

**MÄKIHYYPYN PONNISTUSVAIHEEN BIOMEKANIikka HAHMON ASENNON
TUNNISTAMISEEN PERUSTUVALLA LIIKEANALYYSILLÄ**

Lauri Virtanen

Biomekaniikan Pro gradu -tutkielma

Liikuntatieteellinen tiedekunta

Jyväskylän yliopisto

Kevät 2021

Työn ohjaajat: Jarmo Piirainen

Neil Cronin

TIIVISTELMÄ

Virtanen, L. 2021. Mäkihyppyn ponnistusvaiheen biomekaniikka hahmon asennon tunnistamiseen perustuvalla liikeanalyysillä. Liikuntatieteellinen tiedekunta, Jyväskylän yliopisto, Liikuntateknologian pro gradu -tutkielma, 85 s.

Mäkihyppy on Suomessa perinteikäs laji, jossa on totuttu kansainväliseen menestykseen arvokisoissa. Mäkihyppyä on tutkittu jo 1900-alkupuolelta alkaen ja vilkkain tutkimusaikakausi sijoittuu vähän 2000-luvun molemmiin puoliin. Mäkihyppysuoritus jakaantuu neljään vaiheeseen: ylämäen vauhdinottoon, ponnistukseen, ilmalentoon sekä alastuloon. Eniten lienee tutkittu ponnistusta, sillä se nähdään hypyn pituuden kannalta kaikkein kriittisimpänä.

Tyypillisesti ponnistuksesta tutkitaan liikkeen ajoitusta, nivelkulmia ja kulmanopeuksia, hyppääjän nopeutta, voiman tuottoa, lihasaktivaatiota ja hyppääjään kohdistuvia voimia. Perinteinen liikeanalyysi ei sovellu mäkihyppyyn. Se on operatiivisesti raskasta ja markkereiden kiinnittäminen pukuun aiheuttaa epätarkkuutta tuloksiin ja riskejä hyppääjälle. Tämän Pro gradu -tutkielman tarkoituksena oli selvittää koneoppimiseen perustuvan sovelluksen AlphaPosen ja sen päälle rakennetun sovelluksen suoriutumista ponnistusvaiheen analyysistä, kun vertailtavana menetelmänä oli perinteinen kuva kovalta tehty analyysi.

Tutkimus suoritettiin Vuokatissa K-100 mäestä syyskuussa 2020, jossa videoitiin kahdeksan (15-26-v.) yhdistetyn urheilijan suorittamat 40 hyppyä. Tilastolliseen vertailuun tehtiin 10:lle ponnistukselle ICC testi (N=376) osoitti erinomaista toistettavuutta sekä lantio- (ICC: 0.988, 95% CI[0.984,0.991]), polvi- (ICC: 0.982, 95% CI[0.898,0.993]) että säärikulmille (ICC: 0.936, 95% CI[0.911,0.952]). Ylävartalonkulman osalta tuloshajontaa esiintyi merkittävästi (ICC:0.889, 95% CI[0.506,0.955]). Korrelaatioanalyysi osoitti erittäin vahvan korrelaation lantio- ($r_s=0.975$, $p=0.000^{***}$), polvi- ($r_s=0.931$, $p=0.000^{***}$) ja ylävartalokulman ($r_s=0.882$, $p=0.000^{***}$) sekä vahvan korrelaation säärikulman ($r_s=0.882$, $p=0.000^{***}$) osalta. AlphaPose yliarvioi ylävartalo- ja aliarvioi polvikulmaa laskun loppuvaiheessa. Parillinen t-testi osoitti hyvän vastaavuuden menetelmien välillä ponnistuksen kestolle (sovellus: $M=0.269\pm0.463s$; perinteinen: $M=0.272\pm0.162s$, $p=0.831$) ja lantion kulmanopeudelle keulalla (sovellus: $M=9.319\pm1.230rad/s$; perinteinen: $M=9.417\pm1.165rad/s$, $p=0.791$).

Koneoppimispohjainen liikeanalyysi vaikuttaa lupaavalta ja operatiivisesti kustannustehokkaalta. Mittausmenetelmässä oli selkeästi havaittavissa toistettavuutta ja validiteettia monilta osin, mutta myös mittausarvojen hajontaa. Mittausasetelmaa ja mallia kehittämällä on mahdollista päästä vieläkin tarkempaan sovelluspohjaiseen analyysiratkaisuun.

Asiasanat: neuroverkot, konenäkö, hahmontunnistus, asennon arviointi, liikeanalyysi

ABSTRACT

Virtanen, L. 2021. Applicability of machine learning based motion analysis method during take-off phase in ski jumping, Faculty of Sport and Health Sciences, University of Jyväskylä, Master's thesis, 85 pp.

Ski jumping has long traditions in Finland and the country has enjoyed notable success in the history of Ski jumping events. Research work around ski jumping started in the early 20th century and the busiest era took place at the turn of the millennium. Ski jump performance is divided into in-run, take-off, flight and landing phases. Take-off might be the most actively researched topic as it is widely regarded as the most critical phase as it has the greatest effect on jump length.

Typically, researchers investigate take-off timing, joint angles, angular velocities of joint angles, the speed of a jumper, power generation, muscle activity and forces acting on the jumper from the take-off phase. Traditional motion analysis is not suitable for ski jumping due to operative costs. It is also inaccurate method as markers are difficult to place reliably on loose jump suit. This Master's thesis is about investigating how well a machine learning based AlphaPose and an analysis software built on top of it performs in a take-off analysis compared to a traditional image by image performed analysis.

Research took place in Vuokatti HS-100 hill on September 2020 where total of 40 jumps from 8 Nordic combined athletes (15-26y) were video recorded. Statistical analysis was eventually performed for 10 take-offs. ICC test (N=376) showed excellent reliability for hip (ICC: 0.988, 95% CI[0.984,0.991]), knee (ICC: 0.982, 95% CI[0.898,0.993]) and shank-ski angles (ICC: 0.936, 95% CI[0.911,0.952]). Upper body angle showed significant deviation in results (ICC:0.889, 95% CI[0.506,0.955]). Correlation analysis showed very strong correlation for hip ($r_s=0.975$, $p=0.000^{***}$), knee ($r_s=0.931$, $p=0.000^{***}$) and upper body ($r_s=0.882$, $p=0.000^{***}$) angles and strong correlation for shank-ski angle ($r_s=0.882$, $p=0.000^{***}$). AlphaPose overestimated upper body and underestimated knee angles during late in-run. Paired-samples t-test showed good equivalency for jump duration (software: $M=0.269\pm0.463s$; traditional: $M=0.272\pm0.162s$, $p=0.831$), and hip angular velocity at the time of release (software: $M=9.319\pm1.230rad/s$; traditional: $M=9.417\pm1.165rad/s$, $p=0.791$).

Machine learning based software is promising as a motion analysis method and also operatively cost effective. Reliability and validity were recognized to some extent, but some high deviation was also observed in certain parameters. By enhancing the video shooting setup and analyzing software with dedicated ski jumping training data it is very likely to find even more reliable and valid motion analysis method for ski jumping.

Asiasanat: neuroverkot, konenäkö, hahmontunnistus, asennon arviointi, liikeanalyysi

KÄYTETYT LYHENTEET

2D	Two-Dimensional, kaksiulotteinen avaruus
3D	Three-Dimensional, kolmiulotteinen avaruus
ANN	Artificial Neural Networks, neuroverkot
CAM	Content Addressable Memory, sisältöhakuinen muisti
CoM	Center of Mass, massakeskipiste
CNN	Convolutional Neural Network, konvoluutioneuroverkko
COCO	Common Objects in Context, hahmon tunnistuksessa ja asennon arvioinnissa käytetty tietosarja (kuvapankki)
CPU	Central Processing Unit, tietokoneen keskusprosessori
DNN	Deep Neural Network, syvä neuroverkko
EMG	Electromyography, elektromyografia
EMS	Electromagnetic Spectrum, sähkömagneettinen spektri
FPN	Feature Pyramid Network, hahmon tunnistusmenetelmä
FPS	Frames Per Second, videokuvan taajuus (yksikkö)
GPS	Global Positioning System, satelliittipaikannusjärjestelmä
GPU	Graphical Processing Unit, grafiikkasuoritin
HS	Hill Size, mäen koko
ICC	Intra-Correlation Coefficient, mittajaajan sisäisen toistettavuuden testi
IMS	Image Management System, kuvan prosessointijärjestelmä
IMU	Inertial Measurement Unit, inertiaalimittausyksikkö
JSON	JavaScript Object Notation, formaatti tiedon tallennukselle
JTA	Joint Track Auto, hahmon tunnistuksessa ja asennon arvioinnissa käytetty tietosarja (kuvapankki)
LPM	Local Positioning Measurement System, paikallinen paikannusjärjestelmä
LSP	The Leeds Sports Pose, hahmon tunnistuksessa ja asennon arvioinnissa käytetty tietosarja (kuvapankki)
MLE	Maximum Likelihood Estimate, suurimman uskottavuuden estimointi

MPII	Human Pose Dataset, hahmon tunnistuksessa ja asennon arvioinnissa käytetty tietosarja (kuvapankki)
MSE	Mean Squared Error, keskineliövirhe
NMS	Parametric Pose Non-Maximum-Suppression, parametrisen asennon ei-maksimin rajoitus
OMS	Optoelectric Measurement System, optoelektroninen mittausjärjestelmä
PGPG	Pose-Guided Proposals Generator, asento-ohajattu ehdottajageneraattori
R-CNN	Region-Based Convolutional Neural Networks, aluepohjainen konvoluutioneuroverkko
ResNet	Residual neural network, jäännösneuroverkko
RSME	Root Mean Square Error, neliöllinen keskivirhe
SDTN	Spatial De-Transformer Network, spatiaalinen muuntajaverkko
SPPE	Single-Person Pose Estimator, yksihenkilön asennonarvioija
SSD	Single Shot Detector, yhden laukaisun tunnistaja
SSTN	Symmetric Spatial Transformer Network, symmetrinen spatiaalinen muuntajaverkko
SVM	Support vector machine, tukivektorikone
YOLO	You Only Look Once, koneoppimisen hahmontunnistusmenetelmä

SISÄLLYS

TIIVISTELMÄ

1 JOHDANTO.....	1
2 LIIKEANALYYSI	3
2.1 Perinteiset liikeanalyysimenetelmät	3
2.2 Optoelektronisten menetelmien periaatteet	4
2.3 Perinteisten liikeanalyysimenetelmien käyttö mäkihyppy tutkimuksissa	4
3 KONEOPPIMINEN	6
3.1 Mitä on koneoppiminen?.....	6
3.2 Koneoppimisen alalajit.....	7
3.2.1 Ohjattu koneoppiminen	7
3.2.2 Ohjaamaton koneoppiminen.....	8
3.2.3 Vahvistusoppiminen	9
3.3 Neuroverkot.....	9
3.3.1 Neuroverkkojen opettaminen	11
3.3.2 Virhefunktio.....	11
3.3.3 Vastavirta-algoritmi.....	12
3.3.4 Gradientin soveltaminen neuroverkkoon.....	13
3.4 Syväoppivat neuroverkot.....	15
3.4.1 Konvoluutioneuroverkko.....	17
3.5 Hahmontunnistus.....	19
3.6 Asennon tunnistus.....	20
3.7 AlphaPose.....	24

3.7.1	AlphaPosen toimintaperiaatteet	24
3.8	AlphaPose tutkimuskäytössä	25
4	MÄKIHYPYN BIOMEKANIikka	28
4.1	Ylämäen vauhdinotto ja laskuasento	28
4.1.1	Laskun aikana hyppääjään vaikuttavat ulkoiset voimat	28
4.1.2	Hyppääjän laskuasennon merkitys hypyn pituuteen	33
4.1.3	Vauhtimäessä saavutetun nopeuden korrelaatio hypyn pituuteen	34
4.2	Ponnistus.....	35
4.2.1	Hyppääjään kohdistuvat voimat ponnistuksen aikana.....	36
4.2.2	Ponnistuksen ominaispiirteet	39
4.3	Ilmalento.....	41
4.3.1	Hyppääjään vaikuttavat voimat ilmalennon aikana.....	42
4.3.2	Ilmalennon aikaiset kinemaattiset muuttujat	43
4.4	Alastulo.....	45
5	TUTKIMUSASETELMA JA RATKAISTAVA ONGELMA	46
6	MENETELMÄT.....	47
6.1	Koehenkilöt	47
6.2	Koeasetelma.....	47
6.3	Mittausmenetelmät	47
6.4	Mittausten analysointi AlphaPosen ja analyysisovelluksen avulla	49
6.4.1	Mitattavat nivelkulmat.....	54
6.4.2	Ponnistushetki (hyppyrinkeula).....	56
6.4.3	Hyppääjän nopeus.....	56
6.4.4	Ponnistuksen kesto	57

6.4.5 Nivelen kulmanopeus	57
6.5 Mittausten analysointi perinteisellä menetelmällä	58
6.6 Tilastolliset menetelmät.....	59
7 TULOKSET.....	60
7.1 Reliabiliteetti ja korrelaatioanalyysi neljälle eri kulmamuuttujalle.....	60
7.2 Reliabiliteetti ja korrelaatioanalyysi hyppypuvun värin perusteella	63
7.3 Ponnistuksen kinemaattisten muuttujien vertailu menetelmien kesken	66
8 POHDINTA.....	68
8.1 Johtopäätökset	74
LÄHTEET	75
LIITTEET	

1 JOHDANTO

Mäkihyppy on laji, jossa urheilija pyrkii suksilla saavuttamaan vauhtimäen laskun aikana mahdollisimman suuren lähtönopeuden hyppyripöydälle, jonka kohdalla suoritettua ponnistusliikkeen kautta siirrytään lentoasentoon. Lentoasennolle on tyypillistä vahva vartalolla eteenpäin nojaaminen, jossa suksilla muodostetaan V-asento kasvattamaan urheilijan lentopinta-alaa. Pyrkimys on lentää mahdollisimman pitkälle, suorittaen hallittu alastulo. Ilmalento ja alastulo arvioidaan tuomariston toimesta tyyliarvoilla, minkä lisäksi hypyn pituudesta hyppääjä kerää pituuspisteitä. Mäkikilpailussa on kaksi hyppykierrosta ja eniten pisteitä kerännyt kilpailija voittaa.

Mäkihyppy on haastava laji, joka vaatii urheilijalta sekä erityisiä teknisiä taitoja, lajiin soveltuva kevyttä ruumiinrakennetta, että hyviä fyysisiä ja henkisiä ominaisuuksia. Fyysisten ominaisuuksien puolella korostuvat räjähtävyys, kimmoisuus, tasapaino ja reaktiokyky. Henkisistä ominaisuuksista erityisesti rohkeus ja paineensietokyky ovat keskiössä, sillä hyppääjät altistavat itsensä suurille tilannenopeuksille ja näin ollen vaaralle suoritus toisensa jälkeen. Toisaalta pitkät hypyt näyttävine ilmalentoineen kiehtovat lajiyleisöä, sillä suoritus uhmaa ihmiselle luontaista tapaa liikkua. Mäkihyppy on siinä mielessä erityinen laji, että sitä harrastetaan pääsääntöisesti vain kilpailutarkoituksessa. Lajille ominaista on myös se, että valtaosa kilpailuajasta kuluu oman suoritusvuoron odottamiseen ja henkiseen valmistautumiseen. Schwamederin (2012) mukaan suoritukseen ja odottamiseen kulutetun ajan suhde on 1:120, varsinainen hyppysuoritus kestää mäen koosta riippuen noin 6-12 sekuntia kun itse kilpailu kestää noin kaksi tuntia.

Hyppysuoritus voidaan yleisesti ottaen jakaa viiteen vaiheeseen: ylämäen vauhdinottoon, ponnistusvaiheeseen, alkuilmalennon vaiheeseen, staattiseen lentoon ja alastulovaiheeseen. Kukin vaihe vaatii urheilijalta hyvää hallintaa ja nämä vaiheet ketjuuntuvat toisiinsa siten, että epäonnistuminen yhdessä vaiheessa heijastuu muiden vaiheiden onnistumiseen. Erityisen kriittisenä vaiheena pidetään noin 0.3 sekuntia kestävästä ponnistusvaiheesta, jota lienee tutkittu kaikkein eniten. Tätä äärimmäisen tärkeää hetkeä kuvaavat suuri tilannenopeus sekä

hyppääjään kohdistuvat ulkoiset voimat: painovoima, suksien kitkavoima, noste, ilmanvastus ja kaarrelaskun aikainen keskipakovoima, joka kuitenkin nopeasti häviää hyppyripöydän loppua kohden. Hyppääjä ajoittaa ponnistuksensa pitkälti kehollisen tuntemuksensa mukaan ja sen uskotaan liittyvän keskipakovoiman häviämiseen. Epäonnistuneen ponnistuksen vaikutuksia hyppysuoritukseen on hankala korjata lentovaiheessa.

Ponnistusvaihetta on tutkittu usein perinteisen liikeanalyysin avulla, jossa hyppääjän hyppypukuun kiinnitetään heijastavia markkereita. Hyppysuoritetta on edelleen kuvattu siihen soveltuvilla videokameroilla, joilla liike on tallennettu analyysiä varten. Ongelmana menetelmässä on ollut se, että se ei sovellu hyvin päivittäiseen mäkihyppyharjoitteluun. Ensinnäkin markkereiden kiinnittämiseen kuluu hyvin paljon aikaa ja toisekseen niitä ei pysty kiinnittämään riittävän staattisesti, sillä hyppypuku liikkuu ja elää suorituksen aikana. Näin ollen tallennukseen ja analyysiin tulee liikaa virhettä mukaan. Tämä on johtanut siihen, että useimmat mäkihyppytutkimukset ja etenkin kilpailutilanteiden tutkimukset on tehty pelkästään tulkitsemalla subjektiivisesti videokuvaa.

Tämän Pro gradu -tutkielman tarkoitus oli selvittää, kuinka koneoppimiseen perustuva liikeanalyysi selviytyy mäkihypyn ponnistusvaiheen analyysistä verrattuna perinteiseen liikeanalyysimenetelmään. Koneoppimisen tuottamaa liikeanalyysitietoa verrataan 2D-analyysin tuottamaan tietoon ja arvioidaan sen luotettavuutta sekä validiteettia. Lopuksi on tarkoitus tuottaa vielä aputyökalu mäkihyppyvalmennuksen tueksi, jonka avulla voidaan tuottaa objektiivinen arvio ponnistuksesta koneellisesti.

2 LIIKEANALYYSI

Liikeanalyysillä pyritään ymmärtämään ihmisen liikettä, kaappaamalla liikesuoritus siihen soveltuvalla tekniikalla. Toisaalta liikeanalyysi auttaa liikkeen optimoinnissa, kun liikesarjasta tunnistetaan viallisia liikemalleja ja niistä oppimalla harjoitetaan suoritteeseen optimaalisia liikemalleja. Liikeanalyysiä hyödynnetään yleisesti terveysterveyden- ja kuntoutusalalla, urheilussa sekä peli- ja elokuva-alalla. Luvussa esitellään perinteisen 2D- ja 3D-liikeanalyysin toimintaperiaatteet, niiden heikkoudet ja vahvuudet. Lisäksi tarkastellaan niiden avulla tehtyjä tieteellisiä mäkihyppy tutkimuksia.

2.1 Perinteiset liikeanalyysimenetelmät

Liikeanalyysimenetelmiä käytetään yleisesti muun muassa lääketieteessä ja kuntoutuksessa, biomekaniikan tutkimuksissa, armeijan sovelluksissa sekä peli- ja elokuvateollisuudessa. Liikeanalyysimenetelmiä on kehitetty monen eri tekniikan pohjalta. Jaottelu eri teknologioiden välillä tehdään tavallisesti joukkue- ja yksilölajien perusteella sekä edelleen ulko- ja sisäliikunnan välillä. Joukkuelajeissa käytetään perinteisesti elektromagneettisia menetelmiä (EMS), esimerkiksi GPS ja LPM-tekniikoihin pohjautuvia tekniikoita (van der Kruk & Reijne 2018). Yksilölajeissa puolestaan käytetään kuvanprosessointijärjestelmiä (IMS), optoelektronisia systeemejä (OMS) sekä inertiaalimittausta (IMU) (van der Kruk & Reijne 2018). Mäkihypyssä kaikkein käytetyimmät menetelmät lienevät erilaiset optoelektronisiin järjestelmiin pohjautuneet ratkaisut, missä hyödynnetään heijastavia kehoon kiinnitettäviä markkereita liikkeen kaappaamiseen. Urheilututkimuksissa puhutaan monesti 2D ja 3D-liikeanalyysimenetelmistä niin sanottuina ”kultaisina standardeina”, sillä ne ovat yleisesti standardi menetelmä, kun lähdetään tutkimaan liikettä. 2D- ja 3D- liikeanalyysijärjestelmät ovat kaupallisia sovelluksia ja esimerkiksi Viconin menetelmää on käytetty paljon urheilututkimuksissa. Muita tutkimuksissa esiintyviä kaupallisia sovelluksia on muun muassa Optitrack, MotionAnalysis ja Qualisys. (Corazza ym. 2006; van der Kruk & Reijne 2018; Merriaux ym. 2017).

2.2 Optoelektronisten menetelmien periaatteet

Optoelektronisessa liikkeen kaappauksessa on kaksi erilaista liikkeentallennusmuotoa. Liikettä voidaan kaapata joko 2D- tai 3D-tasosta. 2D-liikkeen mallinnus on yleisesti helpompaa, sillä siinä tarvitaan vain yksi suurnopeuskamera jokaista heijastintarraa kohden. 3D-analyysissä tarvitaan vähintään 2 kameraa jokaista heijastintarraa kohden, yleisemmin kuitenkin 4 - 32 kameraa, jotta saavutetaan parempi tarkkuus. Riippuen analysoitavasta liikkeestä, tutkittavalle puetaan ylle heijastintarroja keskeisimpiin anatomisiin maamerkkeihin. Heijastintarrat voivat olla joko heijastavia (passiivinen) tai emittoivia (aktiivinen). Käytettävät kamerat ovat tyypillisesti suurnopeuskameroita, jotka kykenevät kaappaamaan 30 – 2000 kuvaa sekunnissa. (Fern'ndez-Baena, Susin & Lligadas 2012). Ennen mittaustilannetta suoritetaan kuvauslaitteiston kalibrointi. 2D-mittauksissa kamera asetetaan riittävän etäälle kuvattavasta kohteesta, sillä siinä halutaan saada tallennus mahdollisimman kohtisuoraan tapahtuvasta liikkeestä. Mikäli kuvausalue on esimerkiksi metrin mittainen alue, käytetään yleisesti kuvausetaisyysnä kuuden metrin matkaa. 3D-mittauksissa rajataan suorakulmion muotoinen kuvausalue, joka kattaa ympäröivien kameroiden kuvausalueen. Esimerkiksi Viconin web-sivuilla opastetaan juuri heidän laitteistonsa soveltuvat mitta-alueet. 3D-mittauksissa kalibrointi tapahtuu erityisellä wanda-kalibrointisauvalla, jota liikutetaan kuvauskentässä ennalta määritetyn ajan verran. Varsinaisen liikkeen kaappauksen jälkeen data puretaan siihen soveltuvalla ohjelmistolla, minkä yhteydessä siitä poistetaan ylimääräistä kohinaa ja palautetaan puuttuvien heijastintarrojen data (Fern'ndez-Baena ym. 2012).

2.3 Perinteisten liikeanalyysimenetelmien käyttö mäkihyppytutkimuksissa

Heijastintarroihin ja kameratallennukseen perustuvaa perinteistä liikeanalyysiä kutsutaan usein kultaiseksi standardiksi, sillä sitä käytetään urheilututkimuksissa usein referenssimenetelmänä, kun validoidaan jonkin toisen liikeanalyysimenetelmän tarkkuutta. Esimerkkinä tällaisesta voidaan mainita Chardonnensin ja kumppanien tutkimus (Chardonnens ym. 2012), jossa selvitettiin kiihtyvyyssensorien avulla tapahtuvaa liikeanalyysiä mäkihyppysuorituksen eri vaiheiden kestoista ja kuinka se vertautuu perinteiseen kamerapohjaiseen menetelmään. Toisaalta kamerapohjaista analyysiä on käytetty esimerkiksi Salt Lake Cityn vuoden 2002

talviolympialaisten mäkihyppykilpailussa kahteen eri tutkimukseen. Toisessa tutkittiin yksilöllisiä ilmalentotekniikoita (Schmölzer & Müller 2005) ja toisessa puolestaan alkuilmalennon aikaisia kinemaattisia muuttujia (Schwameder ym. 2005). Muista perinteisen liikeanalyysin tutkimuksista voidaan mainita esimerkiksi norjalaisten tekemä mäkihypyn liikkeenkaappaustutkimus (Gulbrandsen, Å. M. 2015). Vaikka perinteisessä liikeanalyysissä hyödynnetäänkin videoanalyysissä niin kutsuttuja heijastinmarkkereita osoittamaan nivelten sijaintia, niin niitä ei käytännössä katsoen kuitenkaan käytetä kilpailutilanteen aikana tehdyissä tutkimuksissa, sillä ne saattavat häiritä suoritusta ja ovat hitaita kiinnitettäviä. Kilpailutilanteen tutkimukset tehdäänkin usein pelkästään videokuvaa subjektiivisesti tutkimalla.

3 KONEOPPIMINEN

Koneoppiminen luokitellaan tekoälyn alakäsitteeksi. Koneoppimisessa pyritään mallintamaan jotakin käsiteltävää ongelmaa siten, että kartutetulla kokemuksella saavutetaan asiantuntijuutta. Systeemiä mallinnetaan jollakin siihen soveltuvalla algoritmilla, systeemille syötetään erilaisia arvoja ja ulostulona saadaan vastearvoja. Vastearvojen odotetaan ennustavan ilmiötä riittävän hyvällä tarkkuudella. Käytännössä koneoppimissovelluksia hyödynnetään esimerkiksi kuvan- ja kasvojentunnistuksissa, talouslukujen analytiikassa tai itseohjautuvissa autoissa.

3.1 Mitä on koneoppiminen?

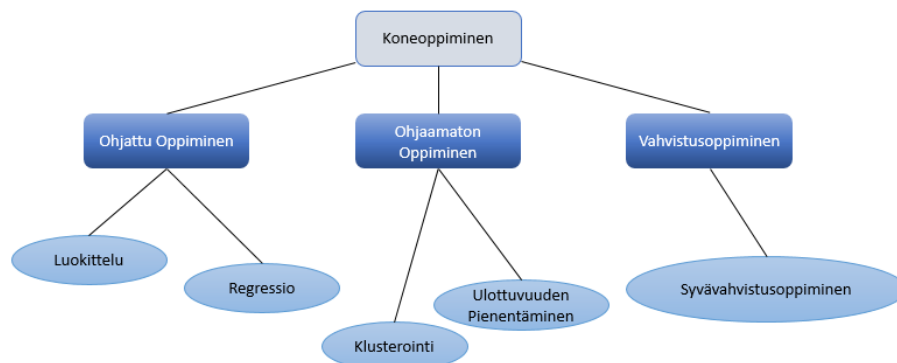
Jotta voidaan ratkaista jokin ongelma tietokoneella, tarvitaan ratkaisua varten sopiva algoritmi. Algoritmi on sarja ohjeita, joiden avulla jokin syöte saadaan muutettua tulosteeksi. Esimerkkinä mainittakoon vaikka lukujoukko, joka halutaan järjestää suuruusjärjestykseen. Syötteenä esimerkissä toimii lukujoukko ja tulosteena samaisen lukujoukon järjestäytynyt listaus. Lukujen järjestäytyminen voidaan toteuttaa useammalla eri tavalla (algoritmi) ja monesti halutaan etsiä tehokkain algoritmi. Tehokkuutta eri algoritmien välillä voidaan mitata esimerkiksi vertaamalla käytettyjen ohjeiden lukumääriä, muistinkulutuksella tai molemmilla. (Alpaydin 2010).

Toisinaan tunnetaan jonkin ongelman syöte ja vaste, mutta ei tunneta varsinaista algoritmia, joka kyseisen ongelman ratkaisee. Esimerkkinä tällaisesta voidaan mainita tilanne, jossa pyritään vaikka röntgenkuvia tulkitsemalla luokittelemaan löydös syöpäkasvaimeksi tai hyvälaatuiseksi löydökseksi. Tämän tunnistamisen toteuttaminen automaattisesti vastaa koneoppimisongelmaa. (Alpaydin 2010). Kun sähköpostin vastaanottaja vastaanottaa tuhansia sähköposteja, algoritmit alkavat kokemuksen karttumisen myötä huomata roskaposteiksi luokitelluista sähköposteista tiettyjä samankaltaisuuksia. Niissä voi esiintyä esimerkiksi tietynlaisia sanoja tai lauserakenteita. Näin ollen menetelmä oppii ja tarkentuu kaiken aikaan enemmän, kun lähdemateriaalin määrä kasvaa. (Mechelli & Vieira 2020). Koneoppimisella tarkoitetaan käytännössä mittausdatan kautta kokemukseen perustuvia koneellisia menetelmiä, joilla pyritään parantamaan jonkin asian suorituskykyä tai ennustamisen tarkkuutta.

Tietomäärän ollessa riittävän suuri, algoritmit oppivat datan käyttäytymisen ja pystyvät tämän avulla ennustamaan tulevien mittaustietojen osalta suoriutumiskykyä tai tekemään älykästä analyysiä tapahtumasta. (Mohri, Rostamizadeh & Talwalkar 2018). Käytännön tasolla koneoppimista sovelletaan esimerkiksi konenäössä, tekstin- ja äänen tunnistamisessa, erilaisissa hakukoneissa, osakemarkkina-analyyseissä, tietokonepeleissä, lääketieteellisessä sairauden diagnostiikassa ja robotiikassa.

3.2 Koneoppimisen alalajit

Koneoppiminen voidaan jakaa alalajeihin, joista ohjattu ja ohjaamaton koneoppiminen ovat yleisimmät alalajit. Muita tunnistettuja alalajeja ovat muun muassa puoliohjattu oppiminen (engl. Semi-supervised learning) ja vahvistusoppiminen (engl. Reinforcement learning). Koneoppimisen alalajit on havainnollistettu kuvassa 1.



KUVA 1: Koneoppimisen jaottelu alalajeihin. Mukailtu (Lai 2020).

3.2.1 Ohjattu koneoppiminen

Ohjattu koneoppiminen (engl. Supervised learning) viittaa menetelmään, jossa pyritään suuren opetusdatamäärän avulla luomaan tutkittavasta asiasta funktio, jonka avulla voidaan ennustaa ja luokitella aineistoa. Toisin sanoen, kun tunnetaan jonkin syötejoukon ominaisuudet eli luokittelijat näytekohtaisesti ja osataan luokitella näytteet niiden mukaisesti, voidaan kehittää yleinen malli, jolla ennustaa ja luokitella tulevaisuuden tapahtumia. Toisaalta voidaan myös

määrittää ne ominaispiirteet, jotka ovat merkityksellisimpiä luokittelun kannalta. (Shameer ym. 2018). Käytännön esimerkkinä ohjatusta luokittelusta voidaan mainita sähköpostien älykäs tunnistaminen ja luokittelu joko roskapostiksi tai hyödylliseksi postiksi tai vaikkapa sovelluksen automaattinen kasvojen tunnistus. Kasvoilla on yleisesti tiettyjä piirteitä ja samankaltaisuuksia ja kuvat eivät lopulta ole täysin satunnaisia joukkoja pikseleitä. (Alpaydin 2010).

Ohjattu koneoppiminen jakaantuu kahteen eri alalajiin riippuen siitä voidaanko opetusdata luokitella ominaisuuksien perusteella eri ryhmiin (luokittelu) vai onko opetusdata luonteeltaan jatkuvaa (regressioanalyysi). Luokittelutyypistä mainittiin käytännön sovellutuksia jo edellä roskapostisuodatuksen ja kasvontunnistuksen myötä. Regressioanalyysi eroaa luokittelevasta koneoppimismallista siten, että systeemin tuottama vaste on jatkuva-arvoinen muuttuja. (Alpaydin 2010). Esimerkkinä regressioanalyysistä voisi mainita esimerkiksi systeemin, joka pyrkii ennustamaan keihäänheittäjän heiton pituuden perustuen valittuihin muuttujiin.

3.2.2 Ohjaamaton koneoppiminen

Ohjaamaton koneoppiminen (engl. Unsupervised learning) poikkeaa ohjatusta oppimisesta siinä, että systeemiin syötettyä dataa ei ole luokiteltu ennalta. Idea toimii siten, että algoritmi koittaa itse selvittää ja hakea syötejoukosta yksilöitä, joilla on suuri samankaltaisuuden aste ja koittaa sen perusteella tehdä tarvittavan jaottelun ja ryhmittelyn. (Shameer ym. 2018). Tämä on ohjaamattoman oppimisen vahvuus, koska siinä ei tarvitse tehdä työlästä opetusdatan luokittelua. Toisaalta, siinä piilee ohjaamattoman koneoppimisen suurin heikkous sillä ongelman ratkaisuun sopivimman algoritmin hakeminen voi olla hankalaa. Käytännön esimerkkinä ohjaamattomasta oppimisesta voidaan mainita esimerkiksi tilanne, jossa pyritään muodostamaan suuresta ihmisjoukosta samalla tavalla käyttäytyviä ihmisryhmittymiä esimerkiksi kulutustottumuksien suhteen. (Mohri ym. 2018).


3.2.3 Vahvistusoppiminen

Vahvistettu oppiminen (engl. Reinforcement learning) perustuu palautteesta oppimiseen. Tässä mallissa kone saa suorittamistaan toimista sekä positiivista, että negatiivista palautetta ja se pyrkii muokkaamaan toimintaansa siten, että positiivisen palautteen määrä kasvaa ja negatiivisen määrä laskee, kun sille syötetään ratkaistavaksi uusia vaihtoehtoja. Vahvistettua oppimista hyödynnetään esimerkiksi robotiikassa ja itseohjautuvissa autoissa. (Niinimäki ym. 2019, 14)

3.3 Neuroverkot

Neuroverkko (engl. Artificial Neural Networks, ANN) on matemaattinen malli, jolla pyritään simuloimaan biologisen neuroverkon rakennetta ja toimintaa (Krenker ym. 2011). Neuroverkkoja on sovellettu esimerkiksi puheen tunnistukseen, geenituotantoon ja syöpäkasvainten luokitteluun (Krogh 2008). Neuroverkoille on tyypillistä niiden opettaminen suoriutumaan halutusta tehtävästä erityisen opetusdatan avulla. Menetelmä jäljittelee ihmiselle tyypillistä tapaa oppia kokemuksen kautta ja suoriutua tehtävästä vastaisuudessa paremmin. Vaikka neuroverkot onkin käsitteenä kehitetty jo 1940-luvulla ja tutkittu laajemmin 1960-luvulta asti, sen laajemmat käytännön sovellukset ovat kuitenkin odottaneet 2000-luvulle saakka. Nykyiset tehokkaat tietokoneen suorittimet ja muu tietokoneen kapasiteetti tarjoavat riittävän suuren laskentatehon neuroverkkojen käytölle. Tämän on mahdollistanut erityisesti tehokkaiden grafiikkaprosessorien (engl. Graphical Processing Unit, GPU) kehittyminen, sillä ne tarjoavat suuren laskentatehon CPU:n rinnalla. Näytönohjainvalmistaja NVIDIA on julkaissut ilmaisen CUDA-ohjelmointirajapinnan, jota hyödynnetään yleisesti koneoppimiskirjastoissa. Tehokas grafiikkasuoritin suorittaa tietokoneen suorittimen rinnalla täysin siitä riippumattomia laskutoimituksia. Kun yksi CPU ydin kykenee suorittamaan vain yhden laskentaoperaation kerralla, niin rinnakkaisoperaatiot tehostavat laskentaa huomattavasti ja suoritintehosta ei näin ollen muodostu pullonkaulaa syvien verkkojen prosessoinnille. Grafiikkasuorittimen tarjotessa moninkertaisen määrän laskentaytimiä, voi laskentateho kasvaa jopa 100-kertaiseksi verrattuna pelkkään CPU:n käyttöön. Neuroverkkojen koulutus nopeutuu suoraan suhteessa kasvavan laskentatehon mukaan. (Heino 2019).

Neuroverkoilla on samanlaiset toimintayksiköt kuin ihmisaivoillakin. Ne koostuvat siis neuroneista, jotka viestivät toisilleen lähettämällä ja vastaanottamalla signaaleja. Neuronit ovat passiivisia ja tarkkailevat vain muilta neuroneilta sisään tulevia signaaleja. Neuroverkot koostuvat ihmisaivojen tavoin tuojahaarakkeista, jotka tuovat signaalin sekä viejähaarakkeista, jotka lähettävät signaalia eteenpäin sekä näiden liittymäkohdista, eli synapseista. Viejähaarake voi liittyä useaan eri synapsiin kerralla. (Elements of AI 2021). Esimerkki yksikerroksisesta neuroverkosta on esitetty kuvassa 2.



KUVA 2: Yksikerroksisen neuroverkon toimintaperiaate (Nicholson 2021).

Neuronin toiminta koostuu kolmesta vaiheesta: kertolaskusta (engl. multiplication), yhteenlaskusta (engl. summation) ja aktivaatiosta (engl. activation). Neuronin ottaa vastaan ja prosessoi painokertoimilla painotettuja syötteitä. Yhteenlaskun vaiheessa nämä painokertoimin varustetut syötteet muodostavat summafunktion, jonka perusteella neuronin tekee vielä yhden laskutoimituksen, jossa se soveltaa niin kutsuttua aktivaatiofunktioita. (Krenker ym. 2011). Aktivaatiofunktio voi olla tyypiltään esimerkiksi identiteettifunktio, porraskäyrä, sigmoidifunktio, softmaxfunktio tai ReLu-funktio (engl. Rectified Linear Unit). Identiteettifunktio tulostaa summafunktion sellaisenaan ja ei tee muuta. Porraskäyrä puolestaan lähettää pulssin, jos summafunktio on positiivinen ja ei lähetä pulssia summafunktion ollessa nolla tai pienempi. Sigmoidifunktio on puolestaan jatkuva ja pehmeäreunainen porraskäyrä, joka palauttaa arvoja 0 ja 1 väliltä. (Elements of AI 2021), (Nicholson 2021). ReLu-funktio saa verkkoon aikaan epälinearisuutta, se ei ole derivoituva nollassa ja sen arvo on 0 negatiivisilla arvoilla (Tuominen 2019, 23-55). Softmax-funktio

on kombinaatio useasta sigmoidifunktiosta ja sitä käytetään useamman luokan luokittelutehtävissä (Sharma ym. 2020).

3.3.1 Neuroverkkojen opettaminen

Koneoppimismalliin sovelletaan tietoaineistoa siten, että se jaetaan kolmeen osajoukkoon: opetus-, validointi- ja testijoukkoon. Yleensä hyvän käytännön mukaan, tämä tapahtuu vastaavassa suhteessa 80%, 15% ja 5% osiin (Heino 2019). Opetusaineistolla pyritään ensi alkuun kouluttamaan käytössä oleva koneoppimismalli siten, että se osaa luokitella sille vastaisuudessa annetut syötteet oikein tai vastaavasti ennustaa jotakin tapahtumaa riittävän suurella todennäköisyydellä oikein. Opetuksen tarkoituksena onkin saada malli toimimaan riittävän tarkasti. (Heino 2019; Niinimäki ym. 2019, 17). Mallin suoriutumista seurataan vertaamalla neuroverkon tuottamaa vastetta ennalta määritettyyn tavoitearvoon. Mallin tuottaman virheen suuruus määritetään erityisen virhefunktion avulla. Virhefunktiota koitetaan minimoida opettamisen aikana ja piilokerrosten parametreja säädetään paremmiksi vastavirta-algoritmin avulla. (Tuominen 2019, 40). Validointijoukolla pyritään tarkistamaan opetetun mallin toiminnallisuus ja varmistamaan, ettei niin sanottua ylisovittumista (engl. Overfitting) pääse tapahtumaan. Ylisovittumista pääsee syntymään tilanteessa, jossa validointiaineisto on ollut osana opetusaineistoa. Ylisovitus tekee mallista näin ollen huonosti soveltuvan älykkääseen päättelyyn. Yksi hyvin yleinen tapa mallin validoinnille on käyttää niin sanottua k-kertaista ristiinvalidointia (engl. k-fold cross-validation), jossa lähdeaineisto jaetaan k:hon yhtä suureen aineistoon. Aineistosta yksi osa toimii kerrallaan validointiaineistona ja loput opetusaineistona ja vuoroa kierrätetään osajoukkojen läpi k kertaa siten, että jokainen osajoukko toimii kertaalleen validointijoukkona. Mallin toimivuus määritetään lopulta validointikertojen keskiarvosta. Lopulta malli testataan vielä muusta aineistosta erilleen irrotetulla testiaineistolla. (Niinimäki ym. 2019, 17).

3.3.2 Virhefunktio

Virhefunktiosta (engl. Error function) käytetään lähteestä riippuen myös termejä kustannusfunktio (engl. Cost function) ja tappiofunktio (engl. Loss function). Neuroverkkojen

opettaminen on optimointiprosessi, jossa kouluttamisen apuna käytetään vastavirta-algoritmia, joka puolestaan vaatii toimiakseen virhefunktion. Virhefunktion tarkoituksena on siis ilmaista, kuinka hyvin neuroverkko kulloinkin toimii sen hetkisillä painokertoimilla. (Brownlee 2019). Neuroverkon opettamisessa on tärkeää, että pieni neuronien painokertoimien muuttaminen aiheuttaa vain pienen muutoksen verkon ulostulossa (Tuominen 2019, 51). Tavoitteena voi olla joko virhefunktion maksimointi tai minimointi. Neuroverkoissa etsitään tyypillisesti virheen minimiä, jolloin puhutaan tappiofunktion tai kustannusfunktion minimoinnista. (Brownlee 2019).

Virhefunktion valinta voi olla monimutkainen tehtävä. Suurimman uskottavuuden estimaatti (engl. Maximum Likelihood Estimate, MLE) on viitekehys, jonka avulla voidaan valita mallille sopiva virhefunktio. Virhefunktio arvioi sen, kuinka hyvin koneoppimismallin tuottamien ennustearvojen jakauma vastaa opetusjoukon vastearvojen jakaumaa. MLE:n hyvyys painokertoimien laskemisessa tulee esille opetusdatan määrän kasvaessa. Kun relevantin opetusdatan määrä kasvaa, myös mallin parametrit tarkentuvat opetettaessa. MLE:tä käytettäessä, virhe kahden eri ennustejakauman välillä mitataan ristientropian virhefunktiolla (engl. Cross-entropy). Perinteisessä luokitteluasettelmassa on yksinkertaisimmillaan syötteellä kaksi mahdollista vasteluokkaa. Toisin sanoen, voidaan ajatella ennustettavan todennäköisyyttä sille, että syötearvo kuuluu vastearvon ensimmäiseen luokkaan. Todennäköisyys tällaiselle tapahtumalle on väliltä 0 ja 1. Näin ollen MLE:n avulla voidaan etsiä neuroneille painokertoimia, joilla minimoidaan mallin antamien ennusteiden ja ennalta tunnetun datasetin vasteiden jakaumien välinen erotus. Tätä kutsutaan ristientropian virhefunktioksi. Mikäli malli antaa pienen todennäköisyyden sille, että se ennustaa luokan oikein, on malli oppinut huonosti. Regressioasetelmassa on puolestaan yleistä käyttää virhefunktiona keskineliövirhettä (engl. Mean Squared Error, MSE). (Brownlee 2019).


3.3.3 Vastavirta-algoritmi

Vastavirta-algoritmia (engl. Backpropagation algorithm) hyödynnetään neuroverkkoa opetettaessa (Gershenson 2003). Sen ideana on kertoa verkolle itselleen, jos se teki ennustevirheen saamalleen syötteelle. Toisin sanoen, neuroverkko lähettää painokertoimin

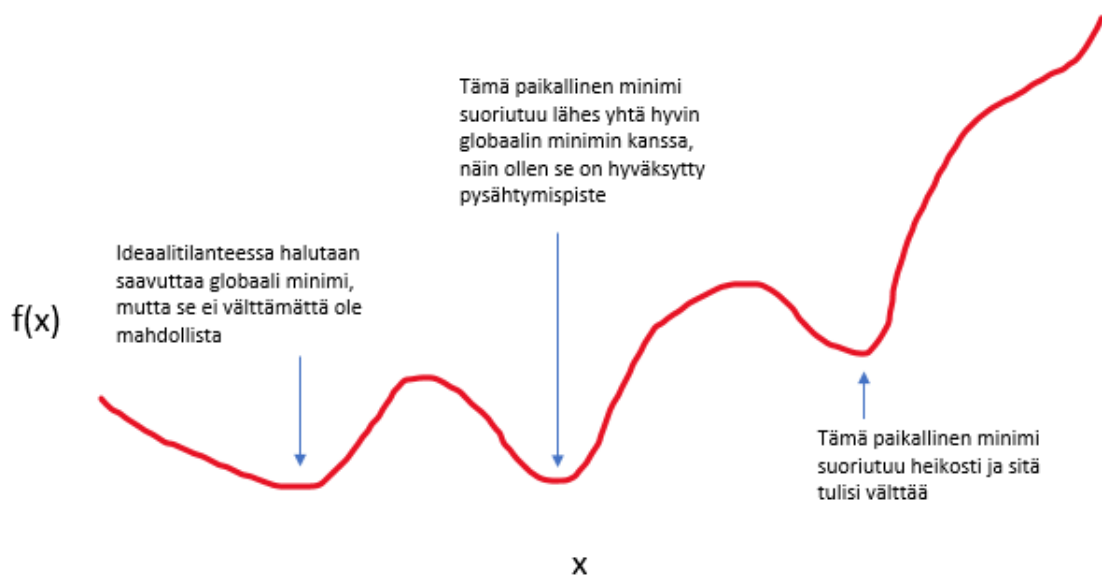
säädelyä signaalia verkon rakennetta pitkin aina kohti viimeistä kerrosta, jossa lasketaan lopulta ulostulovaste ja verrataan sitä tavoitteeseen. Mikäli laskenta osoittaa virheen tapahtuneen kerrosten välillä, lähetetään tästä tieto verkkorakenteessa taaksepäin edelliselle kerrokselle, jossa painokertoimia säädetään uusiksi virheen korjaamiseksi. (Nicholson 2021). Opetus alkaa satunnaisilla painokertoimilla ja vastavirta-algoritmin avulla niitä pyritään säätämään virheen pienenemisen suuntaan, kunnes verkko on oppinut opetusdatan (Gershenson 2003).

3.3.4 Gradientin soveltaminen neuroverkkoon

Vastavirta-algoritmi hyödyntää gradienttimenetelmää (engl. Gradient descent), jotta se osaa määrittää neuronien painokertoimien muutossuunnan virheen tapahtuessa. Gradienttimenetelmän avulla koitetaan minimoida virhefunktion arvoa. Virhefunktion derivaatta kertoo mihin suuntaan mallin parametreja pitää muuttaa, jotta päädytään edellistä pienempään arvoon ja näin ollen minimoimaan virheen suuruutta. Gradientilla voi olla monta nollakohtaa ja näin ollen paikallista minimiä, mutta yleensä vain yksi globaali minimikohta, jossa virhe saa pienimmän mahdollisen arvon. Virhefunktion derivaatan nollakohdat (kriittinen piste) eivät kerro verkolle tietoa suunnasta, johon painokertoimia tulisi säätää. Sen sijaan ne kertovat, että on mahdollisesti aika pysähtyä. Uudet painokertoimet ja vakiotermit saadaan määritettyä kun gradienttia liikutetaan virhefunktiossa nopeimman pienenemisen suuntaan. Gradienttimenetelmä on havainnollistettu kuvissa 3 ja 4. (Tuominen 2019), (Goodfellow, Bengio & Courville 2016).




KUVA 3: Gradientin (oranssilla) liikuttaminen virhefunktiolla. Mukailtu (Goodfellow ym. 2016, 81).



KUVA 4: Gradientilla voi olla useampia nollakohtia, joista toiset sopivat virheen minimointiin hyvin ja toiset huonosti. Toisinaan riittää löytää nollakohta, joka on riittävän lähellä globaalia minimiä. Mukailtu (Goodfellow ym. 2016, 83).

3.4 Syväoppivat neuroverkot

Syvillä neuroverkoilla (engl. Deep Neural Network, DNN) viitataan monimutkaisempiin ja monikerroksisiin neuroverkkoihin, joissa jokaisella kerroksella on oma erityinen tehtävänsä. Niillä käsitellään yleisesti ottaen hyvin monimutkaista dataa ja samalla suuria tietomääriä. Syväoppiminen (engl. Deep learning) tai syvät neuroverkot on koneoppimiskäsitteelle alakäsite. Kuva 5 havainnollistaa tämän paremmin.

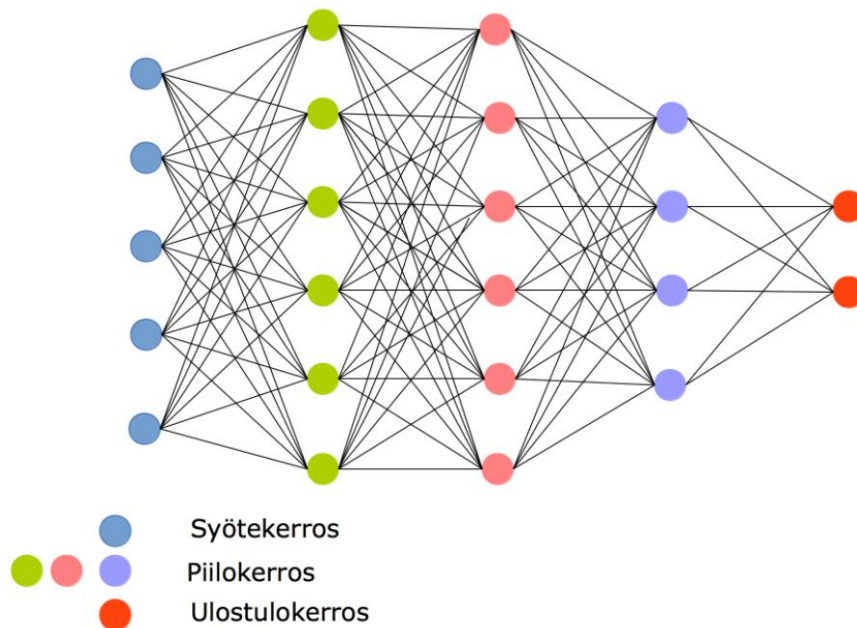


KUVA 5: Koneoppiminen on tekoälyn ja syväoppiminen koneoppimisen osa-alue. Koneoppiminen kattaa asioiden luokittelun ja ennustamisen oppimisen, perustuen käyttäjän toimintaan ja hyödynnettävään pohjatietoon. (Tuominen & Neittaanmäki 2019, 8)

Syvissä neuroverkoissa syötekerroksessa sijaitsevat ne neuronit, jotka saavat alkuperäisen syötteen, esimerkiksi kuvan. (Elements of AI 2021). Syötekerroksen neuronien lukumäärä määrittyy sen perusteella, montako piirrettä syötteestä tutkitaan (Tuominen 2019, 24). Syvän neuroverkon rakenne käsittää lukuisia piilokerroksia, jotka eivät näy käyttäjälle. Nämä piilokerrokset saavat syötteensä aina edellisen kerroksen neuroneilta ja näiden muodostama tuloste (vaste) toimii syötteenä seuraavalle neuronikerrokselle. (Elements of AI 2021). Toisin sanoen, piilo- ja ulostulokerroksien jokaisessa neuronissa lasketaan vastaanotettujen syötteiden

painotettu summa, johon lisätään mukaan neuronin vakiotermi b . Ennen eteenpäin lähetystä summasignaali viedään vielä aktivointifunktiolle, missä lineaarinen syöte muutetaan epälineaariseksi. (Tuominen 2019, 24).

Syvässä neuroverkossa viimeisenä on ulostulokerros, jossa lasketaan koko verkon summatuloste. Termi ”syvä” viittaa nimenomaan kerroksellisuuteen rakenteessa, eli mitä enemmän piilokerroksia verkossa on, sitä syvempi neuroverkko on kyseessä. Toisaalta syvyys vaikeuttaa oppimista, se vaatii suurempaa datamäärää ja näin ollen enemmän laskentatehoa, mutta onnistuessaan tuottaa hankalienkin ilmiöiden oppimista. (Elements of AI 2021). Neuroverkot ovat tyypiltään joko eteenpäin syöttäviä (engl. Feed forward) tai takaisinkytkettyjä (engl. Feedback). Eteenpäin syöttäviä neuroverkkoja käytetään esimerkiksi mallien tunnistamiseen ja luokitteluun, kun taas takaisinkytkettyjä hyödynnetään niin sanotuissa CAM-muisteissa (Content Addressable Memory). (Vähäkainu & Neittaanmäki 2017). Esimerkki monikerroksisesta syväverkosta on havainnollistettu kuvassa 6.



KUVA 6: Monimutkaisissa syvissä neuroverkoissa voi olla jopa tuhansia piilokerroksia. Tässä esimerkissä niitä on kolme. (Tuominen 2019).

3.4.1 Konvoluutioneuroverkko

Konvoluutioneuroverkkoja (engl. Convolutional Neural Network, CNN) käytetään erityisesti tehtävissä, joissa datan spatiaalisella, temporaalisella tai spatiotemporaalisella rakenteella on merkitys. Eli datan pisteellä on arvon lisäksi myös sijainti ajan- ja/tai paikan suhteen. Eräs tällainen käyttösovellus on kuvantunnistustehtävissä. Nimi juontuu piilokerroksissa tapahtuvista konvoluutio-operaatioista. Konvoluutio-operaatiot tunnistavat ja erottelevat kullakin kerrostasolla kuvista piirteitä ja ne syötetään edelleen seuraavalle neurokerrokselle syötteenä. Konvoluutioneuroverkkojen ensimmäiset kerrokset oppivat kuvista yksinkertaisia piirteitä, esimerkiksi värejä ja muotoja ja myöhemmät verkkokerrokset ymmärtävät erotella monimutkaisempia piirteitä, esimerkiksi kasvojen yksityiskohtaisia piirteitä. Konvoluutioverkko voidaan opettaa tunnistamaan vaikka henkilön kuvasta. (Heino 2019; Elements of AI 2021). Tällaisten yksityiskohtaisten piirteiden tunnistaminen kuvasta olisi hankalaa ilman konvoluutiokerroksia, sillä ne voivat esiintyä kuvassa missä tahansa paikassa tai eri kokoisina. Jotta neuroverkko kykenee tunnistamaan ja luokittelemaan kuvion kaikissa eri skenaarioissa, tarvitaan tueksi opetusdataa, jossa kohdeobjekti esiintyy mahdollisimman kattavasti eri etäisyyksiltä, eri suunnista ja eri kuvakulmista. Konvoluutio-operaatioiden ansiosta objekti voidaan havaita ja tunnistaa riippumatta sen sijainnista kuvassa. Konvoluutiokerros sijoitetaan neuroverkossa tyypillisesti ensimmäiselle tasolle, jotka käsittelevät suoraan kuvan pikseleitä. Muissa kerroksissa hyödynnetään tavallisia neuroneja. (Elements of AI 2021).

Havainnollistetaan konvoluutioneuroverkon toimintaa vielä esimerkillä, jossa neuroverkkoon syötetystä kuvasta koitetaan tunnistaa kissa. Kissan tunnistamiseksi tarvitaan ensinnäkin tieto siitä, miltä kissa näyttää ja miten se tunnistetaan. Tunnistamista varten tarvitaan datasetti, eli joukko kuvia, joissa osassa esiintyy kissoja ja osassa ei. Datasetin kissakuvien tulee sisältää kuvia erilaisista, eri värisistä ja eri kokoisista kissoista. Lisäksi lähdedatan tulee sisältää tieto siitä, esiintyykö kissaa kussakin kuvassa vai ei. Kun datasetti on koostettu, tulee sen jälkeen kouluttaa konvoluutioneuroverkko tunnistamaan kissat kuvista. Verkon painokertoimet asetetaan alkuun satunnaisesti ja verkolle syötetään opetusdatana satunnaisesti kuvia. Kuvan prosessoituaan verkko tulostaa ulostulona arvon väliltä [0-1] ja esimerkiksi arvot yli 0.5 tulkitaan kuviksi, joissa esiintyy kissa. Mikäli tunnistuksessa tapahtuu virhe, muokataan


painokertoimia siten, että pienennetään virhefunktion arvoa. Tällä tavoin pyritään parantamaan ennustetarkkuutta vastaisuudessa. Kun kaikki kuvamateriaali käydään tällä tavoin läpi, luo verkko lopulta kissan tunnistamiseen soveltuvan mallin, jossa ne pystytään tunnistamaan tietyllä tarkkuudella. Oppimisnopeutta voidaan nopeuttaa muokkaamalla alkuperäistä videota tai kuvakokoa. Kun kuvaa skaalataan pienemmäksi, tulee syvälle neuroverkolle vähemmän käsiteltävää tietoa. (Heino 2019).

Konenäön (engl. Computer vision) perimmäisenä ideana on yrittää tuottaa koneellisesti ihmiselle ominaista älyyn perustuvaa ympäristön havainnointia, ympäristön ja tilanteen ymmärtämistä sekä päätöksentekoa, joka pohjautuu edellisiin (Khan & Al-Habsi 2020). Näkeminen on ihmisille ja eläimille vaivatonta, mutta tietokoneelle se on monimutkainen tehtäväsarja. Syväoppimisalgoritmien suorituskykyä monesti havainnoidaan juuri hahmon tunnistuskyvyn kautta. (Goodfellow ym. 2016, 447). Tietokonenäköä hyödynnetään nykyään ihan joka päiväisissä sovelluksissa, muun muassa henkilön identifioivassa kasvontunnistuksessa, liukuhihnatuotannon laaduntarkkailussa tai autojen tekniikassa. Konenäkö pohjautuu perinteisiin koneoppimisongelmiin eli aluksi tulee kerätä tietoa, opettaa malli ja käyttää opetettua mallia luomaan ennusteita tuleville datasyötteille. Tietokonenäkösovellukset pohjautuvat joko ohjattuihin, ohjaamattomiin tai puoliohjattuihin koneoppimismenetelmiin.

Yleisimmin tietokonenäkösovellukset hyödyntävät syviä neuroverkkoja (konvoluutioneuroverkot), k-means algoritmia (engl. k-means algorithm), klusterointia tai tukivektorikoneita (engl. Support vector machine, SVM). Tietokonenäön viimeaikaiset sovellutukset ovat usein pohjautuneet hahmon tunnistamisongelmiin, hahmojen luokitteluun, oleellisen tiedon paikantamiseen ja keräämiseen kuvista, graafisiin dokumentteihin ja videokuviin. Internetissä on saatavilla useita avoimen lähdekoodin sovelluskirjastoja, jotka tekevät hahmon tunnistusta ja tuottavat tietokonenäköä. Yleisiä käytettyjä sovelluksia ovat muun muassa OpenPose ja AlphaPose. (Khan & Al-Habsi 2020).

3.5 Hahmontunnistus

Konenäköjakaantuu kolmeen tehtäväkokonaisuuteen: 1) kuvan luokitteluun (engl. Object classification), 2) hahmon havaitseminen (engl. Object detection) ja 3) hahmon paikantamiseen (engl. Object localization) (Jiang ym. 2018). Kuvan luokittelu on yksinkertaista, sillä kuva määrätään vain numeerisesti kuuluvan johonkin käytössä olevaan luokkaan. Hahmon paikantaminen puolestaan käsittää suorakaiteen muotoisen rajauksen (engl. Bounding box) piirtämisen yhden tai useamman hahmon ympärille. Hahmon havaitseminen on näistä haastavin ja se sisältää molemmat edellä mainitut toimenpiteet, piirtäen suorakaiteen muotoisen kehyksen jokaisen kiinnostuksen kohteena olevan objektin ympärille sekä luokittelemalla ne valittuihin luokkiin. Nämä kaikki kolme mainittua ongelmaa muodostavat yhdessä hahmontunnistamisen (engl. Object recognition). Toisinaan puhutaan myös hahmon segmentoinnista (engl. Object segmentation) yhtenä hahmontunnistuksen lisätehtävänä. Siinä tunnistetut hahmot korostetaan ja erotetaan taustasta pikselitasolla sen sijaan, että ne reunustetaan kehyksellä. (Jiang ym. 2018, Brownlee 2021). Kuvien luokittelu, hahmon paikannus ja hahmon tunnistus on havainnollistettu kuvassa 7.



KUVA 7: Hahmontunnistuksen tehtäviä (Sachan 2018).

Hahmontunnistustekniikat jakautuvat useaan eri perheeseen. Region-Based Convolutional Neural Networks (R-CNN) on joukko tekniikoita, joilla tehdään hahmon paikannusta ja tunnistustehtäviä mallin suorituskyky optimoiden. R-CNN pohjaisten tekniikoiden perhe käsittää tavallisesti sekä R-CNN, Fast R-CNN ja Faster-RCNN hahmon paikannus- ja

tunnistustekniikat. (Brownlee 2021). Nämä tekniikat pohjautuvat ajatukseen, jossa kuvista luodaan alkuun ehdotuksia hahmojen esiintymille ja lopulta ehdotemat laatikoiduista objekteista lähetetään luokittelijalle. Luokittelun jälkeen jälkiprosessointi määrittää lopulliset kehykset objektien ympärille, poistaa duplikaattikehykset ja uudelleen pisteyttää kehykset perustuen kuvan maisemassa esiintyviin hahmoihin. Prosessi on kuitenkin hidas ja vaikeasti optimoitavissa, sillä jokainen yksittäinen komponentti pitää kouluttaa erikseen. (Redmon, Divvala, Girshick & Farhadi 2016). Näiden lisäksi on myös joukko regressiomalliin pohjautuvia hahmontunnistusmenetelmiä. Näistä suosituimmat ovat YOLO ja SSD. (Sachan 2018).

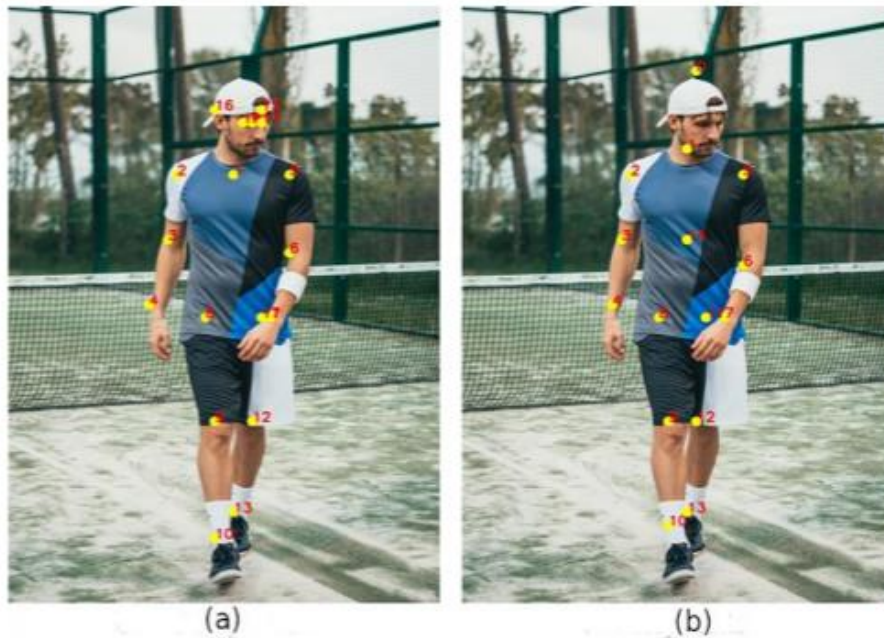
3.6 Asennon tunnistus

Asennon tunnistus (engl. Pose estimation) on tärkeä konenäön ja syvien neuroverkkojen sovellutus ja se on ollut merkittävän huomion kohteena tutkimustyössä viimeisten vuosikymmenten aikana. Asennon tunnistuksen tarkoituksena on paikantaa ihmishahmon ruumiin jäsenet kuvasta ja esittää paikannettujen avainpisteiden (engl. key point) avulla hahmo tikkumallimuodossa (Girdhar ym. 2018). Lähdemateriaalina asennon tunnistukselle käytetään kuvia ja videoita. Käytännön sovellutuksia asennon hahmotukselle on esimerkiksi erilaiset liikeanalyysit, vaikkapa sairaanhoidossa tai urheilusuorituksessa. Vaikka asennon tunnistus - algoritmit ovat kehittyneet merkittävästi viime vuosina, on niillä edelleen haasteita suoriutua esimerkiksi puutteellisen opetusdatan ja kuvien syvyystulkinnan takia. (Zheng ym. 2020).

Ihmisen asennon tunnistuksen prosessi jakaantuu kahteen vaiheeseen: 1) tunnistetaan ja paikannetaan hahmon jäsenet ja niiden avainpisteet ja 2) ryhmitellään löydetyt avainpisteet sekä kootaan niistä ihmisen tikkumallinnus, eli yhdistetään avainpisteet janoin toisiinsa. Avainpisteiden tunnistus ja paikantaminen voidaan tehdä millä tahansa julkisesti noteeratulla ja suositulla opetusdatakuvapankilla, kunhan vain opetusdatan käyttämä avainpisteiden formaatti on tiedossa. Taulukossa 1 on havainnollistettu kahden eri datasetin, COCO:n ja MPII:n tunnistamat avainpisteet ja kuvassa 8 on esimerkkinä havainnollistettu näiden tuottamat avainpistearviointit samalle kuva-aineistolle. (Munea ym. 2020).

TAULUKKO 1: COCO tietosarja tuottaa arvion 18:lle avainpisteelle ja MPIO 15:lle avainpisteelle

COCO output format	MPIO output format
Nose - 0	Head - 0
Neck - 1	Neck - 1
Right Shoulder - 2	Right Shoulder - 2
Right Elbow - 3	Right Elbow - 3
Right Wrist - 4	Right Wrist - 4
Left Shoulder - 5	Left Shoulder - 5
Left Elbow - 6	Left Elbow - 6
Left Wrist - 7	Left Wrist - 7
Right Hip - 8	Right Hip - 8
Right Knee - 9	Right Knee - 9
Right Ankle - 10	Right Ankle - 10
Left Hip - 11	Left Hip - 11
Left Knee - 12	Left Knee - 12
Left Ankle - 13	Left Ankle - 13
Right Eye - 14	Chest - 14
Left Eye - 15	
Right Ear - 16	
Left Ear - 17	
Background - 18	Background - 15



KUVA 8: Avainpisteiden sijainnit toteutettuna COCO datasetillä (a) ja MPIO datasetillä (b) (Munea ym. 2020).

Asennon tunnistuksen toisessa vaiheessa avainpisteet ryhmitellään hahmon asennoksi, josta pystytään määrittämään jäsenten parillisuudet (oikea, vasen). Esimerkki tällaisesta avainpisteiden avulla tehdystä tikkumallinnuksesta nähdään kuvassa 9.



KUVA 9: Asennon määrittäminen avainpisteiden avulla (Munea ym. 2020).

Asennon määrittäminen jakaantuu ongelmanratkaisussa sen mukaan, onko lähdeaineistossa kyseessä niin sanottu yhden hahmon asennon tunnistus (engl. Single-pose estimation) vai monihenkilön asennon tunnistus (engl. Multi-pose estimation). Yhden hahmon asennon tunnistus jakaantuu kategorisesti vielä kahteen syväoppimisongelmaan: 1) regressio-ongelmaan, jossa määritetään suoraan lähdekuvista avainpisteiden koordinaatit syväoppimisregressoreiden avulla ja 2) kehon osien tunnistamismenetelmiin, joissa ensin määritetään kehon osien avainpisteiden lämpökartat (engl. heatmap) lopulta yhdistetään lämpökartoista saadut avainpisteet tikkumahmoksi. (Zheng ym. 2020). Yhden henkilön tunnistaminen on merkittävästi helpompi tehtävä, sillä silloin ei tule kohdanneeksi henkilöiden päällekkäisiä raajoja. Toisaalta yksihahmotunnistus vaatii vähemmän tietokonelaskentaa prosessorilta. (Munea ym. 2020).

Monihenkilöasennon tunnistuksessa on kaksi syväoppimislähestymistapaa, niin sanottu ylhäältä-alas menetelmä (eng. Top-down approach) tai alhaalta-ylös menetelmä (engl. Bottom-

up approach). Ylhäältä-alas menetelmässä koitetaan tunnistaa hahmot kuvasta kokonaisuudessaan rajaamalla ne kehyksiin, jonka jälkeen niille kaikille suoritetaan yhden henkilön asennon tunnistus erikseen. Alhaalta-ylös menetelmä poikkeaa siinä suhteessa, että siinä pyritään tunnistamaan ja kehystämään kuvista raajoja ja jäseniä, jotka lopulta yhdistetään kokonaiselle hahmolle kuuluvaksi. (Zheng ym. 2020). Tämä on ajoittain kuitenkin virhealtista, sillä monihenkilökuvissa raajat saattavat tikkumallissa piirtyä toiselle henkilölle kuin oli tarkoitettu (Babu 2019).

Ylhäältä-alas menetelmillä saavutetaan yleisesti lupaavia tuloksia, sillä ne nojaavat tekniikaltaan uusimpiin hahmon- ja asennontunnistusmenetelmiin. Tosin henkilömäärän kasvaessa lähdekuvissa, ylhäältä-alas menetelmät alkavat käymään operatiivisesti raskaiksi. Lisäksi, osa taustainformaatiosta saattaa kadota kontekstin ymmärryksessä, kun alkuun tunnistetaan ja kehystetään kaikki henkilöhahmot kuvasta. (Zheng ym. 2020). Riippumatta valituista menetelmistä, asennon tunnistuksessa tunnistetaan myös yleisiä haasteita. Nämä haasteet ilmenevät esimerkiksi kunkin hahmon sijainnin ja mittakaavan määrittämisessä. Myös pimennossa olevat nivelet tai kehonosien jääminen kuvausalueen ulkopuolelle vaikeuttavat hahmon paikannusta ja asennon määrittämistä. Henkilöiden läheinen vuorovaikutus, löysiin vaatteisiin pukeutuminen tai vaikkapa taustavalaistus voivat johtaa siihen, että hahmoa ei saada tunnistettua ja avainpisteitä määritettyä. (Munea ym. 2020).

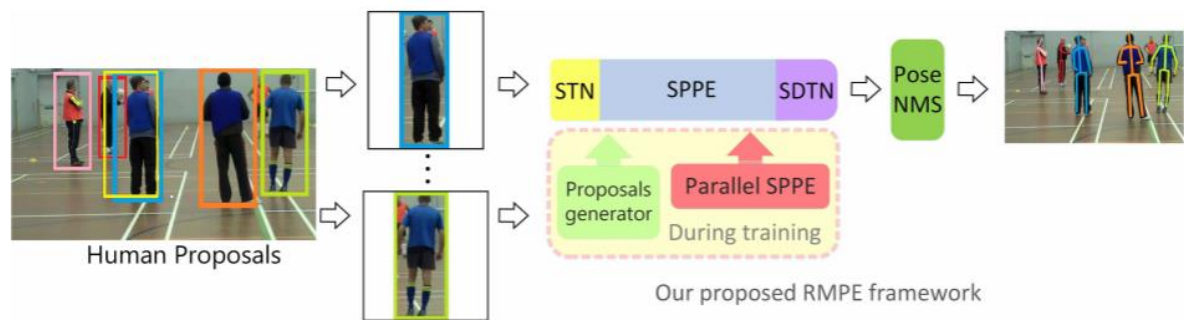
Asennon määrittämisen pääkomponentit ovat tehtävään valittu runkoverkko (engl. Backbone), jolla yleisesti viitataan valittuun neuroverkkoratkaisuun, valittu virhefunktio ja opetusdatajoukko.. Joitakin yleisesti käytettyjä runkoverkkoja ovat esimerkiksi AlexNet, R-CNN, Fast R-CNN, Faster R-CNN, FPN, Mask R-CNN, VGG ja ResNet. Asennonmäärittämissovelluksissa hyödynnetään virhefunktiona monesti joko absoluuttista keskivirhettä (engl. Mean Absolute Error, MAE), keskineliösummaa (engl. Mean Squared Error, MSE) tai ristientropian virhefunktiota (engl. Cross-Entropy loss). Asennonmäärittämissovellukset hyödyntävät usein julkisesti saatavilla olevia kuvapankkeja ja hyvin yleisesti niissä on hyödynnetty joko FLIC, LSP, MPII Human Pose ja COCO tietosarjoja. Vähemmän tunnettuja tietosarjoja ovat esimerkiksi Pascal VOC, SURREAL, HumanEva, Human3.6, CrowdPose ja JTA. (Munea ym. 2020).

3.7 AlphaPose

AlphaPose on avoimeen lähdekoodiin perustuva, ja vapaasti ei-kaupalliseen käyttöön hyödynnettävissä oleva Windows- ja Linux käyttöjärjestelmäyhteensopiva sovellus, jolla tehdään reaaliaikaisia asennon määrittämiä monihenkilömedioille (kuvat ja videot). AlphaPose pohjautuu konenäköön eli siinä pyritään ensin tunnistamaan kuvista objekteja (henkilöitä), jonka jälkeen yritetään määrittää objektien asentoja suhteessa ympäristöön. AlphaPose on rakennettu koneoppimisen ja tarkemmin ottaen neuroverkkojen päälle ja sen suorituskykyä on kokeiltu muun muassa Microsoftin COCO ja MPII tietosarjoilla (engl. dataset), joilla tapahtuu hahmojen ja objektien tunnistaminen kuvasta. Microsoftin COCO tietosarja (Common Objects in Context) on kaikkein suosituin kohteen tunnistukseen käytetty tietosarja. Se on laajasti käytetty kun vertaillaan konenäköön pohjautuvien metodien suorituskykyä. AlphaPose sovellus on ladattavissa GitHub repositoriosta (Lu ym. 2017), mutta siitä on olemassa muitakin kehityshaaroja, esimerkiksi tässä tutkimuksessa käytettävä PyTorch kehityshaaran versio (Lu, Fang & Li 2018) on johdettuversio alkuperäisestä, eli eriytetty kokonaan omaksi sovellukseksi. PyTorchin kehityshaaran versio käyttää hahmon tunnistamiseen YOLO nimistä menetelmää. PyTorch sovellusversio hyödyntää myös esiovetettyä SPPE mallia (Single-Person Pose Estimator), jolla pystytään arvioimaan tunnistetun ihmishahmon asentoja kuvista. AlphaPosen PyTorch kehityshaaran käyttämät esiovetetyt mallit ovat haettavissa internetistä nimillä yolov3-spp.weights ja duc_se.pth.

3.7.1 AlphaPosen toimintaperiaatteet

AlphaPose nojaa ratkaisussaan kaksivaiheiseen ylhäältä-alas pohjaiseen viitekehukseen ja sen toimintakaavio on esitetty kuvassa 10 (Fang, Xie, Tai & Lu 2017).



KUVA 10: AlphaPosen vuokaavio. Symmetrinen STN koostuu STN:stä ja SDTN:stä, jotka on sijoitettu ennen ja jälkeen SPPE:n. STN vastaanottaa ehdotuksia havaituista ihmisistä ja SDTN tuottaa asentoehdotuksia. Rinnakkainen SPPE toimii lisäsäännöstelijänä opetusvaiheen aikana. Lopuksi PoseNMS eliminoi redundandit asentoarviot. (Fang ym. 2017).

AlphaPosen arkkitehtuuri koostuu kolmesta pääkomponentista: symmetrisestä spatiaalisesta muuntoverkosta (SSTN, Symmetric Spatial Transformer Network), parametrisesta asennon ei-maksimaalisesta suppressioijasta (NMS, Parametric Pose Non-Maximum-Suppression) ja asento-ohjatusta ehdottajageneraattorista (PGPG, Pose-Guided Proposals Generator). Ihmisjäljittäjän (engl. Human detector) keräämät tiedot jäljitetyistä henkilöistä kehysteineen syötetään symmetriselle STN + SPPE moduulille ja tämä vaihe luo asentoehdotukset automaattisesti. SPPE pohjautuu konvoluutioneuroverkkoihin. SDTN:n (Spatial De-Transformer) rooli on yhdistää arvioidut henkilöasennot alkuperäisiin koordinaatteihin. Asentoehdotukset on edelleen jalostettu parametrinen asento-NMS:n (Pose NMS) toimesta, jotta saadaan aikaan arvioidut henkilöasennot. Havaitut asennot voivat myös sisältää monia päällekkäisiä havaintoja, joita parametrinen asento-NMS yrittää suodattaa pois. Opetuksen yhteydessä käytetään rinnakkaista SPPE:tä, jotta vältetään paikalliset minimiit ja edelleen kammetaan lisävoimaa SSTN:stä. Olemassa olevan opetusdatan määrän kasvattamiseksi AlphaPosessa käytetään asennonehdottajageneraattoria (engl. Pose-guided proposals generator, PGPG). (Fang ym. 2017).

3.8 AlphaPose tutkimuskäytössä

Asennon arviointi -menetelmien tarkkuutta ilmaistaan yleisesti käyttäen mittayksikköä mAP (engl. Mean value of average precision). Se ilmaisee keskiarvoa tarkkuudelle, jolla aineiston

luokittelu on tapahtunut. Laskennassa vertaillaan algoritmin tuottamaa ennustetta hahmon olemassaolosta ja sijainnista suhteessa ihmisenäön avulla tehtyyn paikannukseen. Mittausarvot ovat aina datasettikohtaisia ja ne riippuvat myös suorituskykylaskennassa käytetyistä erityisistä kynnysarvoista (esim. IoU, engl. Intersection over Union). Näin ollen samalla asennon arviointi menetelmällä saadaan erilaisia tarkkuustuloksia riippuen käytetystä datasetistä. (Zhao & Li 2020). Mittayksiön määrittely on sen verran laaja, että sitä ei avata tässä tarkemmin. Mittayksiköstä voi lukea esimerkiksi seuraavista lähteistä: (Everingham ym. 2010); (Cormack & Lynam 2006). Asennon arviointi -menetelmän suorituskyky on sitä parempi mitä suuremman mAP arvon se saavuttaa. Teoreettinen yläraja on 100 mAP ja yleisesti hyviä mittaustarkkuuksia on ilmoitettu AlphaPosella, joka on ensimmäisenä avoimen lähdekoodin sovelluksena yltänyt yli 70 mAP tarkkuuteen COCO datasetillä ja yli 80 mAP tarkkuuteen MPII datasetillä (Lu ym. 2017).

Asennon arviointi -menetelmien vertautuvuutta toisiinsa nähden on jonkin verran tutkittu ja AlphaPose vaikuttaisi saavan mallinnuksesta keskimäärin tarkempia tuloksia COCO datasetillä (78.6 mAP) OpenPoseen (68.2 mAP) ja Detectroniin (75.6 mAP) verrattuna. AlphaPose vertautuu myös MPII datasetillä (82.1 mAP) hyvin OpenPosen (75.6 mAP) ja Newell & Deng'n (77.5 mAP) menetelmiin nähden. (Lu ym. 2017). AlphaPose havaittiin OpenPosea tarkemmaksi myös (Carey ym. 2020) tutkimuksessa, jossa tutkittiin pistoolein aseistautuneiden henkilöiden ilmentämää uhkaa kolmen eri asennon perusteella 3700:lla kuvalla. AlphaPose-COCO systeemi onnistui luokittelussa 83.7% tarkkuudella ja AlphaPose-MPII 82.2% tarkkuudella, OpenPose-COCO systeemin saavuttaessa 77.6% luokittelutarkkuuden.

AlphaPosea ja muita vastaavia asennon arviointi -sovelluksia ja niiden vertautumista 'kultaisen standardin' mittausmenetelmiin on tähän päivään mennessä tutkittu hyvin vähän. Eräässä tuoreessa tutkimuksessa (Needham ym. 2021) selvitettiin AlphaPosen, OpenPosen ja DeepLabCutin vertautuvuutta Qualisysillä tehtyyn perinteiseen markkeripohjaiseen videoanalyysiin 15:llä henkilöllä, joista kukin suoritti 10 kävelysuoritusta, 10 juoksusuoritusta ja 10 esikevennettyä hyppyä. Asetelmassa määritettiin olka-, lantio-, polvi- ja nilkkanivelten liikeratojen eroavaisuuksia mittausmenetelmien kesken. AlphaPose ja OpenPose suoriutuivat tutkimuksessa DeepLabCut sovellusta paremmin, mutta nekään eivät yltäneet tarkkuudessa perinteisen liikeanalyysin tasolle. Tutkimuksessa havaittiin kaikilla kolmella

koneoppimissovelluksella systemaattista virhettä lantion ja polven sijaintien osalta (~30 – 50 mm), jonka ajateltiin osittain johtuvan käytetyn opetusdatan luokitteluvirheistä. Opetusdatassa ilmeni suuria virheitä nivelkeskipisteiden sijainnin tulkinnessa ja kyseisellä datalla lopulta opetettiin algoritmit. Lantion sijainti määrittyi keskimäärin lateraalis-inferiorispainotteisesti referenssimenetelmään nähden, kun polvi paikantui markkerista inferioriseen suuntaan. Nilkan sijainnin osalta systemaattinen virhe oli pienempää (1 – 15 mm ± 10 mm). Liikesuoritusten välillä paras tarkkuus oli yleisesti esikevennetyissä hyppyissä ja heikoin tarkkuus juoksussa. Syyksi tutkijat epäilivät liikkeissä esiintyvien raajojen liikelaajuutta ja raajojen liikenopeutta.

4 MÄKIHYPPYN BIOMEKANIikka

Mäkihyppysuoritus voidaan jakaa useaan vaiheeseen: laskuasentoon, ponnistukseen, ilmalentoon ja alastuloon. Ilmalennon vaihe jaetaan toisinaan myös alkuilmalennon vaiheeseen ja stabiiliin lentovaiheeseen. Vaiheet ketjuuntuvat toisiinsa ja seuraavat vaiheet ovat aina riippuvaisia aiempien vaiheiden onnistumisesta. Biomekaanisen tarkastelun avulla selvitetään kunkin vaiheen merkitystä kokonaissuoritukseen ja erityisesti hypyn pituuteen.


4.1 Ylämäen vauhdinotto ja laskuasento

Mäkihyppysuoritus alkaa vauhtimäestä, jonka alkupäässä hyppääjä istuu lähtöpuomilla. Hyppääjän irrottaessa otteensa lähtöpuomilta, siirtyy hän välittömästi staattiseen kyykkäävään laskuasentoon, jonka myötä liu'utaan vauhdinottomäessä olevaa latua pitkin hyppyripöydälle ja siirrytään edelleen ponnistusvaiheeseen. (Schwameder 2008). Vauhtimäen laskuasennon aikana hyppääjä pyrkii maksimoimaan kiihdytyksensä minimoimalla sekä kitkan suksiensa ja lumen välillä että aerodynaamisen ilmanvastuksen saavuttaakseen maksimaalisen nopeuden hyppyrin keulalla, millä on suuri vaikutus hypyn pituuteen. Ilmanvastuksen pienenemiseen vaikuttaa pääsääntöisesti hyppääjän asento ja käytetty hyppypuku. (Müller 2006). Laskuasennon tulee olla riittävän matala, jotta voidaan minimoida ilmanvastus ja näin ollen maksimoida horisontaalinen lähtönopeus. Toisaalta laskuasennon tulee olla myös riittävän korkea, jotta kyetään suorittamaan mahdollisimman nopea polven ekstensio ponnistusvaiheessa. (Schwameder 2008).

4.1.1 Laskun aikana hyppääjään vaikuttavat ulkoiset voimat

Vauhtimäen lasku koostuu suoran osan vaiheesta ja kaarrelaskun vaiheesta. Vauhtimäki päättyy tasaiseen hyppyripöytään, joka on kuitenkin noin 10° kulmassa alaspäin. (Schwameder 2008). Nämä vaiheet eroavat toisistaan erityisesti siinä, että kaarrelaskun aikana hyppääjään kohdistuu keskipakoisvoima F_C , mikä selittyy hyppääjä-suksi-kompleksin hitaudesta, eli se pyrkii vastustamaan liiketilan muutosta, mikä kaarteessa muuttuu kaiken aikaa. Virnavirran ja Komin (2001) mukaan keskipakoisvoima on suuruusluokkaa 60-70% hyppääjän painosta, kun taas

toisessa tutkimuksessa (Ettema, Braten & Bobbert 2005) pääteltiin normaalivoiman F_N kasvavan suoran osan arvosta 0.88G arvoon 1.65G kaarrelaskussa. Hyppääjään vaikuttavat voimat ylämäen laskun aikana on havainnollistettu kuvassa 11. (Janura, Cabell, Elfmark & Vaverka 2010; Schwameder 2008).



KUVA 11: Hyppääjään vaikuttavat voimat vauhtimäen suoralla osalla (a) ja kaarrelaskun aikana (b). Kaarrelaskussa alkaa hyppääjään vaikuttamaan keskipakovoima F_C . F_L kuvaa hyppääjään kohdistuvaa nostetta, F_D hyppääjään vaikuttavaa ilmanvastusta, F_G on hyppääjän painovoima, F_N hyppääjään kohdistuva kohtisuora tukivoima, F_μ kuvaa hyppääjä-suksi-kompleksin ja lumen välistä kitkavoimaa, φ kertoo hyppääjän kulman vaakatasoon nähden. Hyppääjän painopiste CoM sijaitsee ylävartalon ja etureisien välillä.

Vauhtimäen laskun aikaisia ilmanvastus- ja nostevoimia on myös arvioitu tutkimusasetelmassa tuulitunnelissa ja ilmanvastukseksi on mitattu arvoja noin 40 - 80 N, kun taas nosteeksi on mitattu arvoja väliltä 5 - 70 N (Virmavirta, Kivekäs & Komi 2001).

Hyppääjään ylämäen laskun aikana vaikuttava nettovoima voidaan määrittää kaavan 1 mukaisesti.

$$(1) \quad m \cdot a = W \cdot \sin\theta - F_\mu - F_D =$$

$$m \cdot g \cdot \sin\theta - m \cdot \mu \cdot \left(\frac{v^2}{r} + g \cdot \cos\theta\right) - \frac{1}{2} \cdot c_d \cdot \rho \cdot v^2 \cdot A_d,$$

missä m = massa, a = kiihtyvyys, v = nopeus, θ = mäen kulma, μ = lumen kitkakerroin, r = kaarteeseen säde, c_d = ilmanvastusvakio, ρ = ilman tiheys, g = gravitaatiivakio $9,81\text{m}\cdot\text{s}^{-2}$ ja A_d = liikkeen suuntaan kohtisuorassa oleva pinta-ala.

Vauhtimäen laskun suoralla osalla $r \rightarrow \infty$, joten v^2/r termi $\rightarrow 0$. Toisaalta kiihtyvyys a voidaan johtaa kaavasta 2.

$$(2) \quad a = \frac{dv}{dt} = \frac{d(v^2)}{2 \cdot ds},$$

missä s tarkoittaa kuljettua matkaa. Tästä saadaan edelleen johdettua kaava 3

$$(3) \quad \frac{d(v^2)}{ds} = 2 \cdot g \cdot (\sin\theta - \mu \cdot \cos\theta) - c_d \cdot \rho \cdot \frac{v^2}{m} \cdot A_d,$$

jonka myötä päästään ylämäen laskun nopeuden määritelmään


$$(4) \quad v = \pm \sqrt{\frac{g \cdot (\sin\theta - \mu \cdot \cos\theta) \cdot (1 - e^{-2 \cdot c_d \cdot A_d \cdot \frac{\rho}{2 \cdot m} \cdot s})}{c_d \cdot A_d \cdot \frac{\rho}{2 \cdot m}}}$$

Kaavan 4 mukaan nähdään, että hyppääjä saavuttaa suuremman nopeuden, mikäli massaa (m) kasvatetaan, kitkavakiota (μ) pienennetään ja sekä ilmanvastusta (c_d) että liikkeen suuntaista kohtisuoraa pinta-ala (A_d) pienennetään. (Janura ym. 2010).

Sen lisäksi, että hyppääjään vaikuttaa kaarrelaskun aikana suuremmat maan tukivoimat, alkaa kaarteeseen aikana vaikuttamaan myös taaksepäin suuntautuva rotaatio, eli hyppääjään kohdistuu pyörimisliikemäärää. Tämä tapahtuu, kun ilmanvastusvoima ja kitkavoima suksien ja lumen välillä kehittävät asteittain kasvavat ulkoiset voimamomentit. Koska molemmat näistä voimista kohdistuu hyppääjän painopisteen alapuolelle, saavat ne hyppääjään aikaan eteenpäin suuntautuvaa kulmakiihtyvyyttä. Vauhtimäen laskussa on erityisen vaativat kohdat, kun tullaan kaarteeseen alkuun ja kun poistutaan kaarteesta. Kaarteeseen tullessa ilmenee kasvavaa

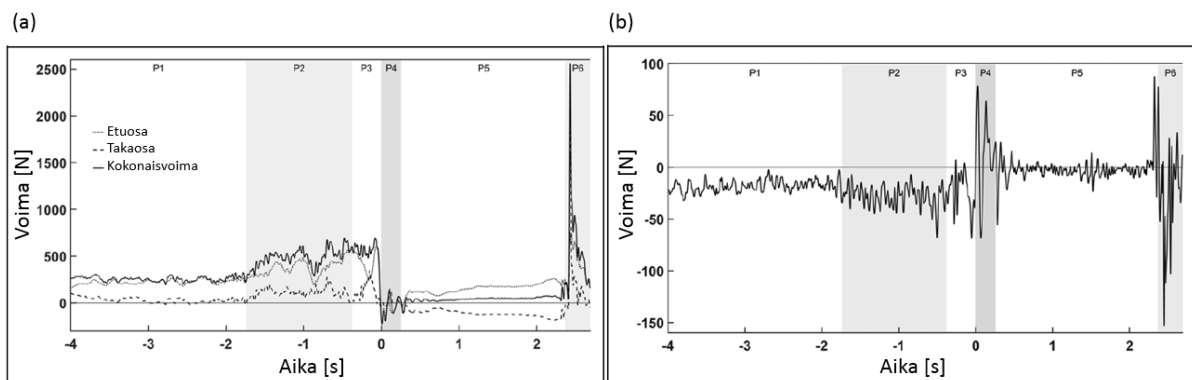
rotaatioliikettä ja kaarteesta poistuttaessa tapahtuu päinvastainen ilmiö, jolloin rotaatio täytyy yhtäkkiä pysäyttää. Kaarteen loppuminen on myös tärkeä kohta mäkihyppysuorituksessa, sillä näihin hetkiin sijoittuu ponnistusvaihe. (Ettema ym. 2005).

Hyppysuorituksen aikaisia horisontaalivoimia on tutkittu verraten hyvin vähän. Fritz ja kumppanit tekivät tutkimuksen (Fritz, Kröll, Jenny & Schwameder 2019), jossa selvitettiin hyppääjä-suksi-kompleksiin vaikuttavia voimia sekä vertikaali- että horisontaalisuunnassa koko hyppysuorituksen ajalta. He selvittivät mäkihyppyyn soveltuvan kannettavan voimamittauslaitteen JH-SJ (Herbert Jenny Static and Dynamic Measurements, Götzis, Itävalta) käytettävyyttä, tarkkuutta ja hajontaa. Molempiin suksiin kiinnitettiin kaksi identtistä, 340 g painavaa voimalevyä siteen etu- ja takaosaan. Näin ollen hyppääjän kokonaispaino kasvoi 1,36 kg verran. He saivat validoinnissa tarkkuudeksi keskiarvoeron välille -7.6 N ja -0.2 N ja RMSE:n pienemmäksi kuin 11.9 N. Keskihajonnan he saivat määritettyä 2.9 N ja 9.1 N välille. Molempien suksien vertikaalivoimien summa vauhtimäen laskun aikana on havainnollistettu kuvassa 12. Kuvasta 12 nähdään hyvin, kuinka keskipakovoima vaikuttaa tukivoimaan kaarrelaskussa.

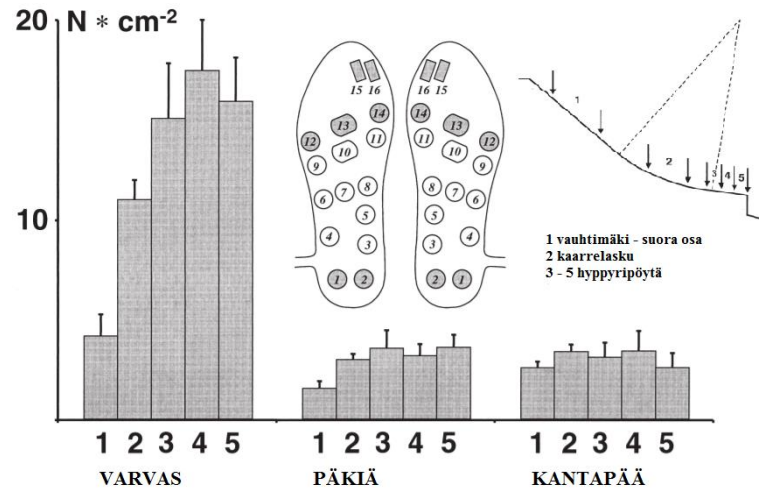


KUVA 12: Vertikaalivoimat neljän hypyn aikana. P1 = suora osa, P2 = kaarrelasku, P3 = ponnistus ja $t = 0$: irtoaminen. Mukailtu (Fritz ym. 2019).

Vauhtimäen suoralla osalla paino on enimmäkseen jalan etuosalla ja kaarrelaskussa ilmenevä keskipakoisvoima johtaa jalan etuosan vertikaalivoiman kasvuun, jolloin myös tasapainopiste liikahtaa posterioriseen suuntaan. Painopisteen liike posteriorisesti ilmenee jalan takaosan voiman kasvuna, mikä on suoralla laskusuudella lähellä nollaa. Kaarteen puolivälissä tapahtuu tyypillinen vertikaalivoimien lasku, juuri ennen ponnistuksen käynnistymistä. (Fritz ym. 2019). Virmavirta ym. (2001) tehdyssä tutkimusasetelmassa selvitettiin myös paineen jakautumista ja reaktivoimia vauhtimäen laskun aikana 16-sensorisilla painepohjallisilla kolmessa eri kokoisessa hyppymäessä (K-35 m, K-65 m, K-90 m). Tässä tutkimuksessa havaittiin myös, että paino on suoran laskun aikana aavistuksen varpailla ja kaarrelaskuun tultaessa paine jalan etuosan alla voimistuu edelleen hyppyripöydän loppua ja ponnistusta kohden. Kuvassa 13(a) on kuvitettuna oikean suksen siteisiin kiinnitetyn JH-SJ voimalevyn mittaamat vertikaalivoimat ja 13(b) horisontaalivoimat ja kuvassa 14 vertauksen vuoksi painepohjallisilla mitatut voimat vauhtimäen laskun aikana.




KUVA 13: Oikean suksen vertikaalivoimat (a) ja horisontaalivoimat (b) hyppysuorituksessa. P1 = suora osa, P2 = kaarrelasku, P3 = ponnistus, P4 = alkuilmalento, P5 = stabiili ilmalento ja P6 = alastulo. Mukailtu (Fritz ym. 2019).



KUVA 14: Keskimääräinen paineenjakauma ison varpaan, päkiän ja kantapään välillä vauhtimäen eri vaiheissa. Mukailtu (Virmavirta, Perttunen & Komi 2001).

4.1.2 Hyppääjän laskuasennon merkitys hypyn pituuteen

Hyppääjän laskuasentoa ja sen yhteyttä hyppysuoritukseen on tutkittu jonkin verran, vaikkakin se on osa-alue, johon on viimeisen parinkymmenen vuoden aikana panostettu melko vähän. Janura ym. (2010) tekivät 10 vuoden pitkittäistutkimuksen aikavälillä 1992 - 2001, jossa selvitettiin hyppääjien sääri-, polvi- ja lonkkanivelen kulmien muuttumista vauhtimäen suoran laskun aikana ja sen vaikutusta hypyn pituuteen. Mittaukset tehtiin videoanalyysin avulla Innsbruckin K-110 mäestä. Tutkimuksessa havaittiin, että laskuasento vaikuttaa hyppysuoritukseen. Tutkimuksen viimeisimpinä vuosina keskimääräinen hypyn pituus kasvoi, vaikkakin laskunopeus hidastui. Lisäksi laskun aikainen sääri- ja polvikulma pieneni, kun taas vartalokulma kasvoi tutkimusjakson loppua kohden. Lonkkanivel liikkui taaksepäin suhteessa nilkkaniveleen. Laskuasento antaa lähtökohdan ponnistustapahtumalle, mikä puolestaan on kriittinen kohta koko suorituksessa. (Virmavirta, Kivekäs & Komi 2001). Tutkimuksessa havaittiin kuvan 15 kaltainen muutos laskuasennon kehityksessä.



KUVA 15: Hyppyasennon evoluutio 1992 - 2001. Mukailtu (Janura ym. 2010).

Toisaalta myös eräässä tutkimuksessa (Schwameder, Müller, Raschner & Brunner 1997) selvitettiin laskuasennon vaikutusta ponnistuksen parametreihin simuloituilla hypyillä voimalevyllä. Tutkimuksessa havaittiin, että korkeampi laskuasento mahdollistaa lyhyempikestoisen ponnistuksen ja laskuasennon pitämisen pidempään. Toisaalta tällöin hyppääjän täytyy pitää korkeampi laskuasento koko laskun ajan. Korkeampi laskuasento mahdollistaa suuremman voimantuoton ponnistuksessa kuin matala asento, toisaalta matala laskuasento on aerodynaamisesti parempi, jolloin saavutetaan suurempi lähtönopeus hypyirin keulalle. Janura ym. (2010) ja Vaverka & Zháněl (1989) ovat todenneet, että vartalon kinemaattiset parametrit eroavat vauhtimäen suoran laskun ja kaarrelaskun osalta. Erityisesti sääri- ja polvikulmat ovat kaarteissa suuremmat ja hyppääjän massakeskipiste siirtyy taaksepäin. Schwamederin ja Müllerin tutkimuskatsauksessa (Schwameder & Müller 2001) viitataan myös samaiseen Vaverkan ja Zhánėlin tutkimukseen (Vaverka & Zháněl 1989), jonka mukaan laskuasennolla ei löydy yhteyttä lähestymisnopeuteen hypyirin keulalla ja hypypituuteen. Havaintojen mukaan parhaimmat hyppääjät kuitenkin käyttävät matalampaa laskuasentoa.

4.1.3 Vauhtimäessä saavutetun nopeuden korrelaatio hypyn pituuteen

Fysiikan näkökulmasta vauhtimäki tuottaa kokonaisnopeuden v , joka koostuu sekä horisontaalisesta laskun tuottamasta nopeuskomponentista v_0 että ponnistusliikkeen tuottamasta vertikaalisesta nopeuskomponentista v_p . Tämä voidaan ilmaista vektorimuodossa $\vec{v} = \vec{v}_0 + \vec{v}_p$. (Müller 2006; Schmölzer & Müller 2005). Horisontaalinen nopeus on mäestä ja olosuhteista hieman riippuen suuruusluokkaa noin 25 m/s (Schmölzer & Müller 2005), kun taas

hyppääjän tuottama vertikaalinopeus on suuruusluokkaa 2,5 m/s (Virmavirta, Kivekäs & Komi 2001). Hyppääjän ballististen parametrien (mm. massakeskipisteen nopeuden suuruus ja suunta) vaikutusta hypyn pituuteen on tutkittu paljon, mutta päätelmät ovat siltä osin hyvin vaihtelevia. Müller ja Schwameder mainitsevat artikkelissaan (Müller & Schwameder 2003), että joissakin tutkimuksissa (Komi ym. 1974; Schwameder & Müller 1995) on havaittu korrelaatio ballististen ominaisuuksien ja hyppypituuden välillä, kun puolestaan toisissa tutkimuksissa (Baumann 1979, Arndt ym. 1995) ymmärretään hypyn pituuden olevan enemmän riippuvaisempi aerodynaamisista tekijöistä. Korrelaatiokerroin nopeuden ja hypyn pituuden välillä vaihtelee tutkimusten välillä paljon ja taulukossa 2 on listattuna Müllerin ja Schwamederin (2003) kokoama listaus eri tutkimuksissa esitetyistä korrelaatiokertoimista.

TAULUKKO 2: Vauhtimäen nopeuden ja hyppypituuden välinen korrelaatio. Mukailtu Müller ja Schwameder (2003).

Tutkijat	Artikkeli	Korrelaatiokerroin
Hochmuth, G.	Studies of the effects of the takeoff on jump length in ski-jumping (1958/1959)	0.75 - 0.80
Virmavirta, M. and Komi, P.V.	Measurement of takeoff forces in ski-jumping Part I (1993)	0.68
Vaverka, F.	The Biomechanics of Ski-jumping (1987)	0.40 - 0.67
Schwameder, H. & Müller, E.	Biomechanische Beschreibung und Analyse der V-Technik im Skispringen (1995)	0.35
Baumann, W.	The biomechanical study of ski-jumping (1979)	0.34
Komi, P.V., Nelson, R. & Pulli, M.	Biomechanics of ski-jumping (1974)	alhainen
Arndt, A., Brüggemann, G.P., Virmavirta, M. & Komi, P.V.	Techniques used by Olympic ski jumpers in the transition from takeoff to early flight (1995)	ei merkitsevä

Toisaalta Virmavirta havaitsi tutkimusryhmänsä kanssa Torinon talviolympialaisissa vuonna 2006 suoritetussa tutkimuksessa (Virmavirta ym. 2009), että kaikkein merkittävin korrelaatio hypyn pituuteen löytyi vauhtimäen laskunopeudesta ($r = 0.628$, $p < 0.001$, $n = 50$).


4.2 Ponnistus

Mäkihypyn ponnistusvaiheessa siirrytään ylämäen kyykkäävästä laskuasennosta räjähtävän polven ekstensioliikkeen avulla ilmalentoon. Mäkihypyn eri vaiheista juuri ponnistusta pidetään yleisesti kaikkein kriittisimpänä, sillä sen uskotaan vaikuttavan eniten hypyn onnistumiseen ja pituuteen. Tämä onkin ollut kaikkein keskeisin mäkihypyn tutkimuskohde. Ponnistus määrittää lähtökohdan sitä seuraavalle ilmalentovaiheelle, sillä se vaikuttaa lähtönopeuteen, lähtökulmaan, syntyneeseen pyörimisliikemäärään ja hyppääjäsuksikompleksin asentoon. (Virmavirta ym. 2009). Ponnistuksessa on pääasiallisesti kolme

tavoitetta: horisontaali- ja vertikaalinopeuden maksimointi sekä pyörimisliikemäärän tuotto eteenpäin. Ponnistuksessa tuotettu vertikaalinopeus määrittää lentokorkeuden ja pyörimisliikemäärällä on suora vaikutus siihen, kuinka tehokkaasti siirtyminen hyvään lentoasentoon tapahtuu ja kuinka pitkälle hyppy lopulta kantaa (Komi & Virmavirta 2000, Müller, Kreibich & Seidel 2015). Ponnistuksen aikana pyritään siis nostamaan painopistettä ylemmäs sekä tuottamaan eteenpäin suuntautuvaa pyörimisliikemäärää, jota samanaikaisesti vastustaa taaksepäin suuntautuva pyörimisliikemäärä, mikä syntyy suksien ilmanvastuksesta lentoon lähdön aikana (Schwameder 2008). Tämän taaksepäin suuntautuvan vääntömomentin on kokonaisuudessaan kumottava eteenpäin tuotettu pyörimisliikemäärä. Ponnistuksen ajoitusta ja hyppyripöytään kohtisuoraan tuotettua voimamomenttia tärkeämpää on pyörimisliikemäärän optimointi, mikä tekee ponnistuksesta vaikean suorituksen. (Schmölzer & Müller 2005) Tehokkaasti suoritettu ponnistus on kestoaltaan vain noin 300 ms (Schwameder & Müller 1995) ja näin ollen se vaatiikin hyppääjältä erityisiä neuromuskulaarisia ominaisuuksia (Komi & Virmavirta 2000). Ponnistuksen aikana hyppääjä liikkuu keskimäärin noin 7,1 metrin matkan. Tämä tarkoittaa samalla sitä, että ponnistus aloitetaan jo ennen hyppyripöytää, tarkemmin ottaen kaarrelaskun loppuvaiheilla. Ponnistuksen alkuhetkeen kytkeytyy yleisesti keskipakovoiman katoaminen. Kinemaattisesti muutokset tapahtuvat erityisesti lonkka- ja polvinivelen kulmissa. (Komi & Virmavirta 2000). Jotta hyppääjä pystyy maksimoimaan ponnistuksella saavutetun korkeuden, tulee painopisteen sijaita samalla vaikutussuoralla hyppääjään vaikuttavan maan reaktivoiman kanssa. Pyörimisliikemäärän syntyminen eteenpäin vaatii painopisteen sijaitsemisen linjan etupuolella. (Arndt ym. 1995).

4.2.1 Hyppääjään kohdistuvat voimat ponnistuksen aikana

Ponnistuksen avaintekijöitä ovat hyppääjään kohdistuvien voimien suuruus ja suunta. Vertikaalinopeuden muutos on suoraan verrannollinen vertikaalisuuntaiseen voimaan ja näin ollen kohtisuora hyppyripöytään kohdistuva voima tulisi saada maksimoitua ponnistuksessa. Koska hyppääjään vaikuttaa sekä painopisteen läpi suuntautuva translaatiovoima että eteenpäin rotatoiva liikemäärä, vaikuttaa hyppääjän painopisteen taakse suuntautuva resultanttivoima. Tämä resultanttivoima syntyy normaali- ja kitkavoiman myötä. Kitkavoima on kuitenkin vähäinen pienen kitkakertoimen vuoksi. Voimat on havainnollistettu kuvassa 16.



KUVA 16: Resultanttivoima (F) translaatiovoiman (F_t) ja rotatoivan voiman (F_r) summana. a = rotaatiovoiman voimanvarsi suhteessa painopisteeseen, d = resultanttivoiman voimanvarsi suhteessa massakeskipisteeseen (Schwameder 2008).

Ajan funktiona vaikuttava translaatiovoima (F_t) määrittää lineaarisen liikemäärän (Δp) muutoksen ja edelleen vertikaalisen nopeuden kasvun kaavan 5 mukaan.

$$(5) \quad \Delta p = \int F_t(t) dt$$


Pyörimisliikemäärään pätee puolestaan kaava 6, missä rotaatiovoiman (F_r) ja sen voimanvarren (a) tai vastaavasti resultanttivoiman ja sen voimanvarren (d) tulo määrittää muutoksen ponnistuksen aikana.

$$(6) \quad \Delta L = \int (F_r(t) \cdot a(t)) dt = \int (F(t) \cdot d(t)) dt$$

Kuva 16 havainnollistaa hyvin sen, kuinka massakeskipisteen sijainnilla suhteessa resultanttivoimaan on paljon suurempi merkitys rotaatiovoiman komponenttiin kuin translaatiovoiman komponenttiin. (Schwameder 2008). Mikäli eteenpäin tuotettu pyörimisliikemäärä jää liian pieneksi, seuraa siitä epäedullinen lentoasento, mikä edelleen vähentää horisontaalinopeutta ja vaikuttaa hypyn pituutta lyhentävästi. Vielä haitallisempaa on pyörimisliikemäärän ylituotto, sillä se on vaarallista ja kasvattaa ylikuperkeikan riskiä. (Müller 2006). Erään tutkimuksen mukaan (Schwameder & Müller 1995) eteenpäin kiertyvä momentti saa keskimäärin arvoja 66 ± 10 Nm ja pyörimisliikemäärä 19 ± 3 Nms. Eteenpäin suuntautuvaa pyörimisliikemäärää voidaan mitata olkapään ja polvinivelen muodostaman linjan ja


horisontaalitasen välisen kulman pienenemisen nopeudella. Tätä kulmaa on nimitetty myös kuperkeikkakulmaksi (somersault angle). (Arndt ym. 1995).

Pyörimisliikemäärän summa ajan funktiona on havainnollistettu kuvassa 17.



KUVA 17: Ponnistuksen aikainen kokonaispyörimisliikemäärä (musta) ajan funktiona muodostuu eteenpäin suuntautuvan pyörimisliikemäärän (harmaa) ja taaksepäin suuntautuvan pyörimisliikemäärän (katkoviiva) summasta (Schwameder 2008).

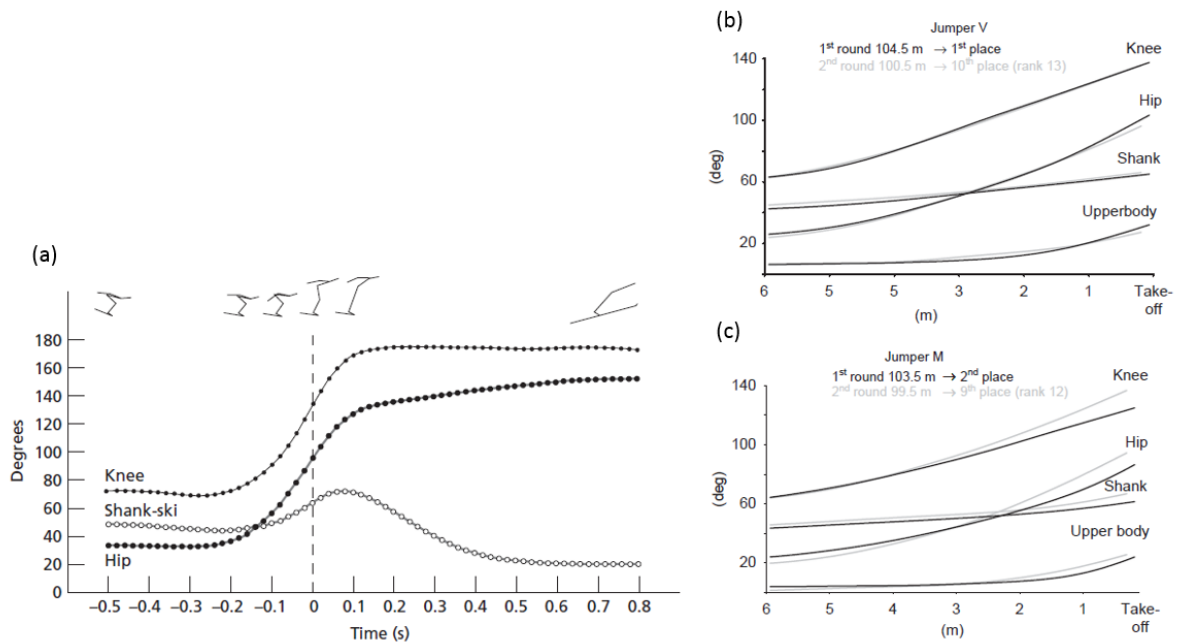
Ponnistuksen aikaisissa reaktivoimissa erottuu tyypillisesti kaksi huippua, joista ensimmäinen on yleisesti hieman suurempi arvoltaan. Esimerkiksi Calgaryn talviolympialaisissa 1988 mitattiin K-70 metrin mäestä arvoja 1795 ± 177 N (Virmavirta & Komi 1989). Saman suuntaisiin tuloksiin on päästy myös muissa tutkimuksissa, muun muassa Sägerserm, ym. (1981) mittasivat 1668 ± 214 N ja Virmavirta & Komi (1988) 1648 ± 353 N arvoja vastaavassa tilanteessa. Esimerkkikuvaaja voiman käyttäytymisestä ajan funktiona ponnistuksen aikana on havainnollistettu kuvassa 18.



KUVA 18: Hyppääjän vertikaalinen voima-aika -kuvaaja hyppyripöydällä ponnistusliikkeen aikana (Komi & Virmavirta 2000).

4.2.2 Ponnistuksen ominaispiirteet

Ponnistuksen aikaisia tapahtumia ja sille tyypillisiä piirteitä on tutkittu paljon ja erityisen kiinnostavia muuttujia tapahtumaketjussa ovat sääri-, polvi-, lonkka- ja ylävartalokulmien muutokset sekä näissä esiintyvät kulmanopeudet. Ponnistuksen alusta irtoamisvaiheeseen lantion kulmamuuutos on keskimäärin 40° - 140° ja polvikulman muutos noin 70° - 140° (Komi & Virmavirta 2000; Arndt ym. 1995; Schwameder & Müller 1995). Virmavirta tutki puolestaan ryhmänsä kanssa (Virmavirta ym. 2009) ponnistuksen muuttujia vuoden 2006 Torinon talviolympialaisissa 6 metrin matkalta hyppyrin keulalle HS-106 mäessä. Tämän tutkimuksen mukaan säärikulma muuttui hyppyripöydän alun noin 50° ja irtoamishetken noin 70° välillä, ylävartalon kulma 5° ja 30° välillä, polvikulma noin 65° ja 140° välillä ja lantiokulma noin 30° ja 100° välillä. Nivelten kulmien muutos ponnistuksen aikana on havainnollistettu kuvassa 19.



KUVA 19: Nivelkulmien muutokset ponnistuksen aikana. Vasemmalla esitetty mittausdata 1990-luvulta (Komi & Virmavirta 2000). Oikealla puolella vertailun vuoksi kahden hyppääjän nivelkulmat HS-106 mäen kilpailusta (Virmavirta ym. 2009).

Ponnistuksessa kiinnitetään usein myös huomiota hyppääjän polven ojennuksen kautta tuottamaan kulmanopeuteen erityisesti polvi- ja lonkkanivelissä, sillä nämä yhdessä kulmamuuutosten kanssa vaikuttavat ponnistuksessa saavutettuun horisontaali- ja vertikaalinopeuteen hyppyrin keulalla. Virmavirran ja kumppanien tutkimuksessa (Virmavirta ym. 2009) mitattiin kulmanopeuksia 6-3 metriä ennen ja 3-0 metriä ennen hyppyrin keulaa. Lantion kulmanopeus sai arvoja noin 200°/s kauempana keulaa ja kiihtyen noin 400°/s nopeuteen keulaa kohti, polvikulman kulmanopeus oli vastaavasti noin 200°/s - 250°/s ja 370°/s - 400°/s sekä säärellä noin 50°/s ja 130°/s - 150°/s. Ponnistuksessa tuotetulla lantion kulmanopeudella on myös havaittu olevan merkitsevä vaikutus hypyn pituuteen.

Yleisellä tasolla ponnistustekniikassa on voi olla paljonkin vaihtelua huippuhyppääjien välillä ja yhtä pitkän hypyn pystyy tuottamaan melko erilaisillakin ponnistusparametreilla (Janura ym. 2011). Sasaki ym. (1998) havaitsivat tutkimusryhmänsä kanssa hyppääjillä kolme toisistaan erilaista ponnistusprofiilia polvi- ja lonkkanivelillä tuotetun kulmanopeuksien suhteen. Heidän havaintonsa mukaan polven kulmanopeus saavuttaa maksiminsa lähellä hyppyrin keulaa,

jokaisella ponnistustavalla. Myös reiden kulmanopeus osoittautui suuremmaksi kuin vartalon kulmanopeus. Toisistaan poikkeavia ponnistusparametreja on havaittu myös muissa tutkimuksissa (Virmavirta ym. 2009), vaikka hypyn pituudet ovatkin olleet samaa suuruusluokkaa. Näin ollen voidaan olettaa, että hyvä hyppy riippuu monesta eri tekijästä ja nämä ovat kytköksissä toisiinsa. Jokaisen hyppääjän ponnistusliikkeeseen vaikuttaa henkilökohtainen antropometria ja fyysiset ominaisuudet, joten ei ole yhtä tiettyä tapaa ponnistaa oikein.

Virmavirta ja Komi julkaisivat vuonna 1994 tutkimuksen (Virmavirta & Komi 1994), jossa he vertailivat aikakautensa parhaimman hyppääjän Matti Nykäsen ponnistusta eräässä tämän voittamassaan kilpailussa sijoille 2-9 päätyneisiin hyppääjiin. Tutkimuksessa havaittiin Nykäsen voimantuoton ja ensimmäisen voimapiikin (F_{max1}) olleen keskimäärin alhaisempi muihin hyppääjiin verrattuna ensimmäinen puolikkaan hyppyripöydän matkan aikana. Sen sijaan jälkimmäisen puolikkaan hyppyripöydän matkan aikana Nykäsen keskimääräinen voimantuotto ja toinen voimapiikki (F_{max2}) olivat merkittävästi suurempia muihin hyppääjiin verrattuna. Samoin voiman lasku F_{max1} ja F_{max2} välillä oli Nykäsellä merkittävästi pienempää muihin nähden. Oleellista oli myös se, että vaikka Nykäsen vauhtimäen laskunopeus oli muita alhaisempi, pystyi hän tuottamaan merkittävästi suuremman horisontaalisen ja vertikaalisen kiihtyvyyden. Suuri selittävä tekijä ponnistuksen ylivoimaisuudessa lienee säären kulman pitäminen muita pienempänä, jolloin ilmanvastus jää pienemmäksi ja lentoasentoon siirtyminen nopeutuu. Pienen säärikulman hyödyistä on havaittu viitteitä myös (Virmavirta ym. 2009) tutkimuksessa.

4.3 Ilmalento

Ilmalento jaetaan usein tutkimuksissa alkuilmalennon vaiheeseen ja stabiiliin lentovaiheeseen. Yleisesti ottaen ponnistusta ja sen jälkeistä alkuilmalennon vaihetta pidetään hypputyön kannalta kaikkein kriittisimpänä, sillä se luo perustan stabiilille ilmalennon vaiheelle. Alkuilmalennon vaiheella tarkoitetaan siirtymää ponnistuksesta stabiiliin lentoasentoon. Alkuilmalennon aikana hyppääjä muodostaa suksillansa V-asennon. Tämä siirtymä tapahtuu noin 17-20 metrin matkalla hyppyrin keulan jälkeen ja siihen kuluu aikaa noin 0.7 – 1.0

sekuntia. Siirtymän aikana hyppääjä koukistaa nilkkojaan, jolloin ilmavirta vaikuttaa suksien pohjaan. Ilmanvastus hyppääjäsuksi-kompleksiin aiheuttaa taaksepäin suuntautuvaa pyörimisliikemäärää ja tämä tulee kumota ponnistuksessa tuotetulla eteenpäin suuntautuvalla pyörimisliikemäärällä. Tämän myötä hyppääjän tulee saavuttaa optimaalinen hyökkäyskulma ilmalennon ajaksi ja vaihe tulee suorittaa mahdollisimman nopeasti, jotta hyppääjä ei menetä vauhtimäen laskun aikana saavuttamaansa vauhtiaan. (Schwameder 2008; Arndt ym. 1995; Schwameder ym. 2005).

4.3.1 Hyppääjään vaikuttavat voimat ilmalennon aikana

Hyppääjään vaikuttaa ilmalennon aikana kolme voimaa, gravitaatiovoima F_g , noste F_l ja ilmanvastusvoima F_d . Suureet on esitetty kaavoissa 7, 8 ja 9. (Müller 2006).

$$(7) \quad F_g = mg$$

$$(8) \quad F_l = \frac{\rho}{2} v^2 c_l A = \frac{\rho}{2} v^2 L$$

$$(9) \quad F_d = \frac{\rho}{2} v^2 c_d A = \frac{\rho}{2} v^2 D$$

Hyppääjän lentoradan nopeus muodostuu \bar{x} ja \bar{y} komponenteista siten, että

$$(10) \quad v^2 = \bar{x}^2 + \bar{y}^2.$$

Urheilija pystyy ilmalennon aikana vaikuttamaan häneen kohdistuviin aerodynaamisiin voimiin muuttamalla lentoasentoaan. Hyppääjä pystyy vaikuttamaan ilmanvastukseen, nosteeseen ja vääntömomenttiin ja näin ollen muuttamaan lentoasentoaan suhteessa ilmavirtaan. Hyppääjän lentorata voidaan kuvata kaavojen 11 ja 12 avulla. (Müller 2006).

$$(11) \quad \bar{v}_x = \frac{(-F_d \cos \varphi - f_l \sin \varphi)}{m}, \quad \bar{x} = v_x$$

$$(12) \quad \bar{v}_y = \frac{(-F_d \sin \varphi - f_l \cos \varphi)}{m} - g, \quad \bar{y} = v_y$$

4.3.2 Ilmalennon aikaiset kinemaattiset muuttujat

Arndt'n ja hänen tutkimusryhmänsä (Arndt ym. 1995) mukaan hyppääjän suuri eteenpäin nojaaminen 17 metrin alkuilmalennon aikana sekä suuri suksen sekä jalkojen aukeamiskulma 17 metrin ilmalennon jälkeen korreloivat suuresti hypyn pituuteen ($R = 0.92$). Toisaalta eräässä toisessa tutkimuksessa (Schwameder & Müller 1995) tultiin lopputulokseen, että hypyn pituus korreloi eniten ($R = 0.89$) yhdessä suuren vertikaalisen irtoamisvaiheen nopeuden, suuren polven kulmanopeuden, suuren ponnistuksen aikaisen vääntömomentin ja pienen vartalo-suksikulman kanssa 20 metrin ilmalennon jälkeen.

Alkuilmalennon aikaiset suorituskykymuuttujat jaetaan ballistisiin ja aerodynaamisiin. Ballistisia muuttujia ovat esimerkiksi sijainti lentoradalla sekä painopisteen nopeus. Aerodynaamisilla muuttujilla tarkoitetaan yleisesti lentävän systeemin segmenttien kulmia ja asentoja. Schwameder vertaili tutkimusryhmänsä kanssa (Schwameder ym. 2005) Salt Lake Cityn talviolympialaisissa 2002 kinemaattisia muuttujia alkuilmalennon aikana parhaiden ja heikoimpien hyppääjien välillä. He havaitsivat painopisteen vertikaalinopeuden olevan koko suorituksen ajan negatiivien, mikä ponnistusvaiheessa johtuu hyppyripöydän keulan negatiivisesta kulmasta ($\sim 10^\circ$). Hypyn irtoamisen jälkeen vertikaalinen nopeus kasvaa lähes lineaarisesti ensimmäiset 0.8 sekuntia ja eri tasoilla hyppääjillä ei juuri esiinny eroavaisuuksia keskenään. Tämän jälkeen eroavaisuuksia alkaa näkyä, sillä noin 1 sekuntia ponnistuksen irtoamisen jälkeen heikommilla hyppääjillä vertikaalinopeus on jo noin 0.8 m/s suurempaa. Vartalon ja suksen välinen kulma kasvaa aavistuksen ponnistuksen aikana ja pienenee merkittävästi ensimmäisen 0.4 s aikana ponnistuksesta. 0.4 – 0.8 s välillä ponnistuksen jälkeen suksi-vartalokulma pienenee enää hieman. Näin ollen ponnistuksessa tuotetaan eteenpäin suuntautuvan pyörimisliikemäärän avulla nopea eteenpäin nojaaminen ja vartalon ja suksen välisen kulman pieneneminen ensimmäisten 0.4 sekunnin aikana. Tutkimuksessa havaittiin, että paremmilla hyppääjillä vartalo-suksikulma on koko alkuilmalennon ajan pienempi tarkoittaen sitä, että he pääsevät staattiseen lentoasentoon heikompia hyppääjiä nopeammin suuremman eteenpäin nojaamisen johdosta. Nopeampi lentoasentoon pääseminen puolestaan vaikuttaa vertikaalinopeuteen. Mitä nopeammin hyppääjä siirtyy lentoasentoon, sitä suurempi on hyppääjään vaikuttava noste ja sitä hitaammin hyppääjä tippuu alas. Schmölzerin tutkimuksessa (Schmölzer & Müller 2005) Salt Lake Cityn olympialaisissa 2002 havaittiin, että

aerodynaamiset voimat ovat verrannollisia ilman tiheyteen ja että huippuhyppääjät ovat taitavampia mukauttamaan tekniikkaansa ilma-alan mukaiseksi saavuttaakseen stabiilimman lentoasennon ja pidemmän hypyn. Hyppääjät asettavat alkuilmalennon aikana suksensa V-asentoon noin 0.6 sekunnin kuluessa. Sukset aukeavat lopullisessa V-asennossa noin 25 – 30° kulmaan (Seo, Murakami & Yoshida 2004; Schmölzer & Müller 2005). Paremmin pärjäävät hyppääjät käyttävät leveämpää V-asentoa (isompi kulma) ja saavat pidettyä sen tulostasoltaan heikompia hyppääjiä vakaammin (Schmölzer & Müller 2005).

Vodičar ja Jošt (2011) tutkivat eri kinemaattisten muuttujien vaikutusta Planican HS-215 lentomässä hypyn pituuteen vuonna 2009 kahtena kilpailupäivänä. Huomion arvoista on, että toisen kilpailupäivän mittaukset eivät olleet johdonmukaisia olosuhteiden, lähinnä vaihtelevien tuuliolosuhteiden myötä. Tutkimuksessa havaittiin, että paremmin pärjäävillä hyppääjillä säilyy stabiili ja virtaviivainen lentoasento (hyppääjän selän ja suksien pohjan välinen etäisyys) läpi koko hypyn, mikä johtaa korkeampaan hypyn lentorataan ja lopulta pidempään hyppyyn. Vodičar ja Jošt (2011) toteavat Vaverkan tutkimukseen (Vaverka 1987) viitaten, että ilmalennon aikana tuleekin saavuttaa jokaisena hetkenä lentoasento, joka samanaikaisesti maksimoi hyppääjän painopisteen horisontaalisen nopeuden ja minimoi vertikaalisen nopeuden. Schmölzerin ja Müllerin (2006) sekä Murakamin ja hänen tutkimusryhmänsä (Murakami ym. 2010) mukaan kasvava ilmanvastus alkuilmalennon aikana on hyvin epäedullista hypyn pituuden kannalta, näin ollen hyppääjät pyrkivät ilmalennon alkuun tuottamaan asennon, jossa ilmanvastus on pieni. Hyppääjä tarkoituksenaan mukaisesti pyrkii kasvattamaan ilmanvastusta ja nostetta hypyn myöhemmässä vaiheessa. Ilmanvastuksen suuruutta pystytään kontrolloimaan suksien muodostaman V-asennon kulmalla ja V-asennon kulman kontrollointi on hypyn pituuden kannalta merkittävämpää kuin eteenpäin nojaamiskulman kontrollointi (Seo ym. 2004). Hypyn pituus ei riipu pelkästään nosteilmanvastus suhteesta (mikä pienenee sukset-vartalosysteemin kulman kasvun myötä) vaan myös nosteen ja ilmanvastuksen absoluuttisista arvoista (Schmölzer & Müller 2006). Esimerkiksi Schmölzerin ja Müller eräessä tutkimuksessa (Schmölzer & Müller 2002) havaittiin L/D suhteen saavuttava maksiminsa suksen ja ilmavirran välisen hyökkäyskulman ollessa 30°, mutta noste L saavutti absoluuttisen maksimiarvonsa hyökkäyskulmalla 40°.

Yamanoben ryhmän (Yamanobe, Shirasaki, Akashi & Ishige 2016) tekemän tutkimuksen mukaan olkapään abduktion kulman tulisi olla pieni, jotta hyppääjä saavuttaa parhaimman L/D (noste/ilmanvastus) suhteen ja näin ollen suuremman nosteen hyppyasennolleen. Kämmenten supinaatioasento ilmalennon aikana puolestaan tuottaa suuremman nosteen kuin muut kämmenen asennot.

4.4 Alastulo

Mäkihyppysuoritus päättyy ilmalennon jälkeen alastuloon, joka voidaan suorittaa joko tasajalka-alastulona tai niin kutsutussa telemark-asennossa, jossa laskeudutaan polvistuen etu- ja takajalan tuen varaan. Mäkihypyssä tuomarit arvioivat alastuloa tyylipistein ja lajin käytäntö on ollut arvottaa telemark-alastuloa korkeammin tyylipistein, sillä sitä on pidetty tyylikkäämpänä ja haastavampana alastulotapana. Koska tasajalka-alastulo on helpompi suorittaa, nähdään niitä enemmän hyvin pitkiksi venyneissä hyppyissä. Hyppääjät haluavat minimoida pitkään hyppyyn sisältyvän kaatumisriskin. Hyppääjät pyrkivät aloittamaan laskeutumisen mahdollisimman myöhään lentovaiheessa, venyttääkseen hypyn pituutta. Tämä voi johtaa epävakaiseen ja huonosti suoritettuun alastuloon johtaen kokonaissuorituksen ja turvallisuuden laskuun. (Schwameder 2008). Riippuen hypyn pituudesta ja käytetystä alastulotyylistä, hyppääjään kohdistuu alastulon yhteydessä 1.1 – 5.3G suuruinen normaalivoima jalkaa kohden (Bessone, Petrat & Schwirtz 2019).

5 TUTKIMUSASETELMA JA RATKAISTAVA ONGELMA

Tämän tutkimuksen tarkoituksena on selvittää hahmon asennon arviointiin perustuvan liikeanalyysisovelluksen soveltuvuutta mäkihypyn ponnistusvaiheen biomekaaniseen analysointiin. Perinteisesti mäkihypyn biomekaaninen analysointi on tehty tavanomaisella videokuva-analyysillä, jossa yksittäiset kuvat tulkitaan ja analysoidaan ja lopullinen laskenta tehdään näiden pohjalta käsityönä. Monesti laboratorio-olosuhteissa päästään tarkempaan analyysiin kuin kilpailu- ja harjoitusolosuhteissa, sillä tällöin voidaan hyödyntää videoanalyysissä siihen soveltuvia heijastinmarkkereita merkitsemään nivelten ja anatomisten maamerkkien sijaintia.

Tässä työssä halutaan selvittää, miten koneoppimiseen pohjautuva AlphaPose ja sen päälle rakennettu analyysisovellus vertautuu perinteisellä videoanalyysillä tehtyyn ponnistusvaiheen analyysiin. Ponnistuksen aikaiset muuttujat määritetään sekä AlphaPosen ja sen päälle tehdyn sovelluksen avulla sekä manuaalisesti kuva kuvalta. Tarkoituksena on verrata tilastollisilla analyyseillä AlphaPosen ja sen päälle tehdyn analyysisovelluksen validiteettia ja reliabiliteettia suhteessa perinteiseen videopohjaiseen liikeanalyysiin. Kirjallisuuden perusteella voidaan olettaa, että koneoppimiseen pohjautuva asennon arviointi -menetelmä soveltuisi myös mäkihypyn ponnistusvaiheen biomekaaniseen 2D analyysiin, sillä sen on osoitettu soveltuvan liikemalleista tarkimmaksi esikevennetyn hypyn osalta (Needham ym. 2021).

6 MENETELMÄT

6.1 Koehenkilöt

Tutkimukseen osallistui kahdeksan tervettä 15-26-vuotiasta yhdistetyn hiihdon urheilijaa ja koehenkilöitä informoitiin tiedottein mahdollisuudesta osallistua tutkimuksen mittauksiin. Tutkittaville kerrottiin tutkimuksen tarkoituksesta ja mittausprotokollasta sekä kerrottiin heidän oikeuksistaan tutkimukseen liittyen. Kaikki koehenkilöt antoivat suostumuksensa tutkimukselle ja tutkimus suoritettiin kokonaisuudessaan Helsingin julistuksen periaatteiden mukaisesti. Lisäksi yliopiston eettinen toimikunta antoi puoltavan ennakoarvion tutkimukselle.

6.2 Koeasetelma

Mittaukset toteutettiin Vuokatissa K-100 mäessä syyskuussa 2020. Mittausajankohdan sää oli kolea ja varsin tyyni, noin +5 astetta sekä hieman sumuinen. Mittauslaitteet asennettiin paikoilleen ja kalibroitiin noin tunti ennen hyppyharjoitusta. Koehenkilöitä ohjeistettiin saapumaan testiin normaalisti valmistautuen, mutta samalla ohjeistettiin olla osallistumatta tutkimukseen sairaana tai toipilaana. Ennen tutkimuksen aloitusta, koehenkilöiltä kerättiin vielä allekirjoitukset suostumuslomakkeisiin. Kukin koehenkilö suoritti normaaliin tapaansa hyppyjä mäestä. Kokonaisuudessaan hyppyjä kertyi koehenkilöiltä 40 kappaletta, jotka kaikki videoitiin hyppyripöydän kohdalta. Tutkimus kesti noin kaksi tuntia.

6.3 Mittausmenetelmät

Neljän koehenkilön hyppypukuun kiinnitettiin teipein pieni rasti olkanivelen, lonkan (greater trochanter), polven (sivuside) ja monon päälle (lateral malleolus). Teipin oli tarkoitus kuvastaa nivelen sijaintia ja näin ollen helpottaa perinteisen liikeanalyysin tekemistä. Heijastinmarkkereita ei tällä kertaa käytetty, sillä niiden saaminen paikalleen olisi vaatinut hyppypuvun rei'ittämistä ja olisivat irrotessaan olleet mahdollinen turvallisuusriski

hyppääjälle. Kamerana käytettiin Lilin (Uusi-Taipei, Taiwan) UFG1122EX3 mallista IP kameraa taajuudella 100 FPS ja kameran linssi 3M 2.8 – 12mm oli mallia PLH-2812MA-3M(Lilin, Uusi-Taipei, Taiwan). Kuvausresoluutiona oli kameran tarjoama yläraja, 1080P (1920x1080). Kamera sijoitettiin valmentajien käyttämään kopperakennuksen kattorakennelmiin (vakioitu sijainti), joka sijaitsee noin 18 metrin päässä hyppyrimäestä. Kamera ruuvattiin telineeseen kiinni, kuvakulma vaakatasossa. Kameran kuvausalue oli tuolta etäisyydeltä kuitenkin liian laaja ja sitä pienennettiin kohdistamalla tarkennusta hyppyripyödyän noin 10 metrin alueelle. Kamera kytkettiin verkkovirtaan ja verkkojohtolla tietokoneeseen kiinni, jossa kuvaus käynnistettiin ja sammutettiin ffmpeg sovelluksen avulla Windows-käyttöjärjestelmän komentoriviltä. Vuokatin K-100 mäen etureunalla on normaalitilanteessa pleksipaloista rakennettu tuulensuoja ja tutkimuksen ajaksi pleksilevyt poistettiin kuvausalueen edestä, sillä näköesteen vuoksi ne olisivat häirinneet analyysiä ja mahdollisesti estäneet AlphaPose hahmontunnistajaa tunnistamasta hyppääjää ja paikantamasta nivelpisteitä (asennon arvio -sovelluksen yhteydessä käytetään yleisesti termiä avainpiste, mutta selkeyden vuoksi tässä työssä käytetään myöhemmin termiä nivelpiste). Pleksilevyn poistosta huolimatta hyppyyriä reunusti muutaman senttimetrin korkuinen puinen ja metallinen kaide, mikä peitti hyppääjän jalkaterän taakseen, estäen kameran suoran näkyvyyden. Näköeste on havainnollistettu kuvassa 20.



KUVA 20: Tutkimuksessa käytetty kuvausalue kokonaisuudessaan, kun etäisyys kamerasta mäkeen oli 18 metriä ja siitä kohdennettiin lähemmäksi. Kuvakäsittelyssä kohdennettiin vielä lisää ja poistettiin ylimääräistä reunagrafiikkaa. Kuvasta ympyröity myös jalkaterän näköeste.

Hyppääjän nopeuden määrittäminen oli tarkoitus suorittaa kuva-analyysistä fysiikan kaavan $v = \frac{s}{t}$ avulla, kun mittayksikkönä hyödynnettiin pleksilevyn pituutta (3m) ja toisaalta tiedettiin kuvaustaajuus ja mäen kaltevuuskulma 10° , mikä määritettiin Kinovea sovelluksen (<https://www.kinovea.org/>) avulla kuvan 21 mukaisesti. Mäen kaltevuudeksi määritettiin hyppyrin keulan lähellä ja alkuilmalennon aikana (suksien kulma) 10° , hieman aikaisemmin hyppyripöydällä 11° ja kuvausalueen alkupäässä 12° . 6m, 3m, ja 0m etäisyyksiä hyppyrin reunalta hyödynnettiin määrittettäessä kulmanopeuksia, joita on vastaavasti määritetty esimerkiksi Virnavirran ja hänen tutkimusryhmänsä tutkimuksessa (Virnavirta ym. 2009).



KUVA 21: Mäen kaltevuuden sekä kolmen metrin ja kuuden metrin etäisyyden määrittäminen hyppyrin keulalta. Apuna käytettiin etualalla olevan pleksin pituuden mittaa (3m).

6.4 Mittausten analysointi AlphaPosen ja analyysisovelluksen avulla

Tutkimuksen aikana kuvattiin 40 hyppysuoritusta ja niistä valikoitiin satunnaisesti 10 videota mukaan analysoitavaksi. Ennen varsinaista analyysiä, videoita editoitiin Kinovea sovelluksella siten että videon aloituskohta ja loppukohta pyrittiin vakioimaan silmämääräisesti mahdollisimman samanlaiseksi. Lisäksi Kinovealla hidastettiin videoiden kelausnopeutta alhaisimpaan mahdolliseen nopeuteen (3%) eli 3 FPS taajuuteen. AlphaPose sovelluksesta

kokeiltiin eri versioita esimerkiksi Lu ym. käyttämää (2017), joka on sovelluksen kehityksen virallinen päähaara. Lopulta tutkimustyö päätettiin toteuttaa Aman Bhandulan haarakehitetyllä ja erilleen johdetulla sovellusversiolla (Lu ym. 2018), sillä siinä käytetty *tracker_general* sovellus vaikutti jäljittävän hyppääjän ja nivelten sijainnit paremmin ja vaikutti helpommin käytettävältä versiolta.

AlphaPosesta valittu PyTorch kehityshaaran sovellusversio asennettiin Linux käyttöjärjestelmälle (Ubuntu 20.04) ja analyysin ponnistusvaiheen parametrien määrittämistä varten ohjelmoitiin Pythonilla (versio 3.6) toisiinsa kytkeytyviä sovelluksia, jotka hyödynsivät AlphaPosen tuottamaa ennustetta nivelten keskipisteiden sijainnista. AlphaPose tuotti ennusteet nivelpisteiden sijainnista erilliseen json formaatin tiedostoon, josta ne olivat luettavissa nivelittain x- ja y-koordinaattipareina. AlphaPosen käyttämän akseliston origo (0.0) oli kuvan vasemmassa yläkulmassa ja kukin nivelpiste kuvattiin koordinaatistossa siten, että sen koordinaatit vastasivat tiettyä kuvan pikseliä. Mainittakoon vielä, että tässä työssä käytettiin COCO tietosarjaa oletusasetuksin, jolloin sen tuottamat nivelpisteiden sijainnit poikkeavat hieman taulukon 1 mukaisesta. AlphaPose käyttää COCO tietosarjaa oletuksena, siksi se valikoitui käyttöön myös tässä tutkimustyössä. Oletuksena COCO tietosarja tuottaa nivelpisteiden sijainnit 17:lle kehon osalle taulukon 3 mukaisesti.

TAULUKKO 3: COCO tuottaa oletusasetuksella nivelpisteiden sijaintitiedot 17:lle kehon osalle.

<i>COCO (17 body parts)</i>	
ID	Keypoint
0	Nose
1	LEye
2	REye
3	LEar
4	REar
5	LShoulder
6	RShoulder
7	LElbow
8	RElbow
9	LWrist
10	RWrist
11	LHip
12	RHip
13	LKnee
14	RKnee
15	LAnkle
16	RAnkle

Ponnistusvaiheen analyysiä varten ohjelmoitiin muutama toisiinsa kytkeytyvä sovellus, joiden työnkulku oli seuraavanlainen:

1. ffmpeg sovelluksella videon kohdennus lähemmäksi sekä kuvan ylimääräisten reunapalojen poisleikkaus
2. videon pilkkominen yksittäisiin kuviin ja jokaiseen kuvan vasempaan yläreunaan framen järjestysnumero helpottamaan analyysiä
3. Henkilöiden jäljitys sekä nivelpisteiden sijainnin määrittäminen (AlphaPose)
4. Tutkimuksen kannalta epäoleellisten nivelpisteiden poisto datasta sekä tuotettavista grafiikoista ja loppuvideoista (koordinaatit vain oikeasta olkapästä, oikeasta lonkasta, oikeasta polvesta ja oikeasta nilkasta jätettiin analyysiin)
5. Nivelpisteistä muodostuvien vektorien välisten kulmien laskeminen (vektorien välinen kulma kuvaa nivelkulmaa)
6. Analyysin ajo, jossa kuvakohtaiset nivelkulmat ovat lähdetietona. Ajo tuottaa jokaisesta kuvasta nivelten kulman suuruuden ajan funktiona kuvaajaan. Viimeisen kuvan kohdalla lasketaan nopeus, ponnistuksen kesto ja kulmanopeudet välillä 6-3 m ja 3-0 m ennen hyppyreunaa, kun hyppyreuna ja ponnistushetki tunnetaan koordinaattien avulla videon taajuuden (FPS) perusteella.
7. Lopuksi tuotetaan videoanalyysi edellisten pohjalta, jossa yhdistetään kaikki yksittäisistä kuvista kerätty grafiikka

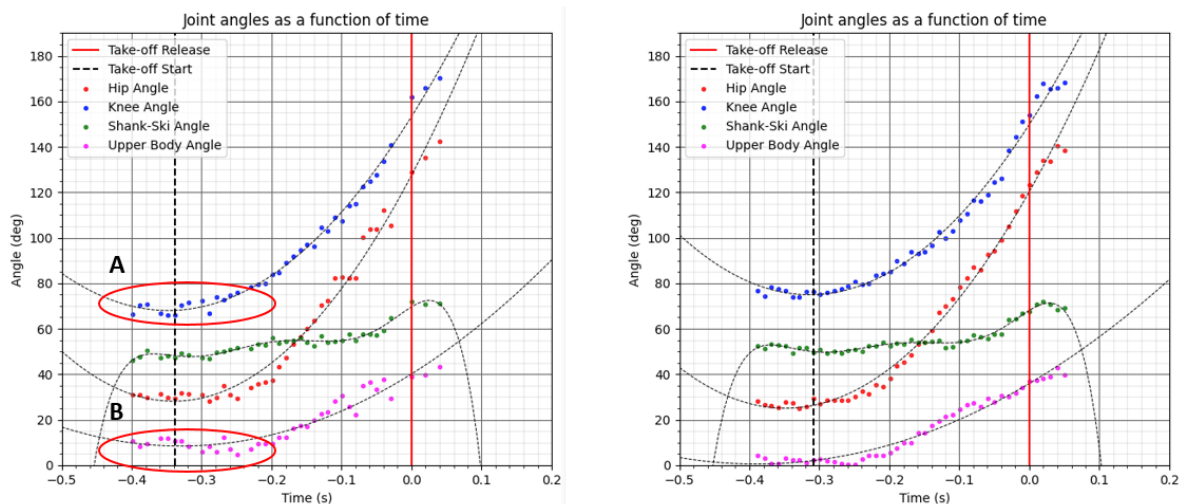
AlphaPosen tuottama json tiedosto henkilöiden jäljittämiseksi ja nivelpisteiden määrittämiselle näytti kuvan 22 kaltaiselta, kun tutkimuksen kannalta tärkeiden nivelten (oikea olkapää, oikea lonkka, oikea polvi ja oikea nilkka) koordinaatit oli säilytetty ja muut nollettu.

j2_alphapose.txt

```
1 {
2   "out0001.png": {
3     "angleUpperBody": 13.363933925460797,
4     "angleHip": 36.45971941129642,
5     "angleKnee": 76.15062957970326,
6     "angleShankSki": 53.05484409386765,
7     "x": 44.47587203979492,
8     "y": 363.3119812011719
9   },
10  "out0003.png": {
11    "angleUpperBody": 14.792690474096538,
12    "angleHip": 38.33033938336114,
13    "angleKnee": 78.41656166208855,
14    "angleShankSki": 54.878912752823965,
15    "x": 109.55349731445312,
16    "y": 381.50860595703125
17  },
18  "out0006.png": {
19    "angleUpperBody": 13.468806235424218,
20    "angleHip": 36.24663286296849,
21    "angleKnee": 73.87168716142492,
22    "angleShankSki": 51.00386053388062
```

KUVA 24 AlphaPosen nivelkoordinaattien pohjalta määritettyjen vektorien avulla laskettuja nivelten välisiä kulmia kuva kovalta.

Kuvassa 25 on puolestaan havainnollistettu yhden hyppysuorituksen välinen vertailu analyysisovelluksella ja manuaalisella analysoinnilla.

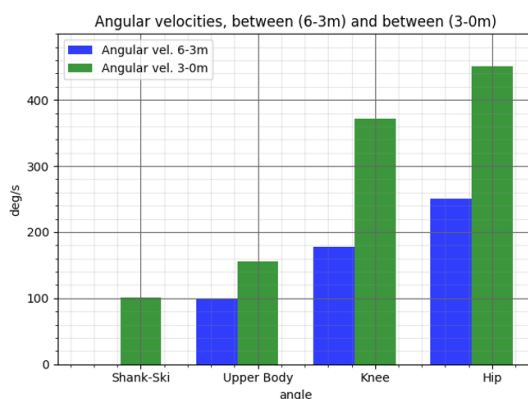


KUVA 25: Analyysityökalun (vasen) ja perinteisen manuaalisen menetelmän (oikea) havaintopisteiden vertailu yhden ponnistuksen ajalta. Kohta A) havainnollistaa AlphaPosen säännöllistä polvikulman aliarviointia ja B) ylävartalokulman yliarviointia suhteessa perinteiseen menetelmään.

Taulukko 4 esittää puolestaan analyysisovelluksen tuottaman tulostaulukon ja kuvassa 26 on havainnollistettu analyysisovelluksen tuottamat laskelmat nivelkulmanopeuksien muutoksille 6 – 3 metrin ja 3 – 0 metrin välimatkoilla hyppyrin keulalta.

TAULUKKO 4: Esimerkki analyysin tuottamista tuloksista mitattaville parametreille yhden hypyn osalta.

Take-Off Duration (s)	0.29
Speed (km/h)	88.7
Upper Body Angle (deg) @ Start of Take-off	4.67
Hip Angle (deg) @ Start of Take-off	24.81
Knee Angle (deg) @ Start of Take-off	67.07
Shank-Ski Angle (deg) @ Start of Take-off	48.01
Upper Body Angle (deg) @ Time of Take-off Release	39.1
Hip Angle (deg) @ Time of Take-off Release	117.98
Knee Angle (deg) @ Time of Take-off Release	138.51
Shank-Ski Angle (deg) @ Time of Take-off Release	61.22
Angular Vel. Hip (rad/s) @ Time of Take-off Release	9.7



KUVA 26: Esimerkki kulmanopeuksien muutoksien määrittämisestä 6-3m ja 3-0m matkalta ennen hyppyrin reunaa.

6.4.1 Mitattavat nivelkulmat

Koska valittu AlphaPosen malli (COCO tietosarja ja siitä muokattu asennon arviointi grafiikka) havaitsi hyppääjän kehosta vain olkapään, lonkan, polven ja nilkan, saatiin näillä määritettyä lonkka- ja polvikulmat ajan funktiona. Malli ei siis itsessään ollut ideaalinen ratkaistavaan

ongelmaan, jossa haluttiin määrittää myös vartalo- ja säärikulma ajan funktiona. Kuvassa 27 on havainnollistettu mitattavat kulmamuuttujat.



KUVA 27: Tutkimuksessa hyppääjästä määritettävät kulmamuuttujat.

Säärikulman määrittämistä varten, mitattiin nilkka-polvivektorin ja nilkan koordinaattien kautta kulkevan x-akselin välinen kulma, sekä lisättiin tähän vielä mäen kaltevuuskulma (10° , 11° tai 12°) kuvan 28 osoittamalla tavalla, riippuen missä kohtaa hyppääjän nilkan x-koordinaatti kullakin hetkellä oli koordinaatistossa.



KUVA 28: Mäen kaltevuuden määrittäminen Kinovealla. Kuva-analyysiä varten kukin kuva jaetaan kaltevuuden suhteen kolmeen sektoriin, jossa kunkin hetken kaltevuuskulma määritetään hyppääjän nilkan x-koordinaatin avulla.

Ylävartalokulma määritettiin samalla logiikalla kuin säärikulma, tässä tapauksessa olkapäälantio vektorin ja lantion x- ja y-koordinaatin läpi kulkevan x-akselin suuntaisen suoran välinen kulma, johon lisättiin mäen kaltevuuden kulma riippuen hyppääjän sijainnista kuvassa.

6.4.2 Ponnistushetki (hyppyrinkeula)

Ponnistushetken x- ja y-koordinaatit määritettiin hypyn (hypyllä ei merkitystä, sillä kuvauspaikka ja koordinaatisto ovat vakio) hetkestä, jossa hyppääjän lateraalinen malleolus oli silmämääräisesti hyppyrin keulan kohdalla. Kyseisen kuvan nilkan x- ja y-koordinaatit poimittiin AlphaPosen analyysin pohjalta talteen ohjelmaan ja analyysissä määritettiin hetki, jolloin hyppääjän nilkan x-koordinaatti on ensimmäisen kerran suurempi, kuin hyppyrin reunan x-koordinaatin arvo. Tätä hetkeä (framea) kuvataan ajanhetkellä 0, joka nähdään esimerkiksi kuvassa 25 punaisena pystyviivana. Loput kuvat analysoitiin suhteessa ponnistushetkeen, jolloin pystyttiin määrittämään kunkin kuvan aikaero hyppyrin reunaan. Tässä auttoi tieto siitä, että lähtövideon taajuus oli 100.411 FPS, eli kahden kuvan välinen aikaero oli noin 0,0096s. Näin ollen esimerkiksi kuvan 25 mukaan tehdyssä analyysissä nähdään, että videon ensimmäinen kuva on noin 0.4 s ennen ponnistushetkeä (hyppyrin keula).

6.4.3 Hyppääjän nopeus

Hyppääjän nopeus hyppyrin keulalla määritettiin hyväksikäyttäen mäen mittasuhtetietoja, jotka on esitetty kuvassa 21. Kun toisaalta tiedettiin hyppyrin keulan ja 3 metrin etäisyyden pisteiden x- ja y-koordinaatit, voitiin näiden välisen vektorin pituus laskea ja käyttää sitä referenssimittana nopeuden laskemiselle. Analyysisovelluksessa tarkastellaan satunnaismäärittämisellä tilannetta 12 kuvaa ponnistushetkestä taaksepäin, josta määritetään hyppääjän nilkan x- ja y-koordinaatit sekä lasketaan vektorin pituus hyppyrin keulaan. Kun tunnetaan matkavektorin pituus suhteessa referenssivektorin (3m) pituuteen, ja toisaalta tiedetään hyppyrin keulan (0s) ja 12:n kuvasta hyppyrin keulalle kuluva aika, voidaan nopeus määrittää kaavan $v = \frac{s}{t}$ avulla.

6.4.4 Ponnistuksen kesto

Ponnistuksen kesto määritettiin tässä tutkimuksessa siten, että sillä tarkoitetaan kestoja ponnistusliikkeen alkamisesta hyppyrin keulalle. Sillä kuvataan siis sitä, kuinka aikaisin tai myöhään ennen hyppyrin keulaa aktiivinen ponnistus alkaa. Tässä tutkimuksessa pyrittiin nojaamaan AlphaPosen tuottaman olkapää-, lonkka-, polvi- ja nilkkanivelten koordinaattitiedoista laskettaviin lonkka- ja polvikulmien muutoksiin ajanfunktiona. Nivelpistesijaintitiedot vaihtelivat AlphaPosen tulkintavirheiden vuoksi kuva kovalta, joten lonkka- ja polvikulmien muutosta ajan funktiona arvioitiin nivelpisteistä muodostettavien toisen asteen yhtälöiden avulla. Nämä toisen asteen regressiokuvaajat mallintavat sopivalla tarkkuudella alkuperäisiä mittauspisteitä. Esimerkki toisen asteen polynomiyhtälöistä (regressioista) on nähtävissä aiemmin kuvassa 25, jossa mustin katkopistein nähdään regressiokuvaajat polven (siniset havaintopisteet) ja lonkan (punaiset havaintopisteet) havaintopisteiden päällä piirrettyinä. Analyysisovellus määrittää molemmista kuvaajasta derivaatan nollakohdan ja määrittää ponnistuksen aloituskohdaksi sen ajanhetken, jossa derivaatta alkaa myöhemmin kasvaa nolasta. Ponnistuksen kesto määritetään tämän derivaatan nollakohdan hetkestä hyppyrin reunaan. Esimerkki analyysisovelluksen tuottamasta ponnistuksen alkuehdestä näkyy mustalla y-akselin suuntaisella katkoviivalla kuvassa 25.

6.4.5 Nivelen kulmanopeus

Analyysisovellus käyttää hyväksi nivelkulmien polynomifunktioita määrittäessään nivelten kulmanopeudet 6-3 m ja 3-0 m välimatkoille ennen hyppyrin keulaa. Eri asteisia polynomifunktioita soviteltiin AlphaPosella saatuihin nivelkulmakuvaajiin ja ylävartalo-, lonkka- ja polvinivelten osalta päädyttiin mallintamaan kuvaajia toisen asteen polynomifunktioilla, kun taas säärikulman tapauksessa kuudennen asteen polynomifunktio valittiin mallinnukseen, sillä se sovitui mittausarvoihin hyvin. Videoanalyysisovelluksessa määritetään kohdat, jolloin hyppääjä on ensimmäisen kerran lähempänä kuin 6 m ja 3 m hyppyrin keulasta. Kun näiden pisteiden koordinaatit olivat tiedossa, saatiin määritettyä näiden ajallinen etäisyys hyppyrin keulasta. Näiden sijaintipisteiden kohdalta kirjataan talteen jokaisen tarkisteltavan nivelen kulman suuruus. Kulmanopeus kullekin nivelelle välillä 6-3 m ennen

hyppyriin keulaa saadaan, kun lasketaan nivelkulman muutos kyseisellä matkalla ja jaetaan se matkaan kuluneella ajalla. Vastaavasti lasketaan kulmanopeus välimatkalle 3-0 m ennen hyppyriin keulaa.

6.5 Mittausten analysointi perinteisellä menetelmällä

Tutkimuksen tarkoituksena oli verrata edellä kuvattua, AlphaPosen ja analyysisovelluksen avulla tuotettujen suureiden vertautumista perinteisellä menetelmällä kerättyyn aineistoon. Perinteinen analyysi kattaa tässä tutkimuksessa samojen kymmenen hyppyvideon analysointia kuva kuvalta ja yhteensä kuvia kertyy valituista hypyistä 446 analysoitavaksi. Perinteistä analyysiä varten hyödynnettiin Pythonilla kirjoitettua skriptiä, jossa ohjelma sai lähdetiedostona analysoitavan kuvan. Ohjelma toimii siten, että käyttäjä paikantaa kuvasta tutkittavan nivelen ja painaa hiiren vasemmalla napilla sen kohdalla. Sama toistetaan kaikille tutkittaville nivelille ja ohjelma tulostaa jokaisen painalluksen kohdalla cursorin x- ja y-koordinaatit. Näin käydään kaikki kuvat läpi ja kirjataan tulokset talteen. Manuaalisesti määritetyt nivelpistesijaintitiedot syötettiin edelleen samalle analyysisovellukselle, jota hyödynnettiin AlphaPosen kanssa. Erona edelliseen on vain tiedon keräystapa, tässä tapauksessa keräys tehtiin itse silmämääräisesti, niin sanotun kultaisen standardin mukaisesti. Nivelten kulmanopeudet määritettiin vastaavasti saman analyysisovelluksen läpi. Esitettävissä tuloksissa on myös erikseen haluttu korostaa lonkkanivelen kulmanopeutta hyppyriin keulan kohdalla, sillä sen on osoitettu korreloivan hypyn pituuteen (Virmavirta ym. 2009). Nopeuden määrittäminen perinteisessä menetelmässä pitäisi tehdä mäen valoporttien avulla, mutta tutkimuksen aikana valoportit eivät olleet toimintakunnossa. Näin ollen analyysisovellus tuottaa arvion hyppääjän nopeudesta, mutta referenssimenetelmän puuttuessa se jätettiin tilastollisesta analyysistä pois. Ponnistuksen aloituskohta ja kesto määritettiin videon kuvista siten, että pyrittiin silmämääräisesti havaitsemaan nivelten liikettä kelailemalla kuvia edestakaisin ja osoittamalla kuvan järjestysluku, jossa liikkeen havaittiin alkavan. Tästä ponnistusliikkeen käynnistymisestä määritettiin ajan erotus hyppyriin keulalle.

6.6 Tilastolliset menetelmät

Tilastolliset analyysit tehtiin Windows 10 käyttöjärjestelmälle asennetulla IBM SPSS Statistics (versio 26) sovelluksella. Testiaineiston normaalijakautuvuus testattiin Kolmogorov-Smirnov menetelmällä, sillä aineiston koko oli suurempi kuin 50. Tutkimuksessa oli tarkoitus selvittää AlphaPosen pohjalta tehdyn analyysisovelluksen toistettavuutta ja validiteettia ja kuinka se vertautuu perinteiseen videoanalyysimenetelmään. Toistettavuus (engl. Reliability) selvitettiin tutkimalla mittaajan sisäistä toistettavuutta (engl. Intra-Class Correlation Coefficient, ICC) kymmenen hypyn kuva-aineiston osalta (N=376) neljälle kulmamuuttujalle: lantiokulmalle, polvikulmalle, säärikulmalle ja ylävartalokulmalle. Validiteettia varten tehtiin Spearmanin korrelaatioanalyysi, josta määritettiin korrelaatiokertoimet ja kuvattiin validiteetti korrelaatiokuvaajan avulla.

Edellä kuvattu tilastollinen tarkastelu (ICC ja korrelaatioanalyysi) toistettiin siten, että lähdeaineisto jaettiin kahteen osaan: kokotummiin hyppypukuihin (5 suoritusta, N=193) ja muun värisiin hyppypukuihin (5 suoritusta, N=183). Asetelmalla haluttiin selvittää kokotummien hyppypukujen mahdollista eroavaisuutta muun värisiin hyppypukuihin. Analyysisovellus tuottaa hyppyripöydältä kulmanopeudet jokaiselle tarkasteltavalle nivelkulmalle (lantio, polvi, säari, ylävartalo) kahdelta välimatkalta: 6-3 metriä ja 3-0 metriä ennen hyppyrin keulaa. Tämä lisäksi sovellus tuottaa tiedon hyppyrin reunan aikaisesta lantion kulmanopeudesta sekä ponnistuksen kestosta. Parametrien välistä erotusta sekä erotusten keskiarvon poikkeamaa nolosta kahden eri testaustavan välillä (analyysisovellus vs. perinteinen) tutkittiin parillisella t-testillä kymmenen hypyn osalta (N=10). Ennen parillista t-testiä selvitettiin aineiston normaalijakautuvuus Shapiro-Wilk menetelmällä ja mikäli normaalijakaumaa ei havaittu, käytettiin non-parametristä testiä.

7 TULOKSET

7.1 Reliabiliteetti ja korrelaatioanalyysi neljälle eri kulmamuuttujalle

Mittausmenetelmien toistettavuutta (reliability) selvitettiin tutkimalla mittaajan sisäistä toistettavuutta (ICC) kymmenen hypyn kuva-aineiston osalta (N=376). ICC analyysin perusteella havaittiin hyvän ja erinomaisen välistä reliabiliteettia lantio-, polvi-, ja säärikulman osalta sekä tyydyttävän ja hyvän välistä reliabiliteettia ylävartalokulman kohdalla 95% luottamusväliin perustuen, kun Alphaposea verrattiin manuaaliseen analyysiin. AlphaPosen (merkitään kuvissa ja taulukoissa 'A' = AlphaPose) ja perinteisen menetelmän (merkitään kuvissa ja taulukoissa 'M' = manual) välisen tilastollisen toistettavuusanalyysin tulokset on esitetty taulukossa 5.

Taulukko 5: AlphaPosesta johdetun sovelluksen reliabiliteetti suhteessa perinteiseen analyysiin neljän eri nivelkulman osalta.

<i>AlphaPose vs perinteinen menetelmä</i>				
	ICC	95% luottamusväli	p-arvo	Reliabiliteetti
lantioikulma	0.988	0.984 to 0.991	0.000 ***	erinomainen
polvikulma	0.982	0.898 to 0.993	0.000 ***	hyvä - erinomainen
säärikulma	0.936	0.911 to 0.952	0.000 ***	erinomainen
ylävartalokulma	0.889	0.506 to 0.955	0.000 ***	keskinkertainen - hyvä

Reliabiliteetti <0.5 heikko, 0.5 - 0.75 keskinkertainen, 0.75 - 0.9 hyvä, > 0.9 erinomainen


Analyysisovelluksen validiteettia selvitettiin korrelaatioanalyysin avulla, josta käytettiin Spearmanin testiä. Testin avulla määritettiin nivelkulmille Spearmanin korrelaatiokertoimet r_s . Testin myötä havaittiin voimakkaasta erittäin voimakkaaseen olevat korrelaatiot eri mittausmenetelmillä mitattujen nivelkulmien välille. Korrelaatioanalyysin tuottamat tulokset on esitetty taulukossa 6.

Taulukko 6: Menetelmien välinen korrelaatio neljän tarkasteltavan nivelkulman osalta (N=376). Spearmanin korrelaatiokerroin mittaa havaintoarvojen suuruusjärjestyksien yhtenevyyttä kahdelle muuttujalle. Järjestyslukujen täydellistä yhtenevyyttä kuvaisi korrelaatiokerroin 1 ja 0 puolestaan yhteyden täydellistä puuttumista.


<i>AlphaPose vs perinteinen menetelmä</i>			
	Korrelaatiokerroin, r_s	p-arvot	Korrelaatio
lantioikulma	0.957	0.000 ***	Erittäin vahva
polvikulma	0.931	0.000 ***	Erittäin vahva
säärikulma	0.738	0.000 ***	Vahva
ylävartalokulma	0.882	0.000 ***	Erittäin vahva

Korrelaatio <0.40 heikko, 0.40 - 0.60 kesinkertainen, 0.60 - 0.80 vahva, > 0.80 erittäin vahva


Korrelaatioanalyysin pohjalta luotiin korrelaatiokuvaajat, joissa nähdään eri menetelmien tuottamien mittauspisteiden suhde toisiinsa. Korrelaatiokuvaajat on esitetty alla kuvissa 29-32.




KUVA 29: Lantioikulman mittapisteiden korrelaatio AlphaPosen (A) ja perinteisen analyysin (M) välillä.



KUVA 30: Polvikulman mittapisteiden korrelaatio AlphaPosen (A) ja perinteisen analyysin (M) välillä.



KUVA 31: Säari-suksikulman mittapisteiden korrelaatio AlphaPosen (A) ja perinteisen analyysin (M) välillä.



KUVA 32: Ylävartalokulman mittapisteiden korrelaatio AlphaPosen (A) ja perinteisen analyysin (M) välillä.

7.2 Reliabiliteetti ja korrelaatioanalyysi hyppypuvun värin perusteella

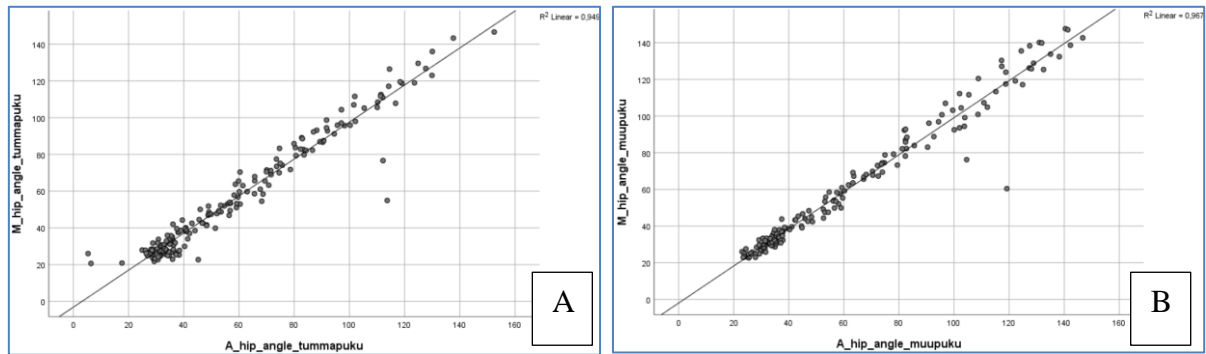
Edellisen kaltainen tilastollinen analyysi suoritettiin myös hyppypukujen värityksen mukaan siten, että yhdessä analyysissä oli näytteet hyppääjiltä, joilla oli kokonaan tumma hyppypuku ja toisessa ryhmässä näytteet hyppääjiltä, joilla oli muun värinen puku. AlphaPosen hahmontunnistus pystyi jäljittämään ihmisen kuvasta, joissa hyppääjällä oli kokonaan tumma hyppypuku, yhteensä 193:sta kuvasta 221 mahdollisesta ja näin ollen jäljitysprosentti oli 87,3%. Muun värisille hyppypuvuille AlphaPose onnistui jäljittämään hyppääjän 183:sta 224:sta mahdollisesta kuvasta ja näin ollen jäljitys onnistui 81,7 % tarkkuudella. ICC analyysi osoitti samankaltaisia tuloksia riippumatta puvun värityksestä: lantio-, polvi- ja nilkkakulmien osalta hyvän ja erinomaisen välistä reliabiliteettia ja ylävartalon osalta heikon ja hyvän välistä reliabiliteettia. Vastaavat ICC ja korrelaatiotulokset näistä ryhmistä on esitetty oheisissa taulukoissa 7 ja 8 allekkain, sekä korrelaatio-suorat rinnakkain kuvissa 33-36.

Taulukko 7: Hyppykuva-aineisto jaettuna kahteen ryhmään, joissa toisessa kokotummat hyppypuvut (N=193) ja toisessa muun väriset hyppypuvut (N=183).

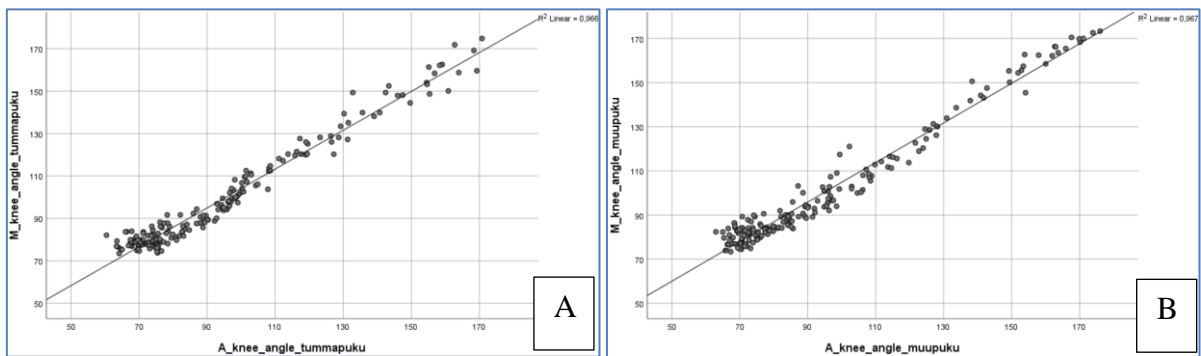
TUMMA HYPYPYPUKU	<i>AlphaPose vs perinteinen menetelmä</i>			
	ICC	95% luottamusväli	p-arvo	Reliabiliteetti
lantiokulma	0.985	0.975 to 0.990	0.000 ***	erinomainen
polvikulma	0.983	0.903 to 0.993	0.000 ***	erinomainen
säärikulma	0.943	0.827 to 0.973	0.000 ***	hyvä - erinomainen
ylävartalokulma	0.898	0.532 to 0.959	0.000 ***	keskinkertainen - hyvä
<i>Reliabiliteetti <0.5 heikko, 0.5 - 0.75 keskinkertainen, 0.75 - 0.9 hyvä, > 0.9 erinomainen</i>				
MUUT HYPYPYPUVUT	<i>AlphaPose vs perinteinen menetelmä</i>			
	ICC	95% luottamusväli	p-arvo	Reliability
lantiokulma	0.991	0.988 to 0.993	0.000 ***	erinomainen
polvikulma	0.981	0.890 to 0.993	0.000 ***	hyvä - erinomainen
säärikulma	0.928	0.904 to 0.946	0.000 ***	erinomainen
ylävartalokulma	0.882	0.455 to 0.953	0.000 ***	heikko - keskinkertainen
<i>Reliabiliteetti <0.5 heikko, 0.5 - 0.75 keskinkertainen, 0.75 - 0.9 hyvä, > 0.9 erinomainen</i>				

Taulukko 8: Korrelaatioanalyysin kertoimet tummille ja muun värisille hyppypuvuille.

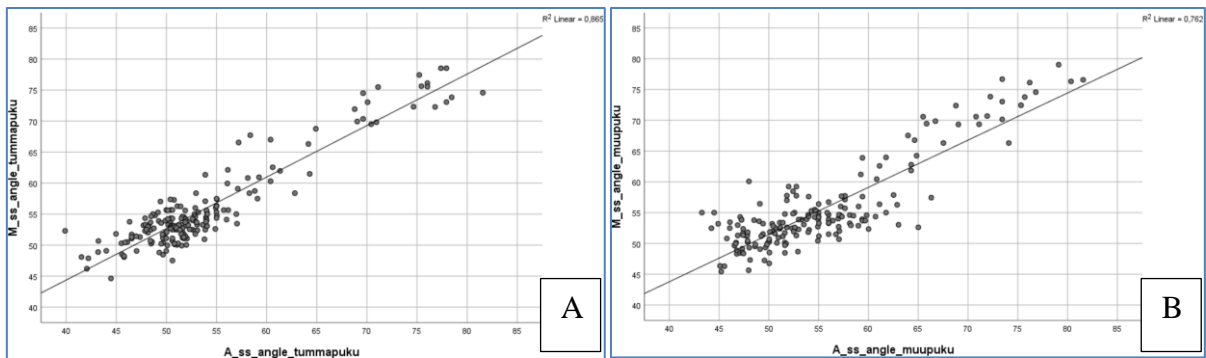
TUMMA HYPYPYPUKU	<i>AlphaPose vs perinteinen menetelmä</i>		
	Korrelaatiokerroin, r_s	p-arvot	Korrelaatio
lantiokulma	0.940	0.000 ***	erittäin vahva
polvikulma	0.926	0.000 ***	erittäin vahva
säärikulma	0.745	0.000 ***	vahva
ylävartalokulma	0.898	0.000 ***	erittäin vahva
<i>Korrelaatio <0.40 heikko, 0.40 - 0.60 keskinkertainen, 0.60 - 0.80 vahva, > 0.80 erittäin vahva</i>			
MUUT HYPYPYPUVUT	<i>AlphaPose vs perinteinen menetelmä</i>		
	Korrelaatiokerroin, r_s	p-arvot	Korrelaatio
lantiokulma	0.975	0.000 ***	erittäin vahva
polvikulma	0.937	0.000 ***	erittäin vahva
säärikulma	0.734	0.000 ***	vahva
ylävartalokulma	0.883	0.000 ***	erittäin vahva
<i>Korrelaatio <0.40 heikko, 0.40 - 0.60 keskinkertainen, 0.60 - 0.80 vahva, > 0.80 erittäin vahva</i>			



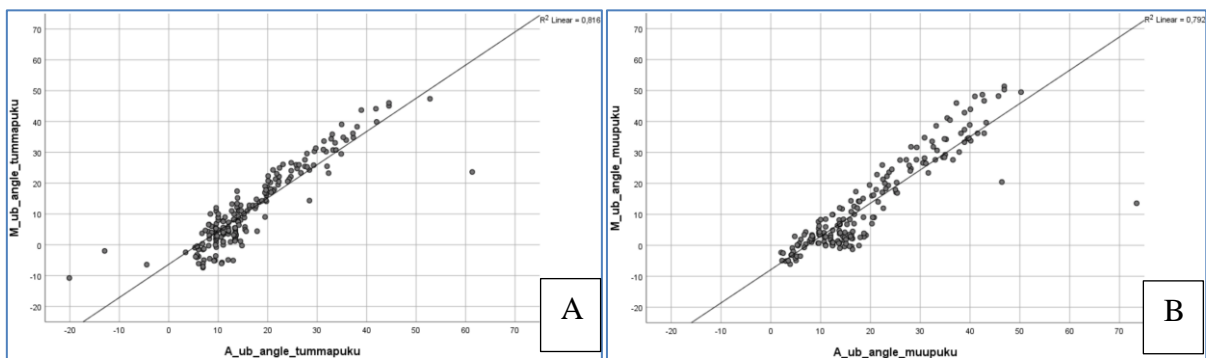
KUVA 33: Vasemmalla (A) kokotummien hyppypukujen lantiokulmien korrelaatio AlphaPosen (A, x-akseli) ja perinteisen menetelmän (M, y-akseli) välillä. Oikealla (B) vastaavasti muille hyppypuville. Kuvissa sama skaalaus.



KUVA 34: Vasemmalla (A) kokotummien hyppypukujen polvikulmien korrelaatio AlphaPosen (A, x-akseli) ja perinteisen menetelmän (M, y-akseli) välillä. Oikealla (B) vastaavasti muille hyppypuville. Kuvissa sama skaalaus.



KUVA 35: Vasemmalla (A) kokotummien hyppypukujen sääri-suksikulmien korrelaatio AlphaPosen (A, x-akseli) ja perinteisen menetelmän (M, y-akseli) välillä. Oikealla (B) vastaavasti muille hyppypuvuille. Kuvissa sama skaalaus.



KUVA 36: Vasemmalla (A) kokotummien hyppypukujen ylävartalokulmien korrelaatio AlphaPosen (A, x-akseli) ja perinteisen menetelmän (M, y-akseli) välillä. Oikealla (B) vastaavasti muille hyppypuvuille. Kuvissa sama skaalaus.

7.3 Ponnistuksen kinemaattisten muuttujien vertailu menetelmien kesken

Ponnistuksen aikaisten kinemaattisten muuttujien osalta ei havaittu tilastollisia eroja menetelmien välillä ponnistuksen keston ja hyppyrin keulalla mitatun lantion kulmanopeuden kohdalla, jotka tuottivat suuren p-arvon ($p=0.831$ ja $p=0.791$ vastaavasti). Näiden kahden muuttujan osalta menetelmät mittaavat melko hyvin samaa asiaa. Muiden muuttujien osalta eroja oli havaittavissa enemmän ja etenkin ylävartalon kulmanopeuksien osalta menetelmien antamat tulokset poikkesivat merkittävästi toisistaan. Tulokset on esitetty taulukossa 9.

TAULUKKO 9: Analyysisovelluksen (A) ja perinteisen mittausmenetelmän (M) tuottamien kinemaattisten muuttujien vertailu, kun aineistossa on 10 hyppyä (N=10).

Ponnistuksen kesto			
<i>AlphaPose vs perinteinen menetelmä</i>			
<i>parillinen t-testi</i>	Keskiarvo	Keskihajonta	p-arvo
M_take_off_duration	0.2720	0.1619	
A_take_off_duration	0.2690	0.4630	
parillinen ero			0.831
Lantion kulmanopeus / ToR			
<i>AlphaPose vs perinteinen menetelmä</i>			
<i>parillinen t-testi</i>	Keskiarvo	Keskihajonta	p-arvo
M_angular_vel_hip_tor	9.4170	1.16531	
A_angular_vel_hip_tor	9.3190	1.23048	
parillinen ero			0.791
Lantion kulmanopeus 6-3m			
<i>AlphaPose vs perinteinen menetelmä</i>			
<i>parillinen t-testi</i>	Keskiarvo	Keskihajonta	p-arvo
M_angular_vel_hip_6_3	221.6000	25.91096	
A_angular_vel_hip_6-3	208.0000	36.41733	
parillinen ero			0.050*
Lantion kulmanopeus 3-0m			
<i>AlphaPose vs perinteinen menetelmä</i>			
<i>parillinen t-testi</i>	Keskiarvo	Keskihajonta	p-arvo
M_angular_vel_hip_3_0	435.2000	49.80138	
A_angular_vel_hip_3-0	422.9000	48.22736	
parillinen ero			0.334
Polven kulmanopeus 6-3m			
<i>AlphaPose vs perinteinen menetelmä</i>			
<i>ei-parametrinen testi (Wilcoxon)</i>	Keskiarvo	Keskihajonta	p-arvo
M_angular_vel_knee_6_3	163.6000	17.46870	
A_angular_vel_knee_6-3	169.4000	48.72873	
parillinen ero			0.092
Polven kulmanopeus 3-0m			
<i>AlphaPose vs perinteinen menetelmä</i>			
<i>parillinen t-testi</i>	Keskiarvo	Keskihajonta	p-arvo
M_angular_vel_knee_3_0	359.1000	26.12980	
A_angular_vel_knee_3-0	382.3000	36.63347	
parillinen ero			0.041*
Säären kulmanopeus 6-3m			
<i>AlphaPose vs perinteinen menetelmä</i>			
<i>parillinen t-testi</i>	Keskiarvo	Keskihajonta	p-arvo
M_angular_vel_ss_6_3	2.7000	10.42486	
A_angular_vel_ss_6-3	13.6000	20.53290	
parillinen ero			0.148
Säären kulmanopeus 3-0m			
<i>AlphaPose vs perinteinen menetelmä</i>			
<i>ei-parametrinen testi (Wilcoxon)</i>	Keskiarvo	Keskihajonta	p-arvo
M_angular_vel_ss_3_0	102.4000	23.16223	
A_angular_vel_ss_3-0	93.2000	38.20064	
parillinen ero			0.333
Ylävartalon kulmanopeus 6-3m			
<i>AlphaPose vs perinteinen menetelmä</i>			
<i>parillinen t-testi</i>	Keskiarvo	Keskihajonta	p-arvo
M_angular_vel_ub_6_3	90.1000	16.72955	
A_angular_vel_ub_6-3	62.6000	20.79637	
parillinen ero			0.001**
Ylävartalon kulmanopeus 3-0m			
<i>AlphaPose vs perinteinen menetelmä</i>			
<i>ei-parametrinen testi (Wilcoxon)</i>	Keskiarvo	Keskihajonta	p-arvo
M_angular_vel_ub_3_0	166.8000	33.24254	
A_angular_vel_ub_3-0	134.9000	17.83536	
parillinen ero			0.013*

8 POHDINTA

Tutkimuksen tarkoituksena oli selvittää, kuinka hyvin koneoppimiseen ja asennon arviointiin pohjautuva analyysisovellus soveltuu mäkihyppyponnistuksen analyysiin, kun verrattavana menetelmänä on perinteinen, manuaalisesti kuva kovalta tehty videopohjainen analyysi. Mittausmenetelmää oli tarkoitus arvioida validiteetin ja reliabiliteetin näkökulmasta, eli kuinka oikeita arvoja mittausmenetelmä antaa ja kuinka paljon ne poikkeavat menetelmän sisällä. Tutkimustulosten perusteella vaikuttaa siltä, että analyysisovellus tuottaa nivelkulmatietoa ponnistuksesta toistettavasti, mutta ylävartalokulman osalta tuloksissa esiintyy luotettavuutta vähentävää hajontaa. Polvi- ja ylävartalokulmissa on havaittavissa säännönmukaista aliarviointia erityisesti laskuasennon aikana, mikä selittyy tulkintaeroista nivelpisteiden sijainnissa. Analyysisovellus on kuitenkin lupaava ja aikaa säästävä käytännön työkalu, jota voi hyödyntää valmennuskäytössä tietyin varauksin.

Tärkeänä seikkana mainittakoon, että tutkimusasetelmaan valikoitiin 40:stä hyppysuoritteesta satunnaisesti 10 hyppyä mukaan analyysiin ja etukäteen sopivan mittaisiksi käsitellyt videot käsittivät yhteensä 445 kuvaa. AlphaPose kykeni tunnistamaan näistä ihmisen 376:n kuvan osalta, jolloin jäljitys onnistui 84.5% tapauksista. Tilastolliset analyysit tehtiin AlphaPosen osalta siten, että siihen otettiin mukaan ne 376 kuvaa, joista molemmilla mittausmenetelmillä oli aineisto kerättyä. Näin ollen tilastollisesta analyysistä jätettiin 69 kuvaa pois, jotka oli manuaalisesti analysoitu, mutta niille ei ollut verrattavaa AlphaPosen tuottamaa mittausdataa saatavilla. AlphaPosen jokseenkin vain tyydyttävälle onnistumisprosentille kuvien hahmontunnistuksessa lienee monta selittävää tekijää. Ensinnäkin, hahmontunnistusalgoritmit (tässä tapauksessa YOLO) menettävät tarkkuuttaan tilanteissa, joissa tunnistettavilla hahmoilla on esimerkiksi löysää vaateetusta yllään, jotka peittävät henkilöahmolta keskeisimmät nivelet. Tätä ongelmaa pystyisi pienentämään käyttämällä opetusdataa, jossa kuvien annotointi on tehty hahmoilla, joilla on tilanteessa yllä monimuotoista, sekä tiukkaa että väljää vaateetusta. Tätä on onnistuneesti kokeiltu esimerkiksi Matsumoton ja kumppanien tutkimuksessa (Matsumoto ym. 2019), jossa peittyvien nivelten koordinaatit projisoitiin liikekaappauksista, joissa oli käytössä työistuvat vaatteet. Tässä tutkimuksessa kuvista yritettiin tunnistaa henkilöä, jolla oli yllään koko vartalon peittävä ja paikoin väljä hyppypuku. Lisäksi kuvissa jäljitettävän henkilön päätä

peitti kypärä ja kasvoja hyppylasit, jotka peittivät ihmispään luonnolliset muodot ja maamerkit alleen. Toisaalta, henkilön asento kuvissa laskuasennon aikana on ihmiselle hyvin erityislaatuinen ja kyseistä asentoa ei juuri käytetä muussa kontekstissa. Näin ollen konenäölle voi olla haastavaa tunnistaa hahmoa kyseisestä asennosta. Todennäköisesti AlphaPosen hyödyntämä opetusdata ei sisällä kuva-aineistoa henkilöistä, joilla olisi tämän kaltainen väljä hyppyasu ja poseerauksia mäkihypyn laskuasennolle tyypillisessä kyykkäävässä laskuasennossa. Tämän vaikutuksen saattoi huomata myös analyysisovelluksen ajoista, sillä useimmiten AlphaPose ei tunnistanut hyppääjää juuri videon alkupään kuvista. Tunnistaminen parani hyppyrin keulaa ja ilmalentoa kohden asennon oietessa. Hahmontunnistusta ei erikseen tutkittu tilastollisilla menetelmillä, mutta kymmenestä analysoidusta hypystä huonoin hahmontunnistusprosentti 51% (23/45) tuli videosta, jossa hyppääjällä oli kaksivärinen sinivalkoinen puku, vaaleanvihreällä kypärällä. Puvussa väri jakautui siniseen selkämykseen ja valkoiseen rintamukseen valkoisilla hihoilla. Tällainen hahmo on mahdollisesti värikontrastin ja kuvioinnin takia haastavampi tunnistaa ihmiseksi (Matsumoto ym. 2019) ja paremmin mäkihyppyyn soveltuvalla opetusdatalla hahmontunnistus voisi parantua entisestään. Tämän monitekstuuristen hyppypukujen prosentuaalisesti heikomman hahmontunnistuksen myötä (sekävärit: 81,7% (183/224) vs. kokotummat: 87,3% (193/221)) haluttiin vielä erikseen selvittää hyppypuvun värityksen vaikutusta analyysin tuloksiin tilastollisella analyysillä, mutta sekä ICC että korrelaatioanalyysi olivat molemmissa ryhmissä samansuuntaisia eikä varsinaisia mittausarvoeroja ryhmien kesken havaittu.

Muut mahdolliset selittävät tekijät kuvien kohtalaisen suurelle hylkäysprosentille liittyvät kuvaustekniisiin ja videon käsittelyyn liittyviin asioihin. Mäkiuoriturukset kuvattiin suurnopeuskameralla, kameran sijaitessa noin 18 metrin etäisyydellä. Kuvausalue osoittautui kuitenkin sen verran laajaksi, että sitä kohdistettiin jo kameran asetuksista kuvaustilanteessa. Videon käsittelyssä tätä kohdistusta vielä jatkettiin, jolloin saatiin kuvausalue mahdollisimman tarkasti osumaan tutkimusalueelle. Tämä kohdennus kuitenkin heikensi kuvan tarkkuutta merkittävästi, alkuperäisen resoluution ollessa vain 1920 x 1080 pikseliä. Kohdennuksen lisäksi, videoita käsiteltiin analyysisovelluksessa ennen AlphaPosen ajoa siten, että siitä poistettiin ylimääräiset kuvakaistaleet kaikista reunoista. Tällä haluttiin varmistaa, että minimoidaan kuvista kaikki ylimääräinen grafiikka, joka voisi vaikeuttaa hahmon tunnistusta.

Muistettakoon tässä kohtaa, että tutkimuksessa käytetty COCO:n tietosarja oletusasetuksella tuotti asennosta taulukon 3 mukaisesti nivelpistetiedot, joista analyysissä hyödynnettiin vain koordinaattitietoja kehon oikealta puolelta olkapäästä, lonkasta, polvesta ja nilkasta. Tutkimuksen aikana kokeiltiin myös Halpe-26 datasettiä (<https://github.com/Fang-Haoshu/Halpe-FullBody>) tuottamaa asennon arviointia, mutta se hylättiin heikon suoriutumisen takia. Tutkimuksen kuvauspaikka oli haasteellinen siinä mielessä, että hyppääjän nilkka peittyi näköesteen (raide) taakse hyppyripöydän kohdalla. Kyseinen näköeste sotki oleellisesti Halpe-26 datasetin tuottaman arvion jalkaterän koordinaateista. COCO datasetilläkin jalkaterän peittyminen esteen taakse johti siihen, että AlphaPose arvioi nilkan koordinaatit vaihtelevasti kuva kвалta ja nilkan sijainti saattoi liikkua kuvien välillä jopa 10 – 15 cm. Tällä puolestaan oli vaikutusta suoraan polvi- ja säärikulman laskentaan, sillä polvikulma määritettiin vektoreiden *lonkka-polvi* ja *nilkka-polvi* välisestä kulmasta ja säärikulma puolestaan vektoreiden *polvi-nilkka* ja *nilkka-x-akseli* (+ mäen kaltevuus silloisessa kohdassa) välisestä kulmasta. Näin ollen oli rajoitteisiin nähden odotettua nähdä suurempaa tulosten hajontaa nilkan sijaintitiedon avulla lasketuissa nivelkulmissa. AlphaPose vaikutti arvioivan olkapään sijaintia aavistuksen jopa niskan puolelle ja se erosi vastaavan tutkijan näkemyksestä. Näin ollen perinteisessä analyysissä olkapään sijainti oli selvästi edempänä, mikä tuottaa ainakin teoriassa pienemmän lantiokulman manuaalisessa analyysissä AlphaPoseen nähden. Toisaalta, AlphaPose vaikutti arvioivan lantion sijainnin ajoittain hieman takapainotteisesti, etenkin laskuasennon aikana ennen ponnistusliikettä. Perinteisen analyysin kohdalla siis tulkittiin lantion sijainti hieman edemmäs, mikä suurentaa lantiokulmaa hypyn alkuvaiheen kohdalla suhteessa AlphaPosen arvioon. Toki on syytä muistaa, että AlphaPosen tuottama arvio lantion sijainnista poikkeaa jo lähtökohtaisesti siinä, että se ei vastaa ison sarvennoisen (engl. greater trochanter) sijaintia, mitä yleisesti käytetään liikeanalyysissä (Cronin 2021).

Kuvausalue ja etäisyys ei myöskään ollut tutkimukselle ihanteellisin, sillä analyysissä voi selvästi havaita sen, että mittausalue ei ole täysin 2D-tasossa. Analyysin alkupäässä hyppääjä on aavistuksen etukulmasta nähden kuvattu ja ponnistuksen loppuvaiheessa ja alkuilmalennon aikana aavistuksen takaviistosta. Hyppyripöydän kohdalla hyppääjä sijaitsee puolestaan aavistuksen kuvauslinjan alapuolella. Tätä kutsutaan niin sanotuksi parallaksivirheeksi (engl. Parallax error), joka on videopohjaisissa liikeanalyysissä yleinen ilmiö (Martin ym. 2020). Nämä kaikki edellä esitetyt seikat osiltaan vääristävät suorituksista mitattuja nivelkulmia, mutta

kuvakulma on menetelmien kesken kuitenkin sama, joten siitä ei synny eroa menetelmien kesken. Tämä on kuitenkin hyvä huomioida suoritusten mittatuloksia tulkittaessa. Mittaajan sisäisen toistettavuuden testi (ICC) osoitti, että AlphaPose kykenee tuottamaan nivelkulmatietoa hyppysuorituksesta erittäin luotettavasti ja johdonmukaisesti. Tulosten perusteella vaikuttaa kuitenkin, että AlphaPose arvioi ylävartalokulman jokseenkin epävarmasti, sillä 95% luottamusvälin alarajalla esiintyi suurta hajontaa.

Mittausmenetelmien välille suoritettiin myös korrelaatioanalyysi, joka tukee ja vahvistaa esitettyjä mittausrajoitteita ja tutkimusasetelman haasteita. Korrelaatioanalyysillä pystyttiin näyttämään, että mitatut nivelkulmat korreloivat vahvasti menetelmien kesken. Näin ollen voidaan todeta, että eri mittausmenetelmät vaikuttaisivat mittaavan hyvin samaa asiaa. Lantiokulman korrelaatiokuvaaja (kuva 29) osoittaa jonkin verran hajontaa tapahtuvan, mutta lineaarisuora vaikuttaa antavan keskimäärin melko yhtenevän tuloksen menetelmien kesken. Polvikulma vaikuttaa korrelaatiokuvaajan (kuva 30) perusteella hajautuvan melko samaan tapaan kuin lantiokulmakin, mutta polvikulman lineaarisuoran perusteella voidaan havaita, että AlphaPose arvioisi säännönmukaisesti polvikulman perinteistä menetelmää pienemmäksi vauhtimäen laskun loppuvaiheeseen asti. Tämä voisi selittyä sillä, että AlphaPose arvioi lantion sijainnin taaemmaksi, kuin tutkija arvioi perinteisessä analyysissä, mikä puolestaan johti aiemmin mainittuun suurempaan kulmaan. Sääri- ja ylävartalokulmien osalta havaitaan jo merkittävästi enemmän havaintopisteiden hajautumista AlphaPosen osalta ja näin ollen säärikulman lineaarisuoraan ja sen kulmaan on suhtauduttava varauksella. Ylävartalon osalta korrelaation lineaarisuora on selvemmin nähtävissä, vaikka mittaushajontaa esiintyy siinäkin selvästi. Ylävartalon osalta havaitaan myös se, että perinteisen analyysin menetelmä tuottaa erityisesti ylämäen laskun loppuvaiheessa pienempiä mittaustuloksia AlphaPoseen nähden, mikä selittyy hyvin paljon sillä, että AlphaPose arvioi olkapään sijainnin enemmän niskan puolelle, kun taas perinteisen menetelmän analyysissä olkapään sijainti paikannettiin selvästi edemmäs. Tässäkin kohtaa sijaintiin vaikuttaa tutkijan subjektiivinen näkemys. Polvi- ja ylävartalokulman suhteellisen säännönmukainen vaihtelu ylämäen laskun aikana havaittiin myös analyysityökalun ajon yhteydessä, joten tilastollinen analyysi tukee tätä hyvin. Korrelaatioanalyysin kuvaajissa on nähtävissä myös muutama selvästi korrelaatiota heikentävä satunnainen mittausarvo, jossa menetelmien näkemys poikkeaa merkittävästi toisistaan. Nämä selittyvät lähinnä sillä, että AlphaPose ei ole onnistunut paikantamaan nivelpisteitä oikein,

vaikka hahmontunnistuksessa se on onnistunutkin. Nämä voisivat mahdollisesti selittyä esimerkiksi nivelpisteiden peitosta raajan tai muun näköesteen taakse.

Tämän tutkimuksen mittauksissa ei suoraan verrattu nivelpisteiden eroavuutta menetelmien välillä, vaan näistä johdettujen nivelkulmien välisiä eroja. Kun ottaa huomioon aikaisemmassa tutkimuksessa (Needham ym. 2021) esitellyn systemaattisen virheen suuruuden niveltä kohti (~30 – 50 mm paikannusvirhe nivelpisteessä sijainneeseen markkeriin nähden), ja toisaalta tiedetään nivelkulman määrittämisen perustuvan kolmen nivelpisteen tuottamaan tietoon (esimerkiksi lantiokulma olkapään, lantion ja polven sijaintitietojen avulla), voidaan tämän tutkimuksen tuloksia pitää jokseenkin samansuuntaisina Needhamin ja kumppanien tutkimuksen kanssa. 30-50 mm eroavaisuus kolmessa nivelpisteessä voi hyvinkin tuottaa 10-15° eroavaisuuksia nivelkulman laskentaan. Koska tässä tutkimuksessa olleen näköesteen takia nilkan paikannus oli selvästi heikompaa, voi sillä hyvin perustella vieläkin suuremmat vaihtelut sääri-suksikulmalla, mikä nähtiin tilastollisen analyysin hajonnassakin. Näen ollen nilkan paikannuksen suoriutumiskykyä ei tämän tutkimuksen osalta pysty kovin hyvin vertaamaan Needhamin (Needham ym. 2021) tutkimukseen.

AlphaPosen avulla tuotetulla analyysisovelluksella lasketaan jokaisen suorituksen yhteydessä kinemaattisia muuttujia. Sovellus laskee arviot ponnistuksen kestolle, lantion kulmanopeudelle hyppyrin keulan kohdalla, sekä kaikille neljälle tutkittavalle nivelelle kulmanopeudet kahdessa eri kohdassa hyppyripöytää. AlphaPose ei siis tuota näitä suoraan, vaan suureet on analyysisovelluksessa johdettu nivelpistetietojen avulla tuotettujen nivelkulmien avulla. Koska AlphaPose saattaa tehdä suuriakin hetkellisiä virheitä kuvasarjoissa, määritettiin analyysisovellukseen useamman asteen polynomifunktiot mallintamaan AlphaPosen mittausdataa. Tällä voitiin estää laskennoissa mahdollisia hetkellisiä AlphaPosen tuottamia virhearvioita. Vertailut menetelmien välillä tehtiin parillisella t-testillä. Tulosten perusteella nähdään, että ponnistuksen keston ja lantion kulmanopeuden määrittämisessä hyppyrin keulalla vaikuttaisi olevan melko hyvä vastaavuus menetelmien välillä. Muiden kinemaattisten muuttujien osalta vastaavuus oli heikkoa, muutaman muuttujan osalta nähtiin jopa tilastollinen ero (lantion kulmanopeus ($p=0.050^*$), polven kulmanopeus 3-0m ($p=0.041^*$), ylävartalon kulmanopeus 6-3m ($p=0.001^{**}$), ylävartalon kulmanopeus 3-0m (0.013^*)). Syitä menetelmien

väliseen heikkoon vastaavuuteen kinemaattisten muuttujien laskennassa on useita. Ensinnäkin kulmasuureita häiritsevät samat tulkintaerot menetelmien osalta, joita jo aiemmin avattiin. Toisekseen, mittausarvot määritettiin analyysisovelluksen läpi siten, että AlphaPosen laskelmissa oli mukana vain ne kuvat, joista hahmo onnistuttiin havaitsemaan. Manuaalisessa määrittämisessä hypyn kaikki kuvat olivat laskennan apuna. Käytännössä tämä tarkoittaa mahdollisuutta, että AlphaPosen tapauksessa 6 metrin tai 3 metrin kohdat onkin määritetty lähemmäksi hyppyrin keulaa pudotettujen kuvien takia. Analyysisovellus määrittää kulman sen perusteella, kun hypääjä ensimmäisen kerran ohittaa kuvasarjassa näiden mittapisteiden koordinaatit. Näin ollen eroja voi tämän myötä syntyä paljonkin, riippuen miten hahmontunnistus on onnistunut kyseisessä hypyssä.

Tutkimuksen selkeimmät rajoitteet olivat kuvausetäisyyden, kuvausalueen ja käytetyn kameran valinta sekä kuvauksen suorittaminen mäessä, jossa on selkeä rakennelmallinen näköeste jalkaterälle. Kuvausetäisyys ja kameran sijainti olisi voinut olla kauempana, jotta koko kuvausalue olisi tullut katettua 2D-tasossa. Tärkeämpi parannus olisi kuitenkin ollut suurempaan kuvaustarkkuuteen kykenevä kamera sekä kuvausalueen rajaaminen mahdollisimman lähelle kohdealuetta jo kuvaustilanteessa. Näillä säädöillä olisi voinut mahdollisesti vaikuttaa hahmontunnistuksen onnistumisprosenttiin positiivisesti. Nilkan paikannus olisi myös oleellisesti ollut parempaa mäessä, jossa ei esiinny yhtä korkeaa näköestettä jalkaterälle, vaikka useimmissa mäissä lienee kuitenkin jonkinlainen latu-urasta aiheutuva näköeste jalkaterälle. Myös heijastinmarkkereiden korvaaminen teipillä on sinällään ihan kelvollinen idea, mutta tulevissa tutkimuksissa kannattaa ennalta varmistua liimapinnan sopivuudesta hypypuvun materiaaliin. Nyt valittu teippi pysyi kiinni heikosti ja siitä ei saatu toivottua apua manuaalisessa analyysissä. Toisaalta teipit kannattanee kiinnittää myös hypääjän ollessa laskuasennossa, jotta teipin paikka ilmentäisi mahdollisimman tarkasti anatomisen maamerkin sijaintia. Myös valoporttien toiminnallisuuden varmistaminen ennen mittauksia olisi tärkeää, jotta nopeuslaskennalle saataisiin mukaan referenssimittausmenetelmä ja tilastollinen analyysilaskenta. Vastaisuudessa olisi hyvä myös selvittää analyysityökalun tarkkuuden mahdollinen paraneminen, mikäli opetusdata tuotettaisiin alusta asti juuri mäkihyppyyn tarkoitettulla kuva-aineistolla. Hyötyä voisi olla esimerkiksi kuvata staattisia laskuasentokuvia hyppyripöydällä käyttäen erilaista vaatetusta: tiukkaa, väljää, yksiväristä, monitekstuurista. Hyötyä voisi saavuttaa myös suorittamalla kuvauksia sellaisista staattisista

asennoista, joissa kädet on sijoitettu esimerkiksi eteen, jolloin kaikki nivelet tulevat näkyviin kuvissa. Opetusdatan olisi hyödyllistä olla mahdollisimman monipuolista (Matsumoto ym. 2019).

8.1 Johtopäätökset

Tutkimustyössä havaittiin, että AlphaPosen forkattu sovellusversio soveltuu tietyiltä osin mittaamaan nivelkulmia ja tuottamaan esimerkiksi niveltiedoista dataa ajan funktiona. Erityisen hyvin se vaikutti suoriutuvan polven- ja lantiokulman määrittämisessä. Nilkkanivelen paikannus ei toiminut toivotusti, sillä näköeste häiritsi paikannusta. On kuitenkin huomioitava, että tutkijan kuvista määrittämät nivelpisteet eivät välttämättä ole arvoina yhtään sen oikeampia kuin mitä AlphaPose tuotti polven, lantion ja olkapään osalta, sillä ne perustuivat vain subjektiiviseen näkemykseen kuva kovalta. Erityisen hankalaa määrittäminen oli hyppysuorituksissa, joissa oli kokotumma hyppypuku, sillä hahmosta oli hankalaa erottaa yksityiskohtia. Huomionarvoista oli kuitenkin se, että analyysisovellus pystyi määrittämään ponnistuksen keston (liikkeen aloitus ennen keulaa) ja myös hyppyrin keulan kohdalla olevan lantion kulmanopeuden suhteellisen tarkasti verrattuna manuaaliseen laskentaan. Tutkimuksen tausta huomioiden, näiden tietojen luotettava saaminen analyysityökalusta on tärkeää, sillä tutkimustiedon valossa melko erityyppisilläkin ponnistustyyyleillä voi päästä yhtä hyvään hyppypituuteen ja lantion kulmanopeuden hyppyrin keulalla on havaittu korreloivan hypyn pituuden kanssa (Virmavirta ym. 2009). Mittausmenetelmän tarkkuutta voi vielä merkittävästi parantaa huomioimalla tutkimuksessa ilmenneet puutteet ja käyttämällä mäkihyppyyn paremmin soveltuvaa itse tuotettua opetusdata-aineistoa. Analyysisovelluksen hyödyntäminen valmennuksen apuna on operatiivisesti kannattavaa, sillä sen avulla voidaan vähentää manuaaliseen analyysiin kuluva henkilöresurssi ja työaika.

LÄHTEET

- Alpaydin, E. 2010. Introduction to Machine Learning. 2. painos. Cambridge, Massachusetts Lontoo, Englanti. The MIT Press
- Arndt, A., Brüggemann, G., Virravirta, M., & Komi, P. 1995. Techniques Used by Olympic Ski Jumpers in the Transition from Takeoff to Early Flight. *Journal of Applied Biomechanics* 11(2), 224-237.
- Babu, S. C. 2019. Human Pose Estimation with Deep Learning [blogikirjoitus]. Viitattu 02.04.2021. <https://nanonets.com/blog/human-pose-estimation-2d-guide/>.
- Bessone, V., Petrat, J. & Schwirtz, A. 2019. Ground Reaction Forces and Kinematics of Ski Jump Landing Using Wearable Sensors. *Sensors (Basel, Switzerland)*, 19(9),2011
- Brownlee, J. 28.01.2019. Loss and Loss Functions for Training Deep Learning Neural Networks [blogikirjoitus]. Viitattu 30.04.2021. <https://machinelearningmastery.com/loss-and-loss-functions-for-training-deep-learning-neural-networks/>
- Brownlee, J. 27.01.2021. A Gentle Introduction to Object Recognition With Deep Learning [blogikirjoitus]. Viitattu 30.04.2021. <https://machinelearningmastery.com/object-recognition-with-deep-learning/>
- Carey, K., Abruzzo, B., Lowrance, C., Sturzinger, E., Arnold, R. & Korpela, C. 2020. Comparison of Skeleton Models and Classification Accuracy for Posture-Based Threat Assessment Using Deep-Learning. *Artificial Intelligence and Machine Learning for Multi-Domain Operations Applications II (Vol. 11413)*.

- Chardonens, J., Favre, J., Le Callennec, B., Cuendet, F., Gremion, G. & Aminian, K. 2012. Automatic measurement of key ski jumping phases and temporal events with a wearable system. *Journal of Sports Sciences*, 30(1), 53-61.
- Corazza, S., Mündermann, L., Chaudhari, A., Demattio, T., Cobelli, C. & Andriacchi, T. 2006. A Markerless Motion Capture System to Study Musculoskeletal Biomechanics: Visual Hull and Simulated Annealing Approach. *Annals of Biomedical Engineering*, 34(6), 1019-1029.
- Cormack, G. & Lynam, T. 2006. Statistical Precision of Information Retrieval Evaluation. Konferenssi: SIGIR 2006: Proceedings of the 29th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval, Seattle, Washington, USA, Elokuu 6-11, 2006. Viitattu 15.06.2021.
<https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.521.369&rep=rep1&type=pdf>
- Cronin, N. 2021. Using deep neural networks for kinematic analysis: Challenges and opportunities. *Journal of Biomechanics*, Volume 123, 23.06.2021, 110460. Viitattu 23.05.2021. <https://www.sciencedirect.com/science/article/pii/S0021929021002402>.
- Elements of AI. 2021. "Neural network basics.". Viitattu 02.04.2021.
<https://course.elementsofai.com/5/1>
- Ettema, G. J., Braten, S. & Bobbert, M. F. 2005. Dynamics of the in-run in ski jumping: a simulation study. *Journal of Applied Biomechanics*, 21(3), 247-59.

- Everingham, M., Van Gool, L., Williams, C. K. I., Winn, J. & Zisserman, A. 2010. The Pascal Visual Object Classes (VOC) Challenge. *International Journal of Computer Vision* volume 88, pages303–338 (2010).
- Fern'ndez-Baena, A., Susin, A. & Lligadas, X. 2012. Biomechanical Validation of Upper-Body and Lower-Body Joint Movements of Kinect Motion Capture Data for Rehabilitation Treatments. *Konferenssi: Intelligent Networking and Collaborative Systems (INCoS)*. 656-661. Viitattu 30.04.2021.
<https://ieeexplore.ieee.org/document/6338001>
- Fritz, J., Kröll, J., Jenny, H. & Schwameder, H. 2019. In-field measurement of vertical and horizontal forces in ski-jumping: Evaluation of a portable two-dimensional force plate. *Proceedings of the Institution of Mechanical Engineers, Part P: Journal of Sports Engineering and Technology*, 233(1), 126-134.
- Gershenson, C. 2003. *Artificial Neural Networks for Beginners*. Viitattu 14.06.2021.
<https://arxiv.org/ftp/cs/papers/0308/0308031.pdf>
- Girdhar, R., Gkioxari, G., Torresani, L., Paluri, M. & Tran, D. 2017. Detect-and-Track: Efficient Pose Estimation in Videos. Viitattu 11.05.2021.
<https://arxiv.org/pdf/1712.09184.pdf>
- Goodfellow, I., Bengio, Y. & Courville, A. 2016. *Deep Learning*. MIT Press. Viitattu 06.04.2021. <http://www.deeplearningbook.org>.
- Gulbrandsen, Å.M. 2015. Are there characteristic movement variations in the take-off technique and do they affect performance related kinetic variables? *Ski Jumping – a*

principal component analysis of technique training. Master's thesis in Human Movement Science. Faculty of medicine (DMF), Department of Neuroscience. Julkaisija: NTNU.

Fang, H-S., Xie, S., Tai, Y-W. & Lu, C. 2017. RMPE: Regional Multi-Person Pose Estimation. Konferenssi: 2017 IEEE International Conference on Computer Vision (ICCV), 22-29.10.2017. Venezia, Italia. Viitattu 30.04.2021.
<https://ieeexplore.ieee.org/document/8237518>

Heino, H. 2019. Syvät neuroverkot ja kuvien käsittely [blogikirjoitus]. Viitattu 30.04.2021.
https://aidmei.blogspot.com/2019/08/syvat-neuroverkot-ja-kuvien-kasittely_94.html

Janura, M., Cabell, L., Elfmark, M. & Vaverka, F. 2010. Kinematic Characteristics of the Ski Jump Inrun: A 10-Year Longitudinal Study. *Journal of Applied Biomechanics*, 26(2), 196-204.

Janura, M., Cabell, L., Svoboda, Z., Elfmark, M., & Zahalka, F. 2011. Kinematic Analysis of the Take-Off and Start of the Early Flight Phase on a Large Hill (HS-134 m) during the 2009 Nordic World Ski Championships. *Journal of Human Kinetics*, 27(1), 5-16.

Jiang, B., Luo, R., Mao, J., Xiao, T., & Jiang, Y. 2018. Acquisition of Localization Confidence for Accurate Object Detection. Viitattu 14.06.2021.
<https://arxiv.org/pdf/1807.11590.pdf>.

Khan, A. I. & Al-Habsi, S. 2020. Machine Learning in Computer Vision. *Procedia Computer Science*, 167, 1444-1451.

- Komi, P.V. & Virravirta, M. 2000. Determinants of successful ski jumping performance. Teoksessa: V. Zatziorsky (toim.) Biomechanics in Sport. Oxford, Blackwell Science. 349-362.
- Krogh, A. 2008. What are artificial neural networks? Nat Biotechnol 26, s. 195-197. Viitattu 12.06.2021. <https://www.nature.com/articles/nbt1386>.
- Lai, K-T. 2020. Machine Learning Basics. Viitattu 28.9.2020. http://www.aiotlab.org/\teaching/intro2ai/slides/2_intro_machine_learning.pdf
- Lu, C., Fang, H-S., Li, J., Tang, H., Xu, C., Zhu, H., Xiu, Y. & Li, Y-L. 2017. AlphaPose. Viitattu 28.04.2021. <https://github.com/MVIG-SJTU/AlphaPose>.
- Lu, C., Fang, H-S. & Li, J. 2018. AlphaPose – Aman Bhandula. Viitattu 28.04.2021. <https://github.com/Amanbhandula/AlphaPose>.
- Martin, T., Frisch, K., & Zwart, J. 2020. Systematic Errors in Video Analysis. The Physics Teacher Vol 58 (issue 3), 195 (2020).
- Matsumoto, T., Shimosato, K., Maeda, T., Murakami, T., Murakoso, K., Mino, K. & Ukita, N. 2019. Human Pose Annotation Using a Motion Capture System for Loose-Fitting Clothes. 06/2020. IEICE Transactions on Information and Systems E103.D(6):1257-1264
- Mechelli, A. & Vieira, S. 2020. Machine learning. Lontoo, Englanti: Academic Press.
- Merriau, P., Dupuis, Y., Boutteau, R., Vasseur, P., & Savatier, X. 2017. A Study of Vicon System Positioning Performance. Sensors (Basel, Switzerland), 17(7), 1591.

- Mohri, M., Rostamizadeh, A. & Talwalkar, A. 2018. *Foundation of machine learning*. Toimien painos. Cambridge, Englanti: The MIT Press.
- Munea, T. L., Jembre, Y. Z., Weldegebriel, H. T., Chen, L., Huang, C. & Yang, C. 2020. *The Progress of Human Pose Estimation: A Survey and Taxonomy of Models Applied in 2D Human Pose Estimation*. *IEEE Access* (2020, Vol. 8).
- Müller, E., & Schwameder, H. 2003. Biomechanical aspects of new techniques in alpine skiing and ski-jumping. *Journal of Sports Sciences*, 21(9), 679-692.
- Müller, W. 2006. *The physics of ski jumping*. Department of Biophysics, Medical University of Graz, Itävalta. Viitattu 30.04.2021. <https://cds.cern.ch/record/1009275/files/p269.pdf>
- Müller, S., Kreibich, S. & Seide, I. 2015. *Analysis of the take-off of top ski jumpers*. Teoksessa Hakkarainen, A., Linnamo, V., & Lindinger, S. (toim.). 2016. *Science and Nordic Skiing III*. Jyväskylä, Suomi: Jyväskylä University Printing House. 141–146.
- Murakami, M., Iwase, M., Seo, K., Ohgi, Y., & Koyanagi, R. 2010. Ski jumping flight skill analysis based on high-speed video image. *Procedia Engineering*, 2(2), 2381-2386.
- Needham, L., Evans, M., Cosker, D.P., Wade, L., McGuigan, P.M., Bilzon, J.L. & Colyer, S.L. 2021. *Human Movement Science in The Wild: Can Current Deep-Learning Based Pose Estimation Free Us from The Lab?* Center for the Analysis of Motion, Entertainment Research and Applications, University of Bath, Bath, UK. Viitattu 29.04.2021. <https://www.biorxiv.org/content/10.1101/2021.04.22.440909v1.full.pdf>
- Nicholson, C. 2021. *A Beginner's Guide to Neural Networks and Deep Learning*. Pathmind. Viitattu 02.04.2021. <https://pathmind.com/wiki/neural-network>.

- Niinimäki, E., Pölonen, I., Rautiainen, I., Tuominen, H. & Äyrämö, S. 2019. Luokittelu- ja ennustemenetelmät. Teoksessa: Tekoälyn perusteita ja sovelluksia. 2019. Neittaanmäki, P. & Tuominen, H. (toim.). <http://urn.fi/URN:ISBN:978-951-39-7796-2>. s. 11-23.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. 2016. You Only Look Once: Unified, Real-Time Object Detection. Konferenssi: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 779-788. Viitattu 30.04.2021.
<https://ieeexplore.ieee.org/document/7780460>
- Sachan, A. 2018. Zero to Hero: Guide to Object Detection using Deep Learning: Faster R-CNN, YOLO, SSD. Viitattu 08.04.2021. <https://cv-tricks.com/object-detection/faster-r-cnn-yolo-ssd/>.
- Sasaki, T., Tsunoda, K. & Hoshino, H. 1998. Three techniques of ski jump take-off modeled by changes of joint angle. Julkaistu teoksessa XVI international symposium on biomechanics in sports. UVK – University of Konstanz: Konstanz. 133-136.
- Schmölzer, B., & Müller, W. 2002. The importance of being light: aerodynamic forces and weight in ski jumping. *Journal of Biomechanics*, 35(8), 1059-1069.
- Schmölzer, B., & Müller, W. 2005. Individual flight styles in ski jumping: results obtained during Olympic Games competitions. *Journal of Biomechanics*, 38(5), 1055-1065.
- Schwameder, H. & Müller, E. 1995. Biomechanische beschreibung und analyse der V-technik im skispringen. *Spectrum der Sportwissenschaft* 7 (1), 5-36

- Schwameder, H., Müller, E., Raschner, C. & Brunner, F. 1997. Aspects of Technique-Specific Strength Training in Ski-Jumping.. Teoksessa Müller, E., Schwameder, H., Kornexl, E. & Raschner, C. (toim.). 1997. Science and Skiing (s. 307-317). Lontoo, Weinheim: E & FN SPON (Painettu: Chapman & Hall).
- Schwameder, H., & Müller, E. 2001. Biomechanics in ski jumping: A review. European Journal of Sport Science, 1(1), 1-16.
- Schwameder, H., Müller, E., Lindenhofer, E., De Monte, G., Potthast, W., Brüggemann, G-P., Virmavirta, M., Isolehto, J. & Komi, P. 2005. Kinematic characteristics of the early flight phase in ski-jumping. Teoksessa Müller, E. (toim.). 2005. Science and Skiing III (s. 381-391). Meyer & Meyer Sport, Adelaide
- Schwameder, H. 2008. Biomechanics research in ski jumping, 1991-2006. Sports Biomechanics, 7(1), 114-136.
- Schwameder, H. 2012. Challenges and issues in ski jumping biomechanics. Teoksessa Müller, E., Lindinger, S. & Stöggl, T. 2012. Science and Skiing V. Vol 5. Meyer & Meyer Sport.
- Seo, K., Murakami, M., & Yoshida, K. 2004. Optimal flight technique for V-style ski jumping. Sports Engineering, 7(2), 97-103.
- Shalev-Shwartz, S. & Ben-David, S. 2014. Understanding machine learning. Cambridge, Englanti: Cambridge University Press.
- Shameer, K., Johnson, K. W., Glicksberg, B. S., Dudley, J. T. & Sengupta, P. P. 2018. Machine learning in cardiovascular medicine: Are we there yet? Heart 104 (14), 1156-1164.

- Sharma, Siddharth, Sharma, Simone & Athaiya, A. 2020. Activation Functions in Neural Networks. *International Journal of Engineering Applied Sciences and Technology*, 2020. Vol 4, Issue 12, ISSN 2455-2143, s. 310-316.
- Krenker, A., Bešter, J. & Kos, A. 2011. Introduction to the Artificial Neural Networks. Teoksessa Suzuki, K. (toim.). 2011. *Artificial Neural Networks – Methodological Advances and Biomedical Applications*. InTech. Viitattu 12.06.2021.
https://www.researchgate.net/publication/319316102_Artificial_Neural_Networks_-_Methodological_Advances_and_Biomedical_Applications. s. 3-18
- Tuominen, H. 2019. Neuroverkkojen matemaattiset perusteet. Teoksessa *Tekoälyn perusteita ja sovelluksia*. 2019. Neittaanmäki, P. & Tuominen, H. (toim.). Viitattu 30.04.2021.
https://jyx.jyu.fi/bitstream/handle/123456789/64975/Tekoalyn_Perusteita_edit.pdf?sequence=1&isAllowed=y. s. 23-55.
- Tuominen, H. & Neittaanmäki, P. 2019. *Tekoälyn perusteita ja sovelluksia*. 2019. Neittaanmäki, P. & Tuominen, H. (toim.). Viitattu 30.04.2021.
https://jyx.jyu.fi/bitstream/handle/123456789/64975/Tekoalyn_Perusteita_edit.pdf?sequence=1&isAllowed=y. s. 1-11.
- van der Kruk, E. & Reijne, M. M. 2018. Accuracy of human motion capture systems for sport applications; state-of-the-art review. *European Journal of Sport Science*, 18(6), 806-819.
- Vaverka, F. 1987. *Biomechanics in ski-jumping*. Olomouc: Univerzita Palackého.
- Virmavirta, M. & Komi, P. V. 1989. The Takeoff Forces in Ski Jumping. *International Journal of Sport Biomechanics*, 5(2), 248-257.

- Virmavirta, M. & Komi, P. V. 1994. Takeoff analysis of a champion ski jumper. *Coaching and Sport Science Journal* (1994). 1:1:23-27.
- Virmavirta, M., Kivekäs, J. & Komi, P. V. 2001. Take-off aerodynamics in ski jumping. *Journal of Biomechanics*, 34(4), 465-470.
- Virmavirta, M. & Komi, P. V. 2001. Plantar pressure and EMG activity of simulated and actual ski jumping take-off. *Scandinavian Journal of Medicine & Science in Sports*, 11(5), 310-314. 10.1034/j.1600-0838.2001.110510.x
- Virmavirta, M., Perttunen, J. & Komi, P. V. 2001. EMG activities and plantar pressures during ski jumping take-off on three different sized hills. *Journal of Electromyography and Kinesiology*, 11(2), 141-147.
- Virmavirta, M., Isolehto, J., Komi, P., Schwameder, H., Pigozzi, F. & Massazza, G. 2009. Take-off analysis of the Olympic ski jumping competition (HS-106m). *Journal of Biomechanics* 42 (2009), 1095–1101.
- Vodičar, J. & Jošt, B. 2011. The relationship between selected kinematic parameters and length of jumps of the ski-flying competition. *Kinesiology* 43(2011) 1:74-81.
- Vähäkainu, P. & Neittaanmäki, P. 2017. *Tekoäly terveydenhuollossa*. Jyväskylän Yliopisto. Informaatioteknologian tiedekunta. Tekes-hanke: Value from Public Health Data with Cognitive Computing. Viitattu 02.04.2021. <http://www.ks2020.fi/wp-content/uploads/2017/06/LIITE-6.-Teko%C3%A4ly-terveydenhuollossa.pdf>

Yamanobe, K., Shirasaki, K., Akashi, K. & Ishige, Y. 2016. The effects of upper limbs position on the aerodynamics in ski jumping flight. 34th International Conference of Biomechanics in Sport (2016).

Zheng, C., Wu, W., Yang, T., Zhu, S., Chen, C., Liu, R., Shen, J., Kehtarnavaz, N. & Shah, M. 2020. Deep Learning-Based Human Pose Estimation: A Survey. Viitattu 30.04.2021. <https://arxiv.org/abs/2012.13392>