





CHALMERS



Motorisk funktionsbedömning med radarsensorteknik och maskininlärning

Med fokus på fingertappning hos patienter med Parkinsons sjukdom

Kandidatarbete inom Elektroteknik

Fia Jacobsson
Elin Johansson

Ebba Larsson
Erna Muheljc

Ellen Nisbet
Tilde Thurffjell Emilsson

INSTITUTIONEN FÖR ELEKTROTEKNIK

CHALMERS TEKNISKA HÖGSKOLA
Göteborg 2025
www.chalmers.se

KANDIDATARBETE 2025

Motorisk funktionsbedömning med radarsensorteknik och maskininlärning

Med fokus på fingertappning hos patienter med Parkinsons sjukdom

Fia Jacobsson
Elin Johansson
Ebba Larsson
Erna Muheljic
Ellen Nisbet
Tilde Thurfjell Emilsson



CHALMERS

Institutionen för Elektroteknik
CHALMERS TEKNISKA HÖGSKOLA
Göteborg 2025

Motorisk funktionsbedömning med radarsensorteknik och maskininlärning
Med fokus på fingertappning hos patienter med Parkinsons sjukdom

Fia Jacobsson
Elin Johansson
Ebba Larsson
Erna Muheljic
Ellen Nisbet
Tilde Thurfjell Emilsson

- © Fia Jacobsson, 2025.
- © Elin Johansson, 2025.
- © Ebba Larsson, 2025.
- © Erna Muheljic, 2025.
- © Ellen Nisbet, 2025.
- © Tilde Thurfjell Emilsson, 2025.

Handledare: Xuezhi Zeng
Handledare: Gunilla Kjellby Wendt
Examinator: Andreas Fhager, Elektroteknik

Kandidatarbete 2025
Institutionen för Elektroteknik
Chalmers Tekniska Högskola
SE-412 96 Göteborg
Telefon +46 31 772 1000

Omslagsbild: *Illustrering av fingertappningstestet.*

Skriven i L^AT_EX
Göteborg 2025

Abstract

This bachelor's thesis investigates how radar sensor technology can be used to assess motor functions in patients with Parkinson's disease, with a particular focus on the finger tapping test. As the project is not part of a formal clinical study, the tests have not been conducted on individuals diagnosed with Parkinson's disease. The project is conducted in collaboration with Sahlgrenska University Hospital and its physiotherapists. A method based on the machine learning algorithms 1D-CNN 3 layer and CNN-LSTM has been developed. The aim is to classify the finger tapping test in accordance with the MDS-UPDRS. This method enables an objective and evidence-based assessment of the patient's motor function, which is crucial both for diagnosis and for monitoring the progression of the disease.

The results using 1D-CNN 3 layer shows a classification accuracy of 74,19 % without data augmentation and 92,72 % with data augmentation. The accuracy is significantly improved with the CNN-LSTM algorithm, achieving 98,38 % without data augmentation. The augmented model demonstrated a marginally lower accuracy; however, it presented a more stable performance. A five-fold cross validation of the algorithm with augmented data shows stable and consistent good performance with accuracy ranging from 96,17 % to 99,28 %. These results suggest that the developed method can identify and classify the different categories, with only minor errors due to the associated complexity of the problem.

Keywords: Parkinson's disease, Finger tapping, Motor function assessment, Monitoring, MDS-UPDRS, Radar sensor technology, Machine learning, 1D-CNN 3 layer, CNN-LSTM, Cross validation

Sammandrag

Detta kandidatarbete undersöker hur radarsensorteknik kan användas för att analysera motoriska funktioner hos patienter med Parkinsons sjukdom, med särskilt fokus på fingertappningstestet. Eftersom projektet inte är en del av en klinisk studie har testerna därav inte utförts på verkliga patienter med Parkinsons sjukdom. Kandidatarbetet sker i samarbete med Sahlgrenska Universitetssjukhuset och dess fysioterapeuter. En metod baserad på maskininlärningsalgoritmerna 1D-CNN 3 layer och CNN-LSTM har utvecklats. Syftet är att klassificera fingertappningstestet i enlighet med MDS-UPDRS. Genom denna metod möjliggörs en objektiv och evidensbaserad bedömning av patientens motoriska funktion, vilket är av stor vikt både för diagnostik och för monitoreringen av sjukdomens progression.

Resultatet med 1D-CNN 3 layer visar en klassificeringsnoggrannhet på 74,19 % utan dataaugmentering och 92,72 % med dataaugmentering. Noggrannheten förbättras avsevärt med CNN-LSTM-algoritmen, som utan dataaugmentering uppnår 98,38 % noggrannhet. Modellen med augmentering uppvisade en något lägre noggrannhet, men en mer stabil prestanda. En 5-fold korsvalidering av algoritmen med augmenterad data visar stabil och konsekvent god prestanda med noggrannhet mellan 96,17 % och 99,28 %. Dessa resultat tyder på att den utvecklade metoden kan identifiera och klassificera de olika kategorierna, med endast mindre fel som beror på problemets komplexitet.

Nyckelord: Parkinsons sjukdom, Fingertappning, Motorisk funktionsbedömning, Monitorering, MDS-UPDRS, Radarsensorteknik, Maskininlärning, 1D-CNN 3 layer, CNN-LSTM, Korsvalidering

Förord

Ett stort tack riktas till vår handledare Xuezhi Zeng för den viktiga kompetensen och vägledning under kandidatarbetet. Vi vill även uttrycka vår tacksamhet till Sahlgrenska Universitetssjukhuset samt vår handledare Gunilla Kjellby Wendt och fysioterapeuterna Per Bodin och Anna Jernås. Ert stöd och engagemang har varit avgörande, utan er hjälp hade detta projekt inte varit möjligt. Slutligen vill vi också rikta ett varmt tack till vår examinator Andreas Fhager för hans stöd under arbetets gång.

Fia Jacobsson, Elin Johansson,
Ebba Larsson, Erna Muheljic,
Ellen Nisbet och Tilde Thurfjell Emilsson
Göteborg, Maj 2025

Akronymer

Nedan listas de akronymer som förekommer i arbetet i alfabetisk ordning:

1D-CNN	One Dimensional - Convolutional Neural Network
CNN	Convolutional Neural Network
CNN-LSTM	Convolutional Neural Network - Long Short-Term Memory
FFT	Fast Fourier Transform
FMCW	Frequency-Modulated Continuous Wave
IF	Intermediate Frequency
IMU	Inertial Measurement Unit
LSTM	Long Short-Term Memory
MDS	Movement Disorder Society
MDS-UPDRS	Movement Disorder Society - Unified Parkinson's Disease Rating Scale
ReLU	Rectified Linear Unit
RNN	Recurrent Neural Network
RX	Receiver
TX	Transmitter
UPDRS	Unified Parkinson's Disease Rating Scale

Innehåll

Akronymer	ix
Figurer	xiii
Tabeller	xv
1 Inledning	1
1.1 Bakgrund	1
1.1.1 Parkinsons sjukdom	1
1.1.1.1 Motoriska och icke-motoriska symptom	2
1.1.1.2 Diagnostik och monitorering av symptom	4
1.1.2 Fingertappningstest	6
1.1.3 State of the art	7
1.2 Syfte	8
1.3 Mål	8
1.4 Avgränsningar	9
2 Teknisk bakgrund	11
2.1 Tidigare arbeten	11
2.2 Radarsensorteknik	12
2.3 Maskininlärning	13
2.3.1 Convolutional Neural Network	13
2.3.2 Long Short-Term Memory	14
3 Metod	17
3.1 Samarbete med fysioterapeuter	17
3.2 Datainsamling	17
3.3 Maskininlärning och algoritmer	19
3.3.1 Algoritmens struktur	19
4 Resultat	23
4.1 Datainsamling	23
4.1.1 Kategori 0 - normal	24
4.1.2 Delkategori a - avbrott	24
4.1.3 Delkategori b - minskad hastighet	25
4.1.4 Delkategori c - amplitudminskning	26
4.1.5 Kategori 4 - svåra symptom	26

4.2	Dataaugmentation	27
4.3	Maskininlärning	27
4.3.1	CNN	27
4.3.2	CNN-LSTM	30
4.3.3	Korsvalidering	32
5	Diskussion	33
5.1	Reflektion kring metod och resultat	33
5.1.1	Modifiering av MDS-UPDRS	33
5.1.2	Användning av augmented data	34
5.1.3	Klassificeringsproblem med CNN-modellen	34
5.1.4	Ändringar i algoritmen för LSTM	35
5.1.5	LSTM	35
5.1.6	Korsvalidering	36
5.1.7	Valideringstest med fysioterapeuter	36
5.1.8	Jämförelse med tidigare arbeten	37
5.2	Felkällor	37
5.3	Vidareutveckling	38
5.3.1	Förbättringsområden	38
5.3.2	Teknisk utveckling	39
5.3.3	Etiska aspekter	40
6	Slutsats	41
	Litteratur	43
A	Appendix 1	I

Figurer

1.1	Substantia nigra för en frisk person och en person med Parkinsons sjukdom.	2
1.2	Motoriska och icke-motoriska symptom vid Parkinsons sjukdom. . . .	4
1.3	Illustration som beskriver fingertappningstestet.	6
1.4	Moment 3.4 Fingertappning, ett av 18 test inom del III i MDS-UPDRS. .	7
2.1	Illustration som visar en chirp samt beskriver hur IF-signalen förhåller sig till TX- och RX-chirpen.	12
2.2	Schematisk illustration av 1D-CNN-struktur.	14
2.3	Schematisk illustration av RNN-struktur.	15
3.1	Fingertappning med olika handplaceringar.	19
3.2	Dopplersignatur från kategori 2c.	20
4.1	Antal filer per kategori.	23
4.2	Kategori 0. Normalt rörelsemönster.	24
4.3	Delkategori a. Avbrott i rörelsemönstret.	24
4.4	Delkategori b. Grad 1 och 2. Minskad hastighet i rörelsemönstret. . .	25
4.5	Delkategori b. Grad 3. Minskad hastighet i rörelsemönstret.	25
4.6	Delkategori c. Minskad amplitud i rörelsemönstret.	26
4.7	Kategori 4. Avsaknad av rörelsemönster.	26
4.8	Antal filer per kategori efter augmentering av data.	27
4.9	Tränings- och valideringsförlust samt noggrannhet för det neurala nätverket över epoker på insamlad data.	28
4.10	Förvirringsmatris för insamlad data över vardera kategori med en valideringsnoggrannhet på 74,19 %.	28
4.11	Tränings- och valideringsförlust samt noggrannhet för det neurala nätverket över epoker på augmenterad data.	29
4.12	Förvirringsmatris för augmenterad data över vardera kategori med en valideringsnoggrannhet på 92,72 %.	29
4.13	Tränings- och valideringsförlust samt noggrannhet för modellen över epokerna för insamlad data.	30
4.14	Förvirringsmatrisen för insamlad data över vardera kategori med en valideringsnoggrannhet på 98,38 %.	30
4.15	Tränings- och valideringsförlust samt noggrannhet för modellen över epokerna för augmenterad data.	31

4.16	Förvirringsmatrisen för augmented data över vardera kategori med en valideringsnoggrannhet på 97,84 %	31
A.1	Sensorkonfiguration i mmWave Studio 02.01.01.00.	I

Tabeller

1.1	Skala från 0 till 4 med tillhörande beskrivningar av patientens motorfunktion.	5
4.1	Resultat från 5-fold korsvalidering.	32

1

Inledning

Parkinsons sjukdom är en av de vanligaste neurologiska sjukdomarna i världen och klassificeras som en neurodegenerativ sjukdom [1]. Globalt lever över 6 miljoner människor med diagnosen vilket är ett resultat av att sjukdomens förekomst ökat med 2,5 gånger under de senaste tre decennierna. I Sverige lever idag cirka 20 000 personer med Parkinsons sjukdom [2]. För närvarande drabbas främst personer över 55 år [3].

1.1 Bakgrund


Detta delkapitel innefattar en genomgång av Parkinsons sjukdom med fokus på symptom, diagnostik och monitorering. Det ger en beskrivning av fingertappning (jfr. eng. finger tapping), state of the art och översiktlig bakgrund till användning av radarsensorteknik.

1.1.1 Parkinsons sjukdom

Parkinsons sjukdom beskrevs för första gången 1817 i essän *Essay on Shaking Palsy* av James Parkinson [4]. Patologin för Parkinsons sjukdom var däremot inte lika välförstådd förrän 1912, då Frederick Lewy rapporterade om felaktiga proteinsamlingar som störde neuronernas normala funktioner. Dessa benämns som Lewy-kroppar och deras uppkomst förknippas med Parkinsons sjukdom [5]. Under samma period observerades den kritiska förändringen i sjukdomen, nämligen förlusten av neuroner i substantia nigra, en struktur i mitthjärnan [4]. Senare, på 1950-talet, började forskare förstå dopaminets stora betydelse för sjukdomens förlopp.

Parkinsons sjukdom definieras patologiskt av en degeneration eller förlust av dopaminproducerande neuroner i substantia nigra, tillsammans med förekomst av Lewy-kroppar i dessa neuroner [5]. I figur 1.1 illustreras skillnaden i substantia nigra mellan en frisk person och en person med Parkinsons sjukdom, där en tydlig förlust av dopaminerga neuroner kan observeras. Förlusten av dopaminproducerande neuroner har en betydande inverkan på motorisk kontroll. En faktor som bidrar till degeneration av neuroner är genetiska mutationer som påverkar proteiner i det centrala nervsystemet. Ett exempel på ett sådant protein är alfa-synuklein, som vid Parkinsons sjukdom ansamlas på ett onormalt sätt inuti neuronerna och blir olösligt. Det leder i sin tur till bildandet av Lewy-kroppar. När symptomen på Parkinsons sjukdom börjar visa sig har ungefär 60–70 % av neuronerna i substantia nigra pars

compacta, den del av substantia nigra som innehåller dopaminerga neuroner [6], redan förlorats [5].



Figur 1.1: Substantia nigra för en frisk person och en person med Parkinsons sjukdom. [7], CC-BY-3.0

Idag fokuserar behandlingen av Parkinsons sjukdom enbart på att lindra symptomen [8]. Ett av de stora framtidsmålen inom forskningen är att utveckla sjukdomsmodifierande läkemedel som kan bromsa eller helt stoppa sjukdomsförloppet. Eftersom dopaminbrist är den främsta orsaken till symptomen används i dagsläget läkemedel som antingen ökar dopaminnivåerna eller stimulerar dopaminreceptorer.

Ett avgörande steg för att planera behandlingar och utvärdera deras effekt är att noggrant övervaka sjukdomsförloppet [9]. Genom regelbundna undersökningar ges en helhetsbild av både sjukdomens utveckling och behandlingens effektivitet.

1.1.1.1 Motoriska och icke-motoriska symptom

Vid den första beskrivningen av Parkinsons sjukdom klarlades att de mest framträdande kännetecknen är försämrade motoriska funktioner [8]. Symptomen leder till en progressiv funktionsnedsättning med svårigheter i utförandet av vardagssysslor [1] och är kopplade till degeneration av substantia nigra och dopaminbrist i de basala ganglierna [8].

De motoriska symptom som kännetecknar Parkinsons sjukdom omfattar bradykinesi, vilotremor, rigiditet samt förändringar i hållning och gång [1]. Även symptom som talstörningar kan förekomma. Dessa motoriska symptom illustreras i figur 1.2. Bradykinesi beskriver förlängsammade och minskade spontana rörelser. Detta leder till begränsat rörelseomfång, nedsatt precision och färre ansiktsuttryck. Dessutom kännetecknas bradykinesi av en progressiv minskning av hastighet och amplitud vid upprepade rörelser, som fingertappning eller handgrepp. Rigiditet beskriver ökad muskeltonus vilket innebär ett motstånd vid passiva rörelser. Det resulterar i att

musklerna känns stela med ett konstant motstånd. Vilotremor beskriver en rytmiskt skakande rörelse som oftast förekommer i extremiteter som händer och fingrar, men kan även uppträda i läppar eller ansikte. Tremorn ligger vanligtvis inom frekvensområdet 4–6 Hz. Ett kännetecken för vilotremor är att den minskar eller helt försvinner när personen utför målinriktade frivilliga rörelser, vilket innebär att skakningarna inte är närvarande under aktiv användning av musklerna. Gångförändringar beskriver en progressiv nedsättning i rörelsemönster, där det bland annat kan innebära minskade armrörelser och en fördröjning i benens rörelsekoordination.

Motoriska symptom som uppträder i de senare stadierna inkluderar posturala förändringar och freezing of gait (jfr. sv. gångstörningar) [1], vilket illustreras i figur 1.2. Posturala förändringar innebär en avvikelse i kroppshållningen, där överkroppen förskjuts vid stående position. Det kan innebära en lateral trunkavvikelse vilket innebär lutning åt sidan. Denna förskjutning kan även innebära en anterior trunkavvikelse som är en framåtböjning av bålen. Det kan även omfatta huvudflexion, där huvudet hänger framåt. Dessutom kan förändringar i armar och fingrar uppstå, såsom böjda armbågar eller förändringar i handledens och fingrarnas positioner. Freezing of gait innebär en tillfällig oförmåga att påbörja eller fortsätta framåtriktad gång, vilket ofta leder till att personen fastnar i ett stillastående tillstånd. Detta kan inträffa vid gångstart eller under gång.

Parkinsons sjukdom är även kopplad till flera icke-motoriska symptom som hyposmi, sömnstörningar, autonom dysfunktion och olika neuropsykiatriska störningar [1]. Dessa icke-motoriska symptom illustreras i figur 1.2. Hyposmi innebär en förlust i luktsinnet och rapporteras drabba upp till 70 % av patienterna. Sömnstörningar, som parasomni, kännetecknas kliniskt av livliga och obehagliga drömmar. Utöver detta kan sömnproblem även yttra sig som sömnlöshet, rastlösa ben och dagtrötthet. Andra exempel på icke-motoriska symptom är neuropsykiatriska symptom, som ångest, panikattacker eller social fobi. Det kan även handla om depression och apati. Icke-motoriska symptom kan även uppträda i form av autonom dysfunktion som exempelvis svettningar [10], förstoppning, urinträngningar samt inkontinens [1]. Dessa icke-motoriska symptom tros vara relaterade till neurodegeneration i andra delar av nervsystemet, till exempel det perifera autonoma nervsystemet. De icke-motoriska symptomen har, liksom de motoriska symptomen, en negativ inverkan på patientens liv och bidrar till försämrad livskvalitet.



Figur 1.2: Motoriska och icke-motoriska symptom vid Parkinsons sjukdom. [11], CC BY-SA 4.0

Braak-modellen är en hypotes om hur Lewy-patologi sprider sig vid Parkinsons sjukdom [8]. Enligt hypotesen delas sjukdomsförloppet in i sex olika stadier, där sjukdomen börjar i det perifera nervsystemet och fortgår uppåt genom hjärnan. Stadierna 1 och 2 motsvarar de första premotoriska symptomen som sömnsvårigheter och hyposmi [12]. Stadie 3 motsvarar de motoriska symptomen, vilka uppträder när dopaminbrist uppstår i substantia nigra [8]. Slutligen motsvarar stadierna 4–6 de icke-motoriska symptomen utav högre grad som demens. De mest avancerade sjukdomsstadierna omfattar både kognitiv svikt och icke-motoriska symptom.

1.1.1.2 Diagnostik och monitorering av symptom

De kliniska diagnostiska kriterierna för Parkinsons sjukdom togs fram av Movement Disorder Society (MDS) och är främst avsedda att användas vid klinisk forskning [13]. Experter inom Parkinsons sjukdom hos MDS tog fram och publicerade dessa kriterier år 2015 [14]. MDS-kriterierna används, utöver till forskning, vid diagnostisering av Parkinsons sjukdom genom att systematisera och standardisera processen samt vara applicerbar för kliniker med mindre erfarenhet av diagnostiseringen [13]. Idag representerar kriterierna den globala standarden för diagnos och de har även validerats av neurologer med över tio års erfarenhet av diagnostisering av Parkinsons sjukdom [14]. Kriterierna beskriver definitionen av Parkinsons sjukdom och appliceras i syfte att avgöra om en patient har sjukdomen för att ställa diagnos.

I MDS-kriterierna ingår både motoriska och icke-motoriska tecken trots att de motoriska delarna, det vill säga bradykinesi, vilotremor och rigiditet, är de mest centrala för sjukdomen [13]. För att fastslå de motoriska symptomen och de diagnostiska kriterierna utförs en anamnes och neurologisk undersökning [14].

Unified Parkinson's Disease Rating Scale (UPDRS) togs fram under 1980-talet [15]. UPDRS har sedan reviderats och utökats av en granskningsgrupp hos MDS för att åtgärda identifierade problem och då skapades Movement Disorder Society–Unified

Parkinson's Disease Rating Scale (MDS-UPDRS). MDS-UPDRS består av fyra delar där del I innefattar vardagliga icke-motoriska upplevelser, del II vardagliga motoriska upplevelser, del III undersökning av motorik och del IV motoriska komplikationer [16].

Del I består av delmomenten IA och IB [17]. I delmoment IA skattas patienten utifrån särskilda beteenden genom bedömning av utredaren som förses med nödvändig information. Delmoment IB genomför patienten utan utredaren. Under del II får patienten vidare utvärdera sig själv via frågor i en enkät. Del III innefattar instruktioner som utredaren ska ge eller visa för patienten där resultaten antecknas av utredaren efter visuell bedömning. Här är fingertappningstestet ett av 18 delmoment som genomförs för att undersöka patientens motoriska förmåga i olika situationer. Exempel på andra delmoment är observation av ansiktsuttryck, gångtest och stabilitet i kroppshållning. Del IV innefattar instruktioner för utredaren samt instruktioner som är avsedda att läsas upp för patienten och kombinerar patientens egna uppgifter med utredarens observationer. Gemensamt för alla fyra delar i MDS-UPDRS är att de innehåller en skala från 0 till 4 enligt tabell 1.1.

Tabell 1.1: Skala från 0 till 4 med tillhörande beskrivningar av patientens motorfunktion.


Grad	Beskrivning
0	Normal
1	Lätt
2	Mild
3	Måttlig
4	Svår

Skalan förmedlar patientens funktion i varje moment, där 0 beskriver normal funktion och övriga siffror beskriver graden av motorisk svårighet hos patienten [17]. Således används skalan för att evaluera symptomens omfattning. En högre slutlig poängsumma innebär större svårigheter hos patienten.

Patienter som fått diagnosen Parkinsons sjukdom remitteras av neurolog till fysioterapeut och arbetsterapeut där bedömning enligt MDS-UPDRS utförs [18]. Därefter påbörjas behandling med medicin och tre månader senare kallas patienten igen för att utvärdera dess effekt. Då utförs en ny bedömning vars resultat kan jämföras med det tidigare utförda för att följa upp symptomen. På så sätt kan förändringar i patientens motoriska funktion noteras. Kontinuerlig bedömning av patientens motoriska funktion, i enlighet med MDS-UPDRS, utförs för att övervaka sjukdomens progression [9], [19].

1.1.2 Fingertappningstest

Fingertappningstestet är ett av delmomenten i MDS-UPDRS del III som används för bedömning av patientens motoriska funktion [16], vilket beskrivs i delkapitel 1.1.1.2. Vid testet utvärderas patientens båda händer separat. Instruktionen ges att föra samman pekfingeret och tummen upprepat tio gånger i en följd så snabbt och med så stor rörelse som möjligt [17]. Fingertappningstestet illustreras i figur 1.3.




(a) Stängd



(b) Öppen

Figur 1.3: Illustration som beskriver fingertappningstestet.

Testet bedöms och graderas enligt skalan i tabell 1.1 utifrån rörelsens hastighet och amplitud samt antal avbrott och tvekingar [17], vilket kan avläsas i figur 1.4. När ett avbrott överstiger en sekund räknas det som freezing (jfr. sv. frysning) [20]. Med hjälp av dessa bedömningsfaktorer är det standardiserat vad som motsvarar vilken grad av svårighet [17].

3.4 FINGER TAPPING	
<p>Instructions to examiner: Each hand is tested separately. Demonstrate the task, but do not continue to perform the task while the patient is being tested. Instruct the patient to tap the index finger on the thumb 10 times as quickly AND as big as possible. Rate each side separately, evaluating speed, amplitude, hesitations, halts, and decrementing amplitude.</p>	
0: Normal:	No problems.
1: Slight:	Any of the following: a) the regular rhythm is broken with one or two interruptions or hesitations of the tapping movement; b) slight slowing; c) the amplitude decrements near the end of the 10 taps.
2: Mild:	Any of the following: a) 3 to 5 interruptions during tapping; b) mild slowing; c) the amplitude decrements midway in the 10-tap sequence.
3: Moderate:	Any of the following: a) more than 5 interruptions during tapping or at least one longer arrest (freeze) in ongoing movement; b) moderate slowing; c) the amplitude decrements starting after the 1st tap.
4: Severe:	Cannot or can only barely perform the task because of slowing, interruptions, or decrements.
	

Figur 1.4: Moment 3.4 Fingertappning, ett av 18 test inom del III i MDS-UPDRS. [17], Copyright © 2008 International Parkinson and Movement Disorder Society (MDS). All Rights Reserved. Reproduced with permission of the copyright owner. Further reproduction prohibited without permission.

Dagens metod för bedömning är subjektiv och baseras endast på visuell observation av utredaren. Enligt MDS-UPDRS instrueras utredaren att visuellt skatta patientens utförande av uppgiften [17]. Det används alltså inte någon objektiv metod för att mäta rörelsens hastighet och amplitud samt förekomsten av avbrott, tvekingar och freezing. Denna bedömningsmetod gör att det krävs många års erfarenhet inom området för att fysioterapeuten tillförlitligt ska kunna skatta patientens motoriska svårigheter [20].

1.1.3 State of the art

I ett tidigare forskningsprojekt har övervakning av symptomet bradykinesi vid Parkinsons sjukdom genomförts med hjälp av ett bärbart sensorsystem baserat på Inertial Measurement Units (IMU) [21]. Genom sensorsystemet har hand- och fingerrörelser, som exempelvis fingertappning, mätts och analyserats. Deltagarna i studien bestod av både friska individer och patienter med Parkinsons sjukdom. Med hjälp av maskininlärningsalgoritmer har data använts för att klassificera testpersonerna som antingen friska eller sjuka. De objektiva sensorbaserade bedömningarna har sedan jämförts med subjektiva kliniska bedömningar som utförts av läkare, baserat på UPDRS. Resultatet visar på att IMU-sensorn kan användas för detektering av bradykinesi. Trots detta har modellerna haft svårt att exakt utvärdera svårighetsgraden av bradykinesi och har främst varit inriktade på att klassificera om en patient är frisk eller lider av Parkinsons sjukdom.

En annan tidigare studie syftar till att utveckla ett AI-baserat system för att bedöma den motoriska funktionen hos personer med Parkinsons sjukdom, genom analyser av videor inspelade i hemmiljö [22]. Totalt deltog 250 deltagare från hela världen, som via en webbkamera spelade in sig själva och utförde ett standardiserat fingertappningstest. Tre stycken expertneurologer bedömde videorna oberoende av varandra utifrån skalan 0 till 4 i MDS-UPDRS. Studien utvecklade även algoritmer för att få objektiva mått i enlighet med MDS-UPDRS och dessa mått visade starka korrelationer med expertbedömningarna. Studien visade lovande resultat, dock fanns det vissa osäkerheter, exempelvis kunde tremor påverka rörelseanalyserna negativt. Trots att modellen hanterade lågkvalitativa videor relativt väl, kunde brus eller låg skärpa påverka både det AI-baserade systemets och läkarens bedömning, särskilt vid utvärdering av tremor.

Radarsensorer kan användas för att mäta kropps rörelser på avstånd från patienter [23]. Tekniken har visat stor potential för flera medicinska tillämpningar, inklusive detektering av hjärtslag och andning. Metoden kan på liknande sätt tillämpas vid fingertappningstestet. Där kan tekniken bidra med mätdata som är värdefull då den motoriska funktionen hos patienter med Parkinsons sjukdom ska bedömas.

1.2 Syfte

Syftet med arbetet är att bidra till förbättrad motorisk funktionsbedömning och monitorering av Parkinsons sjukdom, genom utveckling av en teknisk lösning baserad på radarsensorteknik och maskininlärning. Projektet utförs i ett samarbete med Sahlgrenska Universitetssjukhuset.

1.3 Mål

Detta projekt är ett fortsättningsprojekt som bygger på ett examensarbete [24] samt ett masterkursprojekt [25] som utförts av studenter på Chalmers tekniska högskola. I dessa arbeten har en metod som syftar till att effektivisera diagnostik samt uppföljning av Parkinsons sjukdom tagits fram. Metoden bygger på att data från utförande av fingertappningstest samlas in med hjälp av radarsensorteknik. I masterkursprojektet undersöktes möjligheten att använda maskininlärning för klassificering av fingertappningstester med olika antal avbrott.

Målet med kandidatarbetet är att vidareutveckla metoden för att med hög noggrannhet automatisera bedömningen av fingertappningstestet, baserat på de elva kategorierna i MDS-UPDRS enligt figur 1.4.

1.4 Avgränsningar

För att projektet ska vara genomförbart med de förutsättningar som finns har arbetet avgränsningar. Avgränsningarna baseras på tidsramen för ett kandidatarbete som omfattar 15 högskolepoäng samt på de resurser som projektet har att tillgå.

En avgränsning är att de insamlade datapunkterna inte analyseras i realtid, utan bearbetas i efterhand. Detta eftersom datapunkterna används för att skapa algoritmer för maskininlärning och inte kräver omedelbara svar, utan snarare en större mängd datapunkter för att sedan kunna skapa tillförlitliga modeller. Tidsramen och den begränsade tillgången till testpersoner sätter även gränser för antalet tester som kan genomföras. Det begränsar i sin tur mängden data som kan användas för att utveckla maskininlärningsalgoritmerna.

Eftersom projektet inte är en del av en klinisk studie har testerna inte utförts på verkliga patienter med Parkinsons sjukdom. Istället fungerar projektgruppen själva som testpersoner, vilket innebär att deltagarna utgörs av studenter i 20-årsåldern utan kända motoriska funktionsnedsättningar. Detta beror på begränsad tillgång till testpersoner samt att den tid som skulle krävas för att rekrytera externa testpersoner och hantera regler och dokumentation bedöms vara för tidskrävande. Tiden prioriteras istället för andra delar av arbetet.

Under genomförandet av testerna kommer det antas att testpersonerna i övrigt är stilla, då databearbetningen skulle försvåras av att även behöva hantera övriga rörelser. Analysen bygger därmed på ett idealt scenario utan yttre störningar.

2

Teknisk bakgrund

Detta kapitel innefattar en genomgång av tidigare arbeten samt teorin bakom radarsensorteknik och utvalda maskininlärningsalgoritmer.

2.1 Tidigare arbeten

I tidigare arbeten har radarsensorteknik utforskats för att automatisera fingertappningstesten. Vid ett av de tidigare projekten bidrog fysioterapeuter med kunskap för att fingertappningstesten skulle efterlikna verkliga test [24]. Projektet gav relativt goda resultat utifrån de givna förutsättningarna, det vill säga utan applicering av maskininläring. I projektets diskussion analyserades möjligheten till användning av maskininläring och hur detta hade kunnat förbättra metoden.

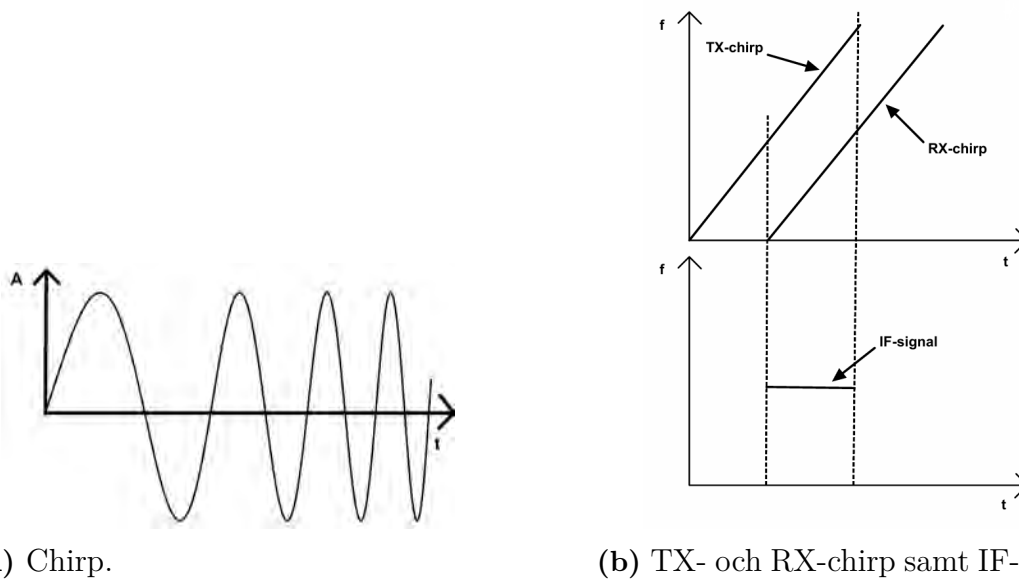
I ett senare projekt tillämpades maskininläring, vilket visade lovande resultat men även potential för förbättring [25]. Ett av projektets största utmaningar var att samla in tillförlitlig data som korrekt återspeglar motoriska rörelser hos patienter med Parkinsons sjukdom, då fysioterapeutiska instruktioner saknades. När data från fysioterapeuter senare användes i maskininlärningsmodellen presterade den sämre i jämförelse med när modellen tränades på data insamlad utan fysioterapeuternas expertis. Detta understryker vikten av att samla in data som realistiskt speglar beteendet hos patienter med Parkinsons sjukdom i framtida projekt, för att förbättra modellens noggrannhet och generaliseringsförmåga. I projektet klassificerades data enbart utifrån förekomst av avbrott. MDS-UPDRS-skalan för fingertappning innefattar utöver avbrott även hastighets- och amplitudminskning, se delkapitel 1.1.2. För att i högre grad efterlikna vårdsammanhang hade en förbättringsmöjlighet därför varit att inkludera alla de kategorier som ingår i MDS-UPDRS-skalan.

Det här kandidatarbetet tar vid där föregående arbeten avslutades. För att möjliggöra insamling av mer verklighetstrogen data utförs arbetet i ett samarbete med Sahlgrenska Universitetssjukhuset. All datainsamling baseras på utförliga instruktioner från fysioterapeuter. Utöver detta utökas antalet kategorier i vilka datapunkterna klassificeras, till att innehålla alla de elva kategorier som ingår i MDS-UDPRS gradering för fingertappning.

2.2 Radarsensorteknik

Den radarsensor som är avsedd att användas i projektet är av modell AWR1642BOOST, tillverkad av Texas Instruments [26]. Denna används i kombination med en data capture board av modell DCA1000EVM [27]. Radarsensorn är av typen Frequency-Modulated Continuous Wave (FMCW). Konfiguration av radarn genomförs med hjälp av den tillhörande programvaran mmWave Studio från Texas Instruments [28].

En FMCW-radar sänder ut en sinusformad signal vars frekvens ökar linjärt med tiden [29]. En sådan signal kallas en chirp och visualiseras i figur 2.1a. Chirpen genereras av en synthesizer och sänds sedan ut av en transmitter (TX). Därefter reflekteras signalen av det objekt den når och den reflekterade chirpen tas emot vid en receiver (RX). Den reflekterade signalen RX är en fördröjd version av den utsända signalen TX, se figur 2.1b. Signalerna TX och RX är insignaler till en mixer som ger en utsignal vars frekvens är skillnaden mellan frekvenserna för de två insignalerna. Utsignalen som genereras av mixern kallas Intermediate Frequency (IF) signal.



(a) Chirp.

(b) TX- och RX-chirp samt IF-signal.

Figur 2.1: Illustration som visar en chirp samt beskriver hur IF-signalen förhåller sig till TX- och RX-chirpen.

Varje objekt som TX-chirpen når resulterar i en RX-chirp vilket innebär att flera objekt framför radarn medför flera RX-chirps [29]. Det resulterar i ett spektrum av frekvenser för IF-signalen där vardera objekt är representerat av en topp. Frekvensen för varje topp i spektrumet är proportionell mot avståndet till det objektet som skapat reflektionen. Dessutom motsvarar fasskillnad en rörelse hos objektet vars hastighet därav kan mätas genom att utnyttja fasskillnaden mellan två efterföljande chirps. Avståndsupplösningen representerar det minsta avstånd som kan detekteras och beror av chirpens bandbredd. Ökad bandbredd leder till förbättrad upplösning [30]. Hastighetsupplösningen förbättras även av längre chirpdurationer [31]. Hastighetsupplösning representerar radarns förmåga att avgöra med vilken hastighet ett

detekterat objekt rör sig. Insamlad data omvandlas från analog till digital, sedan appliceras Fast Fourier Transform (FFT) för att konvertera till frekvensdomänen [29].

Radarsensorn sänder ut elektromagnetiska vågor som reflekteras av objekten framför [23]. De reflekterade signalerna analyseras sedan och ger information om objekten och därmed den utförda rörelsen. På så sätt kan radarsensortekniken appliceras vid bedömning av fingertappningstestet.

2.3 Maskininläring

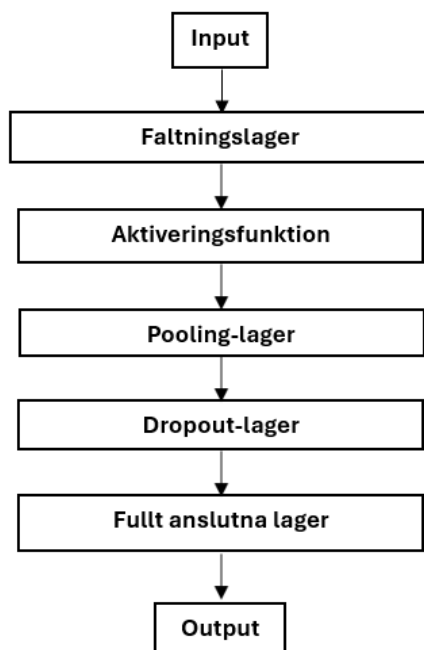
Inom fenomenet artificiell intelligens är maskininläring en av huvudgrenarna. Maskininläring bygger på att en algoritm tillhandahåller data och utifrån denna på egen hand lär sig att detektera mönster och göra prediktioner [32]. Nedan beskrivs de maskininlärningsalgoritmer som används i detta arbete.

2.3.1 Convolutional Neural Network

Convolutional Neural Network (CNN) är en typ av maskininlärningsalgoritm. Det är ett neuralt nätverk av typen feedforward som använder djupinläring [33]. One Dimensional Convolutional Neural Network (1D-CNN) används då den data som ska analyseras är endimensionell. Exempel på sådan data är textsekvenser och tidsserier.

1D-CNN har ett antal huvudkomponenter. En av dessa är faltningsslager [33], där relevanta egenskaper hämtas från inputdata [34]. I faltningsslager finns filter som rör sig längs med ingångssekvensen. Här utförs faltningsoperationer, som för varje respektive filter resulterar i en aktiveringskarta, som representerar de egenskaper som detekterats. Aktiveringsfunktioner, som är en annan grundläggande komponent i 1D-CNN, tillämpas på de aktiveringskartor som producerats genom faltningsslagets faltningsoperationer. Användande av aktiveringsfunktioner syftar här till att, genom införande av icke-linjära transformationer, möjliggöra identifiering av komplexa icke-linjära mönster i data. Ett exempel på en typ av aktiveringsfunktion som ofta används i CNN är Rectified Linear Unit (ReLU). En tredje huvudkomponent i 1D-CNN är pooling-lager, som har i uppgift att komprimera data i aktiveringskartorna [34]. Denna komprimering sker genom att data från närliggande punkter i kartorna sammanfogas [33]. Datakomprimeringen i pooling-lager medför, utöver en minskad belastning beräkningsmässigt samt framhävande av relevant information [35], även en minskad känslighet för små variationer i inputdata [36]. Max-pooling samt medelvärdes-pooling är två av de vanligast förekommande typerna av pooling i CNN [37]. En annan viktig komponent i 1D-CNN är fullt anslutna lager, där information som extraherats från faltningsslager samt pooling-lager kombineras, i syfte att ligga till grund för slutgiltiga beslut, vilket krävs för exempelvis klassificering [33]. Slutligen finns i 1D-CNN även så kallade dropout-lager [38]. Dropout-lagers huvudsakliga funktion är att motverka överfitting (jfr. sv. överanpassning), genom inaktivering av ett antal av neuronnätets kopplingar. Dessa tillämpas på faltningsslager eller fullt anslutna lager [38]. Figur 2.2 visar en översiktlig schematisk illustration

av 1D-CNN, innehållande dess huvudkomponenter.




Figur 2.2: Schematisk illustration av 1D-CNN-struktur.

1D-CNN 3 layer (jfr. sv. lager) har tre faltningslager, till skillnad från 1D-CNN 1 layer och 1D-CNN 2 layer, vilka har ett respektive två lager. Jämfört med de typer av 1D-CNN som har färre lager, finns hos 1D-CNN 3 layer möjlighet till lärande av mer komplexa mönster [39]. Anledningen till detta är att den information som extraheras i varje lager är av olika karaktär och kan kombineras med information från tidigare lager [40].

2.3.2 Long Short-Term Memory

Sekventiell data kan utöver 1D-CNN även hanteras av bland annat neurala nätverk av typen Long Short-Term Memory (LSTM) [41]. LSTM är ett så kallat Recurrent Neural Network (RNN) [42]. Till skillnad från nätverk av typen feedforward så använder RNN återkoppling [43], se figur 2.3. Detta innebär att inputdata i varje steg, utöver den aktuella datapunktens information, även innehåller outputinformation som sparats från föregående steg i sekvensen. Återkopplingskomponenten kallas för hidden state. Hidden state uppdateras vid varje steg i sekvensen och innehåller information från varje steg fram till det aktuella. Denna typ av återkoppling möjliggör lärande av temporala mönster.



Figur 2.3: Schematisk illustration av RNN-struktur.

Enkla typer av RNN har dock i regel svårt att hantera sekvenser innehållande mönster som sträcker sig över längre tidsperioder. Detta beror på att gradienterna för steg långt innan det aktuella steget försvinner under träning, vilket innebär att information från dessa tidiga steg går förlorad. LSTM utvecklades i syfte att minimera detta problem. Hos LSTM finns, utöver hidden state, även så kallade cell states. För varje steg i datasekvensen sparas ett nytt cell state. Utgångspunkten för varje tidsstegs cell state är föregående stegs cell state. Viktiga komponenter relaterade till cell states är tre olika typer av gates. Genom samverkan mellan dessa gates respektive funktioner bestäms vilken data som ingår i varje cell state [43]. Två input gates avgör vilken information från det aktuella tidssteget som ska inkluderas i stegets cell state [42]. En forget gate har i uppgift att bestämma vilken data som ska elimineras från cell state [43]. Via en output gate regleras vilken information som slussas vidare som output från hidden state. Denna utökade funktionalitet hos LSTM jämfört med hos simplare RNN medför att bevarande av gradienter under längre tidsperioder tillåts. Detta innebär att LSTM är bättre lämpat för lärande av långtidsberoenden [43].

En maskininlärningsmodell som bygger på en kombination av tidigare beskrivna 1D-CNN samt LSTM (CNN-LSTM) har visat sig kunna uppnå hög noggrannhet (jfr. eng. accuracy) vid tillämpning på tidsserier [44].

3

Metod

Detta kapitel innefattar en genomgång av metoden bestående av samarbetet med Sahlgrenska Universitetssjukhuset, utförandet av datainsamlingen och bearbetningen av maskininlärningsalgoritmerna.

3.1 Samarbete med fysioterapeuter

Projektets mål och syfte har noggrant bearbetats i samarbete med Sahlgrenska Universitetssjukhuset för att anpassas efter deras behov och önskemål. Ett möte genomfördes med två fysioterapeuter med specialisering inom neurologi och kompetens inom Parkinsons sjukdom. Under mötet identifierades behoven, metoden diskuterades och projektets mål fastställdes. Fysioterapeuterna gav en genomgång av den allmänna fysiologin hos patienter med Parkinsons sjukdom. Samtidigt förklarade de MDS-UPDRS samt sina arbetsmetoder för att tillämpa det i praktiken och hur de kvantifierar samtliga kategorier. Fysioterapeuterna bidrog med videomaterial som visade utförandet av de elva kategorierna utifrån MDS-UPDRS, se figur 1.4. Detta gav projektgruppen bästa möjliga förståelse och förutsättningar för utförandet av projektet.

I arbetets slutskede genomfördes ett ytterligare möte med fysioterapeuterna där en av dem användes som testperson för datainsamling. Dessa datapunkter från fysioterapeuten användes för att testa användbarheten av metoden.

3.2 Datainsamling

Till datainsamlingen användes Texas Instruments AWR1642BOOST radarsensor med en DCA1000EVM data capture board i tre färdigkonfigurerade uppsättningar. Till detta användes mmWave Studio 02.01.01.00 med given konfiguration enligt bilaga A. Testsekvensen för samtliga test var tio sekunder lång med 40 000 data frames.


För att träna maskininlärningsmodellen krävdes en omfattande mängd data. Datainsamlingsbehovet definierades initialt utifrån MDS-UPDRS gradering av fingertappning, vilket resulterade i elva kategorier för insamling och senare analys. Kategori 0 definierades som ett normalt rörelsemönster, där fingertappningen var konstant utan avbrott med hög frekvens och amplitud. Kategori 4 definierades sedan som ett rörelsemönster där fingertappningen inte tydligt utförs på grund av antingen för

långsamt tempo, freezing eller för liten amplitud.

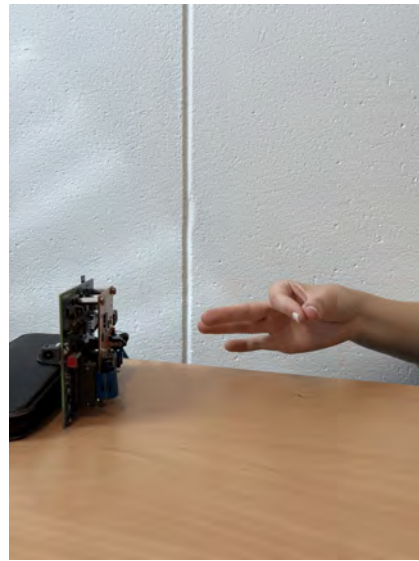
Övriga kategorier delades upp i tre delkategorier utifrån typ av avvikande rörelsemönster, se figur 1.4. Delkategori a utgjordes av avbrott, där kategori 1a motsvarade ett till två avbrott eller tvekan under testsekvensen. Kategori 2a motsvarade tre till fem avbrott och kategori 3a fler än fem avbrott alternativt freezing. Delkategori b utgjordes istället av förlångsamning, där fysioterapeuternas video stod till grund för tempo på fingertappning. Tempot i kategori 1b definierades som lätt förlångsamning, i kategori 2b som mild förlångsamning och i kategori 3b som måttlig förlångsamning. Delkategori c utgjordes av en amplitudminskning, där kategori 1c innebar att amplituden minskade under de sista 2 sekunderna av testet, det vill säga mellan sekund 8 till sekund 10. Kategori 2c avsåg en amplitudminskning som inleddes halvvägs in i testsekvensen, med start mellan sekund 5 och 8. Kategori 3c betecknade en amplitudminskning som påbörjades tidigt i testförloppet, inom intervallet sekund 1 till 4.

Varje test genomfördes av en testperson som instruerades att simulera en specifik rörelsekategori enligt det definierade klassificeringssystemet. Totalt sex personer deltog i datainsamlingen och både höger och vänster hand användes. Antalet tester per kategori fördelades så jämnt som möjligt mellan testpersonerna samt fördelning mellan höger och vänster hand. För varje kategori var målsättningen ett datainnehåll om minst 200 enskilda tester.

Testpersonen genomförde testet sittandes. Handen placerades på ett avstånd om cirka 15 cm från radarsensorn, som stod uppställd på ett bord framför testpersonen. Kategorierna 0, 1b, 2b samt halva 3b genomfördes med handen placerad vertikalt enligt figur 3.1a. Övriga kategorier genomfördes med handen placerad horisontellt enligt figur 3.1b.



(a) Fingertappning med handen placerad vertikalt.



(b) Fingertappning med handen placerad horisontellt.

Figur 3.1: Fingertappning med olika handplaceringar.

3.3 Maskininlärning och algoritmer

Parallellt med datainsamlingen genomfördes ett urval bland potentiella maskininlärningsalgoritmer. Urvalet utgick främst från informationen från tidigare arbeten, sedan gjordes även ytterligare informationssökning om maskininlärningsmodeller som kunde kombineras med den redan befintliga algoritmen, se delkapitel 2.3. Algoritmen skulle på ett effektivt sätt analysera och klassificera insamlad data i enlighet med projektets syfte och avgränsningar. Utifrån dessa kriterier fortsatte därmed arbetet med att modifiera den redan befintliga maskininlärningsalgoritmen från det tidigare arbetet, som byggde på 1D-CNN 3 layer.


Koden justerades utefter de insamlade datapunkterna och ändringarna som gjordes bestod därför till stor del av modifieringar för att få algoritmen att fungera för de elva kategorierna. Detta skiljde sig från det tidigare arbetet [25] som utformade koden för endast sex kategorier. Algoritmen testades initialt med enbart insamlad data. Därefter genomfördes ett andra test, denna gång med augmenterad data, vilket resulterade i fler datapunkter för algoritmen att tränas på.

3.3.1 Algoritmens struktur

Den första delen av koden laddade in matrisfilerna och säkerställde att filerna kategoriserades korrekt av algoritmen. Detta gjordes genom att extrahera numreringen från filnamnen, för att sedan tilldela alla filer ny numrering för att upptäcka eventuella luckor i ordningsföljden. För att kontrollera att kategoriseringen fungerade som avsett skapades slumpmässiga figurer av varje kategori.

3. Metod

Därefter följde dataaugmenteringsdelen, som inte användes i det första testet, men implementerades i det andra. Dataaugmenteringen utfördes genom att vertikalt vända signalerna, se figur 3.2a och figur 3.2b. De nya värdena adderades till den befintliga datamängden för vidare användning i koden. För att tydliggöra skillnaden i antal element mellan datapunkterna utan och med augmentation skapades även stapeldiagram.



(a) Dopplersignatur av ett test.

(b) Dopplersignatur efter vertikal vändning.

Figur 3.2: Dopplersignatur från kategori 2c.

Klassificeringarna tilldelades därefter nya labels, där varje kategori fick ett unikt nummer. Kategori 0 fick label 0, kategori 1a fick label 1, kategori 1b fick label 2 och så vidare, upp till kategori 4 som fick label 10. Detta gjordes genom att omvandla namnet på labels från stringssekvenser till integers, för att underlätta för algoritmen att förstå och hantera de elva olika kategorierna.

Datapunkterna delades upp i tre datasets, där 70 % var träningsdata, 15 % var valideringsdata samt 15 % var testdata. Sedan användes maskininlärningsalgoritmen 1D-CNN 3 layer. Grafer av tränings- och valideringsprestandan samt förvirringsmatriser (jfr. eng. confusion matrix) skapades, för att kunna utvärdera hur väl algoritmen presterat.

Ett tredje och ett fjärde test genomfördes, där maskininlärningsalgoritmen vidareutvecklades med LSTM. Testen utfördes både med augmented data och med enbart insamlad data. Ytterligare ändringar gjordes också i algoritmen för dessa tester, exempelvis förstärktes den första faltningsmatrisen genom att öka storleken från tre till fem. Vidare ersattes `BatchNorm1d` med `GroupNorm` i faltningssteget, för att dela upp varje signal i fler delar. Optimizern byttes från `Adam` till `AdamW` för att hantera viktningen på ett mer korrekt sätt. Dropout-lagret minskades för att ta hänsyn till LSTM-delen. Det fullt anslutna lagret `fc1` ändrades för att bevara tidsdimensionen för LSTM.

Ett femte test genomfördes sedan som byggde vidare på CNN-LSTM med augmenterad data. En 5-fold korsvalidering med 50 epoker implementerades, för att undersöka modellens generaliseringsförmåga. Valideringsnoggrannheten samt valideringsförlusten för korsvalideringen togs fram.

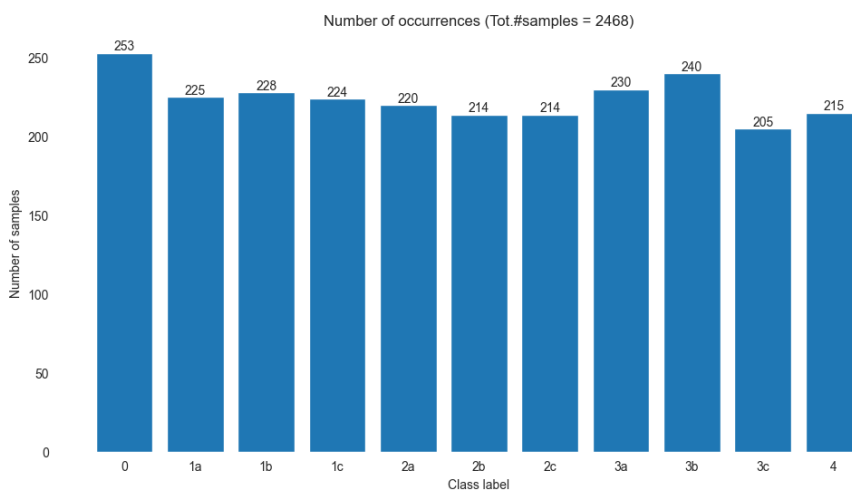
4

Resultat

Detta kapitel innefattar en genomgång av resultatet från datainsamlingen, dataaugmentationen samt maskininlärningen.

4.1 Datainsamling

Totalt samlades 2468 tester in, fördelade mellan de elva kategorierna i MDS-UPDRS enligt figur 4.1. Utav dessa tester genomfördes 810 tester med vertikal handuppställning enligt figur 3.1a. Resterande tester genomfördes med horisontell handuppställning enligt figur 3.1b.

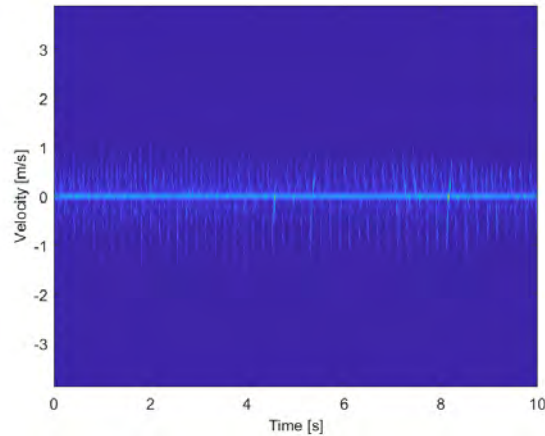


Figur 4.1: Antal filer per kategori.

Samtliga tester visualiserades i MATLAB, vilket gav signaler som presenteras i följande delkapitel.

4.1.1 Kategori 0 - normal


Det normala rörelsemönstret framgår i figur 4.2, där signalen är relativt jämn i frekvens och amplitud. Den saknar även tecken på avbrott.




Figur 4.2: Kategori 0. Normalt rörelsemönster.

4.1.2 Delkategori a - avbrott


Avbrotten kan avläsas i figurerna 4.3a, 4.3b och 4.3c som uppehåll i signalen. Antalet avbrott ökar med stigande klassificeringsgrad.



(a) Kategori 1a med två avbrott i signalen.



(b) Kategori 2a med fyra avbrott i signalen.




(c) Kategori 3a med sex avbrott och ett tillfälle av freezing i signalen.


Figur 4.3: Delkategori a. Avbrott i rörelsemönstret.

4.1.3 Delkategori b - minskad hastighet

Hastighetsminskningen kan avläsas i figurerna 4.4a och 4.5b. Hastigheten visualiseras med hjälp av signalens frekvens och minskar med stigande klassificeringsgrad.




(a) Kategori 1b med lätt förlångsamning.




(b) Kategori 2b med mild förlångsamning.

Figur 4.4: Delkategori b. Grad 1 och 2. Minskad hastighet i rörelsemönstret.

Vid kategori 3b uppstod problem för radarsensorn att läsa av signalerna. Riktningen på handen i förhållande till sensorn justerades. I figur 4.5a visas exempel på signalen från den initiala handuppställningen i figur 3.1 då handen var riktad vertikalt, vilket gav svåravlästa visualiseringar. I figur 4.5b visas exempel på signalen då handen var riktad horisontellt.



(a) Kategori 3b med måttlig förlångsamning. Vid testet var handen placerad vertikalt.




(b) Kategori 3b med måttlig förlångsamning. Vid testet var handen placerad horisontellt.

Figur 4.5: Delkategori b. Grad 3. Minskad hastighet i rörelsemönstret.

4.1.4 Delkategori c - amplitudminskning

Amplitudminskningen kan avläsas i figurerna 4.6a, 4.6b och 4.6c. Minskningen uppstår tidigare under sekvensen med stigande klassificeringsgrad.



(a) Kategori 1c med amplitudminskning vid 8 sekunder.


(b) Kategori 2c med amplitudminskning vid 5,5 sekunder.

(c) Kategori 3c med amplitudminskning vid 1,5 sekunder.

Figur 4.6: Delkategori c. Minskad amplitud i rörelsemönstret.

4.1.5 Kategori 4 - svåra symptom

Kategori 4 utgjordes av avsaknad av rörelse orsakad av en eller flera av delkategoriernas motoriska störningar. Skillnaderna i typen av störning medförde även en bred variation bland signalerna inom kategorin. Exempel på detta syns i figurerna 4.7a, 4.7b, 4.7c.



(a) Kategori 4 med avsaknad av rörelse.

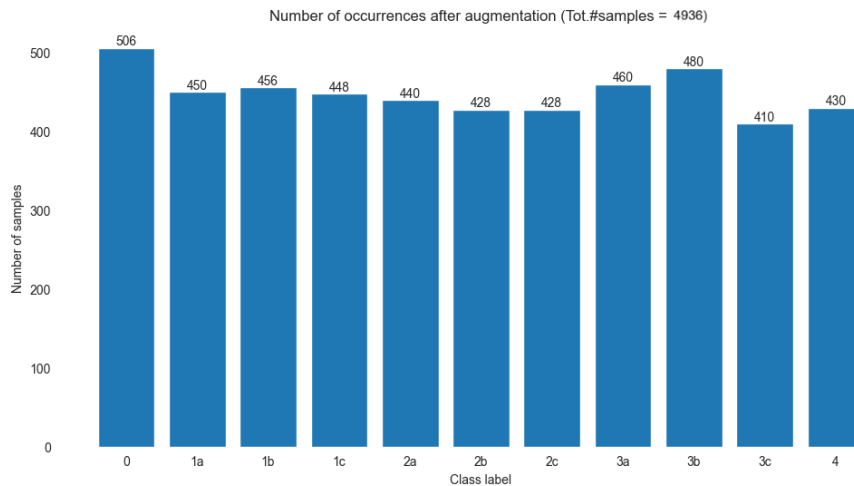
(b) Kategori 4 med enstaka amplitudtoppar.

(c) Kategori 4 med frekventa amplitudtoppar.

Figur 4.7: Kategori 4. Avsaknad av rörelsemönster.

4.2 Dataaugmentation

Efter augmentering av data, se figur 3.2b, uppgick det totala antalet tester till 4936. Kategorierna var fördelade enligt figur 4.8.



Figur 4.8: Antal filer per kategori efter augmentering av data.

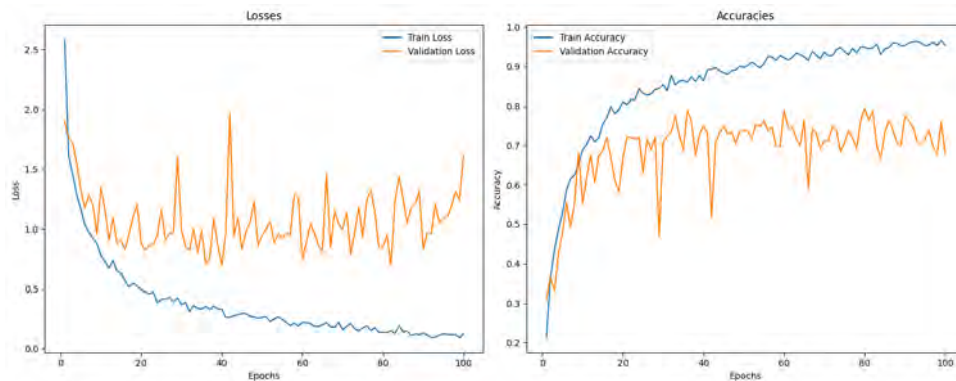
4.3 Maskininlärning

Resultat visualiseras för både insamlad data och augmenterad data. I vardera graf nedan visar vänstra diagrammet utvecklingen av förlustvärden (jfr. eng. loss) för tränings- och valideringsdata. Det högra diagrammet visar noggrannheten under träningens gång. För förvirringsmatrisen visar y-axeln den sanna kategori och x-axeln visar den predikterade kategorin.

4.3.1 CNN

Figur 4.9 visar modellens tränings- och valideringsprestanda över 100 epoker för insamlad data. Träningsförlusten minskar stadigt och stabiliseras efter cirka 70 epoker, vilket tyder på att modellen gradvis anpassas till träningsdata. Valideringsförlusten varierar däremot mer mellan epokerna. Träningsnoggrannheten ökar snabbt till över 90 %. Valideringsnoggrannheten stabiliseras runt 70 % men fortsätter att variera mellan epokerna.

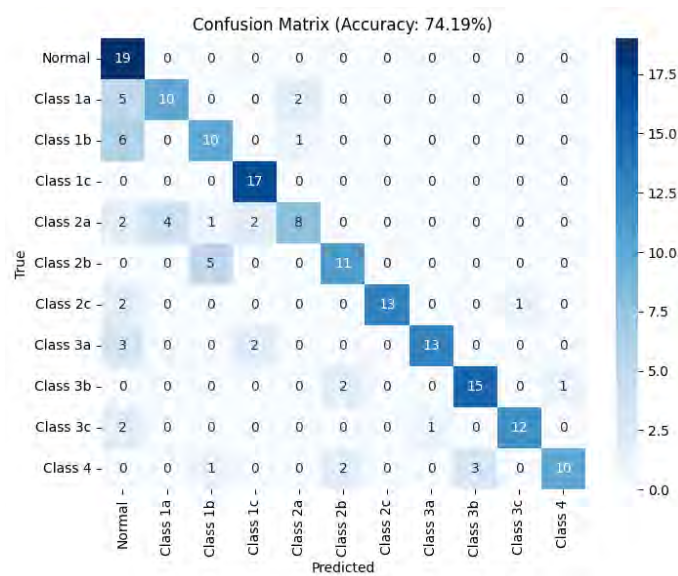
4. Resultat



Figur 4.9: Tränings- och valideringsförlust samt noggrannhet för det neurala nätverket över epoker på insamlad data.

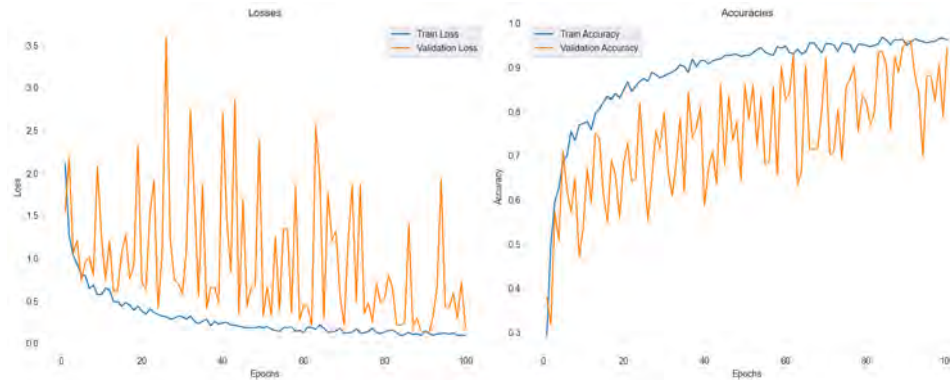
Förvirringsmatrisen i figur 4.10 visar modellens förmåga att korrekt klassificera de olika kategorierna för testdata. Den totala klassificeringsnoggrannheten uppgick till 74,19 %. Vid träningens slut kunde modellen därför korrekt klassificera ungefär tre fjärdedelar av all valideringsdata.

Vissa kategorier klassificeras med hög precision, däribland kategori 1c och normal-kategorin som uppnådde 17 respektive 19 korrekt klassificerade fall. Samtidigt syns viss förväxling mellan kategorier. Exempelvis förväxlades kategorierna 1a och 2a samt även kategorierna 3b och 4.




Figur 4.10: Förvirringsmatris för insamlad data över vardera kategori med en valideringsnoggrannhet på 74,19 %.

I figur 4.11 visas tränings- och valideringsresultaten efter att modellen tränats med augmenterad data. Träningsförlusten minskar stabilt över tid och når låga nivåer. Valideringsförlusten uppvisar stora variationer mellan epoker. Detta mönster syns även i valideringsnoggrannheten som visar en övergripande positiv trend och når upp till 90 % vid flera tillfällen, trots stor variation.



Figur 4.11: Tränings- och valideringsförlust samt noggrannhet för det neurala nätverket över epoker på augmenterad data.

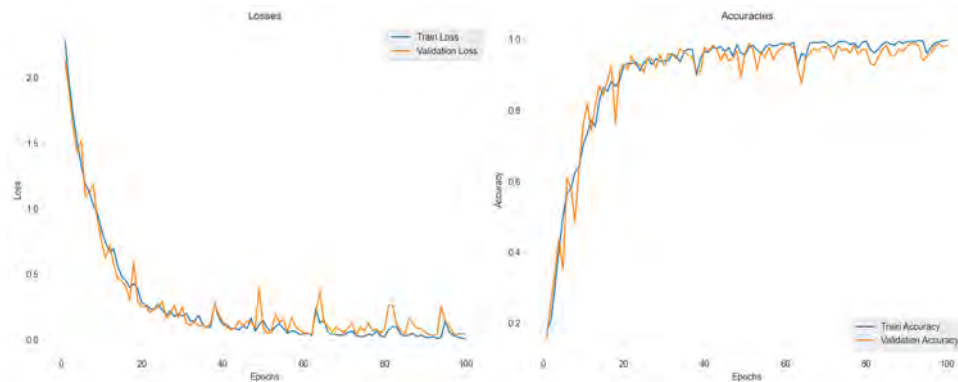
Figur 4.12 visar modellens förmåga att korrekt klassificera de olika kategorierna i augmenterad testdata. Den totala klassificeringsnoggrannheten uppgick till 92,72 %. De flesta kategorierna blev korrekt klassificerade. Kategorierna 1c och 2c blev exempelvis aldrig felklassificerade medan de andra kategorierna hade någon felklassificering. Ett par gånger förväxlades liknande kategorier, som kategorierna 3b, 3c och 4. Även semantiskt liknande kategorier förväxlades, som kategorierna 1b och 2b. Modellen gjorde flest prediktioner mot normalkategorin.



Figur 4.12: Förvirringsmatrix för augmenterad data över vardera kategori med en valideringsnoggrannhet på 92,72 %.

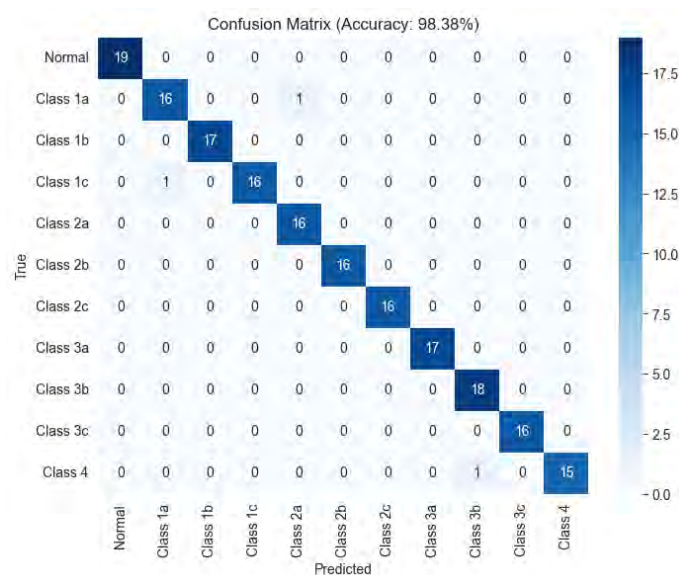
4.3.2 CNN-LSTM

Graferna i figur 4.13 visar att variationen i förlusterna är betydligt mindre än i figurerna som visas i delkapitel 4.3.1. Valideringskurvan för både noggrannhet och förlust följer generellt trenden som syns i träningskurvan.



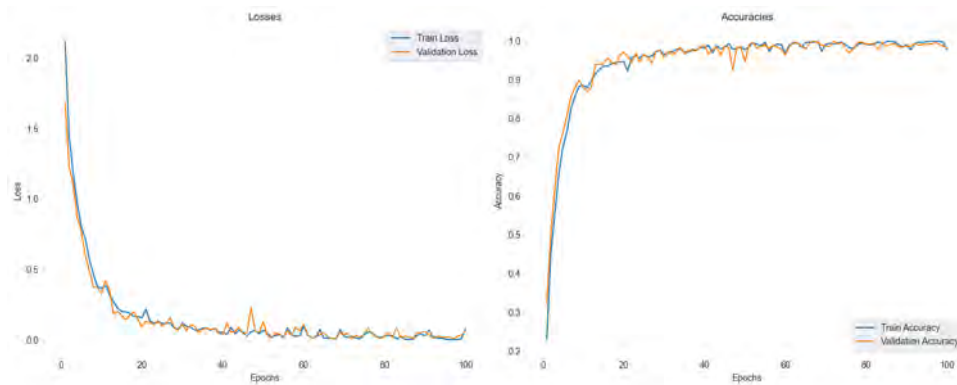
Figur 4.13: Tränings- och valideringsförlust samt noggrannhet för modellen över epokerna för insamlad data.

Förvirringsmatrisen som syns i figur 4.14 visar att modellen har hög noggrannhet vid slutet av träningen. Algoritmen gör enstaka misstag vid klassificering.




Figur 4.14: Förvirringsmatrisen för insamlad data över vardera kategori med en valideringsnoggrannhet på 98,38 %.

Figur 4.15 visar tränings- och valideringsresultaten efter att modellen tränats med augmenterad data. Både tränings- och valideringsförlusten går jämnt ner med antalet epoker, samtidigt som tränings- och valideringsnoggrannheten går upp. Enligt grafen blev modellen osäker runt epok 50, där valideringsförlusten gick upp och valideringsnoggrannheten gick ned. Modellen börjar konvergera efter förlusten runt epok 50.



Figur 4.15: Tränings- och valideringsförlust samt noggrannhet för modellen över epokerna för augmenterad data.

Figur 4.16 visar modellens förmåga att korrekt klassificera de olika kategorierna. De flesta kategorierna blev korrekt klassificerade med en klassificeringsnoggrannhet på 97,84 %. Algoritmen gör enstaka misstag vid klassificering.



Figur 4.16: Förvirringsmatrisen för augmenterad data över vardera kategori med en valideringsnoggrannhet på 97,84 %.

4.3.3 Korsvalidering

CNN-LSTM-modellens generaliseringsförmåga, i form av 5-fold korsvalidering, visas i tabell 4.1.

Tabell 4.1: Resultat från 5-fold korsvalidering.

Fold	Valideringsnoggrannhet (%)	Valideringsförlust
1	97,52	0,0668
2	98,07	0,0509
3	97,46	0,0735
4	99,28	0,0253
5	96,17	0,0906
Medelvärde	97,70	0,0615

Variationen av valideringsnoggrannheten är relativt låg, där skillnaden mellan högsta och lägsta noggrannheten ligger på 3,11 procentenheter. Valideringsförlusten är generellt låg.

5

Diskussion

Detta kapitel innefattar en övergripande diskussion om metod och resultat samt felkällor och vidareutveckling.

5.1 Reflektion kring metod och resultat

Detta delkapitel redovisar en övergripande diskussion av olika faktorer som ligger till grund för metoden och resultatet.

5.1.1 Modifiering av MDS-UPDRS

MDS-UPDRS del III används för att bedöma patientens motoriska funktioner och utgår från att patienten upprepar fingertappningsrörelsen tio gånger. Graderingen är baserad på förändringar i rörelsens amplitud, hastighet och eventuella avbrott under dessa repetitioner. För detta projekt valdes att genomföra testerna under en fast tidsperiod på tio sekunder, istället för att utgå från tio upprepade rörelser. Till skillnad från den traditionella bedömningen enligt MDS-UPDRS, som enbart har baserats på visuell observation av en utredare, har detta projekt samlat in rörelserna med hjälp av en radarsensor. Det har medfört att rörelserna inte omedelbart har bedömts och en utmaning uppstod i att objektivt definiera och identifiera enskilda rörelser på ett jämförbart sätt. En tidsbaserad testperiod bedömdes därför som mer lämplig, då den möjliggjorde en repeterbar och automatiserad process utan subjektiva tolkningar. Ett konstant tidsintervall innebar även att radarns inställningar kunde hållas enhetliga mellan datainsamlingsomgångarna, vilket i sin tur förbättrade jämförbarheten och kvaliteten på insamlad data. Trots att denna metod avviker från MDS-UPDRS ursprungliga instruktioner bedömdes anpassningen som lämplig för att uppnå en tillförlitlig och praktiskt genomförbar datainsamling inom ramen för projektets förutsättningar.

I delkategori b baserades hastigheten vid olika grader av förlångsamning enbart på det videomaterial som tillhandahållits av fysioterapeuterna. Vid en efterkonstruerad beräkning av hastigheterna i videorna motsvarade kategori 1b ett tempo på cirka 130 bpm, kategori 2b ett tempo på cirka 85 bpm och kategori 3b ett tempo på cirka 30 bpm. I MDS-UPDRS saknas samtidigt en kvantitativ definition av förlångsamning. Det innebär att i ett verkligt scenario är dessa hastigheter en subjektiv bedömning utifrån varje enskild fysioterapeuts erfarenheter. Detta ökar komplexiteten i att kategorisera olika nivåer av förlångsamning, då tydliga gränser mellan

kategorier saknas.

5.1.2 Användning av augmenterad data

För augmenterad data uppnåddes för 1D-CNN en total klassificeringsnoggrannhet på 92,72 %, se figur 4.12, jämfört med för insamlad data där noggrannheten uppgick till 74,19 %. Detta tyder på att dataaugmentation har bidragit till en förbättrad prestanda hos modellen. I resultatet för augmenterad data som presenteras i figur 4.11 syns att förlustvärden samt noggrannhet hos valideringsdata generellt följer trenden hos motsvarande värden i träningsdata, jämfört med hos insamlad data. Hos valideringsdata observeras även en hög toppnoggrannhet. Detta indikerar att modellen har blivit bättre på att lära sig robusta mönster. De kraftiga svängningarna i valideringskurvorna tyder dock på instabilitet i inläringen.

5.1.3 Klassificeringsproblem med CNN-modellen

Resultaten från förvirringsmatriserna i figurerna 4.9 och 4.12 visar tydligt att modellen tenderar att överprediktera normalkategorin. Detta mönster förekommer i både insamlad data och augmenterad data, vilket kan antyda att modellen har en viss bias mot denna kategori. En trolig förklaring till det är den obalanserade kategorifördelningen i träningsdata, där normalkategorin var något överrepresenterad jämfört med övriga kategorier. Detta kan ha resulterat i att modellen lärt sig att associera en större del av det inkommande datamönstret till denna kategori, vilket i sin tur riskerar att ge upphov till falska resultat. Den här typen av fel är särskilt problematiskt vid klassificering av högre kategorier, som representerar ett allvarligt tillstånd. Det faktum att modellen felaktigt klassificerar exempelvis kategori 3c som normalkategorin antyder att klassificeringen vid ett antal tillfällen sker med låg säkerhet eller genom rena gissningar. Detta är negativt ur ett praktiskt perspektiv, eftersom en felklassificering av denna typ hade kunnat få stora konsekvenser om modellen skulle användas i ett kliniskt sammanhang som beslutsstöd. Samtidigt bör det noteras att viss osäkerhet kring grad 1, speciellt för delkategorierna a och b, kan vara rimlig. Även vid visuell analys av signalen upplevdes kategorierna gentemot normalkategorin som svårtolkade. Modellens benägenhet att felprediktera denna kategori speglar därmed även de utmaningar som finns i den mänskliga tolkningen av datapunkterna från gruppens sida.

Förvirringsmatrisen i figur 4.12 visar på att CNN-modellen med augmenterad data har svårt att särskilja mellan kategorierna 3b, 3c, och 4. Detta kan bero på att rörelsemönstren för kategorierna är mycket lika, vilket gör att datapunkterna i vissa fall förväxlas. Modellen har exempelvis vid vissa tillfällen klassificerat kategori 3b, som representerar en måttlig förlångsamning, som kategori 4, som motsvarar en kraftigare förlångsamning. Felklassificeringen kan bero på att algoritmen har haft svårt att kvantifiera skillnaderna mellan de olika graderingarna av förlångsamning. Vidare har kategori 4 ibland förväxlats med kategori 3c, där en viktig skillnad är att amplitudminskningen i kategori 3c sker först efter den första fingerrörelsen. En möjlig förklaring till detta är att amplitudminskningen skett så tidigt och hastigt

i testet att radarsensorn inte hunnit registrera förändringen. Amplitudminskningen syns därför inte bland datapunkterna, vilket medför att rörelsemönstret mellan kategori 4 och kategori 3c uppvisar stora likheter. Därmed försämras modellens förmåga att korrekt differentiera mellan kategorierna.

I förvirringsmatrisen för CNN-modellen med augmenterad data, se figur 4.12, är de kvarstående felkategoriseringarna främst inom delkategori b. Kategori 2b felklassificeras som antingen normalkategorin eller kategori 1b. Även kategori 1b felklassificeras som normalkategorin. För kategori 1b och 2b kan detta delvis bero på att det finns en naturlig semantisk likhet mellan kategorierna.

5.1.4 Ändringar i algoritmen för LSTM

När LSTM-delen lades till i modellen ersattes funktionen `BatchNorm1d` med `GroupNorm`. `GroupNorm` normerade per exempel istället för per batch, vilket gjorde normeringen mer specifik. En konsekvens av detta var att beräkningskostnaden ökade. Det bedömdes dock vara en acceptabel kompromiss för att förbättra modellens prestanda. Om projektgruppen utformat 1D-CNN-algoritmen från grunden hade funktionen `GroupNorm` använts från början, eftersom den verkade mer stabil.

För att hantera weight decay bättre byttes regulariseringsfunktionen `Adam` ut mot `AdamW`. Genom att minska viktstorlekarna kunde instabilitet reduceras, vilket i sin tur kunde förbättra modellens prestanda. Trots att 1D-CNN-algoritmen inte uppvisade en tydlig tendens till överfitting, ansågs det ändå fördelaktigt att byta optimizer för att minska instabiliteten.

Faltningsstorleken i det första lagret ökades från tre till fem för att skapa ett större tidsfönster och fånga bredare rörelsemönster i indata. Faltningsstorleken fungerade dessutom som ett lågpasfilter, vilket minskade känsligheten för närliggande brus. Den här typen av ändring hade projektgruppen troligtvis infört i 1D-CNN-algoritmen om modellen hade utformats från grunden.

Dropout användes i både CNN- och LSTM-delarna av modellen för att begränsa överfitting. I den utökade modellen med LSTM minskades dropout-nivån i CNN-lagren för att undvika överreglering, då LSTM-delen också bidrar till generalisering. I LSTM-lagret sattes dropout till 0,3 eftersom högre dropout försämrade modellens förmåga att hantera inputdata.

5.1.5 LSTM

För att minska variationen i förlust- och noggrannhetsgraferna i figurerna 4.9 och 4.11 lades en LSTM-del på den tidigare gjorda modellen. Resultatet i figurerna 4.13 och 4.15 visar att modellen har tränats och validerats på den data som användes med hög säkerhet. Variationen minskade kraftigt i jämförelse mot CNN-modellen utan LSTM-delen. Vid slutet av träningen visar förvirringsmatriserna att noggrannheten för de insamlade datapunkterna är högre än för de augmenterade datapunkterna.

Detta beror på att mot slutet av de 100 epokerna är valideringsgrafens för de insamlade datapunkterna i en uppåtgående trend, medan den är i en dipp för augmenterad data. Utifrån detta går det inte att dra någon slutsats om att den ena är bättre än den andra. Över hela träningen syns det däremot att variationen i graferna minskar med augmenterad data, vilket innebär att modellen har tränats till att bli mer robust och pålitlig.

Tillägget av LSTM-delen resulterade i en mer stabil modell med förbättrad generaliseringsförmåga, särskilt i hanteringen av sekventiella mönster i både insamlad och augmenterad data. Modellen uppvisade konsekvent låga förluster och en jämn valideringsprestanda över träningsepokerna. En tydlig förbättring jämfört med 1D-CNN-algoritmen var en reducerad bias mot normalkategorin, vilket tyder på att LSTM-delen lyckades fånga mer differentierad temporal information. Dessa resultat indikerar att den utvecklade CNN-LSTM-algoritmen har potential som grund för framtida arbete inom området.

5.1.6 Korsvalidering

För att utvärdera modellens generaliseringsförmåga genomfördes en 5-fold korsvalidering på CNN-LSTM-modellen tränad på augmenterad data. Antalet epoker halverades eftersom modellen i figur 4.15 visar tecken på konvergens, vilket även bidrar till att spara tid under korsvalideringen. Resultatet, som presenteras i tabell 4.1, visar genomgående hög och stabil noggrannhet. Medelvärde för valideringsnoggrannheten uppgick till 97,70 % med en låg genomsnittlig valideringsförlust på 0,0615. Detta indikerar att modellen har god generaliseringsförmåga och inte varierar mellan enskilda träningsdelar. Kombinationen av hög valideringsnoggrannhet och låg valideringsförlust tyder också på att modellens träffsäkerhet är hög. Sammantaget visar resultatet av korsvalideringen på att modellen i regel fungerar som önskat enligt de satta målen.

5.1.7 Valideringstest med fysioterapeuter

Från insamlingen av data från fysioterapeuterna blev valideringen som högst 36,36 %, vilket gavs av algoritmen med CNN-LSTM. Felklassificeringarna följer till viss del det mönster som diskuteras i delkapitel 5.1.3, där modellen har svårt att skilja på kategorierna 3b, 3c och 4. Det samlades dock endast in en datapunkt för varje kategori, vilket innebär att mängden data var mycket begränsad och att det inte går att dra någon slutsats utifrån detta. Utfallet av valideringen tyder dock på att insamling av en större mängd data från fler testpersoner är avgörande för att metoden ska kunna användas i ett kliniskt sammanhang. Individuella skillnader i patienters rörelsemönster bidrar till variationer i insamlad data, som modellen måste kunna hantera.

5.1.8 Jämförelse med tidigare arbeten

I det tidigare masterkursprojekt [25] detta kandidatarbete bygger vidare på uppnåddes, med hjälp av 1D-CNN 3 layer, en klassificeringsnoggrannhet på 97,47 %. I jämförelse med det uppnåddes i detta kandidatarbete med CNN-LSTM en något högre maximal klassificeringsnoggrannhet. Att data i masterkursprojektet enbart klassificerades utifrån antal avbrott och även delades in i ett mindre antal kategorier tyder på att det resultat som uppnått i detta kandidatarbete är mycket positivt. I masterkursprojektet presenteras grafer där modellens tränings- och valideringsförluster respektive noggrannhet visualiseras. Vid inspektion av dessa syns att valideringsdata generellt befinner sig längre ifrån träningsdatapunkternas värden, jämfört med hur relationen mellan motsvarande tränings- och valideringsdata hos det här kandidatarbetets CNN-LSTM-modell ser ut. Detta tyder på att den modell med vilket bäst resultat uppnåddes i detta projekt har en bättre generaliseringsförmåga än den som användes i masterkursprojektet.

5.2 Felkällor

En potentiell felkälla i projektet är avståndsuppmätningen i samband med datainsamlingen. Inför varje mätning uppmättes ett avstånd på 15 cm från bordskanten till radarsensorn. Därefter genomfördes fingertappningstestet. Det faktiska avståndet mellan testpersonens hand och sensorn varierade dock beroende på vem som utförde testet. Vissa placerade handen närmare sensorn, medan andra omedvetet förflyttade handen längre ifrån under testets gång. Denna variation kunde även observeras hos samma testperson vid olika tidpunkter på dagen eller efter ett visst antal repetitioner. Utöver detta förekom även variationer i höjd, trots att riktlinjen var att hålla fingrarna i nivå med radarsensorns mittpunkt. Höjden kunde skilja sig mellan olika testpersoner, men kunde även variera över tid för samma person, exempelvis när trötthet påverkade hållningen under dagen. Dessa faktorer kan möjligtvis påverka resultatet men de återspeglar samtidigt ett verkligt scenario då det är svårt för patienten att hålla sin hand i exakt samma position vid varje mätning.

Projektgruppen har under arbetets gång stött på mindre problem relaterade till de tre olika radarsensorerna. Problemen har varierat i karaktär, men har främst ytttrat sig i att sensorerna gett olika resultat vid mätningar utförda med endast några sekunders mellanrum. Detta trots nästintill identiska testförhållanden, där samma avstånd och samma testperson använts. Skillnaderna i resultat rör huvudsakligen hur signalerna som fångats upp av respektive sensor visualiserats.

Datainsamlingen utfördes till en början med handen placerad vertikalt i enlighet med figur 3.1a. Enligt denna uppställning samlades totalt 810 mätningar in. Av dessa mätningar var 224 inom normalkategorin, 211 inom kategorin 1b, 220 inom kategorin 2b och 155 inom kategorin 3b. När mätningarna för kategori 3b genomfördes upptäcktes problem med att visualisera signalen i MATLAB, se figur 4.5a. Testerna visualiserades i en graf med hastighet på y-axeln. Problematiken uppstod då kategori 3b utfördes med måttlig förlängsamning i rörelsen, vilket gjorde att hastigheten

var för liten för att ge tydligt utslag på y-axeln. Efter diskussion med handledare då problemet togs upp gjordes en ändring i handuppställning som åtgärd. Det visade sig även att tester utförda enligt övriga kategorier kunde visualiseras tydligare med den nya handuppställningen som visualiseras i figur 3.1b. Det innebär således att metoden för resterande tester, 1658 stycken, skiljde sig från tidigare och inte var identisk genom hela projektet. Eftersom förändringar i uppställningen inte påverkar rörelsemönstret resonerades tillsammans med handledare att ändringen bidrog till en mer realistisk representation av verkligheten där stor variation mellan patienter förekommer.

Som tidigare nämnt i delkapitel 5.1.3, finns det för 1D-CNN en tydlig likhet i rörelsemönstret för kategori 3c och kategori 4, särskilt i de fall där amplitudminskningen inte registrerats för kategori 3c. Därav utgör detta en betydande felkälla i projektarbetet, då vissa datapunkter som tillhör kategori 3c i praktiken klassificeras som kategori 4. Detta leder till felaktigheter i maskininlärningsmodellen och påverkar därmed slutresultatet. För att undvika denna felkälla borde dessa datapunkter ha uppmärksamats under datainsamlingen och exkluderats.

5.3 Vidareutveckling

Detta delkapitel redovisar relevanta förbättringsområden, möjliga tekniska utvecklingar och dess etiska implikationer.

5.3.1 Förbättringsområden

Efter interna diskussioner inom projektgruppen har flera förbättringsområden identifierats. Den kanske mest betydande förbättringspotentialen rör möjligheten att öka antalet insamlade datapunkter. Med en större mängd data hade modellens noggrannhet sannolikt förbättrats, vilket skulle ha lett till ett mer tillförlitligt resultat. Dessutom hade behovet av augmented data minskat.

Ett ytterligare förbättringsområde är att inkludera fler testpersoner i studien. Ett större urval av deltagare hade kunnat bidra till en mer varierad och representativ datamängd, vilket i sin tur skulle kunna leda till mer tillförlitliga resultat. Projektgruppen hjälptes åt att utföra mätningarna. Tre åt gången samlade in mätningarna och de resterande tre utförde testerna. Detta upplägg ledde till att testpersonerna successivt blev trötta, vilket påverkade datakvaliteten. Därmed skiljde sig datapunkterna som samlades in i början av mätningen från de som registrerades i slutet.

Under projektets gång var arbetsgruppen i kontakt med Sahlgrenska Universitetssjukhuset och höll ett inledande möte samt ett sista valideringsmöte. Ett närmare och mer kontinuerligt samarbete med deras fysioterapeuter hade kunnat ge värdefull återkoppling på metoden. Det hade även möjliggjort datainsamling med fysioterapeuterna som testpersoner och ytterligare validering.

Under projektets inledande del undersöktes olika maskininlärningsmodeller. Baserat på informationssökning samt inhämtad information från tidigare arbeten beslutades att i första hand utgå från 1D-CNN 3 layer. Mot slutet av projektet utvärderades även modellen CNN-LSTM, vilken resulterade i bättre prestanda för klassificering jämfört med den ursprungligen valda modellen. Informationssökningen resulterade i att dessa två modeller bedömdes ha störst potential att uppfylla projektets syfte. Däremot hade mer tid till arbetet möjliggjort testning av ytterligare modeller för att utvärdera prestanda och eventuellt identifiera en modell med ännu bättre resultat än de utvalda. Därtill hade mer tid även möjliggjort en mer omfattande utvärdering av modellernas prestanda i förhållande till förändringar av hyperparametrar. Exempelvis hade det varit möjligt att undersöka effekten av ett varierat antal lager i de båda modellerna. Antalet filter i varje faltningslager för 1D-CNN och antalet LSTM-celler för CNN-LSTM hade också kunnat justeras. Utöver det hade alternativa procentuppdelningar mellan tränings- och testdata kunnat utvärderas, för att analysera om en annan fördelning kunnat bidra till förbättrade resultat.

För att uppnå en ännu högre noggrannhet hade en möjlighet i teorin varit att använda dubbelriktad (jfr. eng. *bidirectional*) LSTM i metoden. Dubbelriktad LSTM har två LSTM-lager som bearbetar sekvensen i båda riktningarna, både framåt och bakåt. Modellen har därför utöver data från föregående steg även tillgång till framtida data. Därigenom möjliggörs ett ännu mer effektivt lärande av kontext samt temporala beroenden. Eftersom denna algoritm till följd av sin natur inte kan bearbeta data i realtid är den dock inte lämplig för klinisk användning.

5.3.2 Teknisk utveckling

Avgränsningarna i arbetet innebär att utförandet inte speglar en realistisk situation med en patient med Parkinsons sjukdom. I verkligheten framkommer sällan motoriska problem som isolerade symptom, vilket innebär att en patient som genomför testerna kan ha problem att placera handen enligt uppställningen som presenteras i figur 3.1. Ofrivilliga rörelser i hand, arm och övriga kroppsdelar kan medföra problem för patienten att bibehålla korrekt avstånd, höjd och vinkel. Den stationära sensorn är känslig mot avvikelser i dessa parametrar, se variationer i figur 4.5. Det tyder på att en vidareutveckling av sensors konfiguration, eventuellt även typ eller storlek, behöver utvärderas i ett vidare steg. Framtida problemställningar skulle kunna innefatta en undersökning av möjligheten att använda sig av en radarsensor med ett större uppsamlingsomfång, en konfiguration med flera sensorer med olika placeringar, eller att använda en sensor med möjlighet att följa patientens hand när den befinner sig i rörelse.

Avvikelserna i patientens rörelser kan skapa ytterligare störningar, vilka med största sannolikhet kommer att få utslag i signalerna. Detta kan i sin tur innebära att skillnaderna mellan kategorierna kan framstå som mindre vid en bedömning av signalerna. Detta kommer att ställa ett ökat krav på mängden data för att träna maskininlärningsalgoritmen, likt tidigare nämnt. Det kan även få konsekvenser i att det ställs ökade krav på algoritmen och att det därmed kan krävas utökade tester och utvärdering av lämpliga alternativ.

I detta arbete utfördes alla fingertappningstester under en tidsperiod på tio sekunder. Som tidigare nämnt i delkapitel 5.1.1 utgör detta en väsentlig skillnad mot en klinisk situation. För att i högre grad efterlikna den kliniska situationen hade metoden eventuellt kunnat justeras så att testpersonen genomför tio upprepningar, likt metoden i MDS-UDPRS. För att möjliggöra detta hade radarsensorns insamlingstid kunnat förlängas för att samla upp hela testförloppet oavsett klassificering. Det är möjligt att detta även hade gett en mer korrekt tolkning i enlighet med MDS-UDPRS. Exempelvis valdes för kategori 3c att inleda amplitudminskningen efter 1,5 sekunder, istället för efter första upprepningen av rörelsen.

5.3.3 Etiska aspekter

En viktig vidareutveckling av projektet är att nyttja verkliga patienter med Parkinsons sjukdom i datainsamling och träning av algoritmen. Patienterna skulle då genomföra fingertappningstestet utifrån sina individuella motoriska funktioner, till skillnad från i detta arbete där alla kategorier är simulerade. En etikprövning hos Etikprövningsmyndigheten är obligatorisk när en studie involverar insamling eller behandling av känsliga personuppgifter från deltagare, enligt lagen om etikprövning av forskning som avser människor [45]. För att skicka in en ansökan till etikprövningsmyndigheten krävs ansökningsblankett, en forskningsplan, informations- och samtyckesformulär för deltagare, en beskrivning av hur personuppgifter hanteras i enlighet med GDPR samt ett CV för ansvarig forskare [46].

Testpersoners integritet och rättigheter behöver värnas om vid insamling av data och eventuella personuppgifter måste hanteras i enlighet med dataskyddsförordningen, GDPR [47]. Insamlingen och behandlingen av personuppgifter måste ske i enlighet med förordningens rättsliga grunder. Det är endast tillåtet att samla in personuppgifter för berättigade ändamål och då endast de uppgifter som krävs för det specifika ändamålet [48]. Testpersonerna måste även få tydlig information kring datahanteringen.

6

Slutsats

Sammanfattningsvis kan det konstateras att projektet var framgångsrikt och uppvisar mycket lovande resultat. Vid korsvalidering gav CNN-LSTM-algoritmen en maximal noggrannhet på 99,28 % och en valideringsförlust på 0,0253. Dessa resultat visar tydligt att CNN-LSTM-algoritmen har en god förmåga att korrekt klassificera kategorierna och lämpar sig väl för uppgiften. Radarsensortekniken i kombination med maskininlärningsalgoritmer, utgör en effektiv metod för att noggrant klassificera skillnader i motoriska funktioner. Den höga noggrannheten visar att projektets mål, att vidareutveckla metoden för att automatisera bedömningen av fingertappningstestet i enlighet med MDS-UPDRS, har uppnåtts. Vidare forskning bör inkludera en större testgrupp samt en mer ingående utvärdering av radarsensors tekniska konfiguration. Med de lovande resultaten som grund finns förhoppningar om att metoden kan vidareutvecklas och framöver ligga till grund för en klinisk studie som stödjer syftet.

Litteratur

- [1] E. Tolosa, A. Garrido, S. W. Scholz m.fl., “Challenges in the diagnosis of Parkinson’s disease,” *The Lancet Neurology*, årg. 20, nr 5, s. 385–397, maj 2021, ISSN: 1474-4422. DOI: 10.1016/S1474-4422(21)00030-2.
- [2] S. Ström Bernad, “Fyra fakta om Parkinsons sjukdom - Hjärnfonden,” [Online], mars 2024, URL: https://www.hjarnfonden.se/2024/03/fyra-fakta-om-parkinsons-sjukdom/?fbclid=IwY2xjawJbNf51eHRuA2F1bQIxMAABHQ1MDxyzLgAkr08CyGgURNcgY91CUdkbZfNTY1ofhmMb4g5Rha0zZrvCiQ_aem_f_OETB_WdYInXU2L4ZDIDQ.
- [3] Parkinsonförbundet, “Parkinsonförbundet - Det här är Parkinson,” [Online], u.å. URL: https://www.parkinsonforbundet.se/om-parkinsons-sjukdom/det-haer-aer-parkinson/?fbclid=IwY2xjawJbNi11eHRuA2F1bQIxMAABHaEieuOywm8j7lhusvdU150DX8Fe9zbP5U3t_YIeg12Kxo8fW1DC2q4VSQ_aem_XSUFIVXpdLjtt2T5mPwDrA.
- [4] J. Jankovic, H. I. Hurtig och J. F. Dashe, “Etiology and pathogenesis of Parkinson disease,” [Online], jan. 2013, URL: https://www.uptodateonline.ir/contents/UTD.htm?36/6/36970?source=see_link.
- [5] J. M. Beitz, “Parkinson’s disease: a review,” *FBS*, årg. 6, s. 65–74, jan. 2014. DOI: 10.2741/S415.
- [6] J. Sonne, V. Reddy och M. R. Beato, “Neuroanatomy, Substantia Nigra,” *StatPearls*, sept. 2024. URL: <https://www.ncbi.nlm.nih.gov/books/NBK536995/>.
- [7] B. Blaus, “Blausen_0704_ParkinsonsDisease.png (2250×1350),” aug. 2013, URL: https://upload.wikimedia.org/wikipedia/commons/c/cb/Blausen_0704_ParkinsonsDisease.png.
- [8] L. V. Kalia och A. E. Lang, “Parkinson’s disease,” *The Lancet*, årg. 386, nr 9996, s. 896–912, aug. 2015, ISSN: 0140-6736. DOI: 10.1016/S0140-6736(14)61393-3.
- [9] W. Poewe, “Clinical measures of progression in Parkinson’s disease,” *Movement Disorders*, årg. 24, nr S2, S671–S676, jan. 2009, ISSN: 1531-8257. DOI: 10.1002/MDS.22600.
- [10] K. L. Chou, H. I. Hurtig och J. F. Dashe, “Parkinson disease symptoms and diagnosis,” [Online], okt. 2013, URL: https://www.uptodateonline.ir/contents/mobipreview.htm?5/4/5188?source=related_link.

- [11] Npatne, "PD_Symptoms.png (PNG-bild, 1554×824 pixlar) - Skalad (85%)," dec. 2023, URL: https://upload.wikimedia.org/wikipedia/commons/3/35/PD_Symptoms.png.
- [12] J. G. Goldman och R. Postuma, "Premotor and non-motor features of Parkinson's disease," *Curr Opin Neurol*, årg. 27, nr 4, s. 434–441, aug. 2014. DOI: 10.1097/WCO.000000000000112.
- [13] R. B. Postuma, D. Berg, M. Stern m. fl., "MDS clinical diagnostic criteria for Parkinson's disease," *Movement Disorders*, årg. 30, nr 12, s. 1591–1601, okt. 2015, ISSN: 1531-8257. DOI: 10.1002/MDS.26424.
- [14] International Parkinson and Movement Disorder Society, "Diagnosis of Parkinson's Disease," [Online], mars 2023, URL: <https://www.movementdisorders.org/MDS/News/Newsroom/Position-Papers/MDS-Position-Diagnosis-of-PD.htm>.
- [15] International Parkinson and Movement Disorder Society, "MDS-Unified Parkinson's Disease Rating Scale (MDS-UPDRS)," [Online], URL: <https://www.movementdisorders.org/MDS/MDS-Rating-Scales/MDS-Unified-Parkinsons-Disease-Rating-Scale-MDS-UPDRS.htm>.
- [16] C. G. Goetz, B. C. Tilley, S. R. Shaftman m. fl., "Movement Disorder Society-sponsored revision of the Unified Parkinson's Disease Rating Scale (MDS-UPDRS): Scale presentation and clinimetric testing results," *Movement Disorders*, årg. 23, nr 15, s. 2129–2170, nov. 2008, ISSN: 1531-8257. DOI: 10.1002/MDS.22340.
- [17] C. G. Goetz, S. Fahn, P. Martinez-Martin m. fl., "MDS-UPDRS The MDS-sponsored Revision of the Unified Parkinson's Disease Rating Scale," 2008. URL: https://www.uwo.ca/fhs/csd/smdl/docs/MDS-UPDRS_English_FINAL_Updated_August2019.pdf.
- [18] E. Eskilsson, "Parkinsons Sjukdom – Fysioterapi," Västra Götaland, Göteborg, tekn. rapport, 2024. URL: <https://mellanarkiv-offentlig.vgregion.se/alfresco/s/archive/stream/public/v1/source/available/SOFIA/SAS9630-14576379-156/SURROGATE/Parkinsons%20sjukdom%20%e2%80%93%20fysioterapi.pdf>.
- [19] S. K. Holden, T. Finseth, S. H. Sillau m. fl., "Progression of MDS-UPDRS Scores Over Five Years in De Novo Parkinson Disease from the Parkinson's Progression Markers Initiative Cohort," *Movement Disorders Clinical Practice*, årg. 5, nr 1, s. 47–53, 2018, ISSN: 23301619. DOI: 10.1002/MDC3.12553.
- [20] P. Bodin och A. Jernås, "Privat kommunikation," febr. 2025.
- [21] D. J. Park, J. W. Lee, M. J. Lee m. fl., "Evaluation for Parkinsonian Bradykinesia by deep learning modeling of kinematic parameters," *Journal of neural transmission (Vienna, Austria : 1996)*, årg. 128, nr 2, s. 181–189, febr. 2021, ISSN: 1435-1463. DOI: 10.1007/S00702-021-02301-7.
- [22] M. S. Islam, W. Rahman, A. Abdelkader m. fl., "Using AI to measure Parkinson's disease severity at home," *NPJ digital medicine*, årg. 6, nr 1, dec. 2023, ISSN: 2398-6352. DOI: 10.1038/S41746-023-00905-9.

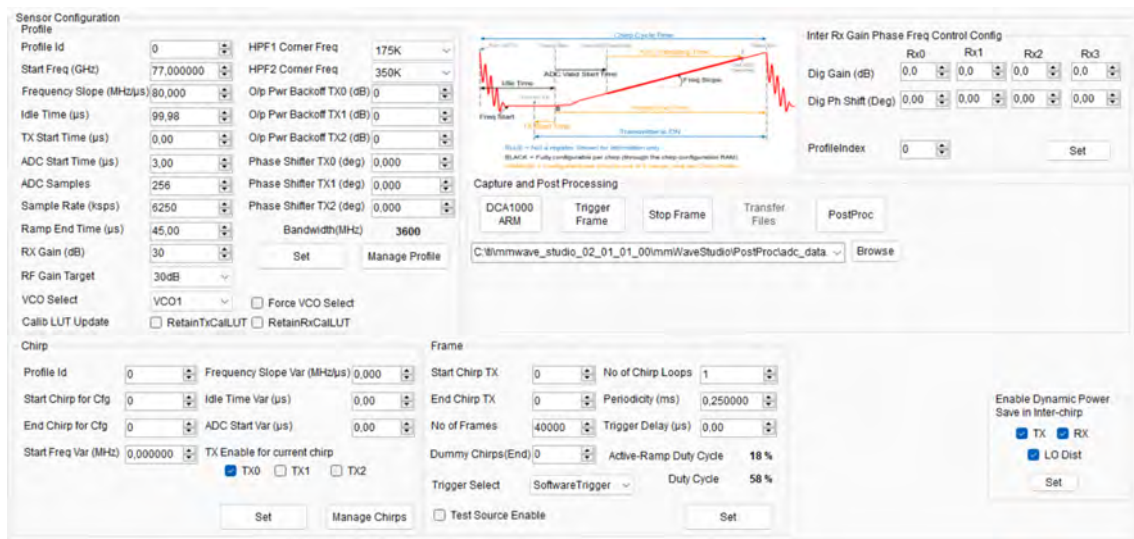
- [23] C. Li, V. M. Lubecke, O. Boric-Lubecke m. fl., “A Review on Recent Advances in Doppler Radar Sensors for Noncontact Healthcare Monitoring,” *IEEE Transactions on Microwave Theory and Techniques*, årg. 61, nr 5, s. 2046–2060, 2013. DOI: 10.1109/TMTT.2013.2256924.
- [24] G. Isaksson och S. Mosaddeghi, “Motor Functions Assessment for Parkinson Disease via Radar Sensors Focusing on Finger Tapping Test,” examensarb., Chalmers tekniska högskola, 2024. URL: <http://hdl.handle.net/20.500.12380/308570>.
- [25] C. Nordberg, D. Pediaditis, M. Manouras m. fl., “Motor Function Assessment for Parkinson’s Patients Using Radar Sensor and Machine Learning – Finger Tapping,” Chalmers tekniska högskola, tekn. rapport, 2024.
- [26] Texas Instruments, “AWR1642 Evaluation Module (AWR1642BOOST) Single-Chip mmWave Sensing Solution User’s Guide,” maj 2020. URL: https://www.ti.com/lit/ug/swru508c/swru508c.pdf?ts=1738672201628&ref_url=https%253A%252F%252Fwww.google.com%252F.
- [27] Texas Instruments, “DCA1000EVM Data Capture Card,” maj 2019. URL: https://www.ti.com/lit/ug/spruij4a/spruij4a.pdf?ts=1738672294354&ref_url=https%253A%252F%252Fwww.ti.com%252Ftool%252FDCA1000EVMf.
- [28] Texas Instruments, “mmWave Demo Visualizer User’s Guide,” april 2020. URL: https://www.ti.com/lit/ug/swru529c/swru529c.pdf?ts=1738659293420&ref_url=https%253A%252F%252Fwww.ti.com%252Ftool%252FMMWAVE-STUDIO.
- [29] S. Rao, “Introduction to mmwave Sensing: FMCW Radars,” *Texas Instruments*, URL: https://www.ti.com/content/dam/videos/external-videos/zh-tw/2/3816841626001/5415203482001.mp4/subassets/mmwaveSensing-FMCW-offlineviewing_0.pdf.
- [30] X. Zhang, W. Zhai och Y. Zhang, “A prototype for stepped-frequency SAR de-chirp imaging system and experimental verification,” English, i *APMC 2009 - Asia Pacific Microwave Conference 2009*, 2009, s. 1208–1211, ISBN: 9781424428021. DOI: 10.1109/APMC.2009.5384425.
- [31] H. Sakurai, Y. Kobayashi, T. Mitomo m. fl., “A 1.5GHz-modulation-range 10ms-modulation-period 180kHzrms- frequency-error 26MHz-reference mixed-mode FMCW synthesizer for mm-wave radar application,” English, i *Digest of Technical Papers - IEEE International Solid-State Circuits Conference*, Institute of Electrical och Electronics Engineers Inc., 2011, s. 292–293, ISBN: 9781612843001. DOI: 10.1109/ISSCC.2011.5746324.
- [32] X. Yao och Y. Liu, “Machine learning,” i *Search Methodologies: Introductory Tutorials in Optimization and Decision Support Techniques, Second Edition*, Springer, utg., New York, USA: Springer, 2014, kap. 17, s. 477–518, ISBN: 9781461469407. DOI: 10.1007/978-1-4614-6940-7_17.
- [33] A. Olalekan Ige och M. Sibiya, “State-of-the-Art in 1D Convolutional Neural Networks: A Survey,” *IEEE Access*, årg. 12, s. 144 082–144 105, 2024. DOI: 10.1109/ACCESS.2024.3433513.

- [34] I. Alqatawneh, R. Deng, K. Rabeyee m. fl., “A Developed Convolutional Neural Network Architecture for Condition Monitoring,” i *2021 26th International Conference on Automation and Computing: System Intelligence through Automation and Computing, ICAC 2021*, 2021, ISBN: 9781860435577. DOI: 10.23919/ICAC50006.2021.9594171.
- [35] A. Zafar, N. Saba, A. Arshad m. fl., “Convolutional Neural Networks: A Comprehensive Evaluation and Benchmarking of Pooling Layer Variants,” *Symmetry*, årg. 16, nr 11, 2024. DOI: 10.3390/sym16111516.
- [36] M. Ali, O. Alsuwaidi och S. Khan, “FlexPooling with Simple Auxiliary Classifiers in Deep Network,” i *Proceedings of the International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications*, vol. 4, 2023, s. 497–505. DOI: 10.5220/0011894400003417.
- [37] K. Gürkahraman och R. Karakiş, “Optimization of Mixed Pooling Using Genetic Algorithm for Convolutional Neural Networks | Evrişimli Sinir Ağları için Genetik Algoritma Kullanılarak Karma Havuzlamanın Optimizasyonu,” i *32nd IEEE Conference on Signal Processing and Communications Applications, SIU 2024 - Proceedings*, 2024, ISBN: 9798350388961. DOI: 10.1109/SIU61531.2024.10601152.
- [38] J. Cordeiro, A. Raimundo, O. Postolache m. fl., “Neural architecture search for 1d cnns. Different approaches tests and measurements,” *Sensors*, årg. 21, nr 23, 2021. DOI: 10.3390/s21237990.
- [39] E. Nichani, A. Damian och J. Lee, “Provable Guarantees for Nonlinear Feature Learning in Three-Layer Neural Networks,” i *Advances in Neural Information Processing Systems*, vol. 36, 2023, ISBN: 9781713899921. DOI: 10.48550/arXiv.2305.06986.
- [40] F. Pereira Dos Santos och M. Antonelli Ponti, “Alignment of local and global features from multiple layers of convolutional neural network for image classification,” i *Proceedings - 32nd Conference on Graphics, Patterns and Images, SIBGRAPI 2019*, 2019, s. 241–248, ISBN: 9781728152271. DOI: 10.1109/SIBGRAPI.2019.00040.
- [41] N. Yu, C. Weber och X. Hu, *Learning Sparse Hidden States in Long Short-Term Memory*. 2019, vol. 11728 LNCS, s. 288–298, ISBN: 9783030304836. DOI: 10.1007/978-3-030-30484-3_{_}24.
- [42] A. Goel, A. Katiyar, A. Goel m. fl., “LSTM Neural Networks for Brain Signals and Neuromorphic Chip,” i *2024 2nd International Conference on Advances in Computation, Communication and Information Technology, ICAICIT 2024*, 2024, s. 1033–1039, ISBN: 9798331541217. DOI: 10.1109/ICAICIT64383.2024.10912358.
- [43] S. Das, A. Tariq, T. Santos m. fl., *Recurrent Neural Networks (RNNs): Architectures, Training Tricks, and Introduction to Influential Research*. 2023, vol. 197, s. 117–138. DOI: 10.1007/978-1-0716-3195-9_{_}4.

-
- [44] J. Goh, K. Lim och C. Lee, "1D Convolutional Neural Network with Long Short-Term Memory for Human Activity Recognition," i *3rd IEEE International Conference on Artificial Intelligence in Engineering and Technology, IICAIET 2021*, 2021, ISBN: 9781665428996. DOI: 10.1109/IICAIET51634.2021.9573979.
- [45] Sveriges riksdag, "Lag (2003:460) om etikprovning av forskning som avser människor | Sveriges riksdag," [Online], 2003, URL: https://www.riksdagen.se/sv/dokument-och-lagar/dokument/svensk-forfattningssamling/lag-2003460-om-etikprovning-av-forskning-som_sfs-2003-460/.
- [46] Etikprovningensmyndigheten, "Etikprovning - så går det till," [Online], URL: <https://etikprovningensmyndigheten.se/for-forskare/sa-gar-det-till/>.
- [47] Integritetsskyddsmyndigheten, "Det här gäller enligt dataskyddsförordningen," [Online], 2021, URL: <https://www.imy.se/verksamhet/dataskydd/det-har-galler-enligt-gdpr/>.
- [48] Integritetsskyddsmyndigheten, "Grundläggande principer," [Online], 2021, URL: <https://www.imy.se/verksamhet/dataskydd/det-har-galler-enligt-gdpr/grundlaggande-principer/>.

A

Appendix 1



Figur A.1: Sensorkonfiguration i mmWave Studio 02.01.01.00.

INSTITUTIONEN FÖR ELEKTROTEKNIK
CHALMERS TEKNISKA HÖGSKOLA

Göteborg, Sverige

www.chalmers.se



CHALMERS