



UNIVERSITY OF
EASTERN FINLAND

Smart Fitness kuntoilijan tukena

Tuomas Mertanen
Tietojenkäsittelytiede
Itä-Suomen yliopisto
Luonnontieteiden, metsätieteiden ja
tekniikan tiedekunta
Tietojenkäsittelytieteen laitos
6.11.2023

Itä-Suomen yliopisto, Luonnontieteiden, metsätieteiden ja tekniikan tiedekunta

Tietojenkäsittelytieteen laitos

Tietojenkäsittelytieteen koulutusohjelma

Mertanen, Tuomas A. J.: Smart Fitness kuntoilijan tukena

Pro gradu -tutkielma, 73 sivua

Tutkielman ohjaaja: Yliopistonlehtori Marko Hassinen, FT

Marraskuu 2023

Asiasanat: Älykäs kuntoilu, Esineiden internet, Tekoäly, Sosiaalinen esineiden internet

ACM-luokat (ACM Computing Classification System 2012 versio): CCS → Computing methodologies → Artificial intelligence

Tässä tutkielmassa selvitetään, mitä Smart Fitness tarkoittaa, mitä Smart Fitnessin avulla voidaan saavuttaa ja millaisia Smart Fitness -toteutuksia on olemassa. Tutkielman käytännöllisessä osuudessa tarkastellaan Smart Fitness -mobiilisovelluksia, ja selvitetään, millaisia tietoja käyttäjän on syötettävä Smart Fitness -treenisovelluksiin ja mitä ominaisuuksia Smart Fitness -treenisovellukset tarjoavat käyttäjälle. Tutkielmassa keskitytään ensisijaisesti Smart fitnessin treenaamispuoleen.

Smart Fitness on suhteellisen uusi sähköisen terveydenhuollon osa-alue. Smart Fitness -toteutuksilla on nykyään tärkeä rooli kuntoilussa ja yleisen hyvinvoinnin ylläpitämisessä. Smart Fitness jaetaan kolmeen alakategoriaan: fitness-sovellukset, fitness-seurantalaitteet ja liikeanalyysi. Fitness-sovellukset tarjoavat erilaisia ominaisuuksia, kuten ruokavalion ja treeniohjelman suunnittelua tai sosiaalisia verkko-ominaisuuksia, kuten samankaltaisten kuntoilijoiden yhdistäminen sovelluksen kautta. Fitness-seurantalaitteet luokitellaan puettaviin ja ei-puettaviin fitness-seurantalaitteisiin, ja ne keräävät kuntoilijasta dataa ja analysoivat sitä. Liikeanalyysissa kuntoilijan toiminnasta tunnistetaan liikemalleja ja suoritetaan toiminnantunnistusta. Lisäksi sosiaalisen esineiden internetin soveltamismahdollisuudet kuntoilussa vaikuttavat erittäin lupaavilta, sillä sosiaalinen esineiden internet tukee niin ihmisten

kuin esineiden välisiä suhteita. Smart Fitness -toteutukset hyödyntävät tekoälyä päätöksenteossa. Fitness-sovellusten tekoälyvalmentajat tarjoavat korvaavan ratkaisun kuntoilijoille, jotka eivät pysty hankkimaan perinteistä kuntoiluvalmentajaa. Fitness-seurantalaitteiden käytöllä on tutkimusten mukaan positiivinen vaikutus ihmisten terveyteen ja niiden suosio kasvaa. Liikeanalyysi voi auttaa valmentajia suunnittelemaan kuntoilijalle sopivia treeniohjelmia esimerkiksi loukkaantumisten ehkäisemiseksi. Tutkielman käytännöllisen osuuden perusteella Smart Fitness -treenisovellusten tekoälyvalmentajat tarvitsevat tietoa käyttäjän kehosta, treenikokemuksesta ja tavoitteista.

University of Eastern Finland, Faculty of Science, Forestry and Technology

School of Computing

Mertanen, Tuomas A. J.: Smart Fitness assisting fitness enthusiast

Master's Thesis, 73 pages

Supervisor: University Lecturer Marko Hassinen, PhD

November 2023

Keywords: Smart Fitness, Internet of Things, Artificial Intelligence, Social Internet of Things

CR Categories (ACM Computing Classification System, 2012 version): CCS → Computing methodologies → Artificial intelligence

In this thesis is examined what Smart Fitness means, what can be achieved with Smart Fitness and what kind of Smart Fitness implementations exist today. In the practical section of the thesis, Smart Fitness mobile apps are examined, and it is examined what information the user has to enter into the Smart Fitness training apps and what features the apps provide to the user. This thesis focuses primarily on the training aspect of Smart fitness.

Smart Fitness is a relatively new subtopic of e-healthcare. Today, Smart Fitness applications play an important role in fitness and general well-being. Smart Fitness falls into three subcategories: fitness apps, fitness trackers and movement analysis. Fitness apps provide various features such as diet and exercise planning or social networking features such as connecting like-minded fitness enthusiasts through the app. Fitness trackers are classified into wearable and non-wearable fitness trackers and they collect and analyze data from the exerciser. Movement analysis identifies movement patterns and performs activity recognition on the exerciser. Furthermore, the potential of the social IoT for fitness seems very promising, as the social IoT supports both human and object relationships. Smart Fitness implementations use artificial intelligence for decision making. AI coaches of fitness applications provide a substitute solution for fitness enthusiasts who cannot afford a personal trainer. The use of fitness trackers has been shown to have a positive impact on people's health and the popularity of fitness tracker is increasing. Movement analysis can help personal trainers to design training plans that are

appropriate for the exerciser and thus prevent injuries. Based on the practical section of the thesis, AI coaches of Smart Fitness training apps need information about the user's body, training experience and goals.

Alkusanat/Esipuhe

Tämä tutkielma on tehty Itä-Suomen yliopiston tietojenkäsittelytieteen laitoksella Kuopion kampuksella 2023.

Kiitos tutkielman ohjaajana toimineelle Marko Hassiselle.

Lyhenteet

AI	Artificial Intelligence. Tekoäly.
AST	Ascending Slope Tracing.
BLE	Bluetooth Low Energy.
CARS	Context-Aware Recommender System. Kontekstietoinen suosittelujärjestelmä.
DST	Descending Slope Tracing.
EMG	Electromyography. Elektromyografia.
HAR	Human Activity Recognition. Ihmistoiminnan tunnistaminen.
IMU	Inertial Measurement Unit. Inertiamittausyksikkö.
ML	Machine Learning. Koneoppiminen.
IoT	Internet of Things. Esineiden internet.
KNN	K-nearest neighbours. K-lähintä naapuria.
PCA	Principal Component Analysis. Pääkomponenttianalyysi.
SIoT	Social Internet of Things. Sosiaalinen esineiden internet.

Sisältö

1	Johdanto.....	3
2	Smart Fitness – Esineiden internet ja fitness-seuranta.....	8
2.1	Puettavat fitness-seurantalaitteet	9
2.2	Ei-puettavat fitness-seurantalaitteet	14
2.3	Liikeanalyysi ja toiminnan tunnistaminen	19
3	Smart Fitness – Tekoäly ja koneoppiminen.....	24
3.1	Ominaisuuksien louhinta ja suunnittelu	25
3.2	Ohjattu oppiminen.....	26
3.3	Ohjaamaton oppiminen	27
3.4	Osittain ohjattu oppiminen	28
3.5	Vahvistusoppiminen	30
3.6	Syväoppivat neuroverkot	32
4	Smart Fitness - Sosiaalinen esineiden internet.....	34
4.1	Sosiaalinen esineiden internet	35
4.2	Käyttäjäprofilointi.....	36
4.3	Suosittelujärjestelmät.....	40
5	Viimeaikaisia kaupallisia Smart Fitness -toteutuksia.....	45
5.1	Kaupallisia Smart Fitness -laitteita.....	45
5.2	Kaupallisia Smart Fitness -sovelluksia.....	50
6	Johtopäätökset.....	56

1 Johdanto

Kuntoillessaan ihmiset yleensä kohtaavat joitakin kuntoiluun liittyviä haasteita. Kuntoilija esimerkiksi saattaa haaveilla omien tavoitteiden mukaisesta treeniohjelmasta ja ruokavaliosuunnitelmasta. Kuntoilija saattaa pohtia, että olisi kätevää, jos hänellä olisi jonkinlainen seurantamekanismi, jonka avulla hän voisi seurata, kuinka hyvin hän on onnistunut noudattamaan treeniohjelmaansa ja ruokavaliosuunnitelmaansa. Kuntoilijalle voisi olla hyötyä myös päätöksentekomekanismista, joka määrittelisi hänelle sopivan seuraavan treenaamistason ja ruokavaliosuunnitelman. Päätöksentekomekanismin ehdotusten ansiosta kuntoilijan olisi mahdollista siirtyä seuraavalle treenaamistasolle optimaaliseen aikaan. Smart Fitnessin edistysaskeleet mahdollistavat kuntoilijoita tukevien palvelujen syntyminen (Farrokhi et al., 2021.) Itse asiassa Smart Fitness -toteutuksilla on jo tärkeä rooli älykkäässä kuntoilussa ja yleisen hyvinvoinnin ylläpitämisessä (Hänsel et al., 2015).

Tutkielmassa vastataan seuraaviin kysymyksiin:

1. Mitä Smart Fitness tarkoittaa?
2. Mitä Smart Fitnessillä voidaan saavuttaa?
3. Millaisia Smart Fitness -toteutuksia on olemassa?

Termit kuten fitness, kuntoilu, fitness-harjoittelu, kuntosaliharjoittelu ja treenaaminen sekoitetaan usein toisiinsa, ja termejä käytetään vaihtelevasti. Nopeat sosioekonomiset ja demografiset muutokset sekä tarve hyödyntää luonnollista ulottuvuutta ovat monipuolistaneet liikuntaa ja urheilua. Nykyään liikuntaan ja urheiluun liitetään erilaisia tavoitteita. Liikunnan ja urheilun erilaiset tavoitteet ovat johtaneet kilpaurheilun suosion laskuun ja yksilöllisen liikunnan suosion kasvuun. Liikuntaharrastuksilla ihmiset pyrkivät saavuttamaan erilaisia tavoitteita, kuten sisäisen tasapainon tai psykofyysisen hyvinvoinnin. (Paoli & Bianco, 2015)

Terminä fitness on kehittynyt viimeisten vuosikymmenien aikana. Aiemmin aerobicia, askel-aerobicia, hölkkäämistä, kehonhuoltoa ja kehonrakennusta, pidettiin yleisimpinä kuntoilumuotoina, joiden ansiosta ihmiset saattoivat olla hyvässä kunnossa (engl. *fit*). Nykyään fitness-termin liitetään aiempaa monipuolisemmin kuntoilumuotoja. Joitakin esimerkkejä fitness-termin nykyään liitettävistä kuntoilumuodoista ovat funky, zumba, pyöräily, voimaharjoittelu, crossfit, ylläpitoharjoittelu, kahvakuulaharjoittelu, keskivartalotreenaaminen, pilates, jooga ja venyttely. On selvää, että kun erilaisia aktiviteetteja liitetään yleisempien käsitteiden fitness ja kuntoilu alle, ihmisten mielissä käynnistyy psykologinen prosessi, joka päivä päivältä muuttaa käsitteen merkitystä (Paoli & Bianco, 2015.) Tässä tutkielmassa keskitytään ensisijaisesti kuntosalilla tapahtuvaan painonnostoharjoitteluun eli treenaamiseen ja toissijaisesti muihin kuntoilumuotoihin, jotka on liitetty termeihin fitness ja kuntoilu.

Moderni teknologia muokkaa urheiluharjoittelua ja muuttaa tapoja, joilla urheilijat maksimoivat suorituskykynsä ja kilpailevat korkeammalla tasolla kuin koskaan aiemmin (Tegmark, 2017). Ihmisten osallistuessa enenevässä määrin massaurheilutapahtumiin ja urheilutoimintaan (Rauter, 2014), tarvitaan järjestelmiä ja sovelluksia, jotka tukevat ihmisten aktiviteeteista saamaa nautintoa (O'Reilly et al., 2001). Esimerkiksi monet ihmiset ympäri maailmaa eivät voi palkata ammattivalmentajaa taloudellisten syiden vuoksi (Rajšp & Fister, 2020). Smart Sports - ja Smart Fitness -toteutusten eli älykkään urheilun ja älykkään kuntoilun toteutusten vaikutus vaihtelee yksinkertaisista suorituksista, kuten *fitness-seurantalaitteiden* (fitness tracker) käytöstä (Kamišalić et al., 2018) monimutkaisten tekoälyvalmentajatoteutusten hyödyntämiseen (Fister et al., 2019). Tekoälyvalmentajatoteutuksissa perinteinen ihmisvalmentaja korvataan älykkäällä agentilla, joka hallinnoi kaikkia treenaamisen osa-alueita lukuun ottamatta varsinaista treenaamista (Fister et al., 2019).

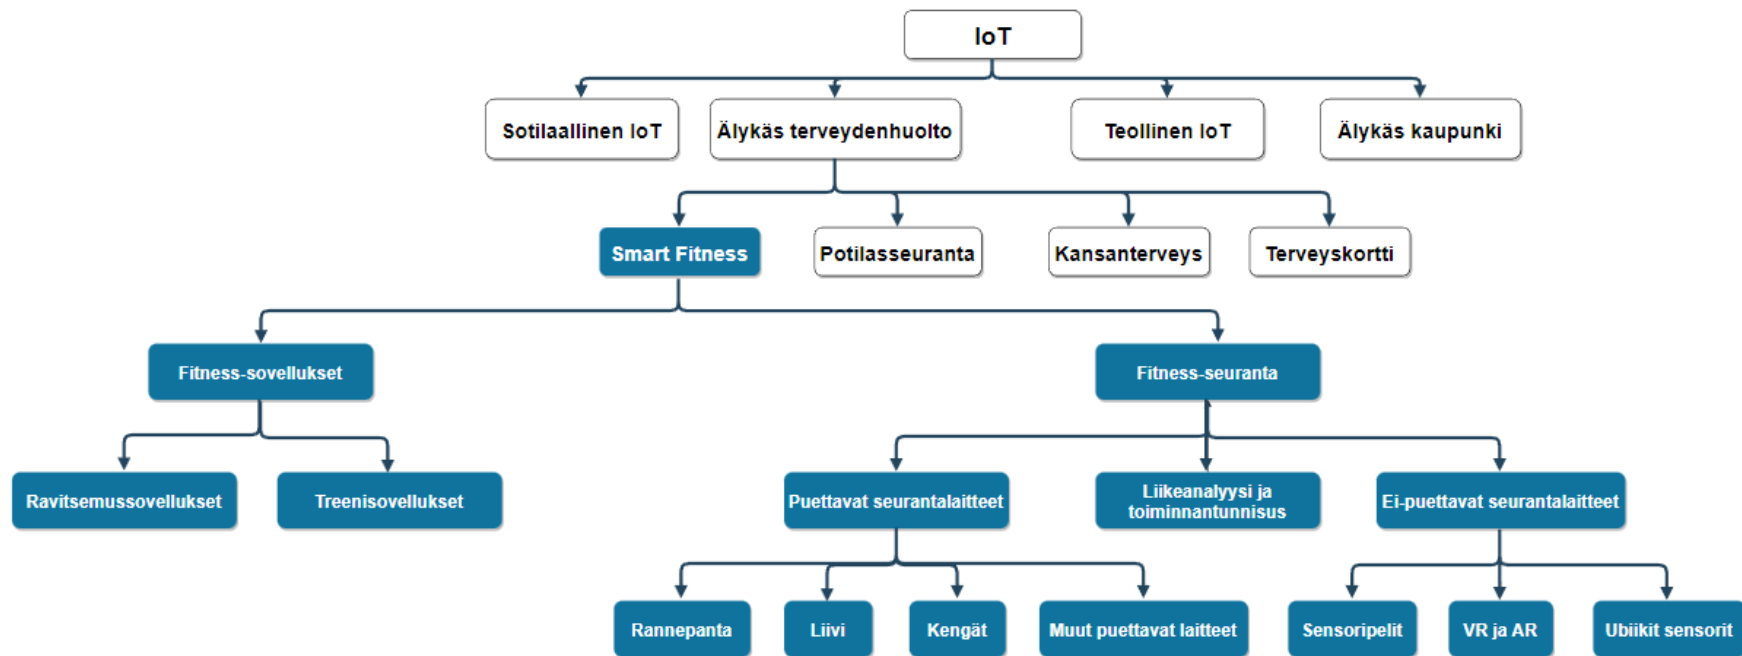
Esineiden internetin (Internet of Things, IoT) konsepteilla ja -palveluilla on ollut huomattava vaikutus useimpiin urheilulajeihin, myös kuntoiluun (Farrokhi et al., 2021). Älykkään kuntoilun ja muiden älykkäiden urheilulajien välillä on monia yhtäläisyyksiä. Älykkäässä urheiluharjoittelussa

on mahdollista seurata tiettyjä ulkoisia tekijöitä, kuten liike-energiaa, aineenvaihdunnan tehokkuutta, kiihtyvyyttä ja kehon kuormitusta sekä myös tiettyjä sisäisiä tekijöitä, kuten hapenottokykyä, sykettä ja nivelten ja lihasten kuormitusta (Vanrenterghem et al., 2017.) Treenaamisen kuormituksen ja treeniohjelman urheilijan kehoon tekemien vaikutusten seuraaminen treeniohjelman laatimiseksi ja ali- ja ylitreenaamisen estämiseksi kuuluu niin älykkääseen kuntoiluun kuin moniin muihin älykkäisiin urheilulajeihin. Älykkään kuntoilun ja muiden älykkäiden urheilulajien välillä on kuitenkin joitakin lajien luonteista johtuvia eroja (Farrokhi et al., 2021.) Esimerkiksi lentopallossa otetaan huomioon ominaisuuksia, kuten reaktioaika, tarkkuus pallon kanssa ja tilannetietoisuus (Postma et al., 2019). Jalkapallossa puolestaan otetaan huomioon esimerkiksi hyppyvoima (Buchheit et al., 2012). Jotkin muissa urheilulajeissa tärkeistä tekijöistä eivät ole yhtä tärkeitä tekijöitä kuntoilussa eikä joitakin muiden urheilulajien tärkeitä tekijöitä voida edes soveltaa kuntoilussa. Älykkäässä kuntoilussa tärkeitä tekijöitä ovat kuormitetut painot, sarjojen pituus, treeniohjelman suorittamiseen kuluva aika, käsien ja jalkojen liikekulman seuranta ja *ominaisuuksien louhinta* (feature extraction) toimien, kuten käsipainon tai tangon liikuttamisen, suorittamiseksi. (Farrokhi et al., 2021)

Smart Fitness on suhteellisen uusi sähköisen ja älykkään terveydenhuollon osa-alue. Viime aikoina Smart Fitness -ratkaisuja on saatu yhä enemmän sekä akateemisilta että teollisilta tahoilta. Yleisesti ottaen Smart Fitness jaetaan kolmeen alakategoriaan: fitness-seurantalaitteet, *fitness-sovellukset* (fitness application) ja *liikeanalyysi* (movement analysis). Fitness-sovellukset tarjoavat erilaisia ominaisuuksia, kuten ruokavalion ja treeniohjelman suunnittelua ja sosiaalisia verkko-ominaisuuksia, kuten samankaltaisten kuntoilijoiden yhdistämistä sovelluksessa. Fitness-seurantalaitteet luokitellaan puettaviin ja ei-puettaviin fitness-seurantalaitteisiin. Fitness-seurantalaitteet keräävät kuntoilijasta dataa ja analysoivat sitä. Liikeanalyysissa kuntoilijan toiminnasta tunnistetaan liikemalleja ja suoritetaan toiminnantunnistusta. Lisäksi *sosiaalisen esineiden internetin* (Social Internet of Things, SloT) soveltamismahdollisuudet älykkäässä kuntoilussa vaikuttavat erittäin lupaavilta, sillä sosiaalinen esineiden internet tukee erilaisia suhteita (Farrokhi et al., 2021.) Sosiaalinen esineiden internet tukee ihmisten välisiä suhteita,

jotka muistuttavat hyvin paljon sosiaalisia verkostoja ja esineiden välisiä suhteita, jotka sosiaalistavat informaatiota ja toiminnallisuuksia (Saleem et al., 2016).

Tutkielman luvussa 2 esitellään esineiden internet ja esineiden internetin käyttömahdollisuuksia älykkäässä kuntoilussa. Luvussa 3 esitellään erilaisia tekoälytekniikoita ja tekoälytekniikoiden käyttömahdollisuuksia älykkäässä kuntoilussa. Luvussa 4 esitellään sosiaalinen esineiden internet ja sosiaalisen esineiden internetin käyttömahdollisuuksia älykkäässä kuntoilussa. Luvussa 5 esitellään viimeaikaisia kaupallisia Smart Fitness -toteutuksia. Luvussa 6 esitellään tutkielman johtopäätökset ja jatkotutkimusideat. Seuraavalla sivulla olevassa kuvassa 1 esitellään yleiskuva Smart Fitnessin ekosysteemistä, joka on jaettu fitness-sovelluksiin ja fitness-seurantaan.



Kuva 1. Smart Fitness on älykkään terveydenhuollon osa-alue (Farrokhi et al., 2021).

2 Smart Fitness – Esineiden internet ja fitness-seuranta

Esineiden internet ja esineiden internetiin liittyvät teknologiat, kuten *langattomat sensoriverkot* (wireless sensor network), kehittyvät nopeasti, ja niiden uudet sovellukset muokkaavat jokapäiväistä elämäämme (Farrokhi et al., 2021). Esineiden internet sisältää joukon internetiin yhdistettyjä laitteita. Esineiden internetin laitteilla on kyky tuottaa ja lähettää dataa automaattisesti ilman ihmisen toimenpiteitä. Esineiden internet koostuu pääasiassa *koneiden välisistä verkoista* (machine-to-machine network), joissa älykkäät laitteet voivat kommunikoida keskenään ja tehdä itsenäisiä päätöksiä tuottamansa ja vastaanottamansa datan perusteella (Wójcicki et al., 2022.) Esineiden internetin viimeaikaiset edistysaskeleet ovat mahdollistaneet suuren määrän sovelluksia monilla eri sovellusalueilla, fitness-ala mukaan lukien (Farrokhi et al., 2021).

Smart Fitness -toteutukset auttavat kuntoilijoita seuraamaan omaa aktiivisuuttaan mittaamalla ja valvomalla heidän treenaamistaan automaattisesti (Hausberger et al., 2016). Yleensä kuntoilijat suunnittelevat treeniohjelmansa itse. Kuntoilijat tekevät usein huonoja valintoja suunnitellessaan treeniohjelmansa, mikä yleensä johtuu oman tilan ja omien kykyjen epärealistisesta kuvasta (Schmidt et al., 2015). Toisaalta Smart Fitness -ratkaisujen avulla pyritäänkin seuraamaan ja valvomaan kuntoilijan treenaamista. Joidenkin IoT-pohjaisten Smart Fitness -laitteiden avulla pystytään seuraamaan myös muita hyvinvointiin ja terveyteen vaikuttavia tekijöitä, kuten unta ja ravitsemusta. Kuntoilijoiden itsetietoisuuden parantamiseen tarkoitettu palaute ja suoritusanalyysi auttavat kuntoilijoita valitsemaan heille parhaiten sopivat treenit. IoT-laitteet tarjoavat jo nyt mahdollisuuden mitata joitakin tavoiteltuja treeninaikaisia lääketieteellisiä arvoja. IoT-laitteita käyttämällä voidaan myös auttaa valmentajia arvioimaan urheilijan tilannetta paremmin ja siten tekemään parempia päätöksiä urheilijan valmennuksen suhteen. (Farrokhi et al., 2021)

Puettavien fitness-seurantalaitteiden kohdalla käyttäjän keho toimii esineen roolissa. Puettava fitness-seurantalaite määrittää esineen roolissa toimivan kehon toimintakyvyn ja ominaisuudet ja lähettää ne IoT-palveluun, kuten mobiilisovellukseen tai verkkosivustolle ja näin käyttäjälle voidaan esittää liikuntainformaatiota IoT-palvelujen avulla (Farrokhi et al., 2021.) Puettavat fitness-seurantalaitteet ovat kuntoilijan kehoon tai vaatteisiin kiinnitettäviä laitteita (Crawford et al., 2015). Ei-puettavat fitness-seurantalaitteet ovat sensorilaitteita, jotka kiinnitetään kuntoilijan ympäristöön, kuten kuntoilulaitteisiin tai -välineisiin. Ei-puettavien fitness-seurantalaitteiden kohdalla kuntoilulaitteella tai -välineellä, kuten tangolla, käsipainolla tai jalkaprässilaitteella, on esineen rooli. Kun ei-puettava fitness-seurantalaite on kiinnitetty esimerkiksi kuntoiluvälineeseen, fitness-seurantalaite tunnistaa kuntoiluvälineestä sen ominaisuudet ja suoritustehon sekä lähettää kerätyn datan IoT-palveluun. Käyttäjä voi olla vuorovaikutuksessa kuntoiluvälineen kanssa ja saada informaatiota treeniliikeominaisuuksista IoT-palvelujen kautta. Liikeanalyysissä puolestaan kuntoilijan toiminnasta tunnistetaan liikemalleja ja suoritetaan toiminnantunnistusta. (Farrokhi et al., 2021) Tässä luvussa kerrotaan esineiden internetistä ja esineiden internetin käyttömahdollisuuksista älykkäässä kuntoilussa. Aliluvussa 2.1 kerrotaan puettavista fitness-seurantalaitteista. Aliluvussa 2.2 kerrotaan ei-puettavista fitness-seurantalaitteista. Aliluvussa 2.3 kerrotaan liikeanalyysistä ja toiminnantunnistuksesta.

2.1 Puettavat fitness-seurantalaitteet

Puettavat fitness-seurantalaitteet ovat IoT-pohjaisia laitteita, jotka valvovat ja seuraavat laitteen käyttäjän fyysistä aktiivisuutta. Puettavia fitness-seurantalaitteita käytetään tyypillisesti rannekkeiden tapaan. Puettavat fitness-seurantalaitteet voivat seurata aktiivisuusparametreja, kuten tietyn ajanjakson aikana käveltyjen askelten määrää, kuljettuja matkoja, keskinopeutta ja kulutettuja kaloreita. Jotkin puettavat fitness-seurantalaitteet voivat seurata myös käyttäjän sykettä ja unen laatua, ja siten puettavilla fitness-seurantalaitteilla kerätty data voi antaa kattavan kuvan käyttäjän terveydentilasta. Jotkin puettavat fitness-seurantalaitteet voivat lisäksi tukea käyttäjän päivittäisten fitness-tavoitteiden määrittelyä ja osoittaa fitness-tavoitteiden saavuttamiseen liittyvän edistymisen. Puettavien fitness-seurantalaitteiden fitness-ominaisuudet

voivat edistää laitteiden käyttäjien päivittäisten fitness-tavoitteiden toteutumista ja siten auttaa heitä parantamaan omaa terveydentilaansa. (Kao et al., 2019)

Puettavia fitness-seurantalaitteita on tarjolla monissa eri muodoissa, kuten älyrannekkeina, älykelloina tai vaatteisiin tai urheiluvälineisiin sulautettuina älylaitteina. Puettavat fitness-seurantalaitteet ovat yleistymässä sekä nuorten että vanhempien ihmisten keskuudessa niiden terveyshyötyjen ansiosta (Wang et al., 2022). Puettavien fitness-seurantalaitteiden suosio kasvaa nopeasti. Statista 2019 -raportin mukaan puettavien fitness-seurantalaitteiden toimituksia oli vuonna 2014 noin 28,8 miljoonaa kappaletta, kun taas vuonna 2017 toimituksia oli jo 115,4 miljoonaa kappaletta. Ennusteiden mukaan vuonna 2023 puettavien fitness-seurantalaitteiden toimituksia on 279 miljoonaa kappaletta. (Farrokhi et al., 2021)

Useimmat puettavat fitness-seurantalaitteet käyttävät keräämänsä informaation visualisointiin jotakin verkkosivustoa tai mobiilisovellusta (Farrokhi et al., 2021). Vaikka puettavat fitness-seurantalaitteet tarjoavat monia hyödyllisiä ominaisuuksia, yksi puettavien fitness-seurantalaitteiden ongelmista on niiden epätarkkuus (El-Amrawy & Nounou, 2015). Lisäksi brändeillä on erilaisia tarkkuusasteita eri tekniikoiden mukaan (Farrokhi et al., 2021). Varsinaisena ongelmana on kuitenkin todellisten ja mitattujen arvojen välinen eroavaisuus (Xie et al., 2018).

Puettavat fitness-seurantalaitteet on suunniteltu paitsi seuraamaan käyttäjän askelia ja liikkumista mutta myös arvioimaan käyttäjän sydämen terveyttä tarkasti käyttäjän leposykkeen avulla. Askelmäärällä on suora suhde käyttäjän aktiivisuuteen eli käyttäjän polttama rasva tai päivittäinen tavoiteltu liikkumismäärä ovat suoraan verrannollisia käyttäjän aktiivisuuteen. Puettavat fitness-seurantalaitteet voivat mitata käyttäjän viikoittaista edistymistä ja tarjota käyttäjälle tilastoja jopa useiden kuukausien ajalta. Jos käyttäjä on määrätietoinen ja noudattaa puettavan fitness-seurantalaitteen punaisia signaaleja, hän voi saavuttaa monotonisesti kasvavan rasvanpolttokäyrän ilman negatiivista notkahdusta, mitä pidetään ihanteellisena kehityksenä. Samoin sydämen terveys voidaan tunnistaa laskevan kuvaajan avulla. Leposykkeen

seuraaminen on puettavien fitness-seurantalaitteiden yksi mielenkiintoisista ominaisuuksista. Puettava fitness-seurantalaite mittaa leposykkeen, kun käyttäjä on täysin levossa. Jos käyttäjän kunto paranee, leposyke laskee, kun taas sairaan, ylikuormittuneen tai yliharjoittelevan käyttäjän leposyke nousee. (Wang et al., 2022)

Hannan et al. (2018) loivat älykkään kannettavan kuntoilusarjan kuluttajille. Hannanin et al. luoman kuntoilusarjan kannettavuuden ansiosta kuntoilijat pystyivät suorittamaan rutiininomaisia treeniliikkeitään ilman valmentajaa ja kuntosaliympäristöä. Hannanin et al. kuntoilusarjajärjestelmä käsitti kaksi treeniliikettä, T-kulmasoudun ja hauiskäännön. Hannanin et al. kuntoilusarjaan sulautettiin gyroskooppi ja EMG-sensorimoduuleja T-kulmasoudun ja hauiskäännön suorittamista varten. Hannanin et al. järjestelmän android-sovellus hälytti terveydelle haitallisista, vääränlaisessa asennossa suoritetuista treeniliikkeistä, ja kuntoilija ohjattiin parhaaseen mahdolliseen asentoon sensoriarvojen perusteella. Hannanin et al. järjestelmä käytti *K-lähintä naapurina* (K-Nearest Neighbors, KNN) -luokittelumallia ennustamiseen sekä kuntoilijan ohjaamiseen treeniliikkeen suorittamisen aikana. Hannanin et al. järjestelmässä android-sovellus toimi virtuaalisen valmentajan roolissa, ja ohjasi kuntoilijaa suorituksen aikana tekstistä puheeksi -moduulin välityksellä. Hannanin et al. järjestelmä saavutti 89 prosentin tarkkuuden, jota voidaan pitää varsin hyvänä, kun otetaan huomioon, että järjestelmä oli kannettava ja se sisälsi myös virtuaalisen valmentajan.



Kuva 2. T-kulmasoudun koeasetelma Hannanin et al. (2018) tutkimuksessa.

Zou et al. (2020) loivat uudenlaisen älykkään kuntoilukäsineen, iCoachin, joka suunniteltiin voimaharjoitteluliikkeiden seurantaan, valmentamiseen ja arviointiin. Zoun et al. luoma iCoach on älykäs kuntoilukäsine, jossa on kaupallinen inertiamittausyksikkö, joka sisältää kiihtyvyyssmittarin, gyroskoopin ja magnetometrin sulautettuna kuntoilukäsineen rannepantaan. Zoun et al. mukaan iCoach-kuntoilukäsine toimii hyödyntämällä *inertiamittausyksikön* (Inertial Measurement Unit, IMU) tuottamaa dataa treeniliikkeiden tunnistamiseen, epätyypillisen käyttäytymisen havaitsemiseen ja treenaamisen laadun arviointiin. Zoun et al. mukaan iCoach voi toimia reaaliaikaisena vuorovaikutteisena käyttöliittymänä valmentajille. Zou et al. kertovat, että käyttäjille lähetetään välittömästi ohjeet virheiden korjaamiseksi ja loukkaantumisten välttämiseksi, jos treenaamisen aikana havaitaan epänormaalia käyttäytymistä. Zoun et al. mukaan kokeelliset tulokset osoittivat, että iCoach pystyi tunnistamaan treeniliikkeet hyvällä tarkkuudella. Zoun et al. mukaan iCoach pystyi myös tunnistamaan hienovaraisemmat epätyypilliset käyttäytymismallit kohtuullisella tarkkuudella. Zou et al. kertovat, että iCoachin avulla treenaamisen laatua pystyttiin arvioimaan luotettavasti.



Kuva 3. Zoun et al. (2020) luoma kuntoilukäsine

Abed et al. (2022) loivat langattoman älykkään t-paidan, joka mittaa reaaliaikaisesti kuntoilijan hengitystahtia. Abedin et al. mukaan kuntoilijan reaaliaikaisen hengitystahdin mittaaminen perustuu paidassa oleviin langattomiin sensoreihin, joiden mittaukset perustuvat sensorien vastaanottaman signaalin voimakkuuden indikaattoreihin. Abed et al. kertovat, että hengitystahdin mittaaminen on mahdollistettu hyödyntämällä älykkään t-paidan sensoreihin liitettyä venyvää kuituantennia, jossa on langaton latausjärjestelmä. Abedin et al. mukaan kuituantenni on huomaamaton pienen kokonsa ansiosta. Abed et al. kertovat, että älykkään t-paidan sensori muodostaa langattoman Bluetooth-yhteyden tietokantaan. Abedin et al. mukaan langaton virransiirto lisäsi älykkääseen t-paitaratkaisuun uuden ominaisuuden tehden t-paidasta käyttäjäystävällisen älyvaatteen tarjoamalla aiempia ratkaisuja enemmän liikkuvuutta ja akun käyttöikä.




Kuva 4. Abedin et al. (2022) luoma älykäs t-paita

2.2 Ei-puettavat fitness-seurantalaitteet

Ei-puettavat fitness-seurantalaitteet ovat esineisiin asennettavia IoT-laitteita, jotka keräävät dataa kuntoilijan toiminnasta esineestä mitattujen arvojen avulla. Ei-puettavia fitness-seurantalaitteita ovat esimerkiksi kuntoilijan toimintaa tarkkailemaan kykenevät kuntoilulaitteisiin asennettavat sensorilaitteet. Ei-puettavat fitness-seurantalaitteet keräävät kuntoilulaitteen välityksellä tietoja, kuten treeniliikkeen nopeus, treeniliikkeen teho ja treeniliikkeessä käytettävä painokuorma, jotka yleensä mitataan treenin aikana ja yhdistetään kuntoilijan profiliin. (Farrokhi et al., 2021)

Farrokhin et al. (2022) tutkimuksen tavoitteena oli luoda kuntoilujärjestelmä, joka pystyy seuraamaan kuntoilijan toimintaa, antamaan palautetta ja esittämään treenisuunnitelman kuntoilijan vartalotyypin ja treenijakson aikaisen käyttäytymisen perusteella. Saavuttaakseen tutkimuksen tavoitteen, Farrokhi et al. suunnittelivat sensoripohjaisen kuntoilulaitteen, johon

asennettiin sensoreita. Farrokhi et al. tutkivat ojentaja- ja hauislihasten toimintaa, koska heidän tutkimussuunnitelmansa perusteella ojentaja- ja hauislihas olivat eniten sensoreita tarvitsevia päälihastyyppejä.



(a)

(b)

Kuva 5. a.) Farrokhin et al. (2022) tutkimuksessa luotu ei-puettavan fitness-seurantalaitteen prototyyppi b.) Fitness-seurantalaitteen prototyyppi asennettuna talja-kuntoilulaitteeseen

Farrokhin et al. (2021) mukaan useissa tutkimuksissa on ehdotettu arkkitehtuuriratkaisuja fitness-alalle. Shin et al. (2012) ehdottivat arkkitehtuuria, joka oli suunniteltu keräämään ja tarkastelemaan informaatiota kuntoilijan voimasta, nopeudesta ja taidoista. Shinin et al. tutkimuksessa oli kaksi tavoitetta: kerätyn informaation tehokkuuden ja vaikuttavuuden lisääminen sekä kerätyn datan analysointi ja treenitulosten parantamista tavoittelevien suositusten tarjoaminen. Farrokhin et al. mukaan Shinin et al. ehdotuksen kaltaisissa infrastruktuureissa on yleensä neljä toiminnallista elementtiä eli neuvojen tarjoamisessa hyödynnettävät asiantuntijapalvelimet, dataa keräävät ja lähettävät kuntoilulaitteet, tiedonkeruuprosessia hallinnoiva verkkopalvelin ja prosessoidun datahistorian arkistoiva

datavarasto. Farrokhi et al. kertovat, että yksilöllisiä ja räätälöityjä tuloksia varten on olemassa yksilöityjä ratkaisuja, joissa jokaisella kuntoilijalla on henkilökohtainen profiili järjestelmässä. Farrokhin et al. mukaan kuntoilijoiden toiminta kerätään, prosessoidaan ja rekisteröidään, ja siten syntyy arkisto kunkin kuntoilijan datahistoriasta.

Ohjelmiston näkökulmasta ei-puettava fitness-seurantalaiteratkaisu edellyttää sovellusta ylläpitäjälle, valmentajalle ja valmennettavalle kuntoilijalle. Valmentaja voi halutessaan vain seurata valmennettavan kuntoilijan tuottamaa dataa, mutta valmentajalla on myös mahdollisuus luoda, määrittää, muokata, lisätä tai poistaa osa valmennettavan kuntoilijan treeniohjelmasta. Ylläpitäjä voi hallita dataa ja kaikkea muuta informaatiota fitness-seurantalaitteen käyttäjän toiminnan seuraamiseksi. Valmentajalla on sisään kirjauduttuaan valittavanaan useita treenimuotoja, joihin kuuluvat esimerkiksi venyttely ja kunnan ylläpitäminen. Valmentaja voi halutessaan muuttaa ennalta määriteltyä treeniohjelmaa esimerkiksi muuttamalla yhtä treeniliikettä tai treeniliikkeen intensiteettiä. Kuntoilija puolestaan näkee vain päivittäisen ohjelman (Farrokhi et al., 2021.) Kuntoilijoiden toiminnan tutkimiseksi on myös ehdotettu digitaalista henkilökohtaista valmentajaa, joka perustuu matemaattisiin malleihin (Schmidt et al., 2015). Matemaattisiin malleihin perustuvaa lähestymistapaa voidaan pitää uutena askeleena Smart Fitness -alalla. Matemaattisiin malleihin perustuva lähestymistapa tarjoaa prototyypin ja hyödyntää matemaattisia malleja, kuten *Markovin päätösprosessia* (Markov Decision Process) ja *osittain havaittavissa olevaa Markovin päätösprosessia* (Partially Observable Markov Decision Process) (Farrokhi et al., 2021).

Farrokhin et al. (2021) mukaan myös inertiamittausyksikköihin pohjautuvien arkkitehtuurien käyttöön liittyy mielenkiintoinen tutkimussuuntaus. Hausberger et al. (2016) käsittelivät inertiamittausyksiköiden käyttöä fitness-seurantalaitteissa ja kuntoilulaitteissa. Hausbergerin et al. mukaan IMU-pohjaiset järjestelmät yleensä analysoivat fyysisiä aktiviteetteja eri liikkeiden välisten erojen perusteella pyrkien tunnistamaan suoritettut aktiviteetit. Hausberger et al. määrittivät aktiviteetin alun ja lopun IMU-pohjaisen laitteen avulla. Hausberger et al. kertovat, että informaatio välitettiin IMU-pohjaisessa laitteessa olevalla viestintätoiminnolla, joka perustuu

Bluetooth Low Energy (BLE) -tekniikkaan. Hausbergerin et al. toteutuksessa käytettiin käsipainossa tai kuntoilulaitteessa olevaa prototyyppi prosessoria, jossa on tunnistin pystysuuntaisen liikkeen sekä aktiviteetin alun ja lopun määrittämiseksi. Hausberger et al. käyttivät kiihtyvyyssmittaria ja gyroskooppia kiihtyvyy- ja kulmanopeusmittausta varten. Hausbergerin et al. mukaan sensorien sijainti ja suunta ovat kaksi tärkeää tekijää aktiviteettiin liittyvän ymmärryksen lisäämiseksi. Hausberger et al. olettivat liikkeen tapahtuvan X-, Y- ja Z- akselien suuntaisesti ja he pystyivät tunnistamaan kuntoilijan treenaamisen tyyppin hyödyntämällä kiihtyvyyssmittari- ja gyroskooppijärjestelmistä saatavaa dataa.

Farrokhin et al., (2021) mukaan ikääntyneiden liikunta- ja treenitoiminta on yksi Smart Fitnessin tärkeistä tavoitteista. Farrokhi et al. kertovat, että tutkimuksissa on pyritty kehittämään ikääntyneille sopivia ratkaisuja hyvinvoinnin ja osallisuuden edistämiseksi. Culén et al. (2013) ehdottavat teoksessaan Smart Fitness -ratkaisuja ikääntyneille ihmisille. Culénin et al. tapaustutkimuksena oli kuntosali, johon jokainen kuntoilija rekisteröityi omalla nimellään ja henkilökohtaisilla tiedoillaan. Culénin et al. ratkaisussa kuntoilijan antamat tiedot kirjoitettiin ja tallennettiin korttiin jokaisen rekisteröinnin jälkeen. Culénin et al. ratkaisussa kortit eivät olleet henkilökohtaisia, vaan rekisteröityminen vaadittiin jokaisen kuntosalikäynnin kohdalla. Culénin et al. ratkaisussa kuntosalin jokaisessa laitteessa oli kosketusnäyttö, ja korttipaikka, johon kortti asetettiin. Culén et al. kertovat, että kun korttiin kirjoitetut kuntoilijan tiedot, kuten ikä, pituus ja paino, oli luettu, kuntoilulaite näytti näytöllä kuntoilijalle sopivat kuntoilulaitteen säädöt, kuntoilulaitteessa suoritettavan treeniliikkeen toistomäärät ja treeniliikkeessä käytettävän painon. Culénin et al. mukaan kuntoilulaitteen vastus ja voima vastasivat kuntoilijan treeniohjelman mukaisia arvoja. Culén et al. kertovat, että kuntoilijaa myös ohjattiin toistamaan treeniliike kuntoilulaitetta käyttäen oman treeniohjelman mukaisesti. Culénin et al. mukaan kuntoilulaite myös laski liikesarjat ja seurasi kuntoilulaitteen käyttäjän toimintaa.

Ei-puettavien fitness-seurantalaitteiden kohdalla tarvitaan myös useita hallintaratkaisuja. Älykkäät kuntoilulaitteet ovat joukko älykkäitä laitteita, joilla kuntosali varustetaan. Älykkäiden kuntoilulaitteiden tehtävänä on tallentaa esimerkiksi aktiviteetin kesto ja aktiviteetin

intensiteetti. Jotta älykkäitä kuntoilulaitteita voitaisiin käyttää, tarvitaan jonkinlaista datahistorian hallintaa. Kuntoilulaitteen käytön päätyttyä kuntoiludata tallennetaan tietokantaan. Identiteetinhallinta on järjestelmän osa, joka käsittelee kuntoilulaitteiden tunnistamista ja yhdistämistä käyttäjien tunnuksiin. Tasonhallinta puolestaan on järjestelmän osa, jossa järjestelmässä ja yksittäisessä laitteessa sovellettavat treeniliiketasot määritetään ja täsmennetään. Treeninhallinta määrittää dynaamisen treenimallin kultakin käyttäjältä kerätyn datan perusteella. Tietokantaan tallennetaan tietoja, kuten kuntoilijan ikä, pituus, paino, painoindeksi, kehon rasvaprosentti ja muita fyysiseen tilaan liittyviä tietoja. Tallennettujen tietojen avulla järjestelmä voi määrittää ja virittää järjestelmän kunkin kuntoilijan alkuperäisten kykyjen ja valmiuksien mukaan sekä lopulta kehittää treeniohjelmaa vastaamaan kuntoilijan kasvavia kykyjä. Tasonhallinta määrittää kuntoilijan nykyisen tason ja kertoo kuntoilijalle, mitä treeniliikkeitä hänen tulisi suorittaa. Järjestelmässä kuntoilulaitteet toimivat käyttöliittymänä, ja identiteetinhallinta mahdollistaa käyttäjien tarkan tunnistamisen, jotta järjestelmä voi hakea käyttäjän täydellisen treenihistorian. Tasonhallinta määrittää sitten käyttäjän perustason käyttäjältä kerättyjen tietojen perusteella. Lopuksi treeninhallinta määrittää varsinaiset treenijaksot. (Farrokhi et al., 2021)

Farrokhi et al. (2021) kertovat, että on jo olemassa tekniikoita, joita voitaisiin soveltaa älykkääseen kuntoiluun treenien arvioimiseksi ja siten tehokkaampien treeniohjelmien määrittelemiseksi ja tarjoamiseksi. Farrokhin et al. mukaan lämpökuvaus on yksi lupaavimmista tekniikoista fitness-alalla. Postolachen (2015) mukaan lämpökuvaus on säteilemätön ja kosketusvapaa tekniikka. Postolache kertoo, että kuntoilijan ihon lämpötila mitataan lämpökameran avulla toiminnan alussa ja lopussa. Postolache kertoo, että ihon lämpötila nousee lihasten ollessa rasituksessa, kun taas muilla levossa tai vähemmän treenissä mukana olevilla ihon alueilla ihon lämpötila ei muutu. Postolachen mukaan lämpökuvaus on tehokas keino arvioida kuntoilijan toimintaa ja ehkäistä vammoja aktiviteettien suorittamisen aikana. Postolache loi järjestelmän, joka otti useita kuvia kustakin kuntoilijan ihoalueesta treenin aikana ja mittasi kuntoilijan ihon lämpötilan minimi-, maksimi- ja keskiarvot ennen toimintaa ja toiminnan jälkeen. Postolache kertoo, että esimerkiksi treeniliikkeitä voitiin kvantifioida ja

verrata toisiinsa niiden tehokkuuden määrittämiseksi. Postolache huomauttaa, että arvot voivat vaihdella ihmisten välillä merkittävästi, joten mitatut ja lasketut arvot räätälöidään kunkin kuntoilijan mukaan. Postolachen mukaan lämpökuvaustekniikkaa ja muita menetelmiä käyttämällä on mahdollista arvioida, kuinka tehokas treeni oli kohdelihakselle ja lisätä tietoisuutta vammoista ja virheellisistä toimista.

2.3 Liikeanalyysi ja toiminnan tunnistaminen

Liikeanalyysi perustuu fitness-seurantalaitteiden keräämään dataan. Liikeanalyysissa keskitytään kuntoilijan eleisiin, kävelyyn ja ryhtiin (Bulling et al., 2010.) Liikeanalyysin tavoitteena on informoida kuntoilijoita ja auttaa heitä suorittamaan aktiviteettinsa parhaalla mahdollisella tavalla (Abowd, 1998). Liikeanalyysilla tapahtuva valmennettavan kuntoilijan toiminnan analysointi voi auttaa kuntoilijan valmentajaa suunnittelemaan parempia treeniohjelmiä (Barris & Button, 2008).

Toiminnantunnistussovelluksien suuri määrä elämän eri osa-alueilla, kuten kuntoilussa, on herättänyt paljon kiinnostusta *ihmistoiminnan tunnistamista* (Human Activity Recognition, HAR) kohtaan (Preatoni et al., 2020; Ashraf et al., 2020; Pires et al., 2021; Oniani et al., 2018). Kuntoileminen ilman valmentajaa voi johtaa vammoihin, jos käytetään vääriä tekniikoita (Hannan et al., 2021). Sensoritekniikan kehittymisen ansiosta ihmisen toimintaa on kuitenkin mahdollista valvoa älypuhelimella ja HAR-järjestelmillä (Skawinski et al., 2019). HAR-järjestelmät voidaan luokitella karkeasti kahteen luokkaan eli puettaviin ja ei-puettaviin HAR-järjestelmiin (Pires et al., 2021; Hussain et al., 2018). Ei-puettavissa HAR-järjestelmissä sensorit, kuten kamerat, painesensorit, tutkasensorit, ultraäänisensorit ja muut laitteet, sijoitetaan ympäristöön seuraamaan ihmisen toimintaa (Hussain et al., 2018). Ympäristöön sijoitettavat ei-puettavat HAR-järjestelmät ovat kuitenkin hyvin kalliita, ja niiden alueellinen kattavuus, joka riippuu järjestelmässä käytettävistä sensoreista, on rajallinen (Hussain et al., 2019). Puettavat HAR-järjestelmät puolestaan yleensä sisältävät inertiasensoreita, kuten kiihtyvyyssensoreita, gyroskooppeja ja magnetometrejä, ihmisen toiminnan seuraamista varten (Hannan et al., 2021).

Puettavat HAR-järjestelmät ovat edullisia, eikä niillä ole peittoalueen rajoituksia, toisin kuin ei-puettavilla HAR-järjestelmillä (Hussain et al., 2019; Pires et al., 2020).

Leen (2017) tutkimuksessa keskityttiin liikeanalyysiin havaitsemalla negatiivisia ja positiivisia huippuja. Leen tutkimuksen tavoitteena oli henkilön liikkeiden positiivisten ja negatiivisten huippujen havaitseminen. Leen järjestelmä analysoi myös keskiarvot positiivisille ja negatiivisille huipuille liikkeen pituuden mittaamiseksi. Leen järjestelmä laski ja analysoi positiivisten huippujen ja negatiivisten huippujen keskimääräisen ajan sekä positiivisten ja negatiivisten huippujen ja negatiivisten ja positiivisten huippujen väliset ajat. Lee suoritti analyysin kolmelle treeniliikkeelle: hauiskäännölle, takakykyllä ja ojentajaliikkeelle. Lee käytti DST-menetelmää positiivisten huippujen havaitsemiseen ja AST-tekniikkaa negatiivisten huippujen havaitsemiseen. Leen toteutukseen tarvittiin yhdeksän vapausasteen inertiamoduuli. Leen inertiamoduuli koostui kiihtyvyyssensorista, magnetometrillä ja gyroskoopista. Inertiamoduuli kiinnitettiin kuntoilijan kehoon. Leen toteutuksella pystyttiin auttamaan kuntoilijoita arvioimaan treeniliikkeitään.

Lee et al. (2009) loivat älypaidan prototyypin fysiologisten tietojen mittaamiseen elektrokardiogrammisignaalien avulla ja fyysisen aktiivisuuden mittaamiseen kiihtyvyyssensorisignaalien avulla. Lee et al. varustivat älypaidan langattomilla sensorisoluilla, elektrokardiogrammitaululla ja kiihtyvyyssmittarilla ja käyttivät tiedonsiirtoon viestintämoduulia. Leen et al. tutkimuksessa data kerättiin ja välitettiin palvelimelle, joka kykeni prosessoimaan ja analysoimaan kerätyn datan. Manjarres et al. (2020) suorittivat liikeanalyysin käyttämällä kahta puettavaa fitness-seurantalaitetta: sykemittaria ja lantioon sijoitettua liiketunnistinta. Manjarres et al. käyttivät *satunnaismetsä*- (random forest) ja KNN-algoritmeja kerätyn datan luokittelussa ja merkitsemisessä, jotta kunkin henkilön toiminnan tunnistaminen ja työmäärän laskeminen olisi mahdollista. Bian et al. (2019) loivat parijännitteen vaihteluun perustuvan kuntosaliharjoittelun tunnistamismekanismien. Bianin et al. tunnistusmekanismissa ihmiskehoa pidettiin yhtenä levynä ja kuntosaliympäristöä toisena levynä, ja siten puettavaa fitness-seurantalaitetta ei tarvinnut sijoittaa liikkuvaan treeniliikkeen mukaan vaihtelevaan kehonosaan. Bianin et al.

tunnistusmekanismeissa kuntoilijan kehoon asetettiin BLE:llä ja paristolla varustettu elektrodi ja prosessointiyksikkö laitteistoyksikkönä, ja signaalit analysoitiin ja luokiteltiin syvien *konvoluutioneuroverkkojen* (convolutional neural network) avulla.

Toiminnantunnistuksessa on käytetty monia koneoppimismenetelmiä, mutta toiminnantunnistukseen liittyy kuitenkin edelleen monia teknisiä haasteita. Osa toiminnantunnistukseen liittyvistä haasteista on yhteisiä muiden hahmontunnistusalojen, kuten konenäön ja luonnollisen kielen prosessoinnin, kanssa. Osa haasteista on ominaisia sensoripohjaiselle toiminnan tunnistamiselle, ja ne edellyttävät erityisiä menetelmiä toiminnantunnistussovelluksia varten. (Chen et al., 2021)

Yksi toiminnan tunnistamiseen liittyvistä haasteista on ominaisuuksien louhinta. Toiminnan tunnistaminen on luokittelutehtävä, joten se jakaa muiden luokitteluongelmien kanssa yhteisen ominaisuuksien louhintaan liittyvän haasteen (Chen et al., 2021.) Sensoripohjaisessa toiminnan tunnistamisessa ominaisuuksien louhinta on vaikeampaa, koska toimien välillä on samankaltaisuutta (Brophy et al., 2018). Eri toimilla, kuten kävelemisellä ja juoksemisella, voi olla samanlaisia ominaisuuksia, ja siten voi olla vaikeaa tuottaa erottuvia ominaisuuksia, jotka edustaisivat toimia yksiselitteisesti (Chen et al., 2021).

Toinen toiminnan tunnistamiseen liittyvä ongelma on se, että koneoppimistekniikoiden kouluttaminen ja arviointi edellyttää suuria datanäytteitä, joihin on merkitty todellinen toiminta. Toimintadatan kerääminen ja merkitseminen on kuitenkin kallista ja aikaa vievää, ja siksi merkityn datan niukkuus on merkittävä haaste sensoripohjaiselle toiminnan tunnistamiselle. Lisäksi joidenkin uusien tai odottamattomien toimien, kuten vahingossa tapahtuvan kaatumisen, dataa on erityisen vaikea saada, mikä johtaa toiseen haasteeseen, jota kutsutaan luokkien epätasapainoksi. (Chen et al., 2021)

Toiminnan tunnistamiseen liittyy kolme tekijää: käyttäjät, aika ja sensorit. Kaikki kolme toiminnan tunnistamiseen liittyvää tekijää johtavat koulutus- ja testidatan väliseen hajontaan.

Käyttäjien osalta koulutus- ja testidatan hajonta johtuu siitä, että toimintamallit ovat kaikilla käyttäjillä erilaisia. Eri käyttäjillä voi olla erilaisia toimintatyylejä. Koulutus- ja testidatan hajontaa syntyy myös siksi että toimintakonseptit vaihtelevat ajan myötä. On epäkäytännöllistä olettaa, että käyttäjien toimintamallit pysyvät muuttumattomina pitkän ajanjakson ajan. Lisäksi käytön aikana syntyy todennäköisesti uusia toimia. Myös erilaisten sensorilaitteiden asentaminen sattumanvaraisesti ihmiskehoon tai ympäristöön luo koulutus- ja testidatan hajontaa, sillä sensorilaitteiden koostumus ja sijoittelu vaikuttavat merkittävästi käyttäjän toimien tuottamaan dataan. (Chen et al., 2021)

On myös tarkasteltava toiminnantunnistusjärjestelmän toteutettavuutta. On tehtävä töitä sen eteen, että suuri joukko käyttäjiä hyväksyy järjestelmän, koska ihmisen toiminnan tunnistaminen on melko lähellä ihmisen jokapäiväistä elämää, mikä voi aiheuttaa ristiriitaisia kokemuksia. Ensinnäkin järjestelmän tulisi olla käyttöintensiivinen, jotta se soveltuisi puettaviin sensorilaitteisiin ja pystyisi välittömästi kertomaan, millaista toimintaa käyttäjä parhaillaan suorittaa. Toiseksi, koska toiminnantunnistusjärjestelmä kerää informaatiota käyttäjien elämästä jatkuvasti, on olemassa riski henkilökohtaisten tietojen paljastumisesta, mikä johtaa yksityisyyden suojaan liittyviin ongelmiin. (Chen et al., 2021)

Toisin kuin kuvia tai tekstejä, sensoridataa ei voida lukea sellaisenaan, vaan sensoridatan ymmärtäminen vaatii erillistä tulkintaa. Lisäksi sensoridata sisältää väistämättä paljon kohinadataa, joka johtuu sensoreiden luontaisista puutteista. Luotettavilla toiminnantunnistusratkaisuilla on siis oltava sensoridatan tulkintakyky ja kyky ymmärtää, mikä osa datasta helpottaa toiminnan tunnistamista ja mikä osa heikentää sitä. (Chen et al., 2021)

Viime vuosina *syväoppivat neuroverkot* (deep neural network) ovat saavuttaneet huomattavaa menestystä korkean tason abstraktioiden mallintamisessa monimutkaisesta datasta monilla aloilla, kuten tietokonenäön, luonnollisen kielen prosessoinnin ja puheen prosessoinnin aloilla (Pouyanfar et al., 2018). *Syväoppimisen* (deep learning) nopean kehityksen myötä on tehty toiminnan tunnistamiseen liittyvää tutkimusta erityishaasteiden ratkaisemiseksi. Syväoppimisen

syvien mallien kerroksittaiset rakenteet mahdollistavat oppimisen yksinkertaisista ominaisuuksista abstrakteihin ominaisuuksiin skaalautuvasti. Lisäksi kehittyneet laskentaresurssit, kuten *näytönohjaimet* (graphics processing unit), tarjoavat syväoppimismalleille tehokkaan kapasiteetin oppia monimutkaisesta datasta kuvaavia ominaisuuksia. Erinomainen oppimiskyky mahdollistaa myös sen, että toiminnantunnistusjärjestelmä pystyy syvällisesti analysoimaan multimodaalista sensoridataa tarkkaa toiminnantunnistusta varten. (Chen et al., 2021)

Syvien neuroverkkojen erilaiset rakenteet enkoodaavat ominaisuuksia useista eri perspektiiveistä (Chen et al., 2021). Esimerkiksi konvoluutioneuroverkot kykenevät tallentamaan multimodaalisen sensoridatan paikalliset yhteydet, mikä johtaa tarkkaan toiminnan tunnistamiseen (Hammerla et al., 2016). *Takaisin kytketyt neuroverkot* (recurrent neural networks) poimivat ajalliset riippuvuudet ja oppivat tietoa asteittain aikavälien kautta, joten ne soveltuvat sensoridatan tulkitsemiseen ihmisen toiminnan tunnistamisessa. Syviä neuroverkkoja voidaan joustavasti koota yhtenäisiksi verkoiksi, joilla on yksi yleinen optimointitoiminto, mikä mahdollistaa erilaiset syväoppimistekniikat, kuten *syvän siirto-oppimisen* (deep transfer learning), *syvän aktiivisen oppimisen* (deep active learning), *syvän huomiomekanismin* (deep attention mechanism) ja muut ei-systemaattiset mutta yhtä tehokkaat ratkaisut. Erilaisia syväoppimistekniikoita käyttäneet tutkimukset vastaavat syväoppimisen erilaisiin haasteisiin. (Chen et al., 2021)

3 Smart Fitness – Tekoäly ja koneoppiminen

Tekoälyn (artificial intelligence) kehitys on ollut nopeaa, ja tekoäly on tarjonnut ennennäkemättömiä mahdollisuuksia terveydenhuollon eri osa-alueilla, Smart Fitness mukaan lukien. Tekoälyn keskeisenä osa-alueena pidetyllä *koneoppimisella* (Machine Learning, ML) on useita yhtäläisyyksiä perinteisen tilastotieteen kanssa (Côté & Lamarche, 2022.) Kuitenkin siinä missä perinteiset tilastolliset menetelmät yleensä keskittyvät enemmän päättelyyn sen todennäköisyyspohjaisen luonteen vuoksi, ML suuntautuu enemmän ennustamiseen ja luokitteluun hyödyntämällä suurilla tietokokonaisuuksilla koulutettuja oppimisalgoritmeja (Bzdok et al., 2018). Toinen ero koneoppimisen ja perinteisten tilastollisten menetelmien välillä on se, että perinteiset tilastolliset mallit kehitetään perustuen a priori -tietoon muuttujien joukon välisistä assosiaatioista, kun taas ML-algoritmit olettavat, että data ei synny minkään tietyn mekanismin perusteella (Lavigne et al., 2019). Koneoppimisessa voidaan myös käsitellä hyvin suuria ja monimutkaisia tietokokonaisuuksia paljon tehokkaammin kuin perinteisen tilastotieteen menetelmillä (Côté & Lamarche, 2022).

Tekoäly ja koneoppiminen vaikuttavat nykyään merkittävästi esineiden internetin paradigmaan (Farrokhi et al., 2021). Tutkimuksissa on hyödynnetty tekoälytekniikoita erilaisissa IoT:n sovelluskohteissa (Kankanhalli et al., 2019). Tekoälyn käyttö IoT:n sovelluskohteissa vaikuttaa myös fitness-alaan. Tällä hetkellä on olemassa joitakin Smart Fitness -sovelluksia, joiden toimintaa on pyritty parantamaan tekoälyalgoritmeja hyödyntäen. Lisäksi esineiden internetin ja tekoälyn välinen suhde on niin syvä, että monet tästä teknologiakumppanuudesta kumpuavat ratkaisut vaikuttavat myös älykkääseen kuntoiluun. On olemassa kolmenlaisia laskennallisen älykkyyden algoritmeja, joista *keinotekoiset neuroverkot* (artificial neural network) on johdettu ihmisen aivojen toiminnasta, *evoluutiolaskenta* (evolutionary computation) darwinistisesta selviytymiskamppailusta ja *parviälykyys* (swarm intelligence) sosiaalisten eläinten, yhdyskuntien ja hyönteisten käyttäytymisestä. Yleisenä lähestymistapana tekoälyalgoritmeja voidaan soveltaa fitness-dataan, tiedonlouhintaan, treenaamisen analysointiin, treeniohjelmien ja ruokavaliosuunnitelmien luomiseen ja vammojen ehkäisyyn (Farrokhi et al., 2021.) Fitness-datan

tiedonlouhintaan on olemassa suosittuja algoritmeja, kuten Apriori-, Eclat- ja Frequent Pattern-Growth -algoritmi (Agrawal et al., 1994; Zaki, 2000; Han et al., 2000). Tässä luvussa kerrotaan tekoälystä ja koneoppimisesta ja erilaisten tekoälytekniikoiden käyttömahdollisuuksista älykkäässä kuntoilussa. Aliluvussa 3.1 kerrotaan ominaisuuksien louhinnasta ja suunnittelusta. Aliluvussa 3.2 kerrotaan ohjatusta oppimisesta. Aliluvussa 3.3 kerrotaan ohjaamattomasta oppimisesta. Aliluvussa 3.4 kerrotaan osittain ohjatusta oppimisesta. Aliluvussa 3.5 kerrotaan vahvistusoppimisesta. Aliluvussa 3.6 kerrotaan syväoppivista neuroverkoista.

3.1 Ominaisuuksien louhinta ja suunnittelu

Ominaisuuksien louhinta on yksi koneoppimisen perusvaiheista (Nahavandi et al., 2022). Liian suuri määrä ominaisuuksia voi häiritä koneoppimisalgoritmeja (Shoeibi et al., 2020; Tor et al., 2020). Kliinisesti merkittävien ominaisuuksien valitsemiseen käytetään *ominaisuuksien valinta -algoritmeja* (feature selection algorithm). Tilastollisesti merkittävien ominaisuuksien valintaan voidaan käyttää myös keskiarvoa ja moodia tai algoritmeja, kuten *pääkomponenttianalyysia* (Principal Component Analysis, PCA), *lineaarista diskriminaatioanalyysia* (linear discriminant analysis), *riippumattomasta komponenttianalyysia* (independent component analysis), *paikallisesti lineaarista sulauttamista* (locally linear embedding) ja *autoenkodereita* (autoencoder). Kliinisesti tai tilastollisesti merkittäviä ominaisuuksia voidaan hyödyntää koneoppimismenetelmissä (Nahavandi et al., 2022.) *Ominaisuuksien suunnittelu* (feature engineering) on prosessi, jossa raakadatasta louhitaan hyödyllisiä ominaisuuksia alaan liittyvän tietämyksen perusteella (Ng, 2013). Ominaisuuksien suunnitteluprosessin ensimmäinen vaihe on hyödyllisten ominaisuuksien kehittäminen joko automaattisella tai manuaalisella ominaisuuksien louhinnalla tai manuaalisen ja automaattisen ominaisuuksien louhinnan yhdistelmällä. Seuraava vaihe on ominaisuuksien valinta, jossa osajoukko louhittuja ominaisuuksia valitaan jonkin ominaisuuspisteytysmittarin mukaisesti. Ominaisuuksien valitsemisen jälkeen valittujen ominaisuuksien suorituskykyä arvioidaan kohdetietokannan perusteella. Ominaisuuksien suunnitteluprosessia toistetaan siihen asti, että saadaan tyydyttäviä tuloksia. (Nahavandi et al., 2022)

3.2 Ohjattu oppiminen

Ohjattu oppiminen (supervised learning) on koneoppimismenetelmä, jota käytetään, kun koulutusdatanäytteiden tavoiteltu tulos on tiedossa (Nahavandi et al., 2022). Ohjatussa oppimisessa malli koulutetaan käyttäen datanäytteitä ja datanäytteiden tavoiteltuja tuloksia (Alizadehsani, et al., 2021). Yleensä ohjattua oppimista käytetään luokittelussa, jonka tavoitteena on kuvata syötenäyte tulostunnisteseeseen (Caruana & Niculescu-Mizil, 2006). Datan luokittelu on yksi merkittävistä tekoälykonsepteista, joista on paljon hyötyä esineiden internetissä (Farrokhi et al., 2021). Ohjattua oppimista käytetään myös regressiossa, jonka tavoitteena on oppia kuvaus syötteistä jatkuvaan tulokseen. Sekä luokittelussa että regressiossa halutaan löytää oikeat suhteet syötteen ja tuloksen välille. Käytännössä ohjatussa oppimisessa etsitään mallia, joka pystyy tuottamaan oikeaa tulosdataa tehokkaasti. Jos koulutusaineisto on kohinaista tai siinä on virheellisiä merkintöjä, koulutetun mallin tehokkuus heikkenee selvästi. Joitakin yleisiä ohjatun oppimisen algoritmeja ovat *tukivektorikone* (support vector machine), keinotekoinen neuroverkko, *Naïvi Bayes* (naïve bayes) ja satunnaismetsä. (Nahavandi et al., 2022)

Satunnaismetsäalgoritmi on saanut merkittävää huomiota IoT-alalla kahden viimeisen vuosikymmenen aikana (Farrokhi et al., 2021). Satunnaismetsän saavuttama huomio johtuu satunnaismetsän kyvystä tarkkaan luokitteluun (Belgiu & Drăguț, 2016). Manjarresin et al. (2020) tutkimuksessa satunnaismetsällä oli parempi tulos verrattuna KNN-algoritmiin. Älykkäässä kuntoilussa voidaan hyödyntää satunnaismetsäalgoritmin vahvuuksia vaihtoehtoisten reittien valinnassa käyttämällä satunnaismetsää vaihtoehtoisten treeniliikkeiden valitsemisessa kuntoilijoille. Vaihtoehtoisia treeniliikkeitä tarvitaan, kun jokin treeniliike ei ole enää tehokas kuntoilijalle tai kun kuntoilijan kuntosalilla ei ole jotakin kuntoilulaitetta, joka tarvittaisiin jonkin treeniliikkeen suorittamiseen. Treeniliike voidaan korvata toisella treeniliikkeellä, jolla on samat vaikutukset. *Päätöspuualgoritmi* (decision tree algorithm) on sopiva tekniikka monimutkaisten ja monivaiheisten päätösten tekemiseen (Farrokhi et al., 2021). Päätöspuualgoritmi jakaa monimutkaiset ja suuret päätökset yksinkertaisempiin päätöksiin pyrkien tekemään niistä johtopäätöksiä (Safavian & Landgrebe, 1991). Päätöspuualgoritmia on käytetty esimerkiksi

tutkimuksessa, jossa pyrittiin valitsemaan urheilijalle paras ruokavaliosuunnitelma urheilusuoritusten kannalta (Fister et al., 2014).

Galán-Mercant et al. (2019) esittelivät tekoälypohjaisen sovelluksen maratonjuoksijoille. Galán-Mercantin et al. sovellus tarjosi juoksijoille tahdistussuunnitelmia heidän kuntotasonsa, olotilansa ja tavoiteaikansa mukaisesti. Galán-Mercantin et al. järjestelmä suositteli henkilökohtaista ennätystavoitetta ja tahdistussuunnitelmaa eri kilpailuosuuksia varten prosessoimalla aiempia viitetasoja ja ennätyksiä. Galán-Mercantin et al. mukaan kaikkien juoksijoiden tahdistustoimenpiteitä seurattiin ja verrattiin suositeltuun suunnitelmaan kilpailun aikana. Galán-Mercantin et al. sovellus myös antoi juoksijoille lisäehdotuksia. Galán-Mercant et al. käyttivät tavoiteajan ennustamiseen kolmea algoritmia: KNN-algoritmia, *lineaariregressiota* (linear regression) ja *elastisia verkkoja* (elastic nets). Galán-Mercant et al. kertovat, että tulokset ovat osoittaneet, että tavoiteajan ennustustarkkuus yleensä kasvaa maamerkkejä lisäämällä, mutta aina niin ei kuitenkaan tapahdu.

3.3 Ohjaamaton oppiminen

Ohjaamaton oppiminen (unsupervised learning) on koneoppimistekniikka, jonka tavoitteena on oppia merkitsemättömän datan luontainen rakenne (Nahavandi et al., 2022). Ohjaamattomassa oppimisessä kone saa syötedataa ilman tavoiteltuja tuloksia tai palkkiota (Farrokhi et al., 2021). Ohjaamattomassa oppimisessä kone ei saa lainkaan palautetta ympäristöstä, vaan siinä tuotetaan hyödyllisiä syötteitä päätöksentekoa tai muita koneoppimisen syötteitä varten (Ghahramani, 2003). Ohjaamattomassa oppimisessä prosessoidaan merkitsemätöntä dataa ja tuotetaan ennustemalleille hyödyllisiä tuloksia (Murdoch et al., 2019). Ohjaamattoman oppimisen tavallisimpia tehtäviä ovat klusterointi, tiheyden estimointi ja representaatio-oppiminen (Nahavandi et al., 2022). Ohjaamattoman oppimisen tehtäviä varten on ehdotettu algoritmeja, kuten pääkomponenttianalyysiä ja autoenkoodereita (Alizadehsani et al., 2021). Tutkiva analyysi ja dimensioiden vähentäminen ovat kaksi yleistä käyttötapaa ohjaamattomassa oppimisessä. Ohjaamattomia oppimismenetelmiä voidaan käyttää myös

silloin kun tietokokonaisuuksien analysointi on ihmiselle mahdotonta, jotta datasta saataisiin alustavat näkemykset. Datasta saatuja näkemyksiä voidaan käyttää erilaisten hypoteesien testaamisessa. Dimensioiden vähentämisessä dataa esitetään pienemmällä määrällä ominaisuuksia. Dimensioiden vähentäminenkin voidaan toteuttaa ohjaamattoman oppimisen avulla. Dimensioiden vähentämistä varten on löydettävä ominaisuuksien väliset suhteet. Kun ominaisuuksien väliset suhteet tiedetään, voidaan poistaa tarpeettomat ominaisuudet (Nahavandi et al., 2022.) Datan prosessointi voidaan suorittaa paljon vähemmän intensiivisellä ratkaisulla, kun tarpeettomat ominaisuudet on poistettu datasta (Fahami et al., 2021).

Ahmad et al. (2019) loivat järjestelmän, joka yhdisti tekoälyn ja sykkeenseurannan, jotta aktiviteetti, kuten juokseminen tai uiminen, voitaisiin tunnistaa. Ahmadin et al. järjestelmä tarjosi kuntoilijoille treenausmenetelmiä, joilla pyrittiin parantamaan suorituskykyä ja ehkäisemään vammoja maksimoimalla treenaamisen tehokkuus voimantuottoa virittämällä. Fisterin et al. (2018) tutkimuksessa k-means-algoritmia sovellettiin kuntoilijoista puettavilla fitness-seurantalaitteilla kerättyyn dataan. Fisterin et al. tutkimuksessa k-means algoritmi klusteroi datajoukoissa esiintyviä aktiviteetteja sykkeen ja aktiviteettien ajallisen keston perusteella. Fister et al. loivat online-datageneraattorin, jotta kuntoilijat voisivat käyttää generaattoria missä tahansa ja jotta laskentaprosessi olisi nopeampi. Fisterin et al. (2015) tutkimuksessa sovellettiin bat-algoritmia treenien suunnitteluun bat-algoritmin yksinkertaisuuden ja vähennettyjen seurantapisteen vuoksi. Crema et al. (2019) ja Depari et al. (2019) käyttivät PCA-algoritmia aktiviteettiklustereiden ja puettavien fitness-seurantalaitteiden keräämän datan karsimiseen.

3.4 Osittain ohjattu oppiminen

Osittain ohjattu oppiminen (semi-supervised learning) on koneoppimistekniikka, jota voidaan käyttää silloin kun ohjattua oppimista ja ohjaamatonta oppimista ei voida käyttää tehokkaasti. Osittain ohjattua oppimista voidaan käyttää esimerkiksi silloin kun merkittyjen datanäytteiden määrä on pieni ja merkitsemättömien datanäytteiden määrä on suuri. Datanäytteitä voidaan uuden esimerkin ennustamiseksi kouluttaa pienellä määrällä merkittyä dataa ja suurella

määrällä merkitsemätöntä dataa. Silloin kun on olemassa jonkin verran merkittyä dataa, merkitty data voi auttaa algoritmeja hyödyntämään merkitsemätöntä dataa tehokkaammin ja siten parantaa oppimisen tarkkuutta huomattavasti. Oppimisongelmissa käytettävän merkityn datan hankkiminen edellyttää yleensä asiantuntija-agentteja (Nahavandi et al., 2022.) Osittain ohjatun oppimisen merkitys tulee ilmi esimerkiksi silloin kun datanäytteiden merkitseminen on kallista tai kun datanäytteiden merkitseminen on mahdotonta merkitsemättömien datanäytteiden suuren määrän takia (Zhu & Goldberg, 2009).

Stikic et al. (2009) esittelivät tutkimuksessaan uuden menetelmän toiminnan tunnistamiseksi. Stikicin et al. tutkimuksen osittain ohjatussa oppimisprosessissa pieniä määriä merkittyä dataa yhdistettiin merkitsemättömään dataan. Stikicin et al. menetelmässä siirrettiin tietoa kuvaajassa, joka sisälsi sekä merkittyä että merkitsemätöntä dataa. Stikic et al. esittelivät kaksi erilaista tapaa yhdistää useita graafeja ominaisuuksien samankaltaisuuden perusteella. Stikic et al. arvioivat merkintöjen levittämisen prosessin laatua ja luokittelijoiden suorituskykyä.

Stikicin et al. (2008) tutkimuksessa testattiin osittain ohjatun oppimisen toteutettavuutta toiminnan tunnistamisessa oppimisen ohjaamisen vähentämiseksi. Stikic et al. käyttivät kahta osittain ohjattua tekniikkaa eli itse- ja yhteisoppimista toimintamallien oppimiseen vähäisesti merkitystä datasta. Stikicin et al. tutkimuksen tulokset osoittivat, että yhteisoppiminen toimi paremmin kuin itseoppiminen, koska yhteisoppimisessa käytettiin sensorimodaliteeteista saatua lisätietoa koulutusprosessin aikana. Lisäksi joissakin Stikicin et al. tutkimuksen tapauksissa yhteisoppimisessa saavutettiin jopa parempi tunnistustarkkuus kuin täysin ohjatuilla menetelmillä. Stikicin et al. ehdottama menetelmä perustui pool-pohjaiseen asetelmaan, joka mahdollisti sen, että käytettävissä oli suuri määrä merkitsemätöntä koulutusdataa pienen merkityn koulutusdatajoukon lisäksi. Stikicin et al. algoritmi pystyi valitsemaan parhaat informatiiviset datanäytteet, jotka asiantuntija myöhemmin merkitsi.

Toinen ihmisen toiminnan tunnistamiseen liittyvä tutkimus oli Man ja Ghasemzadehin (2019) LabelForest. Man ja Ghasemzadehin mukaan puettavilla fitness-seurantalaitteilla kerättyyn

dataan liittyy usein huomattava määrä kohinaa ja epävarmuutta. Man ja Ghasemzadehin LabelForest oli ei-parametrinen osittain ohjattu oppimiskehys toiminnan tunnistamiseen, joka paransi ML-algoritmien suorituskkyä laajentamalla koulutusdatajoukkoa. Man ja Ghasemzadehin LabelForest valitsi osajoukon merkitsemätöntä dataa datan merkitsemistä varten. Man ja Ghasemzadehin LabelForestissa näytteen valinta perustui samankaltaisuuteen merkittyjen datanäytteiden kanssa. Man ja Ghasemzadehin LabelForest-kehys koostui kahdesta algoritmista: spanning forest -algoritmista näytteen valintaa ja merkitsemistä varten sekä siluettipohjaisesta suodatusmenetelmästä, jolla valittiin datanäytteet, joiden klusterointi koulutusdatajoukkoon sisällyttämisestä oli todennäköisempi.

3.5 Vahvistusoppiminen

Vahvistusoppiminen (reinforcement learning) on koneoppimistekniikka, jossa oppija on vuorovaikutuksessa ympäristön kanssa suorittamalla joitakin toimia (Farrokhi et al., 2021). Suoritettavat toimet vaikuttavat ympäristöön, ja toimien suorittamisesta saatu palaute palautetaan oppijalle skalaaripalkkioina oppijan tavoitellessa palkkioiden maksimointia (Ghahramani, 2003). Toisin kuin ohjatussa oppimisessä, vahvistusoppimisessä haluttua toimintoa ei anneta oppijalle, vaan oppijan on kokeiltava erilaisia toimintoja erilaisissa tilanteissa, joita kutsutaan myös tiloiksi, selvittääkseen, mitkä ovat parhaita toimintoja, jotka johtavat maksimipalkkioon havaittujen tilojen perusteella. On tärkeää oppia valitsemaan toiminta siten, että pitkän aikavälin hyöty maksimoituu, sillä naiivi valinta välittömän palkkion maksimoimiseksi saattaa johtaa epäoptimaaliseen suoritukseen pitkällä aikavälillä. Vahvistusoppimisen ongelmat voidaan mallintaa Markovin päätösprosesseina. Markovin päätösprosessi on 4-monikko (S, A, P, R) , jossa S on tilojen joukko eli tila-avaruus, A on toimintojen joukko eli toiminta-avaruus, $P(s_{t+1} = s' | s_t = s, a_t = a)$ on siirtymäfunktio, jonka tulos on todennäköisyys havaita tila s aika-askeleella $t + 1$ edellyttäen, että aika-askeleella t havaittu tila on s ja valittu toiminto on a ja $r_{t+1} = R(s_t = s, a_t = a, s_{t+1} = s')$ on odotettu palkkio, jos aika-askeleella t havaittu tila on s ja valitun toiminnon a suorittaminen johtaa tilaan s' aika-askeleella $t + 1$. (Nahavandi et al., 2022)

Schmidtin et al. (2015) mukaan vahvistusoppimisalgoritmeja käyttämällä järjestelmä voi mallintaa treeniohjelmaa ja seuraavaan aktiviteettiin siirtymistä sekä seurata ja arvioida kullekin henkilölle sopivaa treeniohjelmaa käyttäytymisen perusteella. Schmidt et al. ottivat käyttöön matemaattisia malleja kuntoilijan toiminnan tutkimiseksi. Schmidt et al. käyttivät tarkalleen ottaen Markovin päätösprosessia ja osittain havaittavissa olevaa Markovin päätösprosessia. Schmidtin et al. tutkimuksessa määriteltiin toiminnan laji eli se, onko kuntoilijan treeni nykyiseen kuntotasoon nähden liian kevyt, sopiva vai liian raskas. Jos kuntoilijan treeni oli Schmidtin et al. järjestelmän mukaan kuntoilijan kuntotasoon nähden liian kevyt, kuntoilijan tuli muuttaa treeniään raskaampaan suuntaan. Jos taas Schmidtin et al. järjestelmän mukaan kuntoilijan treeni oli kuntoilijan kuntotasoon nähden liian raskas, kuntoilijan tuli muuttaa treeniään kevyempään suuntaan. Jos Schmidtin et al. järjestelmä piti kuntoilijan treeniä kuntoilijan kuntotasoon nähden sopivana, kuntoilijan tuli säilyttää treeni treeniohjelmassaan.

Zhou et al. (2018) hyödynsivät vahvistusoppimista kehittämässään fitness-sovelluksessa. Zhoun et al. fitness-sovelluksessa käytettiin vahvistusoppimisalgoritmia, joka oli sovitettu siten, että se loi kullekin käyttäjälle henkilökohtaiset ja mukautuvat päivittäiset askelittaiset tavoitteet, jotta käyttäjän tavoitteet olisivat haastavia mutta kuitenkin saavutettavissa. Lisäksi Zhoun et al. sovelluksessa oli monia käyttäytymisen muutokseen liittyviä ominaisuuksia, kuten itseseuranta ja räätälöity palaute. Zhoun et al. käyttämä käänteistä vahvistusoppimista ja vahvistusoppimista sisältävä *käyttäytymisanalytiikan algoritmi* (behavioral analytics algorithm) pääsi käsiksi sovellukseen tallennettuun askel- ja tavoitedataan. Zhoun et al. tutkimuksen käyttäytymisanalytiikan algoritmi arvioi käyttäjää kuvaavia malliparametreja käänteisen vahvistusoppimisen avulla. Zhoun et al. fitness-sovelluksessa käänteistä vahvistusoppimista seurasi vahvistusoppimisen avulla tapahtuva käyttäjän tulevan fyysisen aktiivisuuden maksimoivien henkilökohtaisten askeltavoitteiden laskeminen.

3.6 Syväoppivat neuroverkot

Syväoppiminen on osa laajempaa keinotekoisiiin neuroverkkoihin perustuvaa koneoppimismenetelmien perhettä (Nahavandi et al., 2022). Syväoppimisessa käytetään paljon *konvoluutioneuroverkoja*, jotka ovat erityinen keinotekoisien neuroverkkojen tyyppi, joka pystyy käsittelemään kaksiulotteista kuva-aineistoa (Sharifrazi et al., 2021; Oh et al., 2020). Konvoluutioneuroverkon pääkomponentti on konvoluutiokerros, joka suorittaa konvoluution tietylle kuvalle. Konvoluution suorittamiseksi on määriteltävä kuvaa pienempi kaksiulotteinen painoarvojen joukko, jota kutsutaan *ytimeksi* (kernel) (Nahavandi et al., 2022.) Konvoluutio-operaatio on yksinkertaisesti ytimen pistetulo ytimen kokoisen kuvan osan kanssa (Alizadehsani et al., 2021). Konvoluutiokerroksen tulos ohjataan aktivaatiofunktion, kuten oikaistun lineaarisen yksikön (rectified linear unit), läpi. Automaattinen ominaisuuksien louhinta on yksi konvoluutioneuroverkkojen tärkeimmistä ominaisuuksista. Konvoluutioneuroverkkojen kouluttaminen kuitenkin yleensä vaatii paljon tietokoneresursseja (Nahavandi et al., 2022.) Viime vuosina tietokoneressivaatimuksista johtuva taakka on kuitenkin vähentynyt tehokkaiden näytönohjainten myötä (Khodatars et al., 2020).

Farrokhin et al. (2021) mukaan syväoppiminen ja keinotekoiset neuroverkot ovat tekoälytekniikoita, jotka otetaan tulevaisuudessa laajasti käyttöön monimutkaisemmissa IoT-ratkaisuissa. Yongin et al. (2018) tutkimuksessa syväoppimista käytettiin toiminnan tunnistamiseen ja korjaamiseen loukkaantumisten ehkäisemiseksi. Vainamon et al. (1996) mukaan keinotekoinen neuroverkko voi mahdollisesti auttaa aerobisten kuntoilutreenien arvioinnissa, ohjaamisessa ja määrittelyssä mittaamalla kuntoilijan hapenottokykyä ja sykettä ja hyödyntämällä demografisia muuttujia. Lu et al. (2016) ehdottivat järjestelmää sykevälivaihteluiden hallitsemiseksi. Lun et al. järjestelmä sisälsi käyttäjän rintaan asetettavan sykesensorin, joka lähetti dataa sykevastaanottimeen. Lun et al. järjestelmä kykeni verkkooppimiseen ja se pystyi ohjaamaan juoksumaton nopeutta ja kaltevuutta kullekin kuntoilijalle soveltamalla *takaisinkytkettyyn sumeaan neuroverkkoon* (recurrent fuzzy neural network)

perustuvaa sykesäädintä. Lun et al. mukaan syväoppiminen on hyödyllistä kuntoiluliikkeiden seurannassa ja tunnistamisessa.

Nardi (2014) käytti yksi- ja kaksidimensioisia konvoluutioneuroverkkoja kuntoiluliikkeiden, kuten penkkipunnerruksen, maastavedon ja pystypunnerruksen, tunnistamiseen ja ennustamiseen. Nardin tutkimuksessa käyttäjän olkapäähän asennettiin gyroskooppi olkapään liikkeen seuraamiseksi. Nardin tutkimuksessa asennettiin myös toinen gyroskooppi ja yksi kiihtyvyyssensori käyttäjän käden kiihtyvyyden ja kiertoliikkeen seuraamiseksi. Nardi käytti gyroskooppien ja kiihtyvyyssensorin lisäksi Bluetooth Low Power -laitetta datan lähettämiseksi mobiilisovellukseen.

Xu (2012) käytti tutkimuksessaan geneettistä algoritmia ja neuroverkkoja suorituskyvyn ennustamiseen urheilussa. Xun tutkimuksessa arvioitiin ensin ominaisuuksia, kuten väsymys, sää, kokemus, treenaamisaika, paino, pituus ja ravitsemustiedot. Ominaisuuksien arvioimisen jälkeen Xun tutkimuksessa luokiteltiin ominaisuudet tasoille A, B tai C. Ominaisuuksien luokittelun jälkeen Xun tutkimuksessa määritettiin alustava treeniohjelma ottamalla huomioon käytettävissä olevat ominaisuudet ja niiden luokittelu. Xun tutkimuksessa kuntoilijalle määritettiin kunkin treenin jälkeen uusi treeniohjelma, jossa otettiin huomioon aiemmat ominaisuudet ja treenitulokset. Xun tutkimuksen prosessi jatkui, kunnes (1) saavutettiin tietty määrä iteraatioita, (2) saavutettiin haluttu tavoite, (3) määritettiin parhaan kelpoisuuden treeniohjelma eikä parempiin tuloksiin ollut mahdollista päästä, (4) suoritettiin inhimillinen tarkastelu ongelmien varalta tai (5) kaikki kohdat täyttyivät.

4 Smart Fitness - Sosiaalinen esineiden internet

Ihmisten välillä on sosiaalisia suhteita, jotka muodostavat yhteisöjä useiden tekijöiden perusteella. Yhteisön jäsenet ovat vuorovaikutuksessa keskenään ja he tekevät yhteistyötä ratkaistakseen minkä tahansa monimutkaisen ongelman. Sosiaalisten verkostojen konseptia voidaan soveltaa esineiden internetissä esineiden internetin ekosysteemin haasteisiin vastaamiseksi (Roopa et al., 2019.) Sosiaalisten ominaisuuksien soveltaminen esineiden internetin paradigmaan on luonut uuden konseptin älykkäiden esineiden ja palvelujen sosiaalisesta verkostosta, jota kutsutaan sosiaaliseksi esineiden internetiksi (Atzori et al., 2012). Sosiaalinen esineiden internet on paradigma, jonka avulla esineiden internetin älykkäät esineet, sovellukset ja laitteet voivat luoda yhteyksiä toisiinsa luotettavalla ja turvallisella tavalla datan vaihtamiseksi ja toiminnan muuttamiseksi (Nitti et al., 2013).

Fitness-seurantalaitteiden kehittyessä ja niiden käytön lisääntyessä, datan jakaminen ja vaihtaminen eri järjestelmien välillä on tärkeää, jotta saavutettaisiin täysi ymmärrys käyttäjän tilasta ja kontekstista. Datan jakaminen ja vaihtaminen eri järjestelmien välillä on tärkeää myös käyttäjän tarpeiden ja todellisen toimintaympäristön välillä välittäjänä toimivien päätöksentekoprosessien parantamiseksi. Älykkäässä kuntoilussa käyttäjien kanssa vuorovaikutuksessa olevat järjestelmät, kuten fitness-seurantalaitteet ja älykkäät kuntoilulaitteet, voisivat jakaa dataa ja tunnistaa käyttäjän tilan ja ehdottaa yhdistettyä treeniohjelmaa. Laajemmassa mittakaavassa julkiset hyvinvointisovellukset voisivat hyötyä yhteen toimivuudesta ja tietojenvaihdosta fitness-seurantalaitteiden ja älykkäiden kuntoilulaitteiden kanssa. (Farrokhi et al., 2021) Tässä luvussa kerrotaan sosiaalisesta esineiden internetistä ja sosiaalisen esineiden internetin käyttömahdollisuuksista älykkäässä kuntoilussa. Aliluvussa 4.1 kerrotaan esineiden internetistä yleisellä tasolla. Aliluvussa 4.2 kerrotaan käyttäjäprofiloinnista. Aliluvussa 4.3 kerrotaan suosittelujärjestelmistä.

4.1 Sosiaalinen esineiden internet

Sosiaalinen esineiden internet on yksi nousussa olevista sensorilaitteiden välistä vuorovaikutusta tukevista konsepteista (Farrokhi et al., 2021). SloT eroaa kuitenkin hieman ihmisten sosiaalisista verkostoista (Atzori et al., 2011). SloT:lle on useita määritelmiä (Farrokhi et al., 2021). SloT luo IoT-objektien välille suhteita, joiden avulla IoT-objektit voivat jakaa resursseja ja palveluja ystäväobjektiansa kanssa ja olla vuorovaikutuksessa toistensa kanssa yhteisten tavoitteiden saavuttamiseksi (Atzori et al., 2011; Afzal et al., 2019). SloT:ssa on erilaisia objektien välisiä suhteita. *Objektien vanhemmuussuhde* (parental object relationship) luodaan samaan tuotantoluokkaan kuuluvien objektien välille. *Objektien yhteissijaintisuhde* (co-location object relationship) luodaan samassa paikassa olevien objektien välille välittämättä siitä, ovatko objektit homogeenisia vai heterogeenisia. *Objektien yhteistyösuhde* (co-work object relationship) luodaan objektien välille tietyn IoT-sovelluksen tarjoamiseksi. *Objektien omistajuussuhde* (ownership object relationship) luodaan tietystä käyttäjästä riippuvaisten heterogeenisten objektien välille. *Objektien sosiaalisuussuhde* (social object relationship) luodaan toisiinsa yhteydessä olevien objektien välille, koska objektien omistajat ovat yhteydessä toisiinsa jossakin paikassa. SloT:n objektien suhteet ilmenevät ilman ihmisen toimenpiteitä ja myös suhteiden hallinnan tulisi tapahtua ilman ihmisen toimenpiteitä. (Atzori et al., 2012)

Sosiaalisten verkostojen konsepti ja sosiaalisten verkostojen taustalla olevat mekanismit ovat kiinnostavia Smart Fitness -järjestelmien ja yleisemmin IoT-järjestelmien yhteen toimivuuden kannalta (Farrokhi et al., 2021). IoT käsittää heterogeenisiä laitteita, sensoreita ja järjestelmiä. IoT-järjestelmät ovat tavallisesti sulautettuja ratkaisuja eli IoT-järjestelmät voivat olla vuorovaikutuksessa ja kommunikoida keskenään, jos ne käyttävät yhteensopivia käyttöjärjestelmiä, laitteistoja, ohjelmistoja ja protokollia. IoT-järjestelmien ja -sensorien datan yhteen toimivuutta tarvitaan, jotta voitaisiin mahdollistaa IoT-datan ja -laitteiden yhteistyö ja sosiaalistaminen. (Afzal et al., 2019)

SIoT-määritelmän soveltaminen älykkääseen kuntoiluun vaikuttaa erittäin lupaavalta, sillä SIoT tukee erilaisia suhteita: sosiaalisten verkostojen vuorovaikutusta hyvin paljon muistuttavia ihmisten välisiä suhteita sekä informaatiota ja toiminnallisuuksia sosiaalistavien esineiden välisiä suhteita (Saleem et al., 2016). Esineiden väliset suhteet eivät välttämättä ole kaikkien esineiden käytettävissä, vaan niitä ohjaavat yhteiset tavoitteet ja niitä rajoittavat datan omistusoikeus ja käyttäjien yksityisyys (Farrokhi et al., 2021). Toisiinsa yhteydessä olevat esineet ja objektit voivat tällöin luoda suotuisia vuorovaikutussuhteita ystävöobjektien välille (Atzori et al., 2011; Afzal et al., 2019). SIoT-konseptia ja -mekanismeja hyödyntämällä voidaan kehittää vakaa ja toiminnallisuuksiltaan laaja järjestelmä, joka kykenee koordinoimaan ja organisoimaan sosiaalisen esineverkoston jäseniä ja objekteja (Nitti et al., 2013). SIoT:n potentiaalilla on edellytykset parantaa loppukäyttäjille tarjottavien palvelujen ja toiminnallisuuksien yleistä laatua. SIoT:ssa järjestelmän valmiuksia ja tarjottavien palvelujen laatua voidaan parantaa esimerkiksi käyttäjäprofiloinnilla ja suosittelujärjestelmillä. (Farrokhi et al., 2021)

4.2 Käyttäjäprofilointi

Käyttäjäprofilointi (user profiling) määritellään prosessiksi, jossa kerätään verkkopalveluja käyttävän selkeästi identifioidun yksilön tuottamaa dataa, kehittämällä prosessia jatkuvasti käyttäjän käyttäytymisen ja kiinnostuksen kohteiden selvittämiseksi (Farrokhi et al., 2021). Käyttäjäprofiloinnin avulla voidaan räätälöidä tai parantaa palveluja ja lisätä asiakastytyväisyyttä. Käyttäjäprofilointi on itse asiassa johdettu koneoppimisesta (Kanoje et al., 2015.) Käyttäjäprofilointi havaitsee laitteen käyttäytymisen koneoppimisalgoritmeista johdetun analyysin perusteella (Lee et al., 2017). Käyttäjäinformaatio koostuu useista ominaisuuksista, kuten kohteen käyttäytymisestä, taustasta, prioriteeteista, tavoitteista ja toiveista (Schiaffino & Amandi, 2009). Käyttäjäprofilointia ei käytetä ainoastaan yksilöllisen käyttäytymisen ja toiminnan esittämiseen ja jatkuvaan jalostamiseen. Käyttäjäprofilointia käytetään myös esimerkiksi samankaltaisten kohteiden käyttäytymisen tutkimiseen ja klusterointiin ja palvelujen ja toiminnallisuuksien mallintamiseen. Klusteroinnissa ja mallintamisessa voidaan soveltaa erilaisia tekniikoita ja prosesseja. (Farrokhi et al., 2021)

Staattinen käyttäjäprofilointi on lähestymistapa, jossa analysoidaan käyttäjän staattisia ja ennustettavia ominaisuuksia. Käyttäjän staattisiin ja ennustettaviin ominaisuuksiin liittyvä data saadaan yleensä käyttäjiltä itseltään, esimerkiksi sähköisistä rekisteröinti- tai kyselylomakkeista. Staattisen käyttäjäprofiloinnin avulla yleensä tiedetään, millaisesta tiedosta käyttäjä on kiinnostunut tietojenantamishetkellä. Pelkkään staattiseen käyttäjäprofilointiin eli käyttäjän manuaalisen syötteen avulla tapahtuvaan käyttäjäprofilointiin liittyy useita ongelmia. Ensinnäkin pelkkään staattiseen käyttäjäprofilointiin perustuva käyttäjäprofiili on staattinen, ja se on voimassa vain tietyn ajan, kunnes käyttäjä muuttaa kiinnostustaan. Näin ollen staattisen käyttäjäprofiilin laatu heikkenee ajan myötä. Lisäksi käyttäjän kiinnostuksen kohteisiin perustuva syöte on altis käyttäjän subjektiivisuudelle eikä välttämättä vastaa tarkasti objektiivista näkemystä, josta voitaisiin päätellä muiden samanlaisia kiinnostuksen kohteita omaavien käyttäjien kiinnostuksen kohteita. (Poo, 2003)

Dynaaminen käyttäjäprofilointi taas on lähestymistapa, jossa analysoidaan käyttäjän toimintaa tai toimia käyttäjän kiinnostuksen kohteiden määrittämiseksi. Dynaamisessa käyttäjäprofiloinnissa käyttäjän käyttäytyminen on kiinnostavaa, ja dynaamista käyttäjäprofilointia kutsutaankin joskus käyttäytymisprofiloinniksi. Vaikka käyttäjien kiinnostuksen kohteet saadaankin selville reaaliaikaisesti, käyttäjän yleisempiä kiinnostuksen kohteita ei voida jäljittää. (Poo, 2003)

Hybridikäyttäjäprofiloinnissa staattisen ja dynaamisen käyttäjäprofiloinnin edut yhdistyvät. Toisin sanoen hybridikäyttäjäprofiloinnissa otetaan huomioon sekä käyttäjän staattiset ominaisuudet että haetaan käyttäjää koskevaa käyttäytymistietoa. Hybridikäyttäjäprofiloinnin avulla käyttäjäprofilointi on tehokkaampaa ja ajallisen tiedon tarkkuus säilyy, koska tiedot päivittyvät ajantasaisesti. (Kanoje et al., 2015)

Käyttäjäprofiilien luomiseen voidaan käyttää erilaisia menetelmiä, algoritmeja ja proseduureja. On olemassa useita muita tilastoihin tai numeeriseen analyysiin perustuvia menetelmiä, kuten Bayesin verkot, assosiaatiosäännöt ja tapauspohjainen päättely (Schiaffino & Amandi, 2009).

Myös muita tekoälyyn ja koneoppimiseen perustuvia tekniikoita, kuten datanlouhintaa, datan yhdistämistä, datan puhdistamista ja klusterointia sovelletaan (Lee et al., 2017). Bayes-verkot ovat graafinen malli muuttujien välisistä todennäköisyysuhteista ja kommunikaatiosta. Bayes-verkot ovat yksi yksinkertaisista tavoista esittää laadullisia ja määrällisiä suhteita käyttäjän kiinnostuksen kohteiden välillä ennusteiden tekemistä ja päätöksentekoa varten (Schiaffino & Amandi, 2000; Sebastiani et al., 2000). Tapauspohjainen päättely on ongelmanratkaisumenetelmä, jossa päätökset tehdään kussakin ongelmassa aiempien ongelmien ratkaisemisesta saatujen kokemusten perusteella. Assosiointisäännöt on yksi tärkeimmistä menetelmistä, joilla löydetään joukko tapahtumia, jotka esiintyvät tietyn ajan sisällä. (Farrokhi et al., 2021)

Käyttäjäprofiilien luomisessa käytettyjä tekniikoita verrattaessa voidaan todeta, että Bayes-verkot keskittyvät eniten ominaisuuksien ja piirteiden väliseen suhteeseen niiden välisen riippuvuuden kuvastamiseksi, mikä voi auttaa suodattamaan dataa paremmin datakokonaisuudesta. Tapauskohtainen päättely keskittyy samankaltaisiin tilanteisiin ja tuloksiin. Tapauskohtaisessa päättelyssä suodatus tapahtuu ongelman ja tilanteen sekä aiempien kokemusten mukaan. Assosiaatiosäännöt puolestaan keskittyvät vain useimmiten tiettyinä ajankohtana tapahtuviin tapahtumiin. Assosiointisääntöjen suodatus perustuu pääosin samanaikaisten valintojen määrään. (Farrokhi et al., 2021)

Datan suodattamiseen on olemassa erilaisia lähestymistapoja, kuten sisältöön perustuvat suodatusmenetelmät ja yhteistyösuodatusmenetelmät. Sisältöön perustuvissa suodatusmenetelmissä verrataan käyttäjäprofiiliin liittyvien kohteiden sisältöä ja valitaan ne kohteet, joiden sisältö vastaa parhaiten toisen käyttäjäprofiilin sisältöä samankaltaisuusmittareita käyttäen. Profiilin sisältö on sisältöön perustuvassa suodatusmenetelmässä hallitseva ja riippuu siitä, miten hyvin profiilit vastaavat muiden käyttäjien profiileja, mikä voi kuitenkin olla ongelmallista, koska jotkut käyttäjät ovat haluttomia antamaan tietoja itsestään (Poo, 2003.) On vaikea varmistaa, että kaikki käyttäjät antavat vapaaehtoisesti palautetta tällaisille järjestelmille, koska tutkimuskohteen tutkiminen ja arviointi

on kallista (Ramscar et al., 1997). Ellei käyttäjä koe, että tällaiseen arviointiin osallistumisesta on lisäarvoa, parhaimmillakin suodatusstrategioilla varustettu järjestelmä voi silti johtaa siihen, että arvosanoja ei anneta lainkaan (Hirashima et al., 1998). Näin ollen tarvitaan implisiittistä luokittelua, joka poistaa kohteen tutkimisesta aiheutuvat kustannukset keneltä tahansa arvioijalta. Lisäksi tällaisten implisiittisten luokitusten laskentakustannusten on oltava parhaimmillaan piilossa käyttäjältä. (Poo, 2003)

Yhteistyösuodatusmenetelmissä järjestetään samankaltaisia kiinnostuksen kohteita omaavat käyttäjät vertaisryhmiin, jolloin vertaisryhmän jäsenet voivat suositella muille ryhmän jäsenille vertaisryhmänsä kiinnostavina pitämiään kohteita. Yleensä vertaisryhmiin järjestäminen tehdään klusteroimalla eri käyttäjien profiileja. Koska yhteistyösuodatus nojautuu pitkälti käyttäjäklustereihin, sen tehokkuus riippuu suuresti siitä, miten hyvin profiilien klusterointi korreloi käyttäjien kanssa. (Poo, 2003)

IoT-järjestelmissä on mahdollista liittää tiettyjä käyttäjiä sensoreihin tai mitattuihin konteksteihin. Sensoridatan seuranta voi olla hyödyllistä käyttäjiin liittyvän datan keräämiseksi (Farrokhi et al., 2021.) Solmujen ja esineiden käyttäytymisen ja datan seuranta ja kerääminen voi olla hyödyllistä käyttäjän käyttäytymisen rekonstruoimiseksi ja profiloimiseksi (Lee et al., 2017). Käyttäjäprofilointi älykkäässä kuntoilussa voisi olla keino tarjota relevanttia dataa yhteen toimiville sovelluksille, jotka voisivat tarjota integroituja ehdotuksia treeniliikkeiden tasoista ja aikataulusta sekä ruokavaliosuunnitelmista (Farrokhi et al., 2021). Esimerkiksi Jainin (2015) tutkimuksessa kerättiin käyttäjältä tietoja, kuten ikä, sukupuoli, henkilötunnus, paino, kokemus ja pituus. Lisäksi Jainin tutkimuksessa haettiin ja tallennettiin dynaamisempia tietoja, kuten treeniliikkeiden tyyppi ja tulokset.

Monet Smart Fitness -arkkitehtuurit hyödyntävät perustietoja (Pérez et al., 2012; Yong et al., 2018). Käyttäjäprofilointia käytetään lähes kaikissa fitness-suunnitteluskenaarioissa. Kun valitaan fitness-seurantalaite, käyttäjän on ladattava sovellus sovelluskaupasta ja syötettävä henkilökohtaiset tietonsa ja perustietonsa. Syötettävät tiedot ovat kaikkien Smart Fitness -sovellusten perusvaatimus. Smart Fitness -sovellukset keräävät ja tallentavat perustiedot ja

laativat sen jälkeen treeni- tai ateriasuunnitelmia, joissa on kaavioita ja graafisia esityksiä käyttäjän edistymisestä tai taantumisesta. Kaikki informaatio perustuu perustietojen ja dynaamisten tietojen keräämiseen niiden ollessa osa käyttäjäprofiilia. (Farrokhi et al., 2021)

4.3 Suosittelujärjestelmät

Suosittelujärjestelmät (recommender system) on suunniteltu ennustamaan käyttäjien mieltymyksiä tuotteisiin tai palveluihin ilman suoraa vuorovaikutusta käyttäjien kanssa (Kunaver & Pozrl, 2017). Suosittelujärjestelmien tekemät suositukset räätälöidään käyttäjän kiinnostuksen kohteiden ja ominaisuuksien perusteella (Al-Shamri, 2016). Suositukset ovat hyvin merkityksellisiä erilaisissa Smart Fitness -skenaarioissa. Tyypillisesti suosittelujärjestelmien suosittelumallit toimivat analysoimalla käyttäjien aiempaa dataa, määrittämällä heidän käyttötottumuksiaan ja vertaamalla käyttäjien käyttötottumuksia nykyisten käyttäjien käyttötottumuksiin parhaiten sopivan tuotteen tai palvelun ehdottamiseksi. Suosittelujärjestelmät perustuvat käyttäjäprofilointiin ja datan, mallien ja käyttäytymisen syväanalyysiin, joka on johdettu tekoälyn ja koneoppimisalgoritmien avulla. (Farrokhi et al., 2021)

Suosittelujärjestelmiä voidaan hyödyntää tehokkaamman yksilöllisen kehotyypin huomioivan treenaamisen suositteluun. Suosittelujärjestelmät voivat myös kerätä ja määrittää sopivimmat kokemukset kehon ominaisuuksien erilaisten typologioiden tai iän, sukupuolen ja muiden yksilöllisten tekijöiden perusteella (Farrokhi et al., 2021.) Suosittelujärjestelmä voi esimerkiksi käyttää kaikkea sille syötettyä dataa henkilökohtaisen treenisuunnitelman laatimiseen (Liu et al., 2010).

Suosittelujärjestelmistä voi olla hyötyä myös vammojen ehkäisyssä. Jos esimerkiksi älykkäiden kuntosalien sijainteja palvelevassa IoT:n organisoimassa yhteen toimivassa järjestelmässä jokin aktiviteetti on aiheuttanut vammoja tiettyntyyppisille käyttäjille, kuten tietyn ikäisille tai tietyn kuntoisille käyttäjille, suosittelujärjestelmä voi päätellä, että kyseinen aktiviteetti ei sovellu tiettyntyyppisille käyttäjille tai aktiviteetin suorittaminen voi olla tiettyntyyppisille käyttäjille

riskialtista (Farrokhi et al., 2021.) Schmidtin et al. (2015) suosittelujärjestelmä on toinen hyvä esimerkki arvokkaasta suosittelujärjestelmästä. Schmidtin et al. suosittelujärjestelmä suosittelee käyttäjää valitsemaan raskaampia tai kevyempiä liikkeitä, ja siten suosittelujärjestelmä itse asiassa suosittelee ja ehdottaa yksilöityä treeniä. Ravitsemukseen liittyvä ennustaminen ja ruokien suosittelu ruokavaliosuunnitelmaa varten on toinen aihe, joka suoritetaan analysoimalla käyttäjän tilannetta ja hänen antamaansa palautetta (Fister et al., 2014).

Internetin leviämisen ja mobiilisovellusten lisääntyneen käytön myötä urheilukulttuurin odotetaan kehittyvän ja tarpeen asianmukaisille suosittelujärjestelmille kasvavan (Venkatachalam & Ray, 2022.) Käyttäjän mahdollisuus valita omien mieltymysten mukainen ohjaaja tai valmentaja lisää käyttömukavuutta (Ziv & Lidor, 2009) ja käyttäjän sijaintiin, käyttäjäryhmiin ja ympäristöön liittyvät dynaamiset muutokset tehostavat suosittelujärjestelmiä. Esimerkiksi kontekstietieto vaihtelee saman käyttäjän kohdalla kontekstin, kuten treenipaikan tai ajan mukaan. Käyttäjän mieltymys treenaamiseen tietyssä paikassa, kuten kuntosalilla, voi vaihdella käyttäjän mielialan tai treeniajankohdan mukaan (Venkatachalam & Ray, 2022.) Lisäksi käyttäjäryhmien vuorovaikutus, kulttuuririippuvuus (Dara et al., 2019; Nowak, 2013) ja täydentävät vuorovaikutussuhteet ristikkäistoimintojen, kuten ravitsemuksen, musiikin tai urheiluasun kanssa vaikuttavat suositusten tarkkuuteen ja siihen, mitkä ovat relevantteja suosituksia (Venkatachalam & Ray, 2022). Jos kuntoilija pystyy omaksumaankin teknologian, kuten fitness-seurantalaitteiden, mobiililaitteiden ja digitaalisten sovellusten käytön, dataan perustuvien suositusten tehokkuus kasvaa (Kos et al., 2019). Dataan perustuvien suositusten tehokkuuden ansiosta *kontekstietoiset suosittelujärjestelmät* (Context-Aware Recommender System, CARS) ovat nousseet enenevässä määrin kaikkien fitness-sovellusten kulmakiveksi (Venkatachalam & Ray, 2022). Akateemisessa tutkimuksessa kontekstietoisten suosittelujärjestelmien algoritmit nähdään osana tekoälyä ja erityisesti osana koneoppimista (Del Carmen Rodriguez-Hernández & Ilarri, 2021), sillä yhä useammin tekoälytekniikoita sovelletaan suosittelumootoreiden prosessointialgoritmeissa (Venkatachalam & Ray, 2022).

Huolimatta CARS:ien käytännön eduista fitness-alalla, CARS:eista yhteiskunnalle syntyvistä eduista ja haasteista ja CARS:ien innovatiivisesta potentiaalista, CARS:ihin liittyvä tutkimus on ollut vähäistä (Venkatachalam & Ray, 2022). Fitness-sovelluksissa konteksti voi olla staattinen tai dynaaminen (Villegas et al., 2018), ja CARS:ien datapohjaisen soveltamisen vaikutusta fitness-alaan on tutkittava. Lisäksi fitness-sovellusten lisääntyvä käyttöönotto johtaa datan omistajuuteen, tiedon jakamiseen ja yksityisyyden suojaan liittyviin yhteiskunnallisiin haasteisiin. CARS:eista koituvat yhteiskunnalliset ongelmat saattavat mahdollisesti olla esteenä dataan perustuvien sovellusten innovaatioille. (Venkatachalam & Ray, 2022)

Suosittelujärjestelmät ovat algoritmeja, jotka perustuvat päämäärään (Kunaver & Pozrl, 2017). Ensisijaisesti suosittelujärjestelmät keskittyvät käyttäjään ja kohteeseen liittyviin dimensioihin. Algoritmien prosessointi sisältää asioiden kartoituksen käyttäjiin ja käyttäjäkohtaisiin kohdemieltymyksiin. Kartoitukset voivat olla selkeitä arvostelujen ja luokitusten kautta tai epäsuorasti pääteltävissä käyttäjän vuorovaikutuksen perusteella. Toisaalta yhteissuodatus käyttää käyttäjäyhteisön samankaltaisuusmittaria (Venkatachalam & Ray, 2022.) Käyttäjien mieltymysten relevanssi ja samankaltaisuus kerätään ja kohteita suositellaan mieltymysmallien perusteella (Villegas et al., 2018). Suurempi käyttäjämäärä ja suurempi määrä datapisteitä tai luokituksia parantavat suositusten tarkkuutta. Vastaavasti sosiaalisten verkostojen rooli on noussut yhä suuremmaksi suosittelujärjestelmissä, kuten naapuruspohjaisessa yhteistoiminnallisessa suodatuksessa ja yhteistoiminnallisen suodatuksen aihemallintamisessa yksilöllisten suositusten tarjoamiseksi. (Venkatachalam & Ray, 2022)

Viime vuosina on usein käytetty hybridisuosittelujärjestelmiä, joissa algoritmimallit yhdistetään sopivan kohteen määrittämiseksi (Venkatachalam & Ray, 2022). Hybridialgoritmeissa yhdistetään molemmat lähestymistavat käyttäjäongelmien lieventämiseksi ja prosessoinnin optimoimiseksi (Ben Sassi et al., 2017; Paradarami et al., 2017). Tietoon perustuva suosittelujärjestelmä perustuu käyttäjien sovellusaluekohtaisen tiedon tyydyttämiseen (Ricci et al., 2010). Tietoon perustuvat suosittelujärjestelmät ovat sisältöpohjaisen lähestymistavan alatyyppejä. On myös olemassa yhteissuodatuksen lähestymistavan alle kuuluvia yhteisöpohjaisia suosittelujärjestelmiä, jotka

tarkastelevat käyttäjäprofiilien samankaltaisuutta. (Venkatachalam & Ray, 2022) Taulukossa 1 esitellään erilaisia suosittelujärjestelmätyyppejä.

Taulukko 1. Suosittelujärjestelmätyyppejä. (Venkatachalam & Ray, 2022)

Suosittelujärjestelmätyyppi	Arviointifunktio	Kuvaus
Demografinen suosittelujärjestelmä	Käyttäjäprofiili	Perustuu sukupuoleen, ikään, kansallisuuteen, pituuteen, painoon ja muuhun fysiologiseen dataan
Sisältöperustainen suosittelujärjestelmä	Käyttäjä ja Kohde	Perustuu käyttäjän aiemmin pitämien kohteiden samankaltaisuuteen
Yhteistoiminnallinen suosittelujärjestelmä tai suosittelujärjestelmä sosiaalisella suodatuksella	Käyttäjä ja Kohde	Perustuu kohteisiin, joista myös samankaltaiset käyttäjät pitävät
Hyötysuosittelujärjestelmä	Käyttäjä ja Lyhytaikaiset kohteet, kuten festivaalitarjoukset	Kartoittaa kohteen hyödyllisyyttä käyttäjälle eikä rakenna pitkän aikavälin historiallista havainnointia
Tietosuositelujärjestelmä	Käyttäjä ja Kohde	Edellä mainittujen yhdistelmä - hyöty, tieto ja/tai yhteistyö
Kontekstitietoinen suosittelujärjestelmä	Käyttäjä, Kohde ja Konteksti	Konteksti ratkaisevana ja lisäsuodatustekijänä

Koneoppimissuosittelujärjestelmä	Kohteen arvostelu	Arvostelujen ennustaminen ja suosittelualgoritmien parantaminen
Sovellusalueiden rajat ylittävä suosittelujärjestelmä	Lähdetoimialueen (käyttäjä ja kohde) unioni tai leikkaus kohdetoimialueen (käyttäjä ja kohde) kanssa.	Ennustaminen molemmille sovellusalueille tai toiselle sovellusalueelle toisen sovellusalueen perusteella

5 Viimeaikaisia kaupallisia Smart Fitness -toteutuksia

Tässä luvussa kerrotaan viimeaikaisista kaupallisista Smart Fitness -toteutuksista. Aliluvussa 5.1 kerrotaan viimeaikaisista kaupallisista Smart Fitness -laitteista. Aliluvussa 5.2 kerrotaan tämänhetkisistä kaupallisista Smart Fitness -sovelluksista. Aliluku 5.2 toteutettiin tutkielman käytännöllisenä osuutena tarkastelemalla tämänhetkisiä kaupallisia Smart Fitness -sovelluksia.

5.1 Kaupallisia Smart Fitness -laitteita

Nykyään on olemassa monenlaisia eri brändien valmistamia älykelloja. Älykello on pieni ranteeseen kiinnitettävä puettava fitness-seurantalaite. Älykello yhdistetään älypuhelimeen bluetoothin kautta, ja älykello tarjoaa apua joihinkin älypuhelimien keskeisiin toimintoihin. Käyttäjät voivat käyttää älykelloa kosketusnäytön, painikkeiden tai niiden molempien avulla. Älykelloissa on sensoreita, kuten elektrokardiografiasensoreita ja kiihtyvyydsmittari, jotka auttavat käyttäjiä seuraamaan terveyttään. Ranne on kätevä paikka esittää käyttäjän terveyteen liittyviä tietoja, koska käsivarsi liikkuu useammin kuin monet muut kehon osat. Ranteessa on myös verisuonia ja valtimoita pulssin mittaamista varten, ja ranteen iho on riittävän ohut siihen, että älykellon sensorit voivat mitata verenpaineen. (Jat & Grønli, 2022)

Älykello pystyy seuraamaan esimerkiksi käyttäjän verenpainetta, pulssia, nukkumistottumuksia ja fyysistä aktiivisuutta. Älykelloa voidaan käyttää myös hälytyslaitteena päivittäisiä rutiineja, kuten treenejä varten. Älykello voi seurata käyttäjän fyysisiä liikkeitä, kuten päivittäistä askelmittaria ja käyttäjän sijaintia. Pienen rakenteensa ja laskennallisen innovaationsa ansiosta älykelloa voidaan käyttää jatkuvasti ilman, että se häiritsee käyttäjän liikkumista (Jat & Grønli, 2022.) Älykellot antavat kuntoilijoille mahdollisuuden hyödyntää älypuhelimien prosessointitehoa ilman älypuhelimien treeninaikaisesta käytöstä ja lukemisesta koituvia haasteita. Älypuhelimessa on prosessointi-, tallennus- ja akkukapasiteetti, jonka avulla voidaan integroida useiden integroitujen ja kehoon kiinnitettävien sensoreiden data. Älykello näyttää käyttäjälle vain

relevantin yhteenvetodatan tavalla, jonka kuntoilija voi lukea nopeasti ja helposti. (McGrath & Scanail, 2013)



Kuva 6. Apple Watch on Applen valmistama älykello. (Farrokhi et al., 2021)

Aktiivisuusrannekkeet ovat toinen suosittu fitness-seurantalaite kuntoilijoiden keskuudessa. Aktiivisuusranneketta käytetään kehon toimintojen seurantaan (Yong et al., 2018.) FitBitin valmistama FitBit Charge HR aktiivisuusranneke seuraa käyttäjän fyysistä aktiivisuutta, lepoa, unta ja sykettä (Barricelli et al., 2020).



Kuva 7. FitBit Charge HR aktiivisuusranneke. (MacDermott et al., 2019)

Puettavia fitness-seurantalaitteita on olemassa myös älykkäiden liivien ja t-paitojen muodossa. Yksi suosituimmista kaupallisista liivimuotoisista fitness-seurantalaitteista on GPSport-seurantamalli. GPSports-liiviseurantalaitteita käyttävät jotkin kuuluisat jalkapalloseurat, kuten Real Madrid ja Valencia, sekä yli 150 asiakasta 10 urheilulajista. GPSports-liivit tarjoavat

erikoistunutta tietoa eri urheilulajeista amatööriurheilijoista ammattilaisurheilijoihin (Farrokhi et al., 2021.) GPSports-liivit tarjoavat tietoa käyttäjän sykkeestä ennen ottelua tai treeniä ja niiden aikana sekä käyttäjän juokseman kokonaismatkan, kehon kuormituksen, maksimaalisen aerobisen tehon ja maksimaalisen aerobisen nopeuden (Marinescu et al., 2016). Liivin keräämä data voidaan esittää kuvaajina, joista voidaan analysoida kroonista kuormitusta eli neljän viikon aikana tehtyjen treenien määrä ja akuuttia kuormitusta eli yhden viikon aikana tehtyjen treenien määrä. Pääsy GPSports-liivien keräämään dataan tarjoaa valmentajille ja urheilijoille mahdollisuuden ymmärtää urheilijan kehon toimintaa ja sen hetkistä tilannetta paremmin. Datan avulla valmentajat ja urheilijat saavat myös lisätietoa urheilijan loukkaantumisriskistä laskemalla akuutti:krooninen -suhteen. (Blanch & Gabbett, 2016)



Kuva 8. GPSports mittauslaite. (Gheorghe et al., 2016)



Kuva 9. GPSports-mittauslaite sijoitetaan liiviin. (Gheorghe et al., 2016)

Oura tracker on älysormus, johon on sulautettu sensori. Oura tracker sopii sormeen, ja se voidaan valmistaa eri materiaaleista, ja sormus voidaan jopa koristella timanteilla. Oura hyödyntää optista infrapunamittausta ja se sisältää kolmiulotteisen kiihtyvyyssanturin sekä gyroskoopin ja kehon lämpötilasensorin. Kehon aktiivisuuden mittaamiseen ja unen seurantaan suunniteltu Oura tracker on yhteensopiva iOS- ja Android-käyttöjärjestelmien kanssa. Oura tracker -älysormuksessa on titaaninen kansi, akku, tehonkäsittelypiiri, tuplaydinprosessori, muisti, kaksi LEDiä, valokuvasensori, lämpötilasensoreita, kolmiulotteinen kiihtyvyyssensori ja Bluetooth-yhteys älypuhelinsovellukseen (Farrokhi et al., 2021)



Kuva 10. Tekninen kuva toisen sukupolven Oura-sormuksesta. (Altini & Kinnunen, 2022)

Trendinä on ollut kehittää tilaa vievistä laboratoriolaitteista pienoiskoossa olevia versioita, joita kuluttajat voivat käyttää laboratorion ulkopuolella. Esimerkiksi Breezing Company, Arizonan osavaltion spin-off-yritys, on kehittänyt kannettavan Breezing-seurantalaitteen, joka seuraa käyttäjän aineenvaihduntaa. Breezing-seurantalaite antaa tarkkoja arvioita käyttäjän energiankulutuksesta hyödyntämällä vakiintunutta epäsuoraa kalorimittaustekniikkaa. Urheiluklinikoilla usein käytettävä tekniikka mittaa hiilidioksidin tuotantoa ja hapenkulutusta levon ja tasaisen liikunnan aikana. Breezing-seurantalaitteen pienen koon ansiosta urheilijat voivat kantaa sitä helposti mukanaan treeneissä. Aineenvaihdunnan mittaamisen lisäksi Breezing-seurantalaite määrittää myös hengityskertoimen, joka on tuotetun hiilidioksidin ja kulutetun hapen suhde. Hengityskertoimen avulla voidaan myös tunnistaa, minkälaista

energianlähdettä keho käyttää. Hengityskerroin kertoo käyttääkö kuntoilijan keho hiilihydraatteja, rasvoja vai niiden yhdistelmää energianlähteenään. Seurantalaitteen data lähetetään Bluetoothin kautta joko Android- tai iOS-laitteeseen, jossa käyttäjä voi tarkastella ja seurata aineenvaihduntahistoriaansa, hengityskerrointaan ja painoan. Breezing-seurantalaitteessa on myös älykäs algoritmi, joka tukee käyttäjiä treeniohjelman tai painonpudotussuunnitelman määrittelyssä. (McGrath & Scanail, 2013)



Kuva 11. Breezing aineenvaihdunnan seurantalaite on akkukäyttöinen ja synkronoituu älypuhelimien kanssa. Breezing sisältää käyttöliittymänä käytettävän sovelluksen. (McGrath & Scanail, 2013)

5.2 Kaupallisia Smart Fitness -sovelluksia

Tämä luku suoritettiin tutkielman käytännöllisenä osuutena testaamalla Google Play - mobiilisovelluskaupassa olevia Smart Fitness -sovelluksia. Suorittamalla luku tutkielman käytännöllisenä osuutena, saatiin ajantasaista tietoa tämänhetkisistä kaupallisista Smart Fitness -treenisovelluksista. Tutkielman käytännölliseen osioon valittiin viisi Smart Fitness -treenisovellusta Google Play -kaupan suosituimpien Smart Fitness -treenisovellusten joukosta. Tutkielman käytännölliseen osioon valittiin vain treenisovelluksia, koska tutkielmassa keskitytään Smart Fitnessin treenaamispuoleen. Tutkielman käytännöllisessä osuudessa selvitetään, mitä tietoja käyttäjän on annettava Smart Fitness -treenisovelluksille ja mitä ominaisuuksia Smart Fitness -treenisovellukset puolestaan tarjoavat käyttäjälle.

FitAI. Kun käyttäjä käynnistää FitAI-sovelluksen ensimmäisen kerran, sovellus ilmoittaa, että käyttäjän tulee vastata muutama kysymykseen, jotta sovelluksen tekoälyvalmentaja pystyy luomaan käyttäjälle yksilöidyn älykkään treeniohjelman. Sovellus kysyy käyttäjän sukupuolen, pituuden, painon, iän, päätavoitteen, kohdelihasyhmät, nimen, treenaamiskokemustason, treenikerrat viikossa ja mitä varusteita käyttäjällä on käytettävissään. Käyttäjä voi asettaa päätavoitteekseen joko lihaskasvun, kunnon ylläpitämisen tai painonpudottamisen. Sovelluksen tarjoamat treenikokemustasovaihtoehdot ovat täysin kokematon aloitteleva kuntoilija, hieman treenikokemusta omaava kuntoilija, keskitasoisesti treenikokemusta omaava kuntoilija ja edistynyt kuntoilija. Kun sovellus kysyy käyttäjältä, mitä varusteita hänellä on käytettävissään, käyttäjä voi vastata, että hänellä on käytettävissään käsipainot, vapaat painot, kaikki kuntosalin varusteet tai että hänellä ei ole käytettävissään mitään varusteita.

FitAI-sovelluksen tekoälyvalmentajan luomaa treeniohjelmata tarkasteltaessa, sovellus näyttää kunkin treeniohjelman sisältyvän treenin kohdelihasyhmät ja treeniliikkeet kuvakkeina. Kun sovelluksessa siirrytään tarkastelemaan yksittäistä treeniä, käyttäjälle näytetään lihasryhmien palautumistason muutos treenin suorittamisen seurauksena. Käyttäjälle näytetään treeniliikkeet nimien ja kuvakkeiden kera sekä sarja- ja toistomäärät, jotka käyttäjän tulisi suorittaa. Käyttäjälle

näytetään myös kunkin treeniliikkeen ensisijainen kohdelihasuryhmä ja lepoaika sarjojen välissä. Käyttäjä voi halutessaan muokata treenejä esimerkiksi lisäämällä, poistamalla tai vaihtamalla treeniliikkeitä tai muokkaamalla treeniliikkeiden sarjoja, toistoja tai painoja. Sovellus ei tosin automaattisesti aseta treeniliikkeessä käytettäviä painoja. Sovelluksen tekoälyvalmentaja luo käyttäjälle yksilöidyn treeniohjelman ensimmäisen viikon treenit ilmaiseksi. Käyttäjän tulee tilata sovelluksen maksullinen versio, jotta tekoälyvalmentaja luo käyttäjälle yksilöidyt treenit myös seuraaville viikoille.

FitBod. Käynnistettäessä FitBod-sovellus ensimmäisen kerran, sovellus kysyy käyttäjän treenaamiskokemustason, päätavoitteen, saatavilla olevat varusteet, edellisen treenin kohdelihasuryhmät, treenikerrat viikossa, pituuden, painon, sukupuolen ja iän. Käyttäjä voi asettaa treenaamiskokemustasokseen aloitteleva kuntoilija, keskitason kuntoilija tai edistynyt kuntoilija. Päätavoitteekseen käyttäjä voi asettaa kunnon kohottamisen, lihaskasvun, lihasten kiinteyttämisen ja painonpudottamisen, uusien treeniliikkeiden ja treeniohjelmien kokeilemisen, voimanoston tai olympiavoimanoston. Kun sovellus kysyy käyttäjältä, mitä varusteita hänellä on käytettävissään, käyttäjä voi vastata, että hänellä on käytettävissään kaikki suuren kuntosalin varusteet, kaikki pienen kuntosalin varusteet, vapaat painot, kotitreeneivarusteet tai että hänellä ei ole käytettävissään mitään varusteita. Käyttäjä voi halutessaan asettaa käytettävissä olevat varusteet sovellukseen yksitellen. Käyttäjä voi halutessaan myös asettaa viikonpäivät, jolloin hän treenaa.

FitBod-sovelluksessa tekoälyvalmentaja luo käyttäjälle treenin kerrallaan. Treeniä tarkasteltaessa käyttäjälle näytetään treeniin sisältyvät treeniliikkeet nimien, kuvakkeiden ja ohjevideoiden kera sekä sarja- ja toistomäärät, jotka käyttäjän tulisi suorittaa tekoälyvalmentajan asettamilla painoilla. Käyttäjälle näytetään myös treenin kohdelihasuryhmien palautumistaso ennen treenin suorittamista. Käyttäjä voi halutessaan muokata treenejä esimerkiksi lisäämällä, poistamalla tai vaihtamalla treeniliikkeitä tai muokkaamalla treeniliikkeiden sarjoja, toistoja tai painoja. Käyttäjä voi myös muokata treenin kestoja. Käyttäjä voi treeniä suorittaessaan halutessaan kellottaa sarjojen välisten lepotaukojen keston. Sovelluksen tekoälyvalmentaja luo käyttäjälle yksilöidyn

treeniohjelman viisi ensimmäistä treeniä ilmaiseksi. Käyttäjän tulee tilata sovelluksen maksullinen versio, jotta tekoälyvalmentaja luo käyttäjälle yksilöityjä treenejä lisää.

Fitonist. Käynnistettäessä Fitonist-sovellus ensimmäisen kerran, sovellus kysyy käyttäjän sukupuolen, painon, iän, treenaamiskokemuksen, 10 toiston penkkipunnerrusmaksimipainon, päätavoitteen, treenityylin, treenaamiskerrat viikossa ja treenin mieluisan keston. Sovelluksessa käyttäjä voi asettaa päätavoitteekseen joko lihasmassan kasvattamisen, painonpudottamisen tai treenaamismotivaation ylläpitämisen treenitulosten seuraamisella. Käyttäjä voi myös halutessaan asettaa viikonpäivät, jolloin hän treenaa. Käyttäjä voi asettaa treenityylikseen joko kotitreenaamisen tai kuntosalitreenaamisen. Käyttäjä voi valita treenin mieluisan keston 30 minuutin ja 180 minuutin väliltä 15 minuutin tarkkuudella. Sovellus tarjoaa käyttäjälle sukupuolivalinnat mies, nainen ja ei-binäärinen. Käyttäjä voi halutessaan jättää vastaamatta 10 toiston penkkipunnerrusmaksimipainokysymykseen.

Kun käyttäjä tarkastelee Fitonist-sovelluksen tekoälyvalmentajan luomaa treeniohjelmaa, käyttäjälle näytetään kunkin treeniohjelman sisältyvän treenin kohdelihasuryhmät. Kun käyttäjä siirtyy tarkastelemaan yhtä tekoälyvalmentajan luomaa treeniä, käyttäjälle näytetään arvio treenissä kuluvista kaloreista ja treenin suorittamiseen kuluva ajasta. Käyttäjälle näytetään myös treeniliikkeiden lukumäärä ja kussakin treeniliikkeessä käytettävät painot toistomäärineen. Käyttäjä näkee treeniliikkeiden sarjojen lukumäärän siirtymällä tarkastelemaan yksittäistä treeniliikettä. Yksittäistä treeniliikettä tarkasteltaessa käyttäjälle näytetään myös sarjojen välisten lepotaukojen pituus. Lisäksi käyttäjän on mahdollista katsoa lyhyt video kunkin treeniliikkeen oikeaoppisesta suorittamisesta. Käyttäjä voi halutessaan muokata treenejä esimerkiksi lisäämällä, poistamalla tai vaihtamalla treeniliikkeitä tai muokkaamalla treeniliikkeiden sarjoja, toistoja tai painoja. Käyttäjä voi myös muokata treenin kestoa. Sovelluksen tekoälyvalmentaja luo käyttäjälle yksilöidyn treeniohjelman ensimmäisen viikon treenit ilmaiseksi, mutta käyttäjän on aloitettava sovelluksen ilmainen seitsemän päivän kokeilu tai maksullinen tilaus, jotta käyttäjä voi käyttää sovellusta treeniensä yhteydessä.

GymStreak. Käynnistettäessä GymStreak-sovellus ensimmäisen kerran, sovellus kysyy käyttäjältä sukupuolen, nimen, kehotyyppin, treenikokemustason, päätavoitteen, mieluisan treenin keston, viikoittaiset treenikerrat, automaattinen kehitys -valinnan, treeniohjelman uudistamistiheyden, käytettävissä olevat varusteet, pituuden, painon ja iän. Sovelluksessa käyttäjä voi asettaa olevansa luonnolliselta kehotyypiltään laiha, lihaksikas tai suuremman rasvaprosentin omaava. Käyttäjä voi asettaa olevansa treenikokemustasonsa perusteella aloitteleva kuntoilija, keskitason kuntoilija tai edistynyt kuntoilija. Käyttäjä voi asettaa päätavoitteen lihasmassan kasvattamisen, kehon kiinteyttämisen tai painonpudotuksen. Treenin mieluisaksi kestoksi käyttäjä voi valita 30 minuuttia, 45 minuuttia, 1 tunti tai 1 tunti 30 minuuttia. Jos käyttäjä asettaa automaattisen kehityksen päälle, sovelluksen tekoälyvalmentaja valitsee käyttäjän treeniohjelmassa käytettävät painot, sarjat ja toistot käyttäjän kehityksen perusteella. Käyttäjä voi asettaa treenin uudistamistiheysvalinnalla, että tekoälyvalmentajan luomaa treeniohjelmua uudistetaan harvoin, usein tai tasapainotetusti.

GymStreak- sovelluksessa tekoälyvalmentaja luo käyttäjälle treenin kerrallaan. Kun käyttäjä tarkastelee treeniä, käyttäjälle näytetään arvio treenin suorittamiseen kuluvasta ajasta, treeniliikkeiden määrä ja treenin kohdelihasuryhmät. Käyttäjälle näytetään treeniliikkeet nimien ja kuvakkeiden kera sekä sarja- ja toistomäärät, jotka käyttäjän tulisi suorittaa. Käyttäjälle näytetään myös kunkin treeniliikkeen ensisijainen kohdelihasuryhmä. Käyttäjä voi halutessaan muokata treenejä esimerkiksi lisäämällä, poistamalla tai vaihtamalla treeniliikkeitä tai muokkaamalla treeniliikkeiden sarjoja, toistoja tai painoja. Sovellus ei tosin automaattisesti aseta treeniliikkeessä käytettäviä painoja. Kun käyttäjä asettaa sovelluksessa treenin aloitetuksi, käyttäjälle näytetään myös sarjojen välisten lepotaukojen pituudet. Sovelluksen tekoälyvalmentaja luo käyttäjälle yksilöidyn treeniohjelman kolme ensimmäistä treeniä ilmaiseksi. Käyttäjän tulee tilata sovelluksen maksullinen versio, jotta tekoälyvalmentaja luo lisää käyttäjälle yksilöityjä treenejä.

Zing. Käynnistettäessä Zing-sovellus ensimmäisen kerran, sovellus kysyy käyttäjältä päätavoitteen, nimen, sukupuolen, iän, pituuden, painon, kehotyyppin, mahdolliset aiemmin

loukkaantuneet kehonosat, kohdelihasyhmät, treenikokemustason, sen hetkisen aktiivisuuden, mieluisan treenipaikan, käytettävissä olevan kuntosalin luonteen ja mieluisan treeniajankohdan. Käyttäjän täytyy myös asettaa viikonpäivät, jolloin hän treenaa ja treenin mieluisa kesto. Käyttäjä voi asettaa päätavoitteekseen lihasmassan kasvattamisen, kehon rasvaprosentin laskemisen, painon pudottamisen, terveyden ja kunnon ylläpitämisen tai aktiivisuuden lisäämisen. Käyttäjä voi asettaa kehotyypikseen laiha kehotyyppi, keskivertokehotyyppi, lihaksikas kehotyyppi, hieman ylimääräistä rasvaa omaava kehotyyppi tai jonkin verran ylimääräistä rasvaa omaava kehotyyppi. Käyttäjä voi vastata loukkaantumiskysymykseen, että hänellä ei ole loukkaantumisia tai että hänellä on selkä, polvi ja/tai olkapäävammoja. Käyttäjä voi asettaa kohdelihasyhmiksi koko kehon, olkapäät, hauikset, rinnan, selän, vatsalihakset, pakarat ja/tai jalat. Käyttäjä voi asettaa olevansa treenikokemustasonsa perusteella täysin kokematon aloitteleva kuntoilija, hieman treenikokemusta omaava kuntoilija, keskিতason kuntoilija, edistynyt kuntoilija tai ammattiurheilija. Käyttäjä voi vastata, ettei hän sillä hetkellä harrasta aktiivisesti mitään liikuntaa tai että hän harrastaa cardio-liikuntaa, kuten juoksemista, soutamista tai pyöräilyä tai että hän treenaa notkeutta, kamppailulajeja, kilpaurheilua, palloilua, voimaharjoittelua tai crossfitin kaltaista liikuntaa. Mieluisaksi treenaamispaikaksi käyttäjä voi asettaa kodin, kuntosalin, ulkoilman tai kodin ja kuntosalin yhdistelmän. Käyttäjän on valittava, että hänen kuntoilupaiikkansa vastaa suurta kuntosalia, pientä kuntosalia, autotallikuntosalia tai kotikuntosalia. Sopivaksi treeniajankohdaksi käyttäjä voi asettaa aamun, iltapäivän, illan tai vuorokauden eri ajankohdat. Käyttäjän vaihtoehdot mieluisaksi treenin kestoksi ovat korkeintaan 20 minuuttia, 20-40 minuuttia, 40-60 minuuttia ja yli 60 minuuttia.

Zing-sovelluksessa käyttäjälle näytetään kysymyksiin vastaamisen jälkeen muutama treeniliike, jotka sovelluksen tekoälyvalmentajan mukaan tehostavat käyttäjän kehitystä. Tekoälyvalmentaja luo käyttäjälle yhden treenin kerrallaan. Kun käyttäjä tarkastelee treeniä, käyttäjälle näytetään treeniliikkeet nimien ja kuvien kera sekä sarja- ja toistomäärät, jotka käyttäjän tulisi suorittaa tekoälyvalmentajan asettamilla painoilla. Käyttäjälle näytetään myös treenissä tarvittavat varusteet ja treenin ensisijaiset ja toissijaiset kohdelihasyhmät. Käyttäjä voi halutessaan lisätä treeniin kahden minuutin lämmittelyn ennen varsinaisten treeniliikkeiden suorittamista ja viiden

minuutin jäähdyttelyn varsinaisten treeni liikkeiden suorittamisen jälkeen. Sovelluksen tekoälyvalmentaja luo käyttäjälle rajoitetun määrän yksilöidyn treeniohjelman treenejä ilmaiseksi. Käyttäjän tulee tilata sovelluksen maksullinen versio, jotta tekoälyvalmentaja luo käyttäjälle yksilöityjä treenejä lisää.

6 Johtopäätökset

Fyysisellä aktiivisuudella on vahva yhteys terveyteen ja hyvinvointiin (Mishra et al., 2023). Fitness-seurantalaitteiden kehittyminen on auttanut ihmisiä pysymään aktiivisina (Sullivan & Lachman, 2016). Useissa tutkimuksissa on tarkasteltu fitness-seurantalaitteiden myönteistä vaikutusta kuluttajien terveyteen (Mishra et al., 2023). Tutkimuksissa on havaittu, että fitness-seurantalaitteiden käytöllä on esimerkiksi ollut positiivinen vaikutus korkeakouluopiskelijoiden terveelliseen käyttäytymiseen (Clark & Driller, 2020; Simpson & Mazzeo, 2017). Tutkimukset tukevat myös pitkäaikaisia ja kestäviä terveyden ja hyvinvoinnin muutoksia, mikä on seurausta fitness-seurantalaitteiden käytöstä (Fritz et al., 2014).

Puettavista seurantalaitteista on tulossa olennainen osa paitsi innokkaiden kuntosaliharjoittelijoiden myös fitness-tietoisten ihmisten elämää. Puettavien fitness-seurantalaitteiden kehityksen myötä monet huippumerkit ovat tuoneet markkinoille älykelloja ja älykkäitä fitness-rannekkeita, joilla on kyky valvoa terveellisiä elämäntapoja mittaamalla käyttäjän askelmäärän, sykkeen ja jopa nesteytystasot. Useissa tutkimuksissa on raportoitu puettavien fitness-seurantalaitteiden eduista isojen brändien lanseerattua puettavia fitness-seurantalaitteita maailmanlaajuisesti. (Wang et al., 2022)

Tarkasteltuani fitness-seurantalaitteisiin keskittyviä tutkimuksia, vaikuttaa siltä, että erityisesti kaupallisten fitness-seurantalaitteiden kohdalla puettavat laiteratkaisut ovat huomattavasti yleisempiä kuin ei-puettavat laiteratkaisut. Ei-puettaviin fitness-seurantalaitteisiin keskittyviä tutkimuksia oli tarjolla huomattavasti vähemmän kuin puettaviin fitness-seurantalaitteisiin keskittyviä tutkimuksia. Ei-puettavia fitness-seurantalaitteita käsittelevien tutkimusartikkelien vähäinen määrä viittaa siihen, että suurin osa ei-puettavista fitness-seurantalaiteratkaisuista on vielä prototyypitasolla.

Nykyisten fitness-seurantalaitteiden mittaustarkkuus ei riitä arvioimaan treeniaktiiviteettien oikeaoppisuutta, mikä johtuu siitä, että fitness-seurantalaitteiden keräämä data ei riitä

treeniliikkeiden suorittamisen oikeaoppisuuden tarkkaan havaitsemiseen. Toistaiseksi ei ole olemassa luotettavaa järjestelmää, joka voisi valvoa treenejä ja havaita treeniliikkeitä, analysoida treenin aikana tehtyjen liikkeiden eri osia ja verrata niitä kuntoilijan treenisuunnitelmaan treeniliikkeiden oikeaoppisuuden arvioimiseksi. Smart Fitness -alalla tehtyjen tutkimusten perusteella tekoälyn lisääminen älykkään kuntoilun skenaarioihin kuitenkin mahdollistaa datan prosessoimisen, mikä helpottaa kuntoilijan vahvuuksien ja heikkouksien ymmärtämistä ja siten treeniohjelman tehokkuuden arviointia. Parannellut mallit voisivat tulevaisuudessa tarjota uutta treeniohjelmaa aiempaa parempien tulosten saavuttamiseksi. (Farrokhi et al., 2021)

Kun keskitytään tutkielmassa käsiteltyjen koneoppimistekniikoiden soveltamiskohteisiin Smart Fitness -alalla, voidaan todeta, että vahvistusoppimisalgoritmit soveltuvat parhaiten käyttäjän motivointiin keskittyviin sovelluksiin, koska vahvistusoppimisessa vahvistusoppimisalgoritmit palkitsevat käyttäjää hänen suoritustensa perusteella. Vahvistusoppimisessa sekä vahvistusoppimisalgoritmin että käyttäjän tavoitteena on palkintojen maksimointi. Ohjaamattoman oppimisen käyttö Smart Fitness -alalla on ollut toistaiseksi vähäistä. Ohjaamattoman oppimisen algoritmeja voidaan käyttää silloin, kun tavoitteena on luoda muille koneoppimistekniikoille sopiva syöte. Ohjaamattoman oppimisen algoritmeilla voidaan karsia tarpeetonta dataa klusteroimalla. Smart Fitness -alalla on todennäköisesti enemmän sopivia sovelluskohteita ohjatun oppimisen ja syväoppimisen algoritmeille kuin ohjaamattoman oppimisen algoritmeille. Ohjatun oppimisen ja syväoppimisen algoritmeja voidaan käyttää Smart Fitness -alan sovelluksissa enemmän, koska ohjatussa oppimisessa ja syväoppimisessa järjestelmän tulos ja tavoite on ennalta määritelty. Lisäksi ohjatun oppimisen ja syväoppimisen algoritmit pyrkivät tekemään päätöksiä, joiden myötä ennalta määritelty tavoite saavutetaan mahdollisimman nopeasti parhaalla mahdollisella tavalla. (Farrokhi et al., 2021)

Tutkielman käytännöllisen osuuden perusteella tämänhetkisten Smart Fitness -treenisovellusten tekoälyvalmentajat tarvitsevat sovelluksen käyttäjältä tiedon hänen päätavoitteestaan, sukupuolestaan, iästään, pituudestaan, painostaan, kehotyypistään, kohdelihasryhmistään, treenikokemustasostaan, mieluisasta treenaamispaikastaan ja mieluisasta

treeniajankohdastaan, jotta tekoälyvalmentaja voi luoda käyttäjän tavoitteisiin vastaavan yksilöidyn treeniohjelman. Smart Fitness -sovelluksissa käyttäjälle yleensä luodaan muutama treeni ilmaiseksi, minkä jälkeen käyttäjän on tilattava Smart Fitness -sovelluksen maksullinen versio, jos käyttäjä haluaa jatkaa sovelluksen käyttöä. Smart Fitness -sovelluksissa käyttäjille yleensä näytetään treenin kohdelihasryhmät, arvio treenin suorittamiseen kuluva ajasta, treeniin sisältyvät treeniliikkeet sarja- ja toistomäärineen tekoälyvalmentajan asettamilla painoilla. Käyttäjä voi yleensä kuitenkin muokata Smart Fitness -sovellusten tekoälyvalmentajien treeneihin sisällytettyjä treeniliikkeitä, sarja- ja toistomääriä ja treeniliikkeissä käytettäviä painoja.

Urheilutieteellisten ratkaisujen tärkeimpiä tulevaisuuden painopisteitä on vähentää laitemäärää, joka tarvitaan treeniliikkeiden erotteluun ja kuntoilijan ulkoisen kuormituksen ja vaikutuksen mittaamiseen. Inertiamittausyksiköiden käyttöönoton ansiosta tyypillisesti vähemmän käyttäjäystävällisten ja kannettavien mekaanisten laitteiden käyttö voidaan yleensä minimoida. Älypantojen, -käsineiden ja -kellojen käyttöönotto on askel eteenpäin datan kvantifioinnin helpottamisessa. IoT-laitteiden käytön etuna on niiden kyky luoda yhteys pilviratkaisuihin ja datan prosessointiin. Treenin mukauttaminen välittömän prosessoinnin perusteella voi olla loistava ratkaisu vapaa-ajan kuntoilijoille ja jopa ammattiurheilijoille. IoT-laitteiden kyky havaita muutokset ja tehdä lisäprosessointia koneoppimisen avulla kuntoilijalle sopivan kuormituksen ja toistojen määrittämiseksi voi olla askel eteenpäin. Tulevaisuudessa Smart Fitness -toteutusten kyky suositella kuntoilijalle optimaalisia viikoittaisia treenimääriä ja treeniliikkeitä sekä kuormituksen automaattista muokkaamista, voi olla edistysaskel, joka auttaa kaikkia ihmisiä, jotka kuntoilevat ilman valmentajaa. (Passos et al., 2021)

Smart Fitness -alalla on paljon fitness-sovelluksia, jotka prosessoivat fitness-seurantalaitteiden keräämää dataa. Sosiaalisen esineiden internetin avulla voidaan kerätä tarkempaa dataa kaikista yksilön käyttämistä älykkäistä kuntoilulaitteista ja päästä käsiksi samankaltaisten kuntoilijoiden klusteroituun dataan. Tulevaisuudessa SloT:n sosiaaliset ominaisuudet mahdollistavat parempien päätösten tekemisen suositeltujen toimintojen ja suunnitelmien suhteen. (Farrokhi et

al., 2021) SloT:n ja tekoälyn kehittyminen voi tulevaisuudessa parantaa Smart Fitness -sovellusten luomia treeniohjelmia ja ruokavaliosuunnitelmia. SloT:n käyttöönotto voi parantaa myös fitness-seurantalaitteiden tarkkuutta fitness-seurantalaitteiden saadessa informaatiota kaikista kuntoilijan käyttämistä laitteista. Myös fitness-seurantalaitteiden tuottaman datan turvallisuus voi parantua SloT:n käyttöönoton myötä. SloT:ssa fitness-seurantalaitteiden välinen vuorovaikutus on keskiössä, jolloin olisi luontevaa, että fitness-seurantalaitteiden tuottaman datan tietoturvaan kiinnitettäisiin aiempaa enemmän huomiota. Jatkotutkimus sosiaalisen esineiden internetin käyttömahdollisuuksista älykkäässä kuntoilussa olisi monien mahdollisesti SloT:n käyttöönotosta seuraavien hyötyjen takia hyödyllistä. Tämä tutkielma keskittyi Smart Fitnessin treenaamispuoleen, ja siten tämän tutkielman johtopäätöksiä täydentävä ravitsemuspuoleen keskittyvä Smart Fitness -tutkimus olisi myös hyödyllistä.

Lähteet

- Abed, H., Bellemare-Rousseau, S., Bélanger-Huot, B., Ahadi, M., Drouin, É., Roudjane, M., ... & Messaddeq, Y. (2022). A wire-free and fiber-based smart T-shirt for real-time breathing rate monitoring. *IEEE Sensors Journal*, 22(5), 4463-4471.
- Abowd, D., Dey, A. K., Orr, R., & Brotherton, J. (1998). Context-awareness in wearable and ubiquitous computing. *Virtual Reality*, 3, 200-211.
- Afzal, B., Umair, M., Shah, G. A., & Ahmed, E. (2019). Enabling IoT platforms for social IoT applications: Vision, feature mapping, and challenges. *Future Generation Computer Systems*, 92, 718-731.
- Agrawal, R., & Srikant, R. (1994, September). Fast algorithms for mining association rules. In *Proc. 20th int. conf. very large data bases, VLDB* (Vol. 1215, pp. 487-499).
- Ahmad, S. Z. R. S., Yusoff, Y., Zain, A. M., Samsudin, R., & Ghazali, N. E. (2019, August). Ai for heart rate measurements for sport performance: A review. In *IOP Conference Series: Materials Science and Engineering* (Vol. 551, No. 1, p. 012041). IOP Publishing.
- Al-Shamri, M. Y. H. (2016). User profiling approaches for demographic recommender systems. *Knowledge-Based Systems*, 100, 175-187.
- Alizadehsani, R., Khosravi, A., Roshanzamir, M., Abdar, M., Sarrafzadegan, N., Shafie, D., ... & Acharya, U. R. (2021). Coronary artery disease detection using artificial intelligence techniques: A survey of trends, geographical differences and diagnostic features 1991–2020. *Computers in Biology and Medicine*, 128, 104095.
- Alizadehsani, R., Roshanzamir, M., Hussain, S., Khosravi, A., Koohestani, A., Zangooei, M. H., ... & Acharya, U. R. (2021). Handling of uncertainty in medical data using machine learning and probability theory techniques: A review of 30 years (1991–2020). *Annals of Operations Research*, 1-42.

- Alizadehsani, R., Sharifrazi, D., Izadi, N. H., Joloudari, J. H., Shoeibi, A., Gorriz, J. M., ... & Acharya, U. R. (2021). Uncertainty-aware semi-supervised method using large unlabeled and limited labeled COVID-19 data. *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, 17(3s), 1-24.
- Altini, M., & Kinnunen, H. (2021). The promise of sleep: A multi-sensor approach for accurate sleep stage detection using the oura ring. *Sensors*, 21(13), 4302.
- Atzori, L., Iera, A., & Morabito, G. (2011). Siot: Giving a social structure to the internet of things. *IEEE communications letters*, 15(11), 1193-1195.
- Atzori, L., Iera, A., Morabito, G., & Nitti, M. (2012). The social internet of things (siot)–when social networks meet the internet of things: Concept, architecture and network characterization. *Computer networks*, 56(16), 3594-3608.
- Barricelli, B. R., Casiraghi, E., Gliozzo, J., Petrini, A., & Valtolina, S. (2020). Human digital twin for fitness management. *Ieee Access*, 8, 26637-26664.
- Barris, S., & Button, C. (2008). A review of vision-based motion analysis in sport. *Sports Medicine*, 38, 1025-1043.
- Belgiu, M., & Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS journal of photogrammetry and remote sensing*, 114, 24-31.
- Ben Sassi, I., Mellouli, S., & Yahia, S. B. (2017). Context-aware recommender systems in mobile environment: On the road of future research. *Information Systems*, 72, 27-61.
- Bian, S., Rey, V. F., Hevesi, P., & Lukowicz, P. (2019, March). Passive capacitive based approach for full body gym workout recognition and counting. In *2019 IEEE International Conference on Pervasive Computing and Communications (PerCom)* (pp. 1-10). IEEE.

- Blanch, P., & Gabbett, T. J. (2016). Has the athlete trained enough to return to play safely? The acute: chronic workload ratio permits clinicians to quantify a player's risk of subsequent injury. *British journal of sports medicine*, *50*(8), 471-475.
- Brophy, E., Veiga, J. J. D., Wang, Z., Smeaton, A. F., & Ward, T. E. (2018). An interpretable machine vision approach to human activity recognition using photoplethysmograph sensor data. *arXiv preprint arXiv:1812.00668*.
- Buchheit, M., Simpson, M. B., Al Haddad, H., Bourdon, P. C., & Mendez-Villanueva, A. (2012). Monitoring changes in physical performance with heart rate measures in young soccer players. *European journal of applied physiology*, *112*, 711-723.
- Bulling, A., Ward, J. A., Gellersen, H., & Tröster, G. (2010). Eye movement analysis for activity recognition using electrooculography. *IEEE transactions on pattern analysis and machine intelligence*, *33*(4), 741-753.
- Bzdok, D., Krzywinski, M., & Altman, N. (2018). Machine learning: supervised methods. *Nature methods*, *15*(1), 5.
- Caruana, R., & Niculescu-Mizil, A. (2006, June). An empirical comparison of supervised learning algorithms. In *Proceedings of the 23rd international conference on Machine learning* (pp. 161-168).
- Chen, K., Zhang, D., Yao, L., Guo, B., Yu, Z., & Liu, Y. (2021). Deep learning for sensor-based human activity recognition: Overview, challenges, and opportunities. *ACM Computing Surveys (CSUR)*, *54*(4), 1-40.
- Côté, M., & Lamarche, B. (2022). Artificial intelligence in nutrition research: Perspectives on current and future applications. *Applied Physiology, Nutrition, and Metabolism*, *47*(1), 1-8.
- Crawford, K., Lingel, J., & Karppi, T. (2015). Our metrics, ourselves: A hundred years of self-tracking from the weight scale to the wrist wearable device. *European Journal of Cultural Studies*, *18*(4-5), 479-496.

- Culén, A. L., Finken, S., & Bratteteig, T. (2013). Design and interaction in a smart gym: cognitive and bodily mastering. In *Human Factors in Computing and Informatics: First International Conference, SouthCHI 2013, Maribor, Slovenia, July 1-3, 2013. Proceedings* (pp. 609-616). Springer Berlin Heidelberg.
- Crema, C., Depari, A., Flammini, A., Sisinni, E., Haslwanter, T., & Salzmänn, S. (2019). Characterization of a wearable system for automatic supervision of fitness exercises. *Measurement*, *147*, 106810.
- Dara, S., Chowdary, C. R., & Kumar, C. (2020). A survey on group recommender systems. *Journal of Intelligent Information Systems*, *54*(2), 271-295.
- del Carmen Rodríguez-Hernández, M., & Ilarri, S. (2021). AI-based mobile context-aware recommender systems from an information management perspective: Progress and directions. *Knowledge-Based Systems*, *215*, 106740.
- El-Amrawy, F., & Nounou, M. I. (2015). Are currently available wearable devices for activity tracking and heart rate monitoring accurate, precise, and medically beneficial?. *Healthcare informatics research*, *21*(4), 315-320.
- Fahami, M. A., Roshanzamir, M., Izadi, N. H., Keyvani, V., & Alizadehsani, R. (2021). Detection of effective genes in colon cancer: A machine learning approach. *Informatics in Medicine Unlocked*, *24*, 100605.
- Farrokhi, A., Farahbakhsh, R., Rezazadeh, J., & Minerva, R. (2021). Application of Internet of Things and artificial intelligence for smart fitness: A survey. *Computer Networks*, *189*, 107859.
- Farrokhi, A., Rezazadeh, J., Farahbakhsh, R., & Ayoade, J. (2022). A decision tree-based smart fitness framework in IoT. *SN Computer Science*, *3*, 1-10.

Fister, I., Fister, D., Ljubic, K., Zhuang, Y., & Fong, S. (2014, September). Towards automatic food prediction during endurance sport competitions. In *2014 International Conference on Soft Computing and Machine Intelligence* (pp. 6-10). IEEE.

Fister, I., Fister Jr, I., & Fister, D. (2019). *Computational intelligence in sports* (Vol. 22). Cham: Springer.

Fister, I., Rauter, S., Yang, X. S., Ljubič, K., & Fister Jr, I. (2015). Planning the sports training sessions with the bat algorithm. *Neurocomputing*, *149*, 993-1002.

Fister Jr, I., Ljubič, K., Suganthan, P. N., Perc, M., & Fister, I. (2015). Computational intelligence in sports: challenges and opportunities within a new research domain. *Applied Mathematics and Computation*, *262*, 178-186.

Fister Jr, I., Vrbančič, G., Brezočnik, L., Podgorelec, V., & Fister, I. (2018). SportyDataGen: an online generator of endurance sports activity collections. In *Central European Conference on Information and Intelligent Systems* (pp. 171-178). Faculty of Organization and Informatics Varazdin.

Galán-Mercant, A., Ortiz, A., Herrera-Viedma, E., Tomas, M. T., Fernandes, B., & Moral-Munoz, J. A. (2019). Assessing physical activity and functional fitness level using convolutional neural networks. *Knowledge-Based Systems*, *185*, 104939.

Ghahramani, Z. (2003). Unsupervised learning. In *Summer school on machine learning* (pp. 72-112). Berlin, Heidelberg: Springer Berlin Heidelberg.

Gheorghe, M. A. R. I. N. E. S. C. U., Daniel, T. L., Victor, D. U. L. C. E. A. Ț. Ă., & Nicoleta, B. S. (2016). EFFORT ANALYSIS IN REAL TIME DURING A FOOTBALL GAME–JUNIOR II USING GPSPORTS DEVICE. *Ovidius University Annals, Series Physical Education & Sport/Science, Movement & Health*, *16*.

Hammerla, N. Y., Halloran, S., & Plötz, T. (2016). Deep, convolutional, and recurrent models for human activity recognition using wearables. *arXiv preprint arXiv:1604.08880*.

- Han, J., Pei, J., & Yin, Y. (2000). Mining frequent patterns without candidate generation. *ACM sigmod record*, 29(2), 1-12.
- Hannan, A., Shafiq, M. Z., Hussain, F., & Pires, I. M. (2021). A portable smart fitness suite for real-time exercise monitoring and posture correction. *Sensors*, 21(19), 6692.
- Hausberger, P., Fernbach, A., & Kastner, W. (2016, October). IMU-based smart fitness devices for weight training. In *IECON 2016-42nd Annual Conference of the IEEE Industrial Electronics Society* (pp. 5182-5189). IEEE.
- Hirashima, T., Matsuda, N., Nomoto, T., & Toyoda, J. I. (1998, January). Context-sensitive filtering for browsing in hypertext. In *Proceedings of the 3rd international conference on Intelligent user interfaces* (pp. 119-126).
- Hussain, F., Ehatisham-ul-Haq, M., Azam, M. A., & Khalid, A. (2018, October). Elderly assistance using wearable sensors by detecting fall and recognizing fall patterns. In *Proceedings of the 2018 ACM international joint conference and 2018 international symposium on pervasive and ubiquitous computing and wearable computers* (pp. 770-777).
- Hussain, F., Hussain, F., Ehatisham-ul-Haq, M., & Azam, M. A. (2019). Activity-aware fall detection and recognition based on wearable sensors. *IEEE Sensors Journal*, 19(12), 4528-4536.
- Hänsel, K., Wilde, N., Haddadi, H., & Alomainy, A. (2015, December). Challenges with current wearable technology in monitoring health data and providing positive behavioural support. In *Proceedings of the 5th EAI International Conference on Wireless Mobile Communication and Healthcare* (pp. 158-161).
- Jain, A. (2015, December). A smart gym framework: Theoretical approach. In *2015 IEEE International Symposium on Nanoelectronic and Information Systems* (pp. 191-196). IEEE.

- Jat, A. S., & Grønli, T. M. (2022, June). Smart watch for smart health monitoring: A literature review. In *International Work-Conference on Bioinformatics and Biomedical Engineering* (pp. 256-268). Cham: Springer International Publishing.
- Kamišalić, A., Fister Jr, I., Turkanović, M., & Karakatič, S. (2018). Sensors and functionalities of non-invasive wrist-wearable devices: A review. *Sensors*, *18*(6), 1714.
- Kankanhalli, A., Charalabidis, Y., & Mellouli, S. (2019). IoT and AI for smart government: A research agenda. *Government Information Quarterly*, *36*(2), 304-309.
- Kanoje, S., Girase, S., & Mukhopadhyay, D. (2015). User profiling trends, techniques and applications. *arXiv preprint arXiv:1503.07474*.
- Kao, Y. S., Nawata, K., & Huang, C. Y. (2019). An exploration and confirmation of the factors influencing adoption of IoT-based wearable fitness trackers. *International journal of environmental research and public health*, *16*(18), 3227.
- Khodatars, M., Shoeibi, A., Sadeghi, D., Ghaasemi, N., Jafari, M., Moridian, P., ... & Berk, M. (2021). Deep learning for neuroimaging-based diagnosis and rehabilitation of autism spectrum disorder: a review. *Computers in Biology and Medicine*, *139*, 104949.
- Kos, A., Milutinović, V., & Umek, A. (2019). Challenges in wireless communication for connected sensors and wearable devices used in sport biofeedback applications. *Future generation computer systems*, *92*, 582-592.
- Kunaver, M., & Požrl, T. (2017). Diversity in recommender systems—A survey. *Knowledge-based systems*, *123*, 154-162.
- Lavigne, M., Mussa, F., Creatore, M. I., Hoffman, S. J., & Buckeridge, D. L. (2019, July). A population health perspective on artificial intelligence. In *Healthcare management forum* (Vol. 32, No. 4, pp. 173-177). Sage CA: Los Angeles, CA: SAGE Publications.

- Lee, C. (2017, July). Movement detection and analysis of resistance exercises for smart fitness platform. In *2017 Ninth International Conference on Ubiquitous and Future Networks (ICUFN)* (pp. 410-415). IEEE.
- Lee, Y. D., & Chung, W. Y. (2009). Wireless sensor network based wearable smart shirt for ubiquitous health and activity monitoring. *Sensors and Actuators B: Chemical*, *140*(2), 390-395.
- Liu, J., Wang, X., Liu, X., & Yang, F. (2010, May). Analysis and design of personalized recommendation system for university physical education. In *2010 International Conference on Networking and Digital Society* (Vol. 2, pp. 472-475). IEEE.
- Lu, C. H., Wang, W. C., Tai, C. C., & Chen, T. C. (2016). Design of a heart rate controller for treadmill exercise using a recurrent fuzzy neural network. *Computer methods and programs in biomedicine*, *128*, 27-39.
- Ma, Y., & Ghasemzadeh, H. (2019, July). LabelForest: Non-parametric semi-supervised learning for activity recognition. In *Proceedings of the AAAI Conference on Artificial Intelligence* (Vol. 33, No. 01, pp. 4520-4527).
- MacDermott, Á., Lea, S., Iqbal, F., Idowu, I., & Shah, B. (2019, June). Forensic analysis of wearable devices: Fitbit, Garmin and HETP Watches. In *2019 10th IFIP International Conference on New Technologies, Mobility and Security (NTMS)* (pp. 1-6). IEEE.
- Manjarres, J., Narvaez, P., Gasser, K., Percybrooks, W., & Pardo, M. (2019). Physical workload tracking using human activity recognition with wearable devices. *Sensors*, *20*(1), 39.
- Marinescu, G., Ticala, L. D., Dulceata, V., & Bidiugan, S. N. (2016). Effort analysis in real time during a football game--junior II using GPSports device. *Ovidius University Annals, Series Physical Education and Sport/Science, Movement and Health*, *16*(2 SI), 548-555.
- McGrath, M. J., & Scanail, C. N. (2013). *Sensor technologies: Healthcare, wellness, and environmental applications* (p. 336). Springer Nature.

- Murdoch, W. J., Singh, C., Kumbier, K., Abbasi-Asl, R., & Yu, B. (2019). Interpretable machine learning: definitions, methods, and applications. *arXiv preprint arXiv:1901.04592*.
- Nahavandi, D., Alizadehsani, R., Khosravi, A., & Acharya, U. R. (2022). Application of artificial intelligence in wearable devices: Opportunities and challenges. *Computer Methods and Programs in Biomedicine*, 213, 106541.
- Nardi, P. (2019). Human activity recognition: Deep learning techniques for an upper body exercise classification system.
- Nitti, M., Girau, R., & Atzori, L. (2013). Trustworthiness management in the social internet of things. *IEEE Transactions on knowledge and data engineering*, 26(5), 1253-1266.
- Ng, A. (2013). Machine Learning and AI via Brain simulations.
- Nowak, M. A. (2013). PHYSICAL CULTURE PATTERNS IN THE LIFESTYLE OF THE POLISH SOCIETY. *Polish Journal of Sport & Tourism*, 20(1).
- Oh, S. L., Jahmunah, V., Ooi, C. P., Tan, R. S., Ciaccio, E. J., Yamakawa, T., ... & Acharya, U. R. (2020). Classification of heart sound signals using a novel deep WaveNet model. *Computer Methods and Programs in Biomedicine*, 196, 105604.
- O'Reilly, E., Tompkins, J., & Gallant, M. (2001). 'They Ought to Enjoy Physical Activity, You Know?': Struggling with Fun in Physical Education. *Sport, education and society*, 6(2), 211-221.
- Paoli, A., & Bianco, A. (2015). What is fitness training? Definitions and implications: A systematic review article. *Iranian journal of public health*, 44(5), 602.
- Paradarami, T. K., Bastian, N. D., & Wightman, J. L. (2017). A hybrid recommender system using artificial neural networks. *Expert Systems with Applications*, 83, 300-313.

- Pérez, J. G., Payá, A. S., Fernández, D. R., Sánchez, S. H., & Alonso, O. M. (2012, May). Ubiquitous low-cost sports training system for athletes. In *Proceedings of the 6th Euro American Conference on Telematics and Information Systems* (pp. 105-112).
- Pires, I. M., Hussain, F., Marques, G., & Garcia, N. M. (2021). Comparison of machine learning techniques for the identification of human activities from inertial sensors available in a mobile device after the application of data imputation techniques. *Computers in Biology and Medicine*, 135, 104638.
- Poo, D., Chng, B., & Goh, J. M. (2003, January). A hybrid approach for user profiling. In *36th Annual Hawaii International Conference on System Sciences, 2003. Proceedings of the* (pp. 9-pp). IEEE.
- Postma, D., Van Delden, R., Walinga, W., Koekoek, J., van Beijnum, B. J., Salim, F. A., ... & Reidsma, D. (2019, October). Towards smart sports exercises: First designs. In *Extended Abstracts of the Annual Symposium on Computer-Human Interaction in Play Companion Extended Abstracts* (pp. 619-630).
- Postolache, O., Girão, P. S., Pereira, J. M., & Postolache, G. (2015, May). Wearable system for gait assessment during physical rehabilitation process. In *2015 9th International Symposium on Advanced Topics in Electrical Engineering (ATEE)* (pp. 321-326). IEEE.
- Pouyanfar, S., Sadiq, S., Yan, Y., Tian, H., Tao, Y., Reyes, M. P., ... & Iyengar, S. S. (2018). A survey on deep learning: Algorithms, techniques, and applications. *ACM Computing Surveys (CSUR)*, 51(5), 1-36.
- Rajšp, A., & Fister Jr, I. (2020). A systematic literature review of intelligent data analysis methods for smart sport training. *Applied Sciences*, 10(9), 3013.
- Ramscar, M., Pain, H., & Lee, J. (1997). Do We Know What the User Knows, and Does It Matter? The Epistemics of User Modelling. In *User Modeling: Proceedings of the Sixth International Conference UM97 Chia Laguna, Sardinia, Italy June 2-5 1997* (pp. 429-431). Springer Vienna.

Rauter, S. (2014). Mass sports events as a way of life (differences between the participants in a cycling and a running event). *Kinesiologia Slovenica*, 20(1).

Raza, S., & Ding, C. (2019). Progress in context-aware recommender systems—An overview. *Computer Science Review*, 31, 84-97.

Ricci, F., Rokach, L., & Shapira, B. (2010). Introduction to recommender systems handbook. In *Recommender systems handbook* (pp. 1-35). Boston, MA: springer US.

Roopa, M. S., Pattar, S., Buyya, R., Venugopal, K. R., Iyengar, S. S., & Patnaik, L. M. (2019). Social Internet of Things (SIoT): Foundations, thrust areas, systematic review and future directions. *Computer Communications*, 139, 32-57.

Safavian, S. R., & Landgrebe, D. (1991). A survey of decision tree classifier methodology. *IEEE transactions on systems, man, and cybernetics*, 21(3), 660-674.

Saleem, Y., Crespi, N., Rehmani, M. H., Copeland, R., Hussein, D., & Bertin, E. (2016, December). Exploitation of social IoT for recommendation services. In *2016 IEEE 3rd World Forum on Internet of Things (WF-IoT)* (pp. 359-364). IEEE.

Schiaffino, S., & Amandi, A. (2009). Intelligent user profiling. In *Artificial Intelligence An International Perspective: An International Perspective* (pp. 193-216). Berlin, Heidelberg: Springer Berlin Heidelberg.

Schiaffino, S. N., & Amandi, A. (2000, November). User profiling with Case-Based Reasoning and Bayesian Networks. In *IBERAMIA-SBIA 2000 open discussion track* (pp. 12-21).

Sharifrazi, D., Alizadehsani, R., Roshanzamir, M., Joloudari, J. H., Shoeibi, A., Jafari, M., ... & Acharya, U. R. (2021). Fusion of convolution neural network, support vector machine and Sobel filter for accurate detection of COVID-19 patients using X-ray images. *Biomedical Signal Processing and Control*, 68, 102622.

Schmidt, B., Benchea, S., Eichin, R., & Meurisch, C. (2015, September). Fitness tracker or digital personal coach: How to personalize training. In *Adjunct Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2015 ACM International Symposium on Wearable Computers* (pp. 1063-1067).

Sebastiani, P., Ramoni, M., & Crea, A. (2000). Profiling your customers using Bayesian networks. *ACM SIGKDD Explorations Newsletter*, 1(2), 91-96.

Shin, G., Jarrahi, M. H., Fei, Y., Karami, A., Gafinowitz, N., Byun, A., & Lu, X. (2019). Wearable activity trackers, accuracy, adoption, acceptance and health impact: A systematic literature review. *Journal of biomedical informatics*, 93, 103153.

Shoeibi, A., Khodatars, M., Alizadehsani, R., Ghassemi, N., Jafari, M., Moridian, P., ... & Gorriz, J. M. (2020). Automated detection and forecasting of covid-19 using deep learning techniques: A review. *arXiv preprint arXiv:2007.10785*.

Stikic, M., Larlus, D., & Schiele, B. (2009, September). Multi-graph based semi-supervised learning for activity recognition. In *2009 international symposium on wearable computers* (pp. 85-92). IEEE.

Stikic, M., Van Laerhoven, K., & Schiele, B. (2008, September). Exploring semi-supervised and active learning for activity recognition. In *2008 12th IEEE International Symposium on Wearable Computers* (pp. 81-88). IEEE.

Tegmark, M. (2017). *Life 3.0: Being human in the age of artificial intelligence*. Penguin UK.

Tor, H. T., Ooi, C. P., Lim-Ashworth, N. S., Wei, J. K. E., Jahmunah, V., Oh, S. L., ... & Fung, D. S. S. (2021). Automated detection of conduct disorder and attention deficit hyperactivity disorder using decomposition and nonlinear techniques with EEG signals. *Computer Methods and Programs in Biomedicine*, 200, 105941.

- Vainamo, K., Nissila, S., Makikallio, T., Tulppo, M., & Roning, J. (1996, June). Artificial neural networks for aerobic fitness approximation. In *Proceedings of International Conference on Neural Networks (ICNN'96)* (Vol. 4, pp. 1939-1944). IEEE.
- Vanrenterghem, J., Nedergaard, N. J., Robinson, M. A., & Drust, B. (2017). Training load monitoring in team sports: a novel framework separating physiological and biomechanical load-adaptation pathways. *Sports medicine*, *47*, 2135-2142.
- Venkatachalam, P., & Ray, S. (2022). How do context-aware artificial intelligence algorithms used in fitness recommender systems? A literature review and research agenda. *International Journal of Information Management Data Insights*, *2*(2), 100139.
- Villegas, N. M., Sánchez, C., Díaz-Cely, J., & Tamura, G. (2018). Characterizing context-aware recommender systems: A systematic literature review. *Knowledge-Based Systems*, *140*, 173-200.
- Wang, F., Sohail, A., Tang, Q., & Li, Z. (2022). Impact of fractals emerging from the fitness activities on the retail of smart wearable devices. *Fractals*, 2240112.
- Wójcicki, K., Biegańska, M., Paliwoda, B., & Górna, J. (2022). Internet of Things in Industry: Research Profiling, Application, Challenges and Opportunities—A Review. *Energies*, *15*(5), 1806.
- Xie, J., Wen, D., Liang, L., Jia, Y., Gao, L., & Lei, J. (2018). Evaluating the validity of current mainstream wearable devices in fitness tracking under various physical activities: comparative study. *JMIR mHealth and uHealth*, *6*(4), e9754.
- Xu, B. (2012). Prediction of sports performance based on genetic algorithm and artificial neural network. *International Journal of Digital Content Technology and its Applications*, *6*(22), 141.
- Yong, B., Xu, Z., Wang, X., Cheng, L., Li, X., Wu, X., & Zhou, Q. (2018). IoT-based intelligent fitness system. *Journal of Parallel and Distributed Computing*, *118*, 14-21.

- Zaki, M. J. (2000). Scalable algorithms for association mining. *IEEE transactions on knowledge and data engineering*, 12(3), 372-390.
- Zhou, M., Mintz, Y., Fukuoka, Y., Goldberg, K., Flowers, E., Kaminsky, P., ... & Aswani, A. (2018, March). Personalizing mobile fitness apps using reinforcement learning. In *CEUR workshop proceedings* (Vol. 2068). NIH Public Access.
- Zhu, X., & Goldberg, A. (2009). Introduction to semi-supervised learning. *Synth Lect Artif Intell Mach Learn* 3 (1): 1-130.
- Ziv, G., & Lidor, R. (2009). Physical attributes, physiological characteristics, on-court performances and nutritional strategies of female and male basketball players. *Sports medicine*, 39, 547-568.
- Zou, Y., Wang, D., Hong, S., Ruby, R., Zhang, D., & Wu, K. (2020). A low-cost smart glove system for real-time fitness coaching. *IEEE Internet of Things Journal*, 7(8), 7377-7391.