

# Automatisk segmentering av bevegelsesdata

**Stian Fuglesang Olsen**

Master i teknisk kybernetikk  
Oppgaven levert: Juni 2010  
Hovedveileder: Øyvind Stavadahl, ITK



# Oppgavetekst

Ved analyse av menneskelig bevegelse er det ofte behov for å redigere bort uinteressante deler av opptakene, f.eks. dersom det oppstår en forstyrrelse i opptakssituasjonen slik at bevegelsene blir lite representative eller irrelevante. Dette er i stor grad tilfellet i det pågående CIMA-prosjektet, der målet er å klassifisere spedbarns bevegelser som "normale" eller "avvikende" (dvs. som fører til cerebral parese eller liknende). Innen musikk og andre fagfelt finns tilsvarende problemstillinger; her er det ikke relevansen, men snarere det kvalitative uttrykket i bevegelsene som endres fra én fase til den neste. Felles for disse eksemplene er relevansen i å detekttere tidspunkter der bevegelsene endrer seg vesentlig, enten kvalitativt, kvantitativ eller begge.

I tidligere studentprosjekter er det utviklet metoder for å klassifisere og segmentere opptak av menneskelig bevegelse (kinematiske sensordata, videoopptak m.m.). I denne oppgaven skal du benytte og videreutvikle disse metodene med tanke på en fullstendig eller delvis automatisering av redigeringsprosessen.

1. Sett deg inn i og gi en oversikt over aktuelle typer måledata og analysemetoder for klassifisering av menneskelige bevegelser, spesielt bevegelser hos spedbarn og musikkrelaterte bevegelser. Skisser hvordan de ulike typene måledata konkret kan segmenteres (i tidsplanet) ved hjelp av eksisterende metoder og verktøy (f.eks. ved å foreslå hvilke typer preprocessing som må eller kan benyttes for de ulike datarepresentasjonene).
2. Implementer resultatene fra forrige punkt ved hjelp av eksisterende verktøy. Verktøyene kan utvides eller forbedres etter behov.
3. Prøv ut og evaluer implementasjonen ved hjelp av data fra CIMA-prosjektet og evt. andre relevante datasett. Sammenlign automatisk segmentering med manuell segmentering i den grad slike data foreligger.

Oppgaven gitt: 11. januar 2010  
Hovedveileder: Øyvind Stavadahl, ITK



# Forord

Denne rapporten er et resultat av arbeidet utført i forbindelse med masteroppgaven i 5. klasse avlagt ved NTNU, instituttet for teknisk kybernetikk. Arbeidet har bestått i et litteratursøk for å legge det faglige grunnlaget og for å knytte dette prosjektet til tidligere arbeid. Implementering og testing av metoder i MATLAB samt evaluering av disse er de mest sentrale elementene. Personlig synes jeg prosjektet har vært interessant og givende med tanke på muligheten det har gitt meg til å oppnå ny kunnskap samtidig som vinklingen av oppgaven har gitt meg motivasjon ved å kunne bidra innen et nyttig og spennende forskningsområde. Analysemetodene og måledataene jeg har satt meg inn i har i stor grad vært ukjent for meg fra tidligere og det har derfor vært ekstra givende å lære noe helt nytt i tillegg til å bruke denne kunnskapen til konstruksjon av metoder og anvendelser av disse på nye måter.

Jeg vil først og fremst takke veileder Øyvind Stavdahl for hans entusiasme, gode innspill og motiverende møter som har vært en sentral støtte gjennom hele semesteret. Jeg vil også få takke Lars Adde som med sin kunnskap har bidratt til dypere forståelse av arbeidet med spedbarn samt gjort det mulig å foreta en god evaluering av arbeidets resultater. Til slutt vil jeg takke foreldrene mine for all støtten og oppmuntringen de har gitt meg gjennom alle disse årene som student i Trondheim.

Stian Fuglesang Olsen  
Trondheim, 5. juni 2010



# Sammendrag

Hensikten med dette prosjektet er å benytte og videreutvikle metoder for segmentering av menneskelige bevegelser for fullstendig eller delvis automatisering av redigeringsprosessen. Bevegelsene i dette tilfellet kommer primært fra spedbarn og det er videoopptak av disse som danner grunnlaget for dataene brukt i dette prosjektet. Noen av fremgangsmåtene og metodene benyttet er også sterkt knyttet til musikkrelaterte bevegelser slik at dette også er en naturlig del av bakgrunnen til dette arbeidet. Analysen av musikalske bevegelser er inspirasjonen til de utviklede metodene for behandling av spedbarnsbevegelser og er derfor et viktig element i forklaringen av hvordan metodene er konstruert. Bevegelsene til spedbarn er viktig å kunne tolke dersom det er mistanke om nedsatte motoriske ferdigheter. Slike tegn kan være et varsel på at barnet senere kan få diagnosen cerebral parese og det er derfor en fordel å kunne bekrefte eller avkrefte dette med hensyn på iverksetting av eventuelle forebyggende tiltak.

For å lage metoder for segmentering må man trekke ut nyttige variabler fra de tilgjengelige dataene. I dette tilfellet er det videoopptakene det er snakk om og disse er behandlet for å fokusere på informasjonen som har med bevegelser å gjøre. En video består av bilder (frames) og disse vises 25 ganger i sekundet for å lage "bevegelige bilder" som vanligvis kalles en film. Bildene blir omgjort til "bevegelsesbilder" ved matematisk å subtrahere dem fra hverandre slik at resultatet blir bilder hvor kun bevegelse fra en frame til den neste er synelig. Dette er mulig ved at pikslene i bildet som forandrer seg vises som hvite og alle uforandrede piksler blir svarte. Med dette er det mulig å kalkulere sentrum for bevegelsen i hvert bilde samt hvor mye bevegelse det er, noe som gir grunnlag for enda flere variable som for eksempel standardavvik og varians. Bevegelsesbildene kan også gjøres om til såkalte "motiongram" som er en måte å visualisere bevegelsene i bevegelsesbildene over tid. Motiongram er bilder som inneholder bevegelseskurver og kan selv brukes til segmentering, men er best egnet til grafisk analyse.

Segmenteringen baserer seg altså på data fra bevegelsesbilder og er laget for å finne segmenter hvor bevegelsesmønsteret er betraktet som normalt. Det er ønskelig å finne disse regionene automatisk slik at avgjørelsen om grundigere oppfølging er nødvendig eller ikke kan gjøres mer effektivt. Å kunne finne segmenter som garantert inneholder normal bevegelse ved hjelp av digitale verktøy ville være et stort skritt mot effektivisering av denne analysen. Metodene for generering av bevegelsesbilder og motiongram sammen med gjennomføringen av klassifisering og segmentering er implementert i MATLAB. Segmenteringen baseres på å sammenligne variabelverdier for segmenter med og uten normal bevegelse. En fullstendig egenkomponert algoritme er utviklet og brukt hovedsakelig til testing mens en metode basert på lineær diskriminantanalyse også er laget med tanke på videre bruk. Resultatene viser at de utviklede metodene absolutt er lovende og har potensial til å bidra sterkt ved segmentering av bevegelsesdata. Evalueringen av de automatiske metodene i forhold til den tradisjonelle, manuelle fremgangsmåten, kan vise til solide resultater og med gode muligheter for forbedring ved anvendelse av enda flere variabeltyper samt klassifiseringsalgoritmer har arbeidet videre også svært gode utsikter.





# Innhold

1	Innledning.....	1
1.1	Motivasjon.....	1
1.2	Prosjektomfang .....	1
1.3	Oppgavebeskrivelse.....	2
1.4	Rapportdisposisjon.....	3
2	Bakgrunn .....	5
2.1	Cerebral parese (CP).....	5
2.2	General movement assessment (GMA) .....	6
2.3	Musikkrelaterte bevegelse .....	6
2.4	Metoder for automatisk segmentering av bevegelser.....	7
2.5	Bevegelsesbilder og motiongram.....	8
2.6	Klassifisering av menneskelige bevegelser.....	11
2.7	Annet relevant arbeid.....	13
3	Metode .....	15
3.1	Måledata .....	15
3.2	Preprosessering.....	17
3.3	Lineær diskriminantanalyse (LDA).....	21
3.4	Segmentering basert på bevegelsesbilder .....	22
3.5	Generering og bruk av motiongram.....	29
3.6	Sensordata.....	33
4	MS Toolbox.....	35
4.1	Generelt.....	35
4.2	Generering av bevegelsesbilder og motiongram .....	35
4.3	Behandling av bevegelsesbilder .....	37
4.4	Behandling av motiongram .....	37
5	Evaluering.....	39
5.1	Metode .....	39
5.2	Resultat.....	47

6	Diskusjon .....	51
6.1	Resultat.....	51
6.2	Eget arbeid .....	52
6.3	Videre arbeid.....	53
7	Konklusjon .....	55
	Bibliografi .....	57
	Appendiks.....	59
A.1	Sensitivitet og spesifisitet.....	59
A.2	Sensordata i MATLAB .....	60
A.3	Videoanalyse av L Adde.....	61
A.4	MST Manual.....	63

# Figurliste

2.1	Eksempel på estimerte parametre (theta) for et vilkårlig sensorsignal.....	8
2.2	Oversikt over prosessen for å lage motiongram.....	9
2.3	Fremgangsmåte for å lage motiongram.....	10
2.4	Motiongram i farger som representerer bevegelsene til en person som danser.....	10
2.5	Eksempel på segmentering av talesignal.....	14
3.1	Akseretninger og sensorplasseringer.....	16
3.2	Sensorsignaler i x-retning fra et friskt spedbarn som har normal bevegelse.....	16
3.3	Sensorsignaler i x-retning fra et sykt spedbarn som har avvikende bevegelse.....	17
3.4	”Lag plot” som viser typiske resultater for data.....	18
3.5	Plot av autokorrelasjon.....	18
3.6	Histogram.....	18
3.7	Eksempel på hvordan et bevegelsesbilde kalkuleres.....	19
3.8	Eksempel på filtrering av et bevegelsesbilde.....	20
3.9	Bevegelsesbilder generert i MATLAB.....	20
3.10	Plot av sentroiden til hvert enkelt bevegelsesbilde.....	23
3.11	Oppdeling av QoM i segmenter for utregning av variabelvedier.....	23
3.12	Plot av $Q_{\text{mean}}$ og $C_{\text{SD}}$ for segmentvindu med lengde 50.....	24
3.13	Plot av $Q_{\text{mean}}$ og $C_{\text{SD}}$ for segmentvindu med lengde 125.....	25
3.14	Plot av $Q_{\text{mean}}$ og $C_{\text{SD}}$ (inkl. modFM) for segmentvindu med lengde 125.....	25
3.15	Plot av $Q_{\text{mean}}$ og $C_{\text{SD}}$ for segmentvindu med lengde 175.....	26
3.16	Plot av $Q_{\text{mean}}$ og $C_{\text{SD}}$ for segmentvindu med lengde 225.....	26
3.17	Plot av $Q_{\text{SD}}$ og $C_{\text{SD}}$ for segmentvindu med lengde 125.....	27
3.18	Plot av $Q_{\text{SD}}$ og $C_{\text{SD}}$ for segmentvindu med lengde 225.....	27
3.19	Plot av $Q_{\text{mean}}$ , $Q_{\text{SD}}$ og $C_{\text{SD}}$ .....	28
3.20	Grensesnittet til programmodulen fra GMT (klargjøring).....	30
3.21	Grensesnittet til programmodulen fra GMT (eksportering av data).....	30
3.22	Motiongram fra samme video generert av GMT og MATLAB.....	31
3.23	Kurver som viser bevegelsesmengden til motiongramene fra figur 3.22.....	32
5.1	Horisontalt motiongram med FM laget i MATLAB.....	47
5.2	Horisontalt motiongram uten FM laget i MATLAB.....	47
5.3	Plot av QoM for P100_T03 med segmenteringslinjer.....	48
5.4	Motiongram for P100_T03 med inndelte segmenter.....	48
5.5	Motiongram for P093_T03 med inndelte segmenter.....	49



# Tabelliste

3.1	Sensorplassering.....	16
5.1	Segmentering av P100_T03 med et vindu på 75.....	39
5.2	Segmentering av P100_T03 med et vindu på 125.....	40
5.3	Segmentering av P100_T03 med et vindu på 175.....	40
5.4	Segmentering av P100_T03 med et vindu på 225.....	40
5.5	Segmentering av P100_T03 med et vindu på 375.....	40
5.6	Segmentering av P093_T03 med et vindu på 125.....	41
5.7	Segmentering av P093_T03 med et vindu på 175.....	41
5.8	Segmentering av P093_T03 med et vindu på 225.....	41
5.9	Segmentering av P093_T03 med et vindu på 375.....	42
5.10	Segmentering av P038_T02 med et vindu på 50.....	42
5.11	Segmentering av P038_T02 med et vindu på 75.....	42
5.12	Segmentering av P038_T02 med et vindu på 125.....	43
5.13	Segmentering av P038_T02 med et vindu på 225.....	43
5.14	Segmentering av P001_T03 med et vindu på 125.....	43
5.15	Segmentering av P001_T03 med et vindu på 375.....	44
5.16	Segmentering av P001_T03 basert på LDA.....	44
5.17	Segmentering av P038_T02 basert på LDA.....	44
5.18	Segmentering av P093_T03 basert på LDA.....	45
5.19	Segmentering av P100_T03 basert på LDA.....	45
5.20	Segmentering av P040_T03 basert på LDA.....	45
5.21	Segmentering av P096_T03 basert på LDA.....	46
5.22	Segmentering av P101_T01 basert på LDA.....	46



# 1 Innledning

”Det er ikke noe vanskeligere, mer farlig å gjennomføre, eller mer usikkert i sin suksess, enn å ta ledelsen ved innføringen av en ny orden.”

- Niccolo Machiavelli

## 1.1 Motivasjon

Ved studering av resultatene fra fordypningsprosjektet utført i fjor høst [7] viste det seg at metodene benyttet hadde potensialet til å foreta automatisk segmenteringen av bevegelsesdata. Forsøk ble gjort med forholdsvis korte segmenter av bevegelsesdata, men det ble ikke foretatt noen grundig testing av metodene med hensyn på data fra reelle datasett. Den gangen var det kun sensordata fra spedbarn som ble brukt og metodene som ble produsert var rettet spesielt mot dette. Å arbeide med spedbarnsdata og vite at man har muligheten til å bidra på dette området er god motivasjon i seg selv, men å kunne utvide bruksområdet til å bidra i flere typer bevegelsesanalyse er en bonus.

I tillegg til sensorsignalene som ble brukt i [7] er video også tilgjengelig og å utvikle metoder for å kunne foreta segmenteringer basert på disse dataene føles som et naturlig steg. Å utvikle en ”toolbox” for nye fremgangsmåter samme med det tidligere arbeidet, samt foreta grundig testing ved hjelp av nyttig og relevant data vil vise hvorvidt dette er noe som burde utvikles enda mer og benyttes i fremtiden. Selv om det ikke er sannsynlig at et dataprogram vil kunne erstatte en spesialist fullstendig er det ønskelig å kunne lage et system som bidrar ved å definere hvilke data og spesielt hvilke segmenter som trenger grundigere analyse og på den måten effektivisere arbeidsprosessen.

## 1.2 Prosjektomfang

Arbeidet i dette prosjektet starter med å gi en oversikt over aktuelle analysemetoder for klassifisering av menneskelige bevegelser hvor fokuser er rettet spesielt mot bevegelser hos spedbarn, samt musikkrelaterte bevegelser. På denne måten blir det lettere å forstå sammenhengen

## KAPITTEL 1. INNLEDNING

i det totale arbeidet som omhandler bevegelser hos mennesker samtidig som det gir et klarer bilde av hvordan effektiv segmentering kan bidra på dette området.

Mye av arbeidet er rettet mot spedbarn hvor automatisering og økt effektivisering ved diagnostisering av spedbarn med cerebral parese (CP) søkes. Dagens praksis på dette området gjennomføres ved at en erfaren fysioterapeut selv observerer bevegelsene til spedbarna visuelt og deretter bestemmer seg for om videre oppfølging er nødvendig. Denne fremgangsmåte har fått navnet "General movement assessment" (GMA) og er en klart subjektiv, men likevel veldig presis metode. Det er i denne sammenheng ønskelig å utvikle mer objektive metoder som automatisk detekterer karakteristikkene fysioterapeuten ser etter enten fra video eller sensordata. Om disse nye metodene kan regnes som fullstendig objektive da de baseres på en teknikk som igjen er tolket av et menneske kan diskuteres. Uansett så vil ikke et dataprogram ha den samme tilknytningen til dataene og ikke minst de individene som genererer dem slik som en menneskelig observatør og derfor være med på å bidra til en mer objektiv fremgangsmetode.

CIMA (Computer-based Infant Movement Assessment) er fellesbetegnelsen på arbeidet relatert til spedbarnsbevegelser ved NTNU. I samarbeid med Universitetet i Oslo (UIO) og St. Olavs Hospital har det siden 1998 pågått studier av forskjellige aspekter ved spedbarnsanalyse. I dette arbeidet inngår flere fordypningsprosjekt, masteroppgaver og diverse artikler [1,2,7,11,13,14,21] som alle bidrar til et felles mål.

Musikkrelaterte bevegelser er også et område som gjennomgår diverse analyser. Derfor tar dette prosjektet også utgangspunkt i metoder som benyttes på dette området. Her er det taktskift og repeterende bevegelsesmønstre som er nyttig å kunne detektere. Det er med andre ord de kvalitative uttrykkene i bevegelsen, i takt med musikken det er ønskelig og automatisk kunne identifisere. Tilgjengelig data på dette området er begrenset og derfor er omfanget av metodeutvikling også betraktelig redusert.

### **1.3 Oppgavebeskrivelse**

Det skal gis en innføring i alle måledataene som hører til det pågående CIMA-prosjektet og en oversikt over analysemetodene som er brukt. Målet til dette prosjektet er å utvikle og teste segmenteringsmetoder for menneskelige bevegelser. Fokuset ligger på bruk av bevegelsesdata fra video og det er spedbarnsbevegelser sammen med noe bevegelse i forbindelse med musikk som danner grunnlaget for arbeidet. Et viktig aspekt i tillegg til å utvikle metoder for gjennomføring av segmentering er evaluering av de implementerte metodene. Det er derfor nødvendig å undersøke hvordan den automatiske segmenteringen presterer i forhold til eksisterende og mer tradisjonelle fremgangsmetoder. Det er selve redigeringsprosessen som skal automatiseres slik at det senere vil være enklere og ikke minst mer effektivt for en spesialist å ta de avgjørelsene som ellers krever mye manuell og tidkrevende analyse.



## 1.4 Rapportdisposisjon

Her presenteres et kort sammendrag av innholdet i de forskjellige kapitlene som sammen danner hoveddelen av dette dokumentet.

**Kapittel 1 Innledning** gir en introduksjon til prosjektet ved å presentere arbeidet som skal gjøres, motivasjonen for valget av prosjekt samt hvordan jobben med oppgaven blir gjennomført.

**Kapittel 2 Bakgrunn** tar for seg tidligere arbeid som er relevant for denne oppgaven samt redegjør for hvilke analysemetoder som blir benyttet under klassifisering av menneskelige bevegelser.

**Kapittel 3 Metode** presenterer fremgangsmåter og metoder for segmentering. Hvilke data som blir brukt og hvordan preprosesseringene av disse blir gjennomført er også del av dette kapitlet.

**Kapittel 4 MS Toolbox** går igjennom det arbeidet som er gjort i forbindelse med MATLAB. Her forklares det hvordan toolbox'en er satt sammen og hvilke oppgaver den kan utføre.

**Kapittel 5 Evaluering** presenterer resultatene fra segmenteringsarbeidet samtidig som disse sammen med metodene benyttet blir evaluert.

**Kapittel 6 Diskusjon** tar for seg diskusjoner om kvaliteten og betydningen av de oppnådde resultatene. Eget arbeid samt tanker om videre arbeid på området er også diskutert her.

**Kapittel 7 Konklusjon** markerer slutten på rapporten med noen konkluderende tanker rundt arbeidet og de oppnådde resultatene.

## KAPITTEL 1. INNLEDNING

## 2 Bakgrunn

Dette kapitlet beskriver relevant arbeid som er utført på områdene dette prosjektet omhandler samt bakgrunnsinformasjon om relevante tema. Det er til nå gjort mye forskjellig type analyse av menneskelige bevegelser, men når det gjelder spedbarnsbevegelser er det begrenset hva som er utført. Det vil her komme en kort innføring i betegnelsen cerebral parese samt general movement assessment for å gi innblikk i den faktiske grunnen til at spedbarnsbevegelser er interessant å studere. Musikkrelaterte bevegelser og hva som legges i denne betegnelsen blir også presentert. Et sammendrag av prosjektet fra i fjor høst om metoder for segmentering fremlegges også sammen med forskjellige analysemetoder anvendt på bevegelser, både for de spesielle bevegelsesmønstrene hos spedbarn og forandringer i dans akkompagnert av forskjellig musikk.

### 2.1 Cerebral parese (CP)

Cerebral parese er en betegnelse på forstyrrelser av muskelkontrollen som skyldes en skade påført hjernen før den er fullt utviklet. Dette er med andre ord en alvorlig funksjonshemming som karakteriseres ved at man har en manglende evne til å kontrollere motoriske ferdigheter samtidig som det har potensialet til å ha en negativ effekt på et barns utvikling ved å hemme muligheten til å kommunisere, lære og bli selvstendig [15].

Forekomsten av cerebral parese er omlag 0.2% av alle fødte, noe som betyr at det foreligger ca. 100 nye tilfeller av CP i Norge hvert år. Den hyppigste årsaken til cerebral parese er i dag prematuritet, omtrent halvparten av barn med cerebral parese er født før termin hvor hoveddelen (ca. 80%) er karakterisert som spastisk, det vil si at de har bevegelsehemninger. Diagnostiseringen av CP er vanskelig og tidlig identifisering av barn med CP er viktig for at riktig behandling kan starte så raskt som overhode mulig [16]. Det er mens plastisiteten til barnets hjerne fortsatt er stor det er mest gunstig å foreta forebyggende behandling siden det er på dette tidspunktet den i større grad er mottagelig for forandringer. Dette bekreftes også gjennom flere studier som for eksempel i arbeidet til Blauw-Hospers et al. [18] hvor det vises at tidlig intervensjon og behandling kan ha en positiv effekt på blant annet utviklingen av motoriske ferdigheter. Tidlig diagnose vil også gi muligheten for mer fokusert oppfølging og kan være med på å berolige eventuelle foreldre som har barn med liten sannsynlighet for senere å utvikle CP.

## 2.2 General movement assessment (GMA)

Det menneskelige foster samt spedbarn har et sett distinkte og spontane bevegelsesmønstre. Ett sett av disse mønstrene kalles "general movements" (GM) som kan observeres hos foster så tidlig som i tiende svangerskapsuke. Etter fødselen blir disse bevegelsene ofte kalt "writhing movements" og når barnet er mellom 6 til 9 uker gammel vil disse få et annet distinkt mønster kalt "fidgety movements" (FM). Dette stadiet kan vare frem til barnet er omlag 20 uker og karakteriseres av en rekke små kontinuerlige, sirkulære og rytmiske bevegelser av nakke, bryst, armer og ben [17]. Nøkkelord ved analyse av disse bevegelsene er kompleksitet, variasjon og flyt. Unormale og avvikende bevegelser eller fullstendig fravær av FM viser seg å være en god indikator på nevrologiske funksjonsnedsettelse som senere kan utvikles til CP.

H.F.R. Precht et. al. [17] foretok en kvalitetsvurdering av "general movements" som blir kalt GMA. Resultatene av eksperimentene viste at denne metoden hadde en mye høyere gyldighet ved prediksjon av barnets senere utvikling enn tidligere fremgangsmåter. Likevel kan denne type undersøkelse kun utføres av fagfolk med høy spisskompetanse og mye erfaring slik at bruken av metoden ved oppfølging av barn med risiko for CP har vært begrenset. Et mål for nye metoder er derfor å kunne oppnå like gode eller bedre resultater sammenlignet med GMA, på en mer effektiv og tilgjengelig måte.

## 2.3 Musikkrelaterte bevegelse

Hva man legger i betegnelsen "musikkrelaterte bevegelser" kan være så mangt. Man kan se på bevegelse hos de som opptrer, men også hos de som opplever opptreden. Bevegelse blant publikum er det forsket ytterst lite på og skal ikke tas videre her, men studier av bevegelse blant utøverne innenfor musikken er noe som stadig blir mer utbredt. For å gjøre det enkelt kan man dele utøverne inn i tre typer: musikeren, dirigenten og danseren [6]. Alle disse typene har sine egne sett med bevegelser som er relatert til type opptreden og det man uttrykker. Analysen av bevegelser relatert til musikk er i dette prosjektet begrenset til danseren som man kan si har et "lydakkompagnerende" bevegelsessett.

Studien av musikkrelaterte bevegelser er et forholdsvis nytt forskningsområde og inneholder derfor også en god del ny terminologi. De faglige uttrykkene som benyttes for å beskrive bevegelser har blitt benyttet i lengre tid, men betydningen av dem er ofte forskjellige i ulike fagmiljøer. Scenerom, kroppsrom og handlingsrom er termer som ofte brukes innen musikkrelaterte bevegelser. Også mer vanlige uttrykk som holdning, positur og posisjon er viktige for å kunne beskrive bevegelser. En type bevegelse som er målrettet kalles en handling og dersom denne handlingen har en meningsbærende funksjon er det en gest. En gest (eng: gesture) er en kommunikativ bevegelse som brukes til å belyse eller understreke noe, men som så mange andre slike uttrykk er det ofte brukt feil. I den engelske

## KAPITTEL 2. BAKGRUNN

litteraturen blir ordet "gesture" brukt om alle typer bevegelse noe som både er unødvendig og lite nyttig. Så selv om dette er en veldig liten del av arbeidet i denne rapporten og full forståelse ikke har vært imperativt er det likevel bra å kjenne til disse tingene.

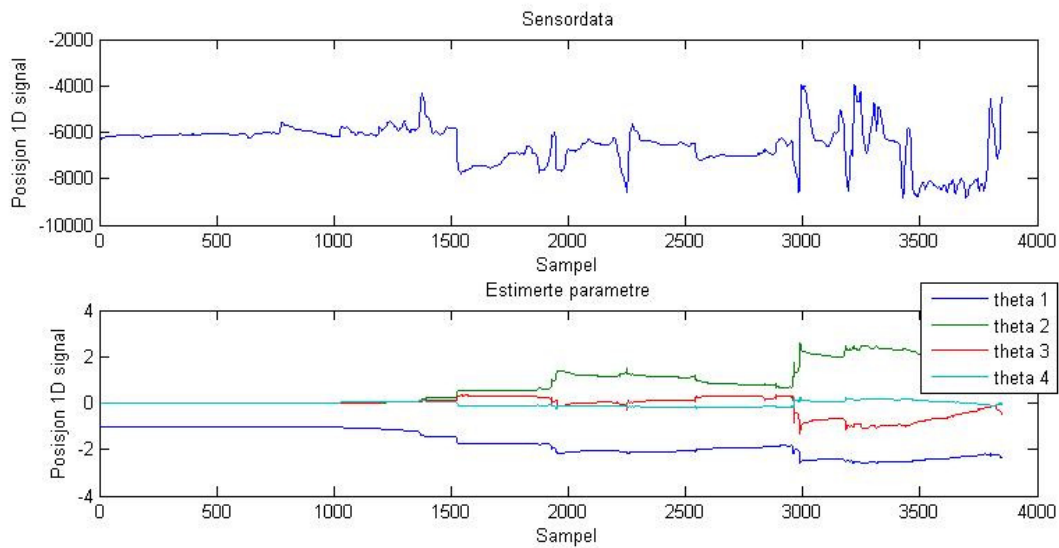
Når det gjelder selve analysen av musikkrelaterte bevegelser er det video av opptredener som er grunnlaget. Siden denne delen av prosjektet har fått mindre tid og fokus enn arbeidet med spedbarnsdata er det kun benyttet ferdigprodusert data fra denne type video. Det skal likevel sies at metodene som under dette prosjektet ble utviklet for behandling av spedbarnsvideo også kunne blitt benyttet på denne type filmer dersom tilgjengelig.

### **2.4 Metoder for automatisk segmentering av bevegelser**

Fordypningsprosjektet [7] i fjor høst hadde som mål å lage en verktøykasse (eng: toolbox) med metoder for automatisk segmentering av bevegelsesdata. Det ble sett på arbeid fra både mekaniske og biomekaniske systemer, men fokuset var anvendelse av metoder på data fra spedbarnsbevegelser (sensordata). Det var også her et mål å bidra i arbeidet med å skille mellom bevegelser som betraktes som normale eller avvikende i forhold til oppfølgingen og diagnostiseringen av CP. Dataene som ble brukt i prosjektet ble generert av sensorer plassert strategisk på barna for innsamling av nyttig bevegelsesdata. Sensorene måler posisjon i rommet, samt rotasjon og ved hjelp av video av barna er disse delt opp i såkalte interessante regioner (ROI) som det er verdt å studere videre med hensyn på klassifisering. Disse regionene representerer helt eller delvis normal eller avvikende bevegelsesmønstre og å kunne finne disse regionene automatisk ved hjelp av digitale verktøy ville være et stort skritt mot effektiviseringen av denne analysen. Hovedmålet til dette arbeidet ble derfor å samle gode metoder for segmentering som senere, ville kunne bidra på dette området.

Metodene som skulle brukes ble implementert i MATLAB og var basert på å tilpasse en modell til bevegessignalene hvor de estimerte parametrene igjen brukes til segmentering. Fordelen med en slik tilnærming er at metodene for parameterestimering gjør det mulig å være nokså selektiv når det gjelder segmenteringstidspunkt. Signal med stor variasjon trenger ikke nødvendigvis ha så mange forskjellige dynamikker (energi, frekvens, amplitude) slik at en fremgangsmåte med estimerte parametre som ikke forandrer seg nevneverdig under slike forhold vil kunne gi gode segmenteringsresultater. Det er autoregressive modeller og de estimerte parametrene fra disse som er første steg av segmenteringen. Flere metoder for estimering er brukt og den endelige segmenteringen avhenger av hvor godt de representerer bevegelsen i de originale signalene. MATLAB's egne funksjoner er brukt for å gi et solid og robust grunnlag for videre utvikling, samt at det er et veldig kraftig verktøy. Det kan brukes til enormt mange forskjellige oppgaver og kan derfor virke komplisert og vanskelig å sette seg inn i, men dersom man opparbeider seg basiskunnskapen som må til for å operere programmet kan man nokså enkelt benytte seg av de mulighetene MATLAB tilbyr.

## KAPITTEL 2. BAKGRUNN



**Figur 2.1:** Eksempel på estimerte parametre ( $\theta$ ) for et vilkårlig sensorsignal. Det er disse parametrene som brukes videre til å segmentere det originale signalet. [7]

Resultatene som ble oppnådd viste at fremgangsmåten benyttet hadde potensialet og viste brukbare resultater under testingen som ble gjort. Selve testingen av metodene var ikke en stor del av prosjektet, men for å få en oversikt over hvordan de fungerte og presterte ble noen få forsøk gjort. Det ble fokusert på metoder som benyttet funksjonen RARX (rekursive autoregressive modeller) med forskjellige attributter og variable som produserte parametre som i neste omgang ble brukt til segmentering.

### 2.5 Bevegelsesbilder og motiongram

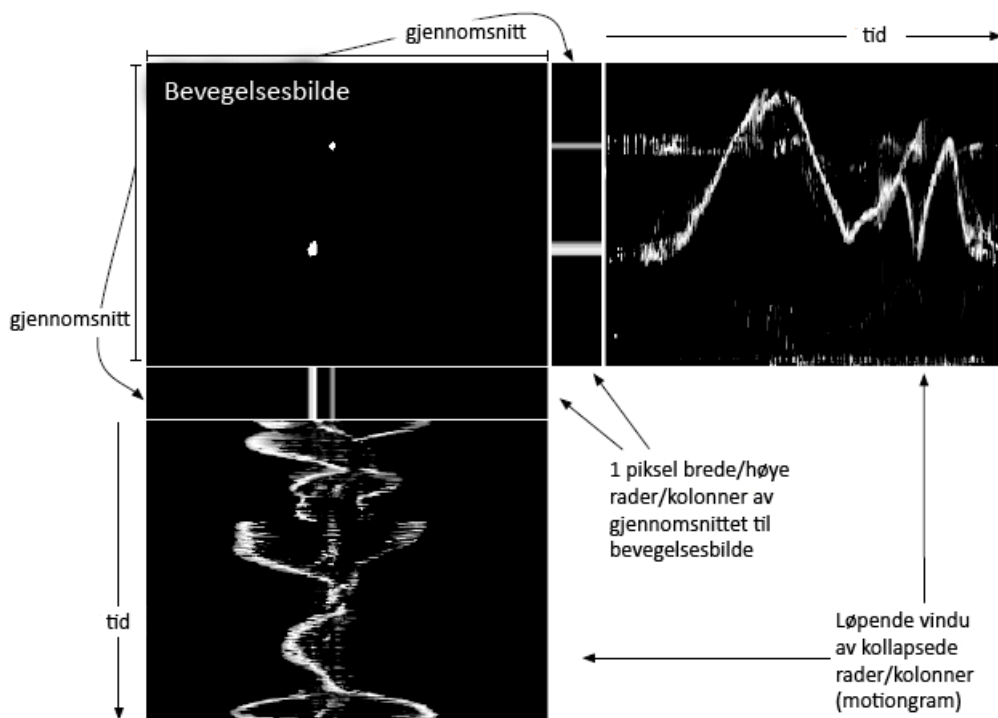
Her vil opprinnelsen til bevegelsesbilder (eng: motion image) og motiongram sammen med en forklaring på hva det er og hvordan det kan brukes bli presentert.

Når utgangspunktet for analyse av bevegelser kommer fra video sier det seg selv at det å navigere gjennom slikt materiale er svært tidkrevende i tillegg til at nytten av å se på sekvenser av stillbilder (eng: frames) er svært begrenset i studier av bevegelse. For å kunne studere informasjon fra musikkrelaterte bevegelser fra videomateriale utviklet derfor A R. Jensenius konseptet motiongram [6,12]. Utgangspunktet for dette var ønske om å forbedre analysemetoden som baserte seg på en tidsserie av stillbilder som representerte bevegelsene i videoen. Først ble det prøvd å velge stillbilder basert på hvor mye bevegelsene i videoen forandret seg. Dette gav mer konkret informasjon om bevegelsesmønsteret, men på grunn av ujevne intervaller mellom stillbildene som ble lagret var det likevel vanskelig å gjenkjenne utviklingen fra et bilde til et annet. Med disse metodene mister man mye av informasjonen om den faktiske bevegelsen i en sekvens så ved å se på analyse av lyd ved bruk

## KAPITTEL 2. BAKGRUNN

av spektrogram i stede fant Jensenius en tilsvarende måte å lage "videospektrogram" på som vi kaller motiongrams hvor man enkelt kan observere bevegelse over tid.

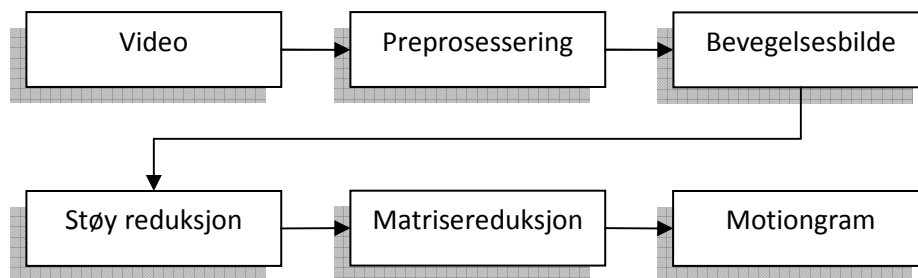
En populær måte å visualisere bevegelse på er ved å kalkulere forskjellen fra et stillbilde til det neste fra en videostrøm. Bildene som da dannes viser kun pikslene som forandrer seg fra gang til gang og er derfor en god indikasjon på en persons bevegelse. Ved å kombinere gamle og nye bilder får man et "bevegelsesbilde" som viser forandringen (historien) over en kort periode. En detaljert beskrivelse av hvordan bevegelsesbilder genereres kommer i kapittel 3.2. For lange sekvenser vil denne måten å analysere bevegelse på bli ubrukelig ra et visuelt standpunkt og det er derfor bruk av motiongrams også er nyttig i analyse. Måten motiongrams lages på er først å redusere matrisen til et bevegelsesbilde til en 1 piksel høy eller bred matrise som plottes over tid. En  $M \times N$  matrise blir da omgjort til en  $1 \times N$  og en  $M \times 1$  matrise ved å regne ut gjennomsnittsverdien til henholdsvis kolonnen og raden. Med dette blir en  $1 \times N$  og en  $M \times 1$  matrise kalkulert for hvert stillbilde og ved å plote disse 1 piksel høye eller brede stripene ved siden av hverandre over tid får man horisontale eller vertikale representasjoner av de kollapsede bevegelsesbildene. Det er dette som er motiongrams og som gjør det mulig å se posisjonen samt graden av bevegelse i en videosekvens over tid. Figur 2.2 viser vertikale og horisontale motiongram for en dansesekvens og her ser man tydelig danserens hender og hode representert ved bevegelseskurver som gjør det mulig å følge bevegelsesmønsteret til disse. For å unngå eventuell forvirring benyttes altså det engelske ordet motiongram for å beskrive de kollapsede bevegelsesbildene mens bevegelseskurvene er det vi observerer som bevegelse i disse bildene.



**Figur 2.2: Oversikt over prosessen for å lage motiongram for en 10 sekunders dansesekvens med bevegelsesbilde, gjennomsnitt av bevegelsesbilder og løpende bevegelseskurver (motiongram). [6]**


## KAPITTEL 2. BAKGRUNN

Figur 2.3 viser en oversikt av prosessen som resulterer i motiongrams. Det starter med å ordne den originale videoen slik at minst mulig støy vil påvirke den videre behandlingen. Dette gjøres ved å automatisk tilpasse videobildet til innholdet for så å øke lysstyrke, kontrast og eksponering for å få et klarere bilde med skarpe farger og kontraster. Neste skritt er å lage bevegelsesbilde ved å subtrahere stillbilder fortløpende for så til slutt å redusere matrisen til bevegelsesbildene. Alt dette blir gjort ved hjelp av programmoduler utviklet av Jensenius i hans "Musical Gestures Toolbox" (MGT).



Figur 2.3: Fremgangsmåte for å lage motiongram.

Det er vanlig å jobbe med bevegelsesbilder i gråtoner noe som i de fleste tilfeller gjør dem enklere å tolke. Når det gjelder analyse av dans kan bruk av klesplagg i forskjellige farger likevel være nyttig for enklere å skille mellom bevegelseskurvene i et motiongram.



Figur 2.4: Motiongram i farger som representerer bevegelsene til en person som danser til 5 forskjellige utdrag av musikk. Hvert utdrag er gjentatt 3 ganger etter hverandre og grensene mellom de ulike utdragene er markert med hvite linjer. [12]



## KAPITTEL 2. BAKGRUNN

Å tolke disse representasjonene krever en del tilvending. Det er viktig å huske på at et motiongram er en serie av reduserte bevegelsesbilder noe som betyr at ved reduksjon i det horisontale plan vil kun bevegelser i det vertikale plan vises. Dette fører til at man mister all informasjon om bevegelse i horisontal retning siden dette da er representert ved kun 1 piksel for hver rad (gjennomsnittet til raden). Når man skal lage motiongram er det derfor viktig å fastslå i hvilke plan bevegelsen opptrer før man velger å lage et horisontalt eller vertikalt motiongram (eller begge).

Det er også verdt å nevne at man kan lage såkalte videogram som nesten er det samme som motiongram med den forskjellen at videobildet brukes i stede for bevegelsesbildet. Bruk av videogram er gunstig i analyser der kameraet også er i bevegelse. Dette medfører at bakgrunnen også forandrer seg over tid i kontrast til stasjonære kamera hvor kun objektet man vil studere er i bevegelse. Ved stasjonær filming vil videogram tydelig vise mye av bakgrunnen noe som kan regnes som ekstra støy og gjør det vanskeligere å tolke. Motiongram er derfor å foretrekke dersom opptaket er tatt fra en stasjonær posisjon.

Motiongram kan benyttes til mange formål. Først og fremst dreier det seg om å bidra i analyse av bevegelser i videoopptak. Alt fra bevegelser ved bruk av musikalske instrumenter, dans og forskning på ADHD ved hjelp av rotter [6] til studier av spedbarnsbevegelser [2] har benyttet denne teknologien. Også innen scenekunst kan motiongram være med på å visualisere det som skjer ved å portrettere forestillingen på en spesiell og unik måte [6].

### 2.6 Klassifisering av menneskelige bevegelser

Her kommer en innføring i forskjellige metoder brukt til klassifisering av menneskelige bevegelser. Å klassifisere vil i denne sammenheng si å kategorisere bevegelsessekvenser etter hvilke type bevegelse de inneholder. Metodene som brukes til dette formålet er mange og hvilke som benyttes avhenger av analysens formål.

Det mest nærliggende dette prosjektet er masteroppgaven til Andreas Berg [1] gjennomført ved NTNU som tar for seg metoder for å klassifisere bevegelsene til spedbarn. Hensikten til oppgaven var å bruke dynamiske modeller til klassifisering av spedbarnsbevegelser som normale eller avvikende, der avvikende kan tyde på fare for utvikling av CP. Bevegelsene har tidligere blitt registrert med 6 sensorer, festet til ankler, håndledd, bryst og panne. Hver enkelt av disse sensorene måler både posisjon i rommet og rotasjon, men foreløpig er det kun posisjonsdataene som er benyttet. Det er de ferdige, manuelt segmenterte ROI'ene fra de forskjellige spedbarnene som benyttes til klassifiseringen og fremgangsmetoden er å identifisere en dynamisk modell på grunnlag av utgangsvariablene. SISO (Single Input Single Output), MIMO (Multiple Input Multiple Output), AR-modeller (Autoregressive) og tilstandsrommodeller ble benyttet og klassifiseringen er gjort på bakgrunn av de identifiserte systemparameterne. To strategier ble fulgt, den første brukte systemparameterne direkte som egenskapsvektor sammen med lineær diskriminantanalyse mens den andre tok for seg metrikker som måler distansen mellom to dynamiske modeller. Resultatene som ble oppnådd viste at bevegelsene til armer og hode er de viktigste eller mest tydelige for å

## KAPITTEL 2. BAKGRUNN

skille mellom normal og avvikende bevegelse. Det ble oppnådd en spesifisitet på 90.91 % og en sensitivitet på 85.71 % og en forklaring på hva disse betegnelsene betyr og hvordan de kalkuleres kan finnes i *Appendiks A.1*. Disse verdiene tilsier at tilpassing av dynamiske modeller er en nyttig metode for klassifisering av spedbarnsbevegelser selv om den foreløpig ikke er helt på høyde med den kliniske metoden GMA (spesifisitet: 96 %, sensitivitet 95 %).

En person som har vært behjelpelig med å bedre forklare den visuelle analysen av spedbarnsbevegelser samt generere data for testing er fysioterapeut ved St. Olavs Hospital Lars Adde. Et betydelig bidrag til CIMA-prosjektet er publikasjonen av Lars Adde et al. [11] som også baserer seg på det faktum at fravær av FM hos høyrisiko spedbarn (barn født før 28 uker med en vekt under 1000 gram) er en god indikator på faren for å utvikle CP. Her har de benyttet databasert videoanalyse for å oppnå en mer objektiv metode i forhold til GMA for klassifisering av fraværende versus normale FM. Måten dette ble gjort på var først å utføre GMA på videomateriale fra 82 spedbarn med både høy og lav risiko for så analysere de samme videoene ved hjelp av en "General Movement Toolbox" (GMT) utviklet av A R Jensenius med utgangspunkt i hans egen MGT. GMT er en modifisert versjon av MGT spesielt tilpasset arbeidet med videoer av spedbarn hvor alle egenskaper som kun er musikkrelevant er fjernet. Med denne programvaren ble blant annet bevegelsesbilder og motiongram laget noe det kunne trekkes diverse nyttige variabler ut av. Bevegelsesmengde (eng: Quantity of motion) eller QoM som det forkortes til i litteraturen ble kalkulert ved å summere alle pikslene som forandrer seg fra et bevegelsesbilde til det neste for så å dividere dette på det totale antall piksler bildet består av. Dette gir en verdi mellom 0 og 1 hvor 1 betyr at alle pikslene forandret seg mens 0 tilsier at ingen forandringer forekom. Dette ble brukt som et estimat av bevegelsen til videosekvensene. En annen variabel som ble brukt i analysen var sentroiden til bevegelsesbildene. Sentroide i denne sammenheng kan ses på som tyngdepunktet til de positive pikslene som igjen kan korreleres til sentrum av bevegelsen til spedbarna. Det viste seg at det var høyere bevegelsesmengde ved FM samt at sentroiden dekket et mindre og mer sirkulært område enn tilfellene med fraværende FM. Når det gjelder spesifisiteten og sensitiviteten (muligheten til å identifisere FM, samt fraværet av FM) som ble oppnådd lå disse på henholdsvis 70.0 % og 81.5 %. Motiongram ble brukt som et visuelt hjelpemiddel og viste tydelig forskjell fra normal og unormal bevegelse noe som stemte godt med analysen gjort ved QoM og sentroidene. Siden resultatene fra arbeidet med disse variablene viste seg å være veldig gode ble det tatt ett skritt lenger noe som er beskrevet i [14]. Her er det benyttet en såkalt cerebral parese prediktor (CPP) som ved hjelp av gjennomsnittsverdien til QoM ( $Q_{mean}$ ) samt standardavviket til både QoM ( $Q_{SD}$ ) og sentroiden ( $C_{SD}$ ) brukes til å klassifisere bevegelser som normale eller avvikende. Det viste seg også her at det var betydelige forskjeller mellom variabelverdiene for barn med CP og de uten, men på grunn av et minimalt testgrunnlag må disse resultatene verifiseres gjennom grundigre testing ved en senere anledning.

Andre metoder for klassifisering av spedbarnsbevegelser ved hjelp av motiongram er gjennomført av Harald Kirkerød [2]. Her var det motiongram fra video av spedbarna på lik linje med [11] og ikke sensordata [1] som dannet grunnlaget for datasettet til prosjektet. Kirkerød brukte Gaussian Mixture modeller samt Markov modeller til klassifiseringen og oppnådde det beste resultatet med en spesifisitet på 90.0 % og en sensitivitet på 86.6 %. Dette er derfor også en metode det kan være nyttig å studere videre da dette ekskluderer behovet for forstyrrende elementer som sensorene plassert på barna til tider kan være.

## KAPITTEL 2. BAKGRUNN

Klassifisering og gjenkjennelse av menneskelige bevegelser er blitt mye studert ved hjelp av video- og sensorbaserte metoder. Mota og Picar [8] benyttet et matriseoppsett av sensorer i setet og ryggen til en stol for å kunne gjenkjenne naturlige positurer hos barn som oppstår ved varierende interesse for oppgaver gjennomført på en PC. Totalt ble 9 positurer etablert og Hidden Markov Modeller (HMM) ble benyttet for å klassifisere disse. Graden av interesse blant barna ble kategorisert som høy, medium eller lav samt positurer som tilsier at man ønsker å ta en pause. Metoden hadde en gjennomsnittelig nøyaktighet på 87.6 % som er godt nok til å gi god nok informasjon om et barn faktisk har nytte og interesse av læringen som formidles via dataskjermen. På samme måte har Kamiya et al. [10] benyttet sensorer i setet til en stol for å imøtekomme etterspørselen etter tjenester som forbedrer tilværelsen til folk basert på hvordan man sitter. Så på bakgrunn av hvordan man "oppfører" seg på en stol vil diverse tjenester kunne bli aktivert. Her ble det oppnådd en nøyaktighet på 93.6 % ved gjenkjenning av positurer samt at systemet i tillegg kunne kjenne igjen personene dersom de hadde vært testet på forhånd. I motsetning til arbeidet med barna [8] hvor klassifiseringen skjedde ved å se på forskjellige typer press på stolen er det her summen av presset på hele stolsetet som blir benyttet.

Metoder som benytter HMM til å gjenkjenne prinsipale positurer er også benyttet av Pellegrini og Locchi [9], men her er det bruk av datasyn (eng: computer vision) som danner grunnlaget for den videre analysen. En eller flere personer blir tracket av kamera hvorpå informasjonen fra dette blir tilpasset en 3D modell av et menneske. Relevante punkt på modellen blir så tracket over tid og transisjoner mellom positurer blir kalkulert. Dette viser seg å være en nokså robust og pålitelig metode for automatisk gjenkjenning av kroppsposisjoner som takler tracking fra forskjellige vinkler og med elementer i bildet som gjør det vanskelig å se hele personen.


### 2.7 Annet relevant arbeid

Denne oppgaven har som mål å segmentere forskjellige datasett for å gjøre den videre jobben med analysen mer effektiv og presis. I de fleste analysetilfeller gjennomfører man en form for preprosessering av dataene, gjerne i form av filtrering for å redusere uønsket støy og segmentering for å dele opp datasettene i mer håndterbare sekvenser. Det vil her bli gjort rede for en del tidligere arbeid hvor målet nettopp er å samle inn forskjellig data for så å kunne behandle det for å gjøre den videre analysen mest mulig effektiv.

En del av utgangspunktet til denne oppgaven samt [1] ligger i resultatene fra ENIGMA (Enhanced interactive general movement assessment) prosjektet [13]. I et samarbeid mellom NTNU og St. Olavs Hospital ble det utviklet et databasert verktøy som ble testet for å se om man objektivt kunne trekke ut FM relaterte egenskaper fra spedbarnsbevegelser. Data fra seks sensorer plassert på håndledd, ankler, bryst og panne hos spedbarn ble samlet og analysert sammen med video av barnet. Resultatet av prosjektet viste at bevegelsesdataene kunne brukes selvstendig til å betrakte GM. På bakgrunn av den utførte analysen ble bevegessignalene manuelt delt inn i ROI'er hvorpå disse kan studeres nærmere for eventuelt å klassifisere bevegelsene.

## KAPITTEL 2. BAKGRUNN

P. M. Baggenstoss [3] utviklet en metode for segmentering som lagde segmenter på grunnlag av den spektrale karakteristikken til signalet. Metoden baserer seg på å lage en spektralfunksjon som kan oppdateres for hvert sampel og funksjonen blir tildelt en poengsum (eng: score) som blir lagret i en tabell. Valg av den beste segmenteringen blir derfor gjort ved å sammenligne tidligere og nye verdier i tabellen. Målet var å dele opp et akustisk signal i segmenter som alle ville være statistisk konsistent slik at for eksempel talesignaler kunne deles opp med hensyn på tonenivået (eng: pitch).



**Figur 2.5:** Eksempel på segmentering av talesignal hvor segmentene velges ut i fra den spektrale karakteristikken til signalet. [3]

Detektering av signifikante hendelser i signaler er nyttig i mange sammenhenger og spesielt ved segmentering. V Guralnik et al. [4] har laget metoder for dette til anvendelse på tidsvarierende signaler fra sensorer. Det er en iterativ algoritme som tilpasser en modell til et segment for så å bruke et sannsynlighets (likelihood) kriterium for å avgjøre om segmentet skal deles opp mer dersom det inneholder flere interessante forandringer. Utgangspunktet er at antall tidspunkter man vil finne er ukjent og metodene i form av en "batch" (har hele signalet tilgjengelig) og en adaptiv (behandler signalet ettersom man mottar det) er testet. Resultatene viste at begge fremgangsmetodene virket tilfredsstillende så lenge støy ikke dominerte signalet. Deler av dette arbeide kan sammenlignes med utredningene gjort av Appel og Brandt [5]. De tok for seg problemet adaptiv segmentering av tidsserier med bråe forandringer ved å bruke de estimerte parametrene til en autoregressiv modell som utgangspunkt. De foreslo en metode for sekvensiell adaptiv segmentering som bygget på to sekvensielle parameterestimeringsmetoder der detektering av forandring i parametrene samt estimering av segmenteringsgrenser ble gjort av såkalte generaliserte "likelihood ratio" tester (GLR). De kunne da justere ordenen til AR-modellen, grensen til GLR testen og lengden til testvinduet for å oppnå ønsket prestasjon. Undersøkelser ble gjort på biomedisinske signaler og resultatene viste tilfredsstillende detekteringsevner hos algoritmen samt svært god prestasjon ved lokalisering av segmenteringsgrenser, også innenfor en sekvens med korte segmenter.

## 3 Metode

Dette kapitlet inneholder informasjon om all type data som er behandlet i dette prosjektet samt beskrivelser av fremgangsmåter og analysemetoder. Arbeidet her er utført med tanke på flere aspekter ved CIMA-prosjektet og ønsket om å bidra på disse områdene. Fokuset er å segmentere data og mange av innfallsvinklene til denne jobben presenteres her. Segmentering i denne sammenheng er å bestemme relevante punkter i datasett hvor parametre forandrer seg tilfredsstillende mye i forhold til visse krav eller overskrider verdier som tilsier at noe har forandret seg i stor nok grad. I forbindelse med musikkrelaterte bevegelser er det gjentakende mønstre i bevegelsen det er interessant å kunne separere fra resten av dataene. Dette gjelder selvfølgelig også for spedbarnsbevegelser, men her er det detekteringen av FM som er mest sentralt.

### 3.1 Måledata

Det er to hovedtyper data i CIMA-prosjektet, data hentet ut i fra video og data fra sensorer. Når det gjelder musikkrelaterte bevegelser er det kun ferdige motiongram som er benyttet, men for spedbarnsbevegelser er begge typene delt inn i gruppene ROI1 og ROI3. ROI1 består av det komplette datasettet hvor da videoene er fullstendige opptak og målingene fra sensorene også representerer hele tidsforløpet under forsøkene. Disse inneholder derfor en del støy i form av påvirkninger utenfra som justering av kablene tilkoblet sensorene og at spedbarna er urolige eller opptatt av ting som ikke er gunstig for analysen. Alle spedbarnsvideoene er derfor behandlet av en spesialist (L Adde) for kun å beholde den delen av videoene som inneholder minst mulig forstyrrelser og da samtidig representerer normal eller avvikende bevegelse på en best mulig måte. På grunnlag av denne redigeringen er også sensorsignalene blitt behandlet for å stemme med videoene og alle disse faller da innenfor gruppen ROI3. På grunn av den forholdsvis lille datamengden og relevansen til oppgavens målsettinger er det kun blitt brukt data fra ROI3.


Fra video er det bevegelsesbilder og motiongram som blir generert for å kunne gjøre videre analyse. En generell forklaring på hva dette innebærer er allerede gjennomgått tidligere mens hvordan det spesifikt gjøres i dette prosjektet forklares i kapittel 3.2. Bevegelsesdata fra sensorene er de samme som originalt ble generert gjennom ENIGMA-prosjektet [13]. Selv om denne dataen ikke blir behandlet mer i dette prosjektet utover arbeidet gjort i [7] er det likevel en viktig del av CIMA-prosjektet og viktig å ha kjennskap til. Hver av sensorene måler posisjon i rommet i form av  $x$ ,  $y$  og  $z$  koordinater. I tillegg måles også rotasjon representert ved et kvaternion som er en vektor med de fire parametrene  $q_0$ ,  $q_1$ ,  $q_2$ ,  $q_3$ . Det er til nå kun blitt fokusert på xyz-koordinatene i arbeidet med

### KAPITTEL 3. METODE

disse dataene. Gjennom arbeidet til Berg [2] viset det seg at sensorene plassert på hode og armer var de mest interessante med hensyn på klassifisering av spedbarnsbevegelser. Tabell 3.1 viser plasseringen av de forskjellige sensorene. Hvordan retningene er definert er illustrert i Figur 3.1 sammen med en illustrasjon av sensorplasseringene (z peker ut av xy-planet).

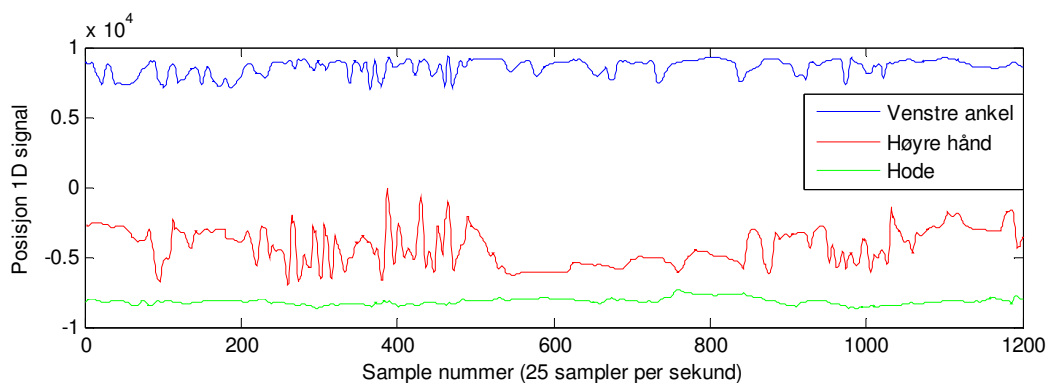
Sensor nr.	Plassering
1	Venstre ankel
2	Bryst (brystbein)
3	Høyre håndledd
4	Venstre håndledd
5	Høyre ankel
6	Hode (panne)

Tabell 3.1: Sensorplassering. [7]




Figur 3.1: Akseretninger og sensorplasseringer. [7]

For å få et bedre bilde av signalene sensorene genererer er det i Figur 3.2 og Figur 3.3 plot av x-kkoordinatene til henholdsvis venstre ankel, høyre hånd og hode for en normal og avvikende ROI.



Figur 3.2: Sensorsignaler i x-retning fra et friskt spedbarn som har normal bevegelse.

## KAPITTEL 3. METODE



**Figur 3.3: Sensorsignaler i x-retning fra et sykt spedbarn som har avvikende bevegelse.**

Figurene over viser en markant forskjell i bevegelsesmønsteret mellom normal og unormal. Visuelt sett ser det ut som det er mer konstant bevegelse hos det friske barnet mens i det unormale tilfellet er mye mindre bevegelse og heller ingen form for kontinuitet eller mønster i bevegelsene. Dette er typiske observasjoner som bekreftes i [11] da det er små konstante sirkelbevegelser som karakteriserer FM og normal bevegelse, mens den unormale oppførselen i noen tilfeller har kraftigere og mer ukontrollerte bevegelser samt fravær av bevegelse i perioder. Likevel er det ikke alltid forskjellene mellom bevegelsene er så tydelig som her.


Behandlingen av data skjer ved hjelp av MATLAB og en beskrivelse av strukturen til sensordataene presenteres i *Appendiks A.2*.

### 3.2 Preprosessering


Behandling av data før selve analysen, såkalt preprosessering, er et viktig steg som kan bidra til generering av bedre resultater ved at dataene i større grad tilpasses metodene som skal behandle dem. Dette oppnås ved å fjerne uønskede karakteristikk samt gjennomføre en forhåndsanalyse av dataene for å gi en formening om hvilke type signal det er og hvordan det oppfører seg. I dette prosjektet er det bruk av video og bilder som står sentralt og disse kan etter noe behandling studeres med mange forskjellige teknikker og metodene. Skal først få et innblikk i fremgangsmetoder som ofte anvendes for å undersøke signalers karakteristikk som kan komme til nytte senere i analysen. Man kan utføre flere tester på datasignal som sjekker de karakteristiske trekkene og på denne måten danne et bedre bilde av hvilken type prosess som ligger bak samt øke sjansene for å velge riktige metoder og modeller for videre arbeid. For å sjekke tilfeldighet (eng: randomness) i signalene kan man gå frem på flere måter for å bekrefte eller avkrefte dette fenomenet. Dersom man har en fullstendig tilfeldig prosess som genererer data kan man tydelig se forskjell fra disse og data generert av ikke-tilfeldige prosesser ved å benytte noen strategiske observasjonsmetoder. "Lag plot" er et av alternativene man kan brukes til dette formålet. Dette er enkelt og greit et plot hvor man benytter sampel nummer  $y_i$  på y-aksen og  $y_{i-1}$  på x-aksen hvorpå en forholdsvis lineær fordeling tilsier at datasettet ikke er tilfeldig og at en autoregressiv modell kan passe godt til prediksjon/estimering. En

### KAPITTEL 3. METODE

veldig lineær fordeling tilsier sterk autokorrelasjon noe som kan bekreftes ved å plote nettopp denne. Figurene 3.4 og 3.5 viser de forskjellige plottene for tre forskjellige typer signal med henholdsvis sterk, moderat og ingen autokorrelasjon.




**Figur 3.4:** "Lag plot" som viser typiske resultat for data. A: sterkt ikke-tilfeldig, B: moderat ikke-tilfeldig og C: tilfeldig (eng: random).



**Figur 3.5:** Plot av autokorrelasjon hvor A viser svært langsom og lineær avtagning som samstemmer med sterk autokorrelasjon. B reduseres hurtigere, men er til tider lineær noe som hører til data med moderat autokorrelasjon. C viser data som ikke har et spesielt mønster og som samtidig ligger innenfor konfidensintervallet markert av de to horisontale linjene, dette er karakteristisk for data med ingen autokorrelasjon.

Histogram er også et nyttig verktøy hvor man raskt kan få en oversikt over sentrum, spredningen og skjevheten til datasett.



**Figur 3.6:** Histogram hvor A viser en nokså symmetrisk normalfordeling mens B ikke er symmetrisk, men har en skjevhet i dataene.




### KAPITTEL 3. METODE

I kapittel 2.4 beskrives det hvordan bevegelseskurver blir dannet ved hjelp av programmene laget av A R Jensenius og denne informasjonen er det som ligger til grunn for genereringen av motiongram i MATLAB. Ønsket om et selvstendig analyseverktøy basert kun på MATLAB sin struktur har ført til at arbeidet i dette prosjektet også innebefatter kode for generering av bevegelsesbilder og bevegelseskurver fra video samt den videre analysen av dette.

Her vil den teoretiske fremgangsmåten for generering av bevegelsesbilder bli presentert og det er dette arbeidet som også beskriver noe av grunnlaget for implementeringen i MATLAB. Utgangspunktet for hvor nøyaktig og tydelig et motiongram representerer bevegelsene fra en video på, avhenger av kvaliteten til videomaterialet. Ved sammenligning av motiongram og de ulike størrelsene kalkulert ut i fra disse er det også viktig at videoene er forholdsvis like med hensyn på lysstyrke. Dersom et opptak er gjennomført med sollys utenfor vinduet og det neste gjøres mens det er overskyet kan til og med denne forandringen lage uønskede konsekvenser for resultatene. Dette problemet blir begrenset av måten bevegelsesbildene blir laget på samtidig som sammenligning av forskjellige motiongram ikke er veldig relevant for denne oppgaven. Det som er relevant er problemet hvor et og samme opptak opplever varierende lysforhold. Dette fører for eksempel til at en viktig verdi som QoM får en kunstig variasjon som følge av lysstyrken i videoen. Det er derfor viktig å kunne kompensere for slike forandringer ved å normalisere hver frame slik at utgangspunktet for dem alle blir så likt som mulig. En måte å gjøre dette på er å juster intensiteten (basert på en viss prosentandel av pikslene) på bildene til et felles nivå.

For å få ferdige motiongram generert fra en videosekvens må det først lages bevegelsesbilder. Dette gjøres ved å se på forskjellene fra en frame til den neste ved å trekke disse fra hverandre. Det man sitter igjen med da er et bilde som viser hvilke piksler som har forandret seg mellom hver frame. Neste steg er da å gi pikslene som har forandret seg verdien 1 (representert ved hvite piksler) og uforandrede piksler verdien 0 (svarte piksler).




**Figur 3.7: Eksempel på hvordan et bevegelsesbilde kalkuleres. Hvert kvadrat representerer en piksel og her er antall piksler satt til  $3 \times 3$ . Forskjellen mellom hver frame regnes ut og vises som hvite piksler i bevegelsesbildet dersom det er en forskjell og svarte dersom det ikke er noen forskjell.**

Å benytte denne teknikken direkte på video eller bilder uten noen form for forhåndsbehandling resulterer i et veldig støyfylt bevegelsesbilde. Dette er blant annet på grunn av lyset i rommet hvor videoen ble spilt inn (lysstoffrør fører til ustabile lysforhold "flickering") og komprimering av video

### KAPITTEL 3. METODE

som fører til tap av bildekvalitet. Disse effektene kan motvirkes i en viss grad ved å ta noen forhåndsregler, men å fjerne grunnleggende støyelementene helt på dette stadiet vil ikke være oppnåelig og heller ikke totalt nødvendig. Noe man kan gjøre for å mildne effekten av støyen er å justere lysstyrken og kontrasten til stillbildene slik at forskjellene på grunn av lysforhold og lignende blir minimale. Å klippe bildene slik at kun området med relevant bevegelse kommer med er også en lønnsom prosess for å fjerne uønsket forstyrrelse som opptrer rundt det man skal studere. Behandling av selve bevegelsesbildet er også nødvendig noe som kan ses på figur 3.9. Støyen her kan reduseres gjennom filtrering ved å innføre terskler for hvor mye bevegelse fra frame til frame som skal regnes som en forandring eller ikke. Fjerning av enslige piksler som tilsier at de ikke tilhører en relevant bevegelse kan med fordel også gjøres. Når alt dette er fullført er man klar til å generere motiongram hvor bevegelseskurvene forhåpentligvis blir tydelige og representerer den vertikale eller horisontale bevegelsen uten for mye støy.



**Figur 3.8:** Eksempel på filtrering av et bevegelsesbilde med  $3 \times 3$  piksler. Her fjernes alle enslige piksler samt klynger av piksler under en spesifisert verdi ( $<0.8$ ).



**Figur 3.9:** Bevegelsesbilder generert i MATLAB. Bildet til venstre er originalbildet som kun har blitt omgjort fra RGB til gråtoner. Bilde i midten er ikke behandlet med hensyn på støyreduksjon og inneholder derfor en del uønskede elementer. Bilde til høyre har gjennomgått en filtreringsprosess og har fått fjernet piksler med verdi lavere enn en gitt terskelverdi samt luket vekk enslige piksler.

### 3.3 Lineær diskriminantanalyse (LDA)

Lineær diskriminantanalyse er en metode brukt innen statistikk og maskinlæring for å finne lineære kombinasjoner av egenskaper som karakteriserer eller separerer to eller flere typer data. Den resulterende kombinasjonen kan benyttes som en lineær klassifikator eller en metode for å redusere dimensjonen til et problem.

I diskriminantanalyse antar man at egenskapsvektoren  $x \in \mathbb{R}^d$  er normalfordelt gitt at den tilhører klassen  $\omega_i$ :

$$p(x|\omega_i) = \frac{1}{(2\pi)^{\frac{d}{2}} |\Sigma_i|^{\frac{1}{2}}} e^{-\frac{1}{2}(x-\mu_i)^T \Sigma_i^{-1} (x-\mu_i)} \quad (3.1)$$

Her er  $p(x|\omega_i)$  en klassebetinget tetthetsfunksjonen,  $\mu_i = E(x)$  gjennomsnittsverdien (forventningsverdien) til egenskapsvektoren  $x$  for klasse  $i$  og  $\Sigma_i \in \mathbb{R}^{d \times d}$  er kovariansmatrisen definert som:

$$\Sigma_i = E[(x - \mu_i)(x - \mu_i)^T] \quad (3.2)$$

For å avgjøre hvilken klasse en gitt observasjon tilhører benyttes "Bayes regel":

- $P(\omega_1|x) > P(\omega_2|x)$ ,  $x$  tilhører klassen  $\omega_1$
- $P(\omega_1|x) < P(\omega_2|x)$ ,  $x$  tilhører klassen  $\omega_2$

Her er  $P(\omega_1|x)$  og  $P(\omega_2|x)$  sannsynligheten (å posteriori) for at  $x$  hører til henholdsvis klasse  $\omega_1$  og klasse  $\omega_2$ . Bayes regel kan skrives på en annen form [19]:

- $p(x|\omega_1)P(\omega_1) > p(x|\omega_2)P(\omega_2)$ ,  $x$  tilhører klassen  $\omega_1$
- $p(x|\omega_1)P(\omega_1) < p(x|\omega_2)P(\omega_2)$ ,  $x$  tilhører klassen  $\omega_2$

Hvor  $P(\omega_1)$  og  $P(\omega_2)$  er å priori sannsynligheter. Ulikhetene over representeres i diskriminantanalyse ofte som en diskriminantfunksjon:

$$g_i(x) = \ln(p(x|\omega_i)P(\omega_i)) \quad (3.3)$$

Nå kan klassifiseringskriteriet skrives som:

- $g_i(x) > g_j(x) \forall i \neq j$ ,  $x$  tilhører klassen  $\omega_i$

Strukturen på kovariansmatrisen  $\Sigma_i$  vil ha mye å si for klassifiseringen [1] og ved å anta identisk kovariansmatrise for de to klassene vil diskriminantfunksjonen kunne uttrykkes som:

$$g_i(x) = \omega_i^T x + \omega_{i0} \quad (3.4)$$

der  $\omega_i = \Sigma_i^{-1} \mu_i$  og  $\omega_{i0} = -\frac{1}{2} \mu_i^T \Sigma_i^{-1} \mu_i + \ln P(\omega_i)$ .

## KAPITTEL 3. METODE

$g(x)$  er her en lineær funksjon av  $x$  og de to klassene skilles ved hjelp av et hyperplan, men i tilfeller hvor  $d = 2$  reduseres dette planet til en linje. Forventningen  $\mu_i$  og kovariansmatrisen  $\Sigma$  blir i LDA normalt funnet med maximum likelihood-algoritmen som i dette tilfellet består av estimatene:

$$\hat{\mu} = \frac{1}{N} \sum_{k=1}^N x_k \quad (3.5)$$

$$\hat{\Sigma} = \frac{1}{N} \sum_{k=1}^N (x_k - \hat{\mu}_i)(x_k - \hat{\mu}_i)^T \quad (3.5)$$

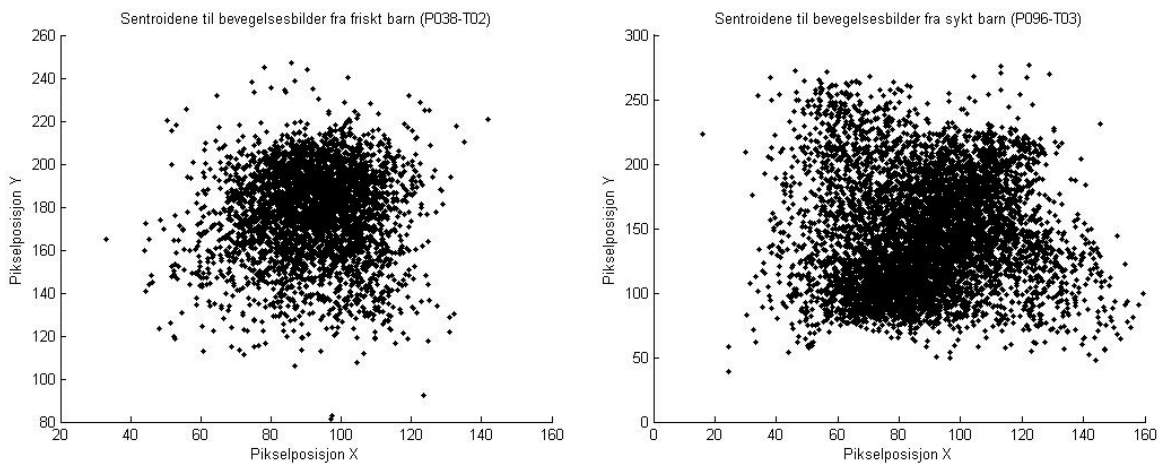
LDA er i dette prosjektet brukt til å klassifisere segmenter til å inneholde FM eller ikke. Det er dette som danner forutsetningen for en av segmenteringsmetodene utarbeidet i dette prosjektet. Som alt annet er dette gjort i MATLAB og det er funksjonen *classify* som er benyttet med tilleggsparemeteren *linear*.

### 3.4 Segmentering basert på bevegelsesbilder

Arbeidet i [11] brukte kun bevegelsesbildene til analyse og klassifisering. To av de viktigste resultatene var basert på QoM og sentroiden til disse bildene. Klassifisering av friske og syke barn kan gjøres ved å se på gjennomsnittsverdien til QoM ( $Q_{\text{mean}}$ ) for en serie med bevegelsesbilder. Det ble funnet en grense for hvilke verdi  $Q_{\text{mean}}$  måtte overstige for at FM skulle være sannsynlig og da bekrefte at barnet hadde et normal bevegelsesmønster. På samme måte ble sentroiden til bevegelsesbildene studert og det viste seg at FM førte i større grad til et mer kompakt og sirkulært mønster ved plotting av sentroiden mens for opptak uten FM ble mønsteret mer ubestemmelig. Variabelen brukt for å skille mellom friske og syke i dette tilfellet var standardavviket til sentroiden ( $C_{SD}$ ) som typisk har en lavere verdi for bevegelsesbilder generert fra video med FM. Videre ble det i [14] utviklet en form for prediktor kalt CPP som ved hjelp av de tre variablene  $Q_{\text{mean}}$ ,  $Q_{SD}$  og  $C_{SD}$  skulle klassifiser opptak som normale eller unormale. Med gode resultater til tross for lite testing er det også i dette prosjektet valgt å ta utgangspunkt i de samme variablene ved utformingen av segmenteringsmetodene. Variansen til sentroiden ble også vurdert, men siden dette er kvadratet av standardavviket er det ikke særlig mye å tjene på å tilføye denne variabelen som kriterium for klassifisering og segmentering.

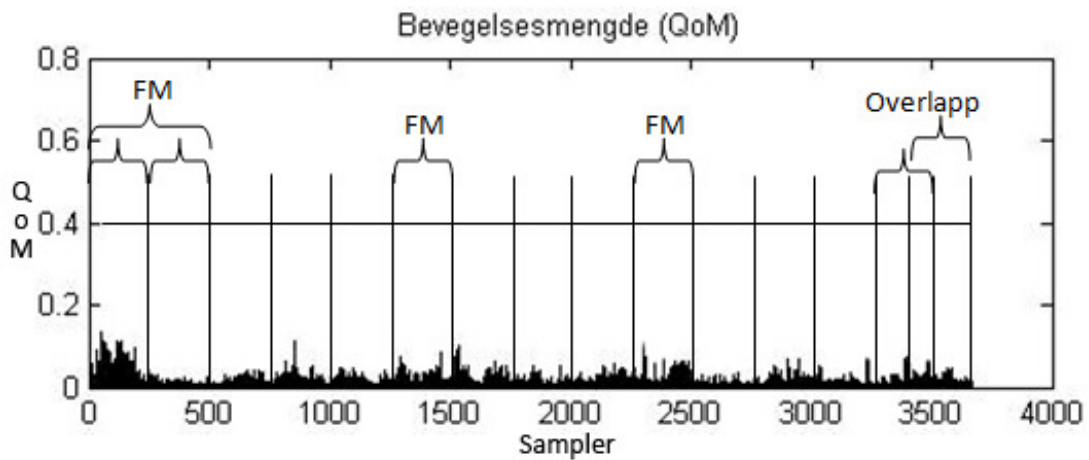
For å forsikre at resultatene fra [11,14] er mulig å gjenskape er det underveis gjort tester i MATLAB for å sammenligne, noe som har bekreftet at programmene laget i MATLAB produserer fullgode resultater med de fra GMT.

## KAPITTEL 3. METODE




**Figur 3.10:** Plot av sentroiden til hvert enkelt bevegelsesbilde. Bildet til venstre viser sentroiden til et friskt barn og man kan tydelig se en sirkulær form på den konsentrerte dataen noe som indikerer forekomster av FM. Bildet til høyre inneholder data fra et sykt barn noe som gjenspeiles ved at formen på plottet er mer ubeskrivelig uten noen tydelig form. Plottene er skalert slik de er siden aksene representerer bildenes høyde og bredde.

For å oppdrive CPP variablene er det laget en metode som kalkulerer disse for segmenter med en spesifisert lengde, kalt et "vindu". Denne metoden tar da altså inn antallet med bevegelsesbilder som passer inn i vinduet og regner ut variabelverdiene for dette segmentet. Når et segment er ferdig hopper det videre til neste segment og nye verdier kalkuleres og lagres. Denne prosessen gjentas helt til det ikke er flere bevegelsesbilder igjen og det man sitter igjen med da er vektorer med alle CPP verdiene for det aktuelle settet av bevegelsesbilder. Vinduet til metoden kan justeres noe som gir klare utslag i resultatene og dersom man vet når FM er til stede og vil finne verdiene for disse spesifikke områdene kan dette gjøres. Dette er også helt nødvendig for å kunne skille mellom sekvenser med FM eller ikke og er samtidig det som muliggjør bruken av de valgte metodene. I disse tilfellene angir man enkelt og greit et startpunkt og slutt punkt og metoden finner variabelverdiene for det valgte segmentet. Situasjoner hvor det siste vinduet til metoden overskrider slutt punktet eller det siste bevegelsesbildet i settet vil dette vinduet flyttes tilbake og overlappes med det forrige for å sørge for en konstant lengde på hvert vindu. Ut i fra hvilke verdier hvert segment har kan det klassifiseres til å inneholde FM eller ikke. Dette betyr at et sett kan inneholde segmenter med og uten FM selv om det tilhører et friskt barn. Poenget er å finne segmentene som garantert inneholder FM og på den måten ekskludere nødvendigheten av at en spesialist må studere et fullstendig opptak. Han eller hun kan da hoppe rett til det angitte segmentet og forhåpentligvis bekrefte at det inneholder FM.




Figur 3.11: Oppdeling av QoM i segmenter for utregning av variabelverdier (samme metode gjelder for bevegelsesbilder). Segmenter blir kategorisert til å inneholde FM eller ikke og nabosegmenter av samme type slås sammen. Det siste segmentet flyttes tilbake med samme lengde som det overskrider enden og overlapper derfor det forrige segmentet. Dersom disse er av samme type blir også disse omgjort til ett segment.

Det er laget to hovedmetoder for å segmentere basert på CPP variablene. Den første er fullstendig egenutviklet uten bruk av større innebygde funksjoner og er nokså enkel i sin virkemåte. Ved å studere variabelverdiene og kombinasjoner av disse er det for denne metoden laget grenser for hver av dem. Et eksempel på dette er dersom et segment tilfredsstiller kriteriene  $C_{SD} < 0.1$ ,  $Q_{SD} > 0.015$  og  $Q_{mean} > 0.03$  betyr det at det klassifiseres til å inneholde FM.




Figur 3.12: Plot av  $Q_{mean}$  og  $C_{SD}$  for segmentvindu med lengde 50 (2 sekunder). Hvert av de svarte punktene representerer et segment bestående av FM. De røde er uten FM.

### KAPITTEL 3. METODE




Figur 3.13: Plot av  $Q_{\text{mean}}$  og  $C_{SD}$  for segmentvindu med lengde 125 (5 sekunder). Hvert av de svarte punktene representerer et segment bestående av FM. De røde er uten FM.




Figur 3.14: Plot av  $Q_{\text{mean}}$  og  $C_{SD}$  for segmentvindu med lengde 125 (5 sekunder). Hvert av de svarte punktene representerer et segment bestående av FM. De røde er uten FM mens de grønne punktene representerer FM med moderat intensitet.

### KAPITTEL 3. METODE




Figur 3.15: Plot av  $Q_{\text{mean}}$  og  $C_{\text{SD}}$  for segmentvindu med lengde 175 (7 sekunder). Hvert av de svarte punktene representerer et segment bestående av FM. De røde er uten FM.




Figur 3.16: Plot av  $Q_{\text{mean}}$  og  $C_{\text{SD}}$  for segmentvindu med lengde 225 (9 sekunder). Hvert av de svarte punktene representerer et segment bestående av FM. De røde er uten FM.



### KAPITTEL 3. METODE

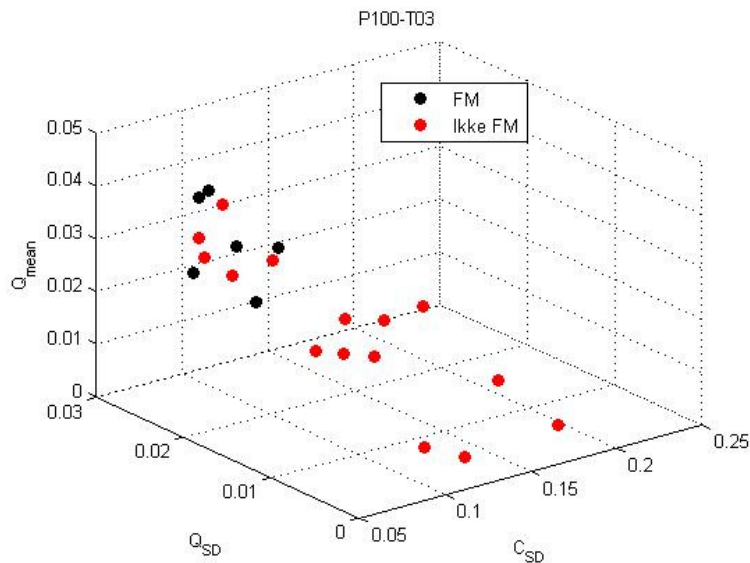


**Figur 3.17:** Plot av  $Q_{SD}$  og  $C_{SD}$  for segmentvindu med lengde 125 (5 sekunder). Hvert av de svarte punktene representerer et segment bestående av FM. De røde er uten FM.



**Figur 3.18:** Plot av  $Q_{SD}$  og  $C_{SD}$  for segmentvindu med lengde 225 (9 sekunder). Hvert av de svarte punktene representerer et segment bestående av FM. De røde er uten FM.

## KAPITTEL 3. METODE



**Figur 3.19:** Plot av  $Q_{\text{mean}}$ ,  $Q_{\text{SD}}$  og  $C_{\text{SD}}$ . Hvert av de svarte punktene representerer et segment bestående av FM mens de røde er uten FM. Denne type plot gjør det mulig å studere de forskjellige variabelverdiene i tre dimensjoner.

Segmenter som klassifiseres til å inneholde FM eller ikke FM, legges i hver sin liste (vektor i MATLAB) og det er listen med FM som brukes til å representere resultatene. Måten dette gjøres på er å skrive til skjermen hvilke bevegelsesbilder som tilhører de aktuelle segmentene og samtidig hvilke tidspunkter disse korrelerer til i den tilhørende videoen. Et eksempel på hvordan dette kan se ut er vist under:

Fant 3 segmenter som inneholder FM!

Segment 1: 1 - 176 (00m00s - 00m07s)

Segment 2: 1225 - 1575 (00m49s - 01m03s)

Segment 3: 1750 - 1925 (01m10s - 01m17s)

Informasjonen vist over kan også representeres grafisk på plot av QoM eller motiongram noe som vises i kapittel 5.2.

Den andre av de to segmenteringsmetodene baserer seg på LDA. Denne metoden benytter også de tre variablene og bruker verdiene produsert på samme måte som illustrert i figur 3.11 til å bestemme hvordan segmenter klassifiseres. Funksjonen *classify* i MATLAB brukes i denne sammenheng og kan på sin enkleste form uttrykkes som:

Klasse = *classify*(testsett, treningssett, gruppe)

## KAPITTEL 3. METODE

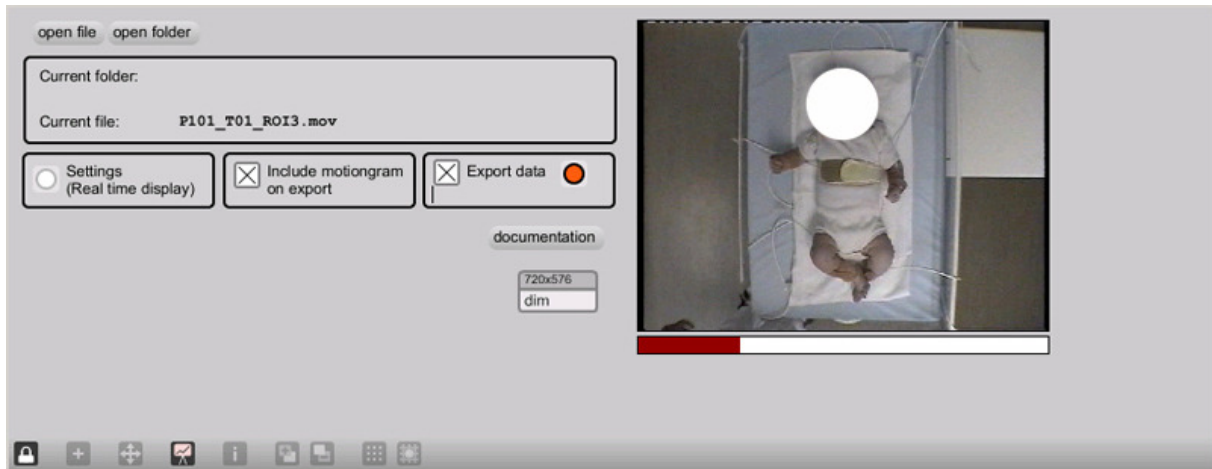
Måten denne funksjonen fungerer på er å benytte såkalte test- og treningssett som i dette tilfellet inneholder verdiene til  $Q_{\text{mean}}$ ,  $Q_{\text{SD}}$  og  $C_{\text{SD}}$  for segment fra de aktuelle settene med bevegelsesbilder. Hver rad i et treningssett inneholder verdiene til hvert segment og avhengig av om segmentene stammer fra bevegelsesbilder med FM eller ikke blir også disse delt inn i treningssett med og uten FM. Det er altså treningssettet som "tuner" klassifikatoren og bestemmer hvilke parametre modellen får. Testsettet består av variabelverdiene for den aktuelle sekvensen med bevegelsesbilder som skal klassifiseres og må ha samme antall kolonner som treningssettet. Variabelen "gruppe" er knyttet til prosedyren på den måten at den bestemmer hvilke rader i treningssettet som representerer FM eller ikke. Resultatet av klassifiseringen finnes til slutt i kolonnevektoren "Klasse" hvor hver rad representerer samme rad i testsettet, men nå med verdien 1 dersom raden (segmentet) er klassifisert til å inneholde FM og 0 dersom klassifikasjonen tilsier ingen FM. For å kunne produsere mer brukervennlig data blir denne resultatvektoren modifisert slik at resultatene kan fremvises på samme måte som for den første metoden.

Det kan tillegges at klassifisering basert på LDA ble foretatt ved kryssvalidering av typen "leave-one-out" som vil si at testsettet består kun av ukjent data og treningssettet er sammensatt av alle de andre datasettene som på forhånd har fått en tilordning (FM eller ikke FM). For hvert nye testsett forandres også treningssettet slik at det ikke inneholder data direkte fra det aktuelle testsettet. På denne måten trenes klassifikatoren uavhengig av dataene i testsettet. Dette er gjort for samtlige tilgjengelige sekvenser med bevegelsesbilder slik at alle har vært både testsett og en del av treningssettet noe som fører til fordelene med full utnyttelse av treningsdataene.

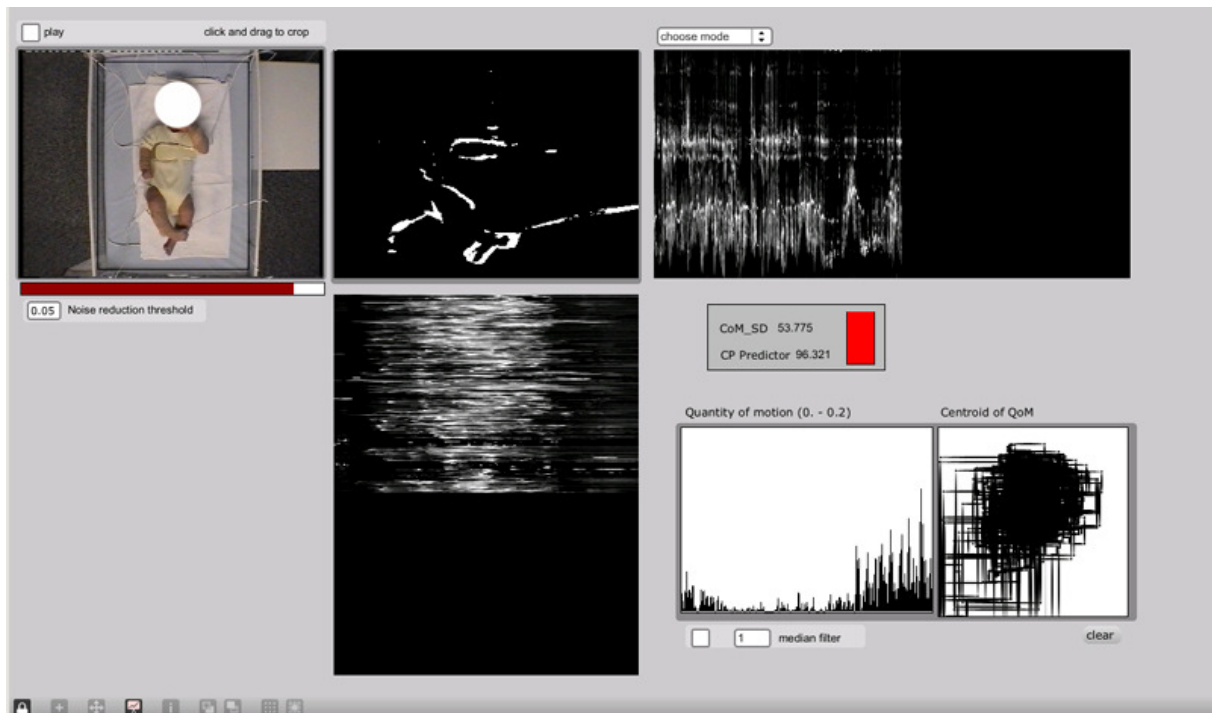
### 3.5 Generering og bruk av motiongram

Det er laget kode i MATLAB for generering av motiongram og analyse av de produserte bildene samt måter å benytte seg av dem på presenteres her. På grunn av den eksisterende modulen til A R. Jensenius for generering av motiongram, som tidligere er brukt til noe av det samme arbeidet og tilpasset analysen av spedbarn [11], ble det naturlig å ta utgangspunkt i dette under konstruksjonen av toolboxen i MATLAB. Plattformen denne modulen baserer seg på er Max/MSP/Jitter som krever rammeverket *Jamoma* for å kunne brukes. Dette er ikke direkte overførbart til MATLAB slik at det kun med utgangspunkt i beskrivelsen av hvordan motiongram blir til [6,12] er blitt utviklet noe lignende for MATLAB. Mangel på detaljerte beskrivelser av virkemåten til modulen med hensyn på motiongram har gjort det vanskelig å få til en identisk reproduksjon på en annen plattform. Dette har ført til at resultatene til de to programmene ikke får blitt 100% identiske, men det er gjennomført testing og sammenligning for å minimere forskjellene. De egenproduserte resultatene i MATLAB er derfor blitt såpass like de motiongramene generert av modulen fra GMT slik at begge antas å produsere likeverdige resultater.

### KAPITTEL 3. METODE



Figur 3.20: Grensesnittet til programmodulen fra GMT hvor aktuelle filer eller mapper med video åpnes og gjøres klare til eksportering av data.




Figur 3.21: Grensesnittet til programmodulen fra GMT hvor dataene visualiseres samtidig som de eksporteres. Dataene for QoM og sentroide til hvert enkelt bevegelsesbilde lagres i en tekstfil sammen med et horisontalt og et vertikalt motiogram. Bevegelsesbildet og motiogramene blir her fremvist på samme måte som i figur 2.2.

### KAPITTEL 3. METODE


Motiongrammodulene fra GMT har et praktisk og brukervennlig grensesnitt som betyr at det kreves minimalt med erfaring for å kunne bruke det effektivt. Likevel har ikke denne modulen noen form for analyse av motiongrammene den produserer. Det fokuseres her heller på hvert enkelt bevegelsesbilde og informasjonen man kan hente fra disse. Motiongrammene med sine bevegelseskurver er kun benyttet som et visuelt hjelpemiddel og er ikke blitt brukt i noen form for kvalitativ analyse slik som bevegelsesbildene. Det er på dette området gjennomført noe mer arbeid med hensyn på uttrekking av variabelverdier også fra motiongrammene. Å lage en form for segmentering basert på informasjonen hentet ut i fra motiongram var det opprinnelige målet her, men ettersom tiden har gått og kunnskapen om disse systemene har blitt betrakelig større er det åpenlyst at å bruke motiongram til dette formålet kun er å gjøre arbeidet mer komplisert enn nødvendig. Det blir en omvei å benytte motiongram til segmentering fordi variablene vi ønsker å trekke ut av dem er lettere tilgjengelig ved bruk av bevegelsesbildene. Motiongram lages av bevegelsesbildene og for å produsere den samme informasjonen som fra tidligere viser seg å gi gode resultater må man i mange tilfeller gjøre en mer omfattende jobb enn nødvendig. Likevel kan det være situasjoner hvor kun motiongram er tilgjengelig noe som er tilfellet med musikkrelatert data i dette prosjektet.

Det videre arbeidet med hensyn på spedbarn er kun basert på bevegelsesbilder og motiongram generert i MATLAB. For å vise hvor sammenlignbare resultatene til de to ulike måtene er kan man betrakte likheten i figurene 3.22 og 3.23. Disse viser henholdsvis motiongram og QoM fra samme videoopptak, men mens GMT modulen har anvendt videoen direkte har den egenproduserte MATLAB modulen benyttet stillbildene fra samme video som også er tilgjengelig.

Motiongram generert av GMT modul

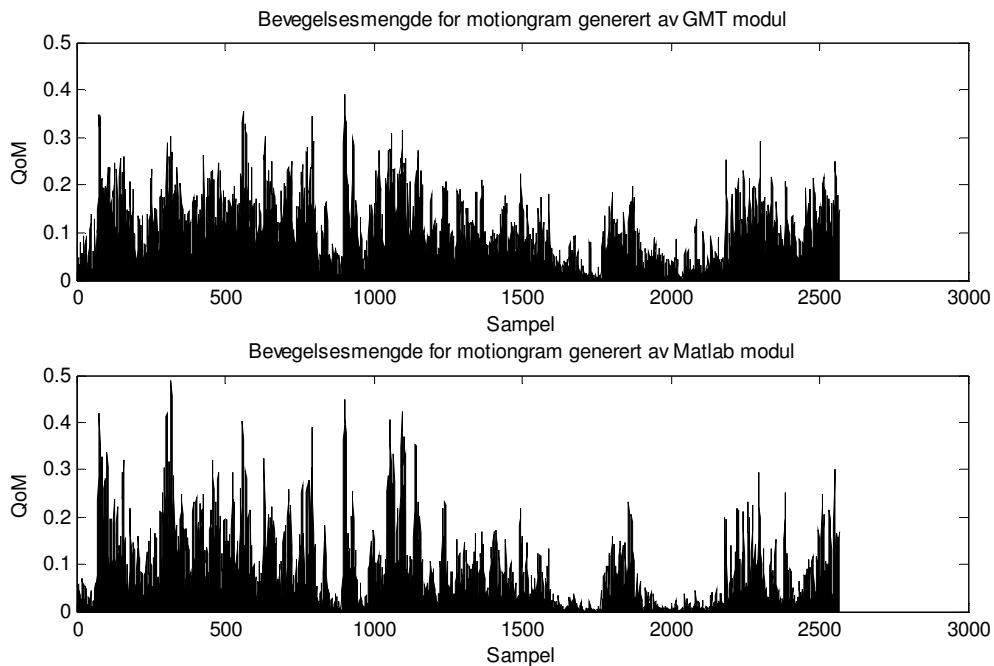


Motiongram generert av Matlab modul



**Figur 3.22:** Motiongram fra samme video generert av henholdsvis modulen fra GMT og de egenproduserte programmene i MATLAB. Man kan observere at bildet laget i MATLAB viser noe mindre bevegelse ved at det er færre hvite piksler (grunnet filtrering), men er ellers veldig like.

### KAPITTEL 3. METODE



**Figur 3.23:** Kurver som viser bevegelsesmengden til motiongramene fra figur 3.22. Gjennomsnittsverdien til QoM fra MATLAB er i dette tilfellet litt lavere enn det fra GMT på grunn av sterkere filtrering av små pikselforandringer under genereringen av bevegelsesbildene motiongramet er basert på.

Arbeidet med metoder for segmentering basert kun på motiongram er ikke en prioritet. Derfor er dette ikke blitt betraktet som et reelt alternativ til segmentering basert på bevegelsesbilder foreløpig. Likevel skal det sies at bruk av både horisontale og vertikale motiongram gir muligheten til å reprodusere samme sentroideverdier som for bevegelsesbilder og da også  $C_{SD}$ . QoM og de variablene som dette bringer med seg kan også benyttes og da har man et grunnlag for en eventuell segmentering som ligner det som benyttes ved behandling av bevegelsesbildene. Motiongram er uansett brukt som et visuelt hjelpemiddel som kan bidra til bedre forståelse av bevegelsesmønstrene samt være med på å fremheve segmenteringsresultater. En måte dette kan gjøres på er presentert i kapittel 5.2.

### 3.6 Sensordata

Utgangspunktet for å gjennomføre segmenteringen av sensordata er ved å tilpasse modeller til dataene som er tilgjengelige. Ved å gjøre dette lager man et system hvor et eller flere av sensorsignalene blir utgangsvariablene til den valgte modellen og får da muligheten til å studere dette nærmere. Ved å estimere modellparametrene kan man iaktta disse mens utgangen forandrer seg og se om det er noe karakteristisk med hvordan de endres. Dersom utgangen, altså sensorsignalene, har en kontinuerlig og forholdsvis ensformig dynamikk over en viss periode vil ikke parametrene til modellen forandre seg nevneverdig. På den andre siden dersom dynamikken eller "mønsteret" til signalene veksler og man opplever sprang i amplitude og frekvens vil parametrene i modellen også gjøre sprang for å tilpasses disse forandringene. Det er "sprangene" i parameterverdi som brukes til segmentering ved at man da kan detektere endringer i signalene som er relevante og ellers ikke så enkle å oppfatte. For å få en oversikt over hvordan parameterestimeringen går til og beskrivelse av matematikken som ligger bak henvises det til [7] hvor dette er presentert på en god og oversiktlig måte.

Arbeidet gjort i [7] er ikke tatt noe videre i dette prosjektet, men å benytte metodene for parameterestimering på dataene fra bevegelsesbilder for å lage tilleggsvariable til de som allerede er benyttet er blitt vurdert. Dette har potensial til å øke nøyaktigheten til segmenteringsmetodene, men på grunn av tidsbegrensning forblir dette et fremtidig alternativ.

KAPITTEL 3. METODE



## 4 MS Toolbox

Her presenteres arbeidet utført i MATLAB som til sammen har akkumulert i en samling av programmer kalt "Motion Segmentation Toolbox" (MST) for behandling av data fra CIMA-prosjektet. Det forklares enkelt hvordan man går frem for å ta i bruk toolbox'en sammen med en utledning av dens utvikling. All relevant informasjon relatert til prosjektet samt MST ligger på en CD vedlagt rapporten.

### 4.1 Generelt

Selve toolbox'en består av en "hovedmappe" kalt MSToolbox hvor alle filene befinner seg. Her ligger alle MATLAB filene med kode samt mapper for bilder, plot og diverse filer som kan komme til nytte i ulike situasjoner. Det første man bør gjøre når man har startet MATLAB er å navigere seg til hovedmappen slik at denne blir "Current Directory". Neste steg er å få en oversikt over toolboxen og ved å skrive "help MSToolbox" i Command Window vil MATLAB ved hjelp av informasjonen i Contents.m, som også ligger i mappen, presentere en oversiktelig liste med navn og en kort beskrivelse på alle filene som inneholder kode. Dersom man vil ha en mer detaljert beskrivelse kan man trykke på ønsket fil i den genererte lisen og man vil få dette. Med dette har man et godt utgangspunkt for å kunne foreta videre arbeid. Det er også i *Appendiks A.4* komponert en kort manual for fremgangsmåtene man benytter avhengig av hvilken jobb man vil ha gjort (segmentere, generere bevegelsesbilder og motiongram osv).

For å gjøre toolbox'en mer komplett er programmene og dataene fra prosjektet i fjor høst [7] lagt ved. Ingen av metodene er benyttet i dette prosjektet, men dersom det skulle være behov for å bruke dem er de tilgjengelige. I tillegg medfølger toolbox'en til Fredrik Gustafsson [20] som inneholder algoritmer for adaptiv filtrering og detektering av forandringer i signal som også kan være nyttig i denne sammenheng.

### 4.2 Generering av bevegelsesbilder og motiongram

Som oppgaveteksten sier skal det benyttes tidligere metoder i den grad detter er mulig og samtidig utvikles nye dersom nødvendig. Utgangspunktet for bruk av måledata i dette prosjektet var å benytte ferdig genererte motiongram eller lage dem selv via GMT. For musikkrelaterte bevegelser er det brukt ferdige motiongram generert av A R Jensenius, men under arbeidet med generering via GMT av

## KAPITTEL 4. MS Toolbox

spedbarnsvideo oppsto det problemer. En feil i programvaren på dette tidspunktet gjorde det umulig å lage motiongram for video med spilletid over en viss lengde. Siden det fra tidligere var ønskelig og nå også nødvendig, ble det laget et alternativ til GMT i MATLAB.

I kapittel 3.2 står det beskrevet hva som inngår i preprosesseringen av data og alt dette er blitt "oversatt" til programkode i MATLAB. Alle videoene som danner datagrunnlaget til prosjektet er også tilgjengelige i bildeform (PNG – portable network graphics). På grunn av videoenes format (*mov* filer som MATLAB ikke leser) og tilgangen til hver frame som et bilde ble det gjort et valg om å bruke bilder i stede for video. De to mediene representerer nøyaktig det samme innholdet, men behandlingen av bilder gjorde jobben videre mindre komplisert. Koden som er laget er ikke programmert med tanke på hurtighet eller optimalisering av kjøretid, men heller konstruert med tanke på dens funksjon. Dette betyr at toolbox'en fungerer tilfredsstillende i forhold til arbeidet med dette prosjektet og denne rapporten, men er altså ikke optimal med hensyn på tids- og minnebruk. Et problem som ofte dukket opp under utviklingen var at det gikk tomt for midlertidig minne. Grunnen til dette er ganske enkel siden videoframes og andre bilder representeres av matriser i MATLAB og ved generering av bevegelsesbilder og motiongram ligger det veldig mange slike matriser i minnet. Så for ikke å bruke enda mer unødig tid på koding ble det bestemt at det skulle behandles en "batch" på 2000 bilder om gangen hvorpå det fullstendige motiongramet som regel er sammensatt av ett eller flere bilder, generert et om gangen. Bildene som leses inn minne organiseres slik at høyde, bredde, farge og antall er variablene som danner matrisene. Dette betyr at bildene lagres som et 4 dimensjonalt dataobjekt som senere gjøres om til en 3 dimensjonal matrise ved at bildene konverteres fra RGB til gråtone. Når bevegelsesbildene er ferdige kan disse enkelt lagres i en spesifiser mappe og selv om bildene lages i omganger vil programmet som lagrer dem legge dem i riktig rekkefølge og med riktig nummerering noe som er svært viktig for den senere behandlingen.

Preprosesseringen av disse bildene er den viktigste delen ved fremstillingen av motiongram og arbeidet i MATLAB i forbindelse med dette tok lengre tid en først antatt. Det ble en god del prøving og feiling før motiongramene kunne sammenlignes med de tidligere eksemplene laget av GMT noe som gjorde denne prosessen mer omfattende enn resultatene skulle tilsi. Uansett så kan det lages både horisontale og vertikale motiongram med variabel filtrering. Man lager motiongram fra bevegelsesbildene i omganger dersom dette gjøres i forbindelse med innlasting av de originale bildene. Har man derimot allerede lagret bevegelsesbildene i en mappe kan man hente alle disse og lage hele motiongramet i en omgang. Dette kommer av at bevegelsesbildene lagres som bilder av typen *logical* som tar opp til 8 ganger mindre plass i minnet enn det et vanelig gråtonebilde av typen *uint8* gjør.

### **4.3 Behandling av bevegelsesbilder**

Bevegelsesbildene er som sagt representert som 3D matriser i MATLAB. Med dette som utgangspunkt er det derfor nokså ukomplisert å foreta diverse utregninger og manipuleringer av disse dataene. Et viktig aspekt er å produsere nyttige variable som danner grunnlaget til den etterfølgende segmenteringen. Det er derfor mulig å plote forskjellige variable for å se på sammensetningen av disse og om det er muligheter for å definere segmenteringsgrenser basert på variablenes skiftende verdi. Videre er det laget segmenteringsalgoritmer som benytter opptil tre variable som basis for å finne og klassifisere interessante segmenter.

### **4.4 Behandling av motiongram**

Når motiongram fra ønsket video er generert er det mulig å behandle disse bildene ved bruk av forskjellige metoder. Det er derfor laget flere programmer som gjennomfører utregninger av ulike variable ut i fra motiongramene. Som tidligere nevnt er det QoM og sentroide som er de mest brukte variablene og disse kan produseres sammen med gjennomsnittsverdier, varianser og standardavvik. På denne måten kan det finnes segmenter i motiongram som tilfredsstill kriterier for å inneholde FM, men behandling av motiongram på denne måten er ikke like god som metodene basert på variable hentet fra bevegelsesbildene. Derfor er bruk av motiongram foreløpig forbeholdt visuell analyse og grafisk representasjon av segmenteringsresultater.

KAPITTEL 4. MS Toolbox

## 5 Evaluering

Her vil metodene som er utviklet og resultatene oppnådd bli evaluert. Hvilke metoder som fungerer best til formålet samt hvordan den automatiske segmenteringen presterer sammenlignet med den manuelle er de viktigste resultatene presentert her.

### 5.1 Metode

Det var den egenkomponerte metoden basert kun på forhåndsbestemte grenser for variablene som ble benyttet til testing av hvilke kombinasjoner som ville produsere mest mulig like resultater sammenlignet med den manuelle segmenteringen. Det ble testet ved bruk av kun en variabel, forskjellige kombinasjoner av to variable og til slutt alle de tre variablene sammen. Det skulle vise seg at bruken av alle de tre variablene samtidig totalt sett gav de beste resultatene, men også noen kombinasjoner av kun to variable presterte godt i enkelte tilfeller. Hvilke segmenter som ble klassifisert til å inneholde FM av de forskjellige metodene og hvordan de skilte seg fra hverandre kan ses i tabellene under. Ikke alle vindulengder eller kombinasjoner av variable er vist for alle testene da det viser seg at noen er overflødige og andre lager resultater som ikke er av interesse. I flere av tilfellen vil også forskjellen mellom den manuelle segmenteringen og den automatiske være veldig stor. En forklaring på dette diskuteres i kapittel 6.1.

**Tabell 5.1: Resultatene til egenutviklet metode for forskjellige variable med den manuelle segmenteringen av L Adde til sammenligning. Testet på pasientoptak P100\_T03 med et vindu på 75 (3 sekunder).**

P100_T03 Vindu: 75	Metode						
	Adde	$Q_{\text{mean}}$	$Q_{\text{SD}}$	$C_{\text{SD}}$	$Q_{\text{mean}}, C_{\text{SD}}$	$Q_{\text{SD}}, C_{\text{SD}}$	$Q_{\text{mean}}, Q_{\text{SD}}, C_{\text{SD}}$
Ant. segment	1	4	4	6	4	5	5
Segment 1	75-750	75-150	75-225	75-825	75-150	75-225	75-150
Segment 2	x	300-600	300-375	900-1200	300-600	300-375	300-375
Segment 3	x	675-825	450-675	1275-1425	675-825	450-675	450-600
Segment 4	x	1050-1200	750-1275	1800-1875	1050-1200	750-825	750-825
Segment 5	x	x	x	2250-2325	x	900-1200	1050-1200
Segment 6	x	x	x	2475-2567	x	x	x

KAPITTEL 5. EVALUERING

**Tabell 5.2: Resultatene til egenutviklet metode for forskjellige variable med den manuelle segmenteringen av L Adde til sammenligning. Testet på pasientopptak P100\_T03 med et vindu på 125 (5 sekunder).**

P100_T03 Vindu: 125	Metode						
	Adde	Q <sub>mean</sub>	Q <sub>SD</sub>	C <sub>SD</sub>	Q <sub>mean</sub> , C <sub>SD</sub>	Q <sub>SD</sub> , C <sub>SD</sub>	Q <sub>mean</sub> , Q <sub>SD</sub> , C <sub>SD</sub>
Ant. segment	1	2	2	3	2	2	2
Segment 1	75-750	250-625	1-625	1-750	250-625	1-625	250-625
Segment 2	x	1125-1250	750-1250	1000-1375	1125-1250	1000-1250	1125-1250
Segment 3	x	x	x	2442-2567	x	x	x

**Tabell 5.3: Resultatene til egenutviklet metode for forskjellige variable med den manuelle segmenteringen av L Adde til sammenligning. Testet på pasientopptak P100\_T03 med et vindu på 175 (7 sekunder).**

P100_T03 Vindu: 175	Metode						
	Adde	Q <sub>mean</sub>	Q <sub>SD</sub>	C <sub>SD</sub>	Q <sub>mean</sub> , C <sub>SD</sub>	Q <sub>SD</sub> , C <sub>SD</sub>	Q <sub>mean</sub> , Q <sub>SD</sub> , C <sub>SD</sub>
Ant. segment	1	2	1	2	2	2	2
Segment 1	75-750	1-700	1-1225	1-875	1-700	1-875	1-700
Segment 2	x	1050-1225	x	1050-1400	1050-1225	1050-1225	1050-1225

**Tabell 5.4: Resultatene til egenutviklet metode for forskjellige variable med den manuelle segmenteringen av L Adde til sammenligning. Testet på pasientopptak P100\_T03 med et vindu på 225 (9 sekunder).**

P100_T03 Vindu: 225	Metode						
	Adde	Q <sub>mean</sub>	Q <sub>SD</sub>	C <sub>SD</sub>	Q <sub>mean</sub> , C <sub>SD</sub>	Q <sub>SD</sub> , C <sub>SD</sub>	Q <sub>mean</sub> , Q <sub>SD</sub> , C <sub>SD</sub>
Ant. segment	1	1	1	2	1	2	1
Segment 1	75-750	225-675	1-1350	1-675	225-675	1-675	225-675
Segment 2	x	x	x	900-1350	x	900-1350	x

**Tabell 5.5: Resultatene til egenutviklet metode for forskjellige variable med den manuelle segmenteringen av L Adde til sammenligning. Testet på pasientopptak P100\_T03 med et vindu på 375 (15 sekunder).**

P100_T03 Vindu: 375	Metode						
	Adde	Q <sub>mean</sub>	Q <sub>SD</sub>	C <sub>SD</sub>	Q <sub>mean</sub> , C <sub>SD</sub>	Q <sub>SD</sub> , C <sub>SD</sub>	Q <sub>mean</sub> , Q <sub>SD</sub> , C <sub>SD</sub>
Ant. segment	1	1	1	1	1	1	1
Segment 1	75-750	1-750	1-1500	1-750	1-750	1-750	1-750

KAPITTEL 5. EVALUERING

**Tabell 5.6: Resultatene til egenutviklet metode for forskjellige variable med den manuelle segmenteringen av L Adde til sammenligning. Testet på pasientopptak P093\_T03 med et vindu på 125 (5 sekunder).**

P093_T03 Vindu: 125	Metode				
	Adde	$Q_{\text{mean}}, Q_{\text{SD}}$	$Q_{\text{mean}}, C_{\text{SD}}$	$Q_{\text{SD}}, C_{\text{SD}}$	$Q_{\text{mean}}, Q_{\text{SD}}, C_{\text{SD}}$
Ant. segment	5	8	8	7	8
Segment 1	0-175	0-125	0-125	0-125	0-125
Segment 2	300-1375	250-375	250-375	250-1375	250-375
Segment 3	1575-2600	500-1375	500-1375	1500-2875	500-1375
Segment 4	4000-4825	1500-2750	1500-2750	3250-3375	1500-2750
Segment 5	5025-5875	3125-3375	3250-3375	3500-3625	3250-3375
Segment 6	x	4000-5500	4000-5500	4000-5750	4000-5500
Segment 7	x	5625-5875	5625-5750	6000-6188	5625-5750
Segment 8	x	6000-6188	5950-6188	x	5950-6188

**Tabell 5.7: Resultatene til egenutviklet metode for forskjellige variable med den manuelle segmenteringen av L Adde til sammenligning. Testet på pasientopptak P093\_T03 med et vindu på 175 (7 sekunder).**

P093_T03 Vindu: 175	Metode				
	Adde	$Q_{\text{mean}}, Q_{\text{SD}}$	$Q_{\text{mean}}, C_{\text{SD}}$	$Q_{\text{SD}}, C_{\text{SD}}$	$Q_{\text{mean}}, Q_{\text{SD}}, C_{\text{SD}}$
Ant. segment	5	6	6	6	6
Segment 1	0-175	0-175	0-175	0-175	0-175
Segment 2	300-1375	525-1400	525-1400	350-1400	525-1400
Segment 3	1575-2600	1575-2975	1575-2975	1575-2975	1575-2975
Segment 4	4000-4825	3150-3325	3150-3325	3150-3325	3150-3325
Segment 5	5025-5875	4025-5775	4025-5775	4025-5775	4025-5775
Segment 6	x	5950-6188	5950-6188	5950-6188	5950-6188

**Tabell 5.8: Resultatene til egenutviklet metode for forskjellige variable med den manuelle segmenteringen av L Adde til sammenligning. Testet på pasientopptak P093\_T03 med et vindu på 225 (9 sekunder).**

P093_T03 Vindu: 225	Metode				
	Adde	$Q_{\text{mean}}, Q_{\text{SD}}$	$Q_{\text{mean}}, C_{\text{SD}}$	$Q_{\text{SD}}, C_{\text{SD}}$	$Q_{\text{mean}}, Q_{\text{SD}}, C_{\text{SD}}$
Ant. segment	5	5	5	5	5
Segment 1	0-175	0-1350	0-1350	0-1350	0-1350
Segment 2	300-1375	1575-2700	1575-2700	1575-2925	1575-2700
Segment 3	1575-2600	3150-3375	3150-3375	3150-3375	3150-3375
Segment 4	4000-4825	4050-5850	4050-5850	4050-5850	4050-5850
Segment 5	5025-5875	5963-6188	5963-6188	5963-6188	5963-6188

KAPITTEL 5. EVALUERING

**Tabell 5.9: Resultatene til egenutviklet metode for forskjellige variable med den manuelle segmenteringen av L Adde til sammenligning. Testet på pasientopptak P093\_T03 med et vindu på 375 (15 sekunder).**

P093_T03 Vindu: 375	Metode				
	Adde	$Q_{\text{mean}}, Q_{\text{SD}}$	$Q_{\text{mean}}, C_{\text{SD}}$	$Q_{\text{SD}}, C_{\text{SD}}$	$Q_{\text{mean}}, Q_{\text{SD}}, C_{\text{SD}}$
Ant. segment	5	2	3	3	3
Segment 1	0-175	0-3375	0-1125	0-1125	0-1125
Segment 2	300-1375	4125-6188	1500-3000	1500-3000	1500-3000
Segment 3	1575-2600	x	4125-6000	4125-6000	4125-6000
Segment 4	4000-4825	x	x	x	x
Segment 5	5025-5875	x	x	x	x

**Tabell 5.10: Resultatene til egenutviklet metode for forskjellige variable med den manuelle segmenteringen av L Adde til sammenligning. Testet på pasientopptak P038\_T02 med et vindu på 50 (2 sekunder).**

P038_T02 Vindu: 50	Metode		
	Adde	$Q_{\text{mean}}, C_{\text{SD}}$	$Q_{\text{mean}}, Q_{\text{SD}}, C_{\text{SD}}$
Ant. segment	4	4	3
Segment 1	0-225	0-200	0-200
Segment 2	1250-1900	1500-1550	1500-1550
Segment 3	2400-2550	2300-2400	2300-2400
Segment 4	3375-3665	2450-2500	x

**Tabell 5.11: Resultatene til egenutviklet metode for forskjellige variable med den manuelle segmenteringen av L Adde til sammenligning. Testet på pasientopptak P038\_T02 med et vindu på 75 (3 sekunder).**

P038_T02 Vindu: 75	Metode		
	Adde	$Q_{\text{mean}}, C_{\text{SD}}$	$Q_{\text{mean}}, Q_{\text{SD}}, C_{\text{SD}}$
Ant. segment	4	4	3
Segment 1	0-225	0-225	0-225
Segment 2	1250-1900	1500-1575	1500-1575
Segment 3	2400-2550	2250-2325	2250-2325
Segment 4	3375-3665	2400-2475	x



KAPITTEL 5. EVALUERING

**Tabell 5.12: Resultatene til egenutviklet metode for forskjellige variable med den manuelle segmenteringen av L Adde til sammenligning. Testet på pasientopptak P038\_T02 med et vindu på 125 (5 sekunder).**

P038_T02 Vindu: 125	Metode		
	Adde	$Q_{\text{mean}}, C_{\text{SD}}$	$Q_{\text{mean}}, Q_{\text{SD}}, C_{\text{SD}}$
Ant. segment	4	2	2
Segment 1	0-225	0-250	0-250
Segment 2	1250-1900	2375-2500	2375-2500
Segment 3	2400-2550	x	x
Segment 4	3375-3665	x	x

**Tabell 5.13: Resultatene til egenutviklet metode for forskjellige variable med den manuelle segmenteringen av L Adde til sammenligning. Testet på pasientopptak P038\_T02 med et vindu på 225 (9 sekunder).**

P038_T02 Vindu: 225	Metode		
	Adde	$Q_{\text{mean}}, C_{\text{SD}}$	$Q_{\text{mean}}, Q_{\text{SD}}, C_{\text{SD}}$
Ant. segment	4	2	2
Segment 1	0-225	0-225	0-225
Segment 2	1250-1900	x	x
Segment 3	2400-2550	x	x
Segment 4	3375-3665	x	x

**Tabell 5.14: Resultatene til egenutviklet metode for forskjellige variable med den manuelle segmenteringen av L Adde til sammenligning. Testet på pasientopptak P001\_T03 med et vindu på 125 (5 sekunder).**

P001_T03 Vindu: 125	Metode		
	Adde	$Q_{\text{mean}}, C_{\text{SD}}$	$Q_{\text{mean}}, Q_{\text{SD}}, C_{\text{SD}}$
Ant. segment	1	4	4
Segment 1	1000-5022	2750-2875	2750-2875
Segment 2	x	3125-3625	3125-3625
Segment 3	x	4625-4750	4625-4750
Segment 4	x	4875-5022	4875-5022

## KAPITTEL 5. EVALUERING

**Tabell 5.15: Resultatene til egenutviklet metode for forskjellige variable med den manuelle segmenteringen av L Adde til sammenligning. Testet på pasientopptak P001\_T03 med et vindu på 375 (15 sekunder).**

P001_T03 Vindu: 375	Metode		
	Adde	$Q_{\text{mean}}, C_{\text{SD}}$	$Q_{\text{mean}}, Q_{\text{SD}}, C_{\text{SD}}$
Ant. segment	1	2	2
Segment 1	1000-5022	2625-3750	2625-3750
Segment 2	x	4647-5022	4647-5022

Som sagt ble de beste resultatene oppnådd ved bruk av alle variable og dette ble derfor videreført under konstrueringen av algoritmene for segmentering basert på LDA. Størrelsen på segmenteringsvinduerne som ble brukt spilte også en utslagsgivende rolle for resultatene. For svært korte vinduer (50 bevegelsesbilder, 2 sekunder) mister man en del av helheten til signalet og får ofte veldig mange segmenter klassifisert som én type separert av segmenter av en annen type. Lange segmentvinduer (375 bevegelsesbilder, 15 sekunder) resulterer regelmessig i at segmentene blir feilklassifisert og man mister detaljene man ellers ville fått dersom man brukte et kortere vindu. På grunnlag av dette er all testingen med LDA-klassifikatoren foretatt med en vindulengde på 175 bevegelsesbilder (7 sekunder). Dette for å bedre kunne skille mellom deler av sekvensen hvor FM avtar eller starter samtidig som resultatet av segmenteringen ikke blir altfor oppstykket. Tabellene 5.1-5.15 viser testing gjort på pasientopptak som aller er friske. Testing av LDA-klassifikatoren ble gjort på opptak fra både friske og syke for å se hvordan den taklet sekvenser som ikke skal inneholde FM.

**Tabell 5.16: Resultatene til LDA-klassifikatoren med den manuelle segmenteringen av L Adde som sammenligning. Testet på pasientopptak P001\_T03 med et vindu på 175 (7 sekunder).**

P001_T03 Vindu: 175	Metode	
	Adde	LDA
Ant. segment	1	5
Segment 1	1000-5022	2100-2275
Segment 2	x	2625-2975
Segment 3	x	3150-3675
Segment 4	x	4200-4375
Segment 5	x	4900-5022

**Tabell 5.17: Resultatene til LDA-klassifikatoren med den manuelle segmenteringen av L Adde som sammenligning. Testet på pasientopptak P038\_T02 med et vindu på 175 (7 sekunder).**

P038_T02 Vindu: 175	Metode	
	Adde	LDA
Ant. segment	4	3
Segment 1	0-225	0-175
Segment 2	1250-1900	1225-1575
Segment 3	2400-2550	1750-1925
Segment 4	3375-3665	x

KAPITTEL 5. EVALUERING

**Tabell 5.18: Resultatene til LDA-klassifikatoren med den manuelle segmenteringen av L Adde som sammenligning. Testet på pasientopptak P093\_T03 med et vindu på 175 (7 sekunder).**

P093_T03 Vindu: 175	Metode	
	Adde	LDA
Ant. segment	5	6
Segment 1	0-175	0-175
Segment 2	300-1375	350-1400
Segment 3	1575-2600	1575-2975
Segment 4	4000-4825	3150-3325
Segment 5	5025-5875	4025-5775
Segment 6	x	5959-6188

**Tabell 5.19: Resultatene til LDA-klassifikatoren med den manuelle segmenteringen av L Adde som sammenligning. Testet på pasientopptak P100\_T03 med et vindu på 175 (7 sekunder).**

P100_T03 Vindu: 175	Metode	
	Adde	LDA
Ant. segment	1	2
Segment 1	75-750	0-875
Segment 2	x	1050-1400

**Tabell 5.20: Resultatene til LDA-klassifikatoren med den manuelle segmenteringen av L Adde som sammenligning. Testet på pasientopptak P040\_T03 (diagnose: CP) med et vindu på 175 (7 sekunder).**

P040_T03 Vindu: 175	Metode	
	Adde	LDA
Ant. segment	0	5
Segment 1	x	1575-1750
Segment 2	x	2275-2675
Segment 3	x	3500-3675
Segment 4	x	4200-4375
Segment 5	x	4550-4725

## KAPITTEL 5. EVALUERING

**Tabell 5.21: Resultatene til LDA-klassifikatoren med den manuelle segmenteringen av L Adde som sammenligning. Testet på pasientopptak P096\_T03 (diagnose: CP) med et vindu på 175 (7 sekunder).**

P096_T03 Vindu: 175	Metode	
	Adde	LDA
Ant. segment	0	4
Segment 1	x	2625-2975
Segment 2	x	3150-3500
Segment 3	x	4200-4725
Segment 4	x	5600-5775


**Tabell 5.22: Resultatene til LDA-klassifikatoren med den manuelle segmenteringen av L Adde som sammenligning. Testet på pasientopptak P101\_T01 (diagnose: CP) med et vindu på 175 (7 sekunder).**

P101_T01 Vindu: 175	Metode	
	Adde	LDA
Ant. segment	0	3
Segment 1	x	700-875
Segment 2	x	1750-2450
Segment 3	x	2625-2975


Pasient P054 er diagnostisert til å ha CP og skal derfor ikke ha et eneste segment med FM i sitt opptak. Dette bekreftet både den egenkomponerte metoden og LDA-klassifikatoren ved at ingen av dem fant segmenter med FM. Likevel er det flere av de testede opptakene som ikke inneholder bevegelsesmønsteret FM, men som likevel har fått klassifisert segmenter med FM på tross av dette. En mulig begrunnelse til disse resultatene samt utfallene av segmenteringen generelt diskuteres i kapittel 6.1.

## 5.2 Resultat

Mye tid er brukt på utvikling av metoder for genereringen av motiongram. For at grunnlaget til den senere segmenteringen skulle bli så korrekt som mulig ble genereringsprosessen kontinuerlig justert. Målet var å lage motiongram i MATLAB med samme standard som de produsert ved hjelp av GMT noe som må sies å være vellykket.



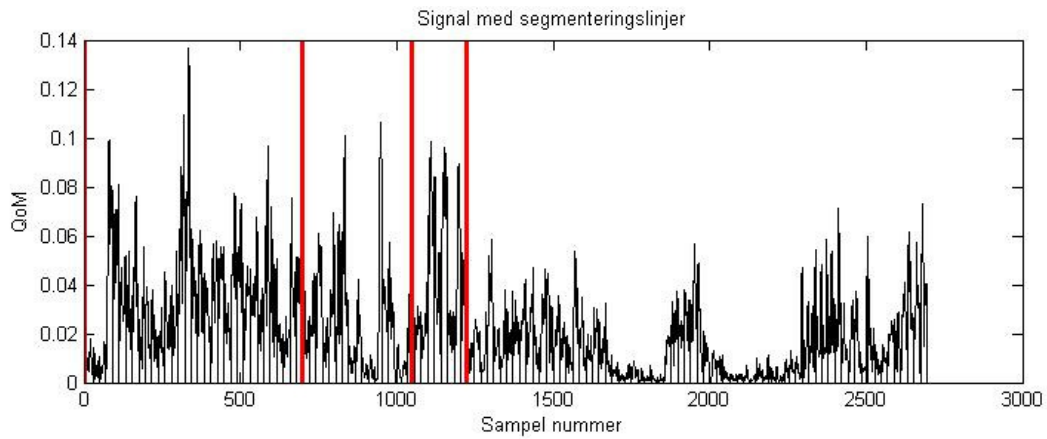
**Figur 5.1:** Horisontalt motiogram fra video av spedbarn med FM (P093\_T03) laget i MATLAB. Arm- og hodebevegelser vises i øverste halvdel av bildet mens bevegelsen til bena vises nederst. Tiden løper fra venstre til høyre og det er den vertikale bevegelsen som vises.




**Figur 5.2:** Horisontalt motiogram fra video av spedbarn uten FM (P040\_T03) laget i MATLAB. Ser av dette bildet at det er svært lite bevegelse sammenlignet med Figur 5.1. Det er heller ingen særlig sammenheng mellom bevegelsene i øvre og nedre del av motiogramet.

Tabellene 5.1-5.22 inneholder resultater i form av utstrekning og lengde av segmenter klassifisert som FM. Det disse ikke viser er hvordan bevegelsene i disse segmentene samt nabosegmentene ser ut samtidig som det er vanskelig å sammenligne resultatene direkte. På grunn av dette er det også blitt laget en form for visuell representasjon av segmenteringsresultatene i form av markerte segmenter i QoM-plot eller direkte på motiogram. Disse segmenteringslinjene kan enkelt overføres til et hvilket som helst signal noe som gjør det mulig å bruke dem i forbindelse med sensorsignalene også. Dette kan brukes i tillegg til de tallbaserte resultatene for å gi et mer helhetlig bilde av hvor godt segmenteringsmetodene har prestert. På denne måten er det umiddelbart mulig å sammenligne resultatene fra flere metoder og se hvilke som egner seg best til formålet.

## KAPITTEL 5. EVALUERING




Figur 5.3: Plot av QoM for P100\_T03 med segmenteringslinjer. Segmentene korresponderer direkte med del B i figur 5.4.



Figur 5.4: Motiongram for P100\_T03 med inndelte segmenter. Under alle segmentene er det en fargekode og dersom denne er rød betyr det at segmentet er klassifisert til ikke å inneholde FM. Dersom segmentet er merket med grønt er det klassifisert med FM. Del A er den manuelle segmenteringen utført av L Adde. Del B og C er segmentering gjort av den egenkomponerte metoden med et vindu på henholdsvis 175 og 225. Del D er resultatet fra segmentering basert på LDA.

## KAPITTEL 5. EVALUERING



**Figur 5.5:** Del av motiongram for P093\_T03 med inndelte segmenter. Under alle segmentene er det en fargekode og dersom denne er rød betyr det at segmentet er klassifisert til ikke å inneholde FM. Dersom segmentet er merket med grønt er det klassifisert med FM. Del A er den manuelle segmenteringen utført av L Adde. Del B og C er segmentering gjort av den egenkomponerte metoden med et vindu på henholdsvis 175 og 225. Del D er resultatet fra segmentering basert på LDA.

Figur 5.4 og 5.5. viser tydelig hvordan segmentene er klassifisert og er nå den beste måten å visuelt sammenligne den manuelle og automastiske segmenteringen på. Resultatene til alle metodene vist i de to figurene må sies å være veldig bra sammenlignet med den manuelle, videobaserte fremgangsmåten. Del B og C representerer segmentene funnet av den egenkomponerte metoden med faste grenser for variablene og siden denne er laget med hensyn på den tidligere testingen er det naturlig at resultatene er gode. Metoden basert på LDA har ikke dette "fortrinnet", men viser gode resultater på tross av at settene som er blitt testet er totalt ukjente for klassifikatoren. Det er dette som er den naturlige måten å foreta segmenteringene på og at resultatene er så lovende allerede ved første gjennomføring er et godt tegn.

## KAPITTEL 5. EVALUERING



## 6 Diskusjon

De oppnådde resultatene sammen med eget og videre arbeid skal diskuteres og evalueres. En forklaring på hvorfor den automatiske segmenteringen ikke ble nøyaktig lik den manuelle samt tanker om arbeidet generelt og mulighetene videre er derfor presentert her.

### 6.1 Resultat

Måten å teste og verifisere metodene som er laget på er kun ved å sammenligne dem med de segmentene L Adde har bestemt inneholder FM etter å ha studert videoopptak. Det ble foretatt manuell analyse av totalt 8 videoer hvor 4 var fra friske barn og 4 fra syke. Ut i fra kommentarene til denne analysen som kan ses i *Appendiks A.3* er det ingen FM i videoene fra syke barn, men det kan forekomme bevegelser som ligner. Dette betyr at segmenteringsresultatene som tilsier at det er segmenter med FM i videoer fra syke barn ikke er totalt feil, selv om det må regnes som en feilklassifisering. Hadde man sett på hele opptaket under ett og klassifisert det ville det bli klassifisert riktig, men siden det her ses på mindre segmenter kan det alltid være bevegelser i deler av en sekvens som oppfører seg som FM selv om teorien tilsier at dette ikke er riktig. Dersom man ser på resultatene hvor feilklassifiseringer har oppstått ser man også at disse segmentene er forholdsvis korte og sporadiske uten noen form for kontinuasjon eller sammenheng. Dette er et tegn på at klassifikatoren har valgt feil og noe det vil være mulig å motvirke til en viss grad ved innføring av flere variable som kanskje opptrer på en litt annen måte enn de allerede benyttet.

Et annet diskusjonstema som gjelder de fleste sekvenser hvor FM er bekreftet, er den moderate formen for FM. Dette er FM med lavere intensitet enn den normale og kan være vanskeligere å skille fra unormal bevegelse. Dette gjenspeiles i noen av resultatene hvor den manuelle segmenteringen har plukket ut flere segmenter enn den automatiske, men da med moderat intensitet på FM. Dette kan også resultere i at den manuelle segmenteringen velger å klassifisere hele opptaket med moderat FM, mens de automatiske metodene finner mange segmenter hvor intensiteten er tilstrekkelig høy nok for å godtas som FM. Selv om det i figur 5.4 er markert at Adde kun har klassifisert ett segment med FM skriver han i sin analyse at det forekommer korte glimt av FM senere i opptaket. Segmenteringsmetoden basert på LDA lager et segment i tillegg til det fra den manuelle metoden av ett eller flere av disse glimtene og man kan i dette tilfellet ikke konkludere med at dette er feil.

## KAPITTEL 6. DISKUSJON

Med et større testgrunnlag hvor tydelige grenser for når FM forekommer etableres vil man sannsynligvis kunne finne måter å ta høyde for opptreden av moderate FM og avvikende bevegelse som ligner normal FM. Uansett så viser resultatene oppnådd her potensial til å kunne bli så nøyaktig slik at man kan kjøre programmet på et testsett for så å kunne gi spesialisten det nøyaktige segmentet i et opptak som burde studeres for å kunne bestemme at barnet har FM og derfor er friskt.

### 6.2 Eget arbeid

Arbeidet i sin helhet har vært veldig spennende og med mye nytt stoff å sette seg inn i har det også vært utfordrende samtidig som det har vært tilfredsstillende med tanke på nytten av det hele. Prosjektet startet med å fokusere på bruk av tilgjengelige motiongram for automatisk segmentering, men etter som tiden gikk og arbeidet utviklet seg ble det bestemt at det måtte lages metoder for å generere disse selv. Dette gjorde at arbeidet med bevegelsesbilder ble mer omfattende noe som til slutt resulterte i at segmenteringen basert på motiongram ble valgt bort til fordel for bruk av bevegelsesbildene. Man oppdager nye fremgangsmåter og bedre alternativ gjennom hele arbeidsprosessen og det avhenger kun av tiden hvor mange forandringer og forbedringer man kan implementere. Planen fra begynnelsen av var også å segmentere musikkrelaterte bevegelser basert på motiongram, men grunnet bytte av fokus og dårlig tilgjengelighet på gode motiongram ble musikkdelen av prosjektet ikke like fremtredende som først antatt. Likevel er alle metodene for å lage bevegelsesbilder og motiongram videreført fra tidligere arbeid ved studie av bevegelser relatert til musikk.

Hadde det vært lagt en hardere plan når det gjelder arbeidsmengde hadde det sannsynligvis vært bedre tid på slutten til å forbedre selve segmenteringen. Analysen av variabelverdiene som grunnlag for segmenteringsmetoden kunne fått en ekstra dimensjon og implementering av flere variable samt ekstra verifisering av resultat kunne vært gjennomført. På tross av dette utvikler et prosjekt seg ofte slik som det har gjort i dette tilfellet. Det har blitt jobbet jevnt og trutt og rapporten har vokst for hver uke bortsett fra perioder hvor programmering var hovedprioritet. Det vil alltid dukke opp forbedringspotensial og ting man burde tilføye og teste mot slutten uansett hvor hard man har jobbet. Arbeidet har vært givende og følelsen av mestring ved stadig oppnåelse av delmål har vært motiverende i seg selv, noe som forhåpentligvis gjenspeiles i denne rapporten.

### 6.3 Videre arbeid

Med tanke på direkte fortsettelse av dette arbeidet er det flere ting som kan gjøres. Måten bevegelsesbildene lages på tar per dags dato tar blant annet ikke spesielt hensyn til varierende lysforhold i et videoopptak. Det benyttes en form for justering av bildene, men virkningen av lysforhold på resultatene er ikke undersøkt. Kanskje en bedre type normalisering av frames før de konverteres til bevegelsesbilder kunne føre til en markant forskjell. Et annet punkt er å se på separabiliteten til de ulike variabelverdiene med og uten FM. Parsa Rahmanpour har i sin masteroppgave [21] ved NTNU sett på ulike egenskaper for prediksjon av CP. En del av dette omhandler nettopp separabilitet og muligheten for å finne ut hvor informative ulike egenskaper er. Selv om det dannes klynger hvor begge typer data (FM eller ikke) er representert kan det hende separasjonen mellom dem likevel er bedre enn for data som grafisk ser mer spredd ut. Generelt er mer testing med større datasett noe som burde gjøres og på denne måten vil man også etter hvert kunne finne andre metoder å basere segmenteringen på. Et alternativ er å bruke sentroideplottene til settene av bevegelsesbilder ved å finne skjevheten i disse dataene. Dette kan bidra til å bestemme om et opptak skal klassifiseres som normalt eller ikke siden formen på disse plottene tidligere har vist seg å være en pålitelig faktor. Et annet alternativ er å bruke metoder basert på parameterestimering på noen av variablene som allerede brukes da disse tross alt også er en type signaler. Estimerte parametre kan da benyttes i tillegg for å se om dette gir noen forbedring ved klassifisering og valg av segmenter. Flere typer klassifiseringsmetoder kunne også være interessant å implementere. Nærmeste-nabo metoder og varianter av algoritmer som ikke bare er lineære kunne vært et fornuftig skritt videre. Noe som senere også burde prøves er å teste segmenteringen på sett med data som ikke er klassifisert på noen som helst måte på forhånd. Kan da kjøre en segmentering på dette og deretter manuelt segmentere dataene for så å sammenligne. Så totalt sett burde det utføres grundigere testing og innføring av nye ekstra variable for å videreutvikle metodene som allerede nå viser seg å være svært lovende.

## KAPITTEL 6. DISKUSJON

## 7 Konklusjon

Det er i dette prosjektet utviklet og testet metoder for å lage bevegelsesbilder og motiongram basert på video samt metoder for segmentering og samtidig klassifisering av disse segmentene. Denne måten å segmentere bevegelsesdata på er aldri utført tidligere og viser et veldig potensial basert på de oppnådde resultatene. Utgangspunktet for prosjektet baserte seg på tidligere arbeid fra analyse av musikkrelatert bevegelse og klassifisering av spedbarnsbevegelser. Utviklingen av metoder for behandling av video og bilder i MATLAB er gjennomført og målene som ble satt for dette arbeidet er oppnådd. Det har tatt tid å sette seg inn i alle de nye analysemetodene og måtene å gå frem på, men samtidig har denne jobben gitt resultater. Selv om veien til målet og den avsluttende segmenteringen har vært lang kan det med trygghet sies å ha vært verdt det. Resultatene fra segmenteringsmetodene viser god evne til å skille mellom segmenter som inneholder FM eller ikke samtidig som bruk av flere variable sannsynligvis vil gjøre metodene enda sterkere på flere områder.

Sammenligningen av den automatiske segmenteringen med den manuelle har gitt grunnlag for utvelgelse av metoder som fungerer bra til formålet samtidig som det har klargjort i større grad hvilke utfordringer man står ovenfor ved videre arbeid. Metoden basert på LDA er til dette formålet godt egnet og ut i fra resultatene viser det seg at den har bedre forutsetninger for segmentering av bevegelse enn metodene tidligere brukt på sensorsignaler. Motiongram er for øyeblikket kun brukt til presentasjon av resultater og som visuell representasjon av bevegelse i form av bevegelseskurver, men det er utviklingen av disse sammen med bevegelsesbildene som har gjort gjennomføringen av den endelige segmenteringen mulig. Det virker i alle fall slik at dette er veien å gå og at denne formen for automatisk segmentering av bevegelsesdata er et reelt alternativ.

KAPITTEL 7. KONKLUSJON

# Bibliografi

- [1] Andreas Berg. Modellbasert klassifisering av spedbarns bevegelser. *Masteroppgave (diplom)*, 2008.
- [2] Harald Kirkerød. Motiongram classification for infant movement assessment. *Spesialiserings Prosjekt Medisinsk Kybernetikk*, 2009.
- [3] Paul M Baggenstoss. Time-series Segmentation. *IEEE Transactions on Signal Processing*, 49:2240-2252, 2001.
- [4] Valery Guralnik, Jaideep Srivastava. Event Detection from Time Series Data. *International Conference on Knowledge Discovery and Data Mining*. 1999.
- [5] Ulrich Appel, Achim V Brandt. Adaptive Sequential Segmentation. *Information Sciences*, 29:27-56, 1983.
- [6] Alexander R Jensenius. Action-Sound: Developing Methods and Tools to Study Music-Related Body Movement. *Doktoravhandling*, 2007.
- [7] Stian F Olsen. Metoder for Automatisk Segmentering av Bevegelser. *Spesialiserings Prosjekt Medisinsk Kybernetikk*, 2009.
- [8] Selene Mota, Rosalind W Picard. Automated Posture Analysis for Detecting Learner's Interest Level. *Conference on Computer Vision and Pattern Recognition Workshop*. 2003.
- [9] Stefano Pellegrini, Luca Iocchi. Human Posture Tracking and Classification through Stereo Vision and 3D Model Matching. *Journal on Image and Video Processing*. 2008
- [10] Kazuhiro Kamiya, Mineichi Kudo, Hidetoshi Nonaka, Jun Toyama. Sitting Posture Analysis by Pressure Sensors. *19th International Conference on Pattern Recognition*. 2008.
- [11] Lars Adde, Jorunn L Helbostad, Alexander R Jensenius, Gunnar Taraldsen, Ragnhild Støen. Using Computer-Based Video Analysis in the Study of Fidgety Movements. *Early Human Development*, 85:541–547, 2009.
- [12] Alexander R Jensenius. Using Motiongrams in the Study of Musical Gestures. *Using motiongrams in the study of musical gestures*. 499-502, 2006.

## BIBLIOGRAFI

- [13] P R Berge, L Adde, G Espinosa, Ø Stavadahl. ENIGMA - Enhanced interactive general movement assessment. *Expert Systems with Applications*, 34:2664-2672, 2008.
- [14] Lars Adde, Jorunn L Helbostad, Alexander R Jensenius, Gunnar Taraldsen, Kristine H Grunewaldt, Ragnhild Støen. Early Prediction of Cerebral Palsy by computer-based video analysis of general movements: a feasibility study. *Developmental Medicine & Child Neurology*. 2009.
- [15] Martha W Jones, Elaine Morgan, Jean E Shelton, Christine Thorogood. Cerebral Palsy: Introduction and Diagnosis (Part I). *Journal of Pediatric Health Care*, 21:146-152, 2007.
- [16] Lidija Dimitrijevic, Bosanka Jovic Jakubi. The importance of early diagnosis and early physical treatment of cerebral palsy. *Medicine and Biology*, 12:119-122, 2005.
- [17] Heinz F R Prechtl, Christa Einspieler, Giovanni Cioni, Arend F Bos, Fabrizio Ferrari, Dieter Sontheimer. An early marker for neurological deficits after perinatal brain lesions. *The Lancet*, 349:1361-1363, 1997.
- [18] Cornill H Blauw-Hospers, Mijna Hadders-Algra. A Systematic Review of the Effects of Early Intervention on Motor Development. *Developmental Medicine & Child Neurology*. 47:421-432, 2005.
- [19] Richard O Duda, Peter E Hart, David G Stork. *Pattern Classification, 2<sup>nd</sup> Edition*, 2000.
- [20] Fredrik Gustafsson. *Adaptive Filtering and Change Detection*, Wiley, 2001.
- [21] Parsa Rahmanpour. Features for Movement based Prediction of Cerebral Palsy. Masteropgave (*diplom*), 2009.



# Appendiks

## A.1 Sensitivitet og spesifisitet

Sensitivitet er et mål på hvor bra en binær klassifiseringstest identifiserer tilstanden som det testes for. Sensitivitet er definert som sannsynligheten for at en test gir positivt utslag, gitt at tilstanden faktisk er positiv. En positiv tilstand vil si at testpersonen har tilstanden det testes for og for arbeidet presentert i denne rapporten gjelder dette tilfellet cerebral parese. Spesifisitet er et mål på hvor bra en binær klassifiseringstest identifiserer en negativ tilstand. Spesifisiteten er definert som sannsynligheten for at en test gir negativt utslag, gitt at tilstanden faktisk er negativ.

Ved klassifisering kan 4 situasjoner oppstå:

1. True Positive (TP): Tilstanden er positiv og testen er positiv
2. False Negative (FN): Tilstanden er positiv og testen er negativ
3. False Positive (FP): Tilstanden er negativ og testen er positiv
4. True Negative (TN): Tilstanden er negativ og testen er negativ

Sensitivitet og spesifisitet til en test kan uttrykkes matematisk som:

$$\text{Sensitivitet} = \frac{TP}{TP + FN}$$

$$\text{Spesifisitet} = \frac{TN}{TN + FP}$$

## A.2 Sensordata i MATLAB

ROI'er i kategorien normal og unormal ligger lagret i henholdsvis normal.mat og abnormal.mat. Disse dataene kommer i utgangspunktet fra et større datasett som igjen er resultatet av konvertert "rådata" fra sensorene (henter ut binærdata fra \*.dat filer som omgjøres til matriser i MATLAB format).

normal.mat og abnormal.mat er *strukter* (en type data som kan inneholde et sett andre datatyper) og ved å skrive "abnormal" i MATLAB får man resultatet:

```
abnormal =
```

```
1x48 struct array with fields:
```

```
tab  
id  
cnt  
ROI_number
```

Dette viser at strukten for unormale barn inneholder 48 ROI'er. Det foreligger altså en tabell med 48 strukter hvor hver inneholder bevegelsesdataene x, y, z og kvaternion samt:

- id'en på barnet som ROI'en kommer fra.
- hvilket opptak ROI'en er hentet fra.
- ROI nummer som inkrementerer for hver ROI innefor en gitt id innenfor et gitt opptak.

Måten å hente ut hele datasettet for den første ROI'en med data fra sensor nummer 6 (uten kvaternion) gjøres med følgende uttrykk:

```
abnormal(1).tab(:,1:3,6)
```

### A.3 Videoanalyse av L Adde

Lars Adde ved St. Olavs Hospital i Trondheim ble forespurt om han kunne foreta en videoanalyse av et sett med filmer for både syke og friske spedbarn. Formålet med dette var å identifisere segmenter hvor FM var tilstede, eventuelt noe som lignet FM, for å kunne bruke dette i arbeidet med segmenteringen basert på bevegelsesbilder for de samme filmene. Siden kameraet brukt til innspillingen av videoene tar 25 bilder i sekundet (25 fps) er det enkelt å overføre minutter og sekunder til deres respektive bevegelsesbilder og kolonner i motiongram.

#### Friske:

P001\_T03

Barnet har *svært moderat intensitet*, men kontinuerlig tilstedeværende FMs på hele opptaket. 00:00-00:40 helt fraværende FMs. Resten av opptaket moderat tilstedeværende.

P038\_T02

00:01-00:09 FMs

00:50-01:16 moderat intensitet FMs

01:36-01:42 moderat intensitet FMs

02:15- ut opptaket moderat intensitet FMs

P093\_T03

00:00-00:07 moderat FMs, mest i beina

00:12-00:55 moderat intensitet FMs, mest beina

01:03-01:44 FMs

02:40-03:13 FMs

03:21-03:55 FMs

P100\_T03

00:03-00:30 FMs

Korte glimt med FMs etter dette også, men svært korte øyeblikk.

## APPENDIKS

### **Syke:**

P040\_T03

*Ingen FMs*

P054\_T01

*Ingen FMs*

P096\_T03

01:15-02:00 Korte glimt periodevis som kan likne på FMs, men er det ikke

02:08-02:25 Korte glimt periodevis som kan likne på FMs, men er det ikke

P101\_T01

Ganske mye bevegelse generelt, men *ingen FMs*

## A.4 MST Manual

Her presenteres en del av de vanligste oppgavene det er naturlig å utføre ved hjelp av dette prosjektets toolbox.

### Komme i gang:

For å få en oversikt over de kjørbare programmene samt funksjonene som er benyttet er det en god idé å benytte kommandoen "help mstoolbox" for å vise innholdet i Contents.m. Dette resulterer i listen under og danner et naturlig utgangspunkt for bruk av toolbox'en.

>> help mstoolbox

Motion Segmentation Toolbox (2010).  
Laget av Stian Fuglesang Olsen.

----Generering av bevegelsesbilder og motiongram----

framesIn	- Her leses bilder (frames) fra ønsket mappe inn i Matlab.
videoIn	- Her kan video leses inn i Matlab.
motiongram	- Generere motiongram.
mImage	- Generere bevegelsesbilder (eng: motion image).
mediaOut	- Lagre bevegelsesbilder eller motiongram til disk.

----Behandling av bevegelsesbilder----

mImageIn	- Her leses bevegelsesbilder fra mappe (eng: motion image) inn i Matlab.
centroid_mImage	- Beregne sentroiden til bevegelsesbilder.
mImage_variables	- Kalkulere standardavvik til sentroidene og QoM for bevegelsesbilder.
segm_mImage	- Her klassifiseres segmenter til å inneholde FM eller ikke.
viewResultSegm	- Visualisere segmenter ved markering på plot av QoM eller motiongram.
lagTestsett	- Lage testsett.
lagTreningssett	- Her kan det lages treningssett med og uten FM.
LDA	- Klassifisere segmenter via LDA.
segm_LDA	- Viser hva segmentene fra LDA-klassifiseringen representerer.
viewResultLDA	- Her kan segmentene fra segmenteringen basert på LDA visualiseres.

----Behandling av motiongram----

motiongramIn	- Lese inn bilde (motiongram) som skal brukes i analyse.
QoM_motiongram	- Regne ut bevegelsesmengden (QoM) til motiongram.
Qmean_motiongram	- Lager en "glattet" versjon av QoM (gjennomsnitt).
centroid_motiongram	- Beregne sentroiden til motiongram.

## APPENDIKS

- stdQoM\_motiongram - Finner standardavviket til deler av QoM for motiongram.
- r\_param\_est\_motionvar - Estimere parametre for variable hentet ut av motiongram.

### ----Behandling av sensordata----

- rekursiv\_param\_est - Her kan man rekursivt estimere modellparametre
- auto\_segment - Automatisk segmentering av signal fra estimerte parametre.
- funk\_seg - SEGMENT funksjonen benyttes her som et alternativ til RARX.
- reprod - I denne filen kan et forhånds definert resultat enkelt reproduseres.

### ----Hjelpfunksjoner----

- centroid - Funksjon som regner ut sentroiden til et bilde.
- areashade - Funksjon som farger området mellom en kurve og en spesifisert verdi.
- intersections - Funksjon som beregner posisjonen hvor to kurver overlapper.
- hline - Funksjon som lager en horisontal linje for en spesifisert verdi.
- vline - Funksjon som lager en vertikal linje for en spesifisert verdi.
- sec2ms - Konverterer sekunder til en minutt-sekund string.
- segmentplot - Plotter aktuelt signal med segmenteringslinjer.

### ----Diverse----

- figurSensordata - Plot av sensorsignaler for normale og unormale tilfeller.
- Plot - Diverse plot.
- analyse - Diverse forhåndsanalyse av aktuell data. Sjekker for "randomness".

### ----SLUTT PÅ FIL----

## **Bevegelsesbilder:**

Avhengig av om man skal lage bevegelsesbilder fra video eller bilder benytter man enten videoIn.m eller framesIn.m. Når riktig video eller mappe med bilder er valgt vil man uavhengig av hvilken metode man kjører få variabelen "frames" som inneholder alle stillbildene. For å lage bevegelsesbilder av bildene i "frames" brukes mImage.m som tar inn denne variabelen og produserer variabelen "mImages" som nå inneholder alle bevegelsesbildene. Disse kan nå behandles videre med centroid\_mImage.m eller mImage\_variables.m som henholdsvis finner sentroider og variabelverdier for bevegelsesbildene. Dersom man bare vil lagre bevegelsesbildene på disk til bruk senere kan man benytte mediaOut.m som legger bildene i en brukerspesifisert mappe.

## APPENDIKS

### **Motiongram:**

Motiongram lages ved å redusere og sette sammen bevegelsesbilder slik at man må igjennom hele prosedyren for å lage bevegelsesbilder først dersom man ikke har dem tilgjengelige. Er bevegelsesbildene klare til bruk benyttes `mImageIn.m` for å laste inn bildene i variabelen "mImages". Deretter er det `motiongram.m` som genererer både horisontale og vertikale motiongram som enten kan lagres som bilder via `mediOut.m` eller analyseres videre ved hjelp av forskjellige motiongram relaterte programmer.

### **Segmentering basert på bevegelsesbilder:**

For å foreta en segmentering må man ha lastet inn bevegelsesbildene for så å finne sentroidene til disse. Deretter har man to segmenteringsmetoder å velge mellom via filene `segm_mImage.m` og `segm_LDA.m`. Den første av disse kan brukes direkte og produserer en liste med FM segmenter og en liste uten. Segmentene med FM og de relaterte tidspunktene i den tilhørende videoen vises samtidig på skjermen og ved bruk av `viewResultSegm.m` kan man få markert disse segmentene på plot av QoM og i motiongram (det aktuelle motiongramet må da være lastet inn). Segmentering basert på LDA krever at `lagTestsett.m` og `lagTreningssett.m` brukes for å generere de nødvendige test- og treningssettene før LDA.m lager variabelen "Klasse" som inneholder selve klassifiseringen av testsettet. Når dette er gjort kan `segm_LDA.m` kjøres for å konvertere "Klasse" til "Segments" som inneholder segmentene med FM og som kan presenteres på samme måte og form som for den første metoden.