

Jesse Kananen

Juoksijan kontaktiajan arviointi kiihtyvyyssanturilla

Tietotekniikan pro gradu -tutkielma

1. heinäkuuta 2020

Jyväskylän yliopisto

Informaatioteknologian tiedekunta

Tekijä: Jesse Kananen

Yhteystiedot: jesse.j.kananen@student.jyu.fi

Ohjaaja: Tommi Kärkkäinen

Työn nimi: Juoksijan kontaktiajan arviointi kiihtyvyyssanturilla

Title in English: Estimating runner's contact time with acceleration sensor

Työ: Pro gradu -tutkielma

Suuntautumisvaihtoehto: Ohjelmistotekniikka

Sivumäärä: 73+1

Tiivistelmä:

Tässä tutkielmassa selvitettiin juoksijan kontaktiajan arviointia kenkään kiinnitettävän kiihtyvyyssanturin datasta. Tutkielma noudatti suunnittelutieteellisen tutkimuksen paradigmaa. Arvioiminen suoritettiin luokitteluongelmana satunnaismetsäalgoritmillä. Luokittelija tunnisti kontaktihetket 88,2 % tarkkuudella. Kaikkiaan kontaktihetkistä 76,9 % luokiteltiin oikein. Estimointi sopivalla sovellutuksella on mahdollista. Tutkielma antaa suuntaviivat, joilla mallin kaltaista ratkaisua voi soveltaa käytännössä.

Avainsanat: design science, kontaktiaika, juokсутekniikka, tiedonlouhinta, satunnaismetsä

Abstract:

The research question of this thesis is estimating runner's ground contact time from a shoe attached acceleration sensor. The research followed the Design Science Research paradigm. Estimating the contact time was performed as a classification problem with a Random Forest algorithm. The classification models were able to classify contact moments with the precision of 88,2 %. Of all the contact moments 76,9 % were classified correctly. Estimation is possible with a fitting application. The thesis guidelines how the classification model would be applicable and usable in practice.

Keywords: design science, contact time, running technique, data mining, random forest

Kuviot

Kuvio 1. Jalkaan tukivaiheessa vaikuttavat voimat Lohman, Sackiriyas ja Wesley Swen (2011, s.155) mukaan. Lyhenteiden merkitykset: Fz on vertikaalinen voima, Fy anteroposteriorinen horisontaalivoima, Fx lateraalinen horisontaalivoima.	18
Kuvio 2. Axivity AX3-kiihtyvyyssanturin akselisto. Anturi asetettiin kenkään siten, että X-akselin suunta oli kohti kengän kantaa, Z-akseli kengänpohjaan ja Y-akseli kengän vasemmalle sivulle. Kuva Axivity AX3:n käyttöohjekirjasta.	31
Kuvio 3. Esimerkkiotos kiihtyvyyssanturin normalisoidusta datasta kahden askeleen ajalta. Näkyvillä akselit X, Y ja Z. Kuvaaja luotu MATLAB:lla.	33
Kuvio 4. Esimerkkiotos voimalevyn normalisoidusta datasta. Kuvaaja kuvaa maahan kohdistuvaa vertikaalista reaktiovoimaa kahden askeleen ajalta. Toisessa askeleessa huomattavissa jarrutus ja siten askellus kantapäälle. Kuvaaja luotu MATLAB:lla.	34
Kuvio 5. Esimerkkiotos kiihtyvyyssanturin normalisoidusta datasta kahden askeleen ajalta. Näkyvillä akselit X, Y ja Z. Kuvaaja luotu MATLAB:lla.	35
Kuvio 6. Esimerkkiotos suorituksen nollakohdan määrittämisestä. Nähtävillä hetki, kun henkilö astuu voimalevyille, hyppää kolmesti ja jää seisomaan levyn päälle. Data on normalisoitu, mutta tarkka synkronointi on vielä tässä vaiheessa tekemättä.	36
Kuvio 7. Kaikkien mallien ja havaintojen yhteenlasketut tulokset. Kuvaajassa jalkojen askelten luokat on yhdistetty yhdeksi luokaksi. Kuvaaja piirretty MATLAB:lla. Recall on laskettu matriisin oikealle puolelle ja tarkkuus alapuolelle.	50
Kuvio 8. Kuvaajassa näkyvissä luokittelijan tekemät luokittelut sekä todelliset luokat. Otos valittu satunnaisesti, kuvaaja piirretty MATLAB:lla.	52

Taulukot

Taulukko 1. Voimalevydatan kynnsarvot juoksijoittain. Suluissa olevaa kynnsarvoa on käytetty keskimäärin vain yhdessä tai kahdessa segmentissä.	40
Taulukko 2. Arviointimetriikoiden laskentakaavat.	44
Taulukko 3. Aineiston luokkien määrät.	45
Taulukko 4. Mallien tarkkuus, recall ja F1-mitta juoksijoittain ja luokittain.	47

Sisältö

1	JOHDANTO	1
1.1	Tutkimuskysymys	1
1.2	Aikaisempi tutkimus	2
1.3	Tutkielman rakenne	3
2	SUUNNITTELUTIETEELLINEN TUTKIMUS	5
2.1	Tutkimusprosessin suuntaviivat.....	7
2.2	Artefakti	11
2.3	Tiedollinen kontribuutio	12
2.4	Yhteenveto.....	14
3	JUOKSUTEKNIikka	16
3.1	Juoksun biomekaniikka	16
3.2	Kontaktiaika osana juoksutekniikkaa.....	18
4	VALITUT MENETELMÄT	21
4.1	Tiedonetsintä ja tiedonlouhinta	21
4.2	Luokittelumenetelmä.....	25
4.3	Satunnaismetsät	26
4.4	Ristiinvalidointi.....	27
4.5	Fourier-muunnos	28
5	SUUNNITTELU JA KEHITYS.....	31
5.1	Koeasetelma	31
5.2	Koeasetelman olosuhteiden vaikutus juoksusuoritukseen	32
5.3	Datan muoto	32
5.4	Datan prosessointi	34
5.5	Suorituksen nollakohta.....	36
5.6	Alustakontaktin alku ja loppu.....	37
5.7	Esiprosessointi.....	38
5.8	Prosessoinnin vaiheiden yhteenveto	40
6	IMPLEMENTOINTI JA TULOKSET.....	42
6.1	Toteutus	42
6.2	Artefaktin arviointimetriikat	42
6.3	Tulokset ja arviointi	45
7	JOHTOPÄÄTÖKSET.....	54
7.1	Tutkimuksellinen arviointi	54
7.2	Tekniset säännöt	55
7.3	Tiedollisen kontribuution arviointi	56
8	YHTEENVETO.....	58

LÄHTEET	60
LIITTEET.....	69
A Koehenkilöiden tiedot.....	69

1 Johdanto

Monessa eri urheilulajissa vahvan tieteellinen valmennusmalli ohjaa jo jokapäiväistä harjoittelua ja suoritustekniikkaa kokemusperäisen tiedon sijaan. Näin on tapahtunut myös juoksemisessa. Tekniikan kehittyminen on mahdollistanut juoksun harjoitteluun ja tutkimukseen uudenlaisen tarkastelun. Samalla erilaiset aiempaa helpommin hankittavat teknisen mittauksen mahdollistavat välineet ovat tulleet myös tavallisen käyttäjän ja kuluttajan saataville. Tieto omasta suorituksesta on saatavilla välittömästi suorituksen aikana ja sitä voi verrata aiempiin suorituksiin heti harjoitteen jälkeen. Tekninen kehitys on edelleen lisännyt erityistä kiinnostusta harjoittelun seurantaan ja kehittämiseen.

Juoksun tekniikka on yksinkertaisuudessaan monipuolinen käsite. Eräs juoksutekniikkaa vahvasti määrittävä mitattava määre on juoksijan kontaktiaika eli se aika, kun juoksijan jalka koskettaa maata. Kontaktiajan määrittämiseen on monenlaisia keinoja, mutta kustannustehokas ja siirrettävä, yleiskäyttöinen menetelmä on vielä puuttunut. Siksi sen laskemiseen ja arvioimiseen on hyvä etsiä uudenlaisia näkökulmia.

Tutkielmassa on etsitty kontaktiajan estimointiin uudenlaisia lähestymistapoja tiedonlouhinnan menetelmistä. Tutkimusongelmaan, sen teoreettiseen taustaan sekä tiedonlouhinnan yleisimpiin menetelmiin perehtymisen jälkeen käytetyksi menetelmäksi valikoitui yleisesti suosittu ja tarkimpana luokittelijana pidetty satunnaismetsäluokittelija.

Tutkielmassa on sovellettu tutkimustieteellisen tutkimuksen prosessimallia. Prosessimalli on tukenut iteratiivista tutkielman laatimista, jossa sovellusalueen teoriaan ja edellisiin tutkimuksen vaiheisiin ja jatkuvasti uuteen ymmärrykseen pohjaten luodaan lopputulos eli artefakti.

1.1 Tutkimuskysymys

Juoksijan kontaktiaika on tärkeä osa juoksutekniikan analysointia. Weyand ym. (2000) mukaan juoksunopeus riippuu enemmän maahan kohdistuvista kontaktivoimista kuin nopeamasta jalkojen liikkeestä. Kontaktivoimat taas riippuvat siitä ajasta, jonka jalka on kosketuk-

sisä maahan. Tätä aikaa kutsutaan kontaktiajaksi. Juoksijan kontaktiajan ja juoksun taloudellisuuden välistä riippuvuutta on tutkittu jonkin verran. Tutkimukset ovat saaneet toisistaan merkittävästi poikkeavia tuloksia: yhtäältä kontaktiajalla ja taloudellisuudella on nähty riippuvan toisistaan, toisaalta niiden välillä ei ole havaittu minkäänlaista yhteyttä. (ks. esim. Chapman ym. 2012; Daniels ja Daniels 1992; Stickford ym. 2014) Tutkimuksissa käytetyt menetelmät ja tekniikat ovat kuitenkin olleet vajavaiset. Osaltaan tutkimusta ovat myös vaikeuttaneet kontaktiajan mittaamiseen tarvittavat välineet. Kontaktiajan laskemiseksi on tarvittu erillisiä voimalevyjä, jotka ovat kalliita ja vaativat kiinteän asentamisen mittauspaikalle. Erilaiset kiihtyvyyssanturien hyödyntämiseen perustuvat laskentamenetelmät ovat yleistyneet vasta viime vuosina, mutta menetelmiä on tähän mennessä vain vähän. Halpaan ja helppokäyttöiseen kiihtyvyyssanturiin perustuvan menetelmän löytäminen mahdollistaisi kontaktiajan paremman seurannan myös tavallisille harrastajille.

Lisäksi juoksijan kontaktiaika on liitoksissa muihin juoksusta mitattaviin määreisiin. Kontaktiajasta on laskettavissa myös juoksijan nopeus, joka taas on hyödyllistä ja tärkeää esimerkiksi juostessa alueilla, joissa GPS-sensorien signaali on heikko ja täten toimintakin epävarmaa. Tällaisia paikkoja ovat esimerkiksi sisätilat. (Ruiter ym. 2016)

Tässä tutkielmassa tarkastellaan juoksijan kontaktiajan laskemista kiihtyvyyssanturin datasta tiedonlouhinnan menetelmillä. Tutkielman tavoitteena on määrittää tiedonlouhintaan pohjautuva malli, jolla juoksijan kontaktiaika olisi mahdollista mitata riittävän hyvällä tarkkuudella. Tutkielmassa ei rakenneta kontaktiaikaa täsmälleen määrittävää sovellutusta, vaan perehdytään tiedonlouhinnan mahdollisuuksiin sitä estimoidessa.

Tämän pro gradu-tutkielman pääkysymys on: Onko juoksijan kontaktiaika mahdollista estimoida kiihtyvyyssanturin datasta tiedonlouhinnan menetelmillä?

1.2 Aikaisempi tutkimus

Kiihtyvyyssantureita on hyödynnetty monissa eri juoksua tarkastelevissa sovellutuksissa, joiden avulla juoksijan suoritusta voi analysoida ja parantaa. Esimerkiksi Patterson, McGrath ja Caulfield (2011) ovat hyödyntäneet kiihtyvyyssanturista saatavaa dataa erityisesti pitkän matkan juoksijan väsymisen analyysissä. Kontaktiaikaa on myös käytetty juoksijoiden askelei-

den metabolisten kustannusten tarkkailussa (Chapman ym. 2012). Lisäksi Ruitter ym. (2016) ovat tutkimuksessaan todenneet, että juoksijan nopeus on ennustettavissa pelkästään juoksijan kontaktiajan perusteella.

Juoksijan kontaktiajan mittaamista kiihtyvyyssanturilla on tutkittu aikaisemmin ilman koneoppimista ja tiedonlouhintaa. Purcell ym. (2006) päätyivät tutkimuksessaan tulokseen, että mittaaminen on mahdollista. Heidän tutkimuksessaan koehenkilöt juoksivat kolmea eri nopeutta: hölkkää, juoksua ja spurttivauhtia. Käytetty kiihtyvyyssanturi kiinnitettiin juoksijan sääreen. Kontaktiajan laskemisessa he käyttivät itse luotua MATLAB-sovellusta, mutta eivät tarkemmin määrittele käytettyjä menetelmiä. He saivat kontaktiajan mittauksen keskiarvoksi voimalevyjen ja kiihtyvyyssanturin välillä 0 ± 12 ms hölkkätessä, -2 ± 3 ms juostessa ja -1 ± 1 ms spurtatessa. Tämän tutkielman tavoitteena on selvittää tiedonlouhinnan ja luokittelun mahdollisuudet kontaktiajan estimoinnissa. Käytännössä tämä tarkoittaa sitä, että luokittelijan tulee tunnistaa juoksijan alustakontaktit kiihtyvyyssanturin datan perusteella. Erona Purcell ym. (2006) tutkimukseen on myös se, että kiihtyvyyssanturi on kiinnitetty juoksijan nauhojen alle oikeaan kenkään, jotta jalan kautta kiihtyvyyssanturiin kohdistuvat voimat ovat tarkemmin mitattavissa.

Tiedonlouhinnan menetelmiä juoksun analysoinnissa on hyödynnetty monissa eri tutkimuksissa. Muiden muassa Osis ym. (2014) ovat tutkimuksessaan luoneet juoksusuoritteesta 3D-analyysin ja arvioineet kontaktiaikaa pääkomponenttianalyysillä. Osis, Hetinga ja Ferber (2016) ovat jatkaneet työtä liittämällä analyysiin myös koneoppimisen, mutta jatkaneet pääkomponenttianalyysin hyödyntämistä. Myös Jauhiainen ym. (2020) ovat tutkimuksessaan luokitelleet juoksutyylejä eri klustereihin koneoppimisen menetelmillä.

1.3 Tutkielman rakenne

Tutkielman rakenne noudattaa pitkälti suunnittelutieteellisen tutkimuksen tutkimusprosessirunkoa, jota avataan tarkemmin seuraavassa luvussa. Luvussa kaksi (Suunnittelutieteellinen tutkimus) avataan suunnittelutieteellisen tutkimuksen perinnettä ja käsitteitä, sen tutkimusprosessin suuntaviivoja sekä tuloksia ja niiden arvioimista. Ne muodostavat tutkielman rungon ja ohjaavat sen etenemistä. Kolmannessa luvussa (Juoksutekniikka) taustoitetaan tutki-

muksen kannalta oleellista kohdealueen teoriapohjaa. Siinä tarkastellaan juoksua biomekaanisena suoritteena sekä yhdistetään kontaktiaika osaksi laajempaa kontekstiaan. Tämä luku luo pohjaa ja perustaa tutkimuskysymyksen laajemmalle ymmärrykselle sekä sen soveltamiselle. Luku neljä (Valitut menetelmät) sitä vastoin taustoittaa tiedonlouhinnan teoriaa ja tutkielmaan valittuja ja siinä käytettyjä menetelmiä. Luku viisi (Suunnittelu ja kehitys) taas avaa tutkielman koeasetelmaa käytännössä. Luvussa lukijalle selvitetään, miten data tallennettiin ja millaista dataa tallennuksessa saatiin. Datan esimerkkien kautta lukijalle avataan sitä, miten dataa analysoitiin, millä tavoin mitattava kontaktiaika ilmenee datassa ja kuinka dataa valmisteltiin varsinaista tiedonlouhintaa varten. Luku kuusi (Implementointi ja tulokset) nivoo yhteen tutkielman käytännön implementoinnin ja niillä saadut tulokset. Lopuksi luvussa seitsemän (Johtopäätökset) pohditaan tutkimustieteellisen prosessin teoreettisia tuloksia teknisten sääntöjen ja tiedollisen kontribuution muodoissa.

2 Suunnittelutieteellinen tutkimus

Tietotekniikan tutkimuksellisen kentän tieto syntyy koneiden ja ihmisten tiedon kohtaamis-
pisteessä. Teoriaa taas tarvitaan luonnollisen maailman ja ihmisten konstruoiman maailman
linkittämiseen. (Gregor 2006)

Tutkielma sijoittuu niin sanotun suunnittelutieteen tutkimuksen eli Design Science Research-
hin (DSR) piiriin. Termi *design* (suom. suunnittelu) tarkoittaa DSR:n näkökulmasta "keksi-
mistä sekä luomista". Tämä tarkoittaa siis jonkin uuden luomista. Vielä tutkimattomassa, tie-
dollisessa aukossa tapahtuva innovatiivinen suunnittelu taas tarvitsee avukseen tutkimusta.
(Vaishnavi, Kuechler ja Petter 2004) Suunnittelutieteellinen tutkimus eroaa siis perinteisis-
tä luonnontieteistä siinä, että sen alainen tutkimus keskittyy keinotekoiseen maailmaa siinä
missä luonnontieteet tarkastelevat luonnollista maailmaa. Lisäksi siinä missä luonnon- ja so-
siaalitieteiden tutkimukset pyrkivät ymmärtämään ja selittämään maailmaa, suunnittelutie-
teellinen tutkimus rakentaa ihmisiä hyödyttäviä asioita. (Simon 1996) DSR on tietotekniikan
tutkimuksessa käytettävä joukko analyyttisiä menetelmiä ja rakenteita. Vaishnavi, Kuechler
ja Petter (2004) nimittävät sitä linssiksi, jonka tarjoamat perspektiivit ovat luonteeltaan po-
sitivistisia, tulkitsevia ja kriittisiä. DSR kertoo, miten jotakin tehdään (Gregor 2006). Tässä
tutkielmassa tämä tarkoittaa siis niin sen esittämistä, kuinka kiihtyvyyssanturilla tallennetus-
ta datasta saadaan muodostettua malli, joka arvioi juoksijan kontaktiajan, kuin itse luotua
mallia.

DSR:n määrittely on monipuolistunut erilaisten tutkimusten myötä. Kuechler ja Vaishnavi
(2012) tuovat DSR:iin kolme uutta määritelmää ja käsitettä. Ensimmäinen käsitteistä on De-
sign Science Research in Information Systems (DSRIS), joka määrittää mitä DSR on. Hei-
dän näkökulmassaan DSRIS tarkastelee uusia ja teoretisoimattomia tietojärjestelmätieteen
alueita konstruktivistisesti tilastollisten menetelmien sijaan. Lisäksi DSRIS sekä rakentaa
että testaa luodut menetelmät. Toinen käsite, Information Systems Design Theory (ISDT)-
menetelmä luo preskriptiivisiä toteamuksia, jotka kuvaavat oletusta eri artefaktien käyttäyty-
misestä ja siitä, miten ne ovat konstruoitavissa. Viimeinen eli Design Relevant Explanatory
/ Predictive Theory (DREPT) on taas teoria, joka täydentää ISDT-menetelmän toteamuksia
selittämällä miksi artefaktit käyttäytyvät kuten ISDT:n avulla on havaittu.

Kuechler ja Vaishnavi (2012) lisäksi muun muassa Peffers, Tuunainen ja Niehaves (2018) ovat hahmotelleet suunnittelutieteellisen tutkimuksen tyyppien jakamista yhteensä viiteen eri genreen.

Genreistä ensimmäisenä he näkevät informaatiotieteellisen tutkimuksen (engl. *IS Design Theory*). Sen keskiössä ovat itsessään suunnittelutieteen teoriat, joita tutkimus jäsentää ja esittää. Tällaista tutkimusta ovat hahmotelleet muun muassa Gregor ja Jones (2007), jotka ovat hahmotelleet artikkelissaan suunnittelutieteellisen teorian mallia informaatiotieteen näkökulmasta.

Suunnitteluorientoituneessa informaatiotieteellisen tutkimuksessa (engl. *Design-Oriented IS Research*) taas korostetaan suunnittelun ja erityisesti sen toteuttamisen merkitystä. Tässä suunnittelutieteellisen tutkimuksen alueessa tarkoitus on suunnitella paremmin toimivia tieteknisiä ratkaisuja. (Österle ym. 2011)

Peffers ym. (2007) taas ovat korostaneet kehitettävän artefaktin soveltuvuutta. Heidän näkemyksensä on nimetty suunnittelutieteellisen tutkimuksen metodologiaksi (engl. *Design Science Research Methodology*). Näkökulmassa painottuu käytäntönsä soveltuvien artefaktin kehitys, joka on avoin monenlaisille eri prosessimalleille. Tutkimusalue voi siis olla sekä toiminnallista että teoriapainotteista tutkimusta riippuen kehitettävästä artefaktista ja sen kehitystyön painotuksista.

Metodien ja teorioiden tutkimukseen keskittyä myös selittävä suunnitteluteoria (engl. *Explanatory Design Theory*). Tässä tutkimuksessa teoria on erityisesti tutkimuksen ytimenä ja kehityksen kohteena. Siinä eri teorioita testataan erillisten hypoteesien kautta arvioiden. Tämä mahdollistaa myös kokeellisemmat tutkimukset. Artefakti taas nähdään enemmänkin väliin haluttuun lopputulokseen, ei niinkään itseisarvoisena lopputuloksena.

Viimeisenä suunnittelutieteen alueena Peffers, Tuunainen ja Niehaves (2018) näkevät toiminnallisen suunnitteluteorian (engl. *Action Design Research, ADR*). Alun perin idean ovat esitelleet Sein ym. (2011). Nimensä mukaisesti pääpaino tutkimusalueessa on ongelmanratkaisuun keskittyneiden artefaktien suunnittelussa. Artefakti taas pohjaa teoriaan. Muista genreistä eroten tämän tutkimusalueen ytimessä on käytännöllisyys. Toiminnallinen suunnitteluteoreettinen tutkimus linkittää teorian käytäntöön ja siten siis myös ajattelutyön varsi-

naiseen tekemiseen. (Peffer, Tuunainen ja Niehaves 2018) Lisäksi Sein ym. (2011) liittävät artefaktien rakennusprosessin ja arvioinnin osaksi organisaation tarpeita, joista myös alkupe-
räinen ongelma on peräisin. ADR:ssä luotava artefakti sijoitetaan jo lähtökohtaisesti organi-
sationaaliseen ongelmaan kuitenkin säilyttäen alkuperäiset DSR:n ohjenuorat (Haj-Bolouri
ym. 2018). Käytännössä Sein ym. (2011) yhteensovittaa IT-organisaatioissa käytetyn itera-
tiivisen kehitysmallin ja -prosessin yhteen tieteellisen suunnitteluteoreettisen tutkimuksen
kanssa.

Tämä tutkielma liittyy selvästi genreistä Peffer ym. (2007) mukaiseen suunnittelutieteel-
liseen tutkimuksen metodologiaan. Lähtökohtana tutkielmassa on tarve määrittää juoksijan
kontakiaika kiihtyvyyssanturilla. Teorian kautta rakennettu ymmärrys juoksutekniikasta sekä
datan prosessoinnista, käsittelystä ja analysoinnista antaa sen pohjan, jolla artefakti rakenne-
taan tutkimusongelman kannalta toimivaksi. Ongelmanratkaisu lähtee käytännöllisestä tar-
peesta ja artefaktia arvioidaan soveltuvuuden kautta.

2.1 Tutkimusprosessin suuntaviivat

Hevner ja Chatterjee (2010) määrittelee DSR:n tutkimusparadigmaksi, jossa suunnitellaan
ratkaisuja ongelmiin lopputulemana artefaktien kautta. Lisäksi ratkaisut ovat käyttökelpoi-
suudessaan hyödyllisiä, mutta myös lisäävät kuvatun ilmiön tieteellistä ymmärrystä.

Behavioristinen tutkimus tuottaa tietotekniikan teorioita ja siten totuuksia, joille DSR raken-
tuu. DSR taas tuottaa artefaktien kautta käytännön sovellutuksia, joita behavioristiset tut-
kimukset hyödyntävät (Hevner ja Chatterjee 2010). Artefaktien tarkoituksena onkin tuottaa
niiden rakentamisprosessin kautta uutta tietopohjaa, mutta myös analyysia artefaktien käy-
töstä tai suorituskyvystä (Vaishnavi, Kuechler ja Petter 2004).

DSR:n pohjalla ovat käsiteltävään viitekehukseen liittyvä ydinteoria. Sitä täydentävät ko-
kemusperäiset näkemykset teknologisesta ongelmasta. ISDT-teoria syntyy preskriptiivisistä
havainnoista, joita tehdään koko DSR-prosessin ajan. DREPT-teoriat taas selittävät sitä, mi-
ten ja miksi juuri kyseinen käytetty suunnittelumalli tuottaa uutta tietoa. ISDT sen sijaan kes-
kittyy käytäntöön. Se vastaa kysymyksiin miten ja mitä kehitetään. (Kuechler ja Vaishnavi
2012)

Peffer ym. (2007) painottavatkin yhteisen viitekehyksen ja mentaalisen mallin merkitystä suunnittelutieteelliselle tutkimukselle. Ensimmäiseksi tunnistetaan ratkaistava ongelma, jolla ongelman ratkaisumalli perustellaan. Toiseksi määritellään tavoitteet, joita ratkaisulla halutaan saavuttaa. Niiden tulee olla sekä mahdollisia että toteutettavissa. Kolmanneksi suunnitellaan ja toteutetaan ratkaisu. Tässä vaiheessa rakennetaan artefakti, joka ratkaisee määritellyn ongelman määritettyjen tavoitteiden mukaisesti. Neljäntenä vaiheena toimii artefaktin soveltaminen käytännössä. Artefaktia siis käytetään siinä tarkoituksessa, johon se on suunniteltu. Samalla osoitetaan, että kehitetty artefakti toimii. Seuraavassa eli viidennessä kehitysvaiheessa käytetty ratkaisumalli asetetaan arvioinnin alle. Artefaktia siis verrataan aiemmin asetettuihin tavoitteisiin ja kriteereihin. Pohjana tälle arvioinnille toimivat edellisen vaiheen kokeilut artefaktista käytännössä. Viimeisessä, kuudennessa vaiheessa kommunikoidaan tutkimusprosessin tulokset. Kommunikaatio kattaa kaikkien aiempien vaiheiden raportoinnin. Vaiheen tarkoituksena on tarjota pohjaa uudelle tutkimukselle.

Suuntaviivoja ovat esitelleet myös muut. Esimerkiksi Hevner ym. (2004) tarjoavat artikkelissaan seitsemän erilaista suuntaviivaa DSR-tutkimukselle:

1. Suunnittelu artefaktina
2. Ongelmarelevanssi
3. Suunnittelun arviointi
4. Myötävaikutus tutkimukselle
5. Tutkimuksen tarkkuus
6. Suunnittelu etsintäprosessina
7. Tutkimuksen kommunikointi

Nämä suuntaviivat on yleisesti hyväksytty oleelliseksi osaksi hyvän DSR-tutkimuksen pohjalle (Hevner ja Chatterjee 2010). Näin ollen DSR-tutkimuksen lopullisia tuloksia on hyvä arvioida esitettyjen suuntaviivojen kautta. Tutkielman luku seitsemän (Johtopäätökset) mukaileekin näitä suuntaviivoja.

DSR:ään pohjaavan tutkimusprosessin käytännön kehitystyö on luonteeltaan iteratiivista. Alustava suunnitelma voi ja todennäköisesti muuttuu, kun kehitystyössä tullaan tietoisiksi uusista ongelmista. Muutokset voivat tulla missä kehitystyön vaiheessa tahansa. Esimerkik-

si tuotettavaa artefaktia muutetaan sitä mukaa, kun sen toimintaa ja sovellutusta arvioidaan. Mikäli toteutustapa osoittautuu esimerkiksi epätarkaksi, tulee suunnitelmaa ja siten myös artefaktia muuttaa tarkempaan suuntaan (Hevner ja Chatterjee 2010).

Huolimatta siitä, että tutkielmaa on ohjannut suunnittelutieteen metodologia, tarjoaa toiminnallinen suunnittelutiede hyödyllistä apua tutkielman jäsentämiseksi. Suuntaviivojen myötä esimerkiksi Sein ym. (2011) ja heidän näkemystään täydentäneet Mullarkey ja Hevner (2019) ovat hahmotelleet toiminnallisen suunnittelutieteellisen tutkimuksen prosessimallia. Mallit ovat samankaltaiset, vaikka käytetyt termit ja käsitteet vaihtelevat.

ADR vastaa prosessiltaan perinteistä DSR-tutkimusta. Ensin laaditaan tutkimukselle tutkimuskysymys, jonka jälkeen rakennetaan artefakti. Tämän toimintaa ja sovellusta arvioidaan taas tutkimuskysymyksen kautta. Vaihetta jatketaan niin kauan kunnes ratkaisu on haluttu lopputuloksen tavoitteet täyttävä. Koko prosessin ajan harjoitetaan jatkuvaa reflektointia ja oppimista, jolla taas peilataan rakennuksen ja arvioinnin syklin vaihetta. (Haj-Bolouri ym. 2018)

Sein ym. (2011) mallissa ADR:n prosessi on nelivaiheinen:

1. Ongelman kaavoittaminen
2. Rakentaminen, interventio, arviointi
3. Reflektointi ja oppiminen
4. Oppimisen kaavoittaminen

Mullarkey ja Hevner (2019) mukainen ADR-malli on:

1. Diagnoosi
2. Suunnittelu
3. Implementointi
4. Evoluutio

Mullarkey ja Hevner (2019) määrittelemässä ADR:n tutkimusprosessissa Sein ym. (2011) prosessimalli toistuu, mutta ne ovat nimetty yksinkertaisemmin ja siinä korostuvat Sein ym. (2011) mukaisesti aiemmasta oppimisen myötä uudelleensuunnittelu ja iteratiivinen kehitys. Molemmat ovat käytännön tasolla samanlaisia malleja. Mallien esittelemät vaiheet

ohjaavat tutkielman rakennetta.

Kuechler ja Vaishnavi (2012) esittelemä DSR-tutkimusmenetelmärakenne muodostaa tämän tutkielman teoreettisen rungon. Siinä korostuvat kolme vaihetta. Ensimmäiseksi tutkittava artefakti konstruoidaan joko käytännöllisestä tai teoreettisesta näkökulmasta. Toiseksi artefaktin toiminnasta kerätään data. Viimeiseksi reflektoidaan konstruointiprosessia ja kerätystä datasta tehtyjä implikaatioita suhteessa artefaktiin tai sen teoriaan. Tämän tutkielman tutkimusprosessi mukaillee käytännössä Mullarkey ja Hevner (2019) tutkimusprosessin sykliä seuraavasti:

1. Ongelman kaavoittaminen ja suunnittelu
2. Artefaktin luominen
3. Arviointi
4. Reflektointi
5. Oppiminen

Samalla tutkimusprosessia ohjataan Mullarkey ja Hevner (2019) mukaisesti diagnosoiden, suunnitellen, uudelleen implementoiden sekä kehittyen seuraavaan evoluutioon. Siinä missä Mullarkey ja Hevner (2019) artikkelissaan pohjaavat iteraatioiden välisen kehityksen enemmän käytännölliselle organisaation interventiolle, toimii malli sen ulkopuolellakin. Interventio on tapahtunut siis jo siinä vaiheessa, kun luotua artefaktia arvioidaan ja kehitetään. Mikäli tutkimusprosessi taas suoritettaisiin organisaation kontekstissa, voisi artefaktina luotua kontaktiaikaa estimoivaa mallia testata käytännön kokeessa.

Kaavoittaminen ja suunnittelu pohjaa teoriaan ja on käytännön innoittamaa. Artefaktin rakentaminen lähtee ongelman taas abstraktoinnista. Arvioinnissa artefaktin toimintaa tarkastellaan suorituskyvyn näkökulmasta. Reflektointivaihe tarkastelee edellisessä vaiheessa kerättyä dataa ja artefaktin luomisprosessia ja niiden vaikutusta artefaktin muodostamaan tietoon tai teoriaan. Oppimisessa syntyneet lopputuotokset yleistetään, jonka pohjalta ongelmaa tarkastellaan uudelleen. Tästä myös syntyy osa kaavoittamisen ja suunnittelun käytännöllisestä pohjasta. (Mullarkey ja Hevner 2019)

2.2 Artefakti

Artefaktit käsitetään tässä tutkielmassa Hevner ja Chatterjee (2010) mukaisesti ihmisten luomuksiksi. Lisäksi Simon (1996) määrittää artefaktit rajapintana itsensä artefaktin sisäisen ympäristön ja olemuksen sekä sen ulkoisen toimintaympäristön välillä. Näin ollen artefaktit ovat erotettavissa luonnollisesti ilmenevistä asioista. Artefaktien tulee joko parantaa olemassa olevaa ratkaisua ongelmaan tai ratkaista se ensimmäistä kertaa. Artefaktin käytännöllisyyden ratkaisee sen toimivuus sisäisen ja ulkoisen ympäristön yhteensovittajana: mikäli sen sisäinen ympäristö vastaa ulkoista, on artefakti toimiva. March ja Smith (1995) ovatkin kuvanneet, että DSR koostuu kahdesta erilaisesta toiminnasta: rakentamisesta ja arvioinnista. Mikäli artefakti on täysin uniikki ja uusi, ei erillinen suorituskyvyn arviointi ole tarpeellista. Jos ratkaistavaan ongelmaan on jo valmis malli, tulee uuden ratkaisun olla merkittävästi parempi. Tällöin arviointivaiheella on erityistä painoarvoa DSR-tutkimusprosessissa. Aken (2004) on täydentänyt edellä esitettyä March ja Smith (1995) näkemystä. Hän on tuonut arviointiin mukaan teknisen säännön käsitteen. Tekniset säännöt ovat yleistä tietoa, jotka liittävät artefaktin ja sen toiminnan sovellutuksen tiettyyn kenttään (Aken 2004). Järvinen (2012) huomauttaakin, että vaikka tekniset säännöt ovatkin uusi käsite DSR-tutkimuksessa, ovat ne lähinnä kuvauksia muutoksen toteuttamisesta.

Tietotekniset, DSR:n prosessin lopputuotteena syntyneet artefaktit ovat luonteeltaan (March ja Smith 1995):

- rakenteita (sanastoa ja symboleja)
- malleja (abstraktioita ja representaatioita)
- metodeja (algoritmit ja käytännöt)
- ilmentymiä (implementoituja järjestelmäprototyyppejä)
- aiempaa parempia suunnitteluteorioita

March ja Smith (1995) mukaan Design Science Research tuottaa neljäntyyppisiä lopputuloksia: rakenteita, malleja, metodeja sekä implementaatioita. Rakenteilla tarkoitetaan ilmiötä hahmottavia konsepteja. Mallit taas ovat luonteeltaan kuvailevia: ne kuvaavat tehtäviä, tilanteita ja artefakteja. Metodit puolestaan ovat ohjeita jonkin tietyn tehtävän suorittamiseksi. Dwivedi, Purao ja Straub (2014) ovat hahmotelleet, että suurin osa DSR:n luomista

artefakteista ovat useaa risteävää tyyppiä. He havaitsivat tutkimuksessaan erityisen yhteyden metodien ja ilmentymien välillä.

DSR eroaa siis luonnontieteistä lopputavoitteiden osalta. Siinä missä luonnontieteet tavallisesti keskittyvät ymmärtämään ja hahmottamaan maailmaa, keskittyy DSR luomaan sovellutuksia ihmisiä varten. DSR:n keskiössä on teknologia ja sen kautta saavutettavat sovellutukset. Design Science Researchin ytimenä ovat artefaktit. Tieto ja ymmärrys suunnitteluongelmasta muotoutuvat artefaktin rakentamisen ja soveltamisen myötä. Tätä Hevner ja Chatterjee (2010) nimittää DSR:n ensimmäiseksi peruseriaatteenksi. Hyvän DSR-tutkimuksen tulisi pohjata teorioihin ja kehyksiin sekä tuottaa uutta tietopohjaa entisen pohjalle. Davern ja Parkes (2010) kirjoittaakin, että DSR on enemmän kuin vain hyvää tekniikkaa ja teknistä osaamista.

Tässä tutkielmassa artefaktilla tarkoitetaan syntynyttä mallia, jolla juoksijan kontaktiaika on mahdollista mitata kiihtyvyyssanturin avulla ilman painelevyjä. Syntyneen mallin toimivuuden taas ratkaisee se, miten hyvin artefaktin sisäinen ympäristö eli arvioitu kontaktihetki on suhteessa ulkoiseen maailmaan eli todelliseen, painelevyillä mitattuun kontaktihetkeen nähden.

2.3 Tiedollinen kontribuutio

March ja Smith (1995) mukaan DSR tuottaa sekä rakennelmia, malleja ja metodeja että myös implementaatioita, mutta he jättävät teorian tuottamisen luonnontieteille. Kuechler ja Vaishnavi (2012) täydentävät DSR:n lopputulosten listaa. Heidän näkemyksessään DSR tuottaa artefaktin lisäksi uutta ISDT-teoriaa sekä suunnitteluun liittyen selittävää tai ennustavaa DREPT-teoriaa. Artefakti on väistämätön lopputulos, mutta uudet teoriat sitä vastoin eivät. Teoriat liittyvät kuitenkin oleellisesti suunnittelutieteellisen tutkimuksen lopputuloksiin ja siten myös sen prosessiin.

Teorian ja artefaktin välistä suhdetta suunnittelutieteellisen tutkimuksen viitekehyksessä ovat pohtineet muiden muassa sekä Hevner (2007) ja Iivari (2007) että Davern ja Parkes (2010). Hevner (2007) pitää teorioita tärkeänä lähteenä luoville ideoille, mutta pitää mahdottomana ajatusta, että kaikki DSR-tutkimus tulisi perustua teorialle. Hän korostaakin teoriapoh-

jan monipuolisuutta ja monitieteellisyttä. Davern ja Parkes (2010) näkevät teoria-artefakti-suhteen syklisenä, jossa syklin vaihe määrittää sen, miten suhde nähdään. Heidän mukaansa ei ole kysymys siitä, kumpi ohjaa kumpaa, vaan suhde toimii molempiin suuntiin sekä teoriasta artefaktiin että artefaktista teoriaan. Davern ja Parkes (2010) esittävätkin, että teorian ja artefaktin suunnittelun yhteensovittaminen vaatii nimenomaan selittävän ja ennustavan että suunnittelun ja toiminnan mallien syklittämistä.

Lopputulosta taas arvioidaan sen käytännöllisyyden ja toimivuuden perusteella. Lisäksi uusia menetelmiä tarkastellaan suhteessa entisiin: tuoko se parannusta vanhaan? DSR-tutkimusmenetelmän tarkoituksena on tuottaa innovatiivisia ja merkittäviä malleja, metodeja ja implementaatioita. Arvioinnissa on tärkeää, että arviointikriteerit ja -metriikat perustuvat lopputuotoksen käyttöympäristön asettamiin vaatimuksiin ja tarpeisiin (March ja Smith 1995). Gregor ja Hevner (2013) esittävät, ettei pelkkä artefakti ja sen arvioiminen tee suunnittelutieteellisestä tutkimuksesta relevanttia. Artefaktin luomisen lisäksi tutkimuksen tulee tarjota tiedollista kontribuutiota omalle lähtökohtaiselle tietopohjalleen. Näkemykset tietopohjan edistämiseksi vaihtelevat eri suunnittelutieteen alalajien mukaan. Käytännössä jaottelun voi tehdä pragmaattisten ja teoreettisten lajien välille.

Jakolinjoja hälventääkseen Gregor ja Hevner (2013) ovat korostaneet artefaktin roolia. Ongelmana he pitävät erityisesti sitä, että IT-artefaktit ovat usein konkreettisia tuotteita teoreettisten abstraktioiden sijaan. Näin yleisten teorioiden ja niiden kehityksen myötävaikutukseen tähtäävät yleistämiset vaikeutuvat. Gregor ja Hevner (2013) jakavatkin artefaktitulokset innovoinnin, parantamisen, muunnosten ja rutiinin käsitteillä. Innovoinnit ovat täysin uusia ratkaisuja uusiin ongelmiin, parantamisessa taas vanha ongelma ratkaistaan uudella tavalla, muunnoksissa tunnetut ratkaisumallit ratkaisevat uusia ongelmia ja rutiiniratkaisuissa vanhoissa ongelmissa hyödynnetään myös vanhoja ratkaisuja. Ensin mainitut tuottavat eniten uutta tietoa, kun taas viimeiseksi mainittu ei käytännössä kartuta tiedollista pohjaa. Gregor ja Hevner (2013) puhuvatkin tutkimuksen maturiteetin asteesta, jota määritellään korkeammalle sen mukaan, mitä enemmän ratkaisu luo uutta tietoa käytännön tai sovellutuksen tasolla.

Gregor ja Hevner (ss. 341-432 2013) jakavat artefaktien kontribuutiotyypit eri tasoihin. Ensimmäiselle ja siten alimmalle tasolle he asettavat artefaktit, jotka on toteutettu implementaa-

tioina. Käytännössä näitä ovat esimerkiksi käyttöön otetut sovellukset tai prosessit. Toisella tasolla ovat suunnittelutieteen prosesseihin lisäarvoa tuottavat metodit, mallit, suunnitteluperiaatteet ja tekniset säännöt. Tämän tason kontribuutioita yhdistää sidonnaisuus teorioihin ja tietopohjaan. Kolmannella, ylimmällä tasolla ovat suunnittelutieteelliset teoriat, jotka ovat yleistettävissä aina niin sanotuiksi suuriksi teorioiksi (engl. *Grand Theory*) asti.

Woo, Saghafi ja Rosales (2014) jakavat DSR:n tiedolliset kontribuutiot teorian ja teknologisen mallin tyyppeihin. Lisäksi kontribuutio voi tapahtua tutkimuskentän sisäisesti tai leviävän sen ulkopuolelle. Molempia kontribuutiotyyppejä voidaan arvioida sen mukaan, miten ne tuottavat tietoa: vain omalle kentälleen vai kenttien välisesti jakaen. Teoriat voivat täydentää oman tutkimusalan tietoa tai tukea vastaavasti muita tutkimusalueita. Teknologisissa malleissa taas on kysymys havainnoista. Teknologiset mallit - jollainen myös tämän tutkielman myötä syntyvä artefakti on - tuottavat havainnoilla ympäristöstään tietoa, joka on teoriasta riippumaton. Siten ne voivat paljastaa tutkijoille teorian saavuttamattomissa olevia ilmiöitä. (Woo, Saghafi ja Rosales 2014) Näin ollen sen vaikutus on parhaimmillaan kenttien välinen. Uudet, artefaktia soveltavat teoriat voivat hyödyntää sen havaintoja ja tiedollista kontribuutiota omasta alastaan.

Olemukseltaan abstraktit teoriat voivat siis parantaa ymmärrystä, tarjota selityksiä tai jopa ennustaa tulevaa. Ne voivat synnyttää siis uusia teknologisia malleja. Sama toimii myös toiseen suuntaan teknologisesta mallista teoriaksi. Esimerkiksi tiedonlouhinta on alun perin ollut teknologinen malli, jonka pohjalle teoreettinen ymmärrys on rakentunut. (Woo, Saghafi ja Rosales 2014) DSR:n tulokset voivat siis sisältää tämänkaltaisiakin artefakteja.

2.4 Yhteenveto

Tässä luvussa esiteltiin suunnittelutieteellisen tutkimuksen prosessimallia, sen erilaisia alatyyppejä sekä lopputuotoksia, joita nimitetään artefakteiksi. Artefaktit voivat olla monenlaisia aina abstrakteista teorioista lähtien käytännölliseen algoritmiin, malliin tai sovellukseen saakka. Tässä tutkielmassa laadittava artefakti on malli, jolla juoksijan kontaktiaikaa voidaan arvioida. DSR:n IT-artefakteille oleellista on se sovellutus, jota varten artefakti tuotetaan. Käytäntö määrittää sen, kuinka hyvin artefakti toimii, ja siten myös suunnittelutie-

teellisen tutkimuksen kontribuution. DSR:n prosessimalli on iteratiivinen ja etenee aina sovellutuksen teoreettisen pohjan ymmärtämisen ja artefaktin luomisen kautta sen arvioimiseen ja reflektioon jatkuvasti artefaktia kehittäen. Artefaktien lisäksi suunnittelutieteellinen tutkimus tuottaa teknisiä sääntöjä ja tiedollista kontribuutiota, jotka osaltaan määrittävät DSR:n onnistumista ja tutkimuksellista tulosta. Tutkielman runko rakentuu DSR:n prosessimallin mukaisesti. Lisäksi lopputuloksen arvioinnissa hyödynnetään DSR-tutkimukselle esitettyjä suuntaviivoja kuten suunnittelua artefaktina, suunnittelun arviointia ja sen myötävaikutusta.

3 Juoksutekniikka

Tässä luvussa taustoitetaan tutkielman teoreettista taustaa juoksutekniikan osalta. Ensin perehdytään juoksun biomekaniikkaan kokonaisuutena. Lisäksi juoksu puretaan erillisiksi osakokonaisuuksiksi. Tämän jälkeen tutkielman tarkastelun kohteena oleva kontaktiaika liitetään osaksi juoksutekniikkaa ja käsitellään sen merkitystä esimerkiksi juoksun taloudellisuuden kannalta.

3.1 Juoksun biomekaniikka

Juoksu on liikkeenä monipuolinen, koordinaatiota vaativa ja koko kehoa kuormittava toiminto. Juoksu on askellaji, jonka mitattava perusyksikkö on askelsykli. Askelsyklin aluksi lasketaan hetki, jolloin yksi jalka koskettaa alustaa ja se katsotaan loppuneeksi, kun sama jalka koskettaa alustaa uudelleen. Juoksussa ei ole hetkeä, jolloin molemmat jalat olisivat yhtä aikaa alustassa. (Baharuddin ym. 2009; Enoka 2008; Novacheck 1998) Kävely vaihtuu siis juoksuksi siinä vaiheessa, kun jalat eivät enää kosketa alustaa samalla hetkellä (Novacheck 1998).


Karkeimmillaan askelsykli on jaettavissa kahteen eri vaiheeseen: tuki- ja heilahdusvaiheeseen. Hetkeä, jolloin jalka koskettaa alustaa, kutsutaan tukivaiheeksi. Hetki, kun jalka taas irtoaa alustasta ja on ilmassa, on taas heilahdusvaihe. Heilahdusvaihe taas voidaan jakaa sen alkuun sekä keski- että loppuvaiheeseen (**parencite {enoka2008}**). Lisäksi leijumisvaiheeksi kutsutaan sitä hetkeä, kun kumpikaan jaloista ei ole kontaktissa alustaan (Dugan ja Bhat 2005). Juoksun askelsykliä voidaan jakaa yhä pienempiin erilaisiin osiin. Esimerkiksi nopeassa juoksussa se on jaettavissa aina yhteensä 72 osa-alueeseen ja esimerkiksi pelkästään tukivaiheessa on tunnistettavissa 24 eri alivaihetta. Kaikki vaiheet toteutuvat jokaisella juoksijalla, mutta niiden kesto ja siten myös suhde vaihtelevat (Lohman, Sackiriyas ja Wesley Swen 2011). Lohman, Sackiriyas ja Wesley Swen (2011) mukaan tukivaiheen osuus koko askelsyklistä on noin 30%-35% ja vastaavasti heilahdusvaiheen osuus siis 65%-70%. Osuuk-sien välinen suhde vaihtelee juoksuopeuden mukaan: nopeammassa vauhdissa ilmassa vietettävä aika kasvaa ja tukivaihe lyhenee.

Juoksu voidaan määrittää sarjaksi pomppivia kontakteja (Farley ja Ferris 1998). Osuessaan maahan juoksijan jalka vaikuttaa voimalla maahan, joka taas vaikuttaa juoksijaan vastaavan suurella voimalla. Näistä voimista käytetään termiä reaktiovoimat (Novacheck 1998). Kävelyyn verrattuna juoksussa alustaan kohdistuvat vertikaaliset voimat ovat voimakkaampia, vaikka varsinainen liikesarja on kaavaltaan samankaltainen. Horisontaaliset alustaan kohdistuvat reaktiovoimat ovat molemmissa liikesarjoissa samanlaiset, sillä molempien liikesarjojen ihmistä liikuttava voima syntyy jalan työntövaiheessa. Juoksussa voimakkuus on suurempi. (Farley ja Ferris 1998)

Tukivaiheen voi jakaa Dugan ja Bhat (2005) mukaisesti kolmeen eri pääosaan. Vaiheista ensimmäinen kulkee jalan alkukontaktista kontaktin kulkemiseen jalan keskiosaan. Toisessa vaiheessa kontaktin painopiste muuttuu keskeltä jalkapohjaa siten, että kantapää irtoaa alustasta. Kolmannessa vaiheessa kantapää irtoaa alustasta ja liike suuntautuu kohti varvastyöntöä. Eliittijuoksijoilla alustakontakti tapahtuu jalkapohjan etuosalla, eivätkä takaosa ja kantapää välttämättä kosketa maata liikkeen missään vaiheessa. Kun nopeus kasvaa, ensimmäinen alustakontaktin alku siirtyy luontaisesti kantapäältä kohti varpaita. Pitkän matkan juoksijoille taas kanta-askellus on erittäin tavallista (Novacheck 1998). Tämän tutkimus koehenkilöt eivät ole tulkittavissa eliittijuoksijoiksi, sillä juoksu ei ole heidän varsinainen päälajinsa. Näin ollen on oletettavissa, että jokaisen koehenkilön askeleessa on Dugan ja Bhat (2005) mukaiset vaiheet.

Jalkaan kohdistuvien voimien näkökulmasta tukivaihe jakautuu jarrutukseen ja työntöön. Jarrutus tapahtuu, kun jalka törmää alustaan ja työntö vastaavasti, kun jalka poistuu alustasta. Molemmat voimat ovat kovemmassa juoksuvauhdissa suurempia, mutta usein lähes saman vahuiset - vain vastakkaiseen suuntaan. (Munro, Miller ja Fuglevand 1987)

Tämä tutkielma keskittyy juoksun kontaktiaikaan, joka tapahtuu jarrituksen, tukivaiheen ja työntöön vaiheissa. Kontakti alustaan tapahtuu näissä juoksun vaiheissa. Tukivaiheessa jalkaan ja siten kiihtyvyyssanturiin vaikuttavat monenlaiset voimat, jotka jakautuvat erilaisten vaiheiden mukaisesti. Voimalevyn datassa näkyvät taas erottuvat leijumisvaihe ja kontaktin eri vaiheet. Nämä ovat siis tutkielman kannalta tärkeimmät tunnistettavat vaiheet.



Kuvio 1. Jalkaan tukivaiheessa vaikuttavat voimat Lohman, Sackiriyas ja Wesley Swen (2011, s.155) mukaan. Lyhenteiden merkitykset: F_z on vertikaalinen voima, F_y anteroposteriorinen horisontaalivoima, F_x lateraalinen horisontaalivoima.

3.2 Kontakiaika osana juoksutekniikkaa

Kontaktiajalla tarkoitetaan sitä aikaa, kun jalka on kosketuksessa alustaan. Kontakiajan laskeminen alkaa, kun jalka osuu alustaan, ja loppuu, kun jalka rullaa varvastyönön kautta takaisin ilmaan (Santos-Concejero ym. 2013; Ruiter ym. 2016). Juoksuliikkeessä varvastyöntö tapahtuu puolivälissä askelsykliä, eliittijuoksijoilla kun vain 22 % syklistä on suoritettu (Baharuddin ym. 2009). Tavallisesti sitä mitataan millisekunteina ja merkitään yleisesti C_t .

Sprinttijuoksijoilla kontakiajat vaihtelevat noin 100-200ms välillä. Ei-sprintterien ajat taas ovat hieman suurempia, noin 120-250ms. Molemmilla kontakiajat ovat suuremmissa nopeudessa pienemmät (Clark ja Weyand 2014). Tutkielmaan osallistuneiden juoksijoiden mitatut kontakiajat asettuivat ei-sprinttereiden vastaaviin. Ne olivat välillä 191-260ms. Juoksi-

jakohtaiset keskimääräiset painelevydatasta mitatut kontaktiajat löytyvät liitteestä A.

Saman maksimihapenottokyvyn eli %VO₂max-arvon urheilijat erottuvat suorituksessaan nimenomaan juoksun taloudellisuuden suhteen. Taloudellisesti hyvät juoksijat kuluttavat siis happea vähemmän (Barnes ja Kilding 2015). Michele ja Merni (2014) mukaan 1 millisekunnin ero kontaktiajassa näkyi 0.51 ml min/kg matalampana hapenkulutuksena, kun juoksijoilla oli sama %VO₂max-arvo.

Kontaktiajan ja juoksun taloudellisuuden suhdetta on tutkittu paljon. Yhtäältä tutkimuksissa ei ole löydetty viitteitä siitä, että kontaktiaika vaikuttaisi taloudellisuuteen. Toisaalta nimenomaan pitkän maakontaktiajan on havaittu liittyvän parempaan taloudellisuuteen (Moore 2016). Lisäksi useat tutkimukset ovat osoittaneet, että liian lyhyt kontaktiaika johtaa suureen metaboliseen kustannukseen (Chapman ym. 2012). Lyhyessä kontaktissa tarvittava voima tuotetaan nopeasti, joka on metabolisesti vaativaa (Moore 2016). Toisaalta liian suuren kontaktiajan on nähty kasvattavan metabolista kustannusta, sillä käytetty voima tuotetaan hitaammin ja pidemmällä aikavälillä (Moore 2016). Käytännössä juoksija siis käyttää vauhdin ylläpitämiseksi hetkellisesti sitä enemmän energiaa mitä lyhyempi on voimantuotantoon käytetty aika. Juoksijoiden on siis tärkeää minimoida askeleen metabolinen kustannus, jotta juokseminen olisi energiankulutuksen kannalta taloudellisempaa (Chapman ym. 2012). Erityisesti tämä korostuu pidemmillä matkoilla.

Juoksijoilla on lukuisia toisistaan poikkeavia juokсутyyplejä, mutta tyylit ovat yleistettävissä eri ryhmiin ja tyypeihin. Luokitellessaan juoksijoiden eri tyyplejä tulivat Jauhiainen ym. (2020) tulokseen, että juoksijoita on viittä eri tyyppiä. Ensimmäisen ryhmän juoksijoilla polvet taipuivat ja koukistuivat eniten. He myös valitsivat nopeimman juoksuvaudin. Suurin osa ryhmästä oli miehiä. Toisessa ryhmässä taas raajat olivat verrattain jäykkiä. Kolmannen ryhmän juoksu oli epätaloudellisinta ja juoksijan lonkan lähennyksen liike oli suurta. Samoin askeltiheys oli matalin ja askel vastaavasti pisin. Neljännen tyyppin juoksijat olivat kanta-askeltajia, joilla askeleessa jalkaterä kääntyi lisäksi sisäänpäin. Viidennen, pääosin naisista koostuneen ryhmän juoksu oli hitainta ja lonkan lähennyksen nopeus ja liikelaajuus olivat suurimpia.

Juoksijan juokсутyyllillä on vaikutusta kontaktin voimakkuuskäyrän malliin ja muotoon. Mikäli juoksija ottaa askeleet kantapää edellä, näkyy voimakäyrällä kaksi erillistä huippua. Jal-

kapohjan puolivälillä askeltavilla kontaktista tulee tasaisempi, eikä erillistä toista huippua ole erotettavissa voimakäyrästä. Mikäli juoksija taas ottaa kontaktin jalan etuosalla, on voimakäyrä tasaisesti kasvava ja vähenevä - siinä on vain yksi selvä huippukohta. (Lohman, Sackiriyas ja Wesley Swen 2011)

4 Valitut menetelmät

Tässä luvussa hahmotellaan tutkimuskysymyksen ratkaisuun valittujen menetelmien teoriaa ja käytäntöä tutkielman näkökulmasta. Ensin luvussa rakennetaan yleiskuva siitä teoreettisesta viitekehystä, jonka ympärille tiedonlouhinta käytettynä menetelmänä rakentuu ja millaisista eri vaiheista sen prosessimalli koostuu. Lisäksi luvussa perustellaan tutkimuskysymyksen ratkaisemista luokittelumenetelmän ja satunnaismetsän avulla. Samoin luodaan katsaus ristiinvalidoinnin suorittamiseen. Ristiinvalidoinnilla mallin toimivuus säilytetään yleistettävänä myös muulle kuin opetusdatalle. Luvussa käydään siis läpi sitä, miten ristiinvalidointi on tässä tutkielmassa toteutettu. Lopuksi luvussa kerrotaan tutkielman datan piirteyttämisessä käytetyn Fourier-muunnoksen toimintaa ja periaatteita.

4.1 Tiedonetsintä ja tiedonlouhinta

Tiedonlouhinta yhdistää monen eri tieteenalan menetelmiä. Se hyödyntää muun muassa tietokantoja, tilastotieteitä, koneoppimista sekä hahmontunnistusta. Tiedonlouhinta on osa laajempaa tietokannoista tiedonlöytämisen (Knowledge Discovery in Databases, KDD) kokonaisuutta. Tiedonlouhinta on yksi KDD-prosessin askeleista (Zaki ja Meira 2014; Fayyad, Piatetsky-Shapiro ja Smyth 1996b; Brodley ja Smyth 1997). KDD:ssä on kysymys laajan ja kompleksisen datan muuttamisesta hallittavampaan, kompaktimpaan, abstraktimpaan tai käytännöllisempään muotoon. Menetelmän keskiössä on tiedonlouhinnan hyödyntäminen kuvion löytämiseksi ja erottamiseksi (Fayyad, Piatetsky-Shapiro ja Smyth 1996a). KDD siis erottaa ja louhii uutta ja käyttökelpoista, implisiittistä tietoa datasta (Frawley, Piatetsky-Shapiro ja Matheus 1992).

KDD:n prosessimallia ja viitekehystä ovat ensimmäisenä määritelleet erityisesti Fayyad, Piatetsky-Shapiro ja Smyth (1996b). Prosessina se sisältää useita eri vaiheita päämääränä olevan tiedon löytämisen toteuttamiseksi. Tiedonlöytämisen prosessimalli koostuu Fayyad, Piatetsky-Shapiro ja Smyth (1996a) mukaan yhdeksästä eri vaiheesta.

Ensimmäisessä vaiheessa rakennetaan ymmärrystä kohdealueesta, aiemmasta tiedosta sekä määritetään tavoitteet. Piatetsky-Shapiro (1990) määrittää taustatiedon sellaiseksi tiedoksi,

joka ei esiinny datassa itsessään eksplisiittisesti. Analysointi käsittää monen eri tekijän huomioonottamisen ja monimutkaisen ja usean eri askeleen sisältämän ongelman yksinkertaistamisen (Brodley ja Smyth 1997).

KDD:n tavoitteet on jaettavissa kahteen tyyppiin: verifiointiin ja löytämiseen. Verifiointin tarkoituksena on tarkastaa suorittajan asettaman hypoteesin paikkansapitävyys. Löytämiseksi järjestelmä taas etsii itsenäisesti uusia kuvioita ja malleja. (Fayyad, Piatetsky-Shapiro ja Smyth 1996a)

Lopputulokset voidaan jakaa kahteen alakategoriaan, jotka ovat luonteeltaan joko kuvaavia eli deskriptiivisiä tai ennustavia eli prediktiiivisiä. Deskriptiivisiä tuloksia tuottaessa järjestelmä etsii ja esittää kuvioita ihmiselle ymmärrettävämmässä muodossa. Järjestelmä siis paljastaa tulkittavasta laajasta datasta kaavoja ja erilaisia yhteyksiä (Kantardzic 2011). Prediktiiiviset tulokset taas esittävät ennustettavaa käytöstä. Usein lopputulos on malli, joka esitetään esimerkiksi ajettavan koodin avulla. Ajettavalle koodille taas voi syöttää uutta dataa. Tällaiset mallit voivat olla esimerkiksi luokittelevia, ennustavia tai arvioivia (Kantardzic 2011). Tässä tutkielmassa on kysymys tällaisen mallin luomisesta. Tutkielmassa mallilla tarkoitetaan Maimon ja Rokach (2005) esittelemää rakennetta, joka on koostettu käytetyillä menetelmillä löydettyistä attribuuttien yhteyksistä.

Toisessa vaiheessa valitaan prosessissa käytettävä data, joka voi olla esimerkiksi erillinen osa laajemmasta tietokantaa tai tietomäärästä. Datalla viitataan Frawley, Piatetsky-Shapiro ja Matheus (1992) mukaisesti kokoelmaan esimerkkejä ja tapauksia. Ne voivat olla joko yksittäisessä tiedostossa tai tietokannassa tai vastaavasti koottu useista lähteistä. Tiedonlouhinnassa ja koneoppimisessa käytetty data on kuitenkin luonteeltaan staattista. Datan tulee olla muodoltaan yhtenäistä.

Todellinen data on kuitenkin harvoin täydellistä ja käyttökelpoista sellaisenaan. Siksi kolmannessa vaiheessa data siivotaan ja esiprosessoidaan. Raakadataa on usein paljon virheitä, jotka vaikeuttavat tai tekevät sen käyttämisen mahdottomaksi. Reaalimaailman raakadataan liittyy monenlaisia ongelmia: siitä voi puuttua arvoja, se voi sisältää häiriötä tai virheellisiä tietoja ja niin edelleen. Syyt virheille ovat moninaiset, mutta data tulee käsitellä ennen käyttämistä. Tavallisesti tämä tarkoittaa esimerkiksi kohinan poistamista, tyhjien

datakenttien käsittelemistä ja aikasekvenssitietojen selvittämistä. Siistiminen ja esikäsitteily tähtää siihen, että käytetyt menetelmät tuottaisivat datasta enemmän ja parempia uusia ominaisuuksia. (Kantardzic 2011)

Neljänneksi suoritetaan datan redusointi ja projektointi. Tässä vaiheessa data muokataan parhaiten lopputulosta palvelevaan muotoon esimerkiksi muuttamalla sen dimensioita. Usein dimensioiden määrä kasvaa, kun tallennettu data on peräisin useasta eri lähteestä. Verleysen ja François (2005) mukaan dimensiot ovat varsinaisesti ongelma, kun data on enemmän kuin 2- tai 3-ulotteista - siis yksinkertaisten visualisointien ulottumattomissa. Kantardzic (2011) taas pitää modernien lounhintamenetelmien vaatimuksena hyvää tarkkuutta myös monidimensioisissa malleissa, vaikkakin se vaikeuttaa tulkintaa.

Viidennessä vaiheessa valitaan tiedonlounhinnan menetelmistä parhaiten ensimmäisessä vaiheessa asetettujen tavoitteiden kannalta sopivat metodit. Näitä ovat esimerkiksi regressioon, luokitteluun, klusterointiin tai tiivistämiseen pohjaavat menetelmät. Tätä vaihetta tulee peilata ensimmäiseen vaiheeseen, jotta asetetut tavoitteet täyttyvät. (Fayyad, Piatetsky-Shapiro ja Smyth 1996a)

Kuudentena valitaan tarkemmat tiedonlounhinnan algoritmit ja mallit, joiden avulla datasta etsitään kuvioita tai malleja. Se siis tarkoittaa, että tässä vaiheessa myös päätetään halutun lopputuloksen kannalta oleelliset mallit ja parametrit (Fayyad, Piatetsky-Shapiro ja Smyth 1996a). Brodley ja Smyth (1997) korostavat, että valintaan vaikuttavat mallien ja algoritmien yleiset piirteet. Näitä voivat olla esimerkiksi mallin ymmärrettävyys, jotta sen tuottamat luokittelut ovat selvästi tulkittavissa. Kantardzic (2011) kuitenkin huomauttaa, että yleensä yksinkertaiset ja helpommin tulkittavat mallit ovat epätarkempia.

Seitsemänneksi suoritetaan valitulle datalle aiemmin valitut tiedonlounhinnan menetelmät. Tämän vaiheen onnistuminen riippuu vahvasti aiempien vaiheiden oikeasta valinnasta ja suorittamisesta. Ensimmäisen iteraation mallin ei tarvitse olla valmis tai oikea, vaan se voi tuottaa uutta informaatiota seuraavan iteraation mallin valintaan. (Brodley ja Smyth 1997; Fayyad, Piatetsky-Shapiro ja Smyth 1996a)

Kahdeksannessa vaiheessa kerättyä uutta tulosdataa tulkitaan ja mallit arvioidaan. Mikäli tiedonlounhinnalla saavutetut lopputulokset eivät vastaa asetettuja tavoitteita, on mahdollista

palata mihin tahansa prosessin vaiheeseen ja suorittaa muut muutosten mukaisesti uudelleen. Löydettyjä kuvioita ja malleja voi tarpeen mukaan myös visualisoida. Jos taas tulokset vastaavat ensimmäisissä vaiheissa asetettuja tavoitteita, voidaan prosessi katsoa päättyneeksi ja edetä. (Brodley ja Smyth 1997; Fayyad, Piatetsky-Shapiro ja Smyth 1996a; Kantardzic 2011)

Viimeisessä eli yhdeksännessä vaiheessa hyödynnetään löydettyä tietoa uusissa sovellutuksissa. Se voi tarkoittaa esimerkiksi tiedon dokumentointia tai vaikkapa raportointia lopputuloksista kiinnostuneille sidosryhmille. Lisäksi uutta tietoa voi hyödyntää sellaisenaan muissa tarkoituksissa ja sovellutuksissa. (Fayyad, Piatetsky-Shapiro ja Smyth 1996a)

KDD:n prosessimalli on vahvasti iteratiivinen. Vaiheita voidaan toistaa tarpeen mukaan monta kertaa peräkkäin, kunnes lopputulos vastaa asetettuja tavoitteita (Fayyad, Piatetsky-Shapiro ja Smyth 1996a). Siksi se sopiikin erityisen hyvin yhden DSR:n tutkimusprosessin kanssa.

Tiedonlouhinnan algoritmit koostuvat Hand, Mannila ja Smyth (2001) mukaan neljästä eri peruskomponentista: Malli- ja kuviorakenteista, pisteytysfunktioista, optimoinnin ja etsinnän menetelmistä sekä tiedonhallinnan strategioista.

Ensiksi ovat mallien (engl. *model*) ja kuvioiden (engl. *pattern*) rakenteet. Mallit ovat Hand, Mannila ja Smyth (2001) mukaan datan globaaleja ja yleistettyjä esitystapoja. Mallin avulla on mahdollista määrittää ja mitata mitä tahansa havainnointipistettä. Kuviot taas ovat rakenteita, jotka pätevät vain rajatulla osa-alueella. Rajoina toimivat tietyt muuttujat. Toisena ovat niin sanotut pisteytysfunktiot (engl. *score function*). Niiden avulla arvioidaan, kuinka hyvin ensin mainitut mallirakenteet sopivat annettuun dataan. Pisteytysfunktion tulisi siis olla sellainen, että se vastaa mallin lopullista käyttötarkoitusta. Mikäli pisteytysfunktiota ei ole, ei eri mallien toimivuutta voi arvioida. Jokainen teoriasolla toimiva ratkaisu täytyy myös todeta käytännössä toimivaksi. Pisteytysfunktio tekee siis tämän. Yhtä ratkaisua voidaan arvioida useamman pisteytysfunktion kautta. (Hand, Mannila ja Smyth 2001)

Kolmantena komponenttina toimii optimoinnin ja etsinnän menetelmä. Optimoinnilla viitataan pisteytysfunktion optimointiin suhteessa rakenteeseen ja käytetyn mallin parametreihin. Mallia ja parametreja muutetaan siten, että pisteytysfunktion lopputulos on mahdollisimman pieni tai suuri, ratkaisun kannalta siis paras. (Hand, Mannila ja Smyth 2001)

Viimeisenä tulevat tiedonhallinnan strategiat. Yksinkertaisesti kysymys on niistä tavoista, joilla dataa tallennetaan, indeksoidaan ja käytetään. Nämä ovat teknisiä ratkaisuja, joissa korostuvat esimerkiksi RAM-muistin tai fyysisen levytilan käyttäminen. Useimmat tiedonlouhintaan käytetyt ohjelmat ottavat nämä huomioon toiminnassaan ja myös valmiissa algoritmeissaan. (Hand, Mannila ja Smyth 2001)

4.2 Luokittelumenetelmä

Tutkielman perusongelma - juoksijan kontaktiajan arviointi kiihtyvyyssanturin datasta - on luonteeltaan luokitteluongelma. Luokitteluongelmalla tarkoitetaan Maimon ja Rokach (2005) määrittelemällä tavalla datan jakamista konsepteihin eri piirteiden mukaisesti. Konseptit ovat kategorioita, luokkia, objekteja tai tapahtumia, jotka muodostuvat osajoukoista. Jalka joko on kontaktissa alustaan tai ei ole. Eri jalkakontaktit voidaan taas jakaa uudelleen oikean ja vasemman jalan kontakteiksi. Näistä koostuvat perusongelman luokat. Säännöt luokkien jaottelulle muodostetaan induktiivisten algoritmien, toisin sanoen oppijoiden avulla. (ks. esim. Quinlan 1987; Maimon ja Rokach 2005)

Kun luokittelua tehdään siten, että mallille annetuilla syötearvoilla ennustetaan tai selitetään kohdemuuttujaa, on kyseessä ohjattu menetelmä. Luokitteluun tähtäävä ohjattu menetelmä jakaa syötearvoista muodostetun avaruuden ennalta annettuihin luokkiin (Maimon ja Rokach 2005). Kiihtyvyyssanturista saadut arvot ovat menetelmän syötearvoja ja tarkastelussa oleva kontaktihetki on kohdeattribuutti. Mallin tarkoituksena on etsiä, esittää ja selittää, mitkä syötearvoista määrittävät riippuvat muuttujat.

Martín, Garcia ja Asuero (2017) esittävät, että lineaaristen ongelmien perusolettamuksien pitävyyttä voi tarkastaa myös numeerisesti ja graafisesti. Jo kuvaajien ja tarkastelulla voimme päätellä, että kiihtyvyyssanturin X-akselin huippukohdat liittyvät voimalevyn datan minimeihin. Näin voimme olettaa, että lineaarisen luokittelun ratkaisevat menetelmät toimivat datan analyysissä.

4.3 Satunnaismetsät

Luokitteluongelmien ratkaisussa varsin hyviksi tiedonlouhinnan menetelmiksi on havaittu erilaisia päätöspuita hyödyntävät menetelmät. Puilla tarkoitetaan graafiteoreettista solmuista ja poluista tai kaarista koostuvaa graafia. Puut koostuvat juurisolmusta, sisäisistä solmuista ja lehtisolmuista. Solmutyypit eroavat toisistaan niihin suuntautuvien ja niistä lähtevien polkujen perusteella. Juurisolmulla ei ole yhtään sisään tulevaa polkua, muilla solmuilla yksi. Juuri- ja sisäisillä solmuilla taas on vähintään yksi lähtevä polku, kun taas lehtisolmuilla ei niitä ole yhtään. Päätöspuut esittävät luokittelijan tekemät rekursiiviset jaottelut syötearvojen avaruudesta puumaisena graafina. (Rokach ja Maimon 2005)

Päätöspuut ovat Louppe (2014) mukaan houkuttelevia, sillä ne eivät ole parametroitavia, joten mallit toimivat tehokkaasti ilman esitietoja. Lisäksi ne toimivat erityisen hyvin laajoilla aineistoilla, jotka sisältävät lukuisia tapauksia ja muuttujia. Sillä päätöspuut toteuttavat luontaisesti piirteiden valinnan, toimivat ne hyvin myös epäolennaisten ja häiriöisten muuttujien kanssa. Lisäksi päätöspuita on helppo tulkita myös ilman tilastotieteiden vahvaa tuntemusta. Ne ovat monen modernin ja suosituksen algoritmin taustalla (Louppe 2014; Sutton 2005). Näistä eräs on niin sanottu satunnaismetsäalgoritmi (engl. *Random Forest*), joka on muunnelma satunnaispäättömetsästä (engl. *Random Decision Forest*).

Satunnaispäättömetsän idean esitteli ensimmäisenä Ho (1995). Satunnaispäättömetsä pohjaa menetelmään, jossa rakennetaan useita satunnaisia päätöspuita satunnaisesti valittujen datan aliavaruuksien pohjalta. Breiman (2001) määrittelee satunnaismetsän formaalisti $\{h(x, \theta_k), k = 1, \dots\}$ joukoksi puumallisia luokittelijoita, jossa θ_k ovat riippumattomia identtisesti jakautuneita satunnaisvektoreita ja jokainen puu valitsee suosituimman luokan syötteestä x . Satunnaismetsissä oppiminen tapahtuu siis jakamalla datan piirteet satunnaisesti eri aliavaruuksiin, joissa vahvimmat piirteet erottuvat, sillä ne saavat aikaan parhaimman lopputuloksen.

Satunnaispäättöspuiden tarkkuuden parantamiseksi on kehitetty kahdenlaisia algoritmeja. Nii- tä ovat bagging- ja boosting-menetelmät (Sutton 2005). MATLAB:n päätöspuuluokittelijat kokeilevat kumpiakin etsiessään parasta mahdollista luokittelijaa. Näin ollen on syytä esitellä molemmat menetelmät.

Muiden muassa Breiman (1996) ja Breiman (2001) kehittivät satunnaispäättöspuiden algorit-

mia eteenpäin. Breiman lisäsi satunnaispäättöspuihin aiemmin kehittämänsä bootstrap-aggregoinnin (bagging). Bagging-algoritmissa luokittelijasta tehdään useita erilaisia versioita, jotka luodaan satunnaisotannalla bootstrap-menetelmää hyödyntäen. Aineistosta valitaan useita eri otantoja bootstrap-menetelmällä. Tämän jälkeen ne syötetään kukin erikseen luokittelijalle. Lopulta tulokset yhdistetään äänestämällä parasta lopputulosta (Breiman 1996; Sutton 2005).

Toinen satunnaispäättöspuiden tehokkuutta parantava menetelmä on boosting. Boosting eroaa baggingista siinä, että sen pohjalla on luokittelun tekeminen painotetun keskiarvon perusteella. Painotettua keskiarvoa käytetään painottamaan algoritmin aiemman askeleen otoksen virheellisiä luokitteluja. Boosting myös antaa enemmän painoarvoa toimivammille malleille, siinä missä baggingissa mallit saavat samanlaiset painotetut arvot. Boosting on iteratiivinen menetelmä, jota hyödynnetään useimmiten heikkojen luokittelijoiden, esimerkiksi kahden solmun päättöspuiden kanssa (Sutton 2005; Witten ym. 2017).

Fernández-Delgado ym. (2014) testasivat ja vertailivat tutkimuksessaan yhteensä 179 luokittelijaa 19 eri luokittelijaperheestä. Koko testijoukon suorituskykyisimmäksi luokittelijaksi nousivat satunnaismetsät: parhaan 25 luokittelijan joukkoon pääsi kuusi kahdeksasta tutkimuksessa olleesta satunnaismetsäluokittelijasta. Parhaiden 20 luokittelijan joukko oli pienen marginaalin sisällä, mutta satunnaismetsät erottuivat selvästi muista luokittelijatyypeistä. Tutkimus on herättänyt kritiikkiä, jota ovat esittäneet muiden muassa Wainberg, Alipana-hi ja Frey (2016). He huomattavat, että esimerkiksi parhaat tukivektorikoneet ja neuroverkot saavuttivat yhtä hyviä tuloksia kuin satunnaismetsät. Kritiikki kuitenkin kohdistuu enemmän esitettyihin väitteisiin kuin satunnaismetsien luokittelun tarkkuuteen.

Satunnaismetsäalgoritmi on tämän tutkielman kannalta toimiva ratkaisu, sillä se on havaittu muissa tutkimuksissa tehokkaaksi ja tarkaksi luokittelijaksi ilman parametrisointia. Lisäksi se on yleisesti käytetty ja varsin suosittu algoritmi.

4.4 Ristiinvalidointi

Mikäli malli opetetaan vain yhdellä tavalla ja datalla, tulee mallista hyvä luokittelemaan opetukseen käytettyä dataa, mutta se ei sovellu hyvin muunlaisen datan luokitteluun. Malli

ei ole siis yleistettävissä muulle datalle. Ongelmaa kutsutaan ylisovittamiseksi (Kantardzic 2011). Ristiinvalidoinnin tarkoitus on estää mallin ylisovittamisen ongelma. Sillä pyritään siis siihen, että malli sopii muullekin datalle kuin pelkästään opetusdatalle. Ylisovittamisen ongelmassa mallista tulee liian tarkka ja malli ei toimi luotettavasti ja tarkasti muulle kuin testidatalle.

Ristiinvalidointiin on mahdollista hyödyntää monenlaisia lähestymistapoja. Tavallisesti osa datasta jätetään pois mallin opettamisesta. Poisjätettävän datan valintaan on käytännössä kaksi menetelmää: satunnainen valikointi ja yhden poisjättäminen. Satunnaisessa valikoinnissa data jaetaan opetusdataksi satunnaisesti, kun taas yhden poisjättämisessä taas poistaminen on valikoitua ja määrittyy tunnistettavan luokan perusteella. (Kohavi 1995)

Tässä tutkielmassa ristiinvalidointi on toteutettu jättämällä pois mallin opetusdatasta kunkin juoksijan data kerrallaan. Poisjätetyn juoksijan dataa on tämän jälkeen käytetty syntyneen mallin arvioinnissa luokittelemalla data. Menetelmää voidaan kutsua sovelletuksi *Leave-One-Out*- tai *k-fold*-menetelmäksi. Perinteisessä *Leave-One-Out*-menetelmässä opettamiseen käytetään $(n-1)$ näytettä ja se toistetaan n kertaa. Menetelmä on kuitenkin laskennallisesti vaativa, jolloin opettaminen vie runsaasti aikaa (Kantardzic 2011). Perinteisessä *k-fold*-menetelmässä data jaetaan k -kertaa satunnaisiksi osajoukoiksi (Kohavi 1995). Satunnaisuuden sijaan tutkielmassa *Leave-One-Out*-menetelmän n ja *k-fold*in k määrittävät juoksijoiden mukaisesti. Sillä juoksijoilla on kaikilla omanlaisensa juoksutekniikka ja tyyli, on näin saatu varmistus käytettyjen tiedonlouhinnan menetelmien toimivuudesta mahdollisimman erilaisella datalla. Samalla saadut tulokset antavat osviittaa siitä, miten hyvin mallit toimisivat uusien juoksijoiden datan kohdalla. Tutkielmassa käytetyllä menetelmällä malleja on siis yhteensä syntynyt seitsemän kappaletta. Jokaisen mallin arviointi on suoritettu erikseen ja tulokset on lopulta laskettu yhteen.

4.5 Fourier-muunnos

Fourier-muunnos (FT, engl. *Fourier Transform*) määrittää signaalista sen, kuinka paljon signaali sisältää kutakin taajuutta. Fourier-muunnosta käyttäen on mahdollista selvittää hallitsevat taajuudet sekä voimalevyistä että kiihtyvyyssanturista ja vertailla niiden samankaltaisuut-

ta. Sillä juoksu on syklinen liikesarja, on syytä olettaa, että samat taajuudet ovat yhtä vahvoja molemmissa datasiinaaleissa. Fourier-muunnoksesta on olemassa erilaisia muunnoksia erilaisille signaalityypeille.

Tavallisen Fourier-muunnoksen laskemisessa suoritetaan siis N^2 kompleksisia kertolaskuoperaatioita ja $N(N - 1)$ yhteenlaskuoperaatioita. Kun N on suuri, kasvaa myös Fourier-muunnoksen laskemiseen vaadittu aika. Nopean Fourier-muunnoksen vaativuus on merkittävästi pienempi ollen aikavaativuudeltaan luokkaa $O(N \log N)$. Diskreetti-aikainen Fourier-muunnos (DTFT, engl. *Discrete-Time Fourier Transform*) vastaavasti kääntää aikapohjaisen signaalin taajuuspohjaisiksi komponenteiksi (ks. esim. Gentleman ja Sande 1966).

Lyhytaikainen Fourier-muunnos (STFT, engl. *Short-Time Fourier Transform*) on digitaalisessa signaalinkäsittelyssä käytetty menetelmä, joka tyypillisesti hyödyntää nopean Fourier-muunnoksen algoritmia. STFT:ta voidaan käyttää sekä jatkuvalla että diskreetille signaalille. Xu ym. (2006) määrittelevät STFT:n seuraavanlaisesti: $STFT(\tau, f) = \int_{-\infty}^{\infty} h(t)w(t - \tau)e^{-i2\pi ft} dt$

STFT:n hyödyntää signaalin ikkunointia. Signaalinkäsittelyssä ikkunointi tapahtuu erillisellä funktiolla. Ikkunointifunktio on matemaattinen funktio, joka antaa signaalin arvoksi nollla funktion ulkopuolella. Ikkunointifunktion avulla voidaan tarkastella helposti pientä osaa signaalista. Ikkunointifunktioita on useanlaisia, joista yleisimpiä ovat esimerkiksi Hanning-, Hamming- ja Blackman-Harris-ikkunat (Bojkovic, Bakmaz ja Bakmaz 2017).

Käytännössä STFT yli tietyn ikkunoinnin tarkoittaa sitä, että signaali jaetaan pienempiin segmentteihin, joiden jaksolle Fourier-muunnos lasketaan. STFT tuottaa matriisin, joka kertoo signaalin sisältämien frekvenssikomponenttien amplitudin ja vaiheen kunkin ajan hetkelle. Käytetty ikkunointi määrittää segmenttien pituudet. Diskreetissä muunnoksessa ikkunoidut segmentit leikkaavat toisiaan (Oppenheim 2010).

Valittu ikkunan koko vaikuttaa Fourier-muunnoksella saatavan taajuusspektrogrammin tarkkuuteen ja laajuuteen. Liian suureksi määritetty ikkuna tuottaa korkeamman spektrin, mutta heikomman ajallisen tarkkuuden kun taas liian pieni ikkuna aiheuttaa päinvastaisen lopputuleman. Ajallinen tarkkuus on parempi, mutta spektri matalampi (Nisar, Khan ja Tariq 2016).

Tässä tutkielmassa ikkunointifunktioksi valittiin Hamming-ikkunointi (tarkemmin Hamming-ikkunoinnista ks. esim. Harris 1978). Ikkunan pituudeksi määritettiin 96 näytettä. Ajallisesti ikkunan pituus oli siis $96/3200$ eli 30 millisekuntia. Ikkunan pituus on siis huomattavasti juoksijoiden keskimääräisiä kontaktaaikoja lyhyempi (ks. esim. Clark ja Weyand (2014) ja liite A). Ikkunoiden leikkaukseksi määritettiin puolet ikkunan koosta eli 48 näytettä eli 15 ms.


Sillä Fourier-muunnoksen tulokset ovat kompleksilukuja, otettiin luvuista käytettäväksi itseisarvot. Näin kiihtyvyyssanturin datasta saaduista hallitsevista taajuuksista valittiin vahvin ja tarkasteltiin ± 17 lähintä taajuutta. Loput taajuuksista olivat niin vaikeita, ettei niillä ollut varsinaista merkitystä signaalin analysoinnissa. Näin syntyi 35 taajuuden matriisi, jonka toisen dimension määritti signaalin sisältämien ikkunoinnilla saatujen näytteiden määrä.

Jotta voimalevyjen data olisi yhtenevä Fourier-muunnoksen kanssa, pilkottiin myös sen data erillisiksi toisiaan leikkaaviksi segmenteiksi. Segmentit muodostettiin MATLAB:n *buffer*-funktioilla. Buffer jakaa signaalin määritetyn mittaisiin, määritetyn verran toisiaan leikkaaviin paloihin. Tässäkin hyödynnettiin 96 näytteen pituutta ja 48 näytteen leikkausta. Lopulliseksi, aikaikkunan luokan määrittäväksi tunnusluvuksi valittiin moodi, sillä se kuvaa parhaiten aikaikkunassa tapahtuvaa kontaktia. Tutkielman kannalta merkityksekkäimmät ikkunat ovat ne, joissa kontakti tapahtuu. Näin ollen mallin tulisi tunnistaa tarkimmin hetket, joissa kontakti alkaa ja loppuu.

5 Suunnittelu ja kehitys

5.1 Koeasetelma

Anturina mallidataa kerätessä käytettiin Axivity AX3-kiihtyvyyssanturia, joka asetettiin koehenkilöiden oikeaan jalkapöytään kengän päälle nauhojen alle. Anturi asetettiin tallentamaan (Accelerometer Sample Rate) 3200 Hz taajuudella ja tallennusalueeksi (Accelerometer Range) määritettiin $\pm 16g$. Anturin data tallennettiin anturista AX3 OMGUI-sovelluksella yksinkertaisiksi CSV-tiedostoiksi (Comma-Separated Values). Axivityn akselit ovat hieman Lohman, Sackiriyas ja Wesley Swen (2011) määrittelemistä tukivaihevoimista poikkeavat. Kiihtyvyyssanturin X-akseli vastaa anteroposteriorista horisontaalivoimaa ja Y-akseli lateraalista horisontaalivoimaa. Z-akseli kuvaa molemmissa vertikaalista voimaa.



Kuvio 2. Axivity AX3-kiihtyvyyssanturin akselisto. Anturi asetettiin kenkään siten, että X-akselin suunta oli kohti kengän kantaa, Z-akseli kengänpohjaan ja Y-akseli kengän vasemmalle sivulle. Kuva Axivity AX3:n käyttöohjekirjasta.

Voimalevyinä käytettiin Jyväskylän yliopiston liikuntatieteellisen tiedekunnan tiloissa Jyväskylässä kiinteästi sijainneita levyjä, jotka ovat kymmenen metriä pitkät. Voimalevyt tallentavat 1000 Hz eli 1 kHz taajuudella. Ajassa mitattuna tarkoittaa 0,1 ms tarkkuutta, joka on riittävä tarkkuus kontaktiajan määrittämiselle. Voimalevyjen data ohjattiin A/D-levyn kautta tietokoneelle, jossa se tallennettiin ja käännettiin Spike2-ohjelmiston avulla suoraan MATLAB-tiedostoiksi. Voimalevyt olivat kahdessa rivissä ja mittaavat molemmat oman puolensa voimaa. Mittaukset yhdistettiin Spike2-ohjelmistossa yhteen tiedostoon. Itse datan analysointi suoritettiin MATLAB-sovelluksella (The MathWorks Inc., versio R2019b, 9.7.0.1261785).

Koehenkilöt hankittiin Keski-Suomen Erotuomarikerhon (KSETK) jäsenistöstä sekä heidän lähipiiristään. Osallistujat olivat vapaaehtoisiksi ilmoittautuneita. Osallistuneita koehenkilöitä oli yhteensä seitsemän, kuusi miestä ja yksi nainen. Henkilöiden keski-ikä koehetkellä oli 32 vuotta. Koehenkilöistä kerätyt tarkemmat tiedot löytyvät liitteestä A. Juoksijoista käytetyt numeromerkinnät ovat samat sekä liitteessä että mallien käsittelyn yhteydessä.

Ennen testisuoritusta koehenkilöt ohjeistettiin tekemään kolmenlaisia juoksusuorituksia: hölkää, juoksua ja kovaa juoksua tai spurttia. Itse suorituksessa koehenkilöt juoksivat 4-5 suoritusta kutakin juoksun intensiteettiä. Juoksijat saivat itse määritellä vauhtinsa parhaaksi katsomallaan tavalla. Juoksijat aloittivat juoksemisen jo ennen painelevyjä, jotta juoksunopeus levyillä olisi mahdollisimman lähellä haluttua juoksun intensiteettiä. Askeleet painelevyjen ulkopuolelle sekä osittaiset kontaktit niiden päälle jätettiin huomioimatta.

Kiihtyvyyssanturin tallennus asetettiin päälle käytetyn AX3 OMGUI-sovelluksen kautta, joten ongelmaksi muodostui kahden eri tallennusvälineen aikaleimojen yhteensovittaminen. Tätä varten koehenkilöt tekivät ennen suoritusta painelevyillä seistessään vähintään kolme tasajalkahyppyä, joiden avulla määritettiin suorituksen alkamisen nollakohta ja synkronoitiin kiihtyvyyssanturin data painelevyjen datan kanssa.


5.2 Koeasetelman olosuhteiden vaikutus juoksusuoritukseen

Sillä, että juoksualustana toimineet painelevyt sijaitsevat tilassa, jossa juoksua ei ole mahdollista jatkaa pitkälle painelevyjen yli, on oma vaikutuksensa juoksusuoritukseen. Johtuen nopeasti vastaan tulevasta seinästä joutuu juoksija hidastamaan vauhtiaan tavallista askelta aiemmin ja enemmän. Tämä näkyy siten myös suorituksen voimatasoissa. Vastaavasti liikkeellelähdöt tapahtuivat lähellä painelevyjen alkua, joten ensimmäiset juoksuaskeleet ovat vahvasti kiihdyttäviä.

5.3 Datan muoto

Kiihtyvyyssanturin ja voimalevyjen datat ovat diskreettejä jaksottomia signaaleja. Kiihtyvyyssanturin mittausdata koostuu aikaleimoista sekä X-, Y- ja Z-akselistoista. Tarkalleen ottaen


kiihtyvyyssanturin tallentama data on siis $n \times 5$ muotoinen matriisi, jossa n tarkoittaa tallennettujen hetkien määrää. Indeksit 1 ja 2 sisälsivät anturin aikaleimoja, joista ensimmäinen oli päivämäärä ja toinen kellonaika, jota mitattiin tuhannesosasekunnin tarkkuudella. n vaihteli eri koehenkilöiden mittauksissa 416280...1074840 mittaushetken välillä. Yksittäinen mittaushetki oli esimerkiksi muotoa [2018, 16, -11.15625, 9.21875, 1.50000]. Sillä kiihtyvyyssanturille oli asetettu tallennusväliksi $\pm 16g$, saivat vaihtelivat myös akselistojen arvot samalla välillä ± 16 . Tallennuspisteet siis kuvasivat kiihtyvyyden suuruutta suhteessa omaan akseliinsa kullakin tallennushetkellä.



Kuvio 3. Esimerkkiotos kiihtyvyyssanturin normalisoidusta datasta kahden askeleen ajalta. Näkyvillä akselit X, Y ja Z. Kuvaaja luotu MATLAB:lla.

Voimalevyjen mittausdatassa molemmat voimalevyjen puolet ovat kahdessa ensimmäisessä kanavassa eriteltynä ja ne kuvaavat voiman muutosta. Kolmannessa kanavassa nämä kaksi ovat yhdistettynä yhdeksi kanavaksi joka kuvaa alustaan kohdistunutta voimaa. Tutkielman tulosten kannalta tärkein on kolmas kanava. Sen avulla askelten kontaktiajat ovat eroteltavissa tarkasti ja selvästi. Kolmannen kanavan tallennusdata on $[n \times 1]$ -muotoinen matriisi, jonka

arvot saivat myös negatiivisia arvoja, sillä voimalevyille ei suoritettu kalibrointia. Voimalevyjen n vaihteli välillä 83678...204284.



Kuvio 4. Esimerkkiotus voimalevyn normalisoidusta datasta. Kuvaaja kuvaa maahan kohdistuvaa vertikaalista reaktivoimaa kahden askeleen ajalta. Toisessa askeleessa huomattavissa jarrutus ja siten askellus kantapäälle. Kuvaaja luotu MATLAB:lla.


5.4 Datan prosessointi

Datan analysointi sisälsi siis kolme erilaista tunnistettavaa vaihetta:

1. Suorituksen nollakohdan määrittäminen $t(0)$ (mittalaitteiden synkronointi)
2. Alustakontaktin alku, IC (initial contact, jalkakontakti)
3. Alustakontaktin loppu, TO (toe-off, varvastyöntö)

Suorituksen nollakohta on molemmille jaloille sama ja sen määrittämistä ja toteutusta on analysoitu tarkemmin seuraavassa luvussa.

Alustakontaktin alku ja loppu määrittyvät kummallekin jalalle erikseen. Juoksijan jalat liikkuvat pääsääntöisesti eteen- ja taaksepäin, joten juoksuliikkeen eri vaiheet erottuvat parhaiten kiihtyvyyssanturin X-akselilla eli anteroposteriorisessa horisontaalivoimassa, joka suuntautuu jalkaterän suuntaisesti. Y-akselin mukaista lateraalisen horisontaalivoiman aiheuttamaa sivuttaisliikettä on jonkin verran. Z-akselin vertikaalinen voimat taas reagoivat voimakkaimmin jalan alustakontaktin alussa sekä varvastyönön vaiheissa.



Kuvio 5. Esimerkkiotos kiihtyvyyssanturin normalisoidusta datasta kahden askeleen ajalta. Näkyvillä akselit X, Y ja Z. Kuvaaja luotu MATLAB:lla.


Sensorijalan kiihtyvyyksissä kontaktin alku ja loppu näkyvät molemmat selvästi. Niiden kohdalla kiihtyvyyden muutos on merkittävä ja havaittavissa signaalista helposti. Nämä kohdat näkyvät kuvassa kohdissa X 202 ja X 876. Niiden välille jäävässä tukivaiheessa kiihty-

vyys ei muutu, sillä jalka ei ole liikkeessä vaan vakaasti kiinni alustassa. Tämä vaihe on merkitty kuvaan merkillä X 590.

Alustakontaktia seuraava jalan heilahdusvaihe taas näkyy kiihtyvyyssignaaleissa tasaisempaan vaiheeseen, kun jalkaan ei kohdistu kiihtyvyyden muutosta. Kuvassa se näkyy merkin X 1496 kohdalla. Heilahdusvaiheen lopussa jalka pysähtyy vastaanottamaan uutta kontaktia, joten vaihe näkyy kiihtyvyyden negatiivisena muutoksena X-akselilla.

5.5 Suorituksen nollakohta

Suorituksen nollakohdassa eli koehenkilön paikallaan tekemien tasajalkahyppyjen aikana kiihtyvyyssanturin data on erilaista kuin tavallisessa liikkeessä ja itse juoksusuoritteissa. Ero on nähtävissä poikkeuksellisena kiihtyvyyssiikkinä koordinaatiston yhden akselin suuntaisesti. Kun kiihdyttävä voima eli maakontakti lakkaa, vähenee myös kiihtyvyyssiikki. Tämä näkyy myös voimalevyihin kohdistuvan voiman loppumisena. Kun nämä kaksi vaihetta on eri lähteiden datasta tunnistettu, on myös suorituksen nollakohta määritetty ja mittalaitteet synkronoitu.



Kuvio 6. Esimerkkiotos suorituksen nollakohdan määrittämisestä. Nähtävillä hetki, kun henkilö astuu voimalevyille, hyppää kolmesti ja jää seisomaan levyn päälle. Data on normalisoitu, mutta tarkka synkronointi on vielä tässä vaiheessa tekemättä.

Suorituksen nollakohdan arvioinnissa ongelmaksi muodostuivat synkronoinnissa käytettävien algoritmien tarkkuus ja toimivuus sekä voimalevylaitteiston tallennustaajuus. MATLAB-algoritmeilla sopivan viiveen määrittäminen ja asettaminen signaalien välille ei toiminut toivotulla tavalla. Viive määrittyi erilaiseksi jopa kiihtyvyyssanturin eri akselien suhteen eikä näin ollen voimalevyjen ja kiihtyvyyssanturin signaalien synkronointiin ei löytynyt toimivaa menetelmää. Synkronointi tehtiin lopulta manuaalisesti jokaiselle juoksijalle ja juoksukerrolle.

5.6 Alustakontaktin alku ja loppu

Jalan kokonaisalustakontakti määritettiin sinä aikana, jonka voimalevyyden kohdistunut voima oli enemmän kuin 0 N. Sillä voimalevylaitteiston nollaamista ei suoritettu, asetettiin voimalevydatan esikäsittelyssä raja-arvo, jonka alle jäävät arvot luokiteltiin kontaktittomiksi hetkiksi. Vaikka voimalevydalle suoritettiin sen normalisointi ja tasaaminen, ei signaali ollut tasaista, vaan aaltoilevaa ja jatkuvan jaksottaista. Lisäksi käytännössä mittalaitteiston 0 N vaihteli mittauskertojen välillä, joten määrittäminen suoritettiin arvioimalla oletettu sopiva nollakohta ja määrittämällä se kynnyksarvoksi.

Alustakontaktin alku on se hetki, kun jalka osuu maahan ja voimalevyyden kohdistuneen voiman määrä on kasvava. Samoin taas maakontaktin lopussa voimalevyyden kohdistunut voima pienenee ja saavuttaa lopulta 0 N.

Tukivaiheesta sekä jalkakontaktin että varvastyönön vaiheet näkyvät voimalevyn datassa selvänä piikkinä, kun taas heilahdusvaiheessa jalkaan ei enää kohdistu räjähtävää voimantuottoa. Näin ollen heilahdusvaihe on tavallisesti juoksuaskeleessa tasaisempi. Alustakontaktin alussa jalkaan kohdistuvat voimat ovat kovat, kun kenkä koskettaa alustaan törmäysmäisesti. Samoin siis kiihtyvyyssanturiin kohdistuvat voimat ovat suuret. Kontaktikohdat näkyvät molemmissa datoissa selvästi; kiihtyvyyssanturin tapauksessa erityisesti sensorijalan maakontaktin kohdalla.

5.7 Esiprosessointi

KDD-prosessin kolmannen vaiheen mukaisesti dataa oli esikäsiteltävä eli esiprosessoitava, jotta se olisi valituille louhintamenetelmille paremmin soveltuva. Raakadata ei ollut käytettävää sellaisenaan, vaan sille tuli suorittaa esiprosessointia sekä automaattisilla että manuaalisilla menetelmillä.

Koska sekä voimalevyt että kiihtyvyyssanturi tallentavat erilaisella tallennustaajuudella, on ne skaalattava vastaamaan toistensa taajuuksia. Kiihtyvyyssanturissa korkein mahdollinen tallennustaajuus oli 3200 Hz, jolla tallennus myös tehtiin ongelmitta. Vaikka voimalevyjen tallennuksen taajuudeksi asetettiin 1000 Hz, ei laitteisto käytännössä tallentanut halulla taajuudella, vaan todellisuudessa tallennustaajuus oli 1022.3 Hz. Taajuusero tuli ilmi, kun voimalevyn ja kiihtyvyyssanturin dataa verrattiin keskenään eivätkä voimalevyjen mitaukset täsmänneet kiihtyvyyssanturin tallentamiin askeleisiin, vaikka nollakohdat määritettiin käsin. Lopulta myös signaalien yksiselitteinen synkronointi oli mahdotonta. Signaalien synkronoinnin ongelmat johtivat siihen, että synkronointi suoritettiin lopulta manuaalisesti siirtämällä kiihtyvyyssanturin signaalin alkua riittävästi oikeaan suuntaan. Siirtämisessä käytettiin MATLAB:n *Signal Analyzer*-sovellusta. Ongelmaa poistettiin siis sillä, että molempien jalkojen askeleet sisältäneet pätkityt signaalin segmentit synkronoitiin käsin mahdollisimman tarkasti. Painelevyjen signaalit muutettiin uudelleenotannalla kiihtyvyyssanturin taajuudelle 3200 Hz Toteutuksessa käytettiin MATLAB:n *resample*-funktioita, joka käyttää uudelleenotannassa äärellisen impulssivasteen (Finite Impulse Response, FIR) niin sanottua anti-aliasing alipäästösuodatinta. (FIR-suodattimista ks. esim. Vaidyanathan 1987)

Voimalevyjen tallennusdatan minimiarvot eli nollakohdat vaihtelivat mittauskertojen välillä, joten datan yhtenäisyyden vuoksi ne tuli tasoittaa ja skaalata välille 0..1. Myös kiihtyvyyssanturin data normalisoitiin, mutta välille -1...1, sillä kiihtyvyyden arvot voivat olla myös negatiivisia. Normalisointi suoritettiin käyttämällä niin sanottua min-max-normalisointia, jonka yleinen kaava on: $x' = \frac{x - \min(x)}{\max(x) - \min(x)}$ (ks. esim. Kantardzic 2011, s.33-34).

Koska voimalevyn tuottama data on aaltomaista ja siksi esimerkiksi kynnyсарvojen asettaminen on haasteellista, tulee voimalevyysignaalia esikäsitellä sen tasoittamiseksi. Ongelman ratkaisuna signaalia tasoitettiin käyttämällä siirtyvän keskiarvon menetelmää. Tasoittami-

seen parhaiten sopiva menetelmä on niin sanottu *moving average* (MA), liikkuva keskiarvo. MA-menetelmä perustuu siihen, että se summaa havaintojen viimeiset m -kappaletta jokaisen arvon määrittämisessä. Se voidaan määrittää Kantardzic (2011) mukaan seuraavanlaisesti:

$$MA(i, m) = 1/m \sum_{j=i-m+1}^i t(j)$$

(Kantardzic 2011, s.38-40).

Ongelma MA:ssa on, että sen määrittämät arvot pehmentävät myös datan äärikohtia, joita voimalevydatassa syntyy jalan ja alustan kontaktin alussa ja lopussa. Jalan kontaktihetkessä syntyvä voima näkyy vahvasti kasvavana ja nousevana käyränä. Näissä kohdissa voimalevydatan käyrä on erittäin jyrkkä. Näin ollen MA:n tekemät tasoitukset vaikuttavat myös alustakontaktin laskemisen tarkkuuteen, sillä se pehmentää myös rajalla olevien arvojen eroja. Kiihtyvyyssanturissa tällaisia on voimalevyjä enemmän niissä hetkissä, kun jalka osuu tai ponnistaa maasta. Nämä ovat taas kontaktiajan kannalta kriittisiä vaiheita. MA-menetelmä ei siis sovellu kiihtyvyyssanturin signaalin tasoittamiseen, mutta voimalevydatassa selviä näkyviä mittauslaitteistosta johtuvia häiriöitä on kuitenkin huomattavasti vähemmän.

Tämän jälkeen voimalevydata luokittelu toteutettiin MATLAB-skriptillä, jolle annettiin parametreina voimalevydatan lisäksi aloitusjalka, seuraava jalka ja kynnyсарvo. Kynnyсарvolle määritettiin arvoksi 0 leijumisvaiheen hetket eli ne kohdat, joissa maakontaktia ei ollut. Mikäli kontakti oli, määritettiin sen arvoksi ensimmäisen jalan arvo, kunnes kontakti maahan loppui. Jos data sisälsi toisen jalan kontaktin, määritettiin seuraavan kontaktin aikaisiksi arvoiksi seuraavan jalan arvo. Oikeasta eli sensorijalasta käytettiin arvoa 1 ja vasemmasta jalasta arvoa 2.

Suurimman osan kohdalla kynnyсарvot oli mahdollista määrittää käyttäen yhtä kynnyсарvoa kaikille segmenteille. Asetetut luokat tarkistettiin käsin virheiden varalta. Mikäli virheitä oli, muutettiin segmentin kynnyсарvoa sopivaksi ja ajamalla MATLAB-skripti uudelleen. Näin meneteltiin neljän juoksijan kohdalla, joilla kullakin ongelmia koitui keskimäärin yhden segmentin kynnyсарvojen kanssa. Juoksijoiden lopullisiksi määritellyt kynnyсарvot on nähtävillä taulukossa 1.

Juoksija	Kynnysarvo
01	0.020
02	0.020 (0.022)
03	0.020 (0.022)
04	0.028
05	0.028 (0.029 ja 0.030)
06	0.040 (0.041)
07	0.020

Taulukko 1. Voimalevydatan kynnysarvot juoksijoittain. Suluissa olevaa kynnysarvoa on käytetty keskimäärin vain yhdessä tai kahdessa segmentissä.

5.8 Prosessoinnin vaiheiden yhteenveto

Tutkielmassa käytetty kiihtyvyyssanturin raakadata oli muotoa $n \times 3$, jossa n määrittyi tallennuksen pituuden mukaan. Kun data oli esikäsitelty ja valmis luokittelua ja mallien opettamista varten, oli se muotoa $k \times 35$, jossa taas k merkitsi ikkunoinnilla ja Fourier-muunnoksella saatujen signaalien osien määrää.

Kiihtyvyyssanturin datan prosessoinnissa suoritettiin vaiheet:

1. Raakasignaalien tallennus
2. Manuaalinen jakaminen osiin
3. Normalisointi välille $[-1...1]$
4. Osien ikkunointi ja piirteytys Hamming-ikkunoinnilla ja Fourier-muunnoksella
5. Hallitsevan frekvenssin ikkunan valitseminen ja piirteiden vähentäminen ± 17 hallitsevasta frekvenssistä

Painelevyjen raakadata taas oli ennen esiprosessointia $n \times 1$ -matriisi, jossa n oli niin ikään tallennuksen pituuden mukainen. Esikäsitelyn jälkeen muoto oli $k \times 1$, jossa k oli yhä tallennuksien määrä.

Painelevydatan prosessoinnissa suoritettiin vaiheet:

1. Raakasignaalien tallennus
2. Uudelleennäytteistys kiihtyvyyssanturin tallennustaajuuden mukaisesti

3. Manuaalinen jakaminen osiin
4. Normalisointi välille [0...1]
5. Luokittelu kynnistyksen avulla
6. Osien ikkunointi ja piirteytys moodin perusteella

Molemmille signaaleille suoritettiin yhteisesti manuaalinen synkronointi. Synkronointi toteutettiin samalla, kun signaaleja jaettiin manuaalisesti osiin. Mallin opettamista varten datat yhdistettiin yhdeksi $n \times 36$ -matriisiksi, jossa viimeinen indeksi eli 36 kertoi oikean luokan ja muut indeksit 1...35 olivat luokittelijalle syötettäviä piirteitä.

6 Implementointi ja tulokset

6.1 Toteutus

Kun kaikki datan esiprosessoinnin vaiheet oli suoritettu ja data jaettu eri juoksijoiden osalta omiin lohkoihinsa, ajettiin luokittelijamallit MATLAB:ssa komennolla *fitcensemble*, jolle parametreiksi annettiin *'Method'*, *'Bag'* sekä *'OptimizeHyperparameters'*, *'auto'*. *Method*-parametri määrittää, mitä luokittelijamallia halutaan käyttää, *Bag*-arvo taas asettaa opetuksen oletusmenetelmäksi bootstrap-aggregoinnin ja käyttää siis satunnaismetsämallia. Iteraatioissa MATLAB kokeilee myös boosting-menetelmiä, mutta jokaisen mallin kohdalla se päätyi lopulta baggingiin. Satunnaismetsät eivät käytännössä hyödynnä tai vaadi hyperparametrejä, joten niitä ei tarvinnut asettaa. Siksi funktiokutsussa niiden arvoksi asetettiin *auto*. Luokittelumallin arviointeja suoritettiin yhteensä 30 kappaletta, joista viimeiset kymmenen parhaaksi arvioidulla menetelmällä. Kun luokittelijat oli opetettu, testattiin niiden tarkkuus ajamalla poisjätetyn juoksijan dataa käyttäen *predict*-komento, joka luokitteli juoksijan datan. Tämän jälkeen mallin luomaa luokittelua verrattiin oikeaan, alkuperäiseen luokitteluun laatimalla tuloksista sekaannusmatriisi. Nämä mallikohtaiset sekaannusmatriisitulokset on nähtävissä seuraavassa luvussa, jossa arvioidaan saatuja tuloksia.

6.2 Artefaktin arviointimetriikat

Tutkielmassa on tarkasteltu juoksijan kontaktiajan arviointia kiihtyvyyssanturin datan perusteella. Kuten aiemmin on todettu, arvioitava artefakti on luokitteluun perustuva malli, joka määrittää kiihtyvyyssanturin signaalista ne hetket, kun jalka on koskettanut maata. Lähtökoh- ta on hyvä pitää mielessä varsinaisia arviointimetriikoita valittaessa ja arvioidessa.

Zaki ja Meira (2014) määrittävät binääriseen luokitteluun soveltuvan käsitteen positiivisista ja negatiivisista luokista seuraavasti:

	Oikea luokka	
Ennustettu luokka	Positiivinen	Negatiivinen
Positiivinen	Oikea positiivinen (OP)	Väärä positiivinen (VP)
Negatiivinen	Väärä negatiivinen (VN)	Oikea negatiivinen (ON)

Taulukkoa kutsutaan joko kontingenssitauluksi, *confusion matrix*-tauluksi tai sekaannusmatriisiksi.

Tässä tutkielmassa positiivinen tarkoittaa kosketusta maahan ja negatiivinen ei kosketusta maahan. Zaki ja Meira (2014) mukailen oikeat positiiviset ovat ne luokittelut, jolloin juoksijalla oli kosketus maahan ja jonka malli tunnisti oikein. Väärät positiiviset ovat hetkiä, kun malli tulkitsi virheellisesti juoksijalla olleen kontaktin maahan. Virheellisissä negatiivisissa taas malli katsoi, että juoksijalla ei ollut kontaktia maahan, vaikka kontakti oli. Oikeiden negatiivisten tapauksessa malli tulkitsi oikein, ettei kontaktia ollut.

Kontingenssitaulut toimivat sekä useilla luokilla että binäärisillä luokilla. Luokittelijan kokonaistarkkuutta tarkasteltaessa maakontaktit jaettiin binääriseksi malliksi kahteen eri luokkaan: oikean eli kiihtyvyyssanturin jalan ja vasemman valan kontakteihin. Tästä syntyi luokittelu:

	0	ON	VP	VP
Oikea luokka	1	VN	OP	OP
	2	VN	OP	OP
	0	1	2	
	Ennustettu luokka			

Zaki ja Meira (2014) esittävät kaksi peruslukua, joilla luokitteluun pohjaavaa mallia arvioidaan. Ensimmäinen on virheiden määrä. Virheiden määrä saadaan yksinkertaisesti jakamalla havaintojen määrä virheellisesti luokiteltujen mallin tuottamien lopputulosten määrällä. Toinen arviointiperuste johdetaan virheiden määrästä ja se on luokittelijan tarkkuus. Tarkkuus on se prosenttimäärä, jonka luokitteleva malli on määrittänyt oikein. Tarkkuus toimii myös useamman luokan luokittelijalle. Mitä korkeampi tarkkuus on, sitä parempi on myös luokittelija. Pelkkä tarkkuus ei ole kuitenkaan aina paras tapa mitata luokittelijan suorituskykyä (Chicco ja Jurman 2020). Tätä varten on kontingenssitaulukosta johdettavissa useita arvioin-

timetriikoita, joita ovat aiemmin esitelty tarkkuuden lisäksi oikeiden positiivisten määrä (engl. *True Positive Rate*, TPR) eli sensitiivisyys tai *recall* sekä F1-mitta.

Metriikat luovat kvalitatiivista ymmärrystä luokittelijan tekemistä virheistä ja oikeista tulkinnoista (Ferri, Hernández-Orallo ja Modrou 2009). Tarkkuus siis kertoo, kuinka moni positiivisista luokitteluista tehtiin oikein ja recall taas sen, kuinka suuri osa positiivisista luokista tunnistettiin oikein. F1-mitta painottaa näistä molempia. F1-mittaa on käytetty laajasti, mutta esimerkiksi Hand ja Christen (2017) kritisoivat sen käyttöä. Heidän mukaansa se on ongelmallinen, sillä mitta painottaa tasapuolisesti sekä tarkkuutta että recall-arvoa. Käytännössä erityyppiset virheelliset luokittelut ovat eri arvoisia ja näin ollen niille tulisi antaa erilainen painoarvo luokitteluongelman mukaisesti.

Chicco ja Jurman (2020) pitävät niin sanottua *Matthews Correlation Coefficient* (MCC)-arvoa F1-mittaa parempana ja kuvaavampana menetelmänä. MCC on Matthews (1975) kehittämä metriikka, joka ottaa huomioon kaikki kontingenssitaulun arvot. Käytännössä MCC on tilastotieteissä yleisesti käytetyn *Pearson Correlation Coefficient* (PCC)-menetelmän kontingenssitaululle soveltuva versio ja sitä myös tulkitaan samalla tavalla. Jotta mallin MCC on korkea, tulee sen saavuttaa hyvä tulos kaikilla kontingenssitaulun luvuilla (Powers ja Ailab 2011). Muiden muassa Jurman, Riccadonna ja Furlanello (2012) esittävät, että MCC on hyvä ja helposti tulkittava kompromissi verrattuna muihin arviointimetriikoihin. MCC on kuitenkin teknisesti tarkoitettu vain binäärisille luokitteluille, joten sen tulosta tarkastellaan vain luokittelijoiden yhdistelmän yhteydessä.

Edellä mainitut arviointimetriikat lasketaan esimerkiksi Kantardzic (2011), Matthews (1975) ja Chicco ja Jurman (2020) mukaan seuraavilla tavoilla:

Taulukko 2. Arviointimetriikoiden laskentakaavat.

Metriikka	Laskentakaava
Tarkkuus	$P = OP / (OP + VN)$
Recall	$R = OP / (OP + VP)$
F1-mitta	$F = 2PR / (P + R)$
MCC	$TP \times TN - FP \times FN / \sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}$

Täydellisesti luokitteluja tekevän mallin tarkkuus-, recall- ja F1-mitan luvut ovat 1.00 ja huonoimmalle 0.00. MCC:n arvot vaihtelevat välillä [-1,+1], jossa arvon -1 saava luokittelija tekisi täydellisesti virheellisiä luokitteluja ja vastaavasti +1 täydellisesti oikeita. Arvo 0 taas vastaa satunnaisesti oikeaan osuvaa luokittelijaa.

Erityisesti tarkkuutta ja recallia on kyseenalaistettu arviointimetriikoina etenkin epätasapainoisten tietomallien yhteydessä. Mikäli data on luokkien välillä epätasaisesti jakautunutta, vaikuttaa se arviointimetriikan käyttökelpoisuuteen, sillä ne ovat esimerkiksi pääsääntöisesti riippuvaisia datan sisältämästä positiivisen luokan yhteismäärästä (Chicco ja Jurman 2020). Tutkielman alkuperäinen data-aineisto oli mallia:

Taulukko 3. Aineiston luokkien määrät.

Luokka	Kpl	%
0	15102	21,18 %
1	28575	40,07 %
2	27633	38,75 %
Yht.	71310	100 %

Kontaktin sisältävät luokat korostuvat, sillä data pilkottiin osiin juuri kontaktien ajalta ja muu jätettiin pääsääntöisesti ulos. Kontaktitonta luokkaa on aineistosta noin viidennes. Yhteensä siis 78,82 % datan luokista oli kontaktillisia. Näin ollen luokkien yhteisvertailun recall olisi noin 0.79, mikäli malli luokittelisi kaikki hetket kumman tahansa jalan kontaktiksi. Aineisto on siis Chicco ja Jurman (2020) mukaillen positiivisesti epätasapainoinen eli se sisältää enemmän positiivisia luokkia. Heidän tapausesimerkkiensä mukaan tällaisen aineiston luokittelijaa kuvaa parhaiten nimenomaan MCC.

6.3 Tulokset ja arviointi

Manuaalisesti asetettu voimalevyn nollakohdan raja-arvo vaikuttaa kontaktiajan määrittymiseen maksimissaan arviolta vain noin 10 näytepisteen eli noin 3 millisekunnin verran. Virhe ei ole merkityksellinen etenkin kun tarkkailussa ovat ikkunoidun signaalin hallitsevat taajuusmäärät ja ikkunan hallitseva kontaktin luokka.

Myöskään manuaalinen kiihtyvyyssanturin ja voimalevyn signaalien synkronointi ei vaikuta tarkkuuteen merkittävästi. Käytetty menetelmä eli Fourier-muunnos ei pohjaudu molempien signaalien tarkkaan synkronointiin, vaan nimenomaan mittaa kunkin taajuuden määrää signaalissa. Näin ollen käsin tehty ajallisten nollakohtien määrittely ja synkronointi on riittävää, eikä aiheuta lopputulokseen merkittävää virhettä.

Mallia arvioitiin Zaki ja Meira (2014) mukaisesti sekä tarkkuuden että luokittelun onnistumisen perusteella. Luokittelun onnistumista tarkasteltiin myös recallin ja F1-mitan kautta. Mallin toimivuuden arvioinnissa on tutkimuskysymyksen kannalta oleellista se, kuinka hyvin malli erottaa kontaktihetket. Eräs tärkeä mittari mallin toimivuuden tarkastelussa on väärin positiivisten ja negatiivisten luokittelujen määrä. Mikäli malli luokittelee virheellisesti kontaktin tapahtuneen, vaikuttaa se suoraan myös kontaktiajan laskemiseen.

Tarkkuus ei yksinään ole riittävä arviointimetriikka, vaan toimivuuden arviointia täydentävät recall ja F1-mitta. Sillä recall kertoo kuinka suuri osa positiivisista havaittiin oikein, voisi sitä pitää tutkimuskysymyksen kannalta relevanttina mittarina. Kuten aiemmin todettiin, datan tasapainolla on kuitenkin vaikutusta recall-luvun luotettavuuteen. Etenkin mallin luokittelun kokonaistarkkuutta tarkasteltaessa voi recall antaa korostetun hyvän kuvan luokittelun toimivuudesta, mikäli data on nimenomaan positiivisiin luokkiin kallistunutta. Jotta recall antaisi luotettavan kuvan mallista, tulisi luokkia olla tasaisesti puolet datasta. Kuten aiemmin todettiin, on tutkielman data positiivisesti painottunutta. Näin ollen recall ei välttämättä ole paras mittari, mutta antaa osviittaa toimivuudesta. Tarkastelemalla vain recall-arvoa tulokset näyttäisivät korostetun toimivilta, sillä recall on riippuvainen positiivisten luokkien määrästä datassa. Vaikka tutkielman data on painottunut niille hetkille, kun juoksijalla on kontakti alustaan, tuo kolmen eri luokan käsittely mallille haastavuutta. Malli ei voi yksinkertaisesti asettaa kaikkia havaintoja positiivisiksi ja näin näyttää korkeaa recall-arvoa. Kaikkien metriikoiden tasapainoinen tarkastelu on siis oleellista.

Taulukko 4. Mallien tarkkuus, recall ja F1-mitta juoksijoittain ja luokittain.

Poisjätetty juoksija	Luokka	Tarkkuus	Recall	F1-mitta
1	0	0.49	0.77	0.60
	1	0.89	0.76	0.82
	2	0.81	0.60	0.69
2	0	0.44	0.60	0.51
	1	0.82	0.76	0.79
	2	0.73	0.60	0.66
3	0	0.41	0.67	0.51
	1	0.85	0.78	0.81
	2	0.88	0.74	0.80
4	0	0.49	0.55	0.52
	1	0.87	0.77	0.82
	2	0.71	0.74	0.73
5	0	0.43	0.53	0.48
	1	0.89	0.67	0.77
	2	0.60	0.73	0.66
6	0	0.38	0.66	0.48
	1	0.90	0.75	0.82
	2	0.77	0.62	0.69
7	0	0.37	0.69	0.48
	1	0.87	0.79	0.83
	2	0.91	0.74	0.82
Keskiarvo	0	0.43	0.64	0.51
	1	0.87	0.75	0.81
	2	0.77	0.68	0.72
Kaikki mallit	0	0.42	0.62	0.50
	1	0.87	0.75	0.81
	2	0.78	0.69	0.73

Malleja nimitetään ja niihin viitataan opetusvaiheessa poisjätettyjen juoksijoiden numeroi-

den mukaan. Esimerkiksi juoksijan yksi mallilla viitataan luokittelijan malliin, joka opetettiin ilman juoksijan yksi dataa ja validoitiin juoksijan yksi datalla.

Yksittäisten juoksijoiden mallien kohdalla on havaittavia eroja. Ensimmäisen juoksijan luokittelun recall oli käytännössä lähes samanlainen sekä sensorijalalle että kontaktittomille hetkille, samoin myös F1-mitta luokille 0 ja 2. Muiden juoksijoiden mallien kohdalla ero kyseenomaisten luokkien arviointimetriikoissa oli selvempi: luokittelijat kykenivät selvästi parempaan tulokseen oikean jalan luokittelussa.

Juoksijoista kolmannen ja seitsemännen mallien kohdalla on mielenkiintoinen ero muihin malleihin. Kun malli luokitteli kontaktijalan vasemmaksi, oli sen tarkkuus molemmissa malleissa parempi verrattuna oikean jalan luokitteluun. Lisäksi myös recall on molemmilla kontaktiluokilla lähes sama. Molempia juoksijoita yhdistää muihin verrattuna pitkä kontaktiaika (ks. liite A). Havainto on mielenkiintoinen, sillä sensori oli kiinnitettynä oikeaan jalkaan. Mallit siis tunnistavat paremmin kiihtyvyyssanturittoman jalan kuin jalan, jossa kiihtyvyyssanturi on kiinnitettynä. Havainto ei kuitenkaan ole täysin yleistettävissä, sillä esimerkiksi viidennen juoksijan mallin vasemman jalan luokittelutarkkuus oli vain alle 60 prosenttia ja merkittävästi oikeaa heikompi. Muilla malleilla ero jalkojen luokittelun tarkkuuden välillä oli pääsääntöisesti pienempi. Havainnon perusteella voi silti sanoa, että vasemman ja oikean jalan kontaktihetket ovat toisiinsa sidonnaisia ja mahdollisesti toistensa perusteella pääteltävissä.

Poikkeuksia lukuun ottamatta usean juoksijan mallien tuloksissa erottuu mallin heikompi tarkkuus luokiteltaessa vasemman jalan kontakteja. Erityisen selvää tämä on juoksijan numero viisi mallin kohdalla. Siinä missä oikean jalan kontaktit on tunnistettu 89.3 prosentin tarkkuudella, jää vasemman tunnistaminen alle 60 prosenttiin. Silti vasemman jalan luokituksen recall on luokista korkein - oikeiden positiivisten identifiointien suhteellinen määrä oli siis korkein. Juoksijan validointidatalla malli kykeni siis recall-arvon perusteella parempaan vasemman anturittoman jalan luokitteluun oikeaan jalkaan verrattuna. Sekä tarkkuutta että recallia painottava F1-mitta kuitenkin ilmaisee, ettei tulkinta ole yksiselitteistä. Sen perusteella luokittelu oli parempaa oikean jalan kontakteille.


Eroja eri mallien tulosten välillä voi selittää osaksi juoksijoiden juoksusuoritusten sekä hei-

dän juoksutekniikkansa eroilla. Juoksijoiden välillä oli ero juostujen vetojen määrässä kutakin intensiteettitasoa kohden. Lisäksi kun juoksun intensiteetti jää koehenkilön itsensä määritettäväksi, korostuvat myös erot juoksijoiden taito- ja fyysisen kunnon tasoissa. Juoksun intensiteetti vaikuttaa merkittävästi suoraan askelväliin ja siten alustakontaktien tiheyteen, joten ero näkyy myös Fourier-muunnoksella saatujen hallitsevien taajuuksien voimakkuuksissa. Tämä vaikeuttaa luokittelua, kun mallin opetukseen käytetty data eroaa testidatasta, joka on myös ristiinvalidoinnin tarkoitus.

Kun kaikkien juoksijoiden mallien yhteenlasketut tulokset liitetään yhdeksi taulukoksi, jossa molempien jalkojen kontaktien luokat yhdistetään yhdeksi luokaksi, voidaan tuloksia tarkastella yksinkertaisemmin kontingenssitaulukon mukaisesti positiivisina ja negatiivisina luokitteluina. Täten on myös mahdollista laskea tarkkuuden ja recallin lisäksi F1-mitta, joka kattaa havainnot uusien yhdistettyjen luokittelujen kautta. Binäärisenä luokitteluna esitetyistä tuloksista voi laskea myös MCC:n. F1-mitaksi saadaan 0.80 ja MCC:n arvoksi 0.34. Saatu positiivinen ja verrattain korkeakin MCC-arvo kertoo siis, että malli on onnistunut luokittelevässänsä hyvin käytetyn datan tasapainon huomioon ottaen.

Lukumääränä virheellisten negatiivisten määrä on tuloksissa merkittävä. Mallit eivät onnistuneet määrittämään kontaktittomia hetkiä kovin hyvällä tarkkuudella tai varmuudella. Tarkkuuden keskiarvona 0.43 on heikko, kuten ovat myös recall ja F1-mittakin. Sama korostuu, kun kontaktien luokat on yhdistetty yhdeksi kontaktiluokaksi - tarkkuus jopa heikkenee 0.42:een. Mallit onnistuivat kuitenkin luokittelemaan varsin luotettavasti oikean ja vasemman jalan kontaktihetket. Erityisesti havainto korostuu neljännen juoksijan datalla, jonka luokitelluista vasemman jalan kontakteista vain yhdeksän näytepistettä luokiteltiin virheellisesti oikean jalan kontakteiksi.

Kaikkien mallien kohdalla tunnistuksen ja luokittelun suurin ongelma oli sama: Malleille oli ongelmallista erottaa vasemman, anturittoman jalan kontaktit hetkistä, kun kontaktia ei ollut. Suuri osa virheellisistä luokitteluista tapahtui nimenomaan näiden kahden luokan välillä. Samoin ongelmia oli kontaktittomien hetkien tunnistamisessa. Niiden kohdalla mallit olivat jopa enemmän väärässä kuin oikeassa. Mallien sovellutuksen kanssa kontaktittomien hetkien tunnistaminen ei välttämättä ole ongelma, sillä kuten mainittu, olisi sen kannalta tärkeämpää havaita tarkasti kontaktin hetket eli tutkimuskysymyksessä määritetty arvioitava määre.




Kuvio 7. Kaikkien mallien ja havaintojen yhteenlasketut tulokset. Kuvaajassa jalkojen askelten luokat on yhdistetty yhdeksi luokaksi. Kuvaaja piirretty MATLAB:lla. Recall on laskettu matriisin oikealle puolelle ja tarkkuus alapuolelle.

Virheellisiin luokitteluihin on vaikuttanut luonnollisesti juoksun intensiteetti. Heilahdusvaiheessa sensorijalkaan liittyvät voimat ovat riippuvaisia juoksun intensiteetistä. Kun juoksu-
vauhti on nopeampi, tapahtuvat siis myös jalkojen liikkeet nopeammin ja näin kiihtyvyys on voimakkaampaa kuin hitaammassa juoksuvauhdissa. Sensorijalan heilahduksessa jalkaan kohdistuvat voimat ovat siis heikommat, joka näkyy taajuuksien voimakkuudessa. Sen vuoksi myös kontaktihetken ja sensorittoman vasemman jalan erottaminen on vaikeampaa ja epätarkempaa. Jos taas juoksija on juossut kovemalla intensiteetillä kuin opetusdatana käytetyn joukon juoksijat, ei malli opi tunnistamaan juoksijan käyttämää intensiteettiä yhtä hyvin kuin opetusdatassa esiintyviä.

Mallin tulosten arvioinnissa korostuu luokittelun vaikeus ja tutkimuskysymyksen pääongelman määrittämä vaatimus myös luokittelun tarkkuudesta. Jotta malli olisi toimiva ja hyö-

dynnettävissä sellaisenaan, vaadittaisiin kontaktin hetkiltä katkeamatonta oikeaa luokittelua. Muussa tapauksessa virheelliset luokittelut katkaisisivat kontaktiajan laskemisen ja näin tekisivät mallin soveltamisesta hyödytöntä. Tämä on nähtävissä kuvaajasta:



Kuvio 8. Kuvaajassa näkyvissä luokittelijan tekemät luokittelut sekä todelliset luokat. Otos valittu satunnaisesti, kuvaaja piirretty MATLAB:lla.

Kuvaajassa on näkyvillä niitä kohtia, joissa luokittelija kykeni erinomaiseen luokitteluun, mutta myös vahvan virheellisiä luokittelujaksoja. Kontaktit näkyvät kuvaajassa nousevina ja laskevina kohtina, jotka saavat arvot 0, 1 ja 2 luokkien mukaan. Erityisen hyvin malli on suoriutunut luokittelussaan, kun luokka on 1. Tämä näkyy katkeamattomina sinisinä viivoina, jotka jäävät oranssin alle. Vastaavasti virheellisiä luokitteluja on tapahtunut, kun oikea luokka on ollut 2. Kuvaajasta tehdyt havainnot tukevat arviointimetriikoista tehtyjä havaintoja.

Siispä mikäli mallista olisi tarkoitus tehdä suoraan sovellettava kontaktiaikaa estimoiva sovellutus, tarvitsisi ratkaisu vielä jonkinlaista säännöstöä ja kynnyksarvoa kontaktiajan laske-

miseksi. Tällainen ratkaisu olisi mahdollista esimerkiksi tulkitsemalla estimoitua luokittelua vaikkapa liikkuvan keskiarvon menetelmällä. Liikkuva keskiarvo vaikuttaisi estimoidun kontaktiajan todelliseen tarkkuuteen, mutta riittävän lyhyt laskennan keskiarvoikkuna vähentäisi laskennan virhettä.

7 Johtopäätökset

Tässä luvussa tarkastellaan tutkielman varsinaisen artefaktin lisäksi tuotettua tutkimuksen teoreettista antia sen tutkimuksellisen viitekehyksen teorian piirissä. Tutkielmaa arvioidaan luvussa 2 (Suunnittelutieteellinen tutkimus) esiteltyjen tutkimustieteellisen tutkimuksen suuntaviivojen mukaisesti. Lisäksi luvussa vedetään yhteen tutkimuksella tuotettuja teknisiä sääntöjä ja arvioidaan sen tiedollisen kontribuution merkitystä ja maturiteetin astetta.

7.1 Tutkimuksellinen arviointi

Tutkimuksen pääkysymyksenä oli tarkastella juoksijan kontaktiaikaa arvioivan artefaktin mahdollisuuksia ja luoda artefakti. Tuloksena oli malli, joka kykeni hyvään arviointitarkkuuteen. Vaikka tutkimuksessa ei tuotettu varsinaista kontaktiaikaa laskevaa sovellusta, antaa artefakti mahdollisuuden sovellutuksen luomiseksi. Tässä mielessä ongelmanratkaisu kuitenkin toimii ja tuottaa teknisen ratkaisun tutkimuskysymykseen.

Tulosten arvioinnissa käytettiin useita erilaisia metriikoita. Käytettyjen metriikoiden soveltuvuutta ja kuvaavuutta tarkasteltiin ja arvioitiin muun muassa tutkimuksen datan tasapainon perusteella. Lopulta artefaktin toimintaa ja tarkkuutta arvioitiin metriikoiden kautta. Metriikat esiteltiin jokaisen luodun mallin kohdalla erikseen.

Tutkimus on omalta osaltaan antanut kontribuutionsa alan tutkimukseen. Siinä tehty havainto, että juoksijan molempien jalkojen kontaktiajat on arvioitavissa vain toiseen kiinnitetystä kiihtyvyyssanturista, on aiemman tutkimuksen näkökulmasta uusi. Samoin satunnaismetsäluokittelun mahdollisuus tutkielman kaltaisen luokitteluongelman ratkaisussa on kontribuutio tutkimusalan tiedolle.

Tutkimuksellinen tarkkuus on liitoksissa tuloksiin ja käytettyihin menetelmiin. Käytettyinä menetelminä piirteytyksessä Fourier-muunnos ja luokittelussa satunnaismetsät olivat tarkkoja ja käytännöllisiä. Ne havaittiin toimiviksi ensin teoreettisessa mielessä ja sitten käytännön kokeissa. Menetelmät olivat soveltuvia tutkimuksen kohdealueen ja ongelman ratkaisun kannalta, sillä juoksu liikesarjana on abstraktoitavissa luokitteluongelmaksi ja datana käyte-

tyt signaalit ovat jaettavissa eri taajuuskomponenteiksi. Taajuuskomponentit taas soveltuvat luokitteluongelman opetusdataksi.

Suunnittelun etsintäprosessin käsitteen ytimessä on ongelmarelevanttius. Tutkielmassa tämä huomioitiin siten, että lopputuloksen arvioinnissa otettiin huomioon ne ongelmat, joita artefaktin soveltaminen mahdollisesti vaatii ratkaistavaksi. Esimerkiksi kontaktihetkien luokittelussa tapahtuviin kontaktin katkeamisiin esitettiin ratkaisuksi liikkuvaa keskiarvoa. Lopuksi tutkimuksen tulokset kommunikoitiin tämän tutkielman kautta kirjallisessa muodossa selkeästi jokaista prosessikokonaisuuden osaa avaten.

7.2 Tekniset säännöt

Tutkielman myötä käsitys teoreettisen ymmärryksen merkityksestä vahvistui. Molempien jalkojen kontaktit oli jo intuitiivisesti pääteltävissä kiihtyvyyssanturin datasta, mutta vain, mikäli juoksutekniikasta ja juoksun mekaniikasta liikkeenä oli riittävän hyvä ymmärrys. Kiihtyvyyssanturin datan perusteella oli hahmotettavissa, että sensorijalan lisäksi myös toisen jalan kontaktit olisivat pääteltävissä. Koneoppimisen menetelmillä saadut mallit ja niiden tulokset vahvistivat havainnot oikeiksi.

Parhaimmillaan kehityksen iteratiivisuus edesauttaa juuri teorian ymmärrystä ja siten vauhdittaa ja parantaa lopputulosta. Tutkielman prosessissa ratkaisu toteutettiin mallilla, joka ei tarvinnut parametointia. Parametrisoitavat mallit olisivat vaatineet uusia iteraatioita, jotka olisivat taas pitkittäneet tutkimusprosessin valmistumista. Toisaalta vahva teoreettinen pohja poistaa niitä mahdollisia virheitä ja hidasteita, joita parametrisoinnissa mahdollisesti syntyisi. Iteratiivinen menetelmä, jossa teoreettinen ymmärrys edesauttaa empiiristä havainnointia uudelleen ja uudelleen antaisi näin yhä parempia tuloksia. Iteratiivisuus on parhaimmillaan hyvä työkalu, mutta sen rajoitteet tulee ymmärtää.

Vaikka signaalien manuaalinen käsittely esimerkiksi synkronoinnin kohdalla ei merkittävästi vaikuttanutkaan lopputuloksen tarkkuuteen, oli sillä oma vaikutuksensa kehitystyön nopeuteen. Tutkielman tutkimuskysymyksen keskiössä ei varsinaisesti ollut voimalevy-signaalin analysoiminen, vaan nimenomaan kiihtyvyyssanturin signaali ja kontaktiajan arviointi sen avulla. Mikäli kehitystyö on pysähtyä havaitun ongelman vuoksi, tulisi tarkentaa ja palaut-

taa mieleen niitä päämääriä, joita DSR-tutkimuksessa halutaan saavuttaa. Tämän tutkielman tapauksessa se oli kontaktiaikaa estimoivan mallin luominen. Sen sijaan, että ongelmaan jäätäisiin kiinni, tulisi se mahdollisuuksien mukaan kiertää tai ratkaista tavalla, joka ei vaikuta merkittävästi lopputulokseen. Näin kehitystyö kulkisi iteratiivisesti kohti alkuperäistä päämäärää ilman tutkimuksellisia harhapolkuja.

Sillä iteratiivisuus voi pahimmillaan viivästyttää työn valmistumista, on tärkeää määritellä lopulliset tutkimukselliset tavoitteet mahdollisimman tarkasti. Mikäli näin ei tehdä, on riskinä jäädä jatkuvan kehittämisen kierteseen, jossa tuloksia ei lopulta saavuteta. Tässä mielessä DSR on tutkimusmenetelmänä lähellä sovelluskehityksen ketteriä prosessimalleja. Samalla se soveltuisikin joillakin muutoksilla erittäin hyvin sovelluskehityksen ohjenuoraksi.

7.3 Tiedollisen kontribuution arviointi

Gregor ja Hevner (2013) artefaktien kontribuutiotyyppien tasoilla tutkielman artefakti ei oikeastaan sijoitu täysin millekään tasolle. Sillä artefaktia tai sen kautta rakennettua sovellusta tai prosessia ei varsinaisesti ole otettu käyttöön, ei se sovellu ensimmäiselle tasolle. Kontribuutio ei myöskään tuota suunnittelutieteeseen uutta teoriaa. Tutkielman artefakti määrittyykin eniten juoksuun liittyvän tiedollisen kontribuution tasolla.

Tutkielman välitön tiedollinen kontribuutio ilmenee artefaktina luodussa mallissa, joka tarjoaa uudenlaisia näkökulmia kontaktiaikaan ja erityisesti sen estimointiin liittyviin mahdollisuuksiin. Erottelemalla juoksussa hallitsevat taajuudet oli juoksu purettavissa osiin. Artefakti antaa näin osin uudenlaista ymmärrystä tutkielman ydinteoriasta eli juoksun mekaanisesta suoritteesta ja sen analysoinnista. Eräs tällainen havainto oli sensorittoman vasemman jalan tunnistamiseen liittyvät mahdollisuudet.

Teknisten sääntöjen ja tiedollisen kontribuution maturiteetin asteen arviointi on vaikeaa. Jotta kattava analyysi ja siten arviointi on olisi mahdollista suorittaa, tulee myös tutkimusalueen aikaisempi tutkimus tuntea erittäin hyvin. Vasta tutkimuksellinen konteksti avaa mahdollisuuden arvioida artefaktin avulla tuotetun uuden informaation arvoa. Maturiteetin kautta tutkimuksen arvottaminen on siis esimerkiksi toiminnallisen suunnittelutieteen kannalta ankaraa, sillä se ei tiukasti tulkittuna ota huomioon niitä lähtökohtia, joista tutkimusta ja sen

tuottamaa sovellutusta tehdään. Organisaation näkökulma muuttaa tutkimuksen maturiteetin arviointia. Organisaatiossa sovellutus voi olla hyvinkin toimiva ja uutta tietoa luova, vaikka samankaltaisia tuloksia olisikin saavutettu jo muissa tutkimuksissa. Kyse on siis pä perspektiivistä, josta käsin tuloksia tarkastellaan ja arvioidaan. Tästä syystä Gregor ja Hevner (2013) esittelemä tapa kontribuution arviointiin maturiteetin kautta on häilyvä. Tietenkin erityisesti tieteellistä tutkimusta suunniteltaessa ymmärrys aiemmasta tutkimuksesta on tärkeässä roolissa, mutta organisaation tilanteessa varsinaisesta tutkimustyöstä irrotettu taustatyö saattaa viedä suuren osan tutkimukselle resursoidusta ajasta ja täten heikentää lopputuloksen laatua. Keskiössä on kuitenkin alkuongelmaan löydetty ratkaisu.

Arviointivaiheen analyysissä korostui monien erilaisten arviointimetriikoiden hyödyntäminen. Jotta arviointimetriikoita on mahdollista käyttää oikein ja tulkita luotettavasti, on oleellista ymmärtää mistä data koostuu ja millainen sen tasapaino on. Tutkielman kohdalla data oli positiivisesti tasapainottunutta, joka merkitsi sitä, ettei esimerkiksi recall ollut luotettava mitta. Sen lisäksi oli tarkasteltava sekä tarkkuutta että recallia painottavaa F1-mittaa. Kaikkia näitä yhdessä tulkitessa oli mallin toimivuuden analysointi luotettavampaa. Kokonaisuutta tarkastellessa taas MCC antoi hyvän yleisarvion mallien toimivuudesta, vaikkakin sen hyödyntämistä varten mallien tuloksia tuli muokata binääriseksi. Tässä tapauksessa kontaktin sisältävien luokkien yhdistäminen oli perusteltua, sillä se oli oleellista mallia soveltavan sovellutuksen oletetun toiminnan näkökulmasta.

Vaikka artefakti ei ole tarkkuudeltaan läheskään täydellinen, antaa se silti oman arvonsa tiedolliseen jatkumoon. Kuten arvioinnin yhteydessä todettiin, tulisi itsenäisesti ilman muita sovellutuksia kontaktiajan tarkkaan laskemiseen perustuvan mallin olla kontaktittomilla luokilla täydellinen. Käytännössä tällaiseen on vaikea ellei mahdoton päästä. Tutkielman malli antaa kuitenkin uutta ymmärrystä sovellutuksen vaatimuksista ja siihen liittyvistä mahdollisista muista ongelmakohdista.

Jatkotutkimuksena heräsi mielenkiintoinen näkökulma. Sikäli kun kontaktiaika on mahdollista arvioida jalasta, olisi myös menetelmää mahdollista testata jalasta mittaamisen sijaan rannemittauksella. Monet juoksussa käytettävät, ranteeseen kiinnitettävät urheilukellot sisältävät jo valmiiksi kiihtyvyyssanturin, jota hyödyntää. Näin opetettua mallia olisi mahdollista testata siis helposti käytännössä.

8 Yhteenveto

Tämän tutkielman tarkoituksena oli selvittää juoksijan kontaktiajan estimoinnin mahdollisuus tiedonlouhinnan menetelmillä. Estimointi suoritettiin tutkielmassa käyttäen MATLAB-sovellusta ja sen tarjoamaa satunnaismetsäalgoritmia. Tulokset vastasivat osaltaan odotettua, vaikkakin mallien tarkkuus etenkin kontaktittomien hetkien tunnistamisessa oli toivottua heikompi. Sen sijaan yllättävää oli mallien onnistuminen sensorittoman jalan kontaktien tunnistamisessa. Seitsemän juoksijan joukossa oli sopiva juoksutekniikoiden diversiteetti, vaikkakin lisätutkimusta ja mallien opettamista varten testijoukkoa olisi syytä laajentaa luokittelukyvyyn parantamiseksi.

Sillä tutkielmaproessin ongelmat erityisesti signaalien synkronoinnissa eivät olleet tutkielman pääkysymyksen keskiössä, ne olisivat hedelmällisiä aihioita jatkotutkimukselle ja menetelmän kehittämiseksi. Jatkokehityksessä signaalien synkronoinnin menetelmällisiä mahdollisuuksia tulisi laajentaa manuaalisesta laskennalliseen ja tekniseen tai teknologiseen tapaan. Uusia ongelmanratkaisuja voisi löytyä uusista algoritmeista tai käytettyjen välineiden aikaleimojen hyödyntämisestä.

Käytetty tutkimusmenetelmä olisi käytännöllinen myös tietotekniikan tutkimuksen ulkopuolella. Monet organisaatiot kohtaavat arjessaan ongelmia, joita olisi mahdollista ratkaista tutkivalla lähestymistavalla. DSR:n menetelmät voivat tuoda järjestelmällisiä malleja, jotka ratkaisevat ongelmat tehokkaasti. Iteratiivisina prosesseina ne toimivat dynaamisesti, mikäli ratkaisun ympäristö muuttuu. Samalla prosessi on itsessään dokumentoiva ja itse itsestään raportoiva. Lopputuloksena syntyvä artefakti taas tulee suoraan ongelman ratkaisuksi käytännön tasolla.

Mielenkiintoista olisi myös tarkastella juostujen kilometrien vaikutusta kontaktiaikaan ja siten juoksijan taloudellisuuteen ja sitä kautta aina juoksukuntoon pitkällä aikavälillä. Mallin sovellutus mahdollistaisi tarkkailun helposti ja nopeasti, ja antaisi mahdollista uutta tietoa juoksutekniikan vaikutuksesta.

Manuaalisen synkronoinnin ongelman ratkaisun jälkeen luotua artefaktia voisi jatkossa testata käytännössä. Kiihtyvyysanturi on erittäin käytännöllinen mittauslaite, sillä se on halpa,

yksinkertainen, kevyt sekä helposti kenkään kiinnitettävä. Yhteydet esimerkiksi laskettua dataa tallentavaan kelloon tai vaikkapa puhelimeen olisi mahdollista toteuttaa luotettavasti yleisesti käytetyllä Bluetooth-tekniikalla.

Tiedonlouhinnalla koostettua luokittelua olisi mahdollista jatkaa juoksun eri vaiheiden tarkasteluun. Pelkän luokittelumenetelmän sijaan havainnoinnissa voisi tarkastella klusteroinnin algoritmeja ja niiden toimivuutta. Niillä menetelmillä juoksusuoritteesta olisi mahdollisesti tunnistettavissa myös muita osa-alueita kuin maakontaktien vaiheita. Sen sijaan, että luokittelu rajattaisiin vain kolmeen, ei luokkien määrää välttämättä tarvitsisi rajata, vaan antaa menetelmän tunnistaa vaiheet ohjaamattomasti. Tällöin käytännölliseksi tulisivat ohjaamattoman koneoppimisen algoritmit, joilla juoksun vaiheiden tunnistaminen ei myöskään rajoittuisi vain niihin, jotka jo tunnetaan. Tällä menetelmällä jo tiedettyä juoksun vaiheiden luokittelua voisi mahdollisesti laajentaa yhä pienempiin vaiheisiin.

Lähteet

Wainberg, Michael, Babak Alipanahi ja Brendan J. Frey. 2016. “Are Random Forests Truly the Best Classifiers?” *J. Mach. Learn. Res.* 17, numero 1 (tammikuu): 3837–3841. ISSN: 1532-4435.

Weyand, Peter G., Deborah B. Sternlight, Matthew J. Bellizzi ja Seth Wright. 2000. “Faster top running speeds are achieved with greater ground forces not more rapid leg movements”. *Journal of Applied Physiology* (marraskuu): 1991–1999.

Witten, Ian H., Eibe Frank, Mark A. Hall ja Christopher J. Pal. 2017. “Chapter 12 - Ensemble learning”. Teoksessa *Data Mining (Fourth Edition)*, Fourth Edition, toimittanut Ian H. Witten, Eibe Frank, Mark A. Hall ja Christopher J. Pal, 479–501. Morgan Kaufmann. ISBN: 978-0-12-804291-5. doi:<https://doi.org/10.1016/B978-0-12-804291-5.00012-X>. <http://www.sciencedirect.com/science/article/pii/B978012804291500012X>.

Woo, Carson C., Arash Saghafi ja Alirio Rosales. 2014. “What is a Contribution to IS Design Science Knowledge?” Teoksessa *ICIS*.

Aken, Joan E. van. 2004. “Management Research Based on the Paradigm of the Design Sciences: The Quest for Field-Tested and Grounded Technological Rules”. *Journal of Management Studies* 41 (2): 219–246. doi:10.1111/j.1467-6486.2004.00430.x. <https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1467-6486.2004.00430.x>.

Baharuddin, Mohd Yusof, Mohd Sayuti, Mohd Salim ja Adilah Hashim. 2009. “Biomechanics Analysis on Running”. *Proceedings of International Conference on Applications and Design in Mechanical Engineering* (lokakuu).

Barnes, Kyle R., ja Andrew E. Kilding. 2015. “Running economy: measurement, norms, and determining factors”. *Sports Medicine - Open* 1, numero 1 (maaliskuu): 8. ISSN: 2198-9761. doi:10.1186/s40798-015-0007-y. <https://doi.org/10.1186/s40798-015-0007-y>.

- Bojkovic, Z. S., B. M. Bakmaz ja M. R. Bakmaz. 2017. “Hamming Window to the Digital World”. *Proceedings of the IEEE* 105 (6): 1185–1190.
- Breiman, Leo. 1996. “Bagging predictors”. *Machine learning* 24 (2): 123–140.
- . 2001. “Random Forests”. *Machine Learning* 45, numero 1 (lokakuu): 5–32. ISSN: 1573-0565.
- Brodley, Carla E., ja Padhraic Smyth. 1997. “Applying classification algorithms in practice”. *Statistics and Computing* 7 (1): 45–56.
- Chapman, Robert, Abigail Laymon, Daniel Wilhite, James McKenzie, David Tanner ja Joel Stager. 2012. “Ground Contact Time as an Indicator of Metabolic Cost in Elite Distance Runners”. *Medicine & Science in Sports & Exercise* 44, numero 5 (toukokuu): 916–925.
- Chicco, Davide, ja Giuseppe Jurman. 2020. “The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation”. *BMC Genomics* 21 (joulukuu). doi:10.1186/s12864-019-6413-7.
- Clark, Kenneth P., ja Peter G. Weyand. 2014. “Are running speeds maximized with simple-spring stance mechanics?” *Journal of Applied Physiology* 117 (6): 604–615.
- Dwivedi, Neelam, Sandeep Puro ja Detmar W. Straub. 2014. “Knowledge Contributions in Design Science Research: A Meta-Analysis”. Teoksessa *Advancing the Impact of Design Science: Moving from Theory to Practice*, toimittanut Monica Chiarini Tremblay, Debra VanderMeer, Marcus Rothenberger, Ashish Gupta ja Victoria Yoon, 115–131. Springer International Publishing.
- Daniels, Jack, ja Nancy Daniels. 1992. “Running economy of elite male and elite female runners.” *Medicine and science in sports and exercise* 24 (4): 483–489.
- Davern, Michael, ja Alison Parkes. 2010. “Incommensurability in design science: which comes first—theory or artefact?” Teoksessa *Information Systems Foundations: The Role of Design Science*, 75–90. ANU Press. ISBN: 9781921666346. <http://www.jstor.org/stable/j.ctt24h3z6.7>.
- Dugan, Sheila A., ja Krishna P. Bhat. 2005. “Biomechanics and analysis of running gait”. *Physical Medicine and Rehabilitation Clinics* 16 (3): 603–621.

Enoka, Roger M. 2008. *Neuromechanics of Human Movement*. Human Kinetics cop.

Österle, Hubert, Jörg Becker, Ulrich Frank, Thomas Hess, Dimitris Karagiannis, Helmut Krcmar, Peter Loos, Peter Mertens, Andreas Oberweis ja Elmar J Sinz. 2011. “Memorandum on design-oriented information systems research”. *European Journal of Information Systems* 20, numero 1 (tammikuu): 7–10.

Farley, Claire T, ja Daniel P. Ferris. 1998. “Biomechanics of walking and running: center of mass movements to muscle action”. *Exercise and sport sciences reviews* 26 (tammikuu): 253–285.

Fayyad, Usama, Gregory Piatetsky-Shapiro ja Padhraic Smyth. 1996a. “From Data Mining to Knowledge Discovery in Databases”. *AI Magazine* 17, numero 3 (maaliskuu): 37. doi:10.1609/aimag.v17i3.1230. <https://www.aaai.org/ojs/index.php/aimagazine/article/view/1230>.

———. 1996b. “Knowledge Discovery and Data Mining: Towards a Unifying Framework”. Teoksessa *Proceedings of the Second International Conference on Knowledge Discovery and Data Mining*, 82–88. KDD’96. Portland, Oregon: AAAI Press.

Fernández-Delgado, Manuel, Eva Cernadas, Senén Barro ja Dinani Amorim. 2014. “Do we Need Hundreds of Classifiers to Solve Real World Classification Problems?” *Journal of Machine Learning Research* 15 (90): 3133–3181.

Ferri, C., J. Hernández-Orallo ja R. Modroui. 2009. “An experimental comparison of performance measures for classification”. *Pattern Recognition Letters* 30 (1): 27–38. ISSN: 0167-8655.

Frawley, William J., Gregory Piatetsky-Shapiro ja Christopher J. Matheus. 1992. “Knowledge Discovery in Databases: An Overview”. *AI Magazine* 13, numero 3 (syyskuu): 57. doi:10.1609/aimag.v13i3.1011. <https://www.aaai.org/ojs/index.php/aimagazine/article/view/1011>.

- Gentleman, W. M., ja G. Sande. 1966. "Fast Fourier Transforms: For Fun and Profit". Teoksessä *Proceedings of the November 7-10, 1966, Fall Joint Computer Conference*, 563–578. AFIPS '66 (Fall). San Francisco, California: Association for Computing Machinery. ISBN: 9781450378932. doi:10.1145/1464291.1464352. <https://doi.org/10.1145/1464291.1464352>.
- Gregor, Shirley. 2006. "The Nature of Theory in Information Systems". *MIS Quarterly* 30 (syyskuu): 611–642. doi:10.2307/25148742.
- Gregor, Shirley, ja Alan R Hevner. 2013. "Positioning and presenting design science research for maximum impact". *MIS quarterly*: 337–355.
- Gregor, Shirley, ja David Jones. 2007. "The Anatomy of a Design Theory". *Journal of the Association for Information Systems* 8 (5): 312–335.
- Haj-Bolouri, Amir, Sandeep Puro, Matti Rossi ja Lennarth Bernhardsson. 2018. "Action Design Research in Practice: Lessons and Concerns". Kesäkuu.
- Hand, David, ja Peter Christen. 2017. "A note on using the F-measure for evaluating record linkage algorithms". *Statistics and Computing* (huhtikuu). doi:10.1007/s11222-017-9746-6.
- Hand, David, Heikki Mannila ja Padhraic Smyth. 2001. *Principles of Data Mining*. The MIT Press.
- Harris, F. J. 1978. "On the use of windows for harmonic analysis with the discrete Fourier transform". *Proceedings of the IEEE* 66 (1): 51–83.
- Hevner, Alan R. 2007. "A Three Cycle View of Design Science Research". *Scandinavian Journal of Information Systems* 19 (2): 87–92.
- Hevner, Alan, ja Samir Chatterjee. 2010. *Design Research in Information Systems: Theory and Practice*. Springer.
- Hevner, Alan, Salvatore March, Jinsoo Park ja Sudha Ram. 2004. "Design Science in Information Systems Research". *Management Information Systems Quarterly* 28, numero 1 (maaliskuu): 75–105.

- Ho, Tin Kam. 1995. "Random Decision Forests". Teoksessa *Proceedings of the Third International Conference on Document Analysis and Recognition (Volume 1) - Volume 1*, 278. ICDAR '95. USA: IEEE Computer Society. ISBN: 0818671289.
- Iivari, Juhani. 2007. "A Paradigmatic Analysis of Information Systems As a Design Science". *Scandinavian Journal of Information Systems* 19 (2): 39–64.
- Jauhiainen, Susanne, Andrew J. Pohl, Sami Äyrämö, Jukka-Pekka Kauppi ja Reed Ferber. 2020. "A hierarchical cluster analysis to determine whether injured runners exhibit similar kinematic gait patterns". *Scandinavian Journal of Medicine & Science in Sports* 30 (4): 732–740. doi:10.1111/sms.13624. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1111/sms.13624>. <https://onlinelibrary.wiley.com/doi/abs/10.1111/sms.13624>.
- Järvinen, Pertti. 2012. *On Research Methods*. Opinpajan kirja.
- Jurman, Giuseppe, Samantha Riccadonna ja Cesare Furlanello. 2012. "A Comparison of MCC and CEN Error Measures in Multi-Class Prediction". Toimittanut Giuseppe Biondi-Zoccai. *PLoS ONE* 7, numero 8 (elokuu): e41882. ISSN: 1932-6203. doi:10.1371/journal.pone.0041882. <http://dx.doi.org/10.1371/journal.pone.0041882>.
- Kantardzic, Mehmed. 2011. *Data Mining: Concepts, Models, Methods, and Algorithms*. John Wiley & Sons, Inc.
- Kohavi, Ron. 1995. "A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection", 1137–1143. Morgan Kaufmann.
- Kuechler, William, ja Vijay Vaishnavi. 2012. "A Framework for Theory Development in Design Science Research: Multiple Perspectives". *Journal of the Association of Information Systems* 13 (kesäkuu): 395–423. doi:10.17705/1jais.00300.
- Lohman, Everett B., Kanikkai Steni Balan Sackiriyas ja R. Wesley Swen. 2011. "A comparison of the spatiotemporal parameters, kinematics, and biomechanics between shod, unshod, and minimally supported running as compared to walking". *Physical Therapy in Sport* 12 (4): 151–163.

- Louppe, Gilles. 2014. "Understanding random forests: From theory to practice". *arXiv preprint arXiv:1407.7502*.
- Maimon, Oded, ja Lior Rokach. 2005. "Introduction to Supervised Methods". Teoksessa *Data Mining and Knowledge Discovery Handbook*, toimittanut Oded Maimon ja Lior Rokach, 149–164. Boston, MA: Springer US. ISBN: 978-0-387-25465-4.
- March, Salvatore, ja Gerald Smith. 1995. "Design and Natural Science Research on Information Technology". *Decision Support Systems* 15 (joulukuu): 251–266. doi:10.1016/0167-9236(94)00041-2.
- Martín, Julia, Alberto Romero Garcia ja Agustín G. Asuero. 2017. *Weighting and Transforming Data in Linear Regression*, toimittanut Vera L. Beck. Analytical Chemistry and Microchemistry. Nova Science Publishers, Inc. ISBN: 9781536119923.
- Matthews, B.W. 1975. "Comparison of the predicted and observed secondary structure of T4 phage lysozyme". *Biochimica et Biophysica Acta (BBA) - Protein Structure* 405 (2): 442–451. ISSN: 0005-2795. doi:[https://doi.org/10.1016/0005-2795\(75\)90109-9](https://doi.org/10.1016/0005-2795(75)90109-9). <http://www.sciencedirect.com/science/article/pii/0005279575901099>.
- Michele, Rocco Di, ja Franco Merni. 2014. "The concurrent effects of strike pattern and ground-contact time on running economy". *Journal of Science and Medicine in Sport* 17 (4): 414–418. ISSN: 1440-2440. doi:<https://doi.org/10.1016/j.jsams.2013.05.012>. <http://www.sciencedirect.com/science/article/pii/S1440244013001382>.
- Moore, Isabel S. 2016. "Is There an Economical Running Technique? A Review of Modifiable Biomechanical Factors Affecting Running Economy". *Sports Medicine* 46, numero 6 (kesäkuu): 793–807.
- Mullarkey, Matthew T., ja Alan R. Hevner. 2019. "An elaborated action design research process model". *European Journal of Information Systems* 28 (1): 6–20.
- Munro, Carolyn F., Doris Ida Miller ja Andrew J. Fuglevand. 1987. "Ground reaction forces in running: a reexamination." *Journal of biomechanics* 20 (2): 147–55.

Nisar, Shibli, Omar Usman Khan ja Muhammad Tariq. 2016. “An Efficient Adaptive Window Size Selection Method for Improving Spectrogram Visualization”. *Computational Intelligence and Neuroscience*.

Novacheck, Tom F. 1998. “The Biomechanics of Running”. *Gait & Posture* 7 (1): 77–95.

Oppenheim, Alan V. 2010. *Discrete-time signal processing*. 3rd ed. Toimittanut John R. Buck. Prentice-Hall.

Osis, Sean T., Blayne A. Hettinga ja Reed Ferber. 2016. “Predicting ground contact events for a continuum of gait types: An application of targeted machine learning using principal component analysis”. *Gait Posture* 46:86–90. ISSN: 0966-6362. doi:<https://doi.org/10.1016/j.gaitpost.2016.02.021>. <http://www.sciencedirect.com/science/article/pii/S096663621600062X>.

Osis, Sean T., Blayne A. Hettinga, Jessica Leitch ja Reed Ferber. 2014. “Predicting timing of foot strike during running, independent of striking technique, using principal component analysis of joint angles”. *Journal of Biomechanics* 47 (11): 2786–2789. ISSN: 0021-9290. doi:<https://doi.org/10.1016/j.jbiomech.2014.06.009>. <http://www.sciencedirect.com/science/article/pii/S0021929014003480>.

Patterson, M., D. McGrath ja B. Caulfield. 2011. “Using a tri-axial accelerometer to detect technique breakdown due to fatigue in distance runners: A preliminary perspective”. Teoksesa *Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society*, 6511–6514. Elokuu. doi:10.1109/IEMBS.2011.6091606.

Peffer, Ken, Tuure Tuunanen ja Björn Niehaves. 2018. “Design science research genres: introduction to the special issue on exemplars and criteria for applicable design science research”. *European Journal of Information Systems* 27 (2): 129–139.

Peffer, Ken, Tuure Tuunanen, Marcus A Rothenberger ja Samir Chatterjee. 2007. “A design science research methodology for information systems research”. *Journal of management information systems* 24 (3): 45–77.

- Piatetsky-Shapiro, Gregory. 1990. "Knowledge Discovery in Real Databases: A Report on the IJCAI-89 Workshop". *AI Magazine* 11, numero 4 (joulukuu): 68. doi:10.1609/aimag.v11i4.873. <https://www.aaai.org/ojs/index.php/aimagazine/article/view/873>.
- Powers, David, ja Ailab. 2011. "Evaluation: From precision, recall and F-measure to ROC, informedness, markedness correlation". *J. Mach. Learn. Technol* 2 (tammikuu): 2229–3981. doi:10.9735/2229–3981.
- Purcell, Brendan, Justin Peter Channells, Daniel James ja Rod Barrett. 2006. "Use of accelerometers for detecting foot-ground contact time during running". *Proc SPIE* (tammikuu).
- Quinlan, J. R. 1987. "Generating Production Rules from Decision Trees". Teoksessa *Proceedings of the 10th International Joint Conference on Artificial Intelligence - Volume 1*, 304–307. IJCAI'87. Milan, Italy: Morgan Kaufmann Publishers Inc.
- Rokach, Lior, ja Oded Maimon. 2005. "Decision Trees". Teoksessa *Data Mining and Knowledge Discovery Handbook*, toimittanut Oded Maimon ja Lior Rokach, 165–192. Boston, MA: Springer US. ISBN: 978-0-387-25465-4.
- Ruiter, Cornelis J. de, Ben van Oeveren, Agnieta Francke, Patrick Zijlstra ja Jaap H. van Dieen. 2016. "Running Speed Can Be Predicted from Foot Contact Time during Outdoor over Ground Running". *PLOS ONE* 11, numero 9 (syyskuu): 1–11. doi:10.1371/journal.pone.0163023. <https://doi.org/10.1371/journal.pone.0163023>.
- Santos-Concejero, J., C. Granados, J. Irazusta, I. Bidaurrezaga-Letona, J. Zabala-Lili, N. Tam ja S.M. Gil. 2013. "Differences in ground contact time explain the less efficient running economy in north african runners." *Biol Sport* (marraskuu): 181–187.
- Sein, Maung, Ola Henfridsson, Sandeep Purao, Matti Rossi ja Rikard Lindgren. 2011. "Action Design Research". *MIS Quarterly* 35 (maaliskuu): 37–56. doi:10.2307/23043488.
- Simon, Herbert Alexander. 1996. *The Sciences of the Artificial*. MIT Press.

Stickford, Abigail, Robert Chapman, Jeanne Johnston ja Joel Stager. 2014. “Lower-Leg Compression, Running Mechanics, and Economy in Trained Distance Runners”. *International journal of sports physiology and performance* 10 (kesäkuu). doi:10.1123/ijsp.2014-0003.

Sutton, Clifton D. 2005. “11 - Classification and Regression Trees, Bagging, and Boosting”. Teoksessa *Data Mining and Data Visualization*, toimittanut C.R. Rao, E.J. Wegman ja J.L. Solka, 24:303–329. Handbook of Statistics. Elsevier.

Vaidyanathan, P.P. 1987. “Chapter 2 - Design and Implementation of Digital FIR Filters”. Teoksessa *Handbook of Digital Signal Processing*, toimittanut Douglas F. Elliott, 55–172. San Diego: Academic Press. ISBN: 978-0-08-050780-4. doi:<https://doi.org/10.1016/B978-0-08-050780-4.50007-2>. <http://www.sciencedirect.com/science/article/pii/B9780080507804500072>.

Vaishnavi, V., W. Kuechler ja S. (eds.) Petter. 2004. *Design Science Research in Information Systems*. Viitattu 10. maaliskuuta 2019. <http://www.desrist.org/design-research-in-information-systems/>.

Verleysen, Michel, ja Damien François. 2005. “The Curse of Dimensionality in Data Mining and Time Series Prediction”. Teoksessa *Computational Intelligence and Bioinspired Systems*, toimittanut Joan Cabestany, Alberto Prieto ja Francisco Sandoval, 758–770. Springer Berlin Heidelberg.

Xu, J., N. Senroy, S. Suryanarayanan ja P. Ribeiro. 2006. “Some Techniques for the Analysis and Visualization of Time-varying Waveform Distortions”. Teoksessa *2006 38th North American Power Symposium*, 257–261. Syyskuu.

Zaki, Mohammed J., ja Wagner Jr. Meira. 2014. *Data Mining and Analysis. Fundamental Concepts and Algorithms*. Cambridge University Press.

Liitteet

A Koehenkilöiden tiedot

ID	Sukupuoli	Syntymävuosi	Kontaktiajan keskiarvo (ms)
01	Mies	1988	191
02	Mies	1990	211
03	Mies	1988	260
04	Mies	1964	236
05	Mies	1997	222
06	Nainen	1968	221
07	Mies	1986	256