

# Ihmisliikkeen fysiologinen analysointi

Antti-Jussi Juppo

Pro gradu -tutkielma



ITÄ-SUOMEN YLIOPISTO

Tietojenkäsittelytieteen laitos

Tietojenkäsittelytiede

Marraskuu 2019

ITÄ-SUOMEN YLIOPISTO, Luonnontieteiden ja metsätieteiden tiedekunta,  
Joensuu  
Tietojenkäsittelytieteen laitos  
Tietojenkäsittelytiede

Opiskelija, Antti-Jussi Juppo: Ihmisliikkeen fysiologinen analysointi  
Pro gradu -tutkielma, 50 s.  
Pro gradu -tutkielman ohjaajat: FT Pasi Fränti ja FT Markku Tukiainen  
Marraskuu 2019

Tiivistelmä: Tutkielmani on ihmisliikkeen fysiologisesta analysoinnista tehty kirjallisuuskatsaus, jonka ulkopuolelle jätin tunteiden ja aistien tutkimiseen liittyvät analysoinnit. Esittelen erilaisten fysiologisten data-arvojen keräykseen kehitettyjä menetelmiä ja laitteita, muutaman kerätyn datan käsittelytavan sekä joitakin käytännön esimerkkejä liikkeenkaappausdatan keräämisestä ja analysoinnista. Esittämiäni fysiologisten data-arvojen keräysinstrumentteja ovat verenpaine, pulssi, sydänkäyrä, aivosähkökäyrä, lihassähkökäyrä, ihmiskehon kattava verkosto sekä markkeriton ja markkerillinen liikkeenkaappaus. Fysiologisen liikedatan käsittelytekniikoista esittelen segmentoinnin, Labanin liikeanalyysin, neuroverkot ja 2D-kuvaamisen. Valitsemiani ihmisliikkeiden fysiologisen tutkinnan käytäntöön sovellettuja esimerkkejä ovat eräs aivohalvauksen kuntoutukseen kehitetty menetelmä, eräs liikkeen Laban-työarvojen tunnistusmenetelmä, datakäsineellä tuotettavan kehon liikeanimaatioiden kehitysmenetelmä ja älypuhelimille suunniteltu silmänliikkeiden mittausprototyyppi. Yhteenvedossa tuon esille näkemyksiäni fysiologisen liikkeentutkinnan haasteista ja tulevaisuuden mahdollisuuksista.

Avainsanat: kirjallisuuskatsaus, fysiologinen analysointi, fysiologinen data, liikkeenkaappaus, aivosähkökäyrä, Labanin liikeanalyysi, datakäsine, optinen virtaus

ACM-luokat (ACM Computing Classification System, 1998 version): H.1.2, I.2.1, I.2.6, I.2.10, J.3

UNIVERSITY OF EASTERN FINLAND, Faculty of Science and Forestry, Joensuu  
School of Computing  
Computer Science

Student, Antti-Jussi Juppo: Physiological analysis of human movement

Master's Thesis, 50 p.

Supervisors of the Master's Thesis: PhD Pasi Fränti and PhD Markku Tukiainen

November 2019

**Abstract:** My thesis is a literature review of physiological analysis of human movement. I have omitted the analysis into emotion detection and senses. I present various different methods and devices designed for gathering physiological data, a few processing methods for the gathered data, and a couple of practical examples of capturing and processing movement data. The instruments of physiological data collection that I present include blood pressure, pulse, electrocardiogram, electroencephalography, electromyography, body area network as well as markerless and marker-based motion capture. The physiological data processing methods that I present include segmentation, Laban movement analysis, artificial neural networks and 2D recording. The examples of practical physiological movement analysis applications that I present include a treatment method for apoplexy, a recognition method for Laban movement values, development of body movement animations using a data glove, and an eye movement measurement prototype designed for smartphones. In the summary I bring forth my opinions about challenges and future prospects of physiological movement analysis.

**Keywords:** literature review, physiological analysis, physiological data, motion capture, electroencephalography, Laban movement analysis, data glove, optical flow

**CR Categories (ACM Computing Classification System, 1998 version):** H.1.2, I.2.1, I.2.6, I.2.10, J.3

## **Esipuhe**

Haluan kiittää Itä-Suomen yliopiston opettajia, joiden opastuksella minulla oli mahdollisuus oppia uusia asioita kaikkina opiskeluvuosinani.

Esitän kiitokseni myös ohjaajilleni professori Pasi Fräntille ja professori Markku Tukiaiselle, jotka hyväksyivät aihe-ehdotukseni ja antoivat arvokasta palautetta tutkielmani kirjoittamisen aikana.

Lopuksi kiitän omaisiani, jotka jaksoivat tukea opiskeluani kaikkien yliopistossa viettämieni vuosien aikana.

## Lyhenneluettelo

BAN	body area network; ihmiskehon kattava verkosto
CNN	convolution neural network; konvoluutioverkko
CSP	common special pattern; matemaattinen toimenpide signaalieriävyyksien havaitsemiseen
DBN	deep belief network; syväuskoverkko
DNN	deep neural network; syvä neuroverkko
DOF	degree of freedom; vapausaste
EEG	elektroenkefalografia; aivosähkökäyrä
EKG	elektrokardiografia; sydänsähkökäyrä
EMG	elektromyografia; lihassähkökäyrä
FNN	feedforward neural network; myötäkytkentäverkko
LMA	Laban movement analysis; Labanin liikeanalyysi
MI	motor imagery; liikekuvittelu
RGB-D	red-green-blue-depth; puna-vihreä-sini -värimalli ja syvyysanturi
RNN	recurrent neural network; toistuva neuroverkko
ToF	time-of-flight; 3D-kuvaa kuvaava kamerajärjestelmä
USB	universal serial bus; tietokoneen oheislaitteiden liitosväylä

# Sisällysluettelo

1	Johdanto .....	1
2	Fysiologisen liikedatan keräysmenetelmät .....	3
2.1	Verenpaine .....	3
2.2	Pulssi .....	4
2.3	EKG .....	5
2.4	EEG .....	6
2.5	EMG .....	7
2.6	BAN .....	9
2.7	Markkeriton liikkeenkaappaus .....	10
2.7.1	Ilmeiden ja katseen kaappaus .....	11
2.7.2	Käsiliikkeiden kaappaus .....	13
2.7.3	Koko kehon kaappaus .....	15
2.8	Markkerillinen liikkeenkaappaus .....	16
3	Kaapatun liikedatan analysointi .....	21
3.1	Segmentointi .....	21
3.2	LMA .....	23
3.3	Neuroverkot .....	26
3.4	2D-kuvaus .....	31
4	Tapaustutkimuksia .....	32
4.1	EEG ja kädenliikkeet kuntoutuksessa .....	32
4.2	Multimodaalisen liikkeen ja LMA-työarvojen tunnistus .....	34
4.3	Koko kehon animaatioiden tuotto datakäsineellä .....	36
4.4	Silmänliikkeen suunnan määrittäminen .....	37
5	Yhteenveto .....	39
	Viitteet .....	41

# 1 Johdanto

*Ihmisliike* on jokin toiminta, ele tai suoritus, joka muodostuu kehon fysiologisista eli ruumiillisista ja psykologisista järjestelmistä. Luustolihakset muodostavat suurimman osan elimistön lihaksista, joiden tehtävä on liikkeen tai liikesarjan tuottaminen, kuten kävely, juoksu, hyppy, pallon heitto, voimistelu ja tanssi. Lihaksen perustoiminto on aivoista lähtevän hermoimpulssin seurauksena tapahtuva supistuminen. Jos tuki- tai liikuntaelin vaurioituu, mekaaninen vuorovaikutus muuttuu ja heikentää liikettä. Tätä tutkii *kinesiologiaksi* kutsuttu tutkimusala, jossa tarkkaillaan fyysisen aktiivisuuden vaikutuksia ihmiskehon liikkeisiin eri tieteenalojen näkökulmasta.

*Ihmisliikkeen fysiologisella analysoinnilla* tarkoitetaan ihmisen kehon elinten toiminnan tutkimista erilaisten mittausten avulla liikkeen aikana. Siinä tarkkaillaan esimerkiksi sydämen sykettä, sydänkäyrää, verenpainetta, hengitystahtia, sekä lihasten ja aivojen toimintaa. Esimerkiksi lihaskuntoaan liikunnalla kohottava henkilö seuraa sydämensä sykettä, sillä se antaa nopean kuvan sydämen koon ja pumppaustehon lisääntymisestä liikkeen aikana. Toisena esimerkkinä on *3D-liikeanalyysin* käyttö nivelten kuormitusten ja nivelrikon etenemisen seurannassa (Kulmala ym., 2014).

*Liiketutkimukset* koostuvat liikkeenseuranta- ja kaappausjärjestelmistä, lihasten ja aivojen elektrofysiologiasta, fysiologisen toiminnan seurantamenetelmistä ja käyttäytymisen ja kognitiivisten tutkimusten tekniikoista. Liikeanalyysin avulla ymmärretään kunkin liikkeen osatekijän biomekaniikka ja kuormitus, mikä puolestaan hyödyttää sairauksien *etiologian* eli syy-seuraus -suhteen tutkimista, hoitopäätösten tekemistä, hoidon vaikutusten arviointia ja lisäksi myös erilaisten toimintojen ja käyttäytymisen tunnistamista.

Omid Alemin ja hänen tovereidensa (2014) mukaan *ihmisliikkeen visualisoinnista* tehdyt tuotokset voidaan jakaa niiden sovellusten mukaan taiteellisiin visualisointeihin, liikeyhteenvetoihin ja liikettä tutkiviin analyysieihin. Taiteelliset visualisoinnit kartoittavat liikettä esityskelpoisiksi visualisointeiksi esimerkiksi viihdeteollisuutta varten, ja ne on yleensä suunnattu tavallisille kuluttajille tutkijoiden ja liikeanalytiikoiden sijaan. Liikeyhteenvetovisualisoinneilla tuotetaan tiivistelmä tai vertaillaan liikevideoleikkeiden sisältöjä yleensä kaksiulotteisessa muodossa.

Liikkeen tutkiva analysointi on liikkeiden systemaattista ja huolellista tarkkailua, jota täydennetään kehon liikkeiden, mekaniikan ja lihasten toiminnan mittausvälineillä. Sen tavoitteena on kerätä kvantitatiivista tietoa tuki- ja liikuntaelinten mekaniikasta motorisen tehtävän suorittamisen aikana. Tietoa kerätään esimerkiksi raajojen liikkeiden laadusta, kasvonilmeiden muutoksista, kehon lämpötilan ja hengityksen vaihteiluista ja silmän liikkeistä. Näiden lisäksi fysiologista analysointia voidaan hyödyntää käyttöliittymien kehittämisessä sekä lääketieteellisessä kuntoutustyössä liikeratojen korjauksissa. Ihmisliikkeitä käytetään myös erilaisten toimintojen ja käyttäytymisen tunnistamisessa sekä joidenkin kroonisten sairauksien ja geneettisten häiriöoireyhtymien merkkien havaitsemisessa.

Tutkielmani on kirjallisuuskatsaus ihmisliikkeiden fysiologisesta analysoinnista yleisesti. Käsittelen luustolihashasten, silmien sekä kasvolihasten liikkeitä, mutta jätän pois tunteisiin ja aistihavaintoihin liittyvät liikkeet niiden analysoinnissa esiin tulevien riskitietoisuuksien sekä saatavilla olevan aineiston puutteen vuoksi. Tässä kirjallisuuskatsauksessa etsin seuraavia tietoja:

- minkälaisilla menetelmillä ihmisliikkeen fysiologista dataa voidaan kaapata (luku 2)
- millä tekniikoilla saatuja tuloksia voidaan analysoida (luku 3)
- miten tutkimusmenetelmiä on käytetty eri aloilla (luku 4)

Yhteenvedossa kertaan tutkielmani koostumuksen. Lisäksi tuon esille datan keräysmenetelmiä ja analysointitekniikoita kehittäneiden sekä liikkeitä tutkineiden ehdottamia sovellusideoita. Lopuksi pohdin tutkimusmenetelmien haasteita ja ajatuksia niiden tulevaisuudesta.



## 2 Fysiologisen liikedatan keräysmenetelmät

Fysiologisen liikedatan keräämiseen käytetään pääosin elektroniikkaan perustuvia laitteita. Fysiologisten signaalien tiedonlähdetyyppeihin kuuluvat muun muassa verenpaine, pulssi, *elektrokardiografia* (EKG), *elektroenkefalografia* (EEG) ja *elektromyografia* (EMG), joita lääketieteen asiantuntijat käyttävät yleisinä terveydentilan tiedonlähteinä. Muita datankeräystyyppejä ovat aiemmin mainittuja signaaleja yhtä aikaa keräävä *ihmiskehon kattava verkosto* (engl. body area network, BAN) sekä liikettä nauhoittavat menetelmät, kuten *markkeriton* ja *markkerillinen liikkeenkaappaus*.

### 2.1 Verenpaine

Tyypillinen liikkuvan ihmiskehon fysiologinen mitattava arvo on verenpaine. Liikkuminen lisää valtimoon syntyvää painetta sydänlihaksen supistuessa ja pumpatessa verta valtimoihin. Verenpaine on korkeimmillaan supistumisvaiheessa vasemman kammion pumpatessa verta suuriin valtimoihin ja alimmillaan lepotilassa ennen seuraavaa supistusta. Verenpainetta säätelevät useat elimistön tekijät ja vaihtelu on normaalia samankin vuorokauden aikana. Sairaanhoidossa verenpainetta on mitattu ylisadan vuoden ajan. Kliinisen elohopeaverenpainemittarin keksijä oli italialainen professori Scipione Riva Rocci (1863–1937). Hänen nimestään juontuu verenpainelukeman lyhenne: RR 120/80.

Liikkeen aikaista verenpainetta mitataan manuaalisesti ihmisen olkavarteen kiinnitettyllä painemansetilla seuraamalla samanaikaisesti valtimon sykettä kyynärtaipeesta akustista signaalia lähettävällä stetoskoopilla (Kuva 1). Digitaaliset mittarit ovat yleistyneet niiden käytön helppouden vuoksi. Sydämen ja keuhkojen tuottamien äänien diagnostiikassa käytetyn akustisen stetoskoopin (Kuva 2) keksi ranskalainen lääkäri René Laënnec vuonna 1816. Stetoskoopin rintaosassa on kaksi kuuntelun mahdollistavaa osaa: kalvo-osa ja suppilo-osa. Tutkittavan henkilön iho aiheuttaa kalvo-osaan värähtelyn, jolloin suppilon sisäpuolella oleva ilma alkaa värähdellä. Värähtely johdetaan letkua pitkin korvakappaleisiin. Akustisen stetoskoopin haittapuolena on esimerkiksi sydämen sivuäänien vaikea havaitseminen. Tutkijat ovat kehitelleet elektronisia,

sähköisesti ääntä vahvistavia stetoskooppeja, joissa on äänen tallennus- ja toistomahdollisuus (Hänninen, 2018).



**Kuva 1.** Vasemmalla manuaalinen verenpaineen mittaus (Weber, 2019) ja oikealla automaattinen Omron M3 -verenpainemittari (Harvard Health Publishing, 2019).



**Kuva 2.** Lääkärien käyttämä stetoskooppi (Medkit, 2019).

## 2.2 Pulssi

Sydämen syke eli pulssi on sydämen lyöntinopeus minuutissa. Aerobinen liikunta vahvistaa kammiolihaksia, mikä johtaa sydämen iskutilavuuden lisääntymiseen ja alhaiseen leposykkeeseen. Pulssin arvo on verenpaineen tavoin jatkuvasti muuttuva. Uusimpien tutkimustulosten mukaan sydämen sykerytmi vaikuttaa yksinkertaisen motorisen reaktion oppimiseen. Lääke- ja liikuntatieteessä syke saadaan suoraan EKG-käyrästä. Varsinaisen sykemittarin on keksinyt ja patentoinut suomalainen professori Seppo Säynjäkangas (1942–2018). Aktiivisesti liikuntaa harrastavat käyttävät sykemittareita harjoitustensa tehon säätämiseen ja fyysisen rasituksen seurantaan.

Tavanomainen lepopulssi on 50–110 lyöntiä minuutissa. Pulssia kiihdyttävät muun muassa liikuntasuoritukset, jännitys ja lääkeaineet. Ranteeseen tai rintakehän ympärille (Kuva 3) kiinnitettävät kaupalliset laitteet mittaavat sykeaaltoa optisesti valon avulla (Polar, 2019). Yksinkertaisin pulssin mittaus suoritetaan painamalla sormella rannetta.



Kuva 3. Vasemmalla Suunto Spartan Sport Wrist HR Blue rannesyke mittari (Keskisenkello, 2019) ja oikealla Garmin Premium HRM-Run -sykevyö (Fitshop, 2019).

### 2.3 EKG

EKG on yleinen menetelmä tutkittaessa fyysisiä aktiviteetteja sekä erilaisia stressitilanteita. Sillä mitataan ja tallennetaan sydämen sähköistä toimintaa. Kyseessä olevan rekisteröinnin aloitti Brittiläinen fysiologi Augustus Waller (1856–1922) ja alankomaalainen lääketieteilijä Willem Einthoven sai Nobelin palkinnon kehittämästään ensimmäisestä toimivasta laitteesta 1924. Sydämen supistumista säätelevät heikot sähköimpulssit, jotka alkavat sydämen eteisen seinämän solmukkeesta ja leviävät sydämen eteisiin ja sitten kammioihin. Eteisten ja kammioiden peräkkäinen aktivoituminen aiheuttaa sähkömagneettisen kentän, jonka muuttumista tutkimuksessa mitataan eri puolille kehoa kiinnitetyillä *elektrodeilla* (Kuva 4). Elektrodit piirtävät EKG-käyrää paperille tai tietokoneen näytölle asiantuntijan tulkittavaksi.

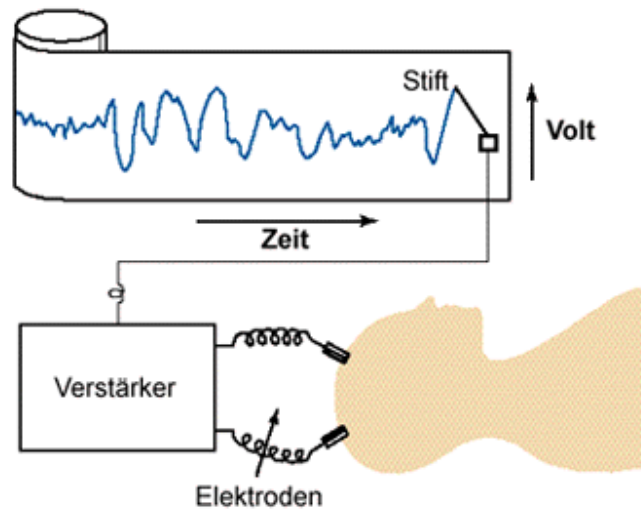


**Kuva 4. Vasemmalla elektrodien kiinnitys EKG-rekisteröinnissä (Nevid, 2019) ja oikealla EKG-käyriä (BioRadio, 2019).**

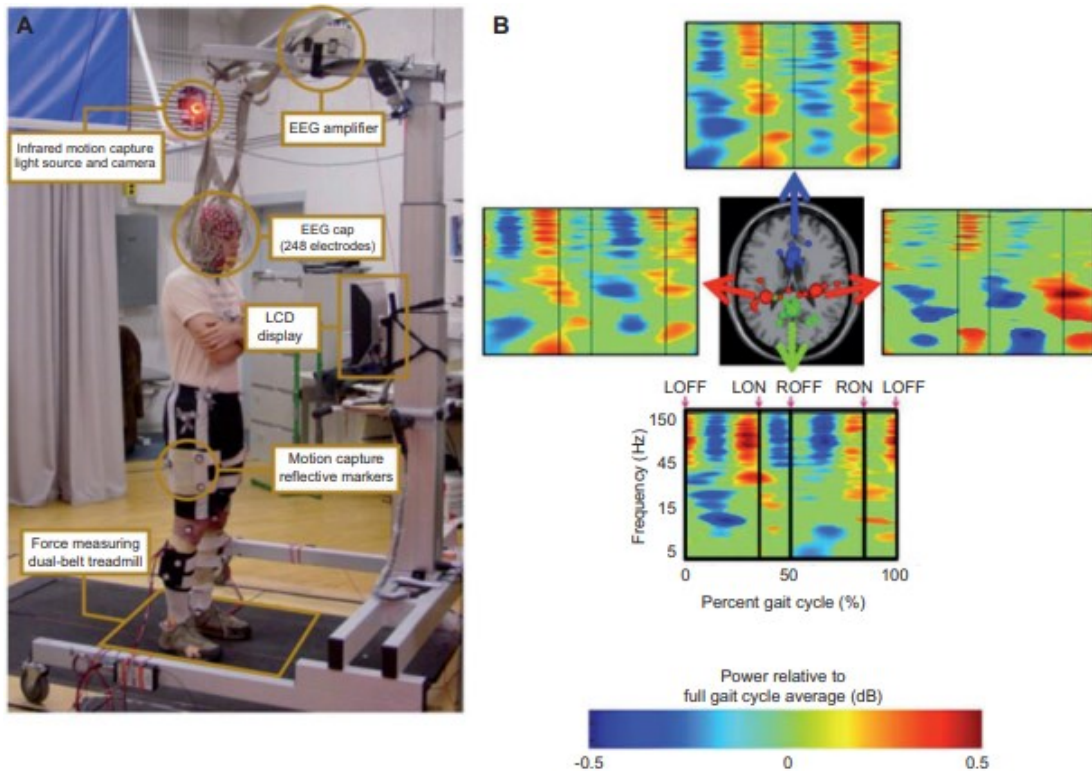
## 2.4 EEG

Aivojen sähköistä toimintaa kuvataan EEG:lla. Saksalainen psykiatri Hans Berger (1873–1941) rekisteröi ensimmäiset ihmisaivojen aktiivisuudet englantilaisen Richard Catonin eläimillä suorittaman pioneerityön jälkeen. Hän erotteli erilaiset aivoaallot sekä nimesi ne *alfa-* ja *beta-aalloiksi*. Alfa-aallot ovat vallitsevia ihmisen ollessa levossa silmät kiinni, kun taas beta-aallot ovat tyypillisiä liikuntasuorituksen aikana.

EEG-tutkimuksessa päänahkaan kiinnitetään määrättyihin aivoalueiden kohtiin elektrodereja, joilla mitataan aivojen pintakerrosten *hermosolujen* eli *neuronien* tuottamia signaaleja. Vahvistetut signaalit rekisteröidään joko paperille tai nykyisin yleisemmin tietokoneelle (Kuva 5). EEG:n käyttö on ollut runsasta terveydenhuollossa monien aivoperäisten sairauksien tunnistamisessa. Lisäksi se on tutkittavalle kivuton. Sen käyttö on kuitenkin vähentynyt uusien kuvantamismenetelmien, erityisesti magneettikuvauksen kehittymisen myötä. EEG on tutkimuskäytössä muun muassa ihmisen vireystilan, tunteiden, stressin ja aivojen aktiivisen toiminnan rekisteröimisessä. Viime vuosina on alettu kehittää uutta tekniikkaa sekä kannettavia rekisteröintilaitteita erityisesti urheiluliikunnan käyttöön (Kuva 6).



Kuva 5. EEG-rekisteröinnin mittaustapahtuma (Mayer, 2019).



Kuva 6. Vasemmalla esimerkki EEG-koejärjestelystä, jossa käytetään juoksumattoa, ja oikealla kävelyn aikana kuvattuja aivotoiminnan muutoksia eri puolilta aivoja (Gramann ym., 2011).


## 2.5 EMG

Ihmisen käsky liikuttaa lihaksia alkaa aivoista, mikä tapahtuu hermostossa sähköisten signaalien välityksellä. Signaali kulkee aivoista selkäytimen kautta ääreishermostoon, mikä aiheuttaa lihasyksiköiden aktivoitumisen liikkeeksi. (Merletti ja Parker, 2004).

EMG:llä kerätään tietoa mainituista lihasten liikkeiden ja hermojen viestinnän välisistä sähkösignaaleista. Lihaksen pintaan kiinnitetty tai sen sisään insertoitu neulaelektrodi (Kuva 7) mittaa sähköisesti tai neurologisesti aktivoitujen lihassolujen sähköpotentiaalin. Elektrodeihin kytketty laite tulkitsee ja muuntaa sähkösignaalit analysoitavaksi dataksi eli *elektromyogrammiksi* tietokoneen ruudulle (Kuva 8). EMG-signaaleja voidaan käyttää liikkeiden analysointiin vasta, kun ne ovat oppineet yksilön fysiologisten ominaisuuksien lihaskuvion. Liikettä analysoitaessa EMG-data esikäsitellään esimerkiksi Matlab-ohjelmistolla.




**Kuva 7. Vasemmalla neulaelektrodi ja oikealla pintaelektrodi (Kaskivirta, 2010).**



**Kuva 8. 2-kanavainen EMG-laite (Indiamart, 2019).**

Lihassähkökäyräsignaalit tapahtuvat ennen varsinaista toimintaa (Falla ym., 2004; Lacquaniti ja Maioli, 1989). Datan analysointi vaatii pienten, mutta merkityksellisten muutosten havaitsemista (Kuva 9). EMG-signaaleista tehdyillä yksilöidyllä tekijäana-

lyyßeillä kerätään tietoa myös kahdesta piiloteekijästä, aktiivisuustasosta ja väsymyksestä (Pradhan ym., 2010). Lihäsjärjestelmien avulla on simuloitu lihasaktiiviteetin ja liikekäyttäytymisen *dynaamisten ja/tai kinemaattisten* ominaisuuksien, kuten nopeuden, kiihtyvyyden ja kaarevuuden välisiä suhteita (Mesin ym., 2006; Wang ja Buchanan, 2002). Liikuntalääketieteessä ja terveysteknologian lihasharjoituksissa EMG:llä tutkitaan, mitkä liikkeet saavat aikaan parhaan lihasaktiivoinnin sekä kartoitetaan mahdollisia hermo- ja lihasvaurioita.



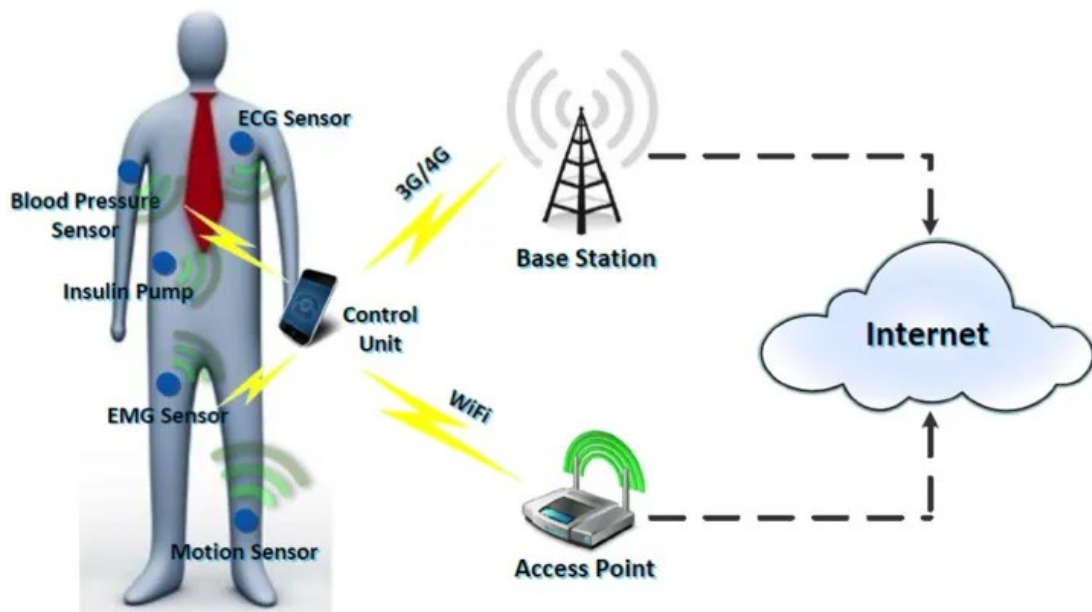
**Kuva 9.** EMG-laite kerää signaaleja lihaksesta ja muuntaa ne graafiseksi esitykseksi (Ever, 2018).

Ensimmäiset dokumentoidut kokeet koskien EMG:tä aloitti italialainen Francesco Redi vuonna 1666 löytäessään sähköankeriaasta sähköä tuottavan lihaksen. Itseaiheutetun lihassupistumisen tallensi ensimmäisenä ranskalainen tiedemies Étienne-Jules Marey vuonna 1890. Menetelmän käyttö lisääntyi merkittävästi vasta 1980-luvulla, kun neulaelektrodien tuotanto saatiin riittävän suureksi ja laitteiden koko tarpeeksi pieneksi.

## 2.6 BAN

BAN on kehokeskeinen järjestelmä, joka koostuu sarjasta kehoon kiinnitettyjä yksiköllisiä *antureita*. BAN:issa anturit keräävät jatkuvasti *multimodaalista* dataa ihmisen liikkumiskyvystä ja fysiologiasta, kuten verenpaineesta, EKG:sta ja EMG:sta, jakavat dataa toistensa kanssa ja lähettävät sen *langattoman lähiverkon* (engl. wireless local area network) tai Internetin kautta etäpalvelukeskukseen ammattilaisten analysoitavaksi (Kuva 10). BAN:in ansiosta henkilön sijainti ei tuota ongelmia, minkä vuoksi se on potentiaalisesti arvokas työkalu terveydenhuoltopalveluille. Puettavassa

anturiteknologiassa tapahtuneiden kehitysten myötä antureita on ryhdytty kiinnittämään paljaan kehon lisäksi vaatteisiin ja varusteisiin, kuten taskuihin, laukkuihin, silmälasisiin ja rannekelloihin.



Kuva 10. Kaaviokuva BAN:ista (Wan, 2014).


## 2.7 Markkeriton liikkeenkaappaus

Liikkeet, eleet, kasvojen ilmeet ja katse ovat ihmisen *sanatonta viestintää*. Liikkeenkaappaus on näiden nauhoittamista digitaaliseen muotoon myöhempää käsittelyä varten, ja se voidaan tehdä joko *markkerien* avulla tai ilman niitä. Markkerittomassa tapauksessa liikkujan ei kiinnitetä oheislaitteita, vaan kaappaus suoritetaan luonnollisessa tilassa yhden tai useamman kameran avulla. Tekniikan alullepanijana voidaan pitää englantilaista valokuvaajaa Eadweard Muybridgea (1830–1904), joka teki liikettä koskevia valokuvatutkimuksia ottamalla kuvasarjoja muun muassa hyppäävästä ihmisestä ja laukkaavasta hevosesta.

Eräs markkerittoman liikkeenkaappauksen toimintatapa on käyttää *syvyyskameroita*, joissa on lisäksi *puna-vihreä-sini -värimalli* (RGB-D). Nämä kamerat kaappaavat tietoa liikkujan nivelten, pään, käsien ja jalkojen sijainnista reaaliajassa, mikä mahdollistaa sen, että projisoidun multim mediasisällön siirtymistä vaiheesta toiseen voidaan tarkkailla (Baptista ym., 2016) (Kuva 11). RGB-D -kameroilla tuotetusta tuoreesta da-



tasta on kuitenkin vaikea tunnistaa ennestään määriteltyä liikettä, ellei erillistä koulutusta ole tehty. Reaaliaikainen liikkeentunnistus on tarpeellista esimerkiksi fysioterapeuttisten liikkeiden tai harjoitusten jatkuvassa seurannassa.



**Kuva 11. Väriesitys oikean rannenivelen liikeradan eri kiihtyvyyksistä (Alemi ym., 2014).**


Ennen RGB-D -kameroiden kehitystä interaktiiviset liikkeenkaappausjärjestelmät rakennettiin erilaisten teknologioiden avulla. Esimerkiksi Latulipen ja Huskeyn (2008) tutkimuksessa liikkeen suorittajat pitelivät *USB-hiiriä* (engl. universal serial bus), jotta alueelliset syöttövirtatiedot voitiin visualisoida ja projisoida. RGB-D -kamerat mahdollistivat uusien, välinevapaiden liikkeenkaappauspohjaisten järjestelmien käyttöönoton, joilla voidaan tutkia esimerkiksi ilmeitä, katsetta sekä käsien ja koko kehon liikettä.

### 2.7.1 Ilmeiden ja katseen kaappaus

Kasvojen lihakset synnyttävät monenlaisia ilmeitä joko tahattomasti tai tahdonalaisesti. Tahdosta riippumaton ja hyvin lyhyt, vain sekunnin kymmenesosien kestoinen kasvojen *mikroilme* kertoo nopeasti ohimenevästä tunteesta. Ne on opittu tunnistamaan videokuvien ja tietokoneanalyysien yleistyessä, mutta tavanomaisessa tilanteessa niitä ei kyetä havaitsemaan. Mikroilmeet ovat yleisiä ilmeitä inhon, vihan, pelon, surun, onnellisuuden ja hämmästyneisyyden yhteydessä. Mikroilmeet löysi ensimmäisenä Ernest Haggard ja Kenneth Isaacs (1966) tutkiessaan psykoterapeutin ja potilaan välistä sanatonta viestintää.

Kasvojen liikkeenkaappauksessa nauhoitetaan henkilön ilmeitä ja niiden muutoksia. Menetelmä vaatii tarkempaa liikkeiden tunnistusta kuin koko kehon kaappaus, sillä pienet ilmeiden muutokset on vaikea havaita. Yhdellä kameralla saadaan tuloksena kaksiulotteinen kaappaus ja useammalla kameralla kolmiulotteinen. Markkerittomalla

ilmeiden kaappauksella saadut tuotokset ovat huomattavasti markkerillisilla tekniikoilla saatuja huonolaatuisempia. Saadut kuvat siirretään digitaalisesti tietokoneelle, jossa niitä sovelletaan eri käyttötarkoituksiin. Carmen Duthoit (2008) tovereineen on tuottanut *vektorikartan* kuvassa tapahtuneen ilmeen muuttumisesta toiseksi (Kuva 12). Kyseistä tekniikkaa käytetään automaattisessa kasvokuva-analyysissä turvallisuus- ja rikostutkimusalalla.



**Kuva 12. Kuvan A ilme vaihtuu kuvan B ilmeeksi. Tästä muutoksesta on tehty kuvan C vektorikartta, josta pieni osa näkyy kuvassa D (Duthoit ym., 2008).**

Osana kasvojen liikkeitä tai itsenäisesti voidaan kaapata myös silmien liikkeitä. Silmänliikettä seuraavien kameroiden avulla on esimerkiksi selvitetty digitaalisen sanomalehden luettavuutta tietokoneen näytöltä sekä lehden kirjasintyyppin valintaa (Josephson, 2008). Affectivan kehittämällä Affdex-ohjelmalla tunnistetaan kasvojen tärkeimpiä alueita, kuten silmien kulmat. Tarkka silmän liikkeen havaitseminen on erityisen tärkeää dementian kaltaisten aivotoimintahäiriöiden diagnosoinnissa. Pamela Deansin ja hänen tovereidensa (2010) mukaan tarkkaavaisuus- ja ylivilkkaisuushäiri-

östä (engl. attention deficit hyperactivity disorder) kärsivillä lapsilla on poikkeuksellisen nopeita silmänliikkeitä, joiden tutkimuksella se voidaan erottaa esimerkiksi autisista, lukihäiriöistä ja erilaisista kehitysviiveistä, kuten oppimisvaikeuksista.

### 2.7.2 Käsiliikkeiden kaappaus

Käsiliikkeiden kaappauksessa on tärkeää pystyä tunnistamaan pieniäkin eleitä, sillä esimerkiksi viittomakielessä jopa vähäisillä sormien asennoilla on jokin merkitys. Tästä johtuen siihen liittyy kaksi haastetta (Tang ym., 2015). Ensimmäinen on käsien hahmottaminen, mikä voidaan tehdä kuvia ottavalla toimintamallilla (Kuva 13). Siinä rajoittavia tekijöitä ovat käytössä olevien kameroiden ottamien kuvien laatu ja kuvausnopeus. Toinen kädenasentotunnistuksen haaste on monimutkaisten eleiden vaatima pidempi käsittelyaika, kun taas vähäeleiset liikkeet voivat johtaa epäselvyyksiin.



Kuva 13. “K”-kirjainta merkitsevä käsimerkki hieman eri asennoissa (Tang ym., 2015).

Ao Tangin ja hänen tovereidensa (2015) mukaan karkeaa kädenhavaitsemista ja kädenasentopiirteiden ennustettavuuden vaikeutta on yritetty tehdä helpommaksi monella lähestymistavalla, joista useimmat kuuluvat yhteen kolmesta kategoriasta:

- väripohjainen toimintamalli
- syvyyspohjainen toimintamalli
- nämä kaksi toimintatapaa yhdistävä toimintamalli


Väripohjaiset toimintatavat käyttävät käden ja taustan välisiä värieroja. Tällaiset toimintatavat sekoittavat usein käden samanväristen objektien, kuten taustan, pään tai muun ruumiinosan, kanssa niiden mennessä päällekkäin. Väripohjaisten toimintamallien onnistuminen riippuu taustan väristä ja kameran vakaudesta.

Syvyyspohjaisilla toimintamalleilla selvitetään raajan ja taustan syvyyden ero. Syvyystietoa kerätään syvyyskameroilla, joihin kuuluvat ihmiskehon liikettä tarkasti seuraava *time of flight* -kamera (ToF) ja Microsoftin julkaisema *Kinect*-kamera (Kuva 14). ToF-kamerat käyttävät etäisyyksien laskemiseen takaisinheijastuvaa infrapunavaloa, jolla syvyyskartan aikaansaaminen hämärässä on olennaisesti tehokkaampaa kuin tavallisella kameralla (Salminen, 2019). Kinect-kamerassa on sisäänrakennettu, syvyysanturilla varustettu RGB-D -kamera ja monitasoinen mikrofoni, joilla saadaan tietoa sekä ympäristön väristä että syvyydestä. Kinectillä pystytään tunnistamaan kasvonpiirteitä ja koko kehon toimintaa, mutta sen syvyyskartan matalan resoluution takia sillä on haastavaa suoraan havaita ja *segmentoida* käden kokoisia tai sitä pienempiä kohteita nauhoitteista. Näiden kameroiden toimintamalleihin kuuluvat segmentointitekniikat olettavat, että kameraa lähimpänä olevat objektit ovat kädet, ja että ne ovat määritetyllä etäisyydellä kehosta eivätkä piilossa.



**Kuva 14.** Vasemmalla Helios ToF-kamera (Metrology.News, 2019) ja oikealla Xbox 360 Kinect Sensor Camera (Lelong.my, 2019).

Esimerkki käsien havaitsemisesta väri- ja syvyyspohjaisilla toimintamalleilla esitetään kuvassa 15. Myös Manuel Caputo tovereineen (2012) hyödynsi värillisiä, taustasta helposti erottuvia käsineitä, joilla he saivat aikaan karheutta objektien reunoille.



**Kuva 15.** (a) Käsien havaitseminen ilman värimallia. (b) Käsien havaitseminen värimallilla. (c) Käsien havaitseminen ilman syvyysmallia. (d) Käsien havaitseminen syvyysmallilla (Tang ym., 2015).

### 2.7.3 Koko kehon kaappaus

Markkerittomassa koko kehon liikkeenkaappauksessa tallennetaan Microsoft Kinectin ja RGB-D -kameroiden kaltaisilla laitteilla ihmisen käsillä, jaloilla tai päällä tehdyt liikkeet. Tällä tekniikalla ei ole tarkoitus tuottaa yhtä tarkkaa hahmomallia kuin käsien ja kasvojen kuvaamisessa, koska esimerkiksi Kinectiä hyödyntävät pelit käyttävät ihmisraajojen aluerajoja tunnistaakseen osuvatko ne pelin kohteiden tunnistusalueelle asetetun aikarajan sisällä. Liikkeenkaappaussovellus voi myös pyytää kuvattavaa henkilöä tekemään joko kameran tai itse sovelluksen kalibrointivaiheessa tiettyjä liikkeitä, jotka voidaan tallentaa sovelluksen tietokantaan myöhempää viittausta varten.

Markkeriton koko kehon liikkeenkaappaus voidaan tehdä esimerkiksi Tianwei Xingin ja hänen tovereidensa (2012) esittämällä tavalla. He käyttivät syötteenä Kinect-syvyysanturilla nauhoitetuista kuvasarjoista saatuja kehon asento- ja sijaintiparametreja sekä toisen asteen geometrisia alkuarvoja, kuten *ellipsoidia* ja *elliptistä sylinteriä* (Kuva 16). Kehon mallin ulottuvuudet arvioitiin Kinect-syvyyskartan mukaan. Asentoparametrit projisoitiin mallinnusohjelmaan ja niiden esittämistä muokattiin *hiukkasparvioptimoinnilla* (engl. particle swarm optimization). Kuvauksen pohjapinta poistettiin *random sample consensus* -iterointimallilla, ja kehomallin asennot esitettiin 26 vapausasteen (engl. degree-of-freedom, DoF) parametrisoinnilla. Jokaisen DoF-parametrin arvolle määritettiin rajat anatomisten tutkimusten perusteella. Tuloksena saatiin noin kolme kertaa pelkkää Kinect-kameran sovellusta tarkempi ihmishahmon mallinujärjestelmä.



Kuva 16. Kinect-kameralla otettu kuva ihmiskehosta (Xing ym., 2012).

## 2.8 Markkerillinen liikkeenkaappaus

Kolmiulotteista koko kehon sijaintidataa ei yleensä kerätä RGB-D -kamaroilla, vaan kohdehenkilöt pitävät yllään kuvaustaustasta erottuvaa pukua, jossa on valoa hohtavia tai heijastavia markkereita, joita kuvataan niitä rekisteröivillä kameroilla. Markkerit on sijoitettu kohdehenkilön nivelten kohdalle, ja liikeradoista lähetetään data analysointi- ja mallinnussovelluksille radioteknisellä langattomalla tekniikalla, kuten esimerkiksi *Bluetoothilla* (Alborno ym., 2017; Piana ym., 2016; Pradhan ym., 2008; Tits ym., 2016). Markkerien liikeradat näkyvät datan käsittelyssä kaksiulotteisina kaarina, minkä jälkeen ohjattu oppimisparadigma päättää, mikä ele parhaiten kuvaa kyseistä liikettä (Chaves ym., 2012). Vastaavasti käsistä ja sormista saadaan liikedataa käyttämällä *datakäsineitä* (Kuva 17) tai vastaavia varusteita, mutta niiden käyttö saattaa tuntua kohdehenkilöistä epämiellyttävältä.



**Kuva 17. Datakäsineellä toistetaan ruudulla näkyvää liikettä (Lam ym., 2004).**

Yleisimmin markkeriperustainen liikkeenkaappaus suoritetaan *optisesti*, mutta se voidaan tehdä myös *magneettisesti* tai *mekaanisesti*. Optisessa liikkeenkaappauksessa liikkuja käyttää erikoispukua, jossa on valoa heijastavia markkereita (Kuva 18). Liikkeen kuvaamiseen tarvitaan samanaikaisesti useita tehtävään kehitettyjä kameroita. Magneettimenetelmässä markkereina toimivat liikkujaan kiinnitetyt magneetit (Kuva 19), joiden sijainti ja asento lähettimen synnyttämässä magneettikentässä eri hetkinä kerätään talteen. Mekaanisessa liikkeenkaappauksessa mitataan liikkuvan kohteen nivelien kulmia tukirankaa muistuttavalla puvulla (Kuva 20), jossa jokaisen nivelen kohdalle on kiinnitetty jännitteen vaihteluja mittaava *potentiometri* (Brotkin, 2010; Lehtinen, 2014).



Kuva 18. Optisen liikkeenkaappauksen puvut (edessä) ja kamerat (takana) (Sentimental Flow, 2017).



Kuva 19. Magneettinen liikkeenkaappauslaite *Nest of Birds* (Gmiterko ja Lipták, 2013).





**Kuva 20. Mekaaninen Gypsy-liikkeenkaappauspuku (Gmiterko ja Lipták, 2013).**

Gaurav Pradhan tovereineen (2008) käytti fysiologisten liikkeiden tarkkailussa liikkeenkaappauslaboratoriossa kuvaustaustasta erottuvaa pukua, johon kiinnitetyistä 44 markkerista 16 *Vicon Systems* -kameraa välitti tietoa käyttäjän nivelten sijainneista tietokoneella tehtyyn mallinnusohjelmaan. Kamerat keräsivät liikkeenkaappausdataa 120 kuvan sekuntinopeudella, ja jokaisesta puvun käyttäjästä kerätty data siirrettiin omaan matriisiinsa.

Yhtä aikaa kehon liikkeiden kanssa voidaan liikkeitä kaapata myös kasvoista ja silmistä. Kasvojen seurantalaitteet perustuvat optiseen tekniikkaan. Kevytrakenteiseen, kuvattavan henkilön päässä olevaan, pään liikkeitä myötäilevään kypärään kiinnitetty videokamera kohdistetaan kasvoihin. Kamera tarkkailee kasvoihin kiinnitettyjen markkerien kaksiulotteista liikettä. Markkerit ovat yleisimmin huulissa, poskissa, kulmakarvoissa ja silmäluomissa. Esimerkiksi James Cameronin ohjaaman *Avatar*-elokuvan animaatiokohtauksissa käytettiin markkereina vihreitä pisteitä Na'vi humanoidiasukkaiden kasvojen animoimiseksi (Kuva 21).



**Kuva 21. Kasvojen markkeriperustainen liikkeenkaappaus Avatar-elokuvan teossa (Adsit, 2015).**

Kasvonliikkeiden seuranta poikkeaa hieman kehonliikkeiden seurannasta: Tarkkuutta vaaditaan enemmän, sillä kasvoilla pienetkin liikkeet voivat olla merkityksellisiä. Kaappausalue on huomattavasti pienempi eikä markkereita voida asettaa kaikkiin kasvojen alueisiin, kuten silmiin tai kieleen. Kasvoilla käytettävät merkkipisteet ovat myös tavallista pienempiä ja ne on aseteltu tiheästi. Kasvojen liikkeet kaapataan yleensä erillään muista kehon liikkeistä, vaikka se tuottaa epäyhtenäisyyttä niiden välille.

Liikkeenkaappaus on nopea menetelmä tehdä liikkeistä animaatioita. Erityisesti peli- ja viihdeteollisuudessa sen käyttö on yleistä digitaalisten hahmojen ohjaamisessa ja esineiden liikuttamisessa. Näiden lisäksi sitä sovelletaan myös lääketieteeseen, robotiikkaan, urheiluun ja teollisuuteen (Metria Innovation Inc., 2015).

### 3 Kaapatun liikedatan analysointi

Tuore fysiologinen liikedata on jatkokäsiteltävä niin, että siitä voidaan tehdä johtopäätöksiä. Kaapattu liikedata esikäsitellään, analysoidaan ja tilanteen mukaan joko verrataan tai liitetään muihin *liikedatavirtoihin* tehtävään tarkoitetuilla työkaluilla. Eri tutkimusmenetelmillä ja -laitteilla kerätyille datatyypeille on olemassa valmiita sovelluksia, jotka ovat yhteydessä keräyslaitteeseen.

Kerättyä tietoa tehdyistä liiketutkimuksista voidaan esittää eri *formaateissa*, joihin kuuluvat muun muassa nivelten asennot ja kiihtyvyys, ruumiinosien fysiologiset ominaisuudet, yksinkertaiset videonauhoitteet sekä suorittajan luuston rakennetta käsittelevät animaatiot. Liiketietoanalytiikka tarjoaa tarkkaa tietoa liikkeen ominaisuuksista, ja liikkeen visualisoinnilla voidaan ymmärtää paremmin liikkeen yksityiskohtaisia piirteitä. Tätä tutkielmaa varten kerätyssä aineistossa useimmin mainitut ja eniten käytetyt liikedatan analysointitekniikat olivat segmentointi, *Labanin liikeanalyysi* (engl. Laban movement analysis, LMA), *keinotekoisien neuroverkkojen* (engl. artificial neural network) käyttö ja *2D-kuvaaminen*.


#### 3.1 Segmentointi

Fysiologisen liikkeenkaappausdatan analysoinnin ensimmäinen prosessi on segmentointi, jossa kerätty datavirta jaetaan joko tietyn mittaisiksi tai mallikuvaajia vastaaviksi osasarjoiksi. Pelien ja animaatioiden kehittäjien sekä datan käsittelijöiden on segmentoitava datavirtaukset lyhyiksi, merkityksellisiksi *sekvensseiksi* ennen varsinaista luomis- tai tutkimustyötä, jotta tuoreesta materiaalista voidaan poistaa tavoitellun tuloksen kannalta turhat rakenteet. Tekemällä keskiarvoja toistettujen liikkeiden datasta ja liittämällä ne animaatioarvoiksi saadaan aikaan sulavampia ja helpommin seurattavia animaatioita. Dataa on helpompi käsitellä pienissä osissa, ja siitä voidaan myös tarkemmin havaita mahdolliset liikettä häiritsevät tekijät.

Segmentointi on joko manuaalista tai automaattista. Manuaalisessa segmentoinnissa käsittelijä päättää itse, minkälaisiin osiin data jaetaan. Tämä on kuitenkin työlästä ja

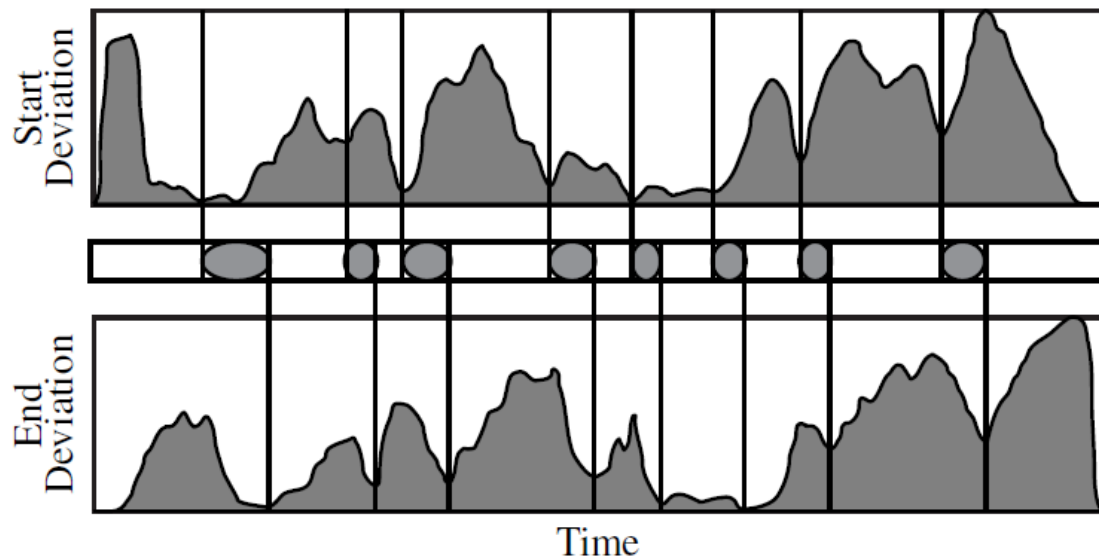
aikaa vievää, eikä sitä ole kannattavaa käyttää reaaliaikaisissa sovelluksissa. Automaattisen segmentoinnin tavoitteena on havaita liikedatasta matalatasoisia kinemaattisia piirteitä, edellyttäen, että se on siihen riittävästi koulutettu. Tehostettu automaattinen segmentointi voi vähentää aikaa, jota animaattorit tarvitsevat luodakseen hahmoille animaatioita, ja se voi yksinkertaistaa syötön käsittelyä peleissä, joita ohjataan pelaajan liikkeellä. (Bouchard ja Badler, 2015)

Yleinen automaattinen segmentointimalli havaitsee muutoksia kinemaattisissa piirteissä, jotka vastaavat etsittyjä segmenttejä (Kuva 22). Kinemaattisia piirteitä ovat esimerkiksi nivelten sijainnit, nopeus- ja kiihtyvyyssarvot sekä *kaarevuussäde*. Näistä piirteistä segmenttirajoja määrittäviä muutoksia ovat muun muassa minimi- ja maksimiarvot, nollan ylitykset sekä raja-arvot. Automaattiset segmentointimallit käyttävät *valvottuja oppimismenetelmiä*, kuten esimerkiksi lähintä naapuria (Müller ja Röder, 2006), Markovin piilomallia (Xia ym., 2012) ja ehdollisia satunnaiskenttiä (engl. conditional random fields; Heryadi ym., 2014). Automaattinen segmentointimalli saattaa kuitenkin epäonnistua merkityksellisten segmenttien tunnistamisessa, jos niiden rajoja ei pystytä havaitsemaan tarpeeksi selkeästi. Segmentointimallien apuna voidaan lisäksi käyttää muutoksen havaitsemisen ja *ryhmittelyn* (engl. clustering) kaltaisia analyysejä tunnistamaan poikkeavuuksia fysiologisesta liikedatasta. Nämä analyysimenetelmät eivät kuitenkaan tutki liikkeen merkityksellistä sisältöä, eivätkä ne siksi tuota hyväksyttäviä segmentointeja. (Bouchard ja Badler, 2015)



**Kuva 22.** Katsaus GP-HSMM -järjestelmästä (Gaussian process–hidden semi-Markov model), jossa yritetään havaita tietyn mallisia dataa, ja laittamalla löydetty mallit järjestykseen (Nakamura ym., 2017).

Durell Bouchard ja Norman Badler (2015) segmentoivat tutkimuksessaan käytettyä liikedataa sovittamalla jokaisen liikkeen aloituksen minimiarvon seuraavaan lähimpään liikkeen päätöksen minimiarvoon (Kuva 23). Monimutkaiset liikkeet segmentoitiin tuottamalla jokaisesta ruumiinosasta erikseen oma segmentointinsa ja tekemällä keskiarvo niistä, joilla oli samanlaiset rajat. Segmenttien yhdistämisestä voitiin säätää muokkaamalla päällekkäin menevien segmenttien lukumäärää ja pituutta.



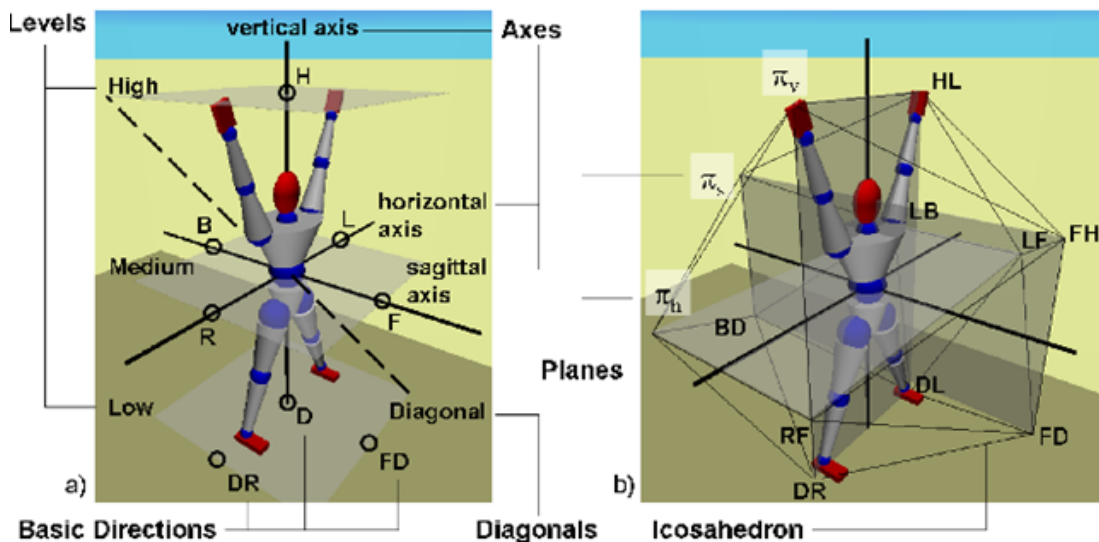
Kuva 23. Rajojen yhdistämistä segmentin tuottamiseksi (Bouchard ja Badler, 2015).

### 3.2 LMA

Eräs fysiologisten liikkeiden laadun analysointiin tarkoitettu järjestelmä on LMA, jonka on kehittänyt liiketeoreetikko ja tanssija Rudolf Laban (1879–1958). Menetelmä keskittyy ihmisliikkeiden tulkintaan ja kuvaukseen liikeratojen sijainnin muutoksen sijasta. Liikkeen *Laban-työarvot* (engl. effort) voidaan esimerkiksi määritellä liikkeiden kinemaattisista piirteistä, joista voidaan edelleen päätellä esittäjän tunteet (Alemi ym., 2014). Mickaël Titsin ja hänen tovereidensa (2016) mukaan liikkeistä saatava datakokoelman tieto on hyvin korkeaulotteista, ja se esitetään laajan solmurakenteen 3D-trajektoreina.

Liikkeen tutkinnassa kerätty liike on kuvattava tilanteeseen sopivina piirteinä, koska käsittelemätön liikedata ei anna tietoa liikkeen taustalla olevista monista vaikuttavista tekijöistä (Alemi ym., 2014). LMA hahmottelee liikkeen neljän komponentin yhdistelmänä: suorittajan keho, kehon muoto, käytössä oleva tila ja työ. Keho, muoto ja tila

kuvaavat kehon artikulaatiota eli suoritettavaa liikettä. Työ kuvaa liikkeen suoritusta neljän eri *liiketekijän* (engl. effort factor) avulla: (1) *tila* (engl. space factor), eli liikkeen suhde ympäristöön; (2) *aika* (engl. time factor), eli liikkeen suorituksen nopeus; (3) *paino* (engl. weight factor), eli liikkeen voima; ja (4) *virtaus* (engl. flow factor), eli liikkeen sulavuus. Tilatekijä käsittelee raajojen ojennusta, taivutusta sekä liikkeen suuruutta (Kuva 24). Aikatekijä käsittelee tahdin muutoksia ja taukojen kestoa. Painotekijä käsittelee liikkeen jännitteen määrää. Virtaustekijä käsittelee nopeus- ja energia-kaarien muotoja, rytmiä sekä liikkeiden kiihtyvyyden määrää. Nämä piirrekuvaukset voidaan yrittää tunnistaa neuroverkolla joksikin aiemmin määritellyksi liikkeeksi, tai ne voidaan sisällyttää visualiseen liikeluontimalliin, jolloin niillä voidaan kehittää liikkeitä, joissa on tarvittavat piirteet.



Kuva 24. Esitys LMA-tilatekijästä (Rett ja Dias, 2007).

Jokainen LMA-työarvoista on jatkumo eri laatujen yltäkylläisyyden ja puutteen välillä. Toisin sanoen, LMA-työarvot kuvataan arvona kahden ääripään väliltä, joiden välillä liike vaihtelee ja paljastaa eri laatuja:

- tila: suora–epäsuora
- aika: äkkinäinen–jatkuva
- paino: kevyt–painava
- virtaus: kontrolloitu–vapaa

Jatkumon ääripäihin viitataan vapauttavana ja hallitsevana elementtinä. Jokainen työarvo voidaan lisäksi määrittää joko vapaaksi, hallituksi tai joksikin siltä väliltä. Esimerkiksi läpsäytys on kevyempi ja äkillisempi kuin nyrkin isku. LMA-työarvoilla voidaan merkitä merkityksellisen segmentin rajoja, koska ne ovat riippuvaisia joistakin liikelaadusta, jotka ilmenevät liikkeen alussa tai lopussa. Esimerkiksi, liikkeen alku analysoidaan, jotta saadaan selville, onko liike äkkinäinen (Bouchard ja Badler, 2015).

Olemassa olevat LMA-tunnistusjärjestelmät käyttävät liikkeenkaappaus- ja videodataa, ja niitä voidaan hyödyntää vain hallituissa ympäristöissä. Liikedatassa kohteen sijainti täytyy olla määritelty suhteessa kameraan tai liikkeenkaappauslaitteistoon. Tämän lisäksi näissä menettelytavoissa liike täytyy jakaa erillisiin osiin, ennen kuin sen luokittelu LMA-työarvojen elementteihin voidaan suorittaa. (Maranan ym., 2014)

Tiedon analysoimiseksi ja tärkeän tiedon löytämiseksi tarvitaan sopivat työkalut, kuten Matlab, Mova (Alemi ym., 2014) ja MotionMachine (Tilmanne ja D'Alessandro, 2015). Liike-esityksen tyypistä (tanssi, juoksu, käsien liike) riippumatta sen suorittajan liikkumistapaan vaikuttavat niin yksilön sisäiset kuin yksilöiden väliset tekijät. Yksilön sisäisiin tekijöihin kuuluvat muun muassa kehon nivelten asemien ja pyörimisliikkeiden muutokset, tunteet sekä kinemaattiset ja *kineettiset* ominaisuudet (Tits ym., 2016). Yksilöiden välisiä tekijöitä ovat esimerkiksi motivaatiot, tavat ja kehojen fysiologiset erot. Näiden tekijöiden määrittelyyn tuoreesta datasta tarvitaan yksi kolmesta menettelytavasta:

- 1) asiantuntija tai hänen määräämänsä manuaaliset muistiinpanot,
- 2) *analyttiset algoritmit* tai
- 3) *koneoppiminen* neuroverkoilla.

Saadut tulokset visualisoidaan yleisölle esitettävään muotoon. Koneoppimista käytetään liikepiirteiden havaitsemiseen sen sijaan, että asiantuntijat määrittelisivät säännöt ja algoritmit.

LMA:ta on käytetty tulkitsemaan robottien fyysistä liikettä sisäisten tunnetilojen näkyvänä ilmentymänä (Barakova ja Lourens, 2010), luomaan fyysisesti ilmaisevia animoituja hahmoja (Chi ym., 2000), tukemaan sosiaalista läheisyyttä tulkitsemalla kosketuslaatuja verkostoiduissa ja tuntoaistia hyödyntävissä käyttöliittymissä (Schiphorst ym., 2007), luokittelemaan aktiviteetteja, kuten kävely ja juokseminen (Khoshhal ym.,

2010) sekä segmentoimaan kaapattua liikedataa neuroverkkojen avulla (Bouchard ja Badler, 2015).

Sarah Alaoui tovereineen (2017) tutki eri LMA-työtekijöiden elementeillä määriteltyjen *basic effort actionien* tunnistusta ja mallinnusta. Lähdemateriaaleina he käyttivät muun muassa videonauhoituksia ja EMG-arvoja ammattilaistanssijoiden liikkeistä. He laativat tanssiliikelaatujen laskentaan metodin, joka käsitteli paino-, aika- ja tilatyötekijöiden elementtien arvoja. Tehtävän helpottamiseksi he kehittivät koneoppimismallin, jossa he käyttivät osahavaintasekvenssiä arvioimaan jatkuvasti todennäköisimmät LMA-työtekijöiden arvot.

Tutkimuksen tueksi värvätyt LMA-asiantuntijat suosittelivat multimodaalisen liikedan keräämistä, jotta mahdollisimman monta LMA-työarvoa voitaisiin määrittää. Tästä syystä Alaoui tovereineen (2017) keräsi tietoa tanssiliikkeitä suorittavista ihmisistä dynaamisilla, fysiologisilla ja sijaintia määrittävillä mittauksilla. Liikkujien oikeasta ranteesta kerätyllä dynaamisella kiihtyvyyssanturidatalla tutkittiin aikatyöarvoja. Liikkujien kyynärvarsista kerätyllä fysiologisella EMG-datalla tutkittiin painotyöarvoja. Liikkujien kehoon kiinnitetyistä markkereista kerätyllä 3D-sijaintidatalla tutkittiin tilatyöarvoja.

LMA:n kehittäjän Rudolf Labanin ja hänen kollegansa Charles Lawrencen (1947) mukaan tämän kaltaisilla liikeanalyysijärjestelmillä on rikas *epistelemologinen* historia erityisesti tanssin, elekkommunikaation, psykoanalyysin ja psykologian alueilla, mikä tarjoaa täsmällisiä ja havainnollistavia malleja liikkeen kuvaukseen, toimintaan ja ilmaisuun.

### 3.3 Neuroverkot

Neuroverkot ovat yksi koneoppimisen malleista, eli koneen itsenäistä oppimista syötettyyn dataan perustuen, jonka mallina ovat varsinaiset biologiset neuronit. Verkkoihin syötettävä data voi olla esimerkiksi tekstiä, kuvia ja signaaleja. Neuroverkon *solmuiksi* kutsutut neuronit ovat yhteydessä toisiinsa *synapseilla* ja välittävät syötteinä saamaansa datatietoa eteenpäin verkossa. Jokaisessa solmussa on vakiotermi, jolla jo-



kaiselta painotetulta vastaanottosynapsilta saatu datatieto kerrotaan kuhunkin kerrokseen määritetyn *summafunktion* avulla. Jos saatu tulos täyttää funktiolle asetetun ehdon, siitä lähetetään päivitetty datatieto kaikille verkon seuraavan kerroksen solmuille, jotka ovat yhteydessä kyseessä olevaan solmuun. Usean solmun yhdistäminen tuo varmempaa tietoa solmujen funktioihin, mikä vaikuttaa datan etenemiseen. Neuroverkoista saadaan tuloksena jokin arvo nollan ja ykkösen väliltä. Data jaotellaan vähintään kahteen eri luokkaan, esimerkiksi jos halutaan tunnistaa kuvasta joko ihminen tai eläin.


Neuroverkot koostuvat *syötekerroksesta*, *tuloskerroksesta* ja niiden välissä olevasta *piilokerroksesta*. Mikäli piilokerroksia on useita, puhutaan *syväoppimisesta* (engl. deep learning) tai *syivistä neuroverkoista* (engl. Deep Neural Network, DNN), joita on käytetty esimerkiksi ihmisen toiminnan tunnistuksessa (Seide ym., 2011) ja kuvien noutamisessa (Krizhevsky ja Hinton, 2011).

Neuroverkkojen painot koulutetaan ajamalla tietty määrä syötteitä verkon läpi ja vertaamalla tuloksia toivottuihin arvoihin. Tämän jälkeen lasketaan kerroksittain korjaukset kunkin solmun *painokertoimiin*, päivitetään verkko ja aloitetaan uudestaan. Kiertoa toistetaan, kunnes tulos ei enää merkittävästi muutu. Vanessa Yaremchukin ja Marcelo Wanderleyn (2014) mukaan neuroverkkojen koulutuksen lopettavia tekijöitä ovat esimerkiksi seuraavat kolme mahdollisuutta:

- 1) neuroverkon painoja edustavan *gradientin* arvo on tarpeeksi lähellä nollaa,
- 2) *keskineliövirhe* (engl. average squared error) saadaan tarpeeksi pieneksi määritellyssä ajassa ja
- 3) neuroverkko testataan onnistuneesti erillisellä datajoukolla samalla välttämättä *ylisovitusta* (engl. overfitting).


Neuroverkkomalleja on useita, joista jokaisella on oma toimintatapansa. Näihin kuuluvat muun muassa *myötäkytkentäverkko* (engl. Feedforward Neural Network, FNN), *toistuva neuroverkko* (engl. Recurrent Neural Network, RNN), *syväuskoverkko* (engl. Deep Belief Network, DBN) ja *konvoluutioverkko* (engl. Convolution Neural Network, CNN).

FNN-verkoissa tieto virtaa jokaisen piilokerroksen läpi vaihtamatta suuntaa, kunnes se saavuttaa tuloskerroksen (Kuva 25).




Kuva 25. Myötäkytkentäverkko (Dash, 2019).

RNN-verkon solmuissa on reitti viedä tietoa takaisin verkon aiempiin solmuihin (Kuva 26). Tämän paluureitin tarkoituksena on muokata syöttödataa, jos se ei solmuun osuessaan täyttänyt eteenpäin siirtymiseen vaadittavaa ehtoa.



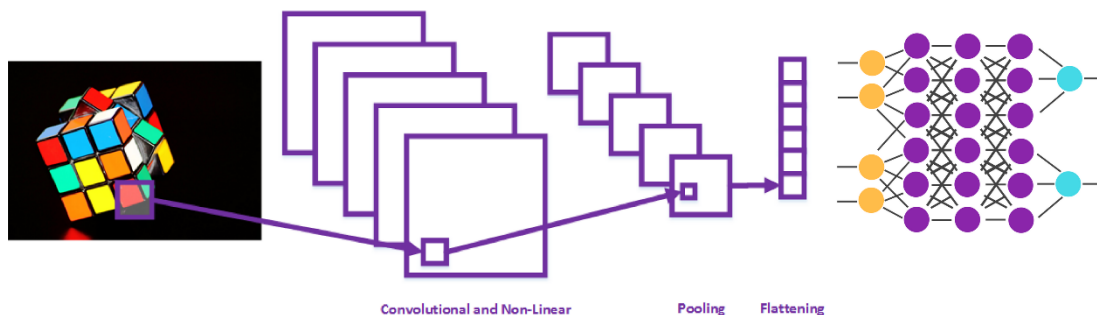
Kuva 26. Toistuva neuroverkko (Chatterjee, 2019).

DBN on neuroverkkojen painojen koulutukseen käytetty malli, jonka alkupään kahden ensimmäisen kerroksen väliset yhteydet ovat *suuntaamattomia*, ja kaikkien muiden piilokerrosten yhteydet ovat *suunnattuja* tuloskerrosta kohti (Kuva 27).




Kuva 27. Syväskoverkko (Khandelwal, 2018).


CNN-verkoilla on syöttö-, tulos- ja piilotettujen datankäsittelykerrosten lisäksi *konvoluutiokerroksia* (Kuva 28), joissa tarkasteltavan kuvasegmentin syöttödatasta prosoidaan talteen tietoa suodattimien (Kuva 29) ja *maksimiyhdistämistoimintamallin* (engl. max-pooling) avulla (Kuva 30). Suodattimilla lasketaan *datapiirrekarttojen* (engl. feature map) arvoista painotetut keskiarvot seuraavalle piirrekartalle, kun taas maksimiyhdistämisessä valitaan jokaiselta piirrekartan tarkastelualueelta suurimmat arvot. Välittämällä *pikselitietoa* usealta konvoluutiokerroksen solmulta seuraavan konvoluutiokerroksen eri solmuille voidaan käsiteltävästä datasta tunnistaa piirteitä, jotka ilmenevät useasti.



Kuva 28. Konvoluutioverkko (Rubik's Code, 2018).



Kuva 29. Esimerkki suodattimesta (Cornelisse, 2018).

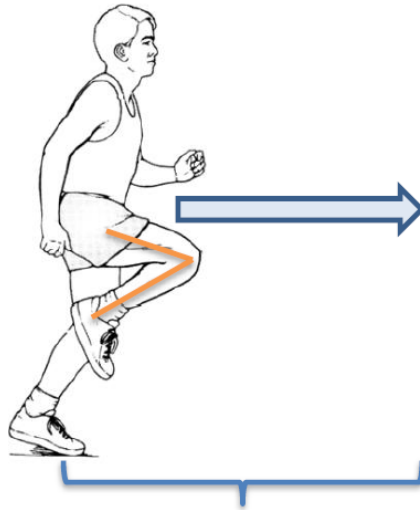


Kuva 30. Esimerkki maksimiyhdistämisestä (Cornelisse, 2018).

Koulutettujen neuroverkkojen käyttäminen liikkeentunnistuksessa auttaa tunnistamaan liikekuvioita ja opettujen eleiden suoritusta. Neuroverkkojen käytössä on se haaste, että ne eivät tunnista, onko liikkeestä käynnissä sen alku, loppu vai keskivaihe. Ne pystyvät tunnistamaan oman koulutuksensa pohjalta vain millainen liike on kyseessä.

### 3.4 2D-kuvaus

Liikkeiden fysiologisessa analysoinnissa voidaan käyttää 2D-kuvausta silloin, kun kysymyksessä on tasossa tapahtuva kehon tai sen osan liike, eli suoristusmuuttujan ollessa *lineaarinen*, kuten juoksunopeuden, askelpituuden, irtoamiskulman ja lähtönopeuden mittaauksessa. Näitä liikkeitä ovat esimerkiksi kävely juoksumatolla, vauhditon hyppy ja telinevoimistelu. Useimmat voidaan analysoida sivusuuntaisesti, jos nilkan, polven ja lantion kulmat pystytään mittaamaan (Kuva 31). Liiketasoista mitatuista arvoista voidaan lisäksi määrittää *massakeskipiste* (Contemplas, 2019).



**Kuva 31. 2D-liikeanalyysi (Kulmala, 2012).**

Menetelmän hyötyjä ovat sen helppous ja nopeus. Tutkimuksiin tarvitaan vain yksi kamera. Sovellettaessa 2D-analysointia on kuitenkin huomioitava tasosta ulos suuntautuvien osatekijöiden aiheuttamat virheet. Jos kamera on kaukana liikkeestä, kaikki segmentit näkyvät yhdessä tasossa. Pienet etäisyserot kamerasta voidaan kuitenkin jättää useimmissa tapauksissa huomiotta. Yksityiskohtaisempia mittauksia saadaan käyttämällä kameroita, jotka on sijoitettu eri kuvakulmiin. Liikkeiden analysointia varten on valmiita tietokoneohjelmia, esimerkiksi Kinovea, Skill Spector ja tutkimuskäyttöön tarkoitettu Qualisys.

## 4 Tapaustutkimuksia

Historiatietojen mukaan ihmisten ja eläinten liikkeiden lihastoiminnan havainnoista kertovan ensimmäisen teoksen, *De Motu Animaliumin* kirjoitti antiikin kreikkalainen filosofi Aristoteles (384–322 eaa.; 1949). Huippusuorituksiin pyrkiessään muinaiset kreikkalaiset olivat todenneet urheilullisen toiminnan vaativan tiedon harjoittamista mielen ja kehon harmonian lisäksi. Varsinaisia ihmisliikkeiden tutkimuksia on tehty 1900-luvun alusta lähtien. Yhdysvalloissa bostonilainen ortopedian kirurgi Robert Lovett (1859–1924) kehitti manuaalisen lihastestauksen tieteen. Hän käytti lihastestiään analysoidakseen polio- ja hermovaurioista johtuvia vammaisuuksia erityisesti lapsilla (O'Neill Kinesiology College Blog, 2019). Vanhin löytämäni maininta suomalaisten tekemästä ihmisliiketutkimuksesta on Ilkka Lehtisen ja hänen tovereidensa vuoden 1976 tutkimus alkoholin vaikutuksesta aivosähkökäyrään.


1900-luvulla ihmisliikkeiden analysointi alkoi kehittyä nopeasti anatomian ja tekniikan tietämyksen lisääntyessä. Nopeiden *infrapunakameroiden* ja muiden videokuvausjärjestelmien tultua 1970-luvulla laajaan käyttöön oli mahdollista saada yksityiskohtaisia liikeanalyysituloksia kohtuullisissa kustannus- ja aikarajoissa. Nopeiden tietokoneiden ja kamerajärjestelmien myötä ihmisliikkeen 3D-analyysi on tullut mahdolliseksi. Tutkimusalueet ja -kohteet ovat laajentuneet lääketieteestä muillekin alueille, kuten liikuntatieteeseen ja viihdeteollisuuteen. Tätä lukua varten valitut esimerkkitaupaukset fysiologisesta ihmisliikkeen analysoinnista ovat aivohalvauksen kuntoutusmenetelmä EEG:n avulla, erilaisten liikkeiden ja LMA-työarvojen tunnistusmenetelmä, koko kehoa koskevien animaatioiden tuottaminen datakäsineellä sekä silmän liikkeen suunnan määrittäminen *optisen virtauksen* (engl. optical flow) avulla.

### 4.1 EEG ja kädenliikkeet kuntoutuksessa

Arpa Suwannarat tovereineen on todennut vuonna 2018 julkaistussa tutkimuksessaan EEG:n olevan lupaavimpia sovelluksia *aivo-tietokone* -pohjaisessa aivohalvauksen kuntoutuksessa. Monet tutkimukset ovat osoittaneet, että erillisten, mielikuviin pohjautuvien liikeharjoitusten (engl. motor imagery, MI) tai kuntoutusrobotiikan avulla voidaan palauttaa aivohalvauspotilaiden motorista toimintakykyä. MI-terapia aktivoi

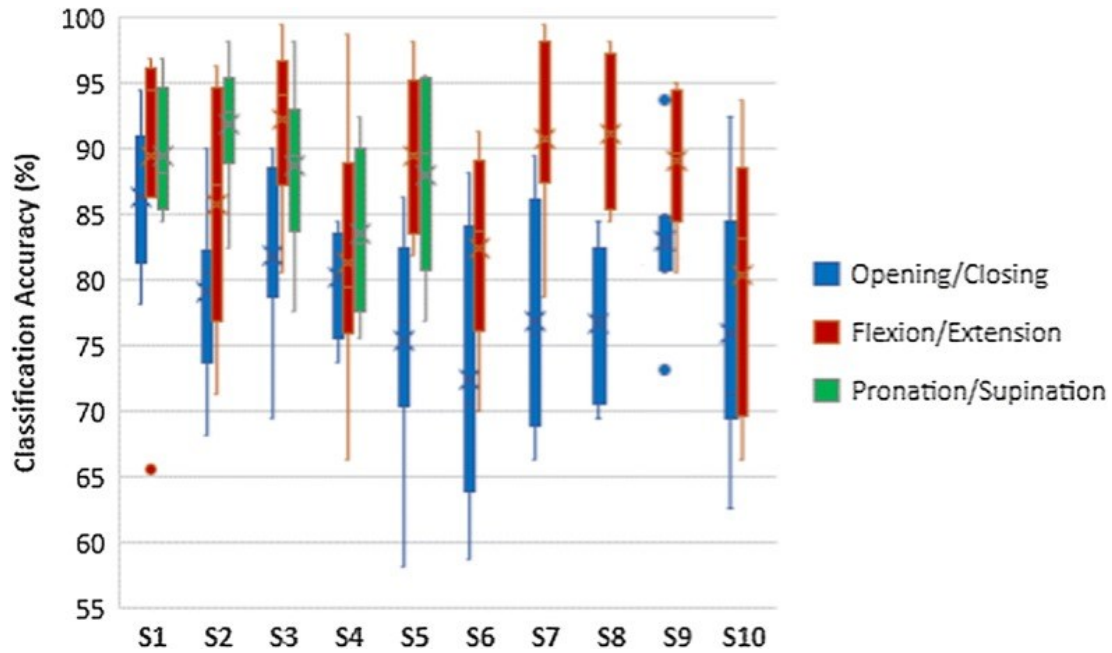
aivojen liikkeitä sääteleviä osia sekä aivokuorten välisiä yhteyksiä. Yleensä MI-harjoituksissa on käytetty käsien liikkeitä. Tässä tutkimuksessa arvioitiin aivohalvauksen saaneiden ensihoidossa yleisimmin käytettyjen, mutta vaikeammin analysoitavien ranne- ja käsivarsiliikkeiden tehokkuutta MI-tehtävissä.

MI-tehtäviksi valittiin kolme ranneliikettä: käden avaaminen ja sulkeminen, ranteen taivutus ja ojennus sekä kyynärvarren *pronaatio* ja *supinaatio* (Kuva 32). Koehenkilöitä oli 11. Kaikki suorittivat käden avaamisen ja sulkemisen. Kymmenen koehenkilöä suoritti kaksi eri kertaa käden avaamisen ja sulkemisen ja ranteen taivutuksen ja ojennuksen. Viisi henkilöä suoritti kaikki kolme MI-tehtävää. Jokainen MI-tehtävä suoritettiin kahdeksan eri kertaa neljän viikon aikana. Luokittelussa käytettiin kahteen *common special pattern* -algoritmiin (CSP) perustuvaa piirrepoimintaa. Ensimmäinen algoritmi tehtiin tavanomaisella CSP:lla ja toisen ominaisuuksia lisättiin suodattamalla EEG-data viiteen kaistaan. Luokittelu suoritettiin koneoppimisen lineaarisella *diskriminanttianalyysillä* ja *tukivektorikoneella*. MI-tehtävän suorituskyky arvioitiin kriteerillä, jonka mukaan osallistujien on saavutettava 60 % tarkkuus.



**Kuva 32. Kolme MI-harjoitusta (Suwannarat ym., 2018).**

Tulokset esitettiin kunkin MI-tehtävän vasemman ja oikean käden luokittelutarkkuuksissa, mikä viittasi koehenkilön kykyyn suorittaa MI-tehtävä. Tutkimustulosten analysointien perusteella todettiin ranteen taivutus- ja ojennustehtävän sekä käsivarren pronatio- ja supinaatiotehtävän yksittäisten tutkimuskertojen keskimääräisen tarkkuuden olleen korkeampi kuin käden avaamis- ja sulkemistehtävän (Kuva 33). Tutkijoiden mukaan ranneliikkeitä tulisikin harkita MI-tehtävissä, koska niiden tarkkuus oli korkeampi kuin käsiliikkeissä, ja ne olivat yhdenmukaisia muiden tutkijoiden aiemmin esittämien kriteerien kanssa.



Kuva 33. Kolmen eri MI-tehtävän luokitustarkkuuden vertailu (Suwannarat ym., 2018).


## 4.2 Multimodaalisen liikkeen ja LMA-työarvojen tunnistus

Sarah Alaoui tovereineen (2017) keräsi ja käytti multimodaalista liikedataa tehdäkseen laskentamallin LMA-työarvojen avulla tanssiliikkeiden tunnistukselle. Lähdetietona he käyttivät ammattilaistanssijoilta kerättyä liikedataa. He kaappasivat tietoa dynaamisilla, fysiologisilla ja *positionaalisilla* mittauksilla. Liikkujan oikeasta ranteesta kerätyllä dynaamisella kiihtyvyyssanturidatalla tutkittiin LMA-aikatyöarvoja. Kyynärvarsista kerätyllä fysiologisella EMG-datalla tutkittiin LMA-painotyöarvoja. Kehoon kiinnitettyjen markkereiden avulla kerättiin 3D-positionaalista liikkeenkaappausdataa rinnan ja kyynärvarsien välisestä etäisyydestä, minkä avulla tutkittiin LMA-tilatyöarvoja. Tutkimustyön tueksi rekrytoidut LMA-asiantuntijat olivat ehdottaneet kyseistä datankeruutapaa. Osana tehtävää kehitettiin koneoppimismalli, jossa käytettiin *osahaivaintasekvenssiä* arvioimaan jatkuvasti reaaliajassa todennäköisimmät LMA-työtekiöiden arvot.

Kaikki kerätty multimodaalinen data *synkronoitiin* ja *nimiöitiin* manuaalisesti Cycling'74 Max6 -sovelluksella koneoppimismallin koulutusta ja liikkeiden tunnistusta varten. Koneoppimismallin kyky tunnistaa jatkuvasti liikkeitä arvioitiin jokaisen koasekvenssin peräkkäisistä kuvista oikein tunnistettujen liike-elementtien prosentiosuudella.



Liikkeiden ja niiden elementtien arvojen todennäköisyydet määritettiin reaaliaikaisesti ja jatkuvasti koneoppimismallilla sekä ristivalidoinnilla jokaisessa eri aikavaiheessa, samoin kuin osasekvenssikohtaisesti kaikille niille liikenuhoituksille, joita ei käytetty koneoppimismallin koulutuksessa. Koulutus- ja samoin myös testivaiheessa arvioitiin todennäköisin LMA-työtekijä testisekvenssin joka kuvalle.



Kuva 34. Liikkeiden ja LMA-työarvojen tunnistustulokset prosenttiosuuksina diagrammissa (Alaoui ym., 2017).

Kuvasta 34 huomataan, että LMA-aikatyön, -painotyön, -tilatyön ja liikkeiden tunnistusprosenttiosuus oli suurimmillaan, kun siihen käytettiin synkronoitua, monesta lähteestä kerättyä multimodaalista dataa. Diagrammi E sisältää lisäksi liikkeen nopeuden ja kiihtyvyyden, mikä parantaa huomattavasti tunnistustarkkuutta.

Useampien dataa keräävien modaliteettien käyttö tarkoittaa suurempaa tarkasteltavien liikelaatujen määrää liikkeen tarkasteluun suunnitelluissa järjestelmissä. Tulos näyttää, että LMA-työarvojen hahmotteluun tarvitaan sellaista multimodaalista dataa, jolla yhdistetään ainakin dynaaminen, fysiologinen ja positionaalinen data.

Lähestymistapa multimodaaliseen kaappaukseen ja LMA-työarvojen tunnistamiseen voidaan sisällyttää interaktiivisten sovellusten suunnitteluun esimerkiksi taiteessa, digitaalisessa mediassa, viihteessä, koulutuksessa tai kuntoutuksessa.

Labanin liikeanalyysin asiantuntijoiden mukaan LMA-tilatyötä on vaikeaa mitata videonauhoitteiden kaltaisesta positionaalisesta datasta tai LMA-muotokomponenttilaataja käyttämällä, koska niistä saatava tieto on joko puutteellista tai vääränlaista. Yleensä LMA-tilatyötä arvioidaan antureiden keräämillä liikkujan kineettisillä piirteillä, kuten nopeudella ja kiihtyvyydellä.

### **4.3 Koko kehon animaatioiden tuotto datakäsineellä**

Wai-Chun Lam tovereineen (2004) kaappasi liikettä ihmiskädestä Essential Reality P5 -datakäsineen avulla. Käsineen käyttäjä toisti graafisella näytöllä esitettyjä käden liikkeitä (Kuva 17). Kaapatut liikkeet johdettiin reaaliajassa kartoitusfunktion avulla etukäteen määrättyihin koko kehon liikkeisiin, jotka oli kaapattu aiemmin. Muuttamalla hieman käden suuntaa tai liikkeen tahtia kaappauksen aikana luotiin uusia liikkeitä ja hallittiin ihmishahmoa reaaliaikaisessa ympäristössä, kuten peleissä ja virtuaalitodellisuusjärjestelmissä.

Datakäsineen ranneosan sijainti ja orientaatio havaittiin infrapuna-antureilla sekä orientaatiota tunnistavilla antureilla. Käsineen A/D-muuntimessa oli 64 välivaiheen resoluutio suoristettujen ja koukistettujen sormien välillä. Käsineen liikkeenkaappaus voitiin toistaa useasti, mikäli tulos ei ollut tarpeeksi hyvä.

Kartoitusfunktio kehitettiin määrittämällä suhde sormille ja ihmiskehon liikkeille. Etusormen ja keskisormen liikkeet vastasivat jalkojen ja olkapäiden liikettä sekä nopeutta. Datakäsineen antureista kerättiin liikerata sekä minimi- ja maksimiarvoparametrit, liikkeen kesto ja yleisten koordinaattien alue. Antureista kerätty *korkeafrekvenssidata* saattoi sisältää tahattomia liikkeiden ja epähienon A/D-muunnoksen takia kartoitusta häiritseviä virhearvoja, mistä syystä ne puhdistettiin Fourier-sarjan laajennoksella. Kartoitusfunktio luotiin käyttämällä B-käyriä ja yhdistettävien liikeratojen pisteitä. Sormien ja kehon liike synkronoitiin yhdistämällä frekvenssivirtojen korkeimpien ja matalimpien kohtien aikavälit.

Toimintamallin ongelma on, että kartoitusfunktio toimii vain, jos uusi luotu liike on samanlainen kuin alkuperäinen. Esimerkiksi, jos alkuperäinen ihmisliikedata on hypähtelyä, niin uudella luodulla liikkeellä täytyy olla samanlainen rakenne. Järjestelmä ei toimi oikein, jos liike on esimerkiksi kävelyä.

Toinen ongelma on, että kinemaattiset rajoitteet, kuten jalkojen kosketus maahan, eivät säily uudessa luodussa liikkeessä. Täten tukijalka usein liukuu maan päällä, mikä tekee tuloksista epärealistisen näköisiä. Tämän parantamiseksi on tarpeellista poimia automaattisesti tällaiset rajoitteet alkuperäisestä liikkeestä ja sisällyttää ne uusiin luotuihin liikkeisiin. Vastaavat rajoitteet on poimittava myös sormista, missä tapauksessa tarvitaan datakäsine, joka antaa paljon tarkempaa tietoa. Koko kehon liikkeitä on haastavaa simuloida datakäsineen avulla, ellei se ole tarpeeksi kehittynyt.


Vaikka käsineen syöttö oli karkeaa eikä se pystynyt kaappaamaan sormien suoristusta tai koukistusta, käsineen tarjoama tieto riitti silti saavuttamaan tutkimuksen tavoitteet. Kädellä pystyttiin hallitsemaan ihmishahmoja yksinkertaisella ja intuitiivisella tavalla. Löytämällä ratkaisut aiemmin mainittuihin ongelmiin on mahdollista, että esitettyä lähestymistapaa voitaisiin käyttää uutena metodina ihmisliikeden muokkauksessa.

#### **4.4 Silmänliikkeen suunnan määrittäminen**

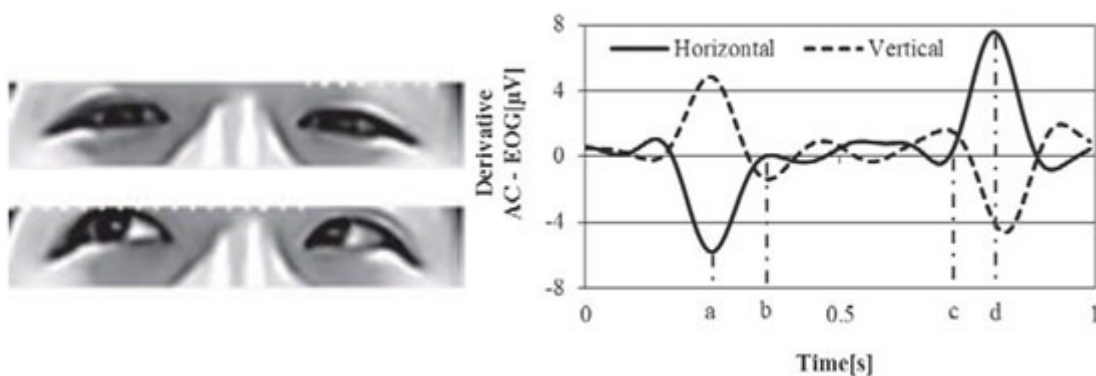
Shogo Matsuno tovereineen (2016) kehitti reaaliaikaisen silmänliikkeen suuntaa analysoivan käyttöliittymäprototyypin kamerallisille älypuhelimille. Tutkimuksen ideana oli laatia perusta silmänliikkeiden suuntaa syötteenä käyttävälle käyttöliittymälle, jolla voitaisiin hallita elektronisia laitteita. Silmien liikesuunta määritettiin optisen virtauksen avulla.

Matsunon ja muiden mukaan optinen virtaus voidaan laskea silmistä otettujen, toisiaan seuraavien kuvien valituista pikseleistä muodostettujen *liikevektorien* avulla. Heidän mukaansa viittauspisteissä, jotka on merkitty silmän alueesta kerättyyn kuvasekvenssiin, tapahtuu muutoksia aina silmien liikkuessa. Sekvenssin peräkkäisten osien viittauspisteistä muodostetaan liikevektorit, joiden keskiarvo määrittää optisen virtauksen.

Silmien liikkeiden kaappauksessa kameran käyttäjä kohdisti kasvonsa näytön kehyksen keskelle (Kuva 35), minkä jälkeen järjestelmä mittasi käyttäjän jokaiseen kamerakuvan kulmaan kohdistaman katseliikkeiden *vektoriaaltomuodon* (Kuva 36). Prototyypin käyttämän syöttöikkunan laajuus ei ole kovin suuri, joten sitä voivat hyödyntää myös pieniruutuiset älypuhelimet. Katseen syötön kaappaukseen liittyy muutama haaste: Tarkka mittaus edellyttää täsmällistä kalibrointia sekä pysyvän asemasuhteen käyttäjän ja järjestelmän välille. Lisäksi minkä tahansa katsetta mittaavan laitteen tarkkuuden täytyy lisääntyä silmänliikkeiden arvoalueen pienentyessä. Katseen suuntatiedon keräämiseen on yleensä tarvittu suhteellisen laaja ruutu tai pikkutarkkaa kuvaa ottava laite, mikä on älypuhelimien kokoisille laitteille vaikeaa.



Kuva 35. Vasemmalla on käyttöliittymäprototyypin luonnos ja oikealla on optisen virtauksen mittaamista (Matsuno ym., 2016).



Kuva 36. Vasemmalla silmien liike lepoasennosta vasempaan kulmaan ja oikealla siitä syntyvä aaltomuotovektori (Matsuno ym., 2016).

## 5 Yhteenveto

Tässä tutkielmassa esitin liikkeiden fysiologista analysointia alkaen liikkeiden keräysmenetelmistä ja päättyen tutkimusesimerkkeihin. Esittelin yleisimmät ja tärkeimmät alan julkaisuissa käytetyt tiedonkaappausmenetelmät. Näihin kuuluivat verenpaineenmittaus, sydämen sykkeen mittaus, EKG, EEG-rekisteröinti, EMG, BAN-verkosto sekä markkeriton ja markkerillinen liikkeenkaappaus.

Seuraavaksi esitin kaapatun liikedatan analysointimenetelmiä, joita olivat segmentointi, LMA, neuroverkot ja 2D-kuvaus.

Tapaustutkimusesimerkeiksi valitsin lääketieteen alalta käsien liikkeiden ja EEG:n käytön kuntoutuksessa, liikuntatieteen alalta multimodaalisen liikkeen sekä LMA-työarvojen tunnistuksen, viihdeteollisuudesta koko kehon animaatioiden tuottamisen datakäsineellä ja älypuheliteollisuudesta silmänliikkeen suunnan määrittämisen optisen virtauksen mittaamisella.

Tutkielmani tietolähteitä luettaessa on nähtävissä, että monet tutkimukset ja niiden tulokset ovat sovellettavissa alalta toiselle. Liikkeiden fysiologisella analysoinnilla vaikutetaan liikesuoritusten kautta ihmisten terveyteen, mikä käy ilmi esimerkiksi EEG:n mittauksesta liikkeen aikana. Neuroverkkojen toiminnan laajempi hyödyntäminen tehostaisi merkittävästi lääkäreiden, fysioterapeuttien, luonnontieteilijöiden, teknisten alojen ammattilaisten sekä monien muiden työtä. Sillä olisi suotuista vaikutus tiedon tulokinnan laatuun, sillä jopa kokenut insinööri tai kirurgi voi ymmärtää ja tulkita dataa väärin. Vaikka tekoälyä kehitetään jatkuvasti, se ei kuitenkaan täysin korvaa taitavaa ammattihenkilöä. Monet muutokset edellyttävät pienten vivahde-erojen havainnointia, minkä vuoksi inhimillinen analysointi on edelleen tarpeellista.

Eräs fysiologisen liikedatan analysoinnin suurimmista haasteista on multimodaalisen tiedon, niiden synkronointitietojen sekä niitä nauhoittaneiden laitteistojen yksityiskohdistaisten kuvausten puute. Jokaisella fysiologisella datalähteellä on muista erottuvia vahvuuksia ja rajoituksia tarkkuudessa, resoluutiossa sekä näytteen oton nopeudessa. Toisaalta, suuren datamäärän pienentämiseen ja käsittelyyn tarvitaan sopiva toimintamalli. Lisäksi multimodaaliset datavirrat on synkronoitava esimerkiksi aikaleimojen

avulla, jotta potentiaalisten, fysiologisissa signaaleissa tapahtuneiden poikkeamien vaikutukset voidaan havaita samaan aikaan eri lähteistä.

Fysiologisen datan keräyksessä kaapattavien signaaleiden laatuun vaikuttavat datan siirtymävirheet sekä kehoon ja mielentilaan liittyvät tekijät, kuten mielialan vaihtelut sekä liikenopeuksien ja -trajektoreiden muutokset. Näistä syistä kehoon kiinnitetyistä antureista kerättyjen tuoreiden datavirtojen käsittely reaaliaikaisilla sovelluksilla on edelleen haasteellista. Mainittujen vaikeuksien ylittämiseksi tarvitaan tiedonhallintajärjestelmä, joka organisoii ja erittelee poimitun datan tarkoituksenmukaisten metodologioiden avulla. Fysiologiset signaalit voivat usein aktivoitua myös ylimääräisen puhumisen tai fyysisten eleiden takia. Kehoon kiinnitetyt anturit saattavat lähettää epäselviä signaaleja tai jopa kadottaa ne. Näissä tapauksissa liikkeenkaappaus on yleensä suoritettava uudestaan, mikä saattaa turhauttaa liikkujaa ja vääristää tuloksia.

Viimeisimmällä teknologialla kehitettyjä sovelluksia, kuten esimerkiksi *älyvaatteita* ja *-varusteita*, on mahdollista käyttää yhä enemmän lähes kaikissa esittelemissäni menetelmissä. Tekniikan kehittymisen taustalla on usein viihdeteollisuuden tarpeet ja ongelmien ratkaisut, joissa hyödynnetään monia viimeisimpiä suuntauksia tietokoneteknologiassa ja koneoppimisessa. Fysiologisen multimodaalidatan keräilyllä viedään tekoälyn ja robottien kehitystä eteenpäin. Älyvarusteiden ja robotiikan yhdistelmillä voidaan kehittää ihmisten terveydenhoitoa tehokkaammaksi samalla vähentäen inhimillisten virheiden mahdollisuutta. Keskittymällä kohdehenkilöiden yksilöllisiin liikepiirteisiin pyritään saamaan lihasten suorituskyvyn tuloksista entistä parempia, millä on suora vaikutus ihmisten hyvinvointiin ja terveyteen.

## Viitteet

Adsit, J. (2015) *Animation & Communication. Phenomenon of Animation: Blog 10*. <https://jadsit0221.wordpress.com/category/animation-communication/> (3.11.2019).

Alaoui, S. F., Françoise, J., Schiphorst, T., Studd, K., Bevilacqua, F. (2017) Seeing, Sensing and Recognizing Laban Movement Qualities. *Proceedings of the 2017 CHI Conference on Human Factors in Computing Systems*, ACM New York, NY, USA, 4009-4020.

Alborno, P., De Giorgis, N., Camurri, A., Puppo, E. (2017) Limbs synchronisation as a measure of movement quality in karate. *Proceedings of the 4th International Conference on Movement Computing* (toim. Niehaus, K.), ACM New York, NY, USA, artikkeli 29.

Alemi, O., Pasquier, P., Shaw, C. (2014) Mova: Interactive Movement Analytics Platform. *Proceedings of the 2014 International Workshop on Movement and Computing*, ACM New York, NY, USA, 37-42.

Aristoteles (1949) *The Works of Aristotle, vol. 5: De Motu Animalium*. Clarendon Press, Oxford, 244-275. (Saatava myös: <https://archive.org/details/worksofaristotle512aris/page/n5>, 12.10.2019)

Baptista, F., Lopes, P. F., Santana, P. (2016) MotionDesigner: Augmented artistic performances with Kinect-based human body motion tracking. *2016 23rd Portuguese Meeting on Computer Graphics and Interaction (EPCGI)*, IEEE, sessio 4.

Barakova, E. I., Lourens, T. (2010) Expressing and interpreting emotional movements in social games with robots. *Personal and Ubiquitous Computing* **14**(5), Springer-Verlag London Ltd., UK, 457-467.

BioRadio (2019) *Mobile & Wireless ECG Systems*. WWW-sivusto, <https://glneurotech.com/bioradio/physiological-signal-monitoring/wireless-ecg-measurement-analysis-teaching/> (1.11.2019).

Bouchard, D., Badler, N. I. (2015) Segmenting motion capture data using a qualitative analysis. *Proceedings of the 8th ACM SIGGRAPH Conference on Motion in Games*, ACM New York, NY, USA, 23-30.

Brotkin, E. (2010) *Optisen liikkeenkaappauksen käyttö hahmoanimoinnissa*. <https://www.theseus.fi/handle/10024/15689> (16.11.2019).

Caputo, M., Denker, K., Dums, B., Umlauf, G. (2012) 3D Hand Gesture Recognition Based on Sensor Fusion of Commodity Hardware. *Mensch & Computer 2012: 12. fachübergreifende Konferenz für interaktive und kooperative Medien, interaktiv informiert - allgegenwärtig und allumfassend!?* (toim. Reiterer, H., Deussen, O.), Oldenbourg Verlag, München, Saksa, 293-302.

Chatterjee, C. C. (2019) *Implementation of RNN, LSTM, and GRU*. <https://towardsdatascience.com/implementation-of-rnn-lstm-and-gru-a4250bf6c090> (12.10.2019).

Chaves, T., Figueiredo, L., Da Gama, A., De Araújo, C., Teichrieb, V. (2012) Human Body Motion and Gestures Recognition Based on Checkpoints. *Proceedings of the 2012 14th Symposium on Virtual and Augmented Reality*. IEEE Computer Society Washington, DC, USA, 271-278.

Chi, D., Costa, M., Zhao, L., Badler, N. I. (2000) The EMOTE model for Effort-Shape. *Proceedings of the 27th annual conference on Computer graphics and interactive techniques*, ACM Press/Addison-Wesley Publishing Co. New York, NY, USA, 173-182.

Contemplas (2019) *2D motion analysis*. WWW-sivusto, [https://www.contemplas.com/2d\\_motion\\_analysis.aspx#2d\\_calibration](https://www.contemplas.com/2d_motion_analysis.aspx#2d_calibration) (13.10.2019).



- Cornelisse, D. (2018) *An intuitive guide to Convolutional Neural Networks*. <https://www.freecodecamp.org/news/an-intuitive-guide-to-convolutional-neural-networks-260c2de0a050/> (12.10.2019).
- Dash, A. K. (2019) *Feed Forward Neural Networks*. <https://iq.opengenus.org/feed-forward-neural-networks/> (12.10.2019).
- Deans, P. O’Laughlin, L. Brubaker, B. Gay, N. Krug, D. (2010) Use of Eye Movement Tracking in the Differential Diagnosis of Attention Deficit Hyperactivity Disorder (ADHD) and Reading Disability. *Psychology* **1**(4), Scientific Research, 238-246.
- Duthoit, C. J., Sztynnda, T., Lal, S. K. L., Jap, B. T., Agbinya, J. I. (2008) Optical Flow Image Analysis of Facial Expressions of Human Emotion – Forensic Applications. *Proceedings of the 1st International ICST Conference on Forensic Applications and Techniques in Telecommunications, Information and Multimedia*, ICST, Bryssel, Belgia, artikkeli 5.
- Ever (2018) *EMG sensor*. <https://hackaday.io/project/113338-pub-lys-an-open-source-biosensing-board/log/143756-emg-sensor> (3.10.2019).
- Falla, D., Rainoldi, A., Merletti, R., Jull, G. (2004) Spatio-temporal Evaluation of Neck Muscle Activation During Postural Perturbations in Healthy Subjects. *Journal of Electromyography and Kinesiology* **14**(4), Elsevier Ltd., 463-474.
- Fitshop (2019) *Garmin Premium HRM-Run sykevyö*. WWW-sivusto, <https://www.fitshop.fi/garmin-premium-hrm-run-sykevyo-ga-10997-12> (3.10.2019).
- Gmiterko, A., Lipták, T. (2013) Motion Capture of Human for Interaction with Service Robot. *American Journal of Mechanical Engineering* **1**(7), Science and Education Publishing, 212-216.
- Gramann, K., Gwin, J. T., Ferris, D. P., Oie, K., Jung, T., Lin, C., Liao, L., Makeig S. (2011) Cognition in action: imaging brain/body dynamics in mobile humans. *Reviews in the Neurosciences* **22**(6), De Gruyter, Berliini, Saksa, 593-608.

Haggard, E. A., Isaacs, K. S. (1966) Micro-momentary facial expressions as indicators of ego mechanisms in psychotherapy. *Century Psychology Series: Methods of Research in Psychotherapy* (toim. Gottschalk, L. A., Auerbach, A. H.), Meredith Publishing Company, Appleton-Century-Crofts, New York, NY, USA, 154-165.

Harvard Health Publishing (2019) *Tips to measure your blood pressure correctly*. WWW-sivusto, <https://www.health.harvard.edu/heart-health/tips-to-measure-your-blood-pressure-correctly> (12.11.2019).

Heryadi, Y., Fanany, M. I., Arymurthy, A. M. (2014) A Method for Dance Motion Recognition and Scoring Using Two-Layer Classifier Based on Conditional Random Field and Stochastic Error-Correcting Context-free Grammar. *2014 IEEE 3rd Global Conference on Consumer Electronics (GCCE)*, IEEE, 771-775.

Hänninen, V. (2018) *Tutka korvaa stetoskoopin*. <http://etn.fi/index.php/subscribe/8317-tutka-korvaa-stetoskoopin> (2.10.2019).

Indiamart (2019) *RMS 2 Channel Portable EMG Machine*. WWW-sivusto, <https://www.indiamart.com/proddetail/rms-2-channel-portable-emg-machine-13718147355.html> (3.10.2019).

Josephson, S. (2008) Keeping Your Readers' Eyes on the Screen: An Eye-Tracking Study Comparing Sans Serif and Serif Typefaces. *Visual Communication Quarterly* **15**(1-2), Taylor & Francis (Routledge), UK, 67-79.

Kaskivirta, V. (2010) *Elektromyografia (EMG)*. [http://users.jyu.fi/~peltsi/ali/opetus/hyvotek/LBIA020\\_raporttit.htm](http://users.jyu.fi/~peltsi/ali/opetus/hyvotek/LBIA020_raporttit.htm) (13.11.2019).

Khandelwal, R. (2018) *Deep Learning – Deep Belief Network (DBN)*. <https://medium.com/datadriveninvestor/deep-learning-deep-belief-network-dbn-ab715b5b8afc> (12.10.2019).

Khoshhal, K., Aliakbarpour, H., Quintas, J., Drews, P., Dias, J. (2010) Probabilistic LMA-based classification of human behaviour understanding using Power Spectrum technique. *2010 13th International Conference on Information Fusion*, IEEE.

Keskisenkello (2019) *Suunto Spartan Sport Wrist HR Blue rannesykemittari*. WWW-sivusto, <https://www.keskisenkello.fi/tuotteet/suunto-spartan-sport-wrist-hr-blue-rannesykemittari> (3.10.2019).

Krizhevsky, A., Hinton, G. E. (2011) Using Very Deep Autoencoders for Content-Based Image Retrieval. *19th European Symposium on Artificial Neural Networks, ESANN 2011*.

Kulmala, J. (2012) Liikeanalyysi valmennuksen apuvälineenä. *Terve urheilija -iltaseminaari 17.1.2012*, UKK-instituutti.

Kulmala, J. Palosaari, K. Äyrämö, S. (2014) 3D-liikeanalyysi määrittää nivelen kuorituksen. *Niveltieto* (3), 16-17.

Laban, R., Lawrence, C. F. (1947) *Effort*. Macdonald & Evans, London.

Lacquaniti, F., Maioli, C. (1989) The Role of Preparation in Tuning Anticipatory and Reflex Responses During Catching. *Journal of Neuroscience* **9**(1), Society for Neuroscience, 134-148.

Lam, W., Zou, F., Komura, T. (2004) Motion editing with data glove. *Proceedings of the 2004 ACM SIGCHI International Conference on Advances in computer entertainment technology*, ACM New York, NY, USA, 337-342.

Latulipe, C., Huskey, S. (2008) Dance.Draw: exquisite interaction. *Proceedings of the 22nd British HCI Group Annual Conference on People and Computers: Culture, Creativity, Interaction - Volume 2*, British Computer Society - Learning & Development Ltd. Swindon, UK, 47-51.

Lehtinen, A. (2014) *Liikkeenkaappauksen editointi. Case: Gonthron*. <https://www.theseus.fi/handle/10024/74526> (16.11.2019).

Lelong.my (2019) *Xbox 360 Kinect Sensor Camera Eye (Refurbished)*. WWW-sivusto, <https://www.lelong.com.my/xbox-360-kinect-sensor-camera-eye-refurbished-kbgamezone-214662414-2020-08-Sale-P.htm> (15.11.2019).

Maranan, D. S., Alaoui, S. F., Schiphorst, T., Pasquier, P., Subyen, P., Bartram, L. (2014) Designing for movement: evaluating computational models using LMA effort qualities. *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, ACM New York, NY, USA, 991-1000.

Matsuno, S., Sorao, S., Susumu, C., Akehi, K., Itakura, N., Mizuno, T., Mito, K. (2016) Eye-movement measurement for operating a smart device: A small-screen line-of-sight input system. *2016 IEEE Region 10 International Conference (TENCON)*, IEEE, 3798-3800.

Mayer, K. C. (2019) *EEG*. <http://www.neuro24.de/eeg.htm> (3.10.2019).

Medkit (2019) *KaWe Standard-Prestige light stetoskooppi, musta*. WWW-sivusto, <https://www.medkit.fi/kawe-standard-prestige-light-stetoskooppi> (3.10.2019).

Merletti, R., Parker, P. J. (2004) *Electromyography: Physiology, Engineering, and Non-Invasive Applications*. Wiley-IEEE Press, xv-xx.

Mesin, L., Joubert, M., Hanekom, T., Merletti, R., Farina, D. (2006) A Finite Element Model for Describing the Effect of Muscle Shortening on Surface EMG. *IEEE Transactions on Biomedical Engineering* **53**(4), IEEE, 593-600.

Metria Innovation Inc. (2015) *Monitoring Buildings and Structures in 3D*. WWW-sivusto, <http://www.metriainnovation.com/monitoring-buildings-and-structures-in-3d> (16.11.2019).

Metrology.News (2019) *Helios Time of Flight Camera Offers Superior Depth Precision*. WWW-sivusto, <https://metrology.news/helios-time-of-flight-camera-featuring-sonys-depthsense-technology-offers-superior-depth-precision/> (15.11.2019).

Müller, M. Röder, T. (2006) Motion templates for automatic classification and retrieval of motion capture data. *Proceedings of the 2006 ACM SIGGRAPH/Eurographics symposium on Computer animation*, Eurographics Association Aire-la-Ville, Sveitsi, 137-146.

Nakamura, T., Nagai, T., Mochihashi, D., Kobayashi, I., Asoh, H., Kaneko, M. (2017) Segmenting Continuous Motions with Hidden Semi-markov Models and Gaussian Processes. *Frontiers in Neurorobotics*, Frontiers.

<https://doi.org/10.3389/fnbot.2017.00067> (16.11.2019).

Nevid (2019) *EKG mitä. Elektrokardiografia (EKG): teorian perusteet, patologioiden poisto, analysointi, havaitseminen. Sydäninfarktin määrittäminen kardiogrammin avulla*. WWW-sivusto, <https://nevid.ru/fi/analiz-krovi/ekg-kakie-elektrokardiografiya-ekg-osnovy-teorii-snyatie/> (1.11.2019).

O'Neill Kinesiology College Blog (2019) *A Brief History of Kinesiology*. WWW-sivusto, <http://www.oneillcollege.com.au/blog/history-of-kinesiology/> (13.10.2019).

Piana, S., Coletta, P., Ghisio, S., Niewiadomski, R., Mancini, M., Sagoleo, R., Volpe, G., Camurri, A. (2016) Towards a Multimodal Repository of Expressive Movement Qualities in Dance. *Proceedings of the 3rd International Symposium on Movement and Computing*, ACM New York, NY, USA, artikkeli 10.

Polar (2019) *Mitä syke tarkoittaa?*. WWW-sivusto, <https://www.polar.com/fi/smart-coaching/what-is-heart-rate> (3.10.2019).

Pradhan, G. N., Chattopadhyay, R., Panchanathan, S. (2010) Processing body sensor data streams for continuous physiological monitoring. *Proceedings of the international conference on Multimedia information retrieval*, ACM New York, NY, USA, 479-485.

Pradhan, G. N., Engineer, N., Nadin, M., Prabhakaran, B. (2008) Analyzing motoric and physiological data in describing upper extremity movement in the aged. *Proceedings of the 1st international conference on PErvasive Technologies Related to Assistive Environments*, ACM New York, NY, USA, artikkeli 50.

Rett, J., Dias, J. M. (2007) Computational Laban Movement Analysis using probability calculus. *Workshop on Robotics and Mathematics RoboMat 2007* (toim. Araújo, H., Ribeiro, M. I.), Centro Internacional de Matemática, 217-224.

Rubik's Code (2018) *Implementation of Convolutional Neural Network using Python and Keras*. WWW-sivusto, <https://rubikscore.net/2018/03/05/implementation-of-convolutional-neural-network-using-python-and-keras/> (12.10.2019).

Salminen, E. (2019) *LG PALJASTI: TULEVA UUTUUSPUHELIN SAA TOF-ETU-KAMERAN*. <https://suomimobiili.fi/lg-paljasti-tuleva-uutuuspuhelin-saa-tof-etukameran/> (3.10.2019).

Schiphorst, T., Nack, F., Kauwatjoe, M., de Bakker, S., Stock, Aroyo, L., Rosillio, A. P., Schut, H., Jaffe, N. (2007) PillowTalk: can we afford intimacy?. *Proceedings of the 1st international conference on Tangible and embedded interaction*, ACM New York, NY, USA, 23-30.

Seide, F., Li, G., Yu, D. (2011) Conversational speech transcription using context-dependent deep neural networks. *INTERSPEECH 2011, 12th Annual Conference of the International Speech Communication Association*, ISCA 2011, 437-440.

Sentimental Flow (2017) *Optical Motion Capture System vs Kinect*. WWW-sivusto, <https://sentimentalflow.wordpress.com/2017/01/30/first-blog-post/> (3.11.2019).

Suwannarat, A., Pan-ngum, S., Israsena, P. (2018) *Comparison of EEG measurement of upper limb movement in motor imagery training system*. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6071373/> (13.10.2019).

Tang, A., Lu, K., Wang, Y., Huang, J., Li, H. (2015) A Real-Time Hand Posture Recognition System Using Deep Neural Networks. *ACM Transactions on Intelligent Systems and Technology (TIST) - Special Section on Visual Understanding with RGB-D Sensors* **6**(2) (toim. Liu, H.), ACM New York, NY, USA, artikkeli 21.

Tilmanne, J., D'Alessandro, N. (2015) Motion machine: A new framework for motion capture signal feature prototyping. *2015 23rd European Signal Processing Conference (EUSIPCO)*, IEEE, 2401-2405.

Tits, M., Tilmanne, J., D'Alessandro, N. (2016) A Novel Tool for Motion Capture Database Factor Statistical Exploration. *Proceedings of the 3rd International Symposium on Movement and Computing*, ACM New York, NY, USA, artikkeli 2.

Wan, C. K. (2014) *Body Area Network (BAN)*. <https://smartcitynetworks.wordpress.com/author/charliekw93/> (8.10.2019).

Wang, L., Buchanan, T. S. (2002) Prediction of Joint Moments Using a Neural Network Model of Muscle Activations from EMG Signals. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* **10**(1), IEEE, 30-37.

Weber, C. O. (2019) *Proper Technique for Blood Pressure Measurement*. <https://www.verywellhealth.com/proper-technique-for-blood-pressure-measurement-1763966> (12.11.2019).

Xia, L., Chen, C., Aggarwal, J. K. (2012) View invariant human action recognition using histograms of 3D joints. *2012 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, IEEE, 20-27.

Xing, T., Yu, Y., Zhou, Y., Du, S. (2012) Markerless Motion Capture of Human Body Using PSO with Single Depth Camera. *Proceedings of the 2012 Second International Conference on 3D Imaging, Modeling, Processing, Visualization & Transmission*, IEEE Computer Society Washington, DC, USA, 192-197.

Yaremchuk, V., Wanderley, M. M. (2014) Brahms, Bodies and Backpropagation: Artificial Neural Networks for Movement Classification in Musical Performance.

*Proceedings of the 2014 International Workshop on Movement and Computing,*  
ACM New York, NY, USA, 88-93.