



**TURUN
YLIOPISTO**
Kauppakorkeakoulu

Tekoäly tukena jalkapalloilijan harjoittelussa ja palautumisessa

Tietojärjestelmätieteen kandidaatintutkielma

Laatija:

Werner Mäkelä

Ohjaaja

Yliopisto-opettaja Kaisa Kukkonen

5.5.2025

Turku

Turun yliopiston laatujärjestelmän mukaisesti tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck -järjestelmällä.

Kandidatutkielma

Oppiaine: Tietojärjestelmätiede

Tekijä(t): Werner Mäkelä

Otsikko: Tekoäly tukena jalkapalloilijan harjoittelussa ja palautumisessa

Ohjaaja(t): Yliopisto-opettaja Kaisa Kukkonen

Sivumäärä: 29

Päivämäärä: 5.5.2025

Seuraava kandidaatintutkielma tarkastelee tekoälyn hyödyntämistä osana jalkapalloilijoiden harjoittelua ja palautumista. Työssä esitellään tekoölyyn liittyvät tärkeät käsitteet ja siihen vaikuttavat tekijät, kuten data. Käymme läpi, kuinka dataa kerätään, mitä siihen liittyviä mittareita ja tutkimusmenetelmiä aihetta käsittelevissä tutkimuksissa on käytetty. Erilaisia tekoölyyn pohjautuvia malleja esitellään ja käydään läpi, kuinka niiden avulla voidaan parantaa pelaajien harjoittelua sekä palautumista. Harjoittelussa merkittäviä etuja mahdollistaa pelaajien yksilökohtaisempi arviointi tekoälyn avulla. Näin voidaan paremmin tuottaa pelaajalle räätälöityjä harjoitusratkaisuja.

Palautumisen mittaamisessa keskeisiksi tekijöiksi nousivat muun muassa fyysisen rasitus sekä uni, mutta myös psykologiset tekijät kuten stressi. Hyödyntämällä tekoälyä voidaan kuitenkin parantaa pelaajien palautumista, sekä pienentää mahdollista loukkaantumiseriskiä. Tulosten avulla voidaankin sanoa, että tekoälymenetelmien avulla voidaan saavuttaa merkittävää kilpailuetua harjoittelun ja palautumisen saralla. Mallien vaatiessa suuria datamääriä, työssä käydään myös läpi sitä, kuinka datan rooli vaikuttaa tähän kehitykseen ja siihen kuinka tarkkoja tuloksia voidaan saada. Työssä kuitenkin tiedostetaan vielä tämänhetkisen tutkimuksen rajallisuus tutkimusaiheen ollessa vielä uudehko.

Avainsanat: tekoäly, koneoppiminen, syväoppiminen, neuroverkot

SISÄLLYS

1	Johdanto	6
1.1	Tutkimuskysymykset sekä tarkoitus	7
1.2	Rakenne	7
1.3	Avaintermit	8
1.3.1	Tekoälyn määritelmä	8
1.3.2	Tekoälyn perusperiaate	9
1.3.3	Tekoälyn alakategoriat	9
2	Tekoäly harjoittelun tukena	11
2.1	Datan kerääminen	12
2.2	Mittauskohteet	13
2.3	Tekoälyn käyttö	13
3	Tekoälyn hyödyntäminen jalkapalloilijan hyvinvoinnissa	17
3.1	Datan kerääminen	18
3.2	Mittauskohteet	20
3.3	Tekoälyn käyttö	21
4	Yhteenveto ja johtopäätökset	25

KUVIOT

Kuva 1 Tekoälyn mallintaminen, mukaillen (Mishra 2024)	10
Kuva 2 Harjoittelun ja palautumisen yhteys	25

TAULUKOT

Taulukko 1 Harjoittelu ja palautuminen	8
--	---

1 Johdanto

Jalkapallo on maailman suosituin urheilulaji ja sitä pelataan käytännössä katsoen joka puolella maailmaa (Siukonen, Rantala & Otava 2006). Pelaajien harjoittelu on koventunut entisestään, mutta kuinka siitä voidaan tehdä tehokkaampaa? Tekoälyn omaksuminen ja sen hyödyntäminen eri aloilla on yleistynyt, eikä jalkapallo ole poikkeus. Tekoälyä voidaan käyttää apuna pelaajakehityksessä tavoilla, joita ei ole aikaisemmin pystytty hyödyntämään edes ajatuksen tasolla (Yang & Feng 2024).

Tekoälyn hyödyntämistä eri urheilulajeissa jalkapallon ohella on tutkittu jo monessa muussakin urheilulajissa. Tutkimuskohteiden painotus on ollut kuitenkin hieman enemmän kallellaan yksilöurheilun puolelle. Eniten tekoälyä näissä tutkimuksissa on käytetty datan keräämiseen sekä harjoittelun suunnitteluun. (Krstić ym. 2023). Jalkapallon kontekstissa tekoälyn vaikutusta on tutkittu jo useampien vuosien aikana etenkin pelaajien loukkaantumisten estämiseksi sekä yleiseen suorituskyvyn parantamiseen. Yksilöiden päätöksentekoprosessia pelin sisällä ei kuitenkaan ole vielä tutkittu paljoa. Tulevaisuudessa olisikin tarkoituksenmukaista hyödyntää sensoreita datan reaaliaikaiseen keräämiseen sekä tulkitsemiseen pelien sisällä (Liu & Liu 2025).

Tekoälyn hyödyntäminen ei kuitenkaan rajoitu vain pelaajien kehitykseen, vaan sitä voidaan hyödyntää moneen muuhunkin jalkapallon osa-alueeseen. Pelaajien jättämää datajälkeä voidaan arvioida ja analysoida hyödyntämällä koneoppimista. Tämä vähentää tai voi poistaa inhimillisen virheen, eli ihmisen subjektiivisuuden päätöksenteossa. Datan ja datamallien hyödyntäminen voi auttaa objektiivisessa tarkastelussa. Esimerkiksi kyvykkäiden yksilöiden löytämisen suuren massan joukosta voi helpottua datamalleja hyödyntämällä. (Monsees 2025)

Vaikka tekoälyn hyödyntäminen kuulostaakin hyvältä, ei se ole kuitenkaan ongelmatonta. Datan pohjalta kerätyt mittarit voivat poiketa toisistaan ja niiden arvostus saattaa vaihdella hyvinkin paljon, eikä esimerkiksi suorituskyvyn arviointiin ole yhtä tiettyä objektiivista määritelmää (Pappalardo ym. 2019). Tekoälyä voidaan hyödyntää myös jalkapallon taktisella puolella. Valmennuksellisilla tavoilla on mahdollista saada etua vastustajaan nähden ja tekoälyn avulla tätä voitaisiin tehostaa entisestään. Tekoäly antaa valmentajille siis entistä enemmän työkaluja (Z. Wang ym. 2024). Tässä tutkielmassa tarkastelu rajoittuu kuitenkin vain tekoälyn hyödyntämiseen palautumisen ja harjoittelun kontekstissa.

1.1 Tutkimuskysymykset sekä tarkoitus

Jalkapallon suosion vuoksi on tärkeää ymmärtää tulevaisuuden kehityssuuntia, ja tässä kehityksessä tekoäly tulee olemaan keskeinen tulevien vuosikymmenien aikana. Tätä pyritään tarkastelemaan seuraavan tutkimuskysymyksen avulla: Kuinka tekoälyä voidaan hyödyntää osana pelaajan harjoittelua ja palautumista? Tutkielma on toteutettu kirjallisuuskatsauksena. Tarkastelemme erilaisia tekoälyyn pohjautuvia menetelmiä ja aiheesta tehtyjä tutkimuksia. Näiden avulla pyrimme vastaamaan tutkimuskysymykseen. Tutkimuskysymys on jaettu kahteen alatutkimuskysymykseen, joihin luvuissa 2 ja 3 pyritään vastaamaan. Nämä alatutkimuskysymykset ovat seuraavia: Kuinka tekoälyä voidaan hyödyntää pelaajan harjoittelussa, sekä kuinka tekoälyä voidaan hyödyntää osana pelaajan palautumisprosessia?

1.2 Rakenne

Tekstin rakenne on seuraavanlainen: Ensimmäisessä osiossa käymme läpi tärkeät käsitteet ja tutkimuskysymyksen. Toisessa luvussa käymme läpi sitä, kuinka tekoälyä voidaan käyttää apuna pelaajien harjoittelussa. Olennaista tässä luvussa on analysoida sitä, millä tavoin harjoittelua voidaan mitata ja kuinka tekoälyä voidaan hyödyntää mittaustulosten tulkinnassa. Lisäksi tarkastelemme, kuinka testeissä käytettyä dataa on kerätty.

Kolmas luku on rakenteeltaan samankaltainen kuin luku 2. Kolmannessa luvussa kuitenkin käsittelemme tekoälyn roolia palautumisessa. Kuinka palautumista voidaan mitata ja mitä keskeisiä menetelmiä tähän on käytetty. Lisäksi pohdimme, onko kaikki kerätty data samanarvoista, ja onko datan laadulla merkitystä tulosten kannalta. Harjoittelu ja palautuminen on jaettu omiksi luvuiksi, jotta niitä voidaan käsitellä ensin toisistaan erillisinä kokonaisuuksina. Viimeisessä luvussa vertailemme, onko näillä yhteyksiä toisiinsa ja minkälaisia yhteydet ovat.

Harjoittelua ja palautumista käsitellään seuraavan taulukon mukaan.

Taulukko 1 Harjoittelu ja palautuminen

	Harjoittelun mittaaminen ja käsittely	Palautumisen mittaaminen ja käsittely
1	Fysiologiset mittarit: Liikenopeus, sijoittuminen, voimaharjoittelu	Fyysiset mittarit: Veriarvot, sykemittaukset
2	Harjoittelun optimointi tekoälyllä: Yksilöllinen harjoitusohjelma, pelipaikkojen analyysi	Unen ja palautumisen analysointi: Älysormukset, unikyselyt
3	Edistyneet suoritusanalyysit: Maaliodottama (xG)	Loukkaantumisten ja ylikuormituksen ennustaminen: Koneoppimismallit, psyykkinen kuormitus

1.3 Avaintermit

Tutkimuksessa käytetään paljon termejä tekoäly, koneoppiminen, syväoppiminen ja neuroverkko. Tutkimuksen ymmärtämisen kannalta termit ovat keskeisiä, ja ne on selitetty tarvittavalla tarkkuudella seuraavissa alaluvuissa.

1.3.1 Tekoälyn määritelmä

Tekoälyn määrittäminen on koettu hankalaksi, ja siitä on monia tulkintoja. Yhteisymmärrykseen varsinaisesta määritelmästä ei ole päästy. Vaikeuden tekoälyn määrittämiseksi tekee se, että edes älykkyydelle ei ole yhtä ja yleistä hyväksyttyä määritelmää. Tästä syystä myöskään tarkkaa tekoälyn määritelmää ei voida vielä tänä päivänäkään käyttää. Ehdotuksia erilaisille tekoälyn määritelmille on kuitenkin annettu. Esimerkiksi ihmismäiseen päätöksentekoon perustuvaa toimintaa, jonka tarkoituksena on saada tietokoneet ajattelemaan ihmismäisellä tavalla. Näillä määritelmillä on kuitenkin omat ongelmansa (Emmert-Streib, Yli-Harja, ja Dehmer 2020). Ei ole olemassa vain yhtä yksittäistä ihmisälyä tai tapaa ajatella. Tästä syystä jo pelkästään älyn määrittäminen on hankalaa kuten jo todettua. Tekoälyä ei voida varsinaisesti siis määritellä ihmiseen liittyvänä älykkyytenä (P. Wang 2019).

Määritelmän ongelmallisuuden tiedostaminen on tärkeää. Tutkimuksen tarkoituksena ei ole kuitenkaan etsiä tarkkaa määritelmää tekoälylle. Edellä mainitusta syystä tässä tutkimuksessa

tekoäly sanaa käyttäessämme, viittaamme sillä älykkyyttä simuloiviin tietokoneisiin tai niiden ohjelmiin.

1.3.2 Tekoälyn peruseriaate

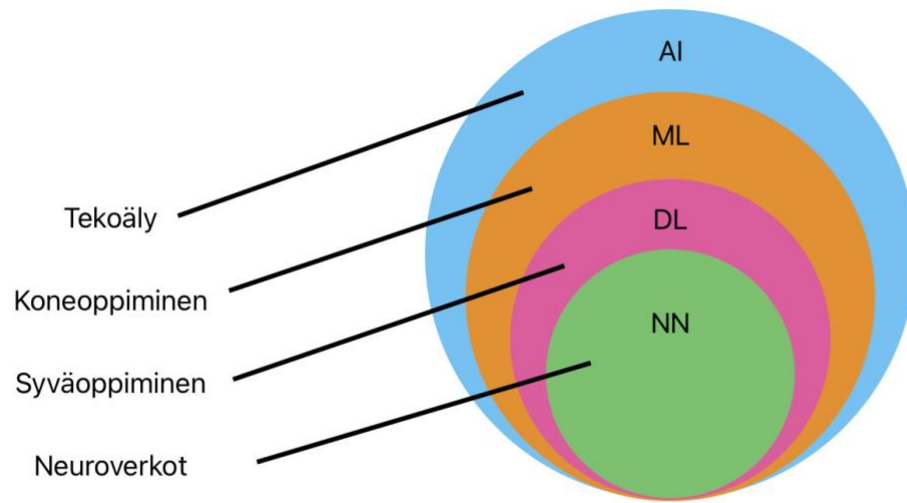
Tekoälyä on mahdotonta luoda ilman dataa. Tekoälyn algoritmit tarvitsevat valtavan määrän dataa, tarkoituksenaan oppia sekä ymmärtää yhdenmukaisuuksia siitä. Algoritmi tuottaa datasta ennusteita ja tulkintoja sen perusteella, miten se on ohjelmoitu toimimaan. Datan merkittävän roolin vuoksi sen laadulla on huomattavan suuri vaikutus. Huonolaatuinen data voikin johtaa vääristymiin ja sitä kautta heikentää tekoälyn avulla saatujen tuotosten luotettavuutta sekä vaikuttavuutta. (Aldoseri, Al-Khalifa & Hamouda 2023)

Aldoserin, Al-Khalifan ja Hamoudan (2023) mukaan laadukkaaseen dataan vaikuttavat monet eri tekijät, kuten sen tarkkuus, eheys, ajantasaisuus, täydellisyys, relevanssi sekä johdonmukaisuus. Nämä ovat tekijöitä, jotka varmistavat, että data on tarpeeksi laadukasta, jotta sitä voidaan käyttää tekoälyn pohjana. Tekoälymalleissa tulee siis panostaa datan hallintaan, jotta tekoäly tuottaisi mahdollisimman tarkkoja lopputuloksia.

1.3.3 Tekoälyn alakategoriat

Tekoälystä puhuttaessa käytetään usein termejä koneoppiminen, syväoppiminen ja neuroverkot. Nämä ovat tekoälyn alakategorioita, jotka osaltaan mahdollistavat tekoälyn toiminnan muun muassa algoritmien ja itseoppivien mallien avulla. Tekoälyn hyödyllisyyden kannalta onkin olennaisen tärkeää, että se pystyy oppimaan ja parantamaan toimintaansa. Syväoppiminen, eli koneoppimisen alakategoria ja neuroverkot ovat mahdollistaneet tekoälyn entistä edistyneemmän kehityksen. Perinteisiin algoritmimalleihin verrattuna syväoppiminen onnistuu ratkaisemaan entistä kompleksisempia ongelmia hyödyntäen neuroverkkoja. Neuroverkot puolestaan muodostuvat kerroksittain olevista neuroneista, jossa data kulkee näiden tasojen läpi saaden painoarvon. Neuroverkot muodostuvat samaan tapaan kuin ihmisen aivot, ja siksi niiden avulla voidaan saada aikaiseksi erittäin yksityiskohtaisia tuloksia. (Mishra 2024)

Seuraava kuvio pyrkii havainnollistamaan tekoälyn ja sen alakategoriat.



Kuva 1 Tekoälyn mallintaminen, mukailten (Mishra 2024)

2 Tekoäly harjoittelun tukena

Tässä luvussa tarkastelemme tekoälyn hyödyntämistä pelaajan harjoittelussa. Käymme läpi, kuinka dataa kerätään ja mitä mittareita näissä käytetään. Tarkoituksena vastata alatutkimuskysymykseen ”Kuinka tekoälyä voidaan hyödyntää pelaajan harjoittelussa”.

Tekoälyä on alettu hyödyntämään urheilussa 2000-luvun alussa. Ensimmäiset sovellukset olivat biomekaniikkaan liittyviä mallinuksia, mutta suosion kasvaessa, niitä alettiin hyödyntämään joukkueurheilussa. Nykyään tekoälyä voidaankin hyödyntää yksilöiden kehitykseen joukkueiden sisällä. Kehittynyt tekoäly mahdollistaa sen, että dataa voidaan entistä tehokkaammin kerätä ja hyödyntää harjoittelun tueksi (Munoz-Macho, Domínguez-Morales & Sevillano-Ramos 2024). Datan hyödyntäminen urheilussa ei ole enää aivan uusi ilmiö, ja sen keräämiseen ja analysoimiseen on kiinnitetty enemmän huomiota viimeisimpien vuosien aikana. Datan ja tekoälyn hyödyntämisessä ongelmaksi onkin muodostunut sen resurssi-intensiivisyys. Tästä syystä tämän ei voida olettaa hyödyttävän kaikkia sen käyttäjiä tasapuolisesti (Monsees 2025).

Keskittyminen pelkästään fyysisiin attributteihin ei kuitenkaan ole paras tapa lähestyä pelaajakohtaista harjoittelua. Tekoälyä hyödyntämällä voidaan kerätä pelaajakohtaista dataa, jonka avulla harjoittelua voidaan optimoida vastaamaan yksilön tarpeita. Pelaajan heikkouksia sekä vahvuuksia on helpompi tunnistaa tekoälyn avulla, jolloin harjoittelua voidaan kohdistaa juuri näihin osa-alueisiin. (Yang & Feng 2024)

Aikaisempien vuosikymmenien aikana ajatuksena oli, että jalkapallon huippuyksilöt erottautuisivat edukseen erityisesti vain atleettisuuden perusteella. Ajatus huippujalkapalloilijoiden kognitiivisten taitojen merkityksestä, on kuitenkin noussut myöhemmin. Tästä syystä aihetta on alettu tutkia, ja esimerkiksi eräässä tutkimuksessa tekoälyä hyödyntäen todettiin, että eliittijalkapalloilijat osoittivat kehittyneempiä kognitiivisia taitoja, kuin tutkimuksessa ollut verrokkiryhmä. Näitä taitoja olivat esimerkiksi tehokkaampi ongelmanratkaisu, parempi muisti, sekä kehittyneempi toiminnallinen päätöksenteko. (Bonetti ym. 2025)

Lisäksi hieman vähemmän esillä ollut aihe on pelaajadataan liittyvän tietoturvan varmistaminen. Suurempien tietomäärien kerääminen ja tämän säilöminen pilvipalveluihin kasvattaa riskiä tietovuodoille sekä datan väärinkäytöksille. Tämä voi olla vahingollista sekä pelaajalle itselleen, että myös joukkueelle. Lohkoketjujen käyttöä pelaajadatan hallinnassa on myös tutkittu, ja sitä miten siihen liittyvät tietoturvallisuusriskit pystyttäisiin minimoimaan (Pu ym. 2023). Näiden

lisäksi tulisi myös huomioida datan laatu ja siihen vaikuttavat tekijät, jotta käytettyjen tekoälymallien luotettavuus ei kärsisi (Aldoseri, Al-Khalifa & Hamouda 2023).

2.1 Datan kerääminen

Dataa pelaajien suoriutumisesta voidaan kerätä monilla eri menetelmillä. Tämän alaluvun tarkoituksena on käsitellä eri menetelmiä, joilla pelaajista ja heidän suoritteistaan voidaan kerätä dataa.

Yksi yleinen mittauskohde on pelaajan sijoittuminen. Pelaajan sijoittumisesta dataa voidaan kerätä erilaisilla sensoreilla. Xun (2025) tutkimuksessa käytettiin esimerkiksi signaaleja tuottavia valosensoreita. Näiden signaalien avulla voidaan tarkastella pelaajan sijoittumista ja liikenopeuksia pelin tai harjoitusten aikana. Kerätyn datan avulla pelaajista voidaan luoda malleja ja arvioida niiden pohjalta heidän suorituskykyään.

Dataa voidaan kerätä myös kameroiden avulla. Eräässä tutkimuksessa dataa kerättiin hyödyntämällä Microsoftin Kinect V2 älykameraa. Saatu data esikäsiteltiin, ja siitä pyrittiin suodattamaan mahdollinen datan taustamelu. Tämän jälkeen data käsiteltiin vielä uudelleen hyödyntämällä datan optimointiin luotuja tekoälyalgoritmeja. Näiden tarkoituksena on saada luotua mahdollisimman laadukasta dataa (Yang & Feng 2024). Infrapunan avulla voidaan myös kerätä dataa pelaajista suorituksen aikana. Infrapunavaloa voidaan hyödyntää esimerkiksi pelaajan kehonlämmön tai lihasten aktivoitumisen mittaamiseen. Infrapunavaloa mitataan siihen soveltuvilla kameroilla, jotka antavat ajankohtaista lämpöjälkidataa (Xu 2025).

Dataa voidaan kerätä kuitenkin myös perinteisemmillä menetelmillä. Eräässä kognitiivisia taitoja mittaavassa tutkimuksessa tutkittiin kolmen eri kohderyhmän suoriutumista samoissa kognitiivisia taitoja vaativissa tehtävissä. Ensimmäinen kohderyhmä muodostui 158 Brasilian pääsarjassa pelaavasta ammattijalkapalloilijasta. Toinen kohderyhmä, eli kontrolliryhmä muodostui 124 brasilialaisesta tavallisesta ihmisestä. Kolmas ryhmä puolestaan koostui 51 ruotsalaisesta eliittitason jalkapalloilijasta. Tutkimuksessa tuotettu data muodostui siis kolmesta kansainvälisestä tietokannasta, jossa osallistujia testattiin kontrolloiduissa olosuhteissa, ilman ulkoisia häiriötekijöitä (Bonetti ym. 2025). Datasta voidaan myös tehdä otoksia ja luoda yksityiskohtaisempaa dataa sen pohjalta. Esimerkiksi laukauksen maaliodottamaa tarkastelevassa tutkimuksessa data koottiin Italian pääsarjan kauden 2019–2020 otteluista. Tutkimuksessa tarkasteltiin 660 laukaisuyritystä sekä niihin vaikuttavia tekijöitä, kuten laukauksen etäisyyttä maalista tai laukaisukulmaa (Cefis ja Carpita 2024).

2.2 Mittauskohteet

Harjoittelua analysoidessa voidaan käyttää monia eri mittareita. Tutkimustulosten kannalta mittauskohteilla on suuri merkitys. Oikeiden mittareiden löytäminen onkin siis erityisen tärkeää tästä syystä. Tässä alaluvussa keskitytään tarkastelemaan mittauskohteita, joita tutkimuksissa on käytetty.

Eräässä tutkimuksessa syväoppimista sekä neuroverkkoja käytettiin videodatan analysoimisen avuksi, jalkapalloilijoiden voimaharjoittelun aikana. Tarkoituksena oli seurata ja analysoida pelaajien liikeratoja hyödyntäen syväoppimisjärjestelmää. Kyseinen järjestelmä oli ohjelmoitu tunnistamaan tarkkuutta ja tehokkuutta korreloitavia liikkeitä (Zhou, Chen & Xu 2022). Jo aiemmin mainitussa kognitiivisia taitoja mittaavassa tutkimuksessa osallistujille tehtiin taas erilaisia persoonallisuustestejä, jotka keskittyivät esimerkiksi muistiin ja suunnitteluun. Testeistä saadun datan avulla huipputason jalkapalloilijoiden kognitiivisia taitoja pystyttiin vertaamaan kontrolliryhmään (Bonetti ym. 2025).

Pelaajista voidaan luoda myös data-aineistoja henkilökohtaisen pelisuoritteiden sekä taidon perusteella. Esimerkiksi syöttöjen tarkkuutta tai pallonhallintaa/pallokosketuksia voidaan kerätä. Näiden avulla pelaajien suoritteita voidaan analysoida tarkemmin (Liu & Liu 2025). Näitä data-aineistoja voidaan luoda esimerkiksi käyttämällä jo aiemmin mainittuja videoon pohjautuvia kone- ja syväoppimisalgoritmeja. Sen lisäksi, että ohjelmat voivat tunnistaa liikkeitä voidaan ohjelmien avulla tunnistaa myös pelaajien suorituksia kuten syöttöjä ja laukauksia (Yin, Sinnott & Jayaputera 2024).

Jo viimeisimpien vuosien aikana yleistynyt laskettu maaliodottama, eli xG on mittari, jonka avulla jokaiselle laukaukselle voidaan laskea arvo 0 ja 1 väliltä. Tämä on ikään kuin laukauksen todennäköisyys mennä maaliin. Esimerkiksi laukauksen maaliodottaman ollessa 0,25 tarkoittaa se, että historiadatan mukaan sadasta samasta laukauksesta 25 niistä menee maaliin, eli 25 % todennäköisyydellä. Tämä edistynyt tilastomalli on kehitetty käyttäen koneoppimista, ja se auttaa kuvaamaan paremmin joukkueen tai pelaajan suoriutumista verrattuna pelkkään laukauksen tilastointiin nähden. (Cefis & Carpita 2024)

2.3 Tekoälyn käyttö

Tekoälyn avulla voidaan havainnoida asioita ja yhteyksiä, jota tutkijat eivät pystyisi välttämättä tunnistamaan tai mittaamaan perinteisillä menetelmillä. Tutkimuksessa, jossa mitattiin

huippujalkapalloilijoiden kognitiivisia ja psykologisia attribuutteja, havaittiin, että huippujalkapalloilijoilla on usein kehittyneempiä kognitiivisia taitoja, kuten ulospäinsuuntautuneisuus, suurempi muistikapasiteetti tai kehittyneemmät päätöksentekotaidot. Tämän lisäksi kyseinen tutkimus osoittaa, että kyseisillä yksilöillä on usein alhaisemmat mielihyvätasot (Bonetti ym. 2025). Harjoittelussa tukena oleva tekoäly on myös yksilön kannalta tehokkaampaa, sillä sen avulla voidaan toteuttaa räätälöityjä harjoittelumalleja sekä kunto-ohjelmia. Näiden avulla pelaaja pystyy parantamaan omaa suorituskykyään ja samalla vähentää riskiä loukkaantua harjoittelun tai pelin aikana (Zhou, Chen & Xu 2022).

Toisaalta taas tekoälyn hyödyntäminen on hyvin riippuvainen resursseista, joka asettaa haasteita sen hyödyntämiselle. Osaavan työvoiman saaminen on myös yksi haasteista, sillä datan ja tekoälyn hyödyntäminen vaatii ammattitaitoa ja ymmärrystä. Osaava työvoiman saaminen ja kouluttaminen on taas järjestelmien käytön varmistamiseksi ehdottoman tärkeää. Tarkoituksena on saavuttaa etua kilpailijoihin nähden, jolloin substanssiosaamisen merkitys on suuri. (Monsees 2025)

Ihmisen kyky tuottaa lisäarvoa on rajallisempi kuin tekoälyn ja sen sovellusten tarjoamat mahdollisuudet. Tekoälyn avulla voidaan siis saada yksityiskohtaisempaa tietoa kuin mitä ihminen kykenisi tuottamaan. Esimerkiksi Xun (2025) tutkimuksessa tekoälyn avulla optimoitua dataa pystyttiin analysoimaan tarkemmin, verrattuna perinteisiin menetelmiin. Toki ihmisen roolia emme vielä toistaiseksi voi jättää huomioimatta, sillä tekoäly ja sen sovellukset tarvitsevat ammattitaitoista ja osaavaa työvoimaa vielä lähitulevaisuudessakin (Monsees 2025).

Toinen esimerkki, jossa tekoälyn sovelluksien avulla pystyttiin tuottamaan yhä laadukkaampaa dataa, on Cefisin ja Carpitan (2024) tutkimus, joka käsitteli maaliodottamaa. Maaliodottaman ennustemallia pystyttiin parantamaan siten, että se vastaa maalin simulaatiota entistä tarkemmalla tavalla. Tässäkin tutkimuksessa datan käsittelyn avulla sen ennustettavuutta ja tarkkuutta pystyttiin parantamaan. Nämä ovat tärkeitä edistysaskelia, sillä kehittyneempien mittareiden avulla pelaajia voidaan arvioida yhä tehokkaammin. Tarkempi ja laadukkaampi data mahdollistaa erilaisten työkalujen kehittämisen, jotka edistävät pelaajien yksilöllisten ominaisuuksien kehittämistä, sekä tukevat valmentajien kykyä kehittää valmennuksen laatua (Cefis & Carpita 2024). Näiden lisäksi myös erilaisten teknologioiden käyttöönotto voi rikastaa pelaajien harjoittelua. Voidaan esimerkiksi luoda virtuaalisia oppimisympäristöjä, joiden avulla pelaajien harjoittelua voidaan monipuolistaa vielä lisää (Yang & Feng 2024).

Nykyään koneoppimisen avulla voidaan myös tunnistaa ihmisten liikkeitä videoiden pohjalta. Tämän kehityksen on mahdollistanut kehittyneet neuroverkkoihin pohjautuvat syväoppimismallit.

Kyseinen teknologia ei varsinaisesti ole uutta, mutta viimeisten vuosien aikana parantuneen laskentatehon avulla on voitu luoda malleja, jotka tunnistavat liikkeitä entistä tarkemmin yhä nopeammista tilanteista. Vaikka mallien teho onkin kasvanut, eivät ne vielääkään ole virheettömiä. Esteenä on jalkapallon sekä muiden joukkuelajien nopeatempoisuus, joka vaikeuttaa liikkeiden tunnistamista. (Yin, Sinnott & Jayaputera 2024)

Tekoälyä sen eri muodoissa voidaan hyödyntää hyvin moneen eri osa-alueeseen. Jo aikaisemmin mainittujen lisäksi tekoälyn avulla voidaan esimerkiksi tunnistaa pelaajalle sopiva pelipaikka, hänen ominaisuuksiensa perusteella. Tässä Snehan ja kumppaneiden (2024) tutkimuksessa, koneoppimista hyödynnettiin juuri tässä yhteydessä. Tutkimuksessa paras malli osasikin tunnistaa 90 % tarkkuudella pelaajien pelipaikan eri ominaisuuksien kuten pituuden, painon, perusaineenvaihdunnan, raajojen pituuden, reaktionopeuden, verenpaineen ja yhteensä 22 eri muuttujan avulla. Pelipaikan tunnistaminen pelaajan ominaisuuksien avulla antaa myös näkymän, mitä kyseisen pelaajan kannattaa harjoittelussaan priorisoida sekä pyrkiä parantamaan. Tunnistamalla pelaajille tyypilliset ominaisuudet voidaan myös arvioida missä pelipaikalla pelaajan tulisi parhaan mahdollisen suorituksen kannalta pelata (Sneha ym. 2024). Eräässä tutkimuksessa myös todettiin, että tietyn tekoälymenetelmän avulla harjoitelleet pelaajat pystyvät toimimaan paremmin joukkueen sisällä. Roolien selkeytyminen paransi pelaajien suorituskykyä ja yhteistyökykyä (Li ym. 2025).

Pelaajien suoritukseen vaikuttaa usein fyysinen kunto, mutta myös valmius tehdä pelillisesti oikeanlaisia ratkaisuja. Esimerkiksi Liun ja Liun (2025) tutkimuksessa luotu tekoälypohjainen suorituskeskeinen strateginen harjoittelumalli korostaa sitä, että pelaajalla voi olla hyvästä fyysisestä kunnosta huolimatta huonompi valmius tehdä pelillisesti oikeantyyppisiä ratkaisuja, kuten antaa syöttö oikea-aikaisesti. Tällöin pelaajan tulisi harjoitella enemmän juuri tätä osa-aluetta. Muita samankaltaisia järjestelmiä hyödyntämällä on pelaajien harjoitusten laadun sekä yksilöllisyyden havaittu parantuneen (Yang & Feng 2024). Monien toistojen avulla voidaan parantaa suorituksen tasoa, mutta kuitenkin vain tiettyyn pisteeseen asti. Saman perustason harjoitteen toistaminen saattaa hidastaa pelaajan kehitystä, ja pelaajan tulisikin pyrkiä harjoittelemaan omaa heikkoa osa-aluettaan. (Liu & Liu 2025).

Fyysisellä kunnolla on kuitenkin suuri rooli pelaajan kehityksessä. Hyvän fyysisen kunnan on huomattu korreloivan paremman suoritusvarmuuden kanssa. Lisäksi se mahdollistaa kyvyn omaksua uusia tekniikoita tehokkaammin. Tämä voi johtua siitä, että pelaajan on helpompi keskittyä itse suoritukseen tai harjoitteluun, kun fyysinen rajoite ei estä sitä (Liu & Liu 2025).

Parempi keskittymiskyky ja pelisuoritukset voivatkin puoltaa sitä, että pelaajan kognitiivisilla kyvyillä on suuri vaikutus pelaajan valppaustilaan ja päätöksentekoon. Tätä näkökulmaa tukisi se, että Bonettin ja kumppaneiden (2025) tutkimus osoittaa huippujalkapalloilijoiden omaavan kehittyneempiä kognitiivisia kykyjä.

Tekoälyn avulla objektiivista päätöksentekoa voidaan parantaa. Lisäksi sen avulla lahjakkaiden pelaajien arvioiminen ja löytäminen saattaa helpottua (Monsees 2025). Tekoälyn käyttö osana jalkapalloilijoiden kehitystä on vasta alkutekijöissä ja sen suosio kasvaa koko ajan. Potentiaali tekoälyn hyödyntämiselle jalkapallossa on kuitenkin valtava, lajin suosion vuoksi. Tulevaisuudessa siis yhdessä puettavan teknologian ja tekoälyn avulla pelaajia voidaan kehittää ja analysoida entistä paremmin (Sneha ym. 2024).

Mallien luomisessa on kuitenkin hyvä ottaa huomioon se, että kerätyn datan laatu saattaa vaihdella paljon lähteestä ja keräystavasta riippuen. Lisäksi mallien tarkkuus saattaa datan määrän mukaan vaihdella hyvinkin paljon. Esimerkiksi pelien sisällä tapahtuu huomattavasti enemmän syöttöjä kuin laukauksia tai erikoistilanteita. Tämän takia malleissa käytettävä data voi olla jakautunut epätasaisesti. Datajakauman epätasapaino saattaa vaikuttaa mallien oppimiseen ja ennustetarkkuuteen. (Yin, Sinnott & Jayaputera 2024)

Näiden edellä mainittujen tutkimusten avulla voimme todeta, että korkealaatuisen datan keräämisen ja tarkoin valittujen mittareiden avulla voidaan luoda harjoittelua tukevia tekoälymalleja. Näiden mallien avulla pelaajien harjoittelua voidaan optimoida, sekä tehostaa pelaajien kehitystä.

3 Tekoälyn hyödyntäminen jalkapalloilijan palautumisessa

Edellisessä luvussa käsiteltiin sitä, kuinka tekoälyllä voidaan vaikuttaa pelaajan harjoitteluun. Tämä ei kuitenkaan ole pelaajakehityksen ainoa osa-alue, jossa tekoälyä tai tekoälymalleja voidaan hyödyntää. Tässä luvussa käsittelemme sitä, kuinka tekoälyä voidaan sen eri muodoissa hyödyntää pelaajan palautumisessa ja sen optimoinnissa. Luku 3 vastaa siis alatutkimuskysymykseen ”Kuinka tekoälyä voidaan hyödyntää pelaajan palautumisessa?”.

Kuten todettua, tekoälyä voidaan hyödyntää urheilussa ja jalkapallossa muuhunkin kuin pelkkään harjoitteluun ja suorituksen arviointiin. Tekoälyä ja sen sovelluksia voidaan hyödyntää myös urheilijan terveyden ja hyvinvoinnin edistämiseksi. Loukkaantumisten tunnistaminen, ehkäiseminen ja loukkaantumisriskin vähentäminen voi olla mahdollista hyödyntämällä tekoälyä (Rossi ym. 2022). Rasituksen ja palautumisen välisen suhteen ymmärtäminen on tärkeää, jotta loukkaantumisia voidaan pyrkiä vähentämään. Tämän suhteen tunnistaminen auttaa luomaan parempia palautusmetodeja, jotka voivat vähentää loukkaantumisriskejä (Munoz-Macho, Domínguez-Morales & Sevillano-Ramos 2024). Myös ravinnolla, ruokavaliolla ja elämäntavoilla on suuri merkitys urheilijan palautumisprosessissa. Oikeanlaisen ravinnon kuten hiilihydraattien riittävä saanti saattaa parantaa urheilijan palautumista (Rothschild ym. 2024).

Kuormituksen määrä vaikuttaa merkittävästi urheilijan suorituskykyyn sekä palautumiseen. Tästä esimerkkinä tutkimus, jossa tarkasteltiin kuinka Covid-19 pandemian aiheuttama Euroopan huippusarjojen sulkeminen, vaikutti pelaajan suorituskykyyn. Omatoiminen harjoittelu, pitkäksi venynyt ottelutauko sekä vähäinen valmistautuminen alkavaan kauteen nostivat pelaajien stressitasoja. Lisääntynyt kuormituksen määrä aiheutti palautumattomuutta ja pelaajien suorituskyky laski. Esimerkiksi stressitasoja mittaavien hormonien määrä oli koko kauden korkeampi kuin normaalilla kaudella. Normaalin kauden aikana aerobinen kunto myös paranee kauden aikana, mutta näin ei kuitenkaan käynyt tauon jälkeisellä kaudella. (My ym. 2023)

Loukkaantumisten arvioiminen ja kuntouttaminen on erittäin tärkeää hoitaa huolellisesti, jotta välttyttäisiin takaiskuilta sekä riski loukkaantua uudelleen vältettäisiin. Hoito ja kuntouttamisprosessin hoitaa lääkäri tai muu ammattilainen, mutta tähän avuksi koneoppiminen voi olla erittäin tehokas työkalu (Skoki ym. 2023). Etenkin nuorilla pelaajilla, joiden fyysinen ja henkinen kehitys ei ole vielä valmis, on erityisen tärkeää huolehtia kuormituksen määrästä. Näin loukkaantumisilta voidaan pyrkiä välttymään, eivätkä ne hidasta pelaajan kehitystä (Teixeira ym. 2024).

Fyysisen palautumisen lisäksi on tärkeää panostaa henkiseen palautumiseen. Myös uupumisen välttäminen on tärkeää. Stressi ja väsymys vaikuttavat negatiivisesti suorituskykyyn. Tekoälyn malleja hyödyntämällä voidaan pyrkiä havaitsemaan milloin psyykinen kuormitus on kasvanut siihen pisteeseen, että se alkaa vaikuttamaan pelaajan suoritukseen ja valppauteen (Teixeira ym. 2024).

Palautumiseen ja rasituksen arvioimiseen hyväksikäytettävää tekoälyä ei ole käytetty ainoastaan jalkapallossa, vaan myös muissa urheilulajeissa. Esimerkiksi tässä Rothschildin ja kumppaneiden (2024) tutkimuksessa tutkittiin kestävyysjuoksijoita, ja kuinka koneoppimismallien avulla pystyttiin tehokkaammin arvioimaan palautumisen tilaa ja räsitusta.

Loukkaantumisia sattuu usein, eikä niiltä oikeastaan voi välttyä. Yleisimpiä ovat erilaiset lihasperäiset loukkaantumiset (Skoki ym. 2023). Tästä huolimatta pelaajille saattaa käydä myös loukkaantumisia, joihin ei liity kontaktia. Pahimpia näistä ovat sairaskohtaukset, joita on sattunut aivan huippujalkapallon korkeimmalla sarjatasolla, kuten Christian Eriksenille. Vuoden 2020 Euroopan mestaruuskilpailuissa Eriksen lyyhistyi kentälle saatuaan sydänkohtauksen. Hyvän ja nopean hoidon avulla Eriksen kuitenkin selvisi (Ferrell, Khojasteh & Vassar 2022).

Loukkaantumisten ennustettavuutta voidaan pyrkiä parantamaan tekoälyn avulla, ja jalkapalloilijoiden terveydentilan seuraamisessa ei kannata keskittyä pelkkään ulkoiseen räsitukseen. Tekoälypohjaisten mallien avulla voidaan tarkemmin seurata pelaajan terveydentilaan liittyviä yksilöllisiä piirteitä. Tällä tavoin voidaan pelaajille rakentaa kokonaisvaltainen kuva hänen palautumisestaan ja hyvinvoinnistaan (Rossi ym. 2023).

3.1 Datan kerääminen

Jotta voimme ymmärtää tekoälymallien toimintaperiaatteet ja niiden vaikutusmahdollisuudet, on tärkeää ymmärtää datan keräämiseen käytetyt menetelmät. Tarkoituksena on ymmärtää datan merkitys osana mallien toimivuutta sekä datan vaikutus niiden tarkkuuteen.

Skokin ja kumppaneiden (2023) lihasvammoja käsittelevässä tutkimuksessa dataa kerättiin kahden vuoden ajan ammattijalkapallojoukkueelta. Tutkimuksessa data kerättiin kuitenkin manuaalisesti tiedostoon, eikä tekoälyä käytetty itse datan keruuseen, vaan päätöksenteon tueksi. Tutkittavan joukkueen nimeä ei ole mainittu, mutta tutkimuksessa oli kyse Euroopassa pelaavasta huippujoukkueesta. Loukkaantumisten määrää seurattiin ympäri vuoden, eli sekä kauden aikana, että kauden jälkeenkin. Tutkimukseen kuului 41 joukkueen pelaajaa ja jakson aikana

loukkaantumisia oli yhteensä 84. Samalla pelaajalla saattoi olla enemmän kuin yksi loukkaantuminen ajanjaksolla.

Palautumista käsittelevissä tutkimuksissa tutkimuskoko, pelaajien taso ja demografit vaihtelevat paljon. Tämä puoltaa tekoälyn vaikutusta pelaajien hyvinvointiin. Tutkimuksissa kohderyhminä ovat toimineet esimerkiksi Serie C:n eli Italian kolmannen sarjatason joukkueista kerätty 101 miespelaajaa. Dataa tässä tutkimuksessa oli kerätty koko kauden ajalta (Carlo Simonelli & Rossi 2025). Myös nais- ja junioripelaajien palautumista tekoälyn avulla on tutkittu. Teixeira ja kumppaneiden (2024) tutkimuksessa kohderyhmänä toimi 60 alle 20-vuotiasta portugalilaisen junioriakatemian pelaajaa. Naispelaajilla tehdyssä tutkimuksessa kohderyhmä taas koostui kahdestakymmenestä Espanjan pääsarjatason eliittipelaajasta, joista jokainen oli pelannut vähintään 30 ottelua (Barba ym. 2025).

Datan jatkuva kerääminen mahdollistaa loukkaantumisriskin mahdollisen vähentämisen. Nykyään yleistyvä puettava teknologia mahdollistaa datan keräämisen jokaiselta pelaajalta suorituksen aikana. Näitä voivat olla esimerkiksi erilaiset pelaajiin kiinnitettävät sykemittarit. Lisäksi kansainvälisen paikanninsysteemin eli GPS:ssän avulla voidaan seurata pelaajan liikkumista. (Teixeira ym. 2024). Puettavaa teknologiaa hyödyntävät myös esimerkiksi älysormukset, joita käytettiin eräässä naisjalkapalloilijoiden unenlaatua mittaavassa tutkimuksessa. Kyseisessä tutkimuksessa hyödynnettiin Suomalaista Oura -merkkistä älysormusta (Barba ym. 2025). Muissa tutkimuksissa on hyödynnetty samanlaista teknologiaa datan keruuseen. Esimerkiksi älykellojen ja -rannekkeiden avulla on mitattu unen pituutta (Rothschild ym. 2024).

Dataa voidaan myös kerätä perinteisemmillä menetelmillä kuten kyselytutkimuksilla. Ongelmana näissä on kuitenkin se, että kyselyissä tulos on subjektiivinen. Tarkoituksena on lähtökohtaisesti tuottaa mahdollisimman objektiivista dataa. Kyselyitä on kuitenkin hyväksikäytetty esimerkiksi oman palautumisen tai unen laadun arviointiin. (Suppiah ym. 2022; Carlo Simonelli & Rossi 2025; Rossi ym. 2022)

Unenlaatua arvioivassa tutkimuksessa 115 nuorta, alle 21-vuotiasta kilpatason urheilijaa Singaporen alueella vastasi kyselyyn uni- ja harjoittelurytmeistään. Kyselyyn vastattiin paperisella lomakkeella. Tarkoituksena datan pohjalta oli luoda tekoälyn malli, joka osaisi tunnistaa hyvään unenlaatuun liittyviä tekijöitä. (Suppiah ym. 2022)

3.2 Mittauskohteet

Urheilijan fyysisen ja psyykkisen hyvinvoinnin mittaamiseksi voidaan käyttää monia eri mittareita. Mittauskohteena voi käytännössä olla mikä vain, jonka voidaan katsoa vaikuttavan pelaajan hyvinvointiin. Tästä syystä hyvinvoinnin mittaaminen voi olla hyvin subjektiivista, palautumisen arvioimiseen taas löytyy monia universaaleja mittareita. Tässä aluvuussa käsittelemme keskeisiä palautumiseen käytettäviä mittareita, joissa tekoälyä on käytetty hyödyksi.

Tekoälyn avulla saatujen tulosten luotettavuuden kannalta on hyvä tiedostaa, että tekoäly tekee päätökset annetun datan pohjalta. Tästä syystä mittauskohteiden valinnalla on suuri merkitys tiedon paikkansapitävyyden kannalta. Rossin ja kumppaneiden (2022) tutkimuksessa tämä käy ilmi. Tutkimuksessa luotujen mallien toimivuutta ja tarkkuutta on testattu luomalla satunnaisia arvoja antavia malleja. Näiden satunnaismallien avulla todettiin, että koulutetut mallit osaavat ennustaa paremmalla tarkkuudella, kuin satunnaiset mallit.

Fyysisen kunnon ja suorituskyvyn arvioimiseen voidaan käyttää monia eri mittareita. Näitä voi olla esimerkiksi kehon koostumusta mittaavia arvoja kuten paino, rasvamassa, lihasmassa sekä veren avulla mitattavia arvoja kuten kortisolia, testosteronia tai laktaattia (My ym. 2023) sekä hemoglobiinia, ferritiiniä ja punasolujen määrää (Rossi ym. 2023). Lisäksi GPS-laitteiden avulla mitattuja juoksunopeuksia, juoksumääriä, sekä kiihdytysten ja suunnanmuutosten määrää voidaan käyttää fyysisen suorituskyvyn ja rasituksen mittaamiseen. Myös sykevaihtelua, maksimi- ja minimisykettä voidaan käyttää suorituskyvyn mittareina (Teixeira ym. 2024).

Useissa tutkimuksissa pelaajia pyydettiin itse arvioimaan omaa jaksamistaan ja palautumista kyselytutkimuksilla. (Rossi ym. 2022; Carlo Simonelli & Rossi 2025). Kyselytutkimuksissa hyödynnettiin esimerkiksi pelaajan subjektiivista kokemusta omasta rasituksesta. RPE eli harjoituksen koettu rasituksen aste 1–10 on yksi keino antaa pelaajan itse arvioida omaa tilaansa. Hyvinvointi-indeksin avulla pelaaja voi subjektiivisesti arvioida omaa palautumisen tilaansa. Rossin ja kumppaneiden (2022) tutkimuksessa seurattiin pelaajien kokemusta stressistä, unesta, lihasrakuudesta sekä väsymyksestä. Näistä luotiin yksi yhteinen hyvinvointi-indeksi. Simonellin ja Rossin (2025) tutkimuksessa käytettiin samantyylistä menetelmää, jossa pelaajat vastasivat omaan hyvinvointiin ja palautumiseen liittyviin kyselyihin. Myös tässä tutkimuksessa hyödynnettiin RPE-lukemaa.

Unta ja sen laatua palautumisen näkökulmasta on myös mitattu monilla eri mittareilla. Suppiahin ja kumppaneiden (2022) tutkimuksessa nuorten urheilijoiden unenlaatua arvioitiin seuraavasti: PSQI

eli Pittsburgh Sleep Quality Indeks on 19 kysymyksestä koostuva subjektiivinen kysely, jossa vastaaja itse arvioi oman unenlaatuensa. Tämä ja 29 osainen nukkumisympäristön kysymyspatteri olivat osa tutkimuksen mittaristoa. Lisäksi urheilijoiden harjoittelutottumukset ja demografiset tiedot kerättiin osaksi tutkimusaineistoa. Toisessa unen palauttavaa vaikutusta arvioivassa tutkimuksessa mitattiin sekä unen määrää, että laatua seuraavin mittarein. Laatuun vaikuttivat unen eri vaiheiden määrät, eli REM, syväuni ja kevyt uni. Lisäksi myös nukahtamisen kesto, liikkumisen määrä ja hereillä oloaika olivat laadun mittareita (Barba ym. 2025).

3.3 Tekoälyn käyttö

Koneoppimisen malleja on monenlaisia ja toiset ovat tarkempia kuin toiset. Tässä luvussa tarkastelemme käytettyjä malleja, joita pelaajan palautumisen ennustamisessa ja arvioimisessa on hyödynnetty. Monissa tuloksissa korostuu gradienttitehostuksen tarkkuus ennustaa annetun datan perusteella. (Rossi ym. 2022; Munoz-Macho, Domínguez-Morales & Sevillano-Ramos 2024; Skoki ym. 2023) Gradienttitehostus perustuu algoritmiin, joka luo sarjan niin sanottuja päätöspuita. Sarjassa jokainen puu pyrkii minimoimaan virheen ja korjaamaan näin edellisen puun. (Rossi ym. 2022) Koneoppiminen yhdistettynä ihmisen ammatilliseen asiantuntemukseen saattaa vielä toistaiseksi luoda parhaan mahdollisen lopputuloksen. Esimerkiksi jalkapalloilijoiden lihasperäisiä loukkaantumisia ja loukkaantumisen paluuaikoja tutkivassa tutkimuksessa huomattiin, että yhdessä lääketieteen ammattilaisen ja koneoppimisen avulla saatiin tarkin arvio pelaajan loukkaantumisen aikataulusta. (Skoki ym. 2023)

Gradienttitehostuksen lisäksi myös satunnais- ja päätöspuualgoritmit ovat erittäin tehokkaita. Esimerkiksi nuorten pelaajien palautumista seuranneessa tutkimuksessa koneoppimisen avulla saavutettiin jopa 99 % tarkkuus käyttämällä näitä kahta koneoppimismallia. Tämänkaltaisella tiedolla on suuri arvo. Näiden mallien avulla voidaan löytää ne pelaajat, joiden palautuminen ei vastaa harjoituksen kuormitusta ja ovat alipalautuneita. Tämän jälkeen heidän harjoitteluansa voidaan muokata kevyemmäksi tai antaa pelaajan kokonaan levätä. (Teixeira ym. 2024)

Pelaajan subjektiivista kokemusta raskuudesta on myös tarkasteltu koneoppimismallien avulla ja tarkemmin ottaen sitä, kuinka subjektiiviset arviot vaikuttavat palautumiseen ja kuinka niiden avulla pystytään ennustamaan palautumista. (Carlo Simonelli & Rossi 2025). Subjektiiviset arvot eivät kuitenkaan anna todenmukaista kuvaa useasti, ja onkin todettu, että urheilijat usein yliarvioivat omaa unenlaatua ja -pituutta (Barba ym. 2025).

Veriarvot ovat erinomainen mittauskohde, kun halutaan arvioida palautumista ja erityisesti välttää loukkaantumisia. Veriarvot mahdollistavat yksilöllisemmän palautumisen arvioimisen (Rossi ym. 2023). Tekoälyn hyödyntäminen veriarvojen analysoinnissa on todettu erityisen hyödylliseksi loukkaantumisten ennustamisessa ja viimekädessä niiden välttämässä. (Munoz-Macho, Domínguez-Morales & Sevillano-Ramos 2024). Veriarvot ovatkin parantaneet tekoälymallien tarkkuutta. Esimerkiksi tässä Rossin ja kumppaneiden tutkimuksessa (2023) veriarvojen sisällyttäminen muuttujana harjoituskuorman lisäksi, paransi tekoälymallin tarkkuutta melkein 15 prosentilla. Samaan lopputulokseen päädyttiin myös toisessa samankaltaisessa tutkimuksessa, jossa tekoälymalli sisällytti veriarvot osaksi pelaajien kuormitusdataa. Veriarvot sisällyttänyt malli antoi siis tarkemman tuloksen kuin mallit ilman veriarvoja. (Munoz-Macho, Domínguez-Morales & Sevillano-Ramos 2024).

Kuten todettua, unella ja sen laadulla on erittäin suuri merkitys palautumisprosessissa. Tekoälymallien avulla unen ennustaminen on entistä tarkempaa ja mallien avulla voidaan havaita, mitkä tekijät vaikuttavat unen laatuun positiivisesti ja mitkä negatiivisesti. Negatiivisia tekijöitä ovat esimerkiksi aikaiset aamuharjoitukset, sekä älylaitteiden katsominen ennen nukkumista tai yöllä. Kyseisiä koneoppimismalleja hyödyntämällä valmentajilla on mahdollisuus auttaa pelaajaa kehittämään parempia nukkumisrutiineja. (Suppiah ym. 2022)

Tekoälypohjaisten työkalujen avulla voidaan seurata urheilijan yksilöllisiä unirytmeyksiä, jotta itse urheilija voisi ymmärtää paremmin unen laatuaan ja sitä kautta parantaa palautumista (Barba ym. 2025). Unen merkitys onkin havaittu olevan yksi tärkeimpiä tekijöitä palautumisen kannalta, vaikka eroja saattaa tuki yksilöiden välillä olla (Rothschild ym. 2024). Unen laatuun vaikuttaa siis muitakin seikkoja, kuin pelkkä nukutun ajan pituus. Siksi olisi tärkeää, ettei unen laatua seurattaessa tukeuduttaisi vain yhteen mittariin, vaan unen laatua tulisi tarkastella kokonaisuutena. Tämän pohjalta olisi parempi valmius tehdä mahdollisia muutoksia unitottumuksiin. Tätä prosessia voisi tekoälyn avulla pyrkiä tehostamaan ja täten huomioimaan yksilön tarpeet paremmin (Barba ym. 2025).

Ravinnon merkitystä ei voida sivuuttaa puhuttaessa kokonaisvaltaisesta palautumisesta. Riittävän energian ja etenkin hiilihydraattien saaminen on tärkeää urheilijalle, suorituskyvyn säilyttämiseksi. Tästä syystä urheilijoiden onkin jatkuvasti yhdessä ammattilaisten kanssa kyettävä varmistamaan oikeinlainen ja riittävä ravinto. Ravinnon seuraamisessa apuna voi nykyään kuitenkin käyttää suosiotaan kasvattaneita mobiiliapplikaatioita (Rothschild ym. 2024). Osa näistä applikaatioista

hyödyntää tekoälyä osana niiden toiminnallisuutta. Näitä tekoälyä käyttäviä mobiiliapplikaatioita voi hyödyntää urheilijoiden lisäksi myös tavalliset ihmiset.

Edellä mainittujen lisäksi tulee palautumisessa ottaa huomioon myös pelaajan psyykinen jaksaminen. Kuten jo aiemmin todettua Bonettin ja kumppaneiden (2025) tutkimus osoitti eliittitason jalkapalloilijoiden omaavan kehittyneemmät kognitiiviset kyvyt. Tämä voi entisestään korostaa psyykkisen palautumisen merkitystä. Hermoston riittävä palautuminen voi siis parantaa suorituskyyä ja näin ollen vaikuttaa pelisuorituksiin. Toisaalta riittämätön hermoston palautuminen voi taas heikentää suorituskyyä.

Voimmekin ajatella, että yhdistelemällä jo olemassa olevia malleja voitaisiin luoda entistä kattavampia tekoälyyn pohjautuvia sovelluksia, jotka voisivat ottaa huomioon entistä enemmän osaluaita. Esimerkiksi tavalla, jota Rossi ja kumppanit (2023) käyttivät tutkimuksessaan, saaden entistä tarkemman palautumisen ennustettavuuden. Samaa logiikkaa voisi soveltaa yhä useampaan tekoälymalliin, tehden niistä entistä tarkempia ja luotettavampia arvioidessa pelaajan palautumista.

Suurien datamäärien käsittelyssä myös tietoturvan merkitys korostuu. Tekoälymallien avulla laskentatehoa voidaan kasvattaa samalla parantaen tietoturvallisuutta. Parempi laskentateho ja tietoturva luo pohjan paremmille pelaajanhallintajärjestelmille, joiden avulla pelaajien terveystietoja voidaan käsitellä. (Pu ym. 2023). Datan määrä ei kuitenkaan ole tärkeämpi kuin se, että datan laatu on varmasti tarpeeksi korkeatasoista. Vajavainen data voi laskea tekoälymallien tarkkuutta ja näin tuottaa vääristyneitä tuloksia. (Liu & Liu 2025). Datan esikäsittelyn avulla datan tarkkuutta voidaan toisaalta parantaa. Esikäsittelyn avulla luotu laadukas data on jo itsessään arvokasta, mutta sen hyödyntäminen tekoälyjärjestelmissä voi luoda entistä suuremman potentiaalin sen käytölle. (Yang & Feng 2024).

Tietoturvallisuuden merkitys korostuu lisäksi entisestään uusien järjestelmien käytössä, sillä pelaajista kerätään runsaasti henkilökohtaista dataa sekä tietoja. Yksityisyysuojan ja pelaajien turvallisuuden takaamiseksi laadukas ja turvallinen tiedon säilytys onkin välttämätöntä, etenkin tulevaisuudessa datamäärien kasvaessa entisestään. (Pu ym. 2023)

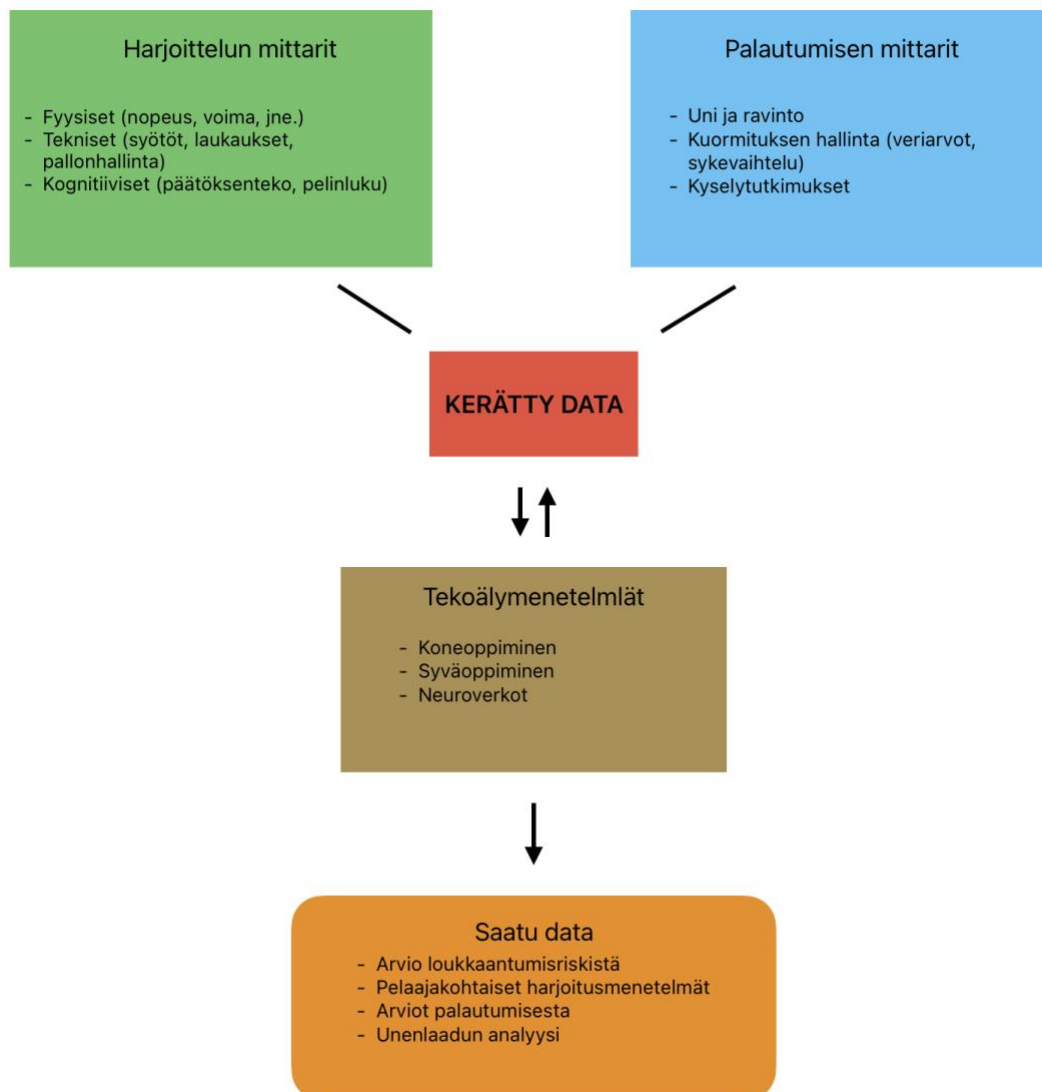
Moni tutkimus puoltaa sitä, että tekoälyn avulla voidaan löytää keinoja parantaa pelaajien hyvinvointia ja palautumista. Toisaalta osassa tutkimuksia on myös nostettu esiin se, että kyseinen tutkimusalue on vielä suhteellisen uusi ja siksi aiheesta tarvitaankin lisää tutkimusta (Rossi ym. 2022). Käyttämällä suurempia otoskokoja tai kohderyhmää, voidaan tulevaisuudessa luoda entistä

kattavimpia tutkimuksia. Näiden tutkimusten tulosten avulla voitaisiin entistä varmemmin vastata alatutkimuskysymykseemme ”kuinka tekoälyä voidaan hyödyntää pelaajan palautumisessa?”.

4 Yhteenveto ja johtopäätökset

Jalkapalloilijan harjoittelu ja palautuminen eivät ole erillisiä toisistaan, vaan toimivat vuorovaikutuksessa. Parempi palautuminen johtaa parempiin suorituksiin. Tekoäly tarjoaa keinoja yhdistää nämä osa-alueet toisiinsa ja tehostaa niiden välistä yhteyttä. (Rossi ym. 2022)

Kuvan 2 avulla pyritään havainnollistamaan, miten tekoälyä voidaan hyödyntää palautumisen ja harjoittelun välillä sekä kuinka nämä kaksi osa-aluetta nivoutuvat toisiinsa.



Kuva 2 Harjoittelun ja palautumisen yhteys

Palautumisen ja suorituskyvyn arvioiminen sekä analysointi oli ennen tekoälyä ihmisistä riippuvainen, ja sen mittaaminen perustui perinteisiin menetelmiin. Väsymystä saatettiin mitata peliminuuteilla ja suorituskykyä esimerkiksi maalien avulla. Nämä mittarit ovat vielä nykyäänkin

käytössä, mutta uuden teknologian ja tekoölyn avulla saatava kilpailuetu voi olla merkittävää (Teixeira ym. 2024). Laajaa datamäärää ja tekoölyä hyödyntämällä voidaan pelaajien harjoittelua säädellä suorituskyvyn parantamiseksi, huomioimalla pelaajan rasitus ja optimoimalla palautuminen (Rossi ym. 2022).

Palautumisessa yksilöiden välillä on eroja ja siksi jokaisen pelaajan tulisi saada itselleen parhaalla tavalla soveltuva palautuminen ja ravinto (Rothschild ym. 2024). Pelaajan tulisi saada itselleen suunniteltu harjoitusohjelma, joka huomioi pelaajan kehitystarpeet ja fyysiset ominaisuudet. (Zhou, Chen & Xu 2022). Eri lähteistä kerättyä monimuotoista dataa yhdistelemällä voidaan luoda kattavia tekoölymalleja. Mallien avulla pelaajia voidaan seurata entistä tarkemmin ja yksityiskohtaisemmin, sekä käsitellä pelaajien kehitystä. (Liu & Liu 2025).

Tällä hetkellä tekoölysovelluksissa hyödynnetään paljon kone- ja syväoppimismalleja. Näiden mallien avulla on jo todettu olevan merkittävää hyötyä järjestelmien luomisessa sekä datan käsittelyssä. Kehittyneempien neuroverkkojen voidaan kuitenkin odottaa ennen pitkää vielä ohittavan näiden mallien tehokkuus. Neuroverkkojen autonomisuus sekä niiden käsittelykerrosten kompleksisuus mahdollistaa vielä tehokkaamman laskentatehon (Krstić ym. 2023). Tuoreessa tutkimuksessa testattiinkin, kuinka hyvin kehittyneemmät neuroverkkoon pohjautuvat ohjelmat suoriutuivat verrattuna perinteisiin tekoölyn menetelmiin. Nämä tulokset osoittivat, että kehittyneimmillä tekoölymalleilla voidaan saavuttaa merkittävää etua (Li ym. 2025).

Tässä tutkielmassa vastattiin kuinka tekoölyn ja sen mallien avulla pelaajien kehitystä voidaan mahdollisesti parantaa harjoittelun ja tekoölyn saralla. Luvussa kaksi keskityttiin etsimään tekoölyn malleja ja mittareita, joiden avulla voitaisiin tarkastella tekoölyn vaikutusta pelaajan harjoittelun edistämässä. Alatutkimuskysymyksen avulla näitä pyrittiin analysoimaan sekä tekemään johtopäätöksiä tekoölyn roolista. Luku kolme rakentui hyvin samalla periaatteella mutta tarkastelussa oli tekoölyn rooli palautumisessa harjoittelun sijaan. Lisäksi luvussa sivuttiin vielä yleisesti datan merkitystä mallien käytön ja paikkansapitävyyden kannalta.

Tämän tutkielman pohjalta voidaan todeta, että tekoölyn avulla voidaan luoda menetelmiä, jotka saattavat parantaa pelaajan harjoittelua sekä palautumista. Jotta voidaan todeta tekoölyn avulla optimoidun harjoittelun ja palautumisen olevan toisiaan vahvistavia tekijöitä, tarvitsee tulevaisuudessa niiden välistä yhteyttä tutkia lisää. Lisäksi on hyvä ymmärtää myös tämänhetkisten tutkimusten rajallisuus. Datan määrä ja laatu sen keräämismenetelmien ja kerääjien välillä voi vaihdella suuresti. Tekoölyn käyttö ja datan kerääminen on kuten aikaisemmin todettu, hyvin resurssi-intensiivistä. Lisäksi nykyisten tutkimusten kohderyhmät rajoittuvat pienehköihin

otoskokoihin. Lisää ja laajempaa tutkimusta tarvitaankin tulevaisuudessa, nähdäksemme kuinka suuri potentiaali tekoälymenetelmien hyödyntämisellä pelaajien kehityksessä on.

Lisäksi voidaan todeta, että tekoälyn hyödyntäminen jalkapalloilijoiden kehityksessä perustuu toistaiseksi vielä hyvin paljon ihmisen ja tekoälyn väliseen yhteistyöhön. Emme myöskään osaa sanoa, voidaanko tämä kehitys automatisoida kokonaan siten, että inhimillistä toimijaa ei enää tarvita osaksi tätä prosessia. Vaikka kattavaa dataa pystyttäisiinkin keräämään sekä analysoimaan ilman käyttäjää, on tämän informaation kulkeuduttava ymmärrettävään muotoon pelaajalle asti. Jotta kehitys olisi mahdollista maksimoida, voidaan ajatella, että pelaajan ei tarvitsisi keskittyä muuhun kuin itse harjoitteluun. Erityisen tärkeää onkin, että tekoälyn avulla saatua dataa analysoi ja arvioivat ammattilaiset, jotta sitä voidaan hyödyntää parhaalla mahdollisella tavalla.

Tulevaisuudessa tutkimuksia voitaisiin tehdä yhä suurempia otoskokoja käyttäen, keskittyen erityisesti huippujalkapallojoukkueisiin. Suurempien resurssien hyödyntäminen näiden joukkueiden osalta voisi avata mahdollisuuksia tuottaa entistä yksityiskohtaisempaa sekä laadukkaampaa dataa juuri huippujalkapallon kontekstissa. On kuitenkin myös pidettävä mielessä se, että jokaisella joukkueilla on omat intressit, eikä kaikkea haluta julkisen tutkimuksen piiriin. Emme voi siis tarkkaan sanoa, kuinka paljon tekoälymenetelmiä huippujoukkueilla on jo käytössä.

Lähteet

- Aldoseri, Abdulaziz, Khalifa N. Al-Khalifa & Abdel Magid Hamouda. 2023. "Re-Thinking Data Strategy and Integration for Artificial Intelligence: Concepts, Opportunities, and Challenges". *Applied Sciences* 13 (12). <https://doi.org/10.3390/app13127082>.
- Barba, Eider, David Casamichana, Pedro Figueiredo, Fábio Yuzo Nakamura & Julen Castellano. 2025. "The Use of Principal Component Analysis for Reduction in Sleep Quality and Quantity Data in Female Professional Soccer". *Sensors* 25 (1). <https://doi.org/10.3390/s25010148>.
- Bonetti, Leonardo, Torbjörn Vestberg, Reza Jafari, Debora Seghezzi, Martin Ingvar, Morten L. Kringelbach, Alberto Filgueiras & Predrag Petrovic. 2025. "Decoding the elite soccer player's psychological profile". *Proceedings of the National Academy of Sciences* 122 (3): e2415126122. <https://doi.org/10.1073/pnas.2415126122>.
- Carlo Simonelli, Damiano Formenti & Alessio Rossi. 2025. "Subjective recovery in professional soccer players: A machine learning and mediation approach". *Journal of Sports Sciences* 0 (0): 1–8. <https://doi.org/10.1080/02640414.2025.2461932>.
- Cefis, Mattia & Maurizio Carpita. 2024. "A new xG model for football analytics". *Journal of the Operational Research Society*, helmikuuta. <https://doi.org/10.1080/01605682.2024.2323669>.
- Emmert-Streib, Frank, Olli Yli-Harja & Matthias Dehmer. 2020. "Artificial Intelligence: A Clarification of Misconceptions, Myths and Desired Status". *Frontiers in Artificial Intelligence* 3. <https://doi.org/10.3389/frai.2020.524339>.
- Ferrell, M. C., J. Khojasteh & M. Vassar. 2022. "Public awareness of cardiopulmonary resuscitation and cardiac arrest in association with Christian Eriksen". *Public Health* 212:42–45. <https://doi.org/10.1016/j.puhe.2022.08.013>.
- Krstić, Dušan, Teodora Vučković, Dusanka Dakic, Sonja Ristic & Darko Stefanović. 2023. "The Application and Impact of Artificial Intelligence on Sports Performance Improvement: A Systematic Literature Review". 2023 4th International Conference on Communications, Information, Electronic and Energy Systems (CIEES), 1–8. <https://doi.org/10.1109/CIEES58940.2023.10378750>.
- Li, Tong, Chenjia Bai, Kang Xu, Chen Chu, Peican Zhu & Zhen Wang. 2025. "Skill matters: Dynamic skill learning for multi-agent cooperative reinforcement learning". *Neural Networks* 181:106852. <https://doi.org/10.1016/j.neunet.2024.106852>.
- Liu, Chengjie & Hongbing Liu. 2025. "The application of artificial intelligence technology in the tactical training of football players". *Entertainment Computing* 52:100913. <https://doi.org/10.1016/j.entcom.2024.100913>.
- Mishra, Akanksha. 2024. "A Comprehensive Review of Artificial Intelligence and Machine Learning : Concepts, Trends, and Applications". *International Journal of Scientific Research in Science and Technology* 11 (syyskuuta):126–42. <https://doi.org/10.32628/IJSRST2411587>.
- Monsees, Leah M. 2025. ""There is a lot more potential" - practitioner perspectives on technology and data-driven talent identification, selection, and development in a German Bundesliga academy". *International Journal of Sports Science & Coaching*, tammikuuta, 17479541241308519. <https://doi.org/10.1177/17479541241308519>.
- Munoz-Macho, A. A., M. J. Domínguez-Morales & J. L. Sevillano-Ramos. 2024. "Performance and healthcare analysis in elite sports teams using artificial intelligence: a scoping review". *Frontiers in Sports and Active Living* 6. <https://doi.org/10.3389/fspor.2024.1383723>.

- My, Giulia, Santo Marsigliante, Okba Selmi & Antonella Muscella. 2023. "Analysis of the COVID-19 Lockdown Impact on Biological Parameters and Physical Performance in Football Players". *Sustainability* 15 (kesäkuuta):9139. <https://doi.org/10.3390/su15119139>.
- Pappalardo, Luca, Paolo Cintia, Paolo Ferragina, Emanuele Massucco, Dino Pedreschi & Fosca Giannotti. 2019. "PlayeRank: Data-driven Performance Evaluation and Player Ranking in Soccer via a Machine Learning Approach". *ACM Trans. Intell. Syst. Technol.* 10 (5). <https://doi.org/10.1145/3343172>.
- Pu, Chunwang, Jun Zhou, Jian Sun & Jianpeng Zhang. 2023. "Football Player Injury Full-Cycle Management and Monitoring System Based on Blockchain and Machine Learning Algorithm". *International Journal of Computational Intelligence Systems* 16 (maaliskuuta). <https://doi.org/10.1007/s44196-023-00217-6>.
- Rossi, Alessio, Luca Pappalardo, Cristoforo Filetti & Paolo Cintia. 2023. "Blood sample profile helps to injury forecasting in elite soccer players". *Sport Sciences for Health* 19 (1): 285–96. <https://doi.org/10.1007/s11332-022-00932-1>.
- Rossi, Alessio, Enrico Perri, Luca Pappalardo, Paolo Cintia, Giampietro Alberti, Darcy Norman & F. Marcello Iaia. 2022. "Wellness Forecasting by External and Internal Workloads in Elite Soccer Players: A Machine Learning Approach". *Frontiers in Physiology* 13. <https://doi.org/10.3389/fphys.2022.896928>.
- Rothschild, Jeffrey A., Tom Stewart, Andrew E. Kilding & Daniel J. Plews. 2024. "Predicting daily recovery during long-term endurance training using machine learning analysis". *European Journal of Applied Physiology* 124 (11): 3279–90. <https://doi.org/10.1007/s00421-024-05530-2>.
- Siukonen, Markku, Risto Rantala & kustantaja. Otava kustannusosakeyhtiö. 2006. *Kaikki urheilusta. Kaikki urheilusta. Mitä-missä-milloin : kansalaisen tietokirjat*. Helsingissä: Otava.
- Skoki, Arian, Mateja Napravnik, Marin Polonijo, Ivan Štajduhar & Jonatan Lerga. 2023. "Revolutionizing Soccer Injury Management: Predicting Muscle Injury Recovery Time Using ML". *Applied Sciences* 13 (10). <https://doi.org/10.3390/app13106222>.
- Sneha, Santoshi, B. S. Prithvi, M. Niranjanamurthy, H. K. Kiran Kumar & P. Dayananda. 2024. "Machine Learning Based Assessment of Elite Football Players Based on Anthropometric and Motor Fitness Parameters with Regard to their Playing Positions". *SN Computer Science* 5 (8): 974. <https://doi.org/10.1007/s42979-024-03261-x>.
- Suppiah, Haresh T., Richard Swinbourne, Jericho Wee, Qixiang He, Johan Pion, Matthew W. Driller, Paul B. Gastin & David L. Carey. 2022. "Predicting Youth Athlete Sleep Quality and the Development of a Translational Tool to Inform Practitioner Decision Making". *Sports Health* 14 (1): 77–83. <https://doi.org/10.1177/19417381211056078>.
- Teixeira, José E., Samuel Encarnação, Luís Branquinho, Ricardo Ferraz, Daniel L. Portella, Diogo Monteiro, Ryland Morgans, Tiago M. Barbosa, António M. Monteiro & Pedro Forte. 2024. "Classification of recovery states in U15, U17, and U19 sub-elite football players: a machine learning approach". *Frontiers in Psychology* 15. <https://doi.org/10.3389/fpsyg.2024.1447968>.
- Wang, Pei. 2019. "On Defining Artificial Intelligence". *Journal of Artificial General Intelligence* 10 (2): 1–37. <https://doi.org/10.2478/jagi-2019-0002>.
- Wang, Zhe, Petar Veličković, Daniel Hennes, Nenad Tomašev, Laurel Prince, Michael Kaisers, Yoram Bachrach, ym. 2024. "TacticAI: an AI assistant for football tactics". *Nature Communications* 15 (1): 1906. <https://doi.org/10.1038/s41467-024-45965-x>.
- Xu, Zuo. 2025. "Light sensors and infrared radiation images based on artificial intelligence data mining for football performance evaluation and prediction". *Thermal Science and Engineering Progress* 58:103250. <https://doi.org/10.1016/j.tsep.2025.103250>.

- Yang, Guanghui & Xinyuan Feng. 2024. "Computer aided technology based on graph sample and aggregate attention network optimized for soccer teaching and training". *Journal of Big Data* 11 (1): 48. <https://doi.org/10.1186/s40537-024-00893-x>.
- Yin, Hongwei, Richard Sinnott & Glenn Jayaputera. 2024. "A survey of video-based human action recognition in team sports". *Artificial Intelligence Review* 57 (syyskuuta). <https://doi.org/10.1007/s10462-024-10934-9>.
- Zhou, Daliang, Gang Chen & Fei Xu. 2022. "Application of Deep Learning Technology in Strength Training of Football Players and Field Line Detection of Football Robots". *Frontiers in Neurorobotics* 16. <https://doi.org/10.3389/fnbot.2022.867028>.