

TALLINNA TEHNIKAÜLIKOOL

Infotehnoloogia teaduskond

Tarkvarateaduse instituut

Tiina Sumeri, 182897IAPM

Närvivõrkudel baseeruv jämemotoorika mudel

Magistritöö

Juhendajad: Sven Nõmm, PhD

Kadri Medijainen, MSc

Tallinn 2020

TALLINN UNIVERSITY OF TECHNOLOGY

Faculty of Information Technology

Department of Software Science

Tiina Sumeri, 182897IAPM

Neural network based gross motor function model

Master's thesis

Supervisors: Sven Nõmm, PhD

Kadri Medijainen, MSc

Tallinn 2020

Autorideklaratsioon

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

Autor: Tiina Sumeri

15.05.2020

Abstract

The main goal of the current thesis is to create a method, which recognizes the differences in gait parameters between healthy people and people diagnosed with Parkinson's disease and also find out which joints of people with Parkinson's disease move differently in comparison to healthy people. To accomplish this goal, gait parameters were calculated from Up and Go test gait phase. Data from this test was already collected for another work. Parameters which were analysed during this study were angles between joints and their effort values. Classification was carried out taking into account these parameters. After classification the people who participated were identified to have the Parkinson's disease or not. The goal of this classification was also to find joint angles with the greatest discriminatory capacity. The accuracy of classification was in the three best cases 79% (+/-20%), 77% (+/- 13%) and 79% (+/- 21%). The left shoulder and the right hip were found to be the most discriminatory joints. Based on these joint angles, the neural network models were created. These models were trained on healthy people's data and tested on data which belonged to people with Parkinson's disease. The goal was to find out if these models are capable of distinguishing healthy people from people with Parkinson's disease. The thesis is in Estonian and contains 33 pages of text, 6 chapters, 18 figures and 7 tables.

Annotatsioon

Käesoleva magistritöö eesmärk oli luua meetod, mis tuvastaks Parkinsoni põdeva inimese kõnnakul eripärasusi võrreldes terve inimesega ning leiaks liigesed, mille liikumisel esineb enim erisusi tervete ning Parkinsoni põdevate inimeste võrdlemisel. Eesmärgi saavutamiseks arvutati esmalt kõnnaku parameetrid, milleks olid antud töös valitud liigete omavahelised nurgad ning nende pingutuse väärtused. Seejärel klassifitseeriti antud parameetrite põhjal inimesed terveteks ning Parkinsoni põdevateks ja klassifikaatorite tulemuste põhjal leiti, millised jäsemetevahelised nurgad on suurima diskrimineerimisvõimega. Antud nurkade põhjal on loodud igale liigesele närvivõrgumudelid, mida treeniti tervete inimeste andmete põhjal ning seeläbi uuritud, kas antud mudelid on võimelised tuvastama erisusi Parkinsoni põdevate inimeste liikumisel võrreldes tervete inimestega. Lõputöö on kirjutatud eesti keeles ning sisaldab teksti 33 leheküljel, 6 peatükki, 18 joonist ja 7 tabelit.

Sisukord

1	Sissejuhatus	10
2	Kirjanduse ülevaade	11
2.1	Parkinsoni tõbi	11
2.2	Up-and-Go test	11
2.3	Varasemad uurimistööd	12
2.3.1	Tallinna Tehnikaülikoolis tehtud tööd	14
2.4	Pingutus	15
2.5	Töös kasutatavad meetodid ja tehnoloogia	15
3	Implementatsioon	21
3.1	Andmed	21
3.2	Andmete eeltöötlus	21
3.3	Parameetrite valik	23
3.4	Mudelite koostamine	26
3.4.1	Klassifikatsioon	26
3.4.2	Närvivõrgu mudel	27
4	Tulemused	32
4.1	Klassifikatsioon	32
4.2	Närvivõrgumudel	34
5	Analüüs	39
5.1	Arutelu	40
6	Kokkuvõte	42
	References	43

7 Kasutatud kirjandus	43
A Lisa 1	47
B Lisa 2	48
C Lisa 3	50

Jooniste loetelu

2.1	Up and Go test. [1]	12
2.2	Kinect sensori poolt väljastatav skelett. [2]	16
2.3	Tugivektor-masin.	18
3.1	Vasakul korrektsed liigeste koordinaadid. Paremal mitte korrektsed liigeste koordinaadid.	22
3.2	Andmete töötlus.	25
3.3	Üks kõigist klassifikaatoritest, mis klassifitseerib kolme liigese parameetrite alusel inimesi Parkinsoni põdevateks või terveteks. PD-Parkinson (1), KT - terve (0).	27
3.4	Töös loodud närvivõrgu mudel.	28
3.5	Mudeli struktuur.	28
3.6	Üks närvivõrgumudelitest, mis on koostatud vasakule randmele. KT** F* tähistab tervet inimest ning tema ühte failidest, PD**F* tähistab Parkinsoni tõvega inimese faili.	30
3.7	Vigade leidmine ning nende põhjal mudelite valimine.	31
4.1	Vasaku randme mudeli ennustused tervetel inimestel.	35
4.2	Vasaku randme mudeli ennustused Parkinsoni põdevatel inimestel.	36
4.3	Kumulatiivne viga	36

Tablete loetelu

3.1	Erinevad nurkade kombinatsioonid liigete vahel. P - parem liiges, V - vasak liiges, K - keskpunkt	24
4.1	Klassifikaatorite täpsused erinevate liigete parameetreid kombineerides, P - tähistab paremat sammu, V - vasakut. DT - otsustuspuu, NB - naiivne Bayesi klassifikaator.	32
4.2	Klassifikaatorite täpsused erinevate liigete parameetreid kombineerides, P - tähistab paremat sammu, V - vasakut. KNN - k-lähima naabri meetod, DT - otsustuspuu, NB - naiivne Bayesi klassifikaator.	33
4.3	Liigete omavahelised nurgad.	34
4.4	A-K - Algas kuni keskpunkt, K-L - keskpunkt kuni sammu lõpp.	35
4.5	TN-õige negatiivne, FP-valepositiivne, FN-valenegatiivne, TP-õige positiivne.	37
4.6	TN-õige negatiivne, FP-valepositiivne, FN-valenegatiivne, TP-õige positiivne	38

1. Sissejuhatus

Tänapäeva meditsiinis kasutatakse aina enam erinevaid tehnoloogiaid ning meetodeid arstide töö toetamiseks. Näiteks kasutatakse masinõpet meditsiiniliste piltide analüüsimiseks, etteantud andmete põhjal haiguste tuvastamiseks, haiguste tekke ennustamiseks, lisaks veel käsitsi kirjutatud vormide konverteerimiseks digitaalseks tekstiks, mis on ka omamoodi arstide töö hõlbustamine. [3] Meditsiini ja tehnoloogia valdkondades toimub pidev ühine areng, proovitakse leida aina enam uusi meetodeid, mille abil inimeste tervislikku heaolu parandada ning eluiga pikendada.

Käesolevas magistritöös uuritakse masinõppe kasutamise võimalusi haiguste tuvastamiseks. Selle eesmärk on leida inimese kõnnaku puhul normist kõrvalekaldeid, mille abil oleks võimalik tuvastada haiguste tunnuseid. Siin töös on aluseks võetud Parkinsoni tõbi, mille puhul inimese kõnnak erineb terve inimese kõnnakust. Eesmärgi saavutamiseks leitakse liigesed, mille liikumine on Parkinsoni põdevatel inimestel häiritud. Liigete liikumist kirjeldavateks parameetriteks on võetud liigete omavahe- lised nurgad ning pingutus. Neid parameetreid kasutades on loodud tehisnärvivõrgu mudelid, mille abil saab kindlaks teha, kas inimesel, kelle andmeid analüüsitakse, on haiguse tunnuseid või mitte.

Antud töö panustab haiguste tuvastamise meetodi arendamisele. Eesmärk on tuvastada liigesed, mille liikumine eristub tervete inimeste ja Parkinsoni põdevate inimeste puhul enim. Selle info põhjal oleks teada, millistele liigestele Parkinsoni diagnoosimisel rohkem tähelepanu pöörata. Samuti võiks tulevikus olla võimalik avastada haiguste tunnuseid võimalikult varajases staadiumis ning ennetada või vähemalt aeglustada haiguse arenemist.

2. Kirjanduse ülevaade


2.1 Parkinsoni tõi

Parkinsoni tõi on üks sagedasemaid kroonilisi neuroloogilisi haigusi, mis avaldub kesk- ja vanemas eas. Seda esineb kogu maailmas, Eestis on kokku umbes 2500 Parkinsoni tõvega inimest. Üle 60 aasta vanuste hulgas esineb Parkinsoni tõbe umbes 1% inimestel. Kuigi 90% Parkinsoni tõvega inimestest on üle 60 aasta vanused, on ka neid, kellel diagnoositakse see haigus aktiivses tööeas. Osadel juhtudel võivad esmassümptomid ilmned juba enne 50. eluaastat. Parkinsoni tõve sümptomid kujunevad välja järk-järgult aastate jooksul. Sümptomid võivad varieeruda ja seega ei ole haiguspilt erinevatel haigetel ühesugune; ka haiguse progresseerumise kiirus erineb haigete vahel. Parkinsoni tõve iseloomulikeks nähtudeks, mille alusel haigust diagnoositakse, on liigutuste ulatuse vähenemine (hüpokineesia), liigutuste aeglus (bradükineesia), lihasjäikus (rigiidsus), värin (tremor), muutunud kehaasend ja tasakaaluhäired (posturaalne ebastabiilsus). Enamasti on sümptomid ühel kehapoolel rohkem väljendunud ja asümmeetria püsib kogu haiguse kulu jooksul. [4]

2.2 Up-and-Go test

Parkinsoni tõbe diagnoositakse erinevate meetodite abil. Üks neist meetoditest on *Up and Go* test. Ajaliselt mõõdetav *Up and Go* test on loodud selleks, et tuvastada tasakaaluprobleeme eakatel inimestel. [5] Test kujutab endast uuritava inimese tõusmist toolilt, 3 meetri kõndimist edaspidi, kindlas kohas ümber pööramist, tagasi toolini kõndimist ning istumist. Aega, mis selle jaoks kulub, mõõdetakse stopperiga. Praegused kliinilised uuringud näitavad, et vanurid, kellel kulub testi täitmiseks rohkem aega, kukuvad suurema tõenäosusega, kui vanurid, kes selle testi kiiremini

läbivad. Eakad inimesed, kes suurema tõenäosusega kukuvad, kalduvad ka selle testi ajal kukkuma, seega on see test hea vahend tuvastamiseks tasakaaluprobleeme. [6] Vanurid, kellel kulub testi sooritamiseks alla 20 sekundi, on võimelised täitma iseseisvalt igapäevaseid ülesandeid ning kõndima piisava kiirusega (0.5m/s). Samas vanurid, kellel kulub testi sooritamiseks vähemalt 30 sekundit või kauem, vajavad igapäevaste toimetustega suure tõenäosusega kõrvalist abi. [7]



Joonis. 2.1: Up and Go test. [1]

2.3 Varasemad uurimistööd

Paljud uuringud on kasutanud *Up and Go* testi tuvastamiseks Parkinsoni tõbe. Parkinsoni tõbe on väga raske diagnoosida ning kindlat meetodit, mis oleks väga hea täpsusega, veel leitud ei ole. Artiklis [8] on kasutatud *Up and Go* testi uuritavate parameetrite kogumiseks, peamiselt on analüüsitud aega ning kukkumiste arvu testi jooksul. Tulemusena selgus, et üle 70% juhtudel on võimalik selle testi parameetreid analüüsides tuvastada Parkinsoni tõbe. Parkinsoni tõbe diagnoosimiseks kasutatakse erinevaid meetodeid, palju erinevaid tehnoloogiaid ning mitmesuguseid vahendeid andmete kogumiseks. Parkinsoni tõbe tuvastamiseks analüüsitakse nii peen- kui ka jämemotoorikat. Tänapäeval on järjest enam hakatud kaasama ka masinõppe meetodeid, sealhulgas ka närvivõrke.

Artiklis [9] on võrreldud liikumise massi parameetreid *Up and Go* testi vältel Parkinsoni põdevate ning tervete inimeste vahel. Mõiste liikumise mass iseloomustab seda, kui palju ning kui sujuvalt liigesed liiguvad. Liikumise massi parameetrid on trajektoori mass, kiirenduse mass, kombineeritud eukleidiline kaugus ning liikumise aeg. Liikumise massi elemendid iseloomustavad, kui palju ning kui sujuvalt kindel

liigutus toimub. Antud töös selgus, et erisusi parameetrite vahel on märgata ning kõige sagedamini eristas Parkinsoni tõvega inimesi tervetest kiirenduse massi parameeter, ka teised parameetrid eristasid PD patsiente tervetest paljudel juhtudel. Töös tuuakse ka välja, et jätkuvalt oleks vaja täpsustada, milliste liigeste liikumisparameetrite alusel oleks võimalik tuvastada Parkinsoni tõbe paremini.

Magistritöös [10] on analüüsitud erinevusi kehahoiakus ja ajalistes parameetrites kõndimise alustamisel Parkinsoni tõvega patsientidel ning võrreldud neid parameetreid tervete eakaaslastega. Samuti analüüsiti kõnnikiirust ja subjektiivselt tajutavaid kõnniraskusi ning võrreldi ka neid parameetreid tervete ning Parkinsoni põdevate inimeste vahel. Tulemustena toodi välja, et erinevusi esines kõndimise alustamisel posturaalsetes parameetrites vaid parema põlve- ning vasaku puusaligese osas, milles Parkinsoni põdevatel inimestel ilmnis suurem liigutusamplituud. Seismisasendi ja kõndimise alustamise puhul ilmnis Parkinsoni tõvega inimestel pea ulatuslik anterioorses suunas (ehk ettepoole) liikumine. Ajalistes parameetrites erinevust ei leitud. Parkinsoni põdevad inimesed tundsid ka ise, et neil esineb kodus ning väljas liikumisel probleeme. Töö jaoks vajalikud andmed olid kogutud Microsoft Kinect sensori abil ning kokkuvõttes toodi ka välja, et selle täpsus sagitaaltasapinnas posturaalsete parameetrite hindamisel on kaheldav.

[11] on kasutatud närvivõrgumudelit Parkinsoni tõvega inimeste klassifitseerimiseks tervetest inimestest. Mudelile anti ette erinevad tunnused – baastunnused (aeg, sammude arv minutis, sammu pikkus, kõndimise kiirus) ja erinevad kineetilised tunnused (pahkluu, põlve ja puusa nurgad ning maksimaalsed venitusasendid, sammude jõutugevust) Tulemustest selgus, et kõiki parameetreid kombineerides oli võimalik kõige paremini klassifitseerida Parkinsoni tõvega inimesi tervetest.

[12] ning [13] kasutavad andmete kogumiseks sammude jõutugevust maapinna suhtes mõõtvate vahendite abi, esimese artikli puhul klassifitseeritakse andmeid erinevate masinõppemeetoditega, näiteks k-keskmise naabri meetodi ja otsustuspuude meetodiga. Teise artikli puhul kasutatakse närvivõrke, tulemusi võrreldakse ka teiste meetoditega ning tuuakse välja, kuidas võiks arendada närvivõrgumudelit, et saada paremaid tulemusi.

Parkinsoni tõve tuvastamiseks on loodud ka isegi mobiilirakendus. [14] See rakendus koosneb testidest, mille puhul peab inimene tegema erinevaid liigutusi

mobiili ekraanil ning nende liigutuste tegemist analüüsitakse ja tuvastatakse haiguse olemasolu või puudumine. Selle töö puhul kasutati samuti tehisnärvivõrke.

2.3.1 Tallinna Tehnikaülikoolis tehtud tööd

Magistritöö [15] analüüsib käesoleva tööga samu Parkinsoni tõvega ning tervete inimeste andmeid ning pakub välja laiendatud parameetrite kogumi, millel on kõrgem diskrimineeriv võimsus Parkinsoni tõve klassifitseerimisel kui tavapärastel meetoditel. Magistritöös lisatakse igale sammule liikumise massi parameetrid. Töö käigus võrreldi baasklassifikaatoreid, mille ainsaks sisendiks on aeg ning töö raames loodud klassifikaatoreid, mille sisendiks on liikumise massi parameetrid. Tulemustena toodi välja, et aeg ei ole kõrgeima diskrimineerimisvõimega. Liikumise massi parameetrid klassifikaatori sisendina kasutades on võimalik ületada vaid ajalisel kestusel põhineva klassifikaatori tootlust. Oma bakalaureusetöös [16] arendas sama üliõpilane välja süsteemi, mis analüüsib inimese kõnnakut, eristab üksikuid samme ning leiab sammude parameetrid. Selle süsteemi rakendusvaldkond oli samuti Parkinsoni ning Alzheimeri haigete diagnoosimine.

Parkinsoni diagnoosimiseks vajalike meetoditega on tegelenud ka teised Tallinna Tehnikaülikooli tudengid. Peenmotoorika põhiselt on loodud meetod [17] bakalaureusetöös, mille eesmärk on käekirja analüüsidest tuvastada Parkinsoni tõvega inimesi. Magistritöös [18] on samuti uuritud parameetreid, mis on leitud lause kirjutamise testi abil, nende abil on koostatud samuti erinevad klassifikaatorid ning leitud parimad, mille abil diagnoosida Parkinsoni. Ka magistritöö [19] uurib käekirja parameetreid. Töö eesmärk oli selgitada välja parameetrid, mis on suurima diskrimineerimise võimega. Lisaks käekirja alusel parameetrite leidmisele, on uuritud ka Luria vahelduvate seeriaste testi põhjal leitud parameetreid, mille põhjal tuvastada Parkinsoni. [20] Luria vahelduvate seeriaste testi puhul peab patsient joonistama üksteise järel kaks vahelduvat kujundit ning seda 5-7 korda. Samuti on tegeletud Luria vahelduvate seeriaste testi parameetrite analüüsimisega magistritöös [21].

2.4 Pingutus

Raamatu [22] eesmärk on simuleerida inimese liigutusi virtuaalmaailmas optimeerimise baasil loodud lähenemisega liigutuste ennustamiseks. Selleks on loodud mudelid igale jäsemele, mille eesmärk on simuleerida inimese liigutusi. Seal on toodud välja mõiste "pingutus" (i.k *effort*). Pingutusena mõõdetakse kumulatiivset üleminekut liigese algolekust lõppolekusse. Algolek ei sõltu oleku mugavusest. Järelikult sõltub pingutus palju liigete esialgsest asendist ning on kõige märkimisväärsem valitud sihtpunktide seerias, kui kehahoiak muutub ühest punktist teise üleminekul.

$$f_E(q) = \sum_{i=1}^n \gamma_i (q_i - q_i^{initial})^2, \quad (2.1)$$

kus γ_i tähistab igale liigesele lisatud kaalu.


2.5 Töös kasutatavad meetodid ja tehnoloogia

Antud magistritöö andmed on kogutud Microsoft Kinect sensori abiga. Selle töö puhul oli tähtis, et andmetena kogutaks liigete koordinaadid ja Kinect sensor võimaldas sellist lähenemist. Tänapäeval liigutakse selles suunas, et inimkeha koordinaate oleks võimalik leida tavalisi kaameraid kasutades ning antud töös loodud meetodis võiks ka tavakaamerate abil salvestatud andmeid kasutada.

Microsoft Kinect sensor

Kinect sensor on pikliku kujuga seade, mis seisab väikesel platvormil ja mida saab asetada lauale või statiivile. Seadmel on RGB kaamera, sügavussensor ja mitu mikrofoni. [23]

Nii video- kui ka sügavussensoril on 640x480-piksliline resolutsioon ja need võimaldavad salvestada 30 kaadrit sekundis [24]. Kinecti sügavussensori ulatus on minimaalselt 800mm ja maksimaalselt 4000mm. Kinect kasutab infrapuna kaamerat, seega näeb ka läbi klaasi, kuid sensorit ei saa selle tõttu kasutada otsese päikese valguse käes. Skeleti andmete koordinaatsüsteem on 3D süsteem, mille väärtused on meetrites [25]. Kinect sensori skeleti andmed koosnevad inimese kehal olevate punktide koordinaatidest.



Joonis. 2.2: Kinect sensori poolt väljastatav skelett. [2]

Interpoleerimine

Interpolatsioon on lõplikus arvus punktides antud funktsiooni jätkamine nende punktide vahele. Olgu lõigul $[a,b]$ antud $n+1$ punkti

$$a = x_0 < x_1 < \dots < x_n = b \quad (2.2)$$

(interpolatsioonisõlmed). Interpolatsioonisõlmed moodustavad lõigul $[a,b]$ nn võrgu. Peale selle, olgu $f(x)$ mingi funktsioon, mille väärtused interpolatsioonisõlmedes on teada, st on antud $f(x_0), \dots, f(x_n)$. Oletame, et funktsiooni f väärtused sõlmede vahel ei ole teada. Interpolatsiooni ülesanne on järgmine: leida mingisse tuntud funktsioonide klassi kuuluv funktsioon $\Phi(x)$, mis on määratud lõigul $[a,b]$ nii, et ta langeks kokku funktsiooniga $f(x)$ interpolatsioonisõlmedes, st

$$\Phi(x_j) = f(x_j), j = 0, \dots, n \quad (2.3)$$

[26]

Klassifitseerimismeetodid

Klassifikatsioon on meetod, mille abil ennustatakse andmepunktide klassi kuuluvust. Klassideks nimetatakse kategooriat või sihtrühma, kuhu andmepunkt kuulub. Klassifikatsiooni ülesandeks on luua funktsioon, mis teisendab sisendväärtused (X) diskreetseteks väljundväärtusteks (y). [27]

K-lähima naabri meetod

K-lähima naabri meetodi puhul salvestatakse treeningandmed n -dimensioonilisse ruumi. Uue andmepunkti puhul analüüsitakse k lähimal asuvat treeningandmepunkti ning uuele andmepunktile seatakse vastavusse klass, mis kuulub kõige rohkematele k lähimatele naabritele. [27]

Otsustuspuu

Otsustuspuu koostab mudeli puu kujul. Selle puhul luuakse reeglid, mille aluseks on üks sõlm, mis jaguneb erinevateks harudeks (oksteks), mis omakorda tipnevad sõlmedega, millest igaüks võib edasi hargneda või lõppeda lehega. Iga sõlme juures on test või küsimus, mis määrab, millist haru mööda edasi minna kuni jõutakse leheni ehk otsuseni, mis klassi valitud andmepunkt kuulub. [28]

Juhuslik mets

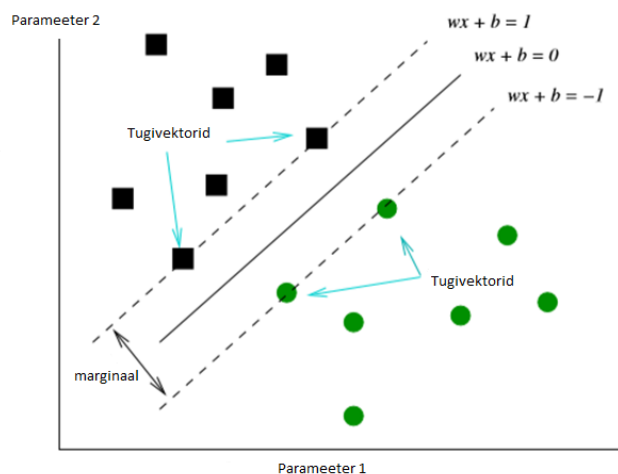
Ühe otsustuspuu loomine pakub lihtsat mudelit vaadeldava probleemi lahendamiseks, kuid tihtipeale jääb see liiga lihtsaks või spetsiifiliseks. Varasemad andmekaeve kogemused on näidanud, et mitmete mudelite koostöö annab paremaid tulemusi. Mitme mudeli (nt otsustuspuu) kombineerimine ühte mudelite kogumisse annab otsustuspuude metsa. [28]

Naiivne Bayesi klassifikaator

Naiivne Bayesi klassifikaator eeldab, et iga tunnus on teistest tunnustest sõltumatu. Klassifikaator põhineb Bayesi teoreemil, mille puhul leitakse väljundi tõenäosus arvestades sisendit. Sisend on tõestus ja väljund hüpotees. [29]

Tugivektor-masin

Tugivektor-masin otsib nii-öelda tugivektoreid, mis on klasside äärealadel asuvad vaatlused, mille abil on võimalik klasse omavahel eristada. Klasside vahele jäävaid alasid nimetatakse klassidevaheliseks marginaaliks. Tugivektorite abil identifitseeritakse kahes dimensioonis klasse eraldav sirge joon (vt joonist 2.3). Algoritmiga otsitakse maksimaalset marginaali erinevate klasside vahel. [28]



Joonis. 2.3: Tugivektor-masin.

Adaboost

Boosting meta-algoritm on efektiivne, kiire ja lihtsasti kasutatav lähenemine mudelite ehitamisele. Üks populaarsemaid versioone on adaptiivne *boosting* (*AdaBoost*). *Boosting* algoritmid ehitavad andmestiku pealt mitu erinevat mudelit mõne teise õppimisalgoritmi põhjal, mis ei pruugi olla eriti hea õppija. *Boosting* seostab algandmetes kaalud vaatlustega ja suurendab kaalusid nendel vaatlustel, mida on raske täpselt modelleerida. Ehitatakse jada mudeleid ning peale iga mudeli ehitamist muudetakse kaalusid nii, et tõsta osatähtsust vaatlustel, mida on raskem klassifitseerida. Mudeli rakendamisel klassifitseerib iga alamudel (puu) vaatluse ning lõpptulemus leitakse kõigi alammudelite ennustuste keskmisena. [28]

Gradient boost

Gradient *boost* klassifitseerija on *Adaboost* meetodi kombinatsioon kaalutud minimaliseerimisest, peale mida iga klassifitseerija ja kaalutud sisendid arvutatakse uuesti. Gradient *boost* meetodi eesmärk on minimiseerida treeninggrupi teadaoleva klassi väärtuse ning ennustatava klassi väärtuse erinevust. [30]

Ristvalideerimine

Ristvalideerimine (inglise k. *cross-validation*) on mudeli statistiline verifitseerimismetod, mis võimaldab hinnata seda, kuidas statistiline mudel sobib kokku sõltumatu valimiga. Enamasti kasutatakse seda ennustavate mudelite puhul, kui tahetakse vaadata, kui hästi mudel saab hakkama ennustamise probleemiga, kasutades eelnevalt teadmata andmed. [31] Näiteks otsustuspuu puhul kasutatakse väikest osa õpiandmetest (näiteks 10%) testandmetena - neid puu konstrueerimise faasis ei kasutata. Valmis puud testitakse seejärel varem kõrvale pandud testandmete peal, et näha, kas saadud puu suudab klassifitseerida vaid õpiobjekte või on see piisavalt korrektne ka tundmatute objektide korral. [32] Tihti jagataksegi õpihulk juhuslikult 10-ks ning konstrueeritakse 10 erinevat otsustuspuud, valides iga kord erineva testkümnendiku. Edasi hinnatakse iga puu klassifitseerimisviga oma testandmetel ning edasitöötamiseks valitakse vähima veaga puu.

Närvivõrgud

Tehisnärvivõrk on väga lihtsustatud bioloogilise närvivõrgu mudel. Tema tööalgoritm on tulnud bioloogiliste närvivõrkude tööprintsibist. Tehisnärvivõrgu mudeli abil üritatakse simuleerida bioloogilise närvivõrgu mudeli tööd. Närvivõrk on andmetöötlussüsteem, mis koosneb suurest arvust lihtsatest ja omavahel tugevalt seotud tehisneuronitest. Tehisneuronid on ühendatud arhitektuuri, mis on võetud inimese ajukoorest. [33]

Aktiviseerimisfunktsioon Aktiviseerimisfunktsioon on matemaatiline võrrand, mis määrab närvivõrgu väljundi. Igale neuronile lisatakse see funktsioon ning see leiab, kas neuron tuleb aktiveerida või mitte arvestades iga neuroni sisendit ning leides, kas see sisend on mudeli ennustuse loomisel vajalik. Samuti aitavad

aktiveerimisfunktsioonid normaliseerida iga neuroni väljundit. [34]

Regressioon

Regressioonianalüüs on ennustava mudeldamise tehnika, mis uurib sõltuvate ja sõltumatute muutujate omavahelist suhet. Seda tehnikat kasutatakse ennustamiseks, ajaseeriade mudeldamiseks, leidmaks erinevate muutujate omavahelisi sõltuvusi. Näiteks kiiresti sõitmise ning autoõnnetuste suhet on võimalik analüüsida regressiooni abil.[35]

Aditiivne viga

Aditiivne viga on viga, mis lisatakse õigele väärtusele ning mis ei sõltu õigest väärtusest endast. Seega mõõtmistulemus on summa õigest väärtusest ja aditiivsest veast.

$$u = U + \epsilon, \tag{2.4}$$

kus

- u on mõõtmistulemus
- U on õige väärtus
- ϵ on aditiivne viga, mis kuulub samasse füüsilisse dimensiooni nagu U [36]

3. Implementatsioon

3.1 Andmed

Antud töös kasutatavad kõnnaku andmed on kogutud nii Parkinsoni tõvega kui ka Parkinsoni tõveta inimestelt. Inimeste vanus ning sugu ühtivad testgrupil ning Parkinsoni tõvega inimeste grupil. Andmed on kogutud varasema töö raames kasutades Microsoft Kinect sensorit.[9] Andmete kogumisel paluti uuritavatel sooritada *Timed Up and Go* test, mille käigus inimene esmalt istub toolil, seejärel tõuseb püsti, kõnnib 3-4 sammu edasi sensori suunas, pöörab ringi ning kõnnib tagasi toolini ning istub sellele. Testi ajal oli sensor asetatud 0.9 meetri kõrgusele maapinnast ning 3.35 meetri kaugusele toolist, millel uuritav algselt istus. Lähim punkt sensorile, kuhu inimene testi vältel liigub, asub 1.27 meetri kaugusel.

Parkinsoni tõvega inimesi, kelle kõnnakut analüüsiti, oli 23 ning terveid inimesi, kes kuulusid kontrollgruppi, 20. Andmed on csv-failid, millest iga fail koosneb ühe inimese liigeste (i.k. *joint*) x-,y- ja z-koordinaatidest, aja tähisest ning terapeutide poolt manuaalselt märgitud sammu faasi märkest. Iga fail koosneb maksimaalselt kolmest *Up and Go* testist. Iga inimese kohta on selliseid faile kokku üks kuni neli, mis on salvestatud kolmel erineval nädalal.


3.2 Andmete eeltöötlus

Esialgsed andmed, mida töös kasutatakse, on csv-failidena. Selleks, et andmeid käesolevas töös kasutada, on vaja leida üksikud sammud, mille puhul inimene kõnnib Kinect sensori poole ning kõik tema liigesed on sensori vaateväljas.

Antud töös analüüsitakse vaid uuritavate kõnnakut, täpsemalt selle üksikuid samme. Selleks, et tuvastada testi vältel toimunud sensori suunas tehtud sammud,

on eemaldatud andmetest *Up and Go* testi faasid, mille puhul inimene kõnnib tooli suunas, istub ja tõuseb ning teeb ümberpöördeid. Selleks on arvestatud ka varasemalt terapeudi poolt manuaalselt märgitud faase.

Microsoft Kinect sensor võimaldab salvestada vaid 30 kaadrit sekundis. Selleks, et oleks võimalik leida iga inimese iga sammu puhul sarnast alguspunkti, on interpoleeritud kõik inimese liigete koordinaadite väärtused kogu kõnnaku vältel. Selle meetodi rakendamisel on 30 kaadrist sekundis saadud poole rohkem kaadreid ning on võimalik leida erinevatel inimestel sarnasemaid sammu faase. Kirjeldatud on ka sensori abil salvestatud liigete koordinaatide korrektsuse nõuded. Korrektselt salvestatud liigete koordinaadid asuvad inimkeha suhtes normaalsetel asukohtadel. Järgnevalt on toodud nõuded: pea peab asuma kõrgemal, kui õlgade keskpunkt, õlgade keskpunkt peab asuma vasaku ning parema õla vahel, parema ja vasaku õla vahe peab olema piisavalt suur, et vältida juhust, mil inimene pöörab. Samuti peab puusade keskpunkt asuma parema ja vasaku puusa vahel, parema ning vasaku puusa kaugus peab olema samuti kontrollitud. Pea ning pahklude kaugus ja põlve ning pahklude kaugus on samuti kontrollitud. Joonisel 3.1 on toodud välja nii korrektne inimkeha kui ka juhust, kus programmis implementeeritud nõuded liigete koordinaatidele pole täidetud.



Joonis. 3.1: Vasakul korrektsed liigete koordinaadid. Paremal mitte korrektsed liigete koordinaadid.

Iga üksiku kaadri kohta on tehtud kontroll ning peale kontrolli vaadeldakse, kas toimub terve samm vastavalt nõuetele ning kui toimub, siis salvestatakse iga inimese kõigi üksikute kontrollitud sammude andmed uuesti csv-failidesse hilisemaks analüüsiks. Iga sammu jaoks on lisatud failile veerg, mis kirjeldab, kas toimub vasak või parem samm ning veerg, mis märgib sammu järjekorranumbrit. Peale andmetöötlust jäid alles 19 testgrupi inimese sammude andmed ning 21 Parkinsoni

tõvega inimese sammude andmed. Iga inimese kohta on alles 1-4 faili, kokku on testgrupi kohta 41 faili, mis kirjeldavad inimeste nii parema kui ka vasaku jalaga alustatud samme ning Parkinsoni tõvega inimeste kohta 54 faili. Iga inimese puhul ei pruugi olla olemas mõlema jalaga alustatud samme, sest võis juhtuda, et andmed olid ilma vigadeta vaid ühe sammu puhul või mitme sama jalaga astunud sammu puhul, seda on arvestatud ka töö hilisemas etapis.

3.3 Parameetrite valik

Edasise töö käigus leitakse parameetrid, mida kasutatakse inimeste klassifitseerimiseks terveteks ja Parkinsoni haigust põdevateks. Raamatus [22] on välja toodud mudelid inimese liigestele, mis kirjeldavad liigeste pingutust (i.k. *effort*) liigutuse vältel. Siin töös ongi loodud igale jäsemele mudel, mis seda pingutust kirjeldab ühe sammu vältel. Pingutuse mudel on defineeritud antud töös järgnevalt:

$$f_E(q) = (q_i - q_i^0)^2, \quad (3.1)$$

kus q_i tähistab ühe liigese nurka radiaanides liigutuse lõppfaasis ning q_i^0 tähistab liigese nurka liigutuse algfaasis. Antud töös on liigutuse algfaasiks võetud sammu algus või sammu keskpunkt ning liigutuse lõppfaasiks vastavalt sammu keskpunkt või sammu lõpp.

Ühe liigese nurga arvutamisel on võetud arvesse kolme liigese 3D koordinaadid, antud töös on proovitud erinevaid nurgakombinatsioone, et näha, milliste nurkade abil on klassifitseerimise tulemus parim. Iga nurga arvutamise jaoks on koostatud 3D koordinaatidest 3D vektorid. Nurki arvutatakse kahe 3D vektori vahel järgnevate valemite järgi:

$$\vec{u} \cdot \vec{v} = \|\vec{u}\| \cdot \|\vec{v}\| \cos\theta \quad (3.2)$$

$$\vec{u} \cdot \vec{v} = u_x v_x + u_y v_y + u_z v_z \quad (3.3)$$

$$\cos\theta = \frac{(\vec{u} \cdot \vec{v})}{(\|\vec{u}\| \cdot \|\vec{v}\|)} \quad (3.4)$$

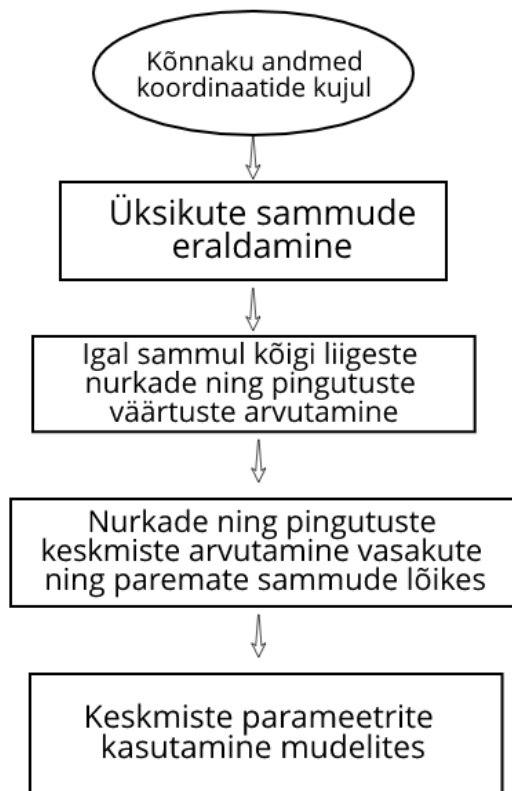
Järgnevalt on toodud välja tabelis 3.1, milliseid liigeste vahelisi nurki on töö edasises etapis kasutatud.

Liiges, millele arvutatakse nurk	variant 1	variant 2	variant 3
puusade K	V põlv, P põlv	V küünarnukk, P küünarnukk	P õlg, P põlv
selgroo K	puusade K, õlgade K	pea, puusade K	V õlg, P õlg
õlgade K	V õlg, parem õlg	V küünarnukk, P küünarnukk	pea, puusade K
pea	V õlg, parem õlg	V küünarnukk, parem küünarnukk	P õlg, P põlv
V õlg	õlgade K, V puus	V küünarnukk, V puus	V küünarnukk, V puus
V küünarnukk	V õlg, V ranne	V õlg, V ranne	V õlg, V ranne
V ranne	V küünarnukk, V käsi	V küünarnukk, V puus	V küünarnukk, V käsi
P õlg	õlgade K, P puus	puusade K, õlgade K	P küünarnukk, P puus
P küünarnukk	P õlg, P ranne	P õlg, P puus	P õlg, P ranne
P ranne	P küünarnukk, P käsi	P küünarnukk, P puus	P küünarnukk, P käsi
V puus	selgroo K, õlgade K	P puus, P õlg	V õlg, V põlv
V põlv	puusade K, V pahkluu	V puus, P põlv	puusade K, V pahkluu
V pahkluu	V põlv, V jalg	V põlv, parem pahkluu	V põlv, V jalg
P puus	selgroo K, õlgade K	P õlg, P põlv	P õlg, P põlv
P põlv	puusade K, P pahkluu	P puus, V põlv	puusade K, P pahkluu
P pahkluu	P põlv, P jalg	P põlv, P jalg	P põlv, P jalg

Tabel. 3.1: Erinevad nurkade kombinatsioonid liigeste vahel. P - parem liiges, V - vasak liiges, K - keskpunkt

Iga inimese kõigi failide (üks fail võib koosneda mitmest sammust) kohta arvutatakse igale liigesele nii paremate kui ka vasakute sammude ajal selle liigese ja kahe teise liigese vaheline nurk sammu alguses ja keskel või sammu keskel ja lõpus. Iga faili puhul on sammude arv, mis inimene testi käigus tegi ning mis esmasest andmetöötlastest alles jäi, erinev. Seetõttu leitakse nurkade keskmine väärtus kõigi nii paremate kui ka vasakute sammude vältel, mis salvestatakse *pandas* teegi andmehulgana (i.k *dataframe*) csv-failidesse.

Joonisel 3.2 on esitatud lihtsustatud kujul, kuidas andmeid on töödeldud.



Joonis. 3.2: Andmete töötlus.

Iga liigese kohta luuakse csv-fail, mis sisaldab kõigi inimeste kõigi failide põhjal saadud liigese nurki. Lisas A on toodud näited ühe liigese csv-faili struktuurist. Samuti arvutatakse iga liigese jaoks selle liigese pingutus iga sammu vältel kasutades varasemalt kirjeldatud pingutuse mudelit. Ka pingutuse väärtuse jaoks leitakse kõikide sammude keskmine pingutuse väärtus ning see salvestatakse samuti csv-faili. Pingutuse väärtuste näidisfail on näha lisas B. Peale nurkade ning pingutuse väärtuste keskmiste leidmist sammude vältel, on alles jäänud 70 kõnnaku andmed,

millest 36 kirjeldavad tervete inimeste samme ning 34 Parkinsoni põdevate inimeste samme, sealhulgas koosnevad tervete inimeste andmed 19 erinevalt inimeselt saadud andmetest ning Parkinsoni põdevate inimeste andmed 19 erinevalt inimeselt leitud andmetest. Seega algsest 95 failist on alles jäänud 70, mis kirjeldavad vasakute ja paremate sammude keskmiseid omadusi: nurki ning pingutusi.

3.4 Mudelite koostamine

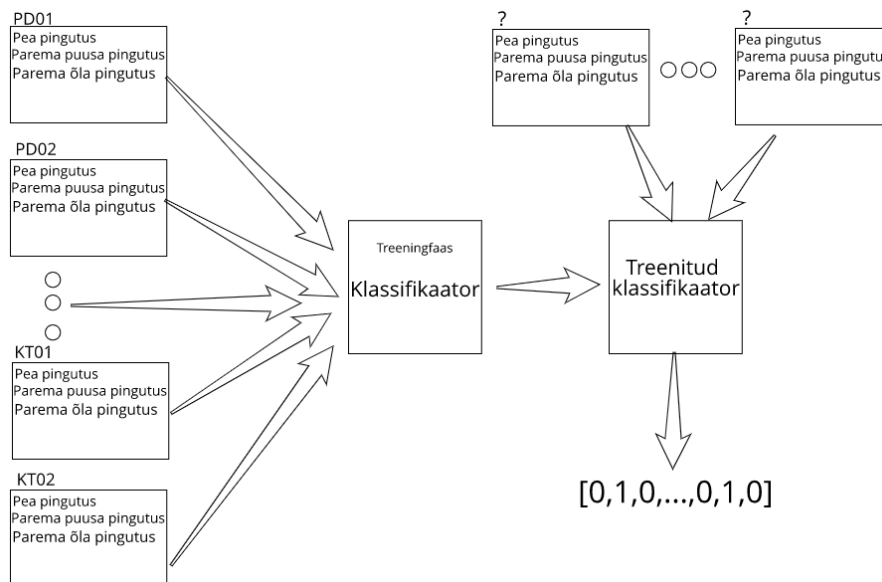
3.4.1 Klassifikatsioon

Töö järgmises etapis oli eesmärk leida liigesed, mille liikumine eristub tervete ning Parkinsoni põdevate inimeste vahel enim. Nende liigete pingutuste väärtuste põhjal klassifitseeritakse inimesi kontrollgruppi kuuluvateks ehk terveteks ning Parkinsoni põdevateks inimesteks. Antud töös on kasutatud mitmeid klassifitseerimismeetodeid ning võrreldud nende tulemusi omavahel. Nendeks meetoditeks on *sklearn* teegi K-lähima naabri klassifikaator, "Naiivne"Bayesi klassifikaator, otsustuspuu, juhuslik mets, gradient boost, adaboost ning tugivektor klassifitseerija. K-lähima naabri meetodi puhul on K valitud 5, ehk selle klassifitseerimismeetodi puhul arvutatakse välja testandmepunktide kaugus treenitud andmepunktidest ning seejärel leitakse 5 kõige lähemal asuvat andmepunkti ning nende põhjal leitakse, millisesse klassi (kas terve või Parkinson) uus testandmepunkt kuulub. Juhusliku metsa klassifikaatori puhul on maksimaalseks sügavuseks selles töös määratud 2. Gradient boostingu meetodit kasutades on töös valitud hindaja (i.k *estimators*) 200 ja õpisamm (i.k *learning rate*) 0.1. Varasemalt prooviti läbi ka muid parameetreid, kuid antud parameetrite kasutamisel andsid vastavad klassifikaatorid rohkem üle 70% täpsusega tulemusi. Adaboost klassifikaatoril on samuti õpisammuks määratud 200. Meetodid on valideeritud ristvalideerimise meetodil, mille puhul K, ehk mitu korda andmed treening- ning testandmeteks jagatakse, on valitud 10. [37]

Andmed, mis antakse ette klassifikaatorile on kõigi inimeste kolme liigese vasakute või paremate sammude keskmised pingutuste väärtused, nii tervete kui ka Parkinsoni põdevate. Töös proovitakse läbi kõik variatsioonid liigestest, mis on võimalikud ning jagatakse need andmed juhuslikult test- ning treeningandmeteks, vastavalt 20% ja 80%. Test- ning treeningandmed koosnevad iga inimese kolmest sisendväärtusest ehk

kolme liigese pingutuse väärtusest ning neile vastavast väljundväärtusest ehk klassist, mis on märgitud vastavalt 0 või 1, 0 tähistab tervet ning 1 Parkinsoni põdevat inimest. Sisendväärtused on esmalt normaliseeritud *sklearn* teegi *StandardScaler* funktsiooni kasutades, et kõik väärtused asuksid ühel skaalal. Töös on eesmärk leida liigesed, mille parameetreid kombineerides saadakse kõige parem diskrimineerimisvõime.

Peale klassifitseerimist leitakse, milline meetod ning millised liigesed annavad kõige paremaid tulemusi, ehk millistel juhtudel klassifitseeritakse testgruppi kuuluvad inimesed õigesti. Selleks kasutatakse *sklearn* teegi *accuracy_score* funktsiooni, millele antakse ette teadaolevad klassid ehk 0 või 1 ning klassifitseerimismeetodiga leitud klassid.

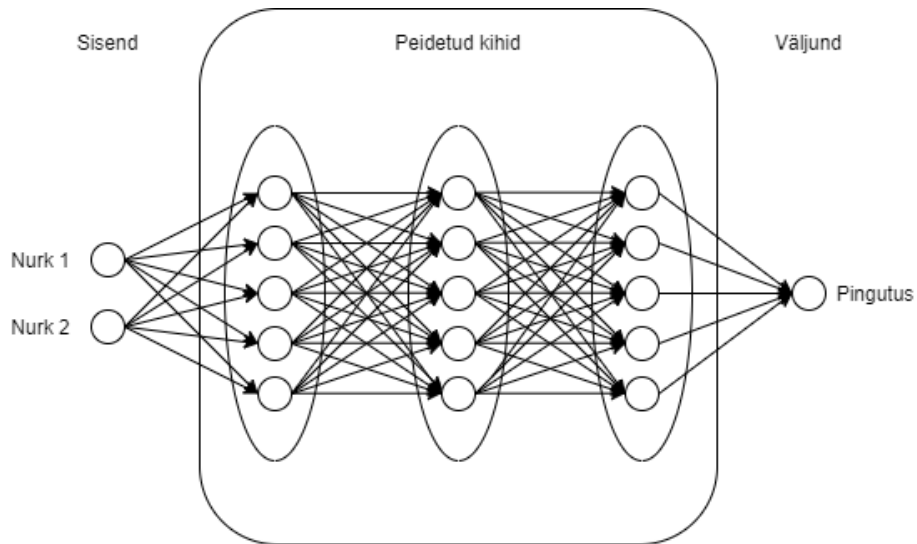


Joonis. 3.3: Üks kõigist klassifikaatoritest, mis klassifitseerib kolme liigese parameetrite alusel inimesi Parkinsoni põdevateks või terveteks. PD- Parkinson (1), KT - terve (0).

3.4.2 Närvivõrgu mudel

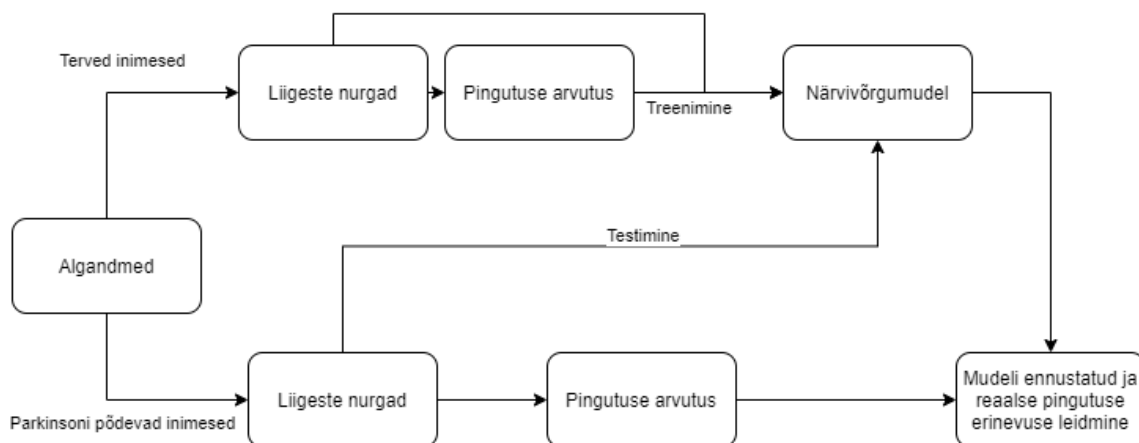
Töö peamine eesmärk oli koostada mudel, mille abil on võimalik tuvastada Parkinsoni tunnuseid. Selleks on loodud närvivõrgumudelid, mis on treenitud kasutades tervete inimeste kõnnaku andmeid. Mudelid on loodud Microsoft Kinect sensoriga tuvastatavatele liigestele: käed, küünarnukid, õlad, pea, õlgade keskpunkt, selgroo keskpunkt, puusad, puusade keskpunkt, põlved ning pahklud. Mudelid on loodud nii vasaku sammu kui ka parema sammu parameetrite kohta eraldi.

Mudelid on koostatud kasutades *tensorflow* teeki, iga mudel koosneb kolmest peidetud kihist ning iga kiht koosneb viiest neuronist. 3.4 Mudeli aktiveerimisfunktsioonina on kasutatud mittenegatiivset lineaarfunktsiooni (i.k *Rectified Linear Unit* ehk ReLu). Mudeli kompileerimisel on kasutatud Nadam (Nesterov Adam optimeerija) optimeerijat.



Joonis. 3.4: Töös loodud närvivõrgu mudel.

Mudelite trenimisel on mudeli sisendiks tervete inimeste jäsemete omavahelised nurgad.

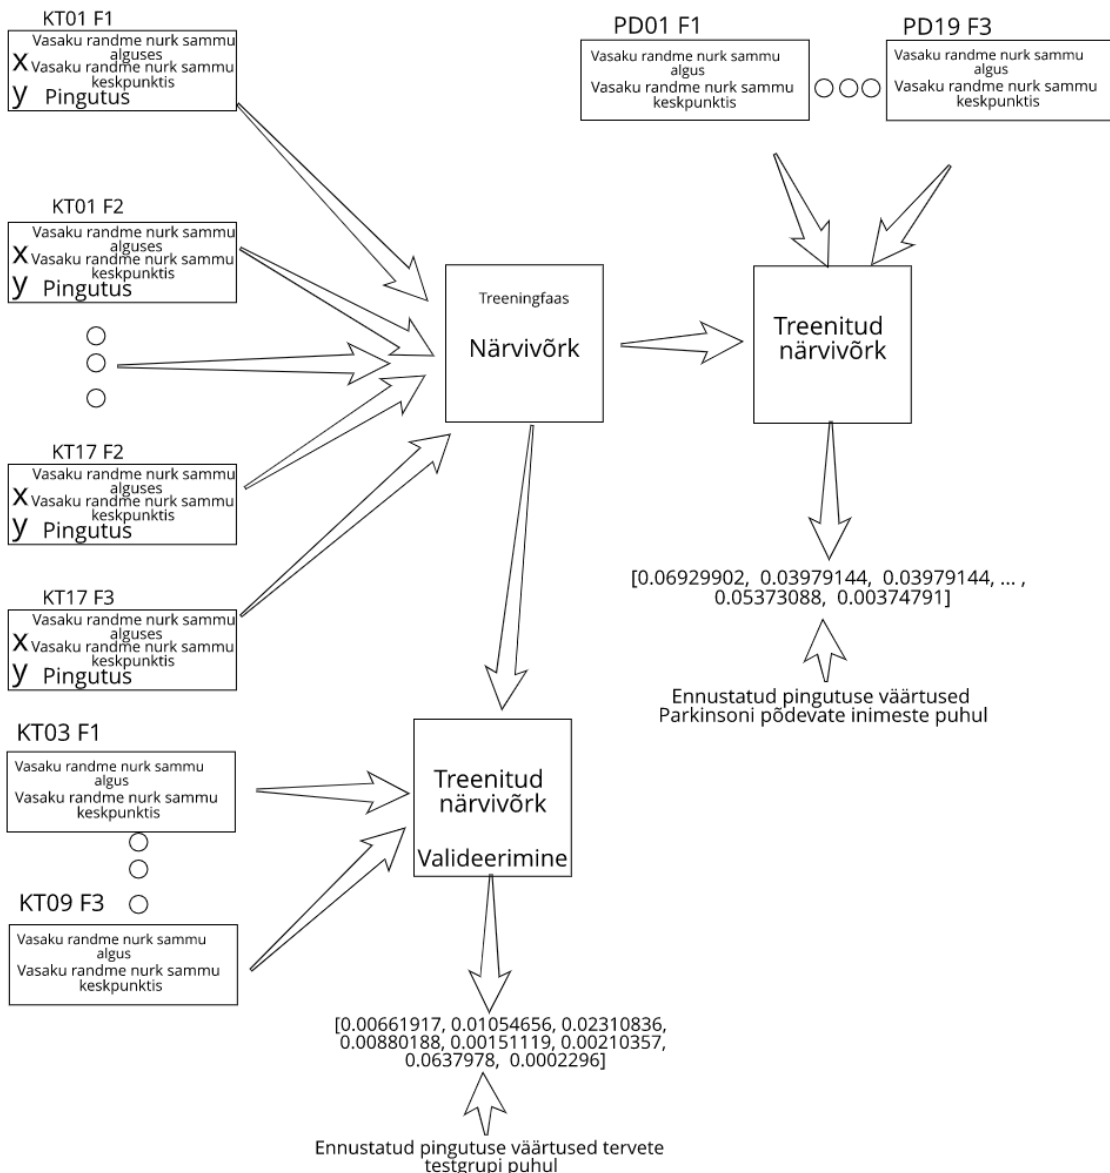


Joonis. 3.5: Mudeli struktuur.

Nurgad, mis kirjeldavad liigeseid, on valitud klassifitseerimistulemuste põhjal ning on toodud välja ka klassifitseerimise tulemuste peatükis tabelis 4.3. Iga inimese iga kõnnaku (ehk algselt ühe faili) kohta on sisendiks kaks jäsemetevahelist nurka.

Ka närvivõrgumudeli puhul on vaadeldud sammu kahte erinevat faasi nagu ka klassifitseerimise puhul. Mudeli sisendi esimene argument on liigese nurk, ühe nurgana on arvutatud sammu algus- või keskpunkti keskmine liigese nurk, teine nurk sammude keskpunkti või lõpu keskmine liigese nurk. Mudeli väljund on liigese pingutus, mis on treeningfaasis samuti mudelile teada. Antud juhul on tegemist regressioonianalüüsiga, pingutuse väärtus on numbriline, mitte diskreetne.

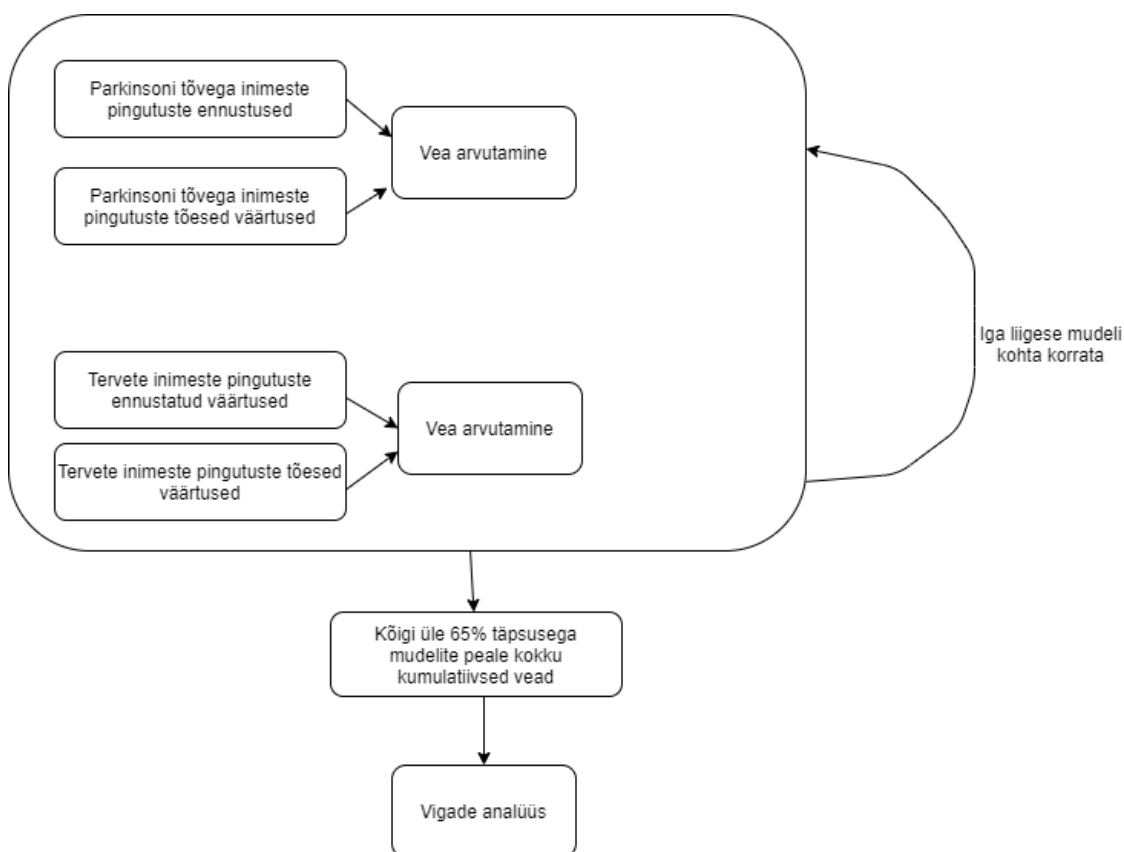
Järgneval joonisel 3.6 on antud meetodi üldine struktuur, joonis kirjeldab ühte mudelitest, mis on loodud ühe liigese pingutuste ennustamiseks. Selliseid mudeleid on kokku koostatud 64: vasaku jalaga tehtud sammu algfaasi ja keskmist faasi vaadeldes leiti 16 liigese liikumisparameetrid, parema jalaga tehtud sammu algfaasi ja keskmist faasi vaadeldes leiti liikumisparameetrid 16 liigesele, vasaku jalaga tehtud sammu keskmist faasi ja lõppfaasi vaadeldes leiti liikumisparameetrid 16 liigesele ja parema jalaga tehtud sammu keskmist faasi ja lõppfaasi vaadeldes leiti liikumisparameetreid 16 liigesele.



Joonis. 3.6: Üks närvivõrgumudelitest, mis on koostatud vasakule randmele. KT**F* tähistab tervet inimest ning tema ühte failidest, PD**F* tähistab Parkinsoni tõvega inimese faili.

Mudelite treenimisel oli sisendiks 80% tervete inimeste andmed, testgrupp koosnes ülejäänud 20% tervete inimeste andmetest, mille abil valideeriti mudelite täpsust. Sisendandmed olid esmalt normaliseeritud kasutades *sklearn* teegi *MinMaxScaler* funktsiooni. Mudelite täpsuse leidmiseks kasutati *sklearn* teegi "*explained_variance_score*" funktsiooni, mille sisenditeks olid testgruppi kuuluvate inimeste teadaolevat pingutuste väärtused ning mudeli poolt ennustatavad väärtused. Selle funktsiooni abil mõõdetakse erinevust teadaolevate tulemuste ning ennustatavate tulemuste vahel

regressiooniülesannete puhul.



Joonis. 3.7: Vigade leidmine ning nende põhjal mudelite valimine.

Treeningfaasi lõppedes tekkis kokku 64 mudelit, igale töös vaadeldud liigesele üks mudel, nii töös vaadeldud sammu esimese faasi kohta kui ka sammu teise faasi kohta. Töö edasises osas võeti aluseks vaid need mudelid, mille täpsus tervete inimeste testgruppi valideerides ületas 65%. Mudelitele anti sisendiks Parkinsoni tõvega inimeste sammude parameetrid ning leiti neile vastav pingutuse väärtus. Peale iga mudeliga pingutuse ennustamist väljasti ennustatud pingutuste väärtused ning leiti nende aditiivne viga võrreldes tegelike pingutuse väärtustega. Kõikide mudelite vead liideti kokku ning saadi kumulatiivne viga. Mudelid koostati nii sammu esimese faasi kui ka sammu teise faasi kohta. Kumulatiivne viga leiti ka tervete inimeste testgrupi igale liikmele. Töö viimases etapis võrreldi vigu omavahel ning leiti, kas Parkinsoni põdevatel inimestel on kumulatiivne viga suurem, kui tervetel inimestel. Lisaks leiti lävi, alla mille arvestati kumulatiivse veaga isik terveks ning üle mille klassifitseeriti ta Parkinsoni põdevaks.

4. Tulemused

4.1 Klassifikatsioon

Klassifitseerimise tulemustena on töös välja toodud klassifikaatorid, mille täpsus Parkinsoni põdevate ning tervete inimeste klassifitseerimisel on üle 70%. Tabelis 4.1 on toodud välja klassifikaator, milliste kolme liigese parameetrite kombineerimisel see klassifikaator koostati ning klassifikaatori täpsus. Samuti on tabelis märgitud, millise sammu ajal pingutus vastavale liigesele arvutati. Esimeses alltoodud tabelis on võetud aluseks sammu algusest keskpunktini arvutatud pingutuste väärtused vastavatel liigestel.

Klassifikaator	Liiges 1	Liiges 2	Liiges 3	Täpsus
Gradient boost	Parem pahkluu P	Puusade keskpunkt V	Pea P	71% (+/-21%)
Adaboost	Vasak pahkluu P	Selgroo keskpunkt V	Pea P	77% (+/-17%)
DT	Vasak puus P	Õlgade keskpunkt V	Parem puus P	77% (+/- 13%)
Gradient boost	Parem pahkluu P	Vasak õlg V	Pea V	79% (+/- 21%)
DT	Parem küünarnukk P	Vasak õlg V	Pea P	71% (+/- 11%)
Gradient boost	Parem küünarnukk P	Parem küünarnukk V	Pea P	72% (+/- 18%)
Gradient boost	Vasak küünarnukk P	Vasak ranne V	Pea P	71% (+/- 20%)
NB	Pea V	Vasak pahkluu V	Parem puus P	76% (+/- 17%)
DT	Parem pahkluu P	Parem küünarnukk P	Pea P	71% (+/- 19%)
Gradient boost	Parem pahkluu P	Parem küünarnukk P	Pea P	74% (+/- 17%)
Gradient boost	Vasak pahkluu P	Parem õlg P	Pea P	77% (+/- 21%)
Adaboost	Vasak pahkluu P	Parem põlv P	Pea P	74% (+/- 19%)

Tabel. 4.1: Klassifikaatorite täpsused erinevate liigeste parameetreid kombineerides, P - tähistab paremat sammu, V - vasakut. DT - otsustuspuu, NB - naiivne Bayesi klassifikaator.

Järgnevas tabelis on toodud välja sammu keskpunktist sammu lõpp-punktini

arvutatud liigete pingutuste väärtuste põhjal klassifitseerimise tulemused.

Klassifikaator	Liiges 1	Liiges 2	Liiges 3	Täpsus
KNN	Vasak õlg V	Selgroo keskpunkt V	Vasak ranne V	71% (+/- 17%)
DT	Vasak küünarnukk V	Selgroo keskpunkt V	Vasak ranne V	72% (+/- 18%)
NB	Parem õlg P	Selgroo keskpunkt V	Vasak pahkluu P	74% (+/- 19%)
KNN	Vasak küünarnukk V	Vasak õlg V	Parem puus P	79% (+/- 20%)
KNN	Vasak ranne V	Vasak õlg V	Vasak puus V	71% (+/- 17%)
KNN	Vasak ranne V	Vasak õlg V	Selgroo keskpunkt V	71% (+/- 17%)
Adaboost	Vasak põlv V	Parem õlg V	Parem põlv P	72% (+/- 16%)
DT	Vasak ranne V	Vasak küünarnukk V	Pea P	71% (+/- 18%)
DT	Parem põlv P	Parem puus V	Vasak pahkluu P	72% (+/- 18%)
Adaboost	Vasak ranne P	Pea V	Vasak pahkluu P	75% (+/- 19%)
DT	Parem ranne P	Vasak ranne P	Vasak pahkluu P	73% (+/- 17%)

Tabel. 4.2: Klassifikaatorite täpsused erinevate liigete parameetreid kombineerides, P - tähistab paremat sammu, V - vasakut. KNN - k-lähima naabri meetod, DT - otsustuspuu, NB - naiivne Bayesi klassifikaator.

Antud töös prooviti läbi erinevaid nurgakombinatsioone, ülaltoodud kaks tabelit vastavad liigete nurkadele, mis on toodud välja tabelis 4.3. Esimene veerg tähistab liigest, millele nurka arvutatakse ning teises veerus on liigesed, mille vahel nurk leitakse.

puusade keskpunkt	vasak küünarnukk, parem küünarnukk
selgroo keskpunkt	pea, puusade keskpunkt
õlgade keskpunkt	vasak küünarnukk, parem küünarnukk
pea	vasak küünarnukk, parem küünarnukk
vasak õlg	vasak küünarnukk, vasak puus
vasak küünarnukk	vasak õlg, vasak ranne
vasak ranne	vasak küünarnukk, vasak puus
parem õlg	puusade keskpunkt, õlgade keskpunkt
parem küünarnukk	parem õlg, parem puus
parem ranne	parem küünarnukk, parem puus
vasak puus	parem puus, parem õlg
vasak põlv	vasak puus, parem põlv
vasak pahkluu	vasak põlv, parem pahkluu
parem puus	parem õlg, parem põlv
parem põlv	parem puus, vasak põlv
parem pahkluu	parem põlv, parem jalg

Tabel. 4.3: Liigete omavahelised nurgad.

4.2 Närvivõrgumudel

Närvivõrgumudeli puhul on kasutatud kõnnaku parameetreid, mis on saadud nii vasaku kui ka parema sammu keskmistest väärtustest ja nii sammu esimest kui ka teist faasi analüüsid.


Mudelite, mis ületasid 65% täpsuse, põhjal leiti aditiivsed vead Parkinsoni põdevatele inimestele ning tervete inimeste testgrupile. Liigesed, millele mudelid loodi, on toodud järgnevas tabelis välja koos mudeli täpsusega.

Liiges	Samm	Sammu faas	Täpsus tervetel	Täpsus PD
Vasak ranne	Vasak	A-K	72.19%	-1.09%
Parem puus	Vasak	K-L	82.94%	73.46%
Parem puus	Vasak	A-K	75.49%	16.84%
Vasak pahkluu	Vasak	K-L	76.10%	64.0%
Õlgade keskpunkt	Parem	K-L	68.49%	14.36%
Õlgade keskpunkt	Parem	A-K	71.75%	-14.51%
Vasak küünarnukk	Parem	K-L	80.74%	82.57%
Vasak ranne	Parem	K-L	98.27%	68.23%
Vasak ranne	Parem	A-K	92.95%	-37.37%
Parem ranne	Parem	K-L	70.30%	-8.88%
Vasak põlv	Parem	K-L	91.67%	84.77%


Tabel. 4.4: A-K - Algu kuni keskpunkt, K-L - keskpunkt kuni sammu lõpp.

Eeltoodud tabeli põhjal on võimalik näha, milliste liigeste liikumine eristub Parkinsoni põdevatel inimestel enim. Antud mudelite põhjal on ennustatud Parkinsoni tõvega inimeste pingutusi ja testgrupi inimeste pingutusi.

Järgneval kahel graafikul on esitatud tervete ning Parkinsoni põdevate inimeste tõesed ning ennustatavad väärtused vasaku randme kohta. Toodud näide kajastab, kuidas tervete inimeste peal treenitud mudel ei taga Parkinsoni põdevate inimeste liigeste pingutuste tõepärasest ennustamist. Vastavalt on välja toodud graafikute puhul mudeli täpsusteks tervetel inimestel 98.27%, Parkinsoni põdevatel aga 68.23%. Kõigi tabelis 4.4 kirjeldatud mudelite graafikud on toodud välja lisa C.




Joonis. 4.1: Vasaku randme mudeli ennustused tervetel inimestel.



Joonis. 4.2: Vasaku randme mudeli ennustused Parkinsoni põdevatel inimestel.

Järgnevalt arvutati iga mudeli kohta vead iga testis osalenud inimese kohta ning liideti need mudelihaaval kokku. Selle tulemusena saadi kumulatiivne viga, mida võrreldi tervetel ning Parkinsoni põdevatel inimestel.



Joonis. 4.3: Kumulatiivne viga

Joonisel 4.3 on punasega märgitud kumulatiivne viga Parkinsoni põdevatel inimestel ning rohelisega märgitud viga tervetel inimestel. Tervete inimeste testgrupis oli kokku 8 Kinect seadme ees toimunud kõnnakut, mis kuuluvad juhuslikult valitud inimestele. X-telg märgib järjekorranumbrit ning ei oma antud juhul tähtsust. Y-telg

kujutab kumulatiivset viga.

Antud joonise põhjal on leitud lävend, mis eristab Parkinsoni patsiente tervetest inimestest. Lävendiks arvestati graafiku põhjal nähtavalt eristuvate tervete inimeste maksimaalset viga. Vastavalt saadud lävendile klassifitseeriti kumulatiivsete vigade alusel inimesed terveteks ning Parkinsoni põdevateks. Kõik vead, mis jäid lävendi alla, kuulusid tervetele inimestele ning vead, mis jäid lävendist kõrgemale, Parkinsoni patsientidele.

Meetodi täpsust arvestati õigsuse (i.k accuracy), täpsuse (i.k precision), saagise (i.k recall) ja F1 skoori alustel. Õigsus on õigesti ennustatud väärtuse suhe kogu väärtuste arvuga. Täpsus hindab ka seda, kas valepositiivsete arv on suur, mida lähemal see arv ühele on, seda väiksem on valepositiivsete arv. Saagis tähistab seda, kui palju on õigeid positiivseid ehk kui palju ennustas mudel õigesti. F1 skoor on kaalutud keskmine täpsusest ja saagisest, mis arvestab nii valepositiivseid kui ka valenegatiivseid, seega on seda parem täpsuse saamisel arvestada, kui õigsust. [38]

Antud töös on õiged positiivsed, õiged negatiivsed, valepositiivsed ja valenegatiivsed pandud vastavusse Parkinsoni tõvega inimeste tuvastamisel vastavalt järgnevale tabelile:

	Terve	Parkinson
Terve	Õige terve (TN)	Vale Parkinson (FP)
Parkinson	Vale terve (FN)	Õige Parkinson (TP)

Tabel. 4.5: TN-õige negatiivne, FP-valepositiivne, FN-valenegatiivne, TP-õige positiivne.

Tabeli põhjal on arvutatud õigsus, täpsus, saagis ja F1 skoor nendele vastavate valemite järgi.

$$\text{Õigsus} = \frac{(TP + TN)}{(TP + FP + FN + TN)} \quad (4.1)$$

$$\text{Täpsus} = \frac{TP}{(TP + FP)} \quad (4.2)$$

$$\text{Saagis} = \frac{TP}{(TP + FN)} \quad (4.3)$$

$$\text{F1skoor} = 2 * \frac{(\text{Saagis} * \text{Täpsus})}{(\text{Saagis} + \text{Täpsus})} \quad (4.4)$$

Järgnevas tabelis on toodud arvud, mis kujutavad valepositiivseid, valenegatiivseid, õigeid positiivseid ning õigeid negatiivseid. Need tulemused on saadud, kui lävendiks arvestati graafiku põhjal nähtavalt eristuvate tervete inimeste maksimaalset viga.

	Terve	Parkinson
Terve	6 (TN)	4 (FP)
Parkinson	2 (FN)	30 (TP)

Tabel. 4.6: TN-õige negatiivne, FP-valepositiivne, FN-valenegatiivne, TP-õige positiivne

Nende andmete põhjal on arvatud õigsus, täpsus, saagis ja F1 skoor.

- Õigsus = 0.85
- Täpsus = 0.88
- Saagis = 0.93
- F1 skoor = 0.85

5. Analüüs

Töö esimeses osas oli eesmärk tuvastada liigesed, mille abil oleks võimalik klassifitseerida inimesi terveteks ning Parkinsoni põdevateks ükskõik millise klassifikaatori abiga. Selleks prooviti läbi erinevaid klassifikaatoreid ning leiti kõigi töös proovitud klassifikaatorite täpsused Parkinsoni põdevate ning tervete inimeste klassifitseerimisel. Klassifikaatorite sisendid olid erinevate liigeste parameetrite kombinatsioonid, nii vasaku jalaga kui ka parema jalaga tehtud sammude vältel.

Sammu algfaasi ja keskmise faasi põhjal leitud parameetritega andis parima klassifitseerimistulemuse Gradient boost klassifikaator täpsusega 79% (+/- 21%), sellele järgnes otsustuspuu klassifikaator täpsusega 77% (+/- 13%). 79% tulemuse andis parema pahkluu, vasaku õla ja pea pingutuste kasutamine Gradient boost klassifikaatoril. Järgneva, 77% tulemuse andis vasaku puusa, õlgade keskpunkti ning parema puusa pingutuse parameetrite kasutamine otsustuspuu klassifikaatoril.

Sammu keskmise ning lõppfaasi põhjal leitud parameetrite järgi on parim klassifikaator k-lähima naabri klassifikaator, mis andis kombineerides vasaku küünarnuki, vasaku õla ning parema puusa pingutuste väärtusi tulemuse 79% (+/- 20%).

Kõige enim on klassifikaatorid kasutanud sisendina pea, vasaku randme ning parema küünarnuki pingutuste väärtuseid. Neile järgnevad parem pahkluu, vasak pahkluu, vasak õlg, selgroo keskpunkt ning vasak pahkluu. Tulemuste põhjal on aga hoopis näha, et nii parema puusa kui ka vasaku õla parameetrid on mõlemad parimate tulemustega klassifikaatorite sisenditeks, ülejäänud sisendid varieeruvad neil klassifikaatoritel. Suur standardhälve on tingitud inselt asjaolust, et antud töös on andmete hulk väike ning Kinect sensor ei ole piisavalt hea täpsusega liigeste koordinaatide tuvastamisel, sellele andis tunnistust ka see, et palju oli kõnnaku andmeid, mis peale andmete esmast töötlust alles ei jäänud. Kindlasti mängib suurt

rolli ka testgrupi vanus. Testgruppi kuulusid samuti vanemaealised inimesed, kellel võis esineda teiste tervislike probleemide tõttu kõndimisega raskusi.

Klassifitseerimistulemuste põhjal on märgata, et ühtegi kindlat liigeste kombinatsiooni, mille puhul klassifikaatorid ühtlaseid tulemusi annaks, ei olnud. Kõik üle 70% täpsusega tulemused on saadud erinevaid liigeseid kombineerides. Võib vaid eeldada, et vasak õlg ja parem puus on suurema diskrimineerimisvõimega, sest nende kahe liigese parameetrid olid sisendiks mitmel klassifikaatoril, mille tulemused olid teistest kõrgemad.

Töö teises pooles loodi närvivõrgumudelid ning valiti parima täpsusega mudelid, mis olid tervete inimeste andmete põhjal treenitud, tuvastamaks erinevusi Parkinsoni põdevate inimeste kõnnaku parameetrites. Antud töös kasutatavaid andmeid on aga vähe ning seega ei kasutatud töös valideerimise täpsuse leidmisel ristvalideerimise meetodit, vaid treeniti mudeleid üks kord ning leiti ühekordne täpsus mudelil. Selle tulemuse põhjal valitigi mudelid, mida testiti Parkinsoni tõvega inimeste kõnnaku parameetritega. Mudelite tulemusena saadi kumulatiivsed vead nii tervete inimeste testgrupil kui ka Parkinsoni põdevatel inimestel ning nende analüüsi põhjal klassifitseeriti inimesed terveteks ja Parkinsoni põdevateks ja saadi täpsus 88%, õigsus 85%.

Antud töös loodud mudeleid oleks vaja treenida ka rohkemate andmetega ning seejärel oleks võimalik teha järeldusi, kas töös rakendatud meetodid võimaldaksid tuvastada liigeseid, mille liikumine erineb tervetel ning Parkinsoni põdevatel inimestel.

5.1 Arutelu

Võrreldes varasemalt tehtud töödega, mis on kirjanduse ülevaates välja toodud, olid käesoleva töö meetodid erinevad. On töid, milles on andmete kogumiseks kasutatud samuti Microsoft Kinecti, kuid klassifitseerimise meetodid või analüüsitavad parameetrid on olnud erinevad praeguse töö omadest. Samuti on kasutatud ka närvivõrgu mudeleid töödes, kuid sellisel juhul on analüüsimiseks võetud parameetrid erinevad. Haiguste, sealhulgas Parkinsoni tuvastamiseks kindlat väga hea täpsusega meetodit veel olemas ei ole, seega on sellel alal uuringud väga vajalikud ning kasulik on proovida läbi nii erinevaid andmete kogumisviise kui ka erinevaid

masinõppemeetodeid. Antud töös kasutatud andmeid on analüüsitud ka teistes magistritöödes ning võrdlusena võib tuua, et magistritöös [15], kus uuriti liikumise massi parameetreid *Up and Go* testi vältel, leiti erinevusi põlvede, õlgade ning puusade liikumises. Selles töös on samuti klassifitseeritud Parkinsoni tõvega ning terveid inimesi ja saadud täpsusteks ühel nädalal salvestatud andmeid valideerides 76.67% ja teisel nädalal salvestatud andmete puhul 87.5%. Ka selles töös mainiti, et andmeid on siiski antud meetodi valideerimiseks vähe, et anda kindlaid vastuseid, kui hästi antud töös loodud meetod Parkinsoni tõvega inimesi tuvastaks.

Magistritöös [10] analüüsiti kehahoiakut ja ajalisi parameetreid kõnni alustamisel, töös toodi välja, et Parkinsoni põdevate inimeste pea-, puusa- ning põlveliigete liigesnurgad ei erine tervete inimeste liigesnurkade näitajatest olulisel määral, põhjuseks arvati olevat nii inimeste teadlik kontroll enda kehahoiu suhtes testi vältel või ka see, et testis osalenutel oli vaid kerge või mõõdukas Parkinsoni diagnoos. Selles töös leiti erinevus vaid pea asendis, nimelt Parkinsoni tõvega inimeste pea oli rohkem ettepoole hoidev kui tervetel inimestel. Ka käesoleva magistritöö tulemustena on näha, et pea põhjal leitud nurk on üks parameetritest, mis oli sisendiks paljudele klassifikaatoritele, mis ületasid 70% täpsuse.

6. Kokkuvõte

Antud magistritöö peamine eesmärk oli luua närvivõrgumudel, mille abil saaks kindlaks teha, kas inimene, kelle kõnnaku andmeid analüüsitakse, põeb Parkinsoni tõbe või mitte ning leida liigesed, mille liikumisel esineb erisusi Parkinsoni põdevate inimeste ning tervete inimeste võrdluses. Töös on kasutatud varasemalt salvestatud *Up and Go* testi andmeid, täpsemalt selle testi vältel toimunud kõnnaku parameetreid. Kõnnaku andmed töödeldi töös vajalikku formaati ehk arvutati liigete omavahelised nurgad ning nende põhjal liigete pingutuse väärtused. Seejärel koostati klassifitseerimismudelid, mille abil klassifitseeriti inimesi nende kõnnaku parameetrite alusel terveteks ning Parkinsoni põdevateks. Antud mudelite sisendiks olid erinevate liigete pingutuste väärtused kõnnaku vältel ning klassifitseerimise tulemusena tuvastati, milliseid nurki liigete vahel tasub närvivõrgumudeli loomisel kasutada. Parima tulemuse andsid klassifikaatorid, mille täpsused oli 79% (+/- 20%) ja 79% (+/- 21%), need klassifikaatorid kasutasid sisendina vastavalt vasaku küünarnuki, vasaku õla ja parema puusa ning parema pahkluu, vasaku õla ja pea parameetreid. Kolmas klassifikaator, mille täpsus oli 77% (+/- 13%) kasutas parameetritena vasaku puusa, õlgade keskpunkti ning parema puusa parameetreid. Seega vasaku õla ning parema puusa parameetrid olid kõige suurema diskrimineerimisvõimega antud tulemuste põhjal. Närvivõrgumudeli eesmärk oli kasutades tervete inimeste kõnnaku parameetreid treenida mudel, mis Parkinsoni põdevate inimeste kõnnaku andmeid sisendina töödeldes tuvastab, et tegemist ei ole terve inimesega ning selle mudeli abil saaks leida ka, milline konkreetne liiges sellel inimesel võrreldes terve inimesega erinevalt liigub. Antud töö põhjal andis selline lähenemisviis parimal juhul klassifitseerimistäpsuse 88%, kuid mitmekordset valideerimist andmete vähesuse tõttu ei tehtud.

7. Kasutatud kirjandus

- [1] Paulina Ortega-Bastidas, Pablo Aqueveque, Britam Gómez, Francisco Saavedra, and Roberto Cano-de-la Cuerda. Use of a single wireless imu for the segmentation and automatic analysis of activities performed in the 3-m timed up and go test. *Sensors*, 19(7):1647, Apr 2019.
- [2] Tiina Sumeri. Kõnnaku analüüs isiku tuvastamiseks, 2018.
- [3] Dale Markowitz. How machine learning is transforming healthcare at google and beyond. <https://towardsdatascience.com/how-machine-learning-is-transforming-healthcare-at-google-and-beyond-d4f664b7e27c>, 2019.
- [4] Pille Taba, Tiiu Paju, Eesti Parkinsoniliit, Tartu Ülikool. Närvikliinik, and Eesti Neuroloogide ja Neurokirurgide Selts. *Parkinsoni tõbi: Raamat haigetele ja nende peredele III*. Tartu Parkinsoni Haigete Selts, 2007.
- [5] Balance in elderly patients: the 'get-up and go' test. *Arch Phys Med Rehabil*, 67:387–389, 1986.
- [6] Anne Shumway-Cook, Sandy Brauer, and Marjorie Woollacott. Predicting the Probability for Falls in Community-Dwelling Older Adults Using the Timed Up and Go Test. *Physical Therapy*, 80(9):896–903, 09 2000.
- [7] Diane Podsiadlo and Sandra Richardson. The timed “up & go”: A test of basic functional mobility for frail elderly persons. *Journal of the American Geriatrics Society*, 39(2):142–148, 1991.
- [8] Joe Nocera, Elizabeth Stegemöller, Irene Malaty, Michael Okun, Michael Marsiske, and Chris Hass. Using the timed up and go test in a clinical setting

to predict falling in parkinson's disease. *Archives of physical medicine and rehabilitation*, 94, 03 2013.

- [9] Sven Nõmm, Aaro Toomela, Martti Vaske, Dan Uvarov, and Pille Taba. An alternative approach to distinguish movements of parkinson disease patients. *IFAC-PapersOnLine*, 49(19):272 – 276, 2016. 13th IFAC Symposium on Analysis, Design, and Evaluation of Human-Machine Systems HMS 2016.
- [10] Eveli Tamm. Erinevused kõnni alustamisel microsoft kinectiga tuvastatavates posturaalsetes ja ajalistes parameetrites ning kõnnikiiruses ja subjektiivselt tajutavates kõnniraskustes parkinsoni tõvega patsientidel ning tervetel eakaaslastel. Master's thesis, Tartu Ülikool, 2017.
- [11] H. Hazfiza Manap, N. Md Tahir, Ahmad Ihsan Mohamed Yassin, and R. Abdullah. Anomaly gait classification of parkinson disease based on ann. In *2011 IEEE International Conference on System Engineering and Technology*, pages 5–9, 2011.
- [12] Nicolas Khoury, Ferhat Attal, Yacine Amirat, Latifa Oukhellou, and Samer Mohammed. Data-driven based approach to aid parkinson's disease diagnosis. *Sensors*, 19(2):242, Jan 2019.
- [13] Eddy Sanchez-DelaCruz and Pilar Pozos-Parra. Machine learning-based classification for diagnosis of neurodegenerative diseases. 2264:40–50, Nov 2018.
- [14] Ioannis Tsoulos, Georgia Mitsi, Athanassios Stavrakoudis, and Spyros Papatropoulos. Application of machine learning in a parkinson's disease digital biomarker dataset using neural network construction (nnc) methodology discriminates patient motor status. *Frontiers in ICT*, 6, 05 2019.
- [15] Anna Krajuškina. Parkinsoni tõve modellerimine kõnnaku analüüsi meetodil. Master's thesis, Tallinna Tehnikaülikool, 2019.
- [16] Anna Krajuškina. Alternatiivne meetodi parkinsoni patsientide kõnnaku analüüsimiseks, 2017.

- [17] Henri Vasserman. Sügavõppepõhine analüüs parkinsoni tõve diagnoosi lause kirjutamise testi toeks, 2019.
- [18] Aleksei Netsunajev. Parkinsoni tõve diagnoosimisel kasutatava lause kirjutamise testi modelleerimine: klassifikaatorite ennustava võime võrdlus. Master's thesis, Tallinna Tehnikaülikool, 2019.
- [19] Thomas-Bairam Toodo. Parkinsoni tõve diagnoosimisel läbitud käekirjaliku lause testi parameetrite analüüs. Master's thesis, Tallinna Tehnikaülikool, 2018.
- [20] Tanel Kossas. Peenmotoortestide optimaalne pikkus parkinsoni tõve diagnoosimiseks, 2019.
- [21] Konstantin Bardõš. Analysis of interpretable anomalies and kinematic parameters in luria's alternating series tests for parkinson's disease modeling. Master's thesis, Tallinna Tehnikaülikool, 2018.
- [22] Karim Abdel-Malek and Jasbir Arora. *Human Motion Simulation: Predictive Dynamics*. 06 2013.
- [23] W. Wang ja F. Wang S. Liu, M.Šun, 2017.
- [24] Stephanie Crawford. How microsoft kinect works. <https://electronics.howstuffworks.com/microsoft-kinect.htm>.
- [25] Kinect sensor. [https://docs.microsoft.com/en-us/previous-versions/microsoft-robotics/hh438998\(v=msdn.10\)?redirectedfrom=MSDN](https://docs.microsoft.com/en-us/previous-versions/microsoft-robotics/hh438998(v=msdn.10)?redirectedfrom=MSDN), 2012.
- [26] Jaan Janno. Interpoleerimine. <http://staff.ttu.ee/~janno/kaugope/rmteooria4.pdf>.
- [27] Sidath Asiri. Machine learning classifiers. <https://towardsdatascience.com/machine-learning-classifiers-a5cc4e1b0623>.
- [28] Masinõppimine. <https://masinope.ee/masinoppimine/>.
- [29] Rohith Gandhi. Naive bayes classifier. <https://towardsdatascience.com/naive-bayes-classifier-81d512f50a7c>.

- [30] By Dan Nelson. Gradient boosting classifiers in python with scikit-learn. <https://stackabuse.com/gradient-boosting-classifiers-in-python-with-scikit-learn/>.
- [31] Ristvalideerimine. <https://et.wikipedia.org/wiki/Ristvalideerimine>.
- [32] Kristo Käärman. Otsustuspuudega klassifitseerimine. http://www.uretec.com/u/vilo/edu/2003-04/DM_seminar_2003_II/Raport/P02/main.pdf.
- [33] Eduard Petlenkov. Tehisnärvivõrgud ja nende rakendused. https://www.ttu.ee/public/i/infotehnoloogia-teaduskond/Instituudid/automaatikainstituut/oppeained/susteemiteooria/Tehisnarvivorgud-EP_2004.pdf, 2004.
- [34] 7 types of neural network activation functions: How to choose? <https://missinglink.ai/guides/neural-network-concepts/7-types-neural-network-activation-functions-right/>.
- [35] Sunil Ray. 7 regression techniques you should know! <https://www.analyticsvidhya.com/blog/2015/08/comprehensive-guide-regression/>.
- [36] Additive error. <https://www.statistics.com/glossary/additive-error/>.
- [37] Trevor Hastie, Robert Tibshirani, and Jerome Friedman. *The Elements of Statistical Learning*. Springer Series in Statistics. Springer New York Inc., New York, NY, USA, 2001.
- [38] Renuka Joshi. Accuracy, precision, recall and f1 score: Interpretation of performance measures. <https://blog.exsilio.com/all/accuracy-precision-recall-f1-score-interpretation-of-performance-measures/>.

A. Lisa 1

	1	2	4	5	6	7	8	10
	0	0	0	0	0	0	0	0
KT_03_алу	KT_04_алу	KT_05_алу	KT_06_алу	KT_07_алу	KT_07_алу	KT_07_алу	KT_08_алу	
0.80843	1.027544	1.025033	0.892675	0.933391	0.876378	0.88801	0.962992	
0.818333	1.005965	1.083682	0.870251	0.912297	0.844161	0.861401	0.902984	
2.383835	1.05795	0.631635	0.888165	1.17672	0.559294	0.28193	1.280846	
2.353689	1.055389	0.609132	0.90336	1.194556	0.570447	0.312887	1.386337	

Joonis. A.1: Nurkade näidisfail tervetel inimestel.

Vasaku õla nurkade näidisfailis tervete inimeste puhul tähistab 2. rida ehk 0 tervet inimest, 3. rida sammu alguse nurka vasakul sammul, 4. rida vasaku sammu keskpunkti nurka, 5. rida parema sammu alguse nurka, 6. rida parema sammu keskpunkti nurka. Ühel inimesel võib olla mitmel erineval kõnnakul salvestatud nurgad.

	50	51	53	54	55	56	57	58
	1	1	1	1	1	1	1	1
SG_04_алу	SG_04_алу	SG_05_алу	SG_05_алу	SG_06_алу	SG_07_алу	SG_07_алу	SG_08_алу	
0.830304	0.838102	0.937456	0.97369	0.937891	0.956346	0.945754	0.861446	
0.795399	0.784397	0.927233	0.909778	0.903363	0.942918	0.925787	0.849677	
0.388484	0.517979	1.2719	0.93147	0.311011	0.97302	1.213335	0.830639	
0.38804	0.517387	1.274181	0.963199	0.321476	0.968416	1.240327	0.862424	

Joonis. A.2: Nurkade näidisfail Parkinsoni põdevatel inimestel.

Vasaku õla nurkade näidisfailis Parkinsoni põdevate inimeste puhul tähistab 2. rida ehk 1 Parkinsoni põdevat inimest, 3. rida sammu alguse nurka vasakul sammul, 4. rida vasaku sammu keskpunkti nurka, 5. rida parema sammu alguse nurka, 6. rida parema sammu keskpunkti nurka. Ühel inimesel võib olla mitmel erineval kõnnakul salvestatud nurgad.

B. Lisa 2

0	0	0	1	1	1
0.039555	0.041309	0.094157	0.010422	0.016435	0.016435
3.72E-05	6.64E-05	0.002355	5.36E-07	5.45E-05	5.45E-05
0.000937	0.000303	0.001258	0.003898	0.004774	0.004774
0.001392	0.001103	0.012964	0.009878	0.019532	0.019532
0.000205	0.002352	0.008871	0.006907	0.012998	0.012998
0.002005	0.000995	0.00189	0.000648	0.001444	0.001444
0.002276	0.001518	0.001371	0.004518	0.005068	0.005068
0.001365	0.001408	0.001333	0.000434	0.000285	0.000285
0.000604	0.000292	0.005422	0.000631	0.000162	0.000162
0.009634	0.007332	0.008016	0.003792	0.00783	0.00783
0.000544	0.001997	0.01099	0.001481	0.000261	0.000261
0.000284	0.000382	8.48E-05	0.001125	0.000848	0.000848
0.007718	0.00687	0.007992	0.005085	0.002026	0.002026
0.008335	0.001657	0.00378	0.002537	8.14E-05	8.14E-05
0.028914	0.00629	0.015796	0.004923	0.01044	0.01044
0.000411	0.000703	0.000905	0.000219	0.003208	0.003208
0.014172	0.148205	0.066456	0.014179	0.012007	0.012007
1.94E-05	0.000532	2.21E-05	1.74E-05	0.000497	0.000497
0.001353	0.003746	0.001269	0.001714	0.007033	0.007033
0.001333	0.004447	0.000284	0.031149	0.042971	0.042971
0.000351	0.000952	0.003756	0.025904	0.012434	0.012434
0.000778	0.002269	0.001694	0.003501	0.000933	0.000933
9.35E-05	0.000573	0.004906	0.002047	0.334611	0.334611
2.24E-05	0.001835	0.003899	0.001063	0.003349	0.003349
8.04E-05	0.000337	0.000228	0.001218	0.001713	0.001713
0.000807	0.004075	0.002078	0.000504	0.000617	0.000617
0.005685	0.014373	0.017082	0.004054	0.006995	0.006995
0.000709	0.00225	0.011565	0.000876	0.006136	0.006136
0.000196	0.000217	0.00173	0.000317	0.003004	0.003004
0.007573	0.019549	0.014835	0.007495	0.006119	0.006119
0.003229	0.002382	0.000706	0.003267	0.007475	0.007475
0.000184	0.000416	0.0003	0.000615	0.001401	0.001401


Joonis. B.1: Pingutuste näidisfail.

Esimene rida tähistab tervet (0) või Parkinsoni põdevat (1) inimest. 16 järgnevat rida kujutavad endast vasakul sammul leitud järgnevate liigete pingutuste väärtusi:


puusade keskpunkt, selgroo keskpunkt, õlgade keskpunkt, vasak õlg, parem õlg, vasak küünarnukk, parem küünarnukk, vasak ranne, parem ranne, vasak puus, parem puus, vasak põlv, parem põlv, vasak pahkluu, parem pahkluu, pea. Ülejäänud 16 rida kujutavad parema sammu jooksul leitud samade liigete pingutuse väärtusi.

C. Lisa 3


Õlgade keskpunkt parem samm, K-L sammu faas



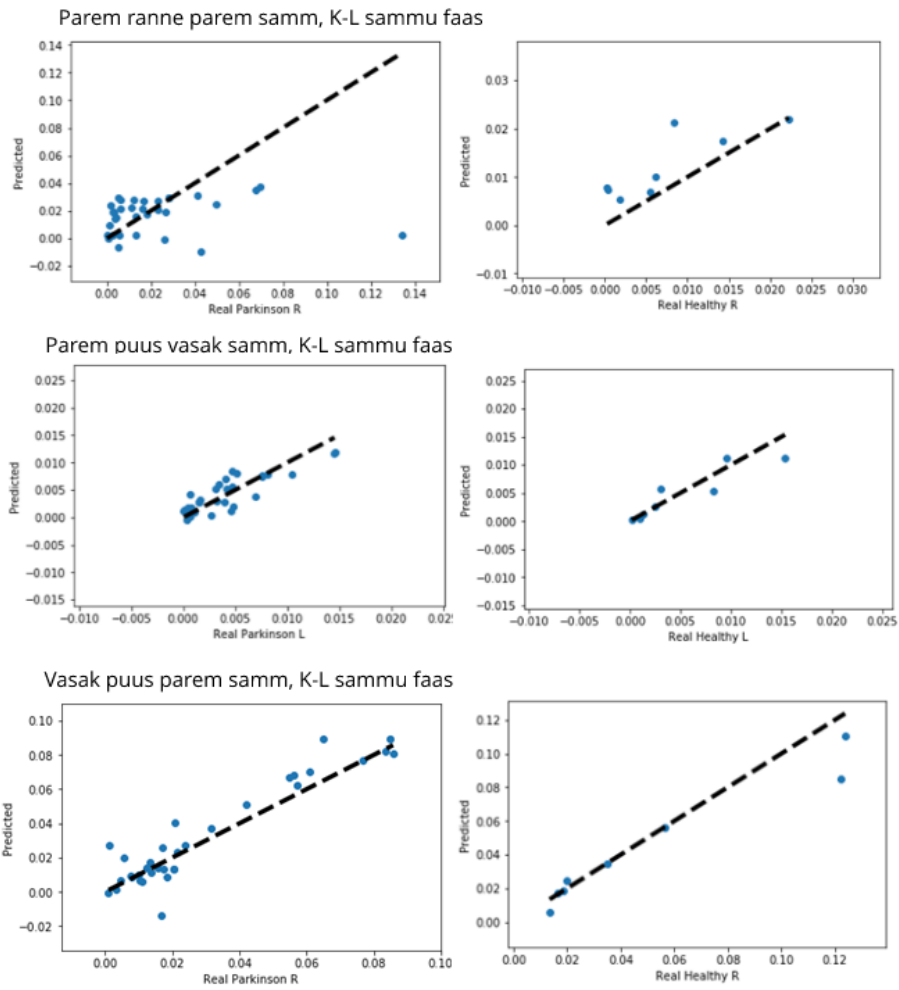
Vasak küünarnukk parem samm, K-L sammu faas



Vasak ranne parem samm, K-L sammu faas




Joonis. C.1: Närvivõrgumodelite graafikud.




Joonis. C.2: Närvivõrgumodelite graafikud.


Vasak pahkluu vasak samm, K-L sammu faas




Õlgade keskpunkt parem samm, A-K sammu faas




Vasak ranne vasak samm, A-K sammu faas



Vasak ranne parem samm, A-K sammu faas



Parem puus vasak samm, A-K sammu faas



Joonis. C.3: Närvivõrgumodelite graafikud.