461	0,7956	0,8561	0,7028
9	0,7889	0,8550	0,8183	0,8533	0,7128
10	0,8022	0,8589	0,8500	0,8500	0,7150
11	0,7861	0,8839	0,8233	0,8761	0,7794
12	0,7956	0,8600	0,8528	0,8972	0,8556
13	0,8306	0,8789	0,8961	0,9339	0,8456
14	0,8272	0,8906	0,9156	0,9383	0,8783
15	0,8317	0,9117	0,9244	0,9061	0,8617
16	0,8739	0,9150	0,9172	0,9361	0,8967
17	0,8739	0,9350	0,9333	0,9367	0,8978
18	0,9017	0,9139	0,9328	0,8778	0,9150
19	0,8689	0,9283	0,9367	0,9189	0,9044
20	0,8961	0,9244	0,9294	0,9317	0,9150
21	0,8461	0,9150	0,9161	0,9394	0,9056
22	0,9017	0,9356	0,9044	0,9183	0,9339
23	0,8817	0,9328	0,9361	0,8989	0,9150
24	0,8506	0,9378	0,9383	0,9400	0,9389
25	0,9117	0,9522	0,9306	0,9461	0,9233
26	0,8783	0,9150	0,9406	0,9417	0,8972
27	0,8633	0,9156	0,9411	0,9506	0,9172
28	0,8650	0,9378	0,9333	0,9422	0,9250
29	0,8917	0,9233	0,9167	0,9256	0,9317

## Lisa 7 – Töös kasutatud tunnused ja nende asukoht joonisel 5

Heledal taustal olev number näitab tunnuse järjekorranumbrit ja helehallil taustal näitab milliste punktide vahel antud tunnus asub. Kahekohalised tunnused on punktide vahel asuvad eukeidilised kaugused ja kolmekohalised (keskmise nr näitab tippu) on kolmnurkade tipunurgad.

0	1	2	3	4	5	6	7	8	9
15_32	32_34	34_15	32_14		33_32	10_8	8_27	27_10	22_3
10	11	12	13	14	15	16	17	18	19
3_30	30_22	8_11	11_27	30_1	1_9	9_30	3_1	1_10	10_9
20	21	22	23	24	25	26	27	28	29
28_22	30_28	28_14	14_22	28_33	28_9	9_33	19_14	32_19	19_18
30	31	32	33	34	35	36	37	38	39
18_14	15_19	15_18	16_22	14_16	12_29	29_34	34_12	31_29	12_31
40	41	42	43	44	45	46	47	48	49
29_15	0_24	24_8	8_0	24_11	24_26	26_11	2_0	8_2	2_3
50	51	52	53	54	55	56	57	58	59
3_0	10_2	1_2	22_21	21_20	20_22	16_21	17_18	15_17	16_17
60	61	62	63	64	65	66	67	68	69
15_16	17_14	5_31	12_5	5_7	7_31	4_11	26_4	7_4	26_7
70	71	72	73	74	75	76	77	78	79
7_23	23_31	21_23	23_20	23_26	26_20	23_29	23_15	23_16	25_24
80	81	82	83	84	85	86	87	88	89
0_25	3_25	26_25	25_20	25_22	13_5	12_13	12_27	27_13	11_13
90	91	92	93	94	95	96	97	98	99
5_6	6_7	13_6	11_6	4_6	27_32	9_12	33_34	34_15_32	15_34_32
100	101	102	103	104	105	106	107	108	109
15_32_34	33_32_14	32_33_14	32_14_33	27_10_8	10_27_8	10_8_27	30_22_3	22_30_3	22_3_30
110	111	112	113	114	115	116	117	118	119
27_8_11	8_27_11	8_11_27	9_30_1	30_9_1	30_1_9	30_3_1	3_30_1	3_1_30	9_1_10
120	121	122	123	124	125	126	127	128	129
1_9_10	1_10_9	30_28_22	28_30_22	28_22_30	14_22_28	22_14_28	22_28_14	33_14_28	14_33_28
130	131	132	133	134	135	136	137	138	139
14_28_33	9_33_28	33_9_28	33_28_9	9_28_30	28_9_30	28_30_9	32_19_14	19_32_14	19_14_32
140	141	142	143	144	145	146	147	148	149
14_19_18	19_14_18	19_18_14	32_15_19	15_32_19	15_19_32	15_18_19	18_15_19	18_19_15	14_16_22
150	151	152	153	154	155	156	157	158	159
16_14_22	16_22_14	34_12_29	12_34_29	12_29_34	12_31_29	31_12_29	31_29_12	34_29_15	29_34_15
160	161	162	163	164	165	166	167	168	169
29_15_34	8_0_24	0_8_24	0_24_8	8_24_11	24_8_11	24_11_8	26_11_24	11_26_24	11_24_26
170	171	172	173	174	175	176	177	178	179
8_2_0	2_8_0	2_0_8	3_0_2	0_3_2	0_2_3	8_10_2	10_8_2	10_2_8	10_1_2

<b>180</b>	181	182	183	184	185	186	187	188	189
<b>1_10_2</b>	1_2_10	3_2_1	2_3_1	2_1_3	20_22_21	22_20_21	22_21_20	22_16_21	16_22_21
<b>190</b>	191	192	193	194	195	196	197	198	199
<b>16_21_22</b>	15_17_18	17_15_18	17_18_15	15_16_17	16_15_17	16_17_15	14_18_17	18_14_17	18_17_14
<b>200</b>	201	202	203	204	205	206	207	208	209
<b>14_17_16</b>	17_14_16	17_16_14	12_5_31	5_12_31	5_31_12	31_5_7	5_31_7	5_7_31	26_4_11
<b>210</b>	211	212	213	214	215	216	217	218	219
<b>4_26_11</b>	4_11_26	26_7_4	7_26_4	7_4_26	31_7_23	7_31_23	7_23_31	20_21_23	21_20_23
<b>220</b>	221	222	223	224	225	226	227	228	229
<b>21_23_20</b>	20_23_26	23_20_26	23_26_20	26_23_7	23_26_7	23_7_26	31_23_29	23_31_29	23_29_31
<b>230</b>	231	232	233	234	235	236	237	238	239
<b>15_29_23</b>	29_15_23	29_23_15	15_23_16	23_15_16	23_16_15	16_23_21	23_16_21	23_21_16	0_25_24
<b>240</b>	241	242	243	244	245	246	247	248	249
<b>25_0_24</b>	25_24_0	3_25_0	25_3_0	25_0_3	20_26_25	26_20_25	26_25_20	26_24_25	24_26_25
<b>250</b>	251	252	253	254	255	256	257	258	259
<b>24_25_26</b>	20_25_22	25_20_22	25_22_20	3_22_25	22_3_25	22_25_3	12_13_5	13_12_5	13_5_12
<b>260</b>	261	262	263	264	265	266	267	268	269
<b>27_13_12</b>	13_27_12	13_12_27	27_11_13	11_27_13	11_13_27	7_5_6	5_7_6	5_6_7	5_13_6
<b>270</b>	271	272	273	274	275	276	277	278	279
<b>13_5_6</b>	13_6_5	11_6_13	6_11_13	6_13_11	11_4_6	4_11_6	4_6_11	7_6_4	6_7_4
<b>280</b>									
<b>6_4_7</b>									