

Data-analytiikan hyödyntäminen urheiluvammojen ehkäisyssä

TURUN YLIOPISTO
Tietotekniikan laitos
TkK-tutkielma
Tietotekniikka
Tammikuu 2025
Ilona Jäppilä

TURUN YLIOPISTO
Tietotekniikan laitos

ILONA JÄPPILÄ: Data-analytiikan hyödyntäminen urheiluvammojen ehkäisyssä

TkK-tutkielma, 22 s.
Tietotekniikka
Tammikuu 2025

Urheilu on tärkeä osa yhteiskuntaa, ja urheiluvammoilla voi olla merkittävä vaikutus urheilijan tai urheilujoukkueen suorituskykyyn ja menestykseen. Pienten marginaalien myötä urheilussa on alettu hyödyntää yhä enemmän data-analytiikkaa tulosten parantamiseen ja loukkaantumisriskin vähentämiseen. Tässä tutkielmassa tarkastellaan kirjallisuuskatsauksen muodossa, miten data-analytiikkaa ja erityisesti koneoppimismalleja sekä puettavia laitteita käytetään urheiluvammojen ehkäisyyn. Tutkielmassa käydään läpi myös datan keräämistä urheilussa.

Dataa voidaan kerätä niin urheilijan sydämen sykkeestä ja liikemalleista kuin harjoitusympäristön olosuhteistakin. Näiden avulla pystytään seuraamaan urheilijan kuormitusta, joka on yksi merkittävimmistä syistä loukkaantumisiin. Kerättyä dataa analysoidaan koneoppimismalleilla, joista yleisimpiä urheiluvammojen ehkäisyssä ovat esimerkiksi satunnaismetsä ja tukivektorikone. Näillä pystytään havaitsemaan suurimpia loukkaantumiseen johtavia riskitekijöitä. Tulokset osoittavat, että tukivektorikone on tällä hetkellä yksi tehokkaimmista ja tarkimmista koneoppimismalleista urheiluvammojen ehkäisyyn ja riskitekijöiden tunnistamiseen. Koneoppimismallien lisäksi puettavat laitteet, kuten erilaiset sensorit, ovat keskeisessä roolissa urheiluvammojen ehkäisyssä, sillä ne mahdollistavat jatkuvan ja reaaliaikaisen datankeruun urheilijan tilasta.

Asiasanat: data-analytiikka, koneoppiminen, puettavat laitteet, urheiluvammat

Sisällys

1	Johdanto	1
2	Tausta	3
2.1	Urheiluanalytiikka	3
2.2	Koneoppiminen data-analytiikassa	4
2.3	Urheiluvammat	5
3	Datan kerääminen urheilussa	7
3.1	Urheiludatan lähteet	7
3.2	Teknologiat urheiludatan keräämisessä	8
4	Urheiluvammojen ehkäisy data-analytiikalla	12
4.1	Koneoppiminen urheiluvammojen ehkäisyssä	12
4.2	Puettavat laitteet urheiluvammojen ehkäisyssä	15
4.3	Urheiluvammojen ehkäisy eri urheilulajeissa	17
5	Yhteenveto	20
	Lähdeluettelo	23

Taulukot

3.1	Urheiludatan kerääminen	11
-----	-----------------------------------	----

1 Johdanto

Urheilu perustuu usein kilpailemiseen ja toisen voittamiseen, ja voitto voi olla hyvin pienistä marginaaleista kiinni, minkä myötä tilastojen ja analytiikan käytön merkitys urheilussa on kasvanut. Näiden avulla voidaan parantaa voiton todennäköisyyttä. Data-analytiikalla voidaan esimerkiksi parantaa urheilijoiden suorituskykyä ja ehkäistä urheiluvammoja, minkä avulla voidaan saada etua vastustajaan nähden. [1] Näiden lisäksi data-analytiikkaa voidaan hyödyntää urheilussa uusien pelaajien löytämiseen, tehokkaiden harjoitussuunnitelmien laatimiseen sekä vastustajan taktiikoiden ja erityisosaamisalueiden tunnistamiseen ottelutilanteissa [2].

Urheiluvammat ovat viime aikoina yleistyneet, ja niillä on suuria vaikutuksia niin urheilijoiden terveyteen kuin urheilijoiden ja joukkueiden suorituskykyyn mutta myös urheilujoukkueiden sekä -seurojen talouteen [3]. Nämä vaikuttavat myös urheilijan tai joukkueen pärjäämiseen kilpailuissa tai peleissä. Urheiluvammojen ehkäisyä ja ennustamista pidetäänkin yhtenä tärkeimmistä urheilusuorituksiin vaikuttavista tekijöistä [4]. Tämän myötä on alettu kehittää tapoja hyödyntää data-analytiikkaa urheiluvammojen ennustamisessa ja ehkäisyssä.

Data-analytiikka mahdollistaa suurten datamäärien hallitsemisen ja analysoimisen, joka on tärkeää nykyurheilussa [2]. Koneoppimismallit ovat nousseet olennaiseksi osaksi data-analytiikkaa urheilussa, sillä ne pystyvät havaitsemaan monimutkaisiakin rakenteita datasta ja mallintamaan erilaisia ennusteita tehokkaasti. Näitä malleja pystytään hyödyntämään niin urheilijan suorituskyvyn optimoinnissa, suoritusten

parantamisessa kuin urheiluvammojen ehkäisyssä ja ennustamisessakin. [5]

Tämän tutkielman tarkoituksena on tutkia kirjallisuuskatsauksen muodossa, miten dataa kerätään urheilussa ja miten data-analytiikkaa voidaan hyödyntää urheiluvammojen ehkäisyssä. Tutkimuskysymykset ovat:

- TK1: Miten urheiludataa kerätään?
- TK2: Miten data-analytiikkaa hyödynnetään urheiluvammojen ehkäisyssä?

Tutkimuksen aineistoa on haettu Web of Science -hakutietokannasta. Joitakin aineistoja on löydetty hakutietokannasta löytyneiden aineistojen lähteistä. Hakulausekkeena käytettiin (*"data analytics" OR "sports analytics"*) AND (*sports OR athlete*) AND *injury*. Hakulauseketta täydennettiin myös hakusanoilla *"machine learning"* ja *wearables*, jolloin tutkimusaineistoa saatiin täydennettyä tähän tutkielmaan sopivilla aineistoilla. Näillä hakulausekkeilla Web of Science -hakutietokannasta löytyi yhteensä 512 eri tieteellistä aineistoa. Hakutuloksia karsittiin ensin otsikon ja tiivistelmien perusteella ja sen jälkeen vielä tarkemman analysoinnin perusteella, jolloin tutkimusaineistoksi valikoitui 10 aineistoa, joista 2 on löydetty hakulausekkeella löydettyjen aineistojen lähdeluetteloista.

Luvussa 2 käsitellään ja avataan tärkeimpiä aiheeseen liittyviä käsitteitä. Luvussa 3 keskitytään siihen, miten dataa kerätään urheilussa. Luvussa tutkitaan, millä laisista asioista dataa kerätään ja millaisia eri teknologioita datan keräämiseen käytetään. Luvussa 4 käydään läpi, miten urheiluvammoja ehkäistään data-analytiikalla. Luvussa käydään läpi erilaisia koneoppimismalleja, joita hyödynnetään urheiluvammojen ehkäisyssä. Sen lisäksi tutkitaan, miten puettavia laitteita voidaan hyödyntää, ja miten eri lajeissa data-analytiikkaa hyödynnetään urheiluvammojen ehkäisyssä. Luku 5 sisältää vastaukset tutkimuskysymyksiin, yhteenvedon tutkielman tuloksista sekä pohdintaa.

2 Tausta

2.1 Urheiluanalytiikka

Urheiluanalytiikka (engl. *Sports Analytics*) on alana herättänyt kiinnostusta varsinkin viime aikoina [6], mutta sillä on kuitenkin myös pitkä historia. Ala sai alkunsa jo 1960-luvulla Yhdysvalloissa, jolloin amerikkalaista jalkapalloa ja koripalloa analysoitiin koodattujen muistiinpanojen avulla. Aivan ensimmäisen kerran analytiikkaa on kuitenkin yritetty käyttää urheilussa jo 1950-luvulla, kun Englannissa Charles Reep alkoi analysoida manuaalisesti maaliin johtaneiden syöttöjen määrää jalkapallopeleissä. [7]

Urheiluanalytiikalla tarkoitetaan urheiluun liittyvään päätöksentekoon käytettävää tiedonkeruuta ja -hallintaa, ennakoivaa mallintamista ja laskennallisia menetelmiä. Se on tieteenala, jossa kerätään ja analysoidaan urheiludataa erilaisilla menetelmillä, joiden myötä voidaan luoda ennusteita tai tehdä päätöksiä. [8] Myös koneoppimismenetelmät ja -sovellukset ovat tärkeä osa urheiluanalytiikkaa, sillä niiden avulla voidaan tehdä hyödyllisiä johtopäätöksiä [6].

Yleisesti polku urheiluanalytiikassa koostuu ensin datan keräämisestä, jossa käytetään monia eri lähteitä, niin kvantitatiivista kuin kvalitatiivistakin dataa. Sen jälkeen tapahtuu tiedonhallinta, jossa data esimerkiksi standardoidaan ja keskitetään, ja seuraavaksi tapahtuu varsinainen data-analyysi. Data-analyysin pohjalta esimerkiksi pelaajat ja valmentajat pystyvät tekemään päätöksiä. [7]

Urheiluanalytiikan avulla voidaan parantaa ymmärrystä fyysisestä suorituskyvystä, toiminnallisista liikkeistä, harjoittelun kuormituksesta ja väsymyksestä. Näiden avulla voidaan parantaa harjoittelua, jolloin saadaan maksimoitua suorituskkyä ja minimoitua väsymystä ja loukkaantumisia. Tällöin voidaan parantaa voittomahdollisuuksia mutta myös saada parempaa ymmärrystä urheiluvammoista ja niiden ehkäisystä, jolloin saadaan lisäetua pelikentälle datalähtöisen urheiluvammojen ehkäisystrategian kautta. Mittareina voidaan käyttää esimerkiksi vapaaheittojen onnistumisprosenttia, juostua matkaa tai fyysisen suorituskvyn mittareita. [1] Datan lähteitä ovat biometrinen data, videot, aiemmat potilastiedot, sijainnin seurantatiedot kentältä tai reitiltä, säätiedot ja yleisön käyttäytyminen. [9]

2.2 Koneoppiminen data-analytiikassa

Koneoppiminen on yksi tekoälyn osa-alueista, jossa järjestelmä oppii datan avulla. Tämän ansiosta se voi optimoida omaa järjestelmäänsä ilman ihmisen jatkuvaa ohjausta. [10] Koneoppiminen on keskeinen osa data-analytiikkaa, varsinkin suurten tietomäärien analysoinnissa. Sen avulla pystytään löytämään malleja, tuottamaan ennusteita ja tekemään päätöksiä. [11] Koneoppiminen voidaan jakaa ohjattuun oppimiseen, ohjaamattomaan oppimiseen ja vahvistusoppimiseen [12].

Ohjattu oppiminen tarkoittaa menetelmää, jossa mallia opetetaan hyödyntämällä harjoitusaineistoa, joka sisältää sekä syöte- että kohdearvot [12]. Ohjattuun oppimiseen kuuluu monia erilaisia luokittelumalleja, kuten päätöspuu (engl. *Decision Tree*) ja tukivektorikone (engl. *Support Vector Machine, SVM*), joita käytetään myös urheiluvammojen ehkäisyssä [10]. Ohjaamaton oppiminen on menetelmä, jossa mallia opetetaan ilman valmiiksi määriteltyjä syöte-kohde pareja. Tavoitteena on löytää aineistosta malleja tai kaavoja ilman ulkoista ohjausta. Vahvistusoppiminen tarkoittaa koneoppimisen menetelmää, jossa kuvataan järjestelmän nykytilaa ja annetaan jokin tavoite, johon pyritään. Malli tutkii ympäristöä ja pyrkii pääsemään tavoit-

teeseen yrityksen ja erehdyksen kautta saaden positiivista ja negatiivista palautetta valintojensa perusteella. [12]

Koneoppiminen on tuonut uusia mahdollisuuksia urheiluvammojen ennustamiseen, sillä koneoppimisalgoritmit pystyvät käsittelemään monimutkaista ja epälineaarista dataa perinteisiä tilastollisia menetelmiä tehokkaammin. Tarkoituksena on tunnistaa datasta malleja, jotka voivat ennustaa loukkaantumisriskiä. [5]

2.3 Urheiluvammat

Urheiluvamma on yleensä fyysinen vamma, joka syntyy urheilun tai muun fyysisen toiminnan yhteydessä. Yleisimpiä ovat tuki- ja liikuntaelimestöön, kuten lihaksiin, niveliin ja luihin, kohdistuvat urheiluvammat. Urheiluvammoja voi kuitenkin olla myös hermostossa esimerkiksi aivotärähdysten ja selkäydinvammojen muodossa, sydän- ja verisuonielimistöissä tai muissa kehon järjestelmissä. [13]

Urheiluvammat ovat urheilun tasosta riippumattomia, sillä niitä esiintyy kaikilla eri tasoilla, niin lapsilla kuin aikuisilla, harrastelijoista ammattiuurheilijoihin [3]. Ne ovat yleisiä sekä yksilö- että joukkueurheilussa, ja niillä voi olla fyysisiä, psykososiaalisia sekä taloudellisia vaikutuksia [14]. Urheilumaailmassa urheilijan loukkaantumiset ovat suuri huolenaihe, sillä ne voivat heikentää merkittävästi suorituskykyä tai pahimmassa tapauksessa katkaista koko urheilu-uran [15]. Ammattiuurheilussa vaikutus voi olla suuri koko joukkueen suoritukseen ja urheiluorganisaatioon. Urheiluvamma voi aiheuttaa myös psyykkisen hyvinvoinnin heikkenemistä, joka voi vaikuttaa itsetuntoon fyysisen suorituskyvyn lisäksi. [3]

Urheiluvammojen ehkäisyssä keskeistä on ymmärtää vammojen riskitekijät ja niiden yhteisvaikutus [14]. Riskitekijät voidaan jakaa ulkoisiin ja sisäisiin tekijöihin ja niiden sisällä tekijät voidaan yleensä luokitella muokattaviksi ja ei-muokattaviksi tekijöiksi. Muokattavat tekijät tarkoittavat sellaisia, joihin voidaan vaikuttaa ja ei-muokattavat tekijät ovat sellaisia, joihin ei voida itse vaikuttaa. Ulkoisiin ei-

muokattaviin tekijöihin voidaan lukea esimerkiksi urheilulaji, urheilun taso ja sää. Ulkoisia muokattavia tekijöitä ovat välineet, säännöt ja alusta, jolla pelataan. Sisäisiin ei-muokattaviin tekijöihin voidaan taas lukea esimerkiksi ikä, aikaisemmat loukkaantumiset ja sukupuoli. Sisäisiin muokattaviin tekijöihin lukeutuu liikkuvuus, koordinaatio ja voimatasot. [3]

Näiden lisäksi riskitekijöitä ovat esimerkiksi myös psykologiset tekijät, venyttelyn ja lämmittelyn puute, kuormituksen määrä ja uupumus. [3] Loukkaantuminen voi kuitenkin tapahtua hyvin arvaamattomasti esimerkiksi kontaktista toiseen pelaajaan tai ulkoisten ja sisäisten riskitekijöiden yhteisvaikutuksesta, mikä tekee loukkaantumisen ennustamisesta haastavaa [14].

Nykypäivänä ammattiurheilun parissa on kehitetty erilaisia ratkaisuja, joilla voitaisiin parantaa ymmärrystä urheiluvammoista ja tehostaa niiden ehkäisyä. Erityisesti urheiluanalytiikka, datatiede (engl. *Data Science*), koneoppiminen ja tiedonlouhinta (engl. *Data Mining*) ovat oleellisena osana urheiluvammojen ehkäisyä nykypäivänä. [15]

3 Datan kerääminen urheilussa

3.1 Urheiludatan lähteet

Dataa voidaan kerätä urheilussa niin kentällä, peleissä ja harjoituksissa (on-field) kuin kentän ulkopuolellakin (off-field). Kun nämä kummatkin yhdistetään, voidaan saada yksityiskohtaisempaa ymmärrystä urheilijasta kokonaisuutena [16].

Harjoitusten aikana voidaan seurata reaaliaikaisesti esimerkiksi urheilijan sykettä, liikemalleja ja askelmäärää. Nämä mittarit antavat yksityiskohtaista tietoa urheilijan fyysisestä kunnosta ja mahdollistavat uupumuksen ja stressin merkkien tunnistamisen ajoissa. [5] Harjoituksissa ja peleissä dataa voidaan kerätä myös ympäristöstä, esimerkiksi lämpötilasta, ilmanpaineesta ja tuulesta, sillä näilläkin tekijöillä voi olla vaikutusta urheilijan suorituskykyyn. [4]

Peleissä dataa voidaan kerätä tehdyistä maaleista, pelin aikana juostusta matkasta tai tietyn pelaajan pelaamista minuuteista. Videoiden avulla voidaan saada dataa taktiikasta tai esimerkiksi jalkapallossa videodataa käytetään pelitilanteiden tulkitsemiseen, kun tuomari ei ole varma tilanteesta, esimerkiksi paitsioissa tai käsivirheissä. [7] Peleissä tai harjoituksissa kamerakuvan avulla voidaan seurata urheilijoiden liikkeitä. Tämän avulla voidaan saada tietoa urheilijan ulkoisesta kuormituksesta. [17]

Suurin osa urheilijan ajasta kuluu harjoitusten ulkopuolella, joten on tärkeää kiinnittää huomiota myös siihen, mitä silloin tapahtuu. Varsinkin uni ja sen laatu

ovat keskeisessä roolissa palautumisessa. Unesta voidaan kerätä dataa esimerkiksi puettavilla laitteilla (engl. *Wearable Devices*), jolloin voidaan saada tietoa unen laadusta, kuten kestosta, tehokkuudesta ja heräämisistä yön aikana. [16] Nämä tiedot ovat tärkeitä urheilijan kuormituksen määrän seuraamisessa. Unen laatu kertoo myös urheilijan valmiudesta päivän harjoitukseen tai peliin, jolloin voidaan säädellä harjoituksen sisältöä valmiuden mukaan, sillä väsyneenä harjoittelu suurentaa riskiä loukkaantumisiin.

Harjoitusten ulkopuolista dataa voivat olla myös urheilijan terveystiedot. Dataa voidaan kerätä urheiluvamman tyypistä, toipumisajoista ja hoidosta. [5] Tärkeitä tietoja voivat olla myös esimerkiksi tiedot urheilijan mielentilasta, stressin määrästä, kiputiloista tai lihasjumeista. Näistä voidaan saada tietoa urheilijan itse tekemistä itsearvioinneista tai harjoituspäiväkirjoista. [16]

3.2 Teknologiat urheiludatan keräämisessä

Urheilussa datan keräämiseen voidaan käyttää monia erilaisia teknologioita. Erilaisia datankeruu- ja analysointimenetelmiä ovat esimerkiksi havainnointianalyysi, videoanalyysi, notaatioanalyysi, aika-liikeanalyysi ja urheiluvammojen ehkäisyssä tärkein teknologia eli puettavista laitteista saatavan datan data-analyysi. [18]

Havainnointianalyysi tarkoittaa datan keräämistä, dokumentoimista ja arviointia suoraan seuraamalla urheilijoiden suorituksia. Videoanalyysissä voidaan videoida otteluita tai harjoituksia, jolloin voidaan arvioida esimerkiksi urheilijan suoritustekniikkaa, pelaajan liikkumista tai urheilujoukkueen taktiikkaa pelissä. Notaatioanalyysissä ottelun tai harjoituksen aikana tapahtuvat yksittäiset suoritukset kirjataan ylös. Jokaisella suorituksella on oma koodinsa, jolloin suorituskyky voidaan tallentaa määrällisesti ja data tarjoaa objektiivisen kuvan suorituksesta. Aika-liikeanalyysi tarkoittaa menetelmää, jossa tallennetaan ja luokitellaan urheilijan jokainen liike ottelun tai harjoituksen aikana. Tämän avulla saadaan tietoa

kuormituksen jakautumisesta ja intensiteetistä, jonka myötä voidaan parantaa harjoittelua ja palautumista. [18]

Datan keräämiseen voidaan käyttää myös urheilijoiden itsearviointeja. Nämä perustuvat kyselyihin, joissa kartoitetaan urheilijan subjektiivista kokemusta omasta hyvinvoinnistaan. Mittareina käytetään esimerkiksi koettua stressiä tai väsymystä, lihaskipuja, energiatasoa ja mielentilaa. [16] Subjektiivisuuden vuoksi nämä mittarit eivät kuitenkaan ole välttämättä aina kovin luotettavia, mutta ne voivat antaa suuntaa tulevaa harjoitusta tai ottelua varten.

Yleisin datan keräämiseen käytetty teknologia urheiluvammojen ehkäisyyn tähtäävässä data-analyysissä on puettavat teknologiat. Puettavilla esineiden internet (engl. *Internet of Things*, IoT) -sensoreilla ja -laitteilla, kuten GPS-seurantalaitteilla, kiihtyvyydsmittareilla, sykemittareilla, ympäristösensoreilla ja biomekaanisilla sensoreilla voidaan kerätä dataa [19]. Puettavien laitteiden avulla voidaan saada dataa urheilijoista reaaliaikaisesti harjoituksissa tai kilpailuissa [5]. Laitteita voidaan sijoittaa eri alueille kehoa, kuten esimerkiksi pään alueelle, silmiin, ylävartalon alueelle tai jalkoihin [17]. Laitteet voivat olla urheilijan pukemia rannekelloja tai sykevöitä, mutta ne voidaan myös integroida vaatteisiin, kuten paitaan, kypärään tai kenkiin [19]. Tärkeää on, etteivät laitteet häiritse urheilijaa tai vaikuta suorituskykyyn [4].

Urheilijan sisäistä ja ulkoista kuormitusta voidaan tarkkailla puettavien sensoreiden avulla, mikä auttaa ehkäisemään loukkaantumisia [20]. Yksi suosituimpia sensoreita liikkeentunnistukseen on inertia-anturi (engl. *Inertial Measurement Unit*, IMU). Inertia-anturi voi sisältää kiihtyvyydsmittareita, gyroskooppeja ja magnetometrejä. Kiihtyvyydsmittarit mittaavat kohteeseen vaikuttavien voimien aiheuttamia kiihtyvyyden muutoksia. Gyroskoopit mittaavat puolestaan kulmakierron määrää, eli esimerkiksi jalkapalloilijan vartalon kiertoa nopean suunnanmuutoksen aikana. Magnetometrit mittaavat ympäristön magneettikenttää, ja sitä käytetään suurimmaksi osaksi tukisensorina kiihtyvyydsmittarille ja gyroskoopille, jolloin se auttaa

määrittämään liikkeen suunnan ja suuruuden. [4] Usein nämä sensorit on integroitu puettaviin laitteisiin, kuten älykelloihin tai älypuhelimiin. Inertia-antureita voidaan soveltaa moniin eri tarkoituksiin, kuten esimerkiksi urheilijan suorituskyvyn arvioimiseen ja harjoittelun optimointiin. [10]

Toinen yleisesti käytetty sensori on elektrokardiografia-anturi (EKG), joka mittaa sydämen sykettä elektrodeilla, jotka tallentavat sydämen sähköisiä signaaleja. EKG-antureilla voidaan seurata sydämen toimintaa reaaliaikaisesti ja usein esimerkiksi älykellot, älysormukset ja unen seuraamisen laitteet, joilla voidaan mitata sykettä, sisältävät EKG-antureita. [10]

GPS-laitteet ovat yksi yleisimpiä laitteita kuormituksen ja harjoittelun mittaamiseen, sillä niillä on mahdollista mitata monia eri asioita, kuten urheilijan sykettä ja juostua matkaa [1]. Ne perustuvat satelliittien toimittamaan signaaliin, jolloin voidaan paikantaa urheilijan sijainti ja seurata sitä. Sisälajeissa, kun satelliittiyhteys saattaa olla heikko, voidaan käyttää LPS-laitteita (Local Positioning System), jotka ovat verrattavissa GPS-laitteisiin. Tällöin satelliitit korvataan paikallisesti asennetuilla antennilla. [21]

Ympäristösensoreilla voidaan mitata ympäristöstä esimerkiksi UV-säteilyä, ilmanlaatua, lämpötilaa, säätä ja ilmanpainetta. Niitä käytetään havainnoimaan ympäristöä, jossa urheillaan, ja sitä, miten ympäristö vaikuttaa urheilijaan. Esimerkiksi ilmanlaadun mittareilla, voidaan havainnoida ilmanlaadun vaikutusta urheilijan hengityselimistöön harjoituksen aikana, tai UV-mittareilla voidaan mitata urheilijan altistumista UV-valolle. [4] Nämä voivat vaikuttaa urheilijan suorituskykyyn, esimerkiksi huono ilmanlaatu tai allergeenit ilmassa, voivat laskea urheilijan suorituskykyä rasittamalla hengitystie-elimistöä. Ympäristöllä voi olla merkittävä vaikutus myös loukkaantumisiin. Esimerkiksi sateen vuoksi kentän pinta voi muuttua liukkaaksi, mikä lisää liukastumisriskiä ja saattaa johtaa loukkaantumisiin.

Kehon ulkopuolisiin teknologioihin kuuluu monikamerajärjestelmä, jossa useita

kameroita sijoitetaan eri kulmiin esimerkiksi urheilustadionille. Tällä teknologialla pystytään seuraamaan urheilijan liikkeitä harjoitusten tai pelin aikana. Nykyään kuitenkin GPS-laitteet ovat korvanneet kamerajärjestelmiä, halvemmän hinnan ja helpomman käytön takia. [17]

Taulukko 3.1: Urheiludatan kerääminen

Kerättävä data	Kentän ulkopuolella	Kentällä	Käytettävä teknologia
syke	x	x	puettavat laitteet (esim. sykemittari)
liikemallit		x	liikeanturit ja videoanalyysi
kuormitus	x	x	puettavat laitteet (esim. GPS-laitteet)
uni	x		puettavat laitteet
terveystiedot (koettu)	x		itsearviointi, kyselyt
terveystiedot (historia)	x		vanhojen terveystietojen analysointi
maalien määrä		x	videodata, havainnointianalyysi
pelitaktiikka		x	videoanalyysi
olosuhteet		x	ympäristösensorit

Tärkeää on myös kerätyn datan visualisointi, jotta urheilijoiden ja valmentajien kuin myös ulkopuolisten henkilöiden, kuten katsojan, on helppo ymmärtää dataa. Visualisointeja voidaan tehdä esimerkiksi otteludatasta, pelaajista tai taloudesta. Urheiluvammojen ehkäisyyn liittyvää seurantadataa voidaan visualisoida monin eri tavoin. Datasta voidaan tehdä esimerkiksi piste- tai lämpökarttoja, joissa visualisoidaan pelin tapahtumia, kuten syöttöjä, laukauksia ja pelaajien liikkumista. [22]

4 Urheiluvammojen ehkäisy data-analytiikalla

4.1 Koneoppiminen urheiluvammojen ehkäisyssä

Koneoppimista voidaan käyttää urheiluvammojen ehkäisyyn. Koneoppimismallit pystyvät tunnistamaan datasta malleja ja tarjoamaan ennustettavuutta, ja näin ollen, ne pystyvät antamaan ajoissa varoituksia loukkaantumisriskistä. [19] Tällöin urheilija pystyy ennakoimaan mahdollisia loukkaantumisia ja muuttamaan harjoitteluaan tai toimintaansa, kuten esimerkiksi vähentämään harjoituskuormitusta tai muuttamaan suoritustekniikkaansa. Koneoppiminen on tuonut uusia mahdollisuuksia urheiluvammojen ennustamiseen. Perinteisten mallien sijaan koneoppimisalgoritmit eivät ole lineaarisia suhteita, vaan ne pystyvät käsittelemään monimutkaista ja epälineaarista dataa tehokkaammin [5].

Ennen koneoppimismallien käyttöä, dataa täytyy usein käsitellä jollain tavalla. Datan esikäsitteleminen on tärkeää, jotta käytettävä data on puhdasta, johdonmukaista ja se sopii mallinnettavaksi. Tässä vaiheessa tunnistetaan virheet ja poistetaan ne, käsitellään puuttuvat arvot, normalisoidaan tiedot ja poimitaan datasta ne mittarit, joita tarvitaan. [5] Tarvittavat mittarit voidaan eritellä datasta esimerkiksi erilaisilla ohjelmistoilla [23]. Puuttavien laitteiden käyttö datan keruussa edellyttää erityistä huomiota, sillä sensoreiden liikkuminen tai laitteen virheellinen asettelu voi vääristää

tuloksia. Tällaisissa tapauksissa kerättyä dataa voidaan joutua käsittelemään tai korjaamaan tarkkuuden varmistamiseksi. [24]

Koneoppimismalli SVM:n käyttö on yleistä, kun halutaan ehkäistä urheiluvammoja ja ennustaa niitä. Lin [5] tutkimuksen tulosten mukaan, kun SVM-mallia yhdistetään massadata-analyysiin (engl. *Big Data analysis*), niin se on tehokkaampi ennustamaan urheiluvammoja kuin muut koneoppimismallit, kuten satunnaismetsä (engl. *Random Forest*) tai neuroverkot (engl. *neural network*, ANN). Renin ym. [25] tutkimus vahvistaa väitettä, että SVM-malli suoriutuu hyvin urheiluvammojen ennustamisesta ja se tarjoaa hyviä tuloksia verrattuna muihin malleihin. SVM on koneoppimisalgoritmi, jolla pystytään analysoimaan niin yksinkertaista kuin monimutkaista ja epälineaaristakin dataa. Sen avulla voidaan tunnistaa loukkaantumisriskiä nostavia tekijöitä ja luokitella urheilijat niihin, joilla on korkeampi riski loukkaantua ja niihin, joilla riski on matala. [5] Mallia koulutetaan suurella määrällä dataa, jolloin se oppii tunnistamaan malleja ja toistuvuuksia, minkä myötä se pystyy luomaan ennustuksia.

Lin [5] tutkimuksessa keskityttiin suurin datamääriin ja siinä yhdistettiinkin tukivektorikonetta massadata-analyysiin. Dataa kerättiin tutkimuksessa suurissa määrin suorituskyvystä, potilastiedoista ja puettavista sensoreista. Data sisälsi historia-tietoja esimerkiksi aiemmista loukkaantumisista ja palautumisajoista. Nämä tiedot yhdistettiin ja puhdistettiin, minkä jälkeen SVM-malli koulutettiin tunnistamaan loukkaantumiseen liittyviä kuvioita ja luokiteltiin urheilijat niihin, joilla on suuri vammariski ja niihin, joilla vammariski on pieni. Tutkimuksen tuloksena SVM-mallin tarkkuus oli 92.3 % ja ennustetaso 87.5 %. Tämä osoittaa mallin merkittävän kyvyn ennustaa loukkaantumisia tehokkaasti.

Renin ym. [25] tutkimuksessa taas keskityttiin reaaliaikaiseen seurantaan, ja siinä on käytetty videodataa liikeratojen seuraamiseen ja analysointiin sekä sensoridataa, joka sisälsi tietoja esimerkiksi sydämen sykkeestä ja urheilijan fyysisestä tilasta.

Mallia testattiin monissa urheilulajeissa, juoksussa, aerobicissa sekä pöytätenniksessä. Näistä lajeista juoksussa se antoi parhaat tulokset, jossa mallin ennustetarkkuus oli jopa 96.28 %. Mallin keskimääräinen ennustetarkkuus oli 92.5 %, joka on lähellä Lin [5] tutkimuksessa saatua tulosta. Molemmissa tutkimuksissa saatiin siis korkea tarkkuus, mikä kertoo, että SVM-malli on tehokas urheiluvammojen ehkäisyssä ja ennustamisessa. Dataa kerätään SVM-mallia käytettäessä monista erilaisista lähteistä, kuten sensori- tai videodatasta tai suorituskykytiedoista. Tällöin saadaan rakennettua kattava loukkaantumisriskimalli.

Toinen yleinen urheiluvammojen ehkäisyssä käytetty koneoppimismalli on satunnaismetsä. Se on epälineaarinen luokittelu- ja regressiomethodi, joka hyödyntää päätöspuista koostuvaa rakennetta. Se on yleisesti käytetty malli lääketieteessä ja bioinformatiikassa sekä urheiluvammojen tutkimuksessa. Urheiluvammojen ehkäisyyn satunnaismetsä sopii hyvin, sillä se kykenee analysoimaan suuria ja monimutkaisia aineistoja ja tunnistamaan riskitekijöitä, jotka ovat epälineaarisia. Se auttaa saamaan luotettavamman mallin vammojen ennustamiselle. [26] Satunnaismetsän käyttö edellyttää laajaa ja monipuolista datamäärää, jonka saatavuus voi olla haaste, jolloin tarkkojen ja luotettavien tulosten saavuttaminen voi olla haastavaa [27].

Jauhaisen ym. [26] tutkimuksessa käytettiin satunnaismetsää urheiluvammojen riskitekijöiden havaitsemiseen erityisesti nuorilla urheilijoilla. Satunnaismetsän avulla löydettiin kaksitoista eri tekijää, jotka voivat vaikuttaa loukkaantumisriskiin. Näitä olivat esimerkiksi sukupuoli, pituus ja takareisien liikkuvuus. Dataa kerättiin tässä tutkimuksessa fyysisillä testeillä, joissa mitattiin esimerkiksi ponnistusvoimaa, liikkuvuutta ja lihasvoimaa. Näiden lisäksi huomioon otettiin myös muita urheilijan tietoja, kuten paino sekä pituus. Tämän tutkimuksen mallin ennustetarkkuus oli vain 65 %, joka on huomattavasti matalampi tulos kuin SVM-mallin ennustetarkkuus. Pienestä ennustetarkkuudesta huolimatta, malli pystyi kuitenkin havaitsemaan urheiluvammoihin johtavia riskitekijöitä. Pieni ennustetarkkuus osoittaa myös

urheiluvammojen ennustamisen haastavuutta.

Tämän perusteella koneoppimismallit ovat osoittautuneet lupaavaksi tavaksi ennustaa ja ehkäistä urheiluvammoja. Mallien tehokkuus riippuu kuitenkin paljon myös kerätyn datan laadusta sekä määrästä. Datan saaminen ja kerääminen voi olla välillä haastavaa, sillä dataa on harvoin avoimesti saatavilla urheilijoista.

4.2 Puettavat laitteet urheiluvammojen ehkäisyssä

Qin ym. [28] tekemän kyselytutkimuksen mukaan urheiluorganisaatiot kokevat puettavien laitteiden olevan suurin tekijä urheiluvammojen vähentämisessä. Puettavat laitteet ovat yleistyneet merkittävästi viime vuosien aikana, niin jokapäiväisessä elämässä kuin urheilussakin. Puettavista laitteista saatava reaaliaikainen data onkin ollut merkittävä kehitysaskel urheilussa. [4] Usein näistä puettavista laitteista saatava data analysoidaan esimerkiksi luvussa 4.1 esitellyillä koneoppimismalleilla [10].

Puettavilla laitteilla pystytään seuraamaan urheilijan liikkeitä ja huomaamaan potentiaalisia riskejä loukkaantumiseen. Laitteissa olevat sensorit pystyvät tarkkailemaan esimerkiksi nivelkulmia, lihasten aktiivisuutta ja tasapainoa. Näiden perusteella pystytään tunnistamaan kehon alueita, joilla on riski urheiluvammaan. Laitteista saatavan datan käsittelyyn ja analysointiin voidaan käyttää myös tekoälyalgoritmeja, jotka pystyvät ennustamaan loukkaantumisia tai riskejä niihin ja antamaan suosituksia urheiluvammojen ehkäisyyn. [28]

Puettavat laitteet mahdollistavat urheilijan reaaliaikaisen seuraamisen harjoituksissa tai ottelussa. Tällöin saadaan reaaliaikaisesti palautetta urheilijan tekniikasta ja mahdolliseen väärään suoritustekniikkaan pystytään puuttamaan heti. [28] Tämän myötä pystytään ehkäisemään loukkaantumisia, jotka johtuvat väärästä tekniikasta. Esimerkiksi lentopallossa ja baseballissa, joissa yläraajojen rasituksesta johtuvat vammat ovat yleisiä, on käytetty käsivarsiin kiinnitettäviä sensoreita, joilla on pystytty luokittelemaan olkanivelen liikkeitä suhteellisen tarkasti [4].

Kuormitusta voidaan seurata reaaliaikaisesti, ja koska se on yksi merkittävimmistä loukkaantumisriskiä lisäävistä tekijöistä, puettavat laitteet ovat keskeisessä roolissa sen seurannassa. Puettavilla laitteilla valmentajat ja lääkärit pystyvät seuraamaan urheilijan ulkoista ja sisäistä kuormitusta, sekä niiden muutoksia reaaliaikaisesti, mikä mahdollistaa loukkaantumisriskin vähentämisen sekä suorituskyvyn optimoinnin. Sisäistä kuormitusta voidaan seurata puettavilla laitteilla mittaamalla esimerkiksi sydämen räsitystä, veren laktaattipitoisuutta ja hapenkulutusta. Ulkoisen kuormituksen seurantaan voidaan puolestaan käyttää puettavia laitteita mittaamaan esimerkiksi nopeutta, kuljettua matkaa ja kiihtyvyyttä. Esimerkiksi puettavia laitteita, jotka käyttävät maailmanlaajuista satelliittipaikannusjärjestelmää (engl. *Global Navigation Satellite System*, GNSS) ja kolmiakselisia kiihtyvyyssmittareita, voidaan käyttää reaaliaikaisen ulkoisen kuormituksen seuraamiseen. [4]

Esimerkkinä puettavasta laitteesta, jota on käytetty urheiluvammojen ehkäisyyn, on Zephyr Bioharness, joka kiinnitetään rintakehälle. Laite sisältää kolmiakselisen kiihtyvyyssanturin, jonka avulla voidaan mitata kehon liikkeen kiihtyvyyttä, analysoida iskujen ja liikkeen voimakkuutta sekä arvioida urheilijan tekniikkaa ja kuormitusta harjoittelun aikana. Muuttujat antavat tärkeää dataa valmentajalle harjoituksen tai ottelun aikana, jolloin valmentaja pystyy arvioimaan tapahtuvien iskujen ja kuormituksen vakavuutta. [24] Laitteet siis tukevat ja helpottavat valmentajien työtä ja ne auttavat tekemään päätöksiä. Tulevaisuudessa puettavat laitteet ottavat kehittyessään mahdollisesti vielä enemmän roolia valmennuksessa, mikä saattaa vähentää valmentajan työn kuormitusta. Valmentajan rooli pysyy silti tärkeänä, sillä hän vastaa päätöksenteosta ja urheilijoiden yksilöllisten tarpeiden huomioimisesta, vaikka puettavat laitteet ja data-analytiikka antavatkin niihin tärkeää tukea.

Vaikka puettavien laitteiden käyttö on tehokasta ja niillä saadaan kerättyä hyödyllistä dataa, niin niiden käyttö tuo myös haasteita. Laitteet voivat maksaa paljonkin, jolloin kaikilla ei välttämättä ole mahdollisuutta hankkia niitä. Nykyään voidaan

puhua jopa teknologisesta dopingista, joka viittaa etuihin, joita teknologiasta voidaan urheilun parissa saada [4]. Puettavilla laitteilla voidaan saada merkittävää etua harjoittelun optimointiin, suorituskyvyn parantamiseen ja loukkaantumisten ehkäisyyn, jolloin laitteiden omistamisella voi olla suuri merkitys menestykseen.

4.3 Urheiluvammojen ehkäisy eri urheilulajeissa

Jalkapalloa pidetään edelläkävijänä urheiluvammojen ennustamisessa seuranta- ja valvontateknologioilla. Kansainvälinen jalkapalloliitto (FIFA) olikin yksi ensimmäisistä urheiluliitoista, joka salli puettavien laitteiden käytön kansainvälisissä peleissä. [4] Muut lajit, kuten koripallo ja amerikkalainen jalkapallo ovat kuitenkin seuranneet perässä, sillä urheiluvammoilla on niin suuri merkitys urheilijaan ja koko joukkueeseen, varsinkin pidemmällä aikavälillä [27]. Eri urheilulajeissa tyypilliset urheiluvammat ovat erilaisia, jolloin eri urheilulajien välillä on myös eroja niiden ehkäisyssä. Monissa lajeissa on kuitenkin myös yhtäläisyyksiä ja perusta urheiluvammojen ehkäisyyn on samanlainen. Tässä luvussa keskitytään siihen, miten eri urheilulajeissa urheiluvammoja ehkäistään.

Joukkuelajeissa puettavien laitteiden käyttö on yleistä, sillä niillä voidaan seurata pelaajien ja joukkueiden suoritusta ja parantaa taktiikkaa, mutta niillä voidaan myös ehkäistä urheiluvammoja [4]. Esimerkiksi jalkapallossa GPS-laitteet ovat suosittuja. Rossin ym. [23] tutkimuksessa tutkittiin loukkaantumisten ehkäisyä GPS-teknologian ja koneoppimismallien yhdistämisellä. GPS-laitteilla mitattiin pelaajien fyysistä kuormitusta harjoituksissa ja otteluissa, keräten dataa esimerkiksi pelaajan liikkeistä, nopeudesta, kiihdytyksistä ja juostusta matkasta. Nämä tiedot yhdistettiin pelaajista kerättyjen muiden tietojen, kuten iän ja pelattujen pelien määrän kanssa ja sitten kaikki data analysoitiin koneoppimismallilla. Tutkimuksessa vertailtiin päätöspuuta ja satunnaismetsää, ja tässä tapauksessa päätöspuu antoi parhaat tulokset. Tällä menetelmällä pystyttiin vähentämään vääriä hälytyksiä, eli tilanteita,

tasoa. Uupumuksen tasoa on seurattu juoksijoilla puettavilla IoT-sensoreilla, kuten GPS-laitteilla ja sykemittareilla. Näillä on saatu dataa esimerkiksi sykevälivaihtelusta ja unitottumuksista. Dataa on analysoitu tekoälyalgoritmeilla, jotka ovat ottaneet huomioon reaaliaikaisen datan ja historiatiedot, jolloin ne pystyivät arvioimaan urheilijan uupumustason ja antamaan urheilijalle suosituksia harjoitusten intensiteetin ja lepoajan muutoksista. Tällä IoT-laitteiden ja tekoälyn yhdistelmällä on pystytty onnistuneesti ennustamaan uupumustasoja, ja ylikuormitusvammoja on saatu vähennettyä ja suorituskykyä parannettua. [19]

Kuten aiemminkin on jo todettu, kuormitus nousee eri lajeissa suurimmaksi syyksi loukkaantumisiin, minkä vuoksi urheiluvammojen ehkäisy perustuu usein kuormituksen seuraamiseen ja hallintaan. Vaikka lajit saattavat olla hyvinkin erilaisia keskenään, niin puettavat laitteet, erityisesti GPS-laitteet, nousevat esiin, kun tarkastellaan urheiluvammojen ehkäisyä data-analytiikalla.

5 Yhteenveto

Tutkielmassa tarkasteltiin data-analytiikan käyttöä urheilussa, erityisesti, miten urheiluvammoja voidaan ehkäistä data-analytiikalla. Tämä luku sisältää vastaukset tutkimuskysymyksiin, pohdintaa, jatkotutkimus- sekä kehitysmahdollisuuksia tulevaisuuteen.

Tutkimuskysymys 1: Miten urheiludataa kerätään? Urheiludataa kerätään monilla eri teknologioilla. Dataa voidaan kerätä urheilussa lähes kaikesta mahdollisesta, kuten juostusta matkasta, syöttöjen määrästä, sydämen sykkeestä tai harjoitusympäristöstä. Erilaisten puettavien sensorien ja laitteiden käyttö on kaikista yleisin tapa kerätä dataa urheilussa. Näitä sensoreita ja laitteita voi olla esimerkiksi sykemitareissa, älykelloissa tai -sormuksissa. Puettavat laitteet tarjoavat mahdollisuuden reaaliaikaiseen dataan, joka mahdollistaa urheilijoiden seuraamisen reaaliaikaisesti pelissä tai harjoituksissa. Puettavien laitteiden lisäksi käytetään paljon muitakin tekniikoita ja teknologioita datan keräämiseen, kuten ympäristösensoreita, videoanalyysiä, itsearviointeja ja havainnointianalyysiä.

Tutkimuskysymys 2: Miten data-analytiikkaa hyödynnetään urheiluvammojen ehkäisyssä? Tehokkain ja yleisin tapa hyödyntää data-analytiikkaa urheiluvammojen ehkäisyssä on koneoppimisen käyttö. Koneoppimismallit pystyvät analysoimaan monimutkaista dataa, jolloin se on koettu paremmaksi menetelmäksi kuin perinteiset tilastolliset menetelmät. Koneoppimismallit pystyvät erottamaan datasta suurimpia riskitekijöitä loukkaantumiseen, jolloin pystytään tekemään varotoimenpiteitä, jotta

loukkaantumista ei tapahtuisi. Erityisesti SVM-malli on tutkimusten mukaan tehokas koneoppimismalli urheiluvammojen ehkäisyyn ja ennustamiseen. Myös puettavat laitteet ovat yleisesti käytettyjä urheiluvammojen ehkäisyssä. Niillä voidaan kerätä tietoa kuormituksesta, joka on yksi yleisimmistä syistä loukkaantumiseen. Sen lisäksi puettavilla laitteilla voidaan saada tietoa urheilijan liikemalleista, jolloin voidaan kiinnittää huomiota suoritustekniikoihin. Laitteista saatavaa dataa voidaan analysoida aiemmin mainituilla koneoppimismalleilla.

Aihe on kuitenkin vielä suhteellisen uusi ja tutkimuksia menetelmien käytöstä urheiluvammojen ehkäisyssä on vielä melko vähän, vaikka urheiluanalytiikalla onkin pitkä historia. Koneoppimismallit saattavat antaa edelleen vääriä tuloksia, jolloin urheilija voidaan laittaa turhaan lepoon. Tämä voi olla suuri riski joukkueelle, sillä yhdenkin pelaajan, varsinkin tärkeän pelaajan puuttuminen, voi vaikuttaa joukkueen suorituskyykyyn merkittävästi. Joukkueen heikentynyt suorituskyyky voi johtaa heikompaan menestykseen, ja heikompi menestys voi taas vaikuttaa urheiluseuran talouteen negatiivisesti. Haasteita urheiluvammojen ehkäisyssä käytettäviin menetelmiin tuo se, että ne vaativat paljon resursseja. Tämä voi tuoda eriarvoisuutta urheilijoiden ja joukkueiden välille, sillä jos jollain on mahdollisuuksia käyttää menetelmiä, voi se tuoda merkittävää etua joukkueelle.

Haasteena tutkielman aiheessa oli se, että eri data-analytiikan menetelmien käytöstä urheilussa, ja varsinkin urheiluvammojen ehkäisyssä löytyy vielä suhteellisen vähän tietoa. Esimerkiksi eri koneoppimismallien käytöstä löytyy tietoa niukasti. Haastetta tuo myös se, että aihetta on vasta viime aikoina alettu tutkia enemmän ja uutta tietoa tulee koko ajan lisää. Lisäksi koneoppimismalleja on usein käytetty vain tietyissä tilanteissa, kuten tietyn ikäisillä tai tietyn urheilulajin urheilijoilla, jolloin tulosten yleistettävyyys voi olla haastavaa. Osa tutkimuksista oli suoritettu myös keinotekoisissa olosuhteissa, jolloin ei välttämättä saada aivan todenmukaisia tuloksia. Tämän myötä on haastavaa vertailla laajasti eri koneoppimismalleja keskenään.

Mahdollisena jatkotutkimusnäkökulmana voisikin olla laajempi vertailu eri koneoppimismallien kesken ja niiden tutkiminen erilaisissa tilanteissa ja eri urheilulajeissa. Koneoppimismalleja voisi myös yhdistää keskenään tai erilaisten tilastollisten menetelmien kanssa, jolloin voisi olla mahdollista saada vielä parempia ja merkittävämpiä tuloksia.

Tulevaisuudessa data-analytiikkaa tullaan hyödyntämään urheilussa ja urheiluvammojen ehkäisyssä entistä enemmän, vaikka jo nyt sen käyttö on yleistynyt viime vuosina paljon ja siitä on tullut tärkeä osa urheilua. Menetelmien kehittyessä urheilijat voivat saada yhä yksilöllisempää tietoa omasta suorituksestaan sekä suosituksia esimerkiksi harjoitteluun, palautumiseen ja loukkaantumisten ehkäisyyn. Data-analytiikan menetelmien yleistyessä, niiden käytöstä tulee todennäköisesti myös halvempaa ja saavutettavampaa myös pienemmille lajeille ja urheiluseuroille, jolloin niiden käyttö laajenee. Data-analytiikka on varmasti jäämässä tärkeäksi ja keskeiseksi osaksi urheilua ja sen kehitystä tulevaisuudessa.

Lähdeluettelo

- [1] E. B. Wasserman, M. M. Herzog, C. L. Collins, S. N. Morris ja S. W. Marshall, ”Fundamentals of Sports Analytics”, *Clinics in Sports Medicine*, vol. 37, nro 3, s. 387–400, heinäkuu 2018, ISSN: 02785919. DOI: 10.1016/j.csm.2018.03.007.
- [2] Z. Bai ja X. Bai, ”Sports Big Data: Management, Analysis, Applications, and Challenges”, *Complexity*, vol. 2021, nro 1, C. Lin, toim., s. 6676297, tammikuu 2021, ISSN: 1076-2787, 1099-0526. DOI: 10.1155/2021/6676297.
- [3] H. Sigurdson ja J. Chan, ”Machine Learning Applications to Sports Injury: A Review:” teoksessa *Proceedings of the 9th International Conference on Sport Sciences Research and Technology Support*, Online Streaming, — Select a Country —: SCITEPRESS - Science ja Technology Publications, 2021, s. 157–168, ISBN: 978-989-758-539-5. DOI: 10.5220/0010717100003059.
- [4] A. Ç. Seçkin, B. Ateş ja M. Seçkin, ”Review on Wearable Technology in Sports: Concepts, Challenges and Opportunities”, *Applied Sciences*, vol. 13, nro 18, s. 10399, syyskuu 2023, ISSN: 2076-3417. DOI: 10.3390/app131810399.
- [5] W. Li, ”A Big Data Approach to Forecast Injuries in Professional Sports Using Support Vector Machine”, *Mobile Networks and Applications*, syyskuu 2024, ISSN: 1383-469X, 1572-8153. DOI: 10.1007/s11036-024-02377-x.
- [6] K. Apostolou ja C. Tjortjis, ”Sports Analytics algorithms for performance prediction”, teoksessa *2019 10th International Conference on Information, Intel-*

- ligence, Systems and Applications (IISA)*, PATRAS, Greece: IEEE, heinäkuu 2019, s. 1–4, ISBN: 978-1-72814-959-2. DOI: 10.1109/IISA.2019.8900754.
- [7] E. Morgulev, O. H. Azar ja R. Lidor, ”Sports analytics and the big-data era”, *International Journal of Data Science and Analytics*, vol. 5, nro 4, s. 213–222, kesäkuu 2018, ISSN: 2364-415X, 2364-4168. DOI: 10.1007/s41060-017-0093-7.
- [8] V. Sarlis ja C. Tjortjis, ”Sports analytics — Evaluation of basketball players and team performance”, *Information Systems*, vol. 93, s. 101562, marraskuu 2020, ISSN: 03064379. DOI: 10.1016/j.is.2020.101562.
- [9] H. Yang, S. Zhang, J. Zhang ja C. Wang, ”Evaluating the performance of athletes in various sports using data mining and big data analytics”, *Soft Computing*, vol. 28, nro 4, s. 2875–2890, helmikuu 2024, ISSN: 1432-7643, 1433-7479. DOI: 10.1007/s00500-023-09620-9.
- [10] L. Yang, O. Amin ja B. Shihada, ”Intelligent Wearable Systems: Opportunities and Challenges in Health and Sports”, *ACM Computing Surveys*, vol. 56, nro 7, s. 1–42, heinäkuu 2024, ISSN: 0360-0300, 1557-7341. DOI: 10.1145/3648469.
- [11] A. L’Heureux, K. Grolinger, H. F. Elyamany ja M. A. M. Capretz, ”Machine Learning With Big Data: Challenges and Approaches”, *IEEE Access*, vol. 5, s. 7776–7797, 2017, ISSN: 2169-3536. DOI: 10.1109/ACCESS.2017.2696365.
- [12] C. Janiesch, P. Zschech ja K. Heinrich, ”Machine learning and deep learning”, *Electronic Markets*, vol. 31, nro 3, s. 685–695, syyskuu 2021, ISSN: 1019-6781, 1422-8890. DOI: 10.1007/s12525-021-00475-2.
- [13] C. Wang, S. D. Stovitz, J. S. Kaufman, R. J. Steele ja I. Shrier, ”Principles of musculoskeletal sport injuries for epidemiologists: a review”, *Injury Epidemiology*, vol. 11, nro 1, s. 21, toukokuu 2024, ISSN: 2197-1714. DOI: 10.1186/s40621-024-00507-3.

- [14] H. Van Eetvelde, L. D. Mendonça, C. Ley, R. Seil ja T. Tischer, "Machine learning methods in sport injury prediction and prevention: a systematic review", *Journal of Experimental Orthopaedics*, vol. 8, nro 1, s. 27, joulukuu 2021, ISSN: 2197-1153. DOI: 10.1186/s40634-021-00346-x.
- [15] V. Sarlis, G. Papageorgiou ja C. Tjortjis, "Injury Patterns and Impact on Performance in the NBA League Using Sports Analytics", *Computation*, vol. 12, nro 2, s. 36, helmikuu 2024, ISSN: 2079-3197. DOI: 10.3390/computation12020036.
- [16] J. Exel ja P. Dabnichki, "Precision Sports Science: What Is Next for Data Analytics for Athlete Performance and Well-Being Optimization?", *Applied Sciences*, vol. 14, nro 8, s. 3361, huhtikuu 2024, ISSN: 2076-3417. DOI: 10.3390/app14083361.
- [17] R. Cheng ja J. H M Bergmann, "Impact and workload are dominating on-field data monitoring techniques to track health and well-being of team-sports athletes", *Physiological Measurement*, vol. 43, nro 3, 03TR01, maaliskuu 2022, ISSN: 0967-3334, 1361-6579. DOI: 10.1088/1361-6579/ac59db.
- [18] V. R. A. Cossich, D. Carlgren, R. J. Holash ja L. Katz, "Technological Breakthroughs in Sport: Current Practice and Future Potential of Artificial Intelligence, Virtual Reality, Augmented Reality, and Modern Data Visualization in Performance Analysis", *Applied Sciences*, vol. 13, nro 23, s. 12965, joulukuu 2023, ISSN: 2076-3417. DOI: 10.3390/app132312965.
- [19] Z. Chen ja X. Dai, "Utilizing AI and IoT technologies for identifying risk factors in sports", *Heliyon*, vol. 10, nro 11, e32477, kesäkuu 2024, ISSN: 24058440. DOI: 10.1016/j.heliyon.2024.e32477.
- [20] M. Kovoov, M. Durairaj, M. S. Karyakarte, M. Zair Hussain, M. Ashraf ja L. P. Maguluri, "Sensor-enhanced wearables and automated analytics for inju-

- ry prevention in sports”, *Measurement: Sensors*, vol. 32, s. 101054, huhtikuu 2024, ISSN: 26659174. DOI: 10.1016/j.measen.2024.101054.
- [21] J. S. Theodoropoulos, J. Bettle ja J. D. Kosy, ”The use of GPS and inertial devices for player monitoring in team sports: A review of current and future applications”, *Orthopedic Reviews*, vol. 12, nro 1, huhtikuu 2020, ISSN: 2035-8164, 2035-8237. DOI: 10.4081/or.2020.7863.
- [22] C. Perin, R. Vuillemot, C. D. Stolper, J. T. Stasko, J. Wood ja S. Carpendale, ”State of the Art of Sports Data Visualization”, *Computer Graphics Forum*, vol. 37, nro 3, s. 663–686, kesäkuu 2018, ISSN: 0167-7055, 1467-8659. DOI: 10.1111/cgf.13447.
- [23] A. Rossi, L. Pappalardo, P. Cintia, F. M. Iaia, J. Fernández ja D. Medina, ”Effective injury forecasting in soccer with GPS training data and machine learning”, *PLOS ONE*, vol. 13, nro 7, J. Sampaio, toim., e0201264, heinäkuu 2018, ISSN: 1932-6203. DOI: 10.1371/journal.pone.0201264.
- [24] A. Zadeh, D. Taylor, M. Bertso, T. Tillman, N. Nosoudi ja S. Bruce, ”Predicting Sports Injuries with Wearable Technology and Data Analysis”, *Information Systems Frontiers*, vol. 23, nro 4, s. 1023–1037, elokuu 2021, ISSN: 1387-3326, 1572-9419. DOI: 10.1007/s10796-020-10018-3.
- [25] L. Ren, Y. Wang ja K. Li, ”Real-time sports injury monitoring system based on the deep learning algorithm”, *BMC Medical Imaging*, vol. 24, nro 1, s. 122, toukokuu 2024, ISSN: 1471-2342. DOI: 10.1186/s12880-024-01304-6.
- [26] S. Jauhiainen, J.-P. Kauppi, M. Leppänen et al., ”New Machine Learning Approach for Detection of Injury Risk Factors in Young Team Sport Athletes”, *International Journal of Sports Medicine*, vol. 42, nro 02, s. 175–182, helmikuu 2021, ISSN: 0172-4622, 1439-3964. DOI: 10.1055/a-1231-5304.

-
- [27] V. Sarlis, V. Chatziilias, C. Tjortjis ja D. Mandalidis, "A Data Science approach analysing the Impact of Injuries on Basketball Player and Team Performance", *Information Systems*, vol. 99, s. 101750, heinäkuu 2021, ISSN: 03064379. DOI: 10.1016/j.is.2021.101750.
- [28] Y. Qi, S. M. Sajadi, S. Baghaei, R. Rezaei ja W. Li, "Digital technologies in sports: Opportunities, challenges, and strategies for safeguarding athlete wellbeing and competitive integrity in the digital era", *Technology in Society*, vol. 77, s. 102496, kesäkuu 2024, ISSN: 0160791X. DOI: 10.1016/j.techsoc.2024.102496.
- [29] W. Ghasem, J. Valenzuela ja L. A. Saxon, "Player Tracking Technology and Data for Injury Prevention in the National Football League", *Current Sports Medicine Reports*, vol. 20, nro 9, s. 436–439, syyskuu 2021, ISSN: 1537-8918. DOI: 10.1249/JSR.0000000000000873.