

Kivun arviointi puettavien laitteiden avulla ja arvioinnin hyödyntäminen yksilöllistetyssä kivun hoidossa

TURUN YLIOPISTO
Tietotekniikan laitos
TkK-tutkielma
Lääketieteellinen tekniikka ja terveysteknologia
Toukokuu 2026
Assi Vänninmaja

Tässä tutkielmassa tarkastellaan, miten puettavien laitteiden avulla pystytään arvioimaan kipua ja miten arviointia voidaan hyödyntää kivun hoidon yksilöllistämässä. Tutkielmassa selvitetään kirjallisuuskatsauksen avulla, minkälaisia tuloksia on saavutettu kivun arvioimisessa hyödyntäen puettavia laitteita. Lähes jokainen ihminen kokee elämänsä aikana kipua. Kipu onkin kaikista yleisin syy hakeutua terveydenhoitoon. Terveystieteiden ammattilaisten on vaikea arvioida potilaan kokemaa kipua objektiivisesti, koska kivusta muodostuu aivoissa subjektiivinen kokemus. Erityisen haasteen tuottavat potilaat, jotka eivät pysty ilmaisemaan selkeästi tunteensa kipua.

Kivun arviointi puettavilla laitteilla mahdollistaa objektiivisemmän tavan arvioida kipua, minkä myötä voidaan tarjota myös entistä yksilöllisempää kivun hoitoa. Yksilöllinen kivun hoito parantaa hoidon tehoa, vähentää lääkkeiden haittavaikutuksia ja on kustannustehokkaampaa. Tutkielmassa havaittiin, että kivun arvioinnissa voidaan hyödyntää useita antureita sekä koneoppimismenetelmiä. Arviointimallit koulutetaan tunnistamaan kivun taso potilaan fysiologisten signaalien ominaisuuksista. Arvioinnit ovat osoittautuneet lupaaviksi ja parhaiten kivun arvioinnissa pärjäävät satunaismetsämenetelmä, tukivektorikone sekä erilaiset yhdistelmämallit.

Suurimmat haasteet liittyvät mallien luotettavuuteen ja yleistettävyyteen suuremmalle potilasjoukolle. Havaittiin myös, että tulevaisuudessa kivun arviointia voisi hyödyntää sekä lääkityksen suunnittelussa että annossa. Arviointimallia olisi tarpeen testata suuremmalla ja mahdollisimman monimuotoisella otoksella. Lisäksi olisi tarpeellista tutkia enemmän puettavien laitteiden avulla tehtävän kivun arvioinnin hyödyntämistä lääkityksen yksilöimisessä käytännössä.

Asiasanat: puettavat laitteet, kivun arviointi, koneoppiminen, yksilöllistetty hoito

Sisällys

1	Johdanto	1
2	Kiputuntemuksen fysiologia	4
3	Kivun arvioiminen puettavien laitteiden avulla	8
3.1	Fysiologisten vasteiden mittaaminen	9
3.2	Kivun tason arviointi koneoppimismenetelmin	13
4	Yksilöllistetty hoito kivun arvioinnin avulla	24
5	Pohdinta	27
6	Yhteenveto	30
	Lähdeluettelo	32

1 Johdanto

Lähes jokainen ihminen kokee elämänsä aikana subjektiivista epämiellyttävää tunnetta tai aistimusta eli kipua. Kipu on kaikista yleisin syy hakeutua terveydenhoitoon ja Suomessa jopa 40 % kaikista perusterveydenhuollon lääkärikäynneistä varataan kivun vuoksi. Kipu on merkittävä ongelma, sillä se vaikuttaa sekä yksilö- että yhteiskuntatasolla niin sosiaalisesti kuin taloudellisestikin. [1]. Kipukokemus on hyvin subjektiivinen, koska se muodostuu esimerkiksi aiempien kokemusten myötä. Subjektiivisuuden vuoksi kivun arviointi perustuu tällä hetkellä lähinnä potilaan itse kertomaan kokemukseen kivusta sekä ulkoisiin vasteisiin, kuten kasvojen ilmeisiin tai liikeratojen muutoksiin. [2]. Kuitenkaan jokainen ihminen ei pysty ilmaisemaan kokemaansa kipua, jolloin kivun arviointi on huomattavasti monimutkaisempaa.

Oikeanlainen kivun arviointi on erityisen tärkeää kivun hoidossa, sillä paras hoitotulos saavutetaan, kun kivun hoitoa muokataan vastamaan potilaan tarpeita eli hoitoa yksilöllistetään. [3]. Vääränlainen kivun hoito tuo mukanaan riskejä, sillä liian vähäinen kivun hoito johtaa turhaan kärsimykseen ja ylihoito taas altistaa päihderiippuvuudelle. [4]. Tällä hetkellä kivun hoidossa on useita haasteita, kuten se, että lääkehoito perustuu vain yksilön ilmaisemaan kipukokemukseen ja kipulääkkeen vaikiintuneisiin määräämisohjeistuksiin [5]. Lisäksi kivun hoitoon vaikuttavat lääkäreiden vinoumat liittyen sosioekonomiseen asemaan sekä etnisyyteen. Esimerkiksi alempaan sosioekonomiseen asemaan kuuluville määrätään usein vähemmän kipulääkettä kuin ylempään sosioekonomiseen asemaan kuuluville. [3].

Kivun arviointiin ja sen myötä kivun hoitoon liittyvien haasteiden vuoksi on erityisen tärkeää löytää objektiivinen keino arvioida kipua. Puettavien laitteiden avulla tehty kivun arviointi vaikuttaa lupaavalta, sillä se perustuu kipureaktion synnyttämän fysiologisen vasteen mittaamiseen. Tämänkaltaisen fysiologinen vaste on riippumaton potilaan kyvystä ilmaista kipua. Nopean koneoppimismenetelmien kehittymisen ansiosta puettavien laitteiden avulla saatavaa dataa pystytään käsittelemään laskennallisesti nopeammin kuin ennen, mikä mahdollistaa jopa reaaliaikaisen kivun arvioinnin. Tämä tekee aiheesta entistä ajankohtaisemman.

Tämä kandidaatintutkielma on kirjallisuuskatsaus, jossa tarkastellaan puettavilla laitteilla suoritettavaa kudosvauriokivun arviointia. Lisäksi tarkastellaan mahdollisuutta hyödyntää kivun arviointia hoidon yksilöllistämisessä. Tutkielma keskittyy puettavilla laitteilla tehtävän kivun arvioinnin periaatteisiin ja luotettavuuteen. Tävoitteena on selvittää, miten puettavien laitteiden avulla tehtävää kivun arviointia voidaan hyödyntää kipulääkityksen yksilöllistämisessä.

Tutkielman tutkimuskysymykset ovat:


TK1: Miten kipua voidaan arvioida puettavien laitteiden avulla?

TK2: Kuinka tarkasti puettavien laitteiden avulla arvioitu kivun taso vastaa potilaan subjektiivista kokemusta kivusta?

TK3: Millainen rooli kivun arvioinnilla voisi olla kipulääkityksen suunnittelussa ja antamisessa tulevaisuudessa?

Kirjallisuuskatsauksena toteutetussa tutkielmassa aineisto kerättiin useista tietokannoista. Kuvassa 1.1 on tämän tutkielman aineiston tiedonhakuprosessi. Aineistoa haettiin Web of Science -, PubMed- ja Google Scholar -tietokannoista käyttäen hakulauseketta *sensor* AND ("pain measurement" OR "pain assessment") AND personalized pain medicine AND machine learning*. Aineisto rajattiin viimeisen viiden vuoden aikana julkaistuihin artikkeleihin. Web of Science -tietokannasta löytyi 68

tulosta, Google Scholarista 271 tulosta ja PubMedistä 11 tulosta. Hakutulokset olivat osittain päällekkäisiä ja tulokset käsittelivät kivun arviointia puettavien laitteiden, raajojen liikeratojen ja erilaisten kuvantamismenetelmien avulla. Tuloksista rajattiin muut kivun arviointimenetelmät, sillä tutkielman on tarkoitus keskittyä puettavien laitteiden avulla tehtävään kivun arviointiin. Hakutuloksissa tutkittiin myös eri syntymekanismien aiheuttamaa kipua, minkä vuoksi tutkielma rajattiin käsittelemään kudოსvauriokivun arviointia. Katsaukseen valittiin aiheen sekä tutkimuskysymysten kannalta relevantti aineisto otsikoiden sekä abstraktien perusteella. Lopulta aineistoa kertyi yhteensä 11 artikkelia. Tämän lisäksi relevanttia aineistoa löytyi valittujen artikkeleiden lähdeluetteloista.



Kuva 1.1: Tiedonhakuprosessin vaiheet.

Tutkielman luvussa 2 taustoitetaan tutkielman aihetta käsittelemällä kivun syntymekanismeja ja sen aiheuttamaa fysiologista vastetta. Fysiologian käsittely luo pohjan puettavien laitteiden toiminnan ja kivun arvioinnin ymmärtämiselle. Luvussa 3 siirrytään tarkastelemaan kivun arviointiprosessia tarkastellen erilaisia mittausmenetelmiä, kuten sydämen sähkökäyrää ja ihon sähköjohtavuutta. Lisäksi esitellään koneoppimismallien periaatteet ja vertaillaan kivun arviointimenetelmiä. Luvussa 4 syvennyttään tarkastelemaan mahdollisuutta hyödyntää kivun arviointia yksilöllisemmän kivun hoidon saavuttamisessa. Luvussa 5 puolestaan arvioidaan arviointimenetelmien luotettavuutta ja merkitystä yksilöllisemmän kipulääkehoidon kehittämisessä. Lopuksi luvussa 6 tiivistetään keskeiset johtopäätökset.

2 Kiputuntemuksen fysiologia

Kipuaistimus muodostuu useista sähköisistä ja kemiallisista tapahtumista hermostossa, minkä seurauksena kipuärsykkeestä syntyy kipukokemus [6]. Kuvassa 2.1 kuvataan kipuaistimuksen syntymekanismi. Kipu voidaan jakaa sen syntyperän mukaisesti kudonsvauriokipuun, hermovauriokipuun tai idiopaattiseen kipuun eli mekani miltaan tuntemattomaan kipuun. Kivusta puhuttaessa tarkoitetaan usein akuuttia kudonsvauriokipua, jossa kipureseptorit aktivoituvat, kun kudonsvaurio on tapahtunut tai uhkaa tapahtua. [7]. Kipuaistimuksen tapahtumien yhteydessä myös autonominen hermosto aktivoituu, jolloin syntyy fysiologinen vaste [6].


Kivun syntymekanismi ei välttämättä vaikuta fysiologisen vasteen syntymiseen. Kuitenkin hermovauriokivussa kiputuntemus ja fysiologinen vaste voivat olla muista poikkeavia, sillä viestiä välittävä hermosto on vaurioitunut. Idiopaattisessa kivussa taas tarkkaa aistimuksen ja vasteen syntymekanismia ei saada selville. [6]. Tämän vuoksi tutkielma on rajattu kuvaamaan yleisimmän kivun muodon eli kudonsvauriokivun syntymekanismia.

Kudonsvauriokivun syntymekanismi voidaan jakaa neljään tapahtumaan: transduktioon, transmissioon, modulaatioon sekä perseptioon. Kudonsvauriokivun aistiminen alkaa reseptoriin kohdistuvasta kipuärsykkeestä, joka muuntuu transduktiossa sähköiseksi signaaliksi. Hermopäätteissä olevat reseptorit muuntavat astinelimeen kohdistuva ärsykkeet hermoimpulssiksi. Kivun kannalta olennaisimpia hermopäätteitä ovat nosiseptorit, joita on eri puolilla kehoa, kuten ihossa ja lihaksissa. [7].

Hermosyiden ominaisuudet vaihtelevat paljon esimerkiksi koon ja myeliinitupellisuuden perusteella. Tyypillisesti nosiseptoreiksi luokitellaan paksut myeliinitupelliset A-delta-hermosyyt ja ohut myeliinitupettomat C-hermosyyt. Niiden reseptorit reagoivat hermosyylle ominaiseen ärsykkeeseen, joka voi olla mekaaninen, kemiallinen tai lämpöärsyke. Vaikka tuntoärsyke voi kipuärsykkeen lailla olla esimerkiksi mekaaninen, nosiseptorit aktivoituvat vasta kudosisäilyriota aiheuttavasta mekaanisesta ärsykkeestä, kun taas tuntoaistimus syntyy jo kevyestä kosketuksesta. [6]. Kipuärsykkeiden on siis oltava tarpeeksi voimakkaita, jotta ne aiheuttavat solukalvon depolarisaation eli muuntuvat sähköiseksi signaaliksi [7].

Toisessa vaiheessa eli transmissiossa signaali välittyy kudoksesta selkäytimen kautta aivorunkoon [6]. Selkäyttimeen saapuu hermotusta sekä lihaksista että sisäelimestä, minkä vuoksi eri elimistä lähtöisin oleva kipu aiheuttaa samanlaisen fysiologisen vasteen [7]. Aivorungosta kipusignaali etenee talamuksen kautta aivokuorelle, jossa kiputuntemus syntyy [6]. Hermostossa tapahtuu signaalien modulaatiota eli muuntelua. Muuntelua tapahtuu sekä keskushermostossa että selkäytimessä. Modulaatio voi estää tai jopa vahvistaa aistimusta.

Viimeisessä vaiheessa eli perseptiossa kipuaistimus muuttuu subjektiiviseksi kokemukseksi aivoissa, mikä voidaan huomata kuvantamismenetelmillä sekä elektroencefalografialla (engl. electroencephalography, EEG). Aivokuorella kipusignaali muuttuu aistimukseksi ja limbisessä järjestelmässä aistimukseen liittyvät tunteet, kuten pelko. Ihmiselle muodostuu lopulta subjektiivinen kipukokemus, johon vaikuttavat aikaisemmat kipukokemukset sekä genetiikka. [6].



Kuva 2.1: Kipuaistimus syntyy, kun ärsykkeen aiheuttama signaali kulkee selkäytimestä aivorungon kautta sensoriselle aivokuorelle.

Lähde: Kuva on kirjoittajan laatima perustuen lähteeseen [7].

Kipureaktion fysiologinen vaste syntyy, kun kipuaistimuksen yhteydessä autonominen hermosto aktivoituu [6]. Autonominen hermosto voidaan jakaa parasympaattiseen ja sympaattiseen hermostoon, joista parasympaattinen aktivoituu levossa ja sympaattinen rasituksessa. Sympaattisen hermoston aktivoituminen alkaa, kun no-siseptorit kuljettavat signaalin selkärangan ympärillä olevaan sympaattiseen hermorunkoon. Sieltä signaali kulkee hermosyitä pitkin kohde-eliiniin, joita ovat esimerkiksi sydän, hikirauhaset ja keuhkot. [8].

Hermosyyt erittävät välittäjäaineita eli kehon kemiallisia viestejä. Sympaattisen hermoston pääasiallisina välittäjäaineina toimivat noradrenaliini ja lisämunuaisytimen erittämä adrenaliini. Poikkeuksena esimerkiksi hikirauhasiin vievät hermosyyt, jotka erittävät välittäjäaineena asetyylikoliinia. Eritetyt välittäjäaineet sitoutuvat kohdekudoksissa oleviin aineille spesifisiin reseptoreihin. Välittäjäaineiden sitoutuminen aktivoi reseptorit, minkä seurauksena syntyy fysiologinen vaste. Esimerkiksi noradrenaliini sitoutuu kohdekudoksissa oleviin adreno-reseptoreihin. Adreno-resep-


toreihin kuuluvien beeta-adrenoreseptorien aktivoituminen laajentaa keuhkoputkia ja kiihdyttää sydämen toimintaa. Kohdekudosten fysiologiset vasteet eroavat eri kudosten välillä. [8].

Kivun arvioinnissa mitataan sympaattisen hermoston aktivoitumisen aiheuttamia fysiologisia vasteita, sillä aktivoituminen voi johtua kipureaktiosta. Aktivoitumista tapahtuu kuitenkin myös esimerkiksi stressissä. Mielenkiintoisimpia vasteita ovat sydämen lyöntitiheyden tiheneminen ja keuhkoputkien laajeneminen. Tämän seurauksena verenpaine nousee ja syke kasvaa, mikä voidaan havaita tarkkailtaessa kardiovaskulaarista järjestelmää. Kiinnostava vaste on myös ihon hikirauhasten hienerityksen kasvu, minkä seurauksena ihon johtavuus paranee, mikä pystytään havaitsemaan puettavilla laitteilla ihon sähköisen aktiivisuuden muutoksena. Myös irvistäminen on vaste kipureaktioon, mikä johtaa kasvojen poskilihasten sekä kulmakarvojen kurtistuslihaksen supistumiseen, mikä pystytään havaitsemaan lihasten sähköisen aktiivisuuden muutoksena. [8].

Useita sympaattisen hermoston kohde-elimä pystytään mittaamaan puettavilla laitteilla, minkä vuoksi kivun arvioinnissa ollaan erityisesti kiinnostuneita sympaattisen hermoston vasteiden aiheuttamista muutoksista kohde-elimien toiminnassa. Nämä vasteet ovat myös riippumattomia henkilön kyvystä ilmaista kipua. Sen vuoksi puettavien laitteiden avulla tehty kivun arviointi on objektiivisempi tapa arvioida kipua kuin tällä hetkellä käytössä olevat arviointimenetelmät.

3 Kivun arvioiminen puettavien laitteiden avulla

Kivun arvioiminen puettavilla laitteilla perustuu sympaattisen hermoston fysiologisen vasteen mittaamiseen. Tutkielmassa keskitytään fysiologisten vasteiden mittaamiseen puettavien laitteiden eli kehon ulkopuolella käytettävien laitteiden avulla. Puettavien laitteiden anturit muuntavat fysiologisen vasteen sähköiseksi signaaliksi, joka on usein heikko signaali. Mittausprosessit ovat myös herkkiä kohinalle, minkä vuoksi kerättyä dataa täytyy esikäsittää. Koska fysiologiset signaalit ovat ajallista dataa, mittauksista saadaan valtava määrä dataa, jonka käsittelyä koneoppimismenetelmät helpottavat. Käsittelyä varten datasta valitaan ominaisuuksia, joiden avulla kipua voidaan tunnistaa. Koneoppimismenetelmät kykenevät tunnistamaan ominaisuuksien välisiä riippuvuuksia, joita ihminen ei välttämättä tunnistaisi. Kivun arvioiminen puettavilla laitteilla voidaan jakaa kuvan 3.1 mukaisiin vaiheisiin: fysiologisten vasteiden mittaaminen puettavilla laitteilla, kerätyn datan esikäsittely sekä ominaisuuksien erottaminen ja kivun arviointi koneoppimismenetelmin.



Kuva 3.1: Kivun arviointiprosessi.

Lähde: Kuva on kirjoittajan laatima mukaillen lähteessä [9] esitettyä kaaviota.

3.1 Fysiologisten vasteiden mittaaminen

Fysiologisten vasteiden mittaaminen perustuu kehon fysiologiseen muutokseen. Muutokset ovat jatkuvia, minkä vuoksi mittaus tuottaa ajallista dataa. Esimerkiksi sydämen syke voidaan mitata mittaamalla anturilla sydänlihaksen supistumista. Verenkiertojärjestelmästä mitatuista vasteista kiinnostavimpia ovat esimerkiksi syke (engl. heart rate, HR), sykevälivaihtelu (engl. heart rate variability, HRV) ja hengitystiheys (engl. respiration rate, RR) sekä verentilavuuden muutos (engl. blood volume pulse, BV). Mittausprosessit tyypillisesti koostuvat mittausvaiheesta, jossa fysiologiseen vasteen aiheuttamat muutokset, kuten jännite-erot, havaitaan elektrodilla, sekä muunnosvaiheesta, jossa nämä analogiset havainnot muutetaan digitaalseksi dataksi. Datasta saadaan laskettua kivun kannalta mielenkiintoisimpia mitattavia ominaisuuksia.

Sydämen sähköistä toimintaa mitataan elektrokardiografialla (EKG, engl. electrocardiography). EKG perustuu sydänlihassolujen solukalvojen jännitteiden mittamiseen. Elektrodit muuntavat solujen de- ja repolarisaatioiden tuottamat ionivirrat jännite-eroiksi. Sydänsähkökäyrän analysointia varten jännite-erot muutetaan digitaalseksi dataksi. Koska EKG-signaalin piikit kuvastavat sydämen supistumista, joka tihenee sympaattisen hermoston aktivoituessa, kivun mittauksessa kiinnostaa erityisesti vierekkäisten R-piikkien välinen etäisyys. [10]. Tämän tutkielman kirjallisuusaineistossa EKG:tä mitattiin yleensä rintakehän päältä elektrodeilla.

Toinen kardiovaskulaarisen järjestelmän mittaamiseen käytetty mittausmenetelmä kivun havaitsemiseksi on fotopletysmografia (engl. photoplethysmography, PPG). Tämä optinen menetelmä perustuu valon voimakkuuden eli intensiteetin muutokseen havaitussa valossa veren tilavuuden muuttuessa mitattavassa kudoksessa. Iholle asetettu infrapunavalo heijastetaan kudokseen. Ilmaisina, joka on kudoksen toisella puolella tai valon lähteen vieressä, mittaa heijastetun valon intensiteetin, kun osa valosta on absorboitunut kudokseen. Kun mittaus muutetaan digi-

taaliseksi dataksi, voidaan siitä analysoida pulssiaaltoja. Pulssiaalto kuvaa sydämen supistumisen aiheuttamaa paineaaltoa valtimoissa ja pulssiaallon nopeus kuvastaa sydäimestä pumpatun verimäärän nopeutta aortassa. Tämän vuoksi kivun mittauksessa kiinnostaa erityisesti PPG-signaalin huippuihin liittyvät ominaisuudet, kuten huippujen määrä sekä minimi- ja maksimi-arvot. [11]. Aineistossa PPG:tä mitattiin yleensä rannekkeella ranteesta.

Kardiovaskulaarisen järjestelmän lisäksi kivun arvioinnissa hyödynnetään sähköisen aktiivisuuden mittaamista aivoista, lihaksista ja ihosta. EEG:ssä mitataan päänahalle asetettujen elektrodien avulla jännite-eroja, jotka aiheutuvat aivosolujen ionivirroista. Digitaaliseksi muutetusta datasta voidaan analysoida aivosähkökäyrän erilaisia aaltomuotoja. [10]. Aaltomuotojen muutokset viittaavat aivojen aktiivisuuden muutoksiin, mikä on kivun arvioinnin kannalta oleellista. Tämän vuoksi kivun arvioinnissa on kiinnostuttu taajuuteen liittyvistä ominaisuuksista kuten taajuuden keskiarvosta ja muuntelusta. [12].

Elektromyografia (engl. electromyography, EMG) perustuu lihasten sähköisen aktiivisuuden mittaamiseen jännitteenä. Lihasten aktiivisuutta voidaan mitata ihon pinnalle kiinnitetyillä elektrodeilla tai lihakseen asetetuilla neuloilla. Kivun arvioimisen kannalta elektrodien avulla mitattava EMG on kuitenkin kiinnostavampi, sillä neulat voivat itsessään aiheuttaa kipua. Lihaksen aktivoituessa vasteena kipuun aktiopotentiaalit, eli hermostossa kulkevat sähköiset signaalit, aiheuttavat ionivirtoja, mikä johtaa lihaksen supistumiseen. Ihon pinnalle kiinnitetyt elektrodit havaitsevat ionivirtojen aiheuttamat jännite-erot. Jännite muutetaan EMG-aaltojen analysointia varten digitaaliseksi dataksi. EMG-aallossa piikit kuvaavat lihasten supistumisesta. [13]. Aineistossa EMG:tä mitattiin yleensä asettamalla kasvolihaksiin elektrodit, sillä kasvolihasten aktivoitumisella tiedetään olevan yhteys kipureaktioon.

Elektrodermaalinen aktiivisuus (engl. electrodermal activity, EDA), joka tunnetaan myös termillä galvaaniset ihoreaktiot (engl. galvanic skin response, GSR),

tarkoittaa ihon sähköisiä ominaisuuksia. EDA:n muutokset johtuvat keskushermoston aiheuttamista autonomisista muutoksista, kuten hikoilusta ja ihon ionikalvojen läpäisevyyden vaihtelusta, mitkä voivat olla seurausta esimerkiksi kipureaktiosta. Aktiivisuutta mitataan ihon sähkönjohtavuutena (engl. skin conductance). Ihosta voidaan mitata myös esimerkiksi johtavuuden tasoa (engl. skin conductance level) eli hitaita muutoksia johtavuudessa tai johtavuuden vastetta (engl. skin conductance response) eli nopeita väliaikaisia muutoksia johtokyvyssä. Sähkönjohtavuutta mitattaessa ihon läpi johdetaan pieni sähkövirta elektrodien kautta ja mitataan sähkövirran kohtaamaa vastusta. Sähkönjohtavuutta kuvaavassa käyrässä piikit viittaavat sähkönjohtavuuden kasvuun. Sen vuoksi kivun arvioinnissa on kiinnostuttu erityisesti signaalin piikeistä ja niiden välisestä etäisyydestä. [14]. Aineistossa EDA:ta mitattiin yleensä rannekkeella ranteesta.

Kun fysiologiset vasteet on muutettu digitaalseksi dataksi, täytyy signaaleja vielä esikäsittellä ennen koneoppimismenetelmien käyttöä. Esikäsittely on tärkeä osa kivun arviointia, sillä fysiologiset signaalit ovat usein heikkoja ja antureihin tallentuu fysiologisen vasteen lisäksi häiriösignaaleja. Esikäsittelyllä pyritään poistamaan häiriösignaaleja sekä vahvistamaan haluttua fysiologista signaalia. [10]. Häiriösignaaleja ovat esimerkiksi tahattomista liikkeistä syntyvät artefaktit. Esikäsittely on tärkeää, sillä koneoppimismenetelmät ovat herkkiä fysiologisten signaalien mittausprosessille tyypillisille häiriösignaaleille. [15]. Kuva 3.2 kuvaa tyypillisiä kirjallisuusaineistossa käytettyjä puettavia laitteita ja niillä mitattuja esikäsiteltyjä signaaleja. Kivun arvioimisessa fysiologisia signaaleja on aineiston mukaan esikäsitelty anturin mukaan eri menetelmin. Kaikissa tutkimuksissa ei ole kuvattu datan esikäsittelyä.


Tämän tutkielman kirjallisuusaineistossa esikäsittelyn ensimmäinen vaihe on laskea näytteenottotaajuutta, jos signaalit on kerätty korkealla näytteenottotaajuudella. Datan alinäytteistäminen (engl. downsampling) säästää muistia ja käsittelyaikaa, mikä on tärkeää, kun tavoitteena on saavuttaa reaaliaikainen kivun arviointi [16].

Esimerkiksi Kongin ja muiden [17] tutkimuksessa, jossa kipua arvioitiin lähes reaaliaikaisesti, EDA-data kerättiin 130 Hz:in taajuudella ja alinäytteistettiin lopulta 2 Hz:iin.

Lisäksi signaaleja esikäsitellään suodattamalla niitä, millä pyritään poistamaan ylimääräiset taajuusalueet jättäen jäljelle vain halutut fysiologisen signaalin taajuuDET. [15]. Aineistossa suodattamiseen tyypillisesti käytetään ali- tai ylipäästösuodatinta sekä Notch-suodatinta. Alipäästösuodatin päästää nimensä mukaisesti rajataajuuden alla olevat taajuuDET läpi ja suodattaa loput, kun ylipäästösuodatin toimii päinvastoin. Notch-suodatin suodattaa puolestaan tietyn taajuuden pois jättäen muut jäljelle. Esimerkiksi Subramanianin ja muiden [18] tutkimuksessa EKG-signaalin haluttu taajuusalue oli 0,1–250 Hz. EDA-signaalissa puolestaan haluttiin säilyttää Kongin ja muiden [17] tutkimuksessa yli 0,1 Hz:n taajuuDET. EEG-signaalista Imain ja muiden [12] tutkimuksessa säilytettiin 0,5–90 Hz:n taajuuDET. EMG-signaaleista haluttu taajuusalue on suurempi, minkä vuoksi siitä suodatettiin Subramanianin ja muiden [18] tutkimuksessa virhetaajuuDET pois, kuten alle 20 Hz:n taajuuDET sekä 50 Hz:n ja 100 Hz:n taajuuDET.

Suodatuksen lisäksi myös ikkunointia (engl. windowing). Ikkunoinnissa signaali jaetaan lyhyisiin aikaikkunoihin. Aikaikkuna sisältää tyypillisesti jakson, joka voi olla yksittäinen tai useampi fysiologinen tapahtuma, sekä sen lisäksi hieman jakson jälkeistä aikaa. [15]. Aineistossa EKG- ja EMG-datalle tyypillistä on erottelu 5,5 ja 10 sekunnin liukuviin aikaikkunoihin [18], [19]. Kasaeyan Naeini ja muut [19] käyttävät näitä liukuvia aikaikkunoita poistamaan liian lähellä esiintyvät piikit. EDA-datalle tyypillisiä aikaikkunoita ovat 5 sekunnin liukuvat aikaikkunat [16], [17], [18]. Kongin ja muiden mukaan [17] 5 sekunnin aikaikkuna on sopiva kuvaamaan nopeita kivun aiheuttamia muutoksia EDA-signaalissa. Lyhyt aikaikkuna mahdollistaa myös lähes reaaliaikaisen kivun arvioinnin. Lopuksi data voidaan normalisoida (engl. norma-

lization) eli kaikki signaalit sovitetaan samalle asteikolle, jolloin ne ovat helpommin vertailtavissa keskenään [16].



Kuva 3.2: Fysiologisten vasteiden mittaaminen puettavilla laitteilla.
Lähde: Kuva on kirjoittajan laatima mukaillen lähteitä [9] ja [20].

3.2 Kivun tason arviointi koneoppimismenetelmin

Kivun arvioinnin viimeinen vaihe on datan käsittely koneoppimismenetelmin. Koneoppimismallien koulutusta varten datasta erotellaan erilaisia ominaisuuksia käsin sekä koneoppimismenetelmien avulla liittyen signaalien amplitudiin, taajuuteen, stationaarisuuteen, entropiaan ja lineaarisuuteen sekä vaihtelevuuteen [21]. Piikillisissä signaaleissa, kuten EKG-, EDA-, EMG- ja PPG-signaaleissa, valitut ominaisuudet tyypillisesti liittyvät signaalien piikkeihin. Esimerkiksi Subramanianin ja muiden [18] tutkimuksessa PPG-datasta halutaan tietää muun muassa huippujen lukumäärä, minimi- ja maksimiarvo sekä huippujen aikavälien keskiarvo. EEG:ssä puolestaan ollaan kiinnostuneita yksittäisten piikkien sijasta esimerkiksi taajuuden keskiarvosta ja muuntelusta. Koneoppimismenetelmät oppivat datasta sen ominaisuuksien perusteella. Data esitetään muodossa, joka sisältää vain halutut ominaisuudet. Tämän vuoksi tarkkuus paranee. Lisäksi koneoppimismallin koulutus kestää vä-

hemmän aikaa, sillä koulutusdataa on vähemmän. Kirjallisuuskatsauksen tutkimuksessa ominaisuudet vaihtelivat tutkimusten välillä, sillä ei ole yksiselitteistä, mitkä ominaisuuksista tuottavat parhaimmat tulokset. Signaaleista eroteltuihin ominaisuuksiin yhdistyy lopulta potilaiden kertoma kokemus kivun tasosta, jolloin malli voidaan kouluttaa havaitsemaan kipua. [16].

Kivun arvioinnissa koneoppimismallit koulutetaan ohjatulla oppimisella. Ohjatussa oppimisessa kone saa opetusmateriaalina syötteen ja oikean vastauksen eli kivun arvioinnin tapauksessa mittausdataa ja kivun tason, minkä avulla mallin tulisi oppia jaottelemaan samankaltainen data ilman tietoa potilaan kertomasta kivun tasosta. Aineistossa koneoppimismallien koulutukseen käytetty data on fysiologinen signaali ja sitä ajanhetkeä vastaava kipukokemus, joka kerätään joko kivun tasona tai erotetaan vain kivulliset hetket kivuttomista. Tutkielman kirjallisuusaineistossa kipureaktiot olivat joko koetilanteessa tuotettuja lämpögrillin tai sähköiskun avulla tai jo tehtyjen toimenpiteiden, kuten leikkausten, aiheuttamia. [16], [17], [21].

Tärkeä osa koneoppimismallien koulutusta on validointi. Validoinnilla on tarkoitus selvittää, kuinka hyvin malli toimii täysin uudella aineistolla. [22]. Tyypillinen validointimenetelmä on Leave-one-subject-out-ristiinvalidointi (engl. Leave-one-subject-out Cross-validation, LOSOCV), jossa yhden potilaan datan avulla testataan, kuinka hyvin malli havaitsee kipua, kun malli on koulutettu muiden potilaiden datan avulla. Jokaisen potilaan data toimi kerran testijoukkona. [16], [17], [19]. Albahdal ja muut [23] käyttivät validointimenetelmänä muista poiketen k-kertaista ristiinvalidointia (engl. k-fold cross-validation, KCV), jossa data jaettiin seitsemäksi yhtä suureksi osaksi, joista jokainen osa toimi kerran testijoukkona. Gasmi ja muut [21] käyttivät puolestaan ristiinvalidointia, jossa 80 % datasta käytettiin opetukseen ja 20 % testaukseen.

Koneoppimismallien kehittämiseen käytetään erilaisia menetelmiä. Taulukkoon 3.1 on koottu kaikki tämän kirjallisuuskatsauksen aineiston kokeissa käytetyt mene-

telmät. Menetelmät ovat joko luokittelu- tai regressiomenetelmiä. Luokittelumenetelmiä käytetään, kun kohdemuuttujat voidaan jakaa yhteen tai useampaan luokkaan [22]. Kivun arvioinnissa luokittelualgoritmit jaottelevat datan ominaisuuksien perusteella eri luokkiin. Luokat vastaavat kivun eri tasoja, joiden avulla voidaan määritellä kivun senhetkinen voimakkuus. Regressiomenetelmiä käytetään puolestaan, kun kohdemuuttujan arvo on jatkuva lukuarvo. Regressiomenetelmillä pyritään selittämään muuttujien vaikutusta selitettävään muuttujaan [22]. Regressiomenetelmissä kipua ajatellaan tavoitearvojen kautta, jolloin syntyy kipuasteikko.

Kivun arvioimiseen käytettyjä menetelmiä voidaan kuvata niiden ominaisuuksien perusteella. Aineistossa käytetyt menetelmät voidaan jakaa ominaisuuksien perusteella esimerkiksi lineaarisiin, syväoppimis- ja ensemble-menetelmiin sekä päätöspuu- ja etäisyyspohjaisiin menetelmiin. Aineistossa päätöspuupohjaisista menetelmistä käytettiin päätöspuita (engl. Decision Tree, DT). Päätöspuut perustuvat luokittelijoihin, jotka jakavat datan sen ominaisuuksien perusteella pienempiin osiin aina yksittäisiin esiintymiin asti [22]. Luokittelijat lajittelevat jokaisen esiintymän kiputasoon, minkä avulla saadaan eroteltua kiputasot toisistaan. [17], [21], [23].

Kivun arvioimiseen aineistossa hyödynnettiin lisäksi useita ensemble-menetelmiä (engl. ensemble learning), joissa useampi yksittäinen malli yhdistetään yhdeksi malliksi. Yhdistetty malli pärjää usein paremmin kuin mallit yksinään, sillä siihen yhdistyy kaikkien mallien parhaat puolet [24]. Käytettyjä menetelmiä olivat XGBoost (engl. eXtreme Gradient Boosting) ja AdaBoost (engl. Adaptive Boosting). Lisäksi käytettiin Bagging-menetelmää (engl. Bootstrap Aggregating), Light GBM-menetelmää (engl. Light Gradient Boosting Machine) ja satunnaismetsämenetelmää (engl. Random Forest, RF). RF voidaan ajatella myös päätöspuupohjaiseksi, sillä se koostuu useista päätöspuista. [12], [16], [17], [19], [21], [23], [25].

Lisäksi kivun arvioimiseen aineistossa käytettiin lineaarisia koneoppimismenetelmiä. Lineaarisisissa menetelmissä päätöspinta jakaa datan lineaarisesti. [22]. Ai-

neistossa lineaarisista menetelmistä käytettiin logistista regressiota (engl. Logistic Regression, LR), Naive Bayes -luokittelijaa (engl. Naive Bayes, NB) sekä tukivektorikonetta (engl. Support Vector Machine, SVM) ja sen eri variaatioita. SVM voi olla myös ei-lineaarinen, jolloin se pystyy havaitsemaan monimutkaisempia suhteita datasta. [17], [18], [19], [21], [23], [25].

Koneoppimismenetelmät voivat olla myös etäisyyspohjaisia, jotka nimensä mukaisesti perustuvat luokitteluun datapisteiden etäisyyden perusteella [22]. Kivun arvioinnissa datapisteet jaetaan etäisyyden perusteella lähimpään luokkaan. Aineistossa etäisyyspohjaisista koneoppimismenetelmistä käytettiin K :n lähimmän naapurin menetelmää (engl. K-Nearest Neighbors, KNN). [16], [17], [19], [21], [23], [25].

Perinteisten koneoppimismenetelmien lisäksi kivun tunnistamiseen aineistossa käytettiin keinotekoisia neuroverkkoja (engl. Neural Network). Neuroverkot koostuvat neuroneista, joista jokainen saa syötteen ja antaa neuronin parametrien sekä syötteen perusteella tuloksen. Neuroverkot jäljittelevät ihmisen aivojen rakennetta. Menetelmät pystyvät tunnistamaan datasta monimutkaisia kuvioita. [22]. Kirjallisuusaineistossa käytettiin monikerroksista perseptroniverkkoa (engl. Multilayer Perceptron, MLP) eli neuroverkkoa, joka koostuu useista kerroksista. Lisäksi käytettiin konvoluutioneuroverkkoja (engl. Convolutional Neural Network, CNN), jotka perustuvat piirteitä tunnistavaan konvoluutiokerrokseen, ja syviä neuroverkkoja (engl. Deep Neural Network, DNN), jotka perustuvat neuroverkon useisiin piirkerroksiin. [17], [18], [21]. Näiden lisäksi käytettiin takaisinkytkettyjä neuroverkkoja (engl. Recurrent Neural Network, RNN), joissa syötteet ovat kytketty aika-akseleihin, minkä ansiosta RNN hyödyntää muistia uusien syötteiden käsittelyyn. Myös menetelmät, kuten kaksisuuntaiset GRU-verkot (engl. Bidirectional Gated Recurrent Unit network, BiGRU) ja pitkän aikavälin lyhytmuistiverkot (engl. Long short-term memory network, LSTM), perustuvat takaisinkytkettyihin neuroverkkoi-

hin, mutta niiden erityispiirteiden vuoksi ne pystyvät käsittelemään pidempiaikaisia riippuvuuksia kuin perinteinen RNN. [18], [21].

Taulukko 3.1: Yhteenveto kokeissa käytetyistä koneoppimismenetelmistä

Lähde	Menetelmä														
	Päätöspuu- pohjaiset	Ensemble -menetelmät					Lineaariset			Etäisyys- pohjaiset	Neuroverkot				
		DT	RF	AdaBoost	XGBoost	Bagging	Light GBM	LR	NB		SVM	KNN	MLP	CNN	DNN
Aqajari ym. [16]		x									x				
Kasaeyan Naeini ym. [19]		x	x	x					x		x				
Kong ym. [17]	x	x				x			x		x	x			
Subramanian ym. [18]									x				x		x
Gasmi ym. [21]	x	x	x		x		x		x		x		x	x	x
Albahdal ym. [23]	x	x					x	x	x		x				
Cao ym. [25]		x	x	x					x		x				
Imai ym. [12]		x		x		x									

Koneoppimismenetelmien hyödyntäminen kivun arvioinnissa perustuu kivun tason havaitsemiseen. Kirjallisuusaineistossa kivun arviointimallien tietoaaineistoina käytettiin joko itse mitattuja tai valmiita tietoaaineistoja. Toinen valmiina olevista tietoaaineistoista on iHurt, johon on kerätty 25 potilaalta leikkauksen jälkeistä dataa PPG-, EDA-, EKG- ja EMG-mittauslaitteilla [18]. Toinen käytetty tietoaaineisto on BioVid Heat Pain -tietoaaineisto (BVHP), johon data on kerätty 90 koehenkilöltä EDA-, EKG-, EMG- ja EEG-mittauslaitteilla. Tietoaaineistossa kipu on tuotettu lämpögrillillä. [26]. Kirjallisuusaineiston kokeissa, Kongin ja muiden [17] tutkimusta lukuun ottamatta, kivun tasoa ei arvioitu reaaliajassa, vaan signaali oli kerätty ja esikäsitelty etukäteen. Kongin ja muiden [17] tutkimus puolestaan arvioi kipua lähes reaaliaikaisesti, mutta vain binäärisesti eli tunteeke potilas kipua vai ei. Kivun tasoa arvioitaessa kiputasot olivat 0–4. Tasot voidaan sanallistaa tasoiksi: 0 perustaso, jossa kipua ei tunneta, sekä kiputasot 1 vähäinen kipu, 2 lievä kipu, 3 kohtalainen kipu ja 4 voimakas kipu. Poikkeuksena Subramanianin ja muiden [18] sekä Caon ja muiden [25] tutkimukset, joissa käytetyt tasot olivat 0–3.

Taulukkoon 3.3 on koottu yksittäisten antureiden avulla suoritettujen kokeiden tulokset ja taulukkoon 3.4 on koottu puolestaan yhdistelmämallien kokeiden tulokset. Tutkimusten tulokset on mitattu tarkkuutena (engl. accuracy). Tarkkuus lasketaan jakamalla oikeiden ennusteiden määrä kaikkien ennusteiden määrällä. Kivun tasoa arvioivissa tutkimuksissa mallin tarkkuus taulukoihin 3.3 ja 3.4 on laskettu kaikkien kiputasojen tarkkuuksien keskiarvona.

Eri tutkimusten mallit eivät ole kuitenkaan täysin vertailtavissa, sillä niissä on useampia muuttuvia tekijöitä, kuten eri antureita tai validointimenetelmiä. Taulukkoon 3.2 on koottu kirjallisuusaineiston koeasetelmat. Esimerkiksi Gasmi ja muut [21] saavuttavat tutkimuksessa korkeampia tarkkuuksia kuin muut, mutta toteavat, että heidän validointimenetelmänsä saattaa liioitella mallin todellista tarkkuutta. Heidän validoinnissaan ei varmistettu, että koko koehenkilön data on vain joko koulutus- tai testiaineistossa. Koska saman henkilön dataa voi olla molemmissa aineistoissa, malli on saatettu kouluttaa testiaineistossa esiintyvien henkilöiden datalla eikä testiaineisto ole mallille uutta.

Taulukko 3.2: Yhteenvedo koeasetelmista

Lähde	Vuosi	Anturi	Tietoaineisto	Validointi
Subramanian ym. [18]	2025	PPG, EMG, EKG, EDA	iHurt	LOSOCV
Cao ym. [25]	2021	PPG	iHurt	LOSOCV
Aqajari ym. [16]	2021	EDA	iHurt	LOSOCV
Kasaeyan Naeini ym. [19]	2021	EKG	iHurt BioVid Heat Pain	LOSOCV
Albahdal ym. [23]	2024	EMG, EKG, EDA	BioVid Heat Pain	KCV
Gasmi ym. [21]	2025	EMG, EKG, EDA	BioVid Heat Pain	80 % / 20 %
Kong ym. [17]	2021	EDA	Itse kerätty	LOSOCV
Imai ym. [12]	2025	EEG	Itse kerätty	KCV

Taulukko 3.3: Yhteenveto yksittäisten antureiden avulla suoritettujen kokeiden tuloksista. Kokeissa on käytetty eri ominaisuuksia, validointimenetelmiä ja tietoaaineistoja. Kasaeyan Naeini ja muiden [19] tutkimuksessa on tehty vertailua kahden tietoaaineiston avulla. Lisäksi Kongin ja muiden [17] tutkimuksessa kipua arvioidaan muista poiketen binäärisesti.

Menetelmä	Anturi				
	PPG	EKG	EMG	EDA	EEG
DT				76,1 [17]	
RF	69,56 [25]	62,26 [19] 56,00 [19]		71,83 [16] 81,5 [17]	56 [12]
AdaBoost	64,73 [25]	58,23 [19] 59,04 [19]			
XGBoost	67,71 [25]	62,00 [19] 55,3 [19]			75 [12]
Light GBM					78 [12]
LR				81,3 [17]	
KNN	62,31 [25]	53,36 [19] 54,72 [19]		69,5 [16] 78,0 [17]	
SVM	83,03 [18] 80,42 [25]	72,97 [19] 72,94 [19]	82,8 [18]	80,8 [17] 77,4 [17] 81,1 [17]	
MLP			79,6* [17]		
CNN-SVM			79,04 [18]		
LSTM-SVM		81,08 [18]			

Taulukosta 3.3 huomataan, että mallien tuloksissa on huomattavasti hajontaa, sillä tarkkuudet vaihtelevat 53,36–83,03 % välillä. Toiset koneoppimismenetelmistä soveltuvat siis kivun arviointiin huomattavasti paremmin kuin toiset. Parhaimpia yksittäisiä perinteisiä koneoppimismalleja tulosten perusteella ovat RF ja SVM. Taulukon korkein tarkkuus 83,03 % saavutettiin Subramanianin ja muiden [18] tutkimuksessa SVM-mallilla PPG-dataa käyttäen.

Vertaillen tuloksia huomataan, että samoilla koeasetelmilla tehtyjen kokeiden tulokset eivät ole täysin samat. Esimerkiksi Subramanianin ja muiden [18] tutkimuksessa SVM-mallilla päästään 83,03 % tarkkuuteen, mutta Caon ja muiden [25] tutkimuksessa SVM-malli yltää vain 80,42 % tarkkuuteen, vaikka tietoaaineisto, anturi sekä validointi- ja koneoppimismenetelmä ovat samat. Eroa todennäköisesti selittää mallien erilainen koulutusprosessi, sillä tutkimuksissa datasta valittiin koulutukseen eri ominaisuuksia.

Taulukko 3.4: Yhteenvedo yhdistelmämallien kokeiden tuloksista

Artikkeli	Anturi	Tietoaaineisto	Menetelmä	Tulos
Subramanian ym. [18]	EKG, EMG, EDA, PPG	iHurt	LSTM-SVM	81,08
Albahdal ym. [23]	EMG, EKG, EDA	BVHP	RF	80,00
			SVM	59,25
			LR	75,5
			DT	74,00
			NB	64,50
			KNN	59,90
Gasmi ym. [21]	EMG, EKG, EDA	BVHP	DT	76,17
			LR	50,04
			RF	83,35
			AdaBoost	82,10
			SVM	50,18
			KNN	53,52
			Bagging	80,17
			CNN	82,37
			LSTM	82,6
			DNN	81,81
			BiGRU	81,75
			CNN-LSTM	84,18
			Muut yhdistelmät	82,34–83,85


Taulukosta 3.4 huomataan, että syväoppimismalleilla voidaan saavuttaa parempia tuloksia kuin perinteisillä koneoppimismalleilla. Kuitenkin parhaimpaan tulokseen pääsevä syväoppimismalli CNN-LSTM oli vain 0,83 prosenttiyksikköä tarkempi kuin RF-malli samalla tietoaaineistolla. Koska syväoppimismallien kouluttaminen on kalliimpaa verrattuna perinteisten mallien kouluttamiseen, ei syväoppimismenetelmien käyttö tuo merkittävää etua, vaikka ne ovat hieman tarkempia.

Taulukosta 3.4 huomataan, että useamman anturin käytöllä päästään parempiin tarkkuuksiin kuin yksittäisillä antureilla. Gasmi ja muut [21] pääsivät multimodaalisella anturidatalla parempiin tuloksiin lähes jokaisella koneoppimismallilla kuin Kasaeyan Naeini ja muut [19] pelkästään EKG-datalla, kun molemmilla oli käytössä BioVid Heat Pain -tietoaaineisto. Kun mallina käytettiin AdaBoostia, ero tutkimusten välillä oli 23,06 prosenttiyksikköä ja RF:llä 27,35 prosenttiyksikköä. Poikkeuksena oli KNN-malli, jolla Kasaeyan Naieni ja muut [19] saavuttivat paremman tuloksen. Myös koneoppimismenetelmien yhdistäminen tuotti parempia tuloksia kuin mallit yksinään. Esimerkiksi Gasmi ja muut [21] pääsivät CNN-LSTM-mallilla jopa 84,18 % tarkkuuteen arvioidessa kivun tasoa, kun tarkkuus yksittäin CNN-mallilla oli 82,37 % ja LSTM-mallilla 82,6 %. Voidaan siis sanoa, että multimodaaliset arviointimallit lähtökohtaisesti parantavat tarkkuutta.

Toisaalta Zhu ja muut [20] nostavat esiin, että yksittäisen anturin käyttö on huomattavasti yksinkertaisempaa ja myös tavoiteltavaa, jos sillä saavutetaan lähes sama tarkkuus kuin monimutkaisemmilla multimodaalisilla järjestelmillä. Lisäksi oletuksen vastaisesti Subramanianin ja muiden [18] tutkimuksessa kaiken itse kerätyn anturin datan yhdistäminen ei tuottanut parasta tulosta. Tämän perusteella voidaan todeta, että tavoitteena on löytää arviointimenetelmä, joka on mahdollisimman yksinkertainen, mutta saavuttaa samalla mahdollisimman suuren tarkkuuden.

Kivun arvioinnin tarkkuuksia vertaillessa on tärkeä nostaa esiin, että tarkkuus kivun eri tasojen arvioimisessa eri tutkimuksissa vaihtelee huomattavasti. Tietyn

kivun tason havaitseminen onkin haastavampaa kuin kivun erottaminen kivuttomasta hetkestä. Kuvan 3.3 pylväsdiagrammiin on koottu eri tutkimusten parhaiden menetelmien tarkkuudet tasokohtaisesti. Erilaisten käytettyjen tasojen ja muiden kokeiden muuttujien vuoksi tutkimusten saavutetut tarkkuudet kiputasoittain eivät ole suoraan verrattavissa toisiinsa.



Kuva 3.3: Yhteenveto kokeiden tarkimpien menetelmien tuloksista kiputasoittain.

Kuvan 3.3 pylväsdiagrammin mukaan vähiten hajontaa tarkkuuksissa on, kun yritettiin tunnistaa lievää kiputasoa. Lievä kiputaso tunnistettiin yhtä tutkimusta lukuun ottamatta aina vähintään 80 % tarkkuudella. Tämän perusteella voidaan todeta, että kiputaso 2 tunnistetaan yleisesti parhaiten. Eniten hajontaa taas oli korkeammilla kiputasoilla. Voimakasta kiputasoa tunnistessa Gasmi ja muut [21] pääsivät jopa yli 90 % tarkkuuteen CNN-BiGRU-mallilla, kun taas Aqajarin ja muiden [16] RF-malli jäi alle 60 % tarkkuuteen. Pylväsdiagrammista huomataan siis, että tulokset ovat osittain täysin päinvastaisia. Esimerkiksi Aqajarin ja muiden [16] tutkimuksessa tarkkuus laskee, mitä korkeampaa kiputasoa yritetään havaita, kun taas Gasmin ja muiden [21] tutkimuksessa tarkkuus paranee.

Ristiriitaiset tulokset johtuvat monista asioista. Esimerkiksi Kasaeyan Naeinin ja muiden [19] mukaan korkeamman kiputason tunnistusta vaikeutti se, että koulutus-

datassa oli erityisesti korkeimman kiputason esiintymiä niukasti. Aqajarin ja muiden [16] mukaan korkeampaa tasoa on vaikeampi tunnistaa, sillä kovassa kivussa olevat potilaat liikkuvat, mikä synnyttää artefakteja. Vähäisen kivun tunnistamista puolestaan vaikeuttaa Subramanianin ja muiden [18] mukaan se, että fysiologisten signaalien muutokset ovat lähtötasoon nähden maltilliset. Heidän anturivertailuissaan EMG:llä tunnistettiin hyvin erityisesti korkeita kiputasoja, kun taas EDA:lla oli vaikeampi erottaa kiputasoja toisistaan. Tämä johtuu siitä, ettei EDA:lla mitatussa datassa ollut huomattavia tasojen välisiä eroja, joita EMG:llä mitatussa datassa taas oli erityisesti korkeissa kiputasoissa.

Kiputasojen arvioimiseen liittyvien haasteiden lisäksi arviointimalleihin liittyy monia muitakin haasteita. Esimerkiksi tosielämässä tarkkuus on heikompi kuin laboratorioympäristössä, sillä potilaan liikkeistä syntyy helposti tuloksia häiritsevää liikeartefaktikohinaa. [16]. Lisäksi fysiologisen vasteen saa aikaan myös esimerkiksi tunteet, uni ja stressi. Näiden vuoksi koneoppimismalleilla voi olla hankaluuksia erottaa fysiologisten signaalien muutosten syyt oikein. [27]. Tätä vaikeuttaa myös se, että kivun eri tasot voivat olla huomattavan erilaisia eri yksilöillä, sillä kipukokemukseen vaikuttavat myös sosioekonomiset tekijät. [16], [27].

Arviointimallit eivät myöskään ole kaiken kattavia, sillä ne eivät sellaisenaan pysty paikantamaan kivun lähdettä. Kivun paikantaminen helpottaa kivun hoitoa tapauksissa, joissa potilas ei pysty itse kommunikoimaan [17]. Näiden haasteiden lisäksi Gasmi ja muut [21] nostavat esiin vielä malleihin liittyvät eettiset kysymykset, kuten potilaan suostumus, fysiologinen tietosuoja ja algoritmisen vinouman riski. Näihin haasteisiin tulisi löytää vastaukset ennen mallien käyttöönottoa. Kaiken kaikkiaan Aqajari ja muut [16] kuitenkin toteavat, että kivun arviointimalleja voitaisiin ottaa käyttöön tulevaisuudessa. Erityisenä mielenkiinnon kohteena on kivun arviointimallien hyödyntäminen lääkityksen yksilöllistämisessä.

4 Yksilöllistetty hoito kivun arvioinnin avulla

Yksilöllisellä hoidolla tarkoitetaan hoidon räätälöimistä jokaiselle yksilölle ottaen huomioon heidän henkilökohtaiset tarpeensa [28]. Yksilön huomiointi on askel kohti parempaa hoitoa, sillä se parantaa hoitotuloksia ja vähentää lääkkeiden aiheuttamia sivuvaikutuksia. Lisäksi potilastyytyväisyys paranee, mikä on hoitoon sitoutumisen kannalta merkittävää. [29]. Yksilöllinen hoito parantaa siis elämänlaatua ja pelastaa ihmishenkiä, mikä on myös lääketieteen perimmäinen tavoite [28].

Kivun hoidon räätälöiminen yksilölle on erityisen tärkeää, sillä kipu muodostuu yksilön subjektiiviseksi kokemukseksi, johon vaikuttavat monet tekijät, kuten biologiset, psykologiset ja ympäristötekijät [30]. Jopa 60 prosenttia ihmisten välisten kiputasojen vaihtelusta selittyy genetiikalla [31]. Kun genetiikan lisäksi kokemukseen vaikuttavat esimerkiksi aiemmat kokemukset kivusta, muodostuu kipukokemuksesta hyvin yksilöllinen.

Yksilöimisestä hyödytään erityisesti kivun hoidossa, sillä kivun hoidossa käytettäviin kipulääkkeisiin liittyy useita riskejä ja haittoja. Esimerkiksi keskushermostoon vaikuttavia tehokkaita kipulääkkeitä käyttävillä potilailla ilmenee usein haittavaikutuksia. Lähes joka kolmannella opioidien käyttäjällä esiintyy riippuvuuden ja käyttöhäiriön merkkejä ja oireita [32]. Tulevaisuuden näkymät eivät myöskään ole valoisat, sillä opioidiriippuvuuden uskotaan kasvavan globaalisti väestömäärään

suhteutettuna 25 prosenttia vuodesta 2021 vuoteen 2040 mennessä. Haittoja pystytään kuitenkin merkittävästi vähentämään oikeanlaisella ja yksilölle räätälöidyllä lääkityksellä. [30].

Kiinnostava ajatus on yksilöidä kipulääkitystä puettavien laitteiden avulla tehtävän kivun arvioinnin avulla, sillä se tarjoaa objektiivisemmän ja kokonaisvaltaisemman arvion kivusta. Kivun arviointia voisi olla mahdollista hyödyntää niin lääkityksen suunnittelussa kuin annossa. Lääkehoitoa suunniteltaessa arvioitaisiin kivun tasoa ja sen myötä kipulääkityksen tarvetta. [29]. Tämänhetkinen käytäntö lääkahoitoa määrätessä perustuu yksilön subjektiiviseen kertomukseen koetusta kivusta ja kipulääkkeen vakiintuneisiin annostusohjeistuksiin, jolloin ei ehkä saavuteta yksilön eikä yhteiskunnan näkökulmasta tehokkainta hoitoa. [5]. Kivun arvioinnin avulla lääkahoito voisi olla mahdollista saada vastaamaan juuri yksittäisen potilaan tarpeita paremmin kuin aikaisemmin, minkä myötä hoidosta saadaan tehokkaammaksi ja haittavaikutusten riskit minimoidaan. [29].

Kivun arvioinnin avulla voisi olla mahdollisuus myös arvioida kipuprofilia ja tulevaa kiputasoa, jolloin kipulääkitystä voitaisiin suunnitella jo ennen toimenpidettä. Nickerson ja muut [33] saavuttivat lupaavia tuloksia tutkimuksessaan, jossa koulutettiin neuroverkko ennustamaan kivun tasoa antamalla mallille potilaiden omia arvioita kivun tasosta ennen lääkkeen antamista ja sen jälkeen sekä hyödyntämällä potilastietoja. Tutkijat kuitenkin toteavat, että ennustamiseen liittyy vielä haasteita ja ajallisen datan, kuten elintoimintodatan, lisäämisen myötä mallin ennustuksen tulokset todennäköisesti paranevat. Tämän perusteella voidaan sanoa, että mallin yhdistäminen kivun arvioinnista saatuun fysiologiseen dataan voisi mahdollistaa paremmat ennustukset, sillä etuna olisi fysiologisen datan tuoma tarkkuus sekä objektiivisempi kivun arviointi. Leurox ja muut [34] esittävät puolestaan, että koneoppimista voitaisiin hyödyntää myös tulevien kroonisten kiputilojen alkamisen ennustamisessa. Voidaan todeta, että tulevan kiputason ennustaminen mahdollis-

taisi yksilöllisemmän lääkehoidon, mikäli esimerkiksi ennen leikkausta pystyttäisiin ennustamaan leikkauksen jälkeisen kiputason. Ennustamisesta saatuja tuloksia voitaisiin hyödyntää myös sairaalan ulkopuolella tapahtuvassa hoidossa, kuten kotona leikkauksen jälkeen, missä ei pystyttäisi hyödyntämään reaaliaikaista mittausta.

Lääkehoidon suunnittelun lisäksi kivun arvioinnin tuloksia voisi olla mahdollista hyödyntää kipulääkkeiden annossa, sillä reaaliaikaista dataa hyödynnetään nyt jo esimerkiksi diabeteksen hoidossa käytetyissä lääkepumpuissa [35]. Lääkkeenantojärjestelmät pystyvät seuraamaan reaaliaikaisesti potilaan reaktioita ja säätämään niiden mukaan lääkkeenantoa. Fysiologisten muutosten mukaisesti säädeltä lääkkeenanto varmistaa lääkkeen terapeuttisen tason ylläpidon ja vaikuttaa lupaavalta tutkimusalueelta. [36].

Erityisen mielenkiintoista reaaliaikaisista lääkkeenannostelujärjestelmistä tekee se, että Kong ja muut [17] osoittivat tutkimuksessaan, että kipua voidaan arvioida puettavien laitteiden avulla lähes reaaliajassa. Tämän takia reaaliaikainen kipulääkkeenannostelujärjestelmä voisi teoriassa olla mahdollinen. Jos lääkkeenannostelujärjestelmät pystyisivät säätämään kipulääkkeiden annostusta reaaliaikaiseen dataan pohjautuen, saataisiin lääkehoidosta vielä tarkempaa ja helpompaa.

Kaiken kaikkiaan kivun arvioinnin hyödyntäminen lääkehoidon yksilöimisessä, niin suunnittelu- kuin antovaiheessa mahdollistaisi täsmällisemmän hoidon. Tarkemman kivun hoidon avulla on mahdollista päästä parempiin hoitotuloksiin, mikä myötä myös hoidon kustannukset pienenevät [28]. Puettavien laitteiden avulla saadun kivun arvioinnin perusteella tehty lääkehoito voisi mahdollisesti parantaa hoidon tehoa kustannustehokkaasti.

5 Pohdinta

Kuten aiemmissa luvuissa todettiin, kivun arvioinnissa puettavien laitteiden avulla on saavutettu hyviä tuloksia, minkä myötä niiden käyttöönottaminen tulevaisuudessa vaikuttaa lupaavalta. Kuitenkaan kivun arviointimallit eivät ole tarpeeksi tarkkoja toimiakseen ilman ihmisen harkintaa. Arviointimallit pystyisivät helpottamaan kivun arviointia, mutta ne eivät voi arvioida kipua täysin itsenäisesti, sillä kivun arviointiin liittyy vielä useita haasteita esimerkiksi luotettavuuteen ja eettisyyteen liittyen. Aineistosta tulee ilmi, että suurimmat haasteet liittyvät mallin yleistettävyyteen kipu kokemuksen subjektiivisuuden vuoksi. Koska kipukokemukseen vaikuttavat esimerkiksi kulttuuriset tekijät, ei malli välttämättä skaalaudu täysin esimerkiksi maailmanlaajuisesti. Aineistossa keskityttiinkin lähinnä tutkimaan, onko kivun arviointi puettavilla laitteilla mahdollista, eikä onko realistista, että tämän kaltaisia arviointijärjestelmiä olisi terveydenhuollossa käytössä.

Ennen kuin arviointimalleilla on jalansijaa terveydenhuollossa, täytyy ratkaista useita ongelmia. Ensimmäkin täytyy huomioida, miten uuteen teknologiaan suhtaututaan. Lähtökohtaisesti potilaat suhtautuvat yleisesti tekoälyn tekemiin diagnooseihin kriittisemmin kuin ihmisten tekemiin [37]. Suhtautuminen kivun diagnosoinnissa tuskin on poikkeus, sillä kipu on hyvin subjektiivinen kokemus. Koska potilaan suhtautuminen on kuitenkin tärkeä osa hoitomyönteisyyttä, suhtautuminen vaikuttaa hoidon tehokkuuteen. Arviointimallien käyttöönotto terveydenhuollossa vaatisi asenteiden muuttumisen lisäksi myös sääntelyn haasteiden ratkomista. Täl-

lä hetkellä tekoälypohjaisten lääkinnällisten laitteiden sääntely vaatii toimia, kuten sääntelyn globaalia yhtenäistämistä [38].

Kivun arviointi puettavien laitteiden avulla ei myöskään ole täydellinen arviointimenetelmä, sillä aineistosta tulee ilmi, ettei kaikenlaista kipua voida tunnistaa. Tyypillisesti kivun syntymekanismi tunnistetaan ja sen aiheuttama fysiologinen vaste voidaan mitata. Kuitenkin esimerkiksi kivun kroonistuttua fysiologinen vaste voi muuttua, minkä myötä kroonisen kivun tunnistamiseen tarvitaan erilainen arviointimalli [17]. Jotta arviointimalli olisi mahdollisimman kattava, sen tulisi pystyä arvioimaan lähes kaikenlaista kipua, mikä tulisi huomioida koulutusprosessissa. Kattavuutta heikentää lisäksi se, ettei kivun paikantamista voida aina tehdä, sillä kipureaktio on hyvin monimutkainen. Toisaalta idiopaattisen kivun syntyä ei pystytä edes teoriassa paikantamaan [7]. Sen lisäksi, että kivun paikantaminen antureiden avulla on hyvin haastavaa, se vaatisi huomattavan määrän antureita. Voidaan todeta, että nämä rajaavat puettavien laitteiden avulla tehtävän kivun arvioinnin käyttökohteita huomattavasti.

Puettavien laitteiden avulla tehtävässä kivun arvioinnissa joudutaan puntaroimaan monen asian välillä, esimerkiksi multimodaalisuuden ja yksinkertaisuuden välillä. Aineistosta tulee ilmi, että multimodaaliset mallit ovat tarkempia, sillä koneoppimismenetelmät ja anturit täydentävät toisiaan. Toisaalta yksinkertaisemmat mallit vaativat vähemmän laskentatehoa sekä koulutusaikaa, minkä vuoksi ne ovat myös halvempia. Lisäksi useampaa anturia käyttävä menetelmä on teknisesti vaikeampi toteuttaa [20]. Tämän perusteella voidaan sanoa, että puettavilla laitteilla tapahtuvassa kivun arvioinnissa avainasemassa tulevat olemaan yksittäiset koneoppimismenetelmät ja yksittäiset puettavat laitteet, joilla pystytään mittaamaan useaa fysiologista vastetta. Multimodaalisuuden lisäksi koneoppimismenetelmiä valittaessa joudutaan pohtimaan myös mallien selitettävyyttä, vaikkei sitä nostettukaan aineistossa esiin yhtenä arviointimallien haasteena. Syväoppimismallien tekemä päättely

ei aina ole läpinäkyvää, minkä vuoksi ei ole mahdollista saada selville, miksi malli päätyi kyseisiin tuloksiin [36]. Tämän perusteella voidaan sanoa, että vaikka syväoppimismalleilla päästäisiin parempiin tuloksiin, ei niitä välttämättä silti voitaisi käyttää terveydenhuollossa.

Arviointimalleissa joudutaan valitsemaan myös käytettävyyden ja mittausmenetelmän tarkkuuden välillä. Aineiston mukaan osa antureista tunnisti paremmin tiettyjä kiputasoja. Esimerkiksi kasvojen lihaksiin kytketyllä EMG:llä saavutettiin paras tarkkuus korkeissa kiputasoissa [18]. Voidaan kuitenkin todeta, ettei kasvoihin kiinnitetyt elektrodit ole potilaan kannalta mukavin tai käytännöllisin ratkaisu varsinkaan jatkuvassa reaaliaikaisessa mittauksessa. Sen vuoksi käytettävyys tuo omat rajoitteet arviointimalleille. Kivun arvioinnin ei kuitenkaan välttämättä täydy olla kiputasoihin perustuvaa, vaan reaaliaikaisessa arvioinnissa riittää havaita, onko potilaalla kipua vai ei. Tasojen avulla arvioinnissa etuna kuitenkin on huomata, paheneeko vai hellittäkö kipu.

Aineistosta tulee ilmi, että seuraavaksi olisi tarpeen testata kivun arviointimallia suuremmalla otoksella. Kaikki aineiston tutkimukset olivat tehty alle sadan ihmisen otoksilla. Otoksokoa kasvattaessa tulisi huomioida otoksen monimuotoisuus, kun tiedetään, että kipukokemukseen voi vaikuttaa esimerkiksi kulttuurilliset tekijät. Lisäksi olisi tarpeellista tutkia enemmän puettavien laitteiden avulla tehtävän kivun arvioinnin hyödyntämistä lääkityksen yksilöimisessä käytännössä, sillä tällä hetkellä tutkimukset perustuvat lähinnä teoreettiseen mahdollisuuteen.

6 Yhteenveto

Tässä tutkielmassa tarkasteltiin kivun arviointia puettavien laitteiden avulla ja arvioinnin hyödyntämistä yksilöllistetyssä kivunhoidossa. Kivusta muodostuu aivoissa subjektiivinen kokemus, minkä vuoksi terveydenhuollon ammattilaisen on vaikea arvioida potilaan kokemaa kipua objektiivisesti – erityisesti sellaisten potilaiden kohdalla, jotka eivät kykene ilmaisemaan tuntemaansa kipua selkeästi. Puettavat laitteet tarjoavat objektiivisen tavan arvioida kipua, sillä ne mittaavat ihmisen fysiologista vastetta kipureaktiolle, joka on riippumaton potilaan kyvystä ilmaista kipua. Objektiivinen kivun arviointi mahdollistaa tehokkaamman kivun hoidon, sillä se vähentää lääkehaittoja ja nopeuttaa paranemisprosessia. Kirjallisuuskatsauksen perusteella voidaan vastata johdannossa esitettyihin tutkimuskysymyksiin seuraavasti.

Puettavilla laitteilla kivun tasoa voidaan arvioida hyödyntäen koneoppimismenetelmiä. Kivun arviointi puettavilla laitteilla alkaa fysiologisen vasteen mittaamisesta ja signaalin esikäsittelystä. Esikäsittelystä datasta erotellaan valitut ominaisuudet, joiden avulla koneoppimismalli havaitsee, milloin potilas tuntee kipua ja milloin ei. Lisäksi malli havaitsee kivun tason. Kivun arvioimiseen on testattu useita koneoppimismenetelmiä, joista parhaiten pärjäävät satunnaismetsämenetelmä, tukivektorikone sekä erilaiset menetelmien yhdistelmämallit.

Puettavien laitteiden avulla arvioidun kivun tason tarkkuus vaihtelee tutkimusten välillä riippuen kokeissa käytetyistä menetelmistä. Parhaimpaan tarkkuuteen

pääsevät Gasmi ja muut [21] useamman anturin ja koneoppimismallin yhdistelmällä saavuttaen 84,18 % tarkkuuden. Lisäksi tarkkuus eri kiputasojen välillä vaihtelee huomattavasti. Kiputasot luokitellaan välille 1–4 ja 0 vastaa kivutonta olotilaa. Lievä kipu tunnistetaan kaikista parhaiten, kun taas voimakkaan kivun tunnistamisessa on eniten haasteita, jotka voivat johtua liian vähäisestä tai huonolaatuisesta datasta voimakkaan kiputilan aikana. Toisaalta vähäistä kipua on vaikeampi erottaa kivuttomasta hetkestä, sillä kipureaktio ei tuota tarpeeksi voimakasta signaalia.

Kivun arviointia on mahdollisuus hyödyntää niin kipulääkityksen suunnittelussa kuin antamisessa tulevaisuudessa. Suunnittelussa voitaisiin hyödyntää reaaliaikaista mittausdataa, jolloin lääkitystä voitaisiin nostaa tai laskea kivun tason mukaisesti. Datasta voisi olla mahdollisuus arvioida kipuprofilia ja ennustaa tulevaa kiputasoa, mikä mahdollistaisi lääkityksen suunnittelun jo ennen toimenpidettä, kuten leikkausta. Kipulääkityksen annossa kivun arviointia voisi olla mahdollista hyödyntää lääkepumpuissa, jotka annostelevat lääkettä reaaliaikaiseen dataan perustuen. Tällöin lääke annosteltaisiin kivun tasoon perustuen.

Tutkielma osoittaa, että kivun arviointi puettavien laitteiden avulla tarjoaa objektiivisemmän tavan arvioida kipua ja sen myötä yksilöllisemmän kivun hoidon. Ennen kuin arviointimallia voidaan käyttää terveydenhuollossa, täytyy kuitenkin ratkoa useita haasteita, esimerkiksi laitteiden luotettavuuteen ja käytettävyyteen liittyen. Kokonaisuudessaan puettavien laitteiden avulla tehtävä kivun arviointi vaikuttaa lupaavalta.

Lähdeluettelo

- [1] P. Mäntyselkä, E. Kumpusalo, R. Ahonen, A. Kumpusalo, J. Kauhanen, H. Viinamäki, P. Halonen ja J. Takala, "Pain as a Reason to Visit the Doctor: A Study in Finnish Primary Health Care", *Pain*, vol. 89, s. 175–180, 2001. DOI: 10.1016/S0304-3959(00)00361-4.
- [2] T. H. Wideman, R. R. Edwards, D. M. Walton, M. O. Martel, A. Hudon ja D. A. Seminowicz, "The Multimodal Assessment Model of Pain: A Novel Framework for Further Integrating the Subjective Pain Experience Within Research and Practice", *The Clinical journal of pain*, vol. 35, s. 212–221, 2019. DOI: 10.1097/AJP.0000000000000670.
- [3] M. Joynt, M. K. Train, B. W. Robbins, J. S. Halterman, E. Caiola ja R. J. Fortuna, "The Impact of Neighborhood Socioeconomic Status and Race on the Prescribing of Opioids in Emergency Departments Throughout the United States", *Journal of General Internal Medicine*, vol. 28, s. 1604–1610, 2013. DOI: 10.1007/s11606-013-2516-z.
- [4] C. V. Preuss, A. Kalava ja K. C. King, *Prescription of Controlled Substances: Benefits and Risks*. Treasure Island, FL, Yhdysvallat: StatPearls Publishing, 2025. url: <https://www.ncbi.nlm.nih.gov/books/NBK537318/>.
- [5] J. H. Knab, M. S. Wallace, R. L. Wagner, J. Tsoukatos ja M. B. Weinger, "The Use of a Computer-Based Decision Support System Facilitates Primary Care

- Physicians' Management of Chronic Pain", *Anesthesia & Analgesia*, vol. 93, s. 712–720, 2001. DOI: 10.1097/00000539-200109000-00035.
- [6] E. Kalso, M. Haanpää, K. Hamunen, V. Kontinen, A. Vainio, H. Aho ja S. Rusanen, *Kipu*. Helsinki, Suomi: Kustannus Oy Duodecim, 2018.
- [7] S. Soinila ja M. Kaste, *Neurologia*. Helsinki, Suomi: Kustannus Oy Duodecim, 2015. url: <https://www.oppiportti.fi/neu00254>.
- [8] J. Leppäluoto, H. Rintamäki, O. Vakkuri, H. Vierimaa, T. Lauri, E. Müller, S. Lätti ja T. Ripatti, *Anatomia ja fysiologia : rakenteesta toimintaan*. Helsinki, Suomi: Sanoma Pro Oy, 2019.
- [9] E. Kasaeyan Naeini, M. Jiang, E. Syrjälä, M.-D. Calderon, R. Mieronkoski, K. Zheng, N. Dutt, P. Liljeberg, S. Salanterä, A. M. Nelson ja A. M. Rahmani, "Prospective study evaluating a pain assessment tool in a postoperative environment: Protocol for algorithm testing and enhancement", *JMIR Res. Protoc.*, vol. 9, e17783, 2020. DOI: 10.2196/17783.
- [10] A. G. Webb, *Principles of Biomedical Instrumentation*. Cambridge, Iso-Britannia: Cambridge University Press, 2018.
- [11] S. C. Mukhopadhyay ja T. Islam, *Wearable sensors : applications, design and implementation*. Bristol, Iso-Britannia: IOP Publishing, 2017. DOI: 10.1088/978-0-7503-1505-0ch0.
- [12] H. Imai, Y. Kanie, S. Yoshimoto, N. Yamamoto, M. Furuya, T. Fujimori ja S. Okada, "Classification accuracy of pain intensity induced by leg blood flow restriction during walking using machine learning based on electroencephalography", *Scientific Reports*, vol. 15, s. 27955, 2025. DOI: 10.1038/s41598-025-13433-1.

-
- [13] H. H. Plácido da Silva, H. F. Silveira Gamboa, R. P. Sousa Varandas ja G. A. dos Santos Espadanal Ramos, *Biosignal Acquisition and Processing: A Project-Based Learning Approach*. Cham, Sveitsi: Springer International Publishing, 2024. DOI: 10.1007/978-3-031-35187-7.
- [14] A. Greco, G. Valenza ja E. P. Scilingo, *Advances in Electrodermal Activity Processing with Applications for Mental Health : From Heuristic Methods to Convex Optimization*. Cham, Sveitsi: Springer International Publishing, 2016. DOI: 10.1007/978-3-319-46705-4.
- [15] A. Torres-García, C. Garcia, L. Villasenor-Pineda ja O. Mendoza-Montoya, *Biosignal Processing and Classification Using Computational Learning and Intelligence: Principles, Algorithms, and Applications*. Puebla, Meksiko: Academic Press, 2021. DOI: 10.1016/b978-0-12-820125-1.00002-6.
- [16] S. A. H. Aqajari, R. Cao, E. Kasaeyan Naeini, M.-D. Calderon, K. Zheng, N. Dutt, P. Liljeberg, S. Salanterä, A. M. Nelson ja A. M. Rahmani, "Pain assessment tool with electrodermal activity for postoperative patients: Method validation study", *JMIR MHealth and UHealth*, vol. 9, e25258, 2021. DOI: 10.2196/25258.
- [17] Y. Kong, H. F. Posada-Quintero ja K. H. Chon, "Real-Time High-Level Acute Pain Detection Using a Smartphone and a Wrist-Worn Electrodermal Activity Sensor", *Sensors*, vol. 21, s. 3956, 2021. DOI: 10.3390/s21123956.
- [18] A. Subramanian, R. Cao, E. K. Naeini, S. A. H. Aqajari, T. D. Hughes, M.-D. Calderon, K. Zheng, N. Dutt, P. Liljeberg, S. Salanterä, A. M. Nelson ja A. M. Rahmani, "Multimodal pain recognition in postoperative patients: Machine learning approach", *JMIR Formative Research*, vol. 9, e67969, 2025. DOI: 10.2196/67969.

- [19] E. Kasaeyan Naeini, A. Subramanian, M.-D. Calderon, K. Zheng, N. Dutt, P. Liljeberg, S. Salantera, A. M. Nelson ja A. M. Rahmani, "Pain recognition with electrocardiographic features in postoperative patients: Method validation study", *The Journal of Medical Internet Research*, vol. 23, e25079, 2021. DOI: 10.2196/25079.
- [20] W. Zhu ja Y. Lin, "Physiological-based comparison of deep learning models for pain level estimation", teoksessa *2024 IEEE International Conference on Service Operations and Logistics, and Informatics (SOLI)*, Boston, MA, Yhdysvallat: IEEE, 2024, s. 1–6. DOI: 10.1109/SOLI63266.2024.10956064.
- [21] K. Gasmi, O. Hrizi, N. B. Aoun, I. Alrashdi, A. Alqazzaz, O. Hamid, M. O. Altaieb, A. E. M. Abdalrahman, L. B. Ammar, M. Mrabet ja O. Necibi, "Enhanced multimodal physiological signal analysis for pain assessment using optimized ensemble deep learning", *Computer Modeling in Engineering Sciences*, vol. 143, s. 2459–2489, 2025. DOI: 10.32604/cmes.2025.065817.
- [22] H. Tuominen, P. Neittaanmäki, E. Niinimäki, I. Pölönen, I. Rautiainen, S. Äyrämö, T. Ruohonen, R. Nyrhinen, A. Ojalainen, P. Vähäkainu ja S.-M. Äyrämö, *Tekoälyn perusteita ja sovelluksia*. Jyväskylä, Suomi: Jyväskylän yliopisto, 2019. url: <https://urn.fi/URN:ISBN:978-951-39-7796-2>.
- [23] D. Albahdal, W. Aljebreen ja D. M. Ibrahim, "PainMeter: Automatic assessment of pain intensity levels from multiple physiological signals using machine learning", *IEEE Access*, vol. 12, s. 48 349–48 365, 2024. DOI: 10.1109/ACCESS.2024.3384359.
- [24] X. Dong, Z. Yu, W. Cao, Y. Shi ja Q. Ma, "A survey on ensemble learning", *Frontiers of Computer Science*, vol. 14, s. 241–258, 2020. DOI: 10.1007/s11704-019-8208-z.

- [25] R. Cao, S. A. H. Aqajari, E. Kasaeyan Naeini ja A. M. Rahmani, "Objective pain assessment using wrist-based PPG signals: A respiratory rate based method", Mexico, United States: IEEE, 2021, s. 1164–1167. DOI: 10.1109/EMBC46164.2021.9630002.
- [26] S. Walter, S. Gruss, H. Ehleiter, J. Tan, H. C. Traue, S. Crawcour, P. Werner, A. Al-Hamadi ja A. O. Andrade, "The biovid heat pain database data for the advancement and systematic validation of an automated pain recognition system", teoksessa *2013 IEEE International Conference on Cybernetics (CYBCO)*, Lausanne, Sveitsi: IEEE, 2013, s. 128–131.
- [27] F. Pouromran, Y. Lin ja S. Kamarthi, "Personalized deep bi-LSTM RNN based model for pain intensity classification using EDA signal", *Sensors*, vol. 22, s. 8087, 2022. DOI: 10.3390/s22218087.
- [28] A. Dabbagh, *Personalized Medicine in Anesthesia, Pain and Perioperative Medicine*. Cham, Sveitsi: Springer International Publishing, 2021. DOI: 10.1007/978-3-030-53525-4,.
- [29] Y. Xing, K. Yang, A. Lu, K. Mackie ja F. Guo, "Sensors and Devices Guided by Artificial Intelligence for Personalized Pain Medicine", *Cyborg and Bionic Systems*, vol. 5, s. 0160, 2024. DOI: 10.34133/cbsystems.0160.
- [30] S. Wang, Y. He ja Y. Huang, "Global, regional, and national trends and burden of opioid use disorder in individuals aged 15 years and above: 1990 to 2021 and projections to 2040", *Epidemiology and Psychiatric Sciences*, vol. 34, e32, 2025. DOI: 10.1017/S2045796025100085.
- [31] C. S. Nielsen, A. Stubhaug, D. D. Price, O. Vassend, N. Czajkowski ja J. R. Harris, "Individual differences in pain sensitivity: genetic and environmental contributions", *Pain*, vol. 136, s. 21–29, 2008. DOI: 10.1016/j.pain.2007.06.008.

- [32] K. H. Thomas, M. N. Dalili, H.-Y. Cheng, S. Dawson, N. Donnelly, J. P. T. Higgins ja M. Hickman, "Prevalence of problematic pharmaceutical opioid use in patients with chronic non-cancer pain: A systematic review and meta-analysis", *Addiction*, vol. 119, s. 1904–1922, 2024. DOI: 10.1111/add.16616.
- [33] P. Nickerson, P. Tighe, B. Shickel ja P. Rashidi, "Deep neural network architectures for forecasting analgesic response", teoksessa *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Orlando, FL, Yhdysvallat: IEEE, 2016, s. 2966–2969. DOI: 10.1109/EMBC.2016.7591352.
- [34] A. Leroux, R. Rzasa-Lynn, C. Crainiceanu ja T. Sharma, "Wearable Devices: Current Status and Opportunities in Pain Assessment and Management", *Digital Biomarkers*, vol. 5, s. 89–102, 2021. DOI: 10.1159/000515576.
- [35] C. Berget, L. H. Messer ja G. P. Forlenza, "A Clinical Overview of Insulin Pump Therapy for the Management of Diabetes: Past, Present, and Future of Intensive Therapy", *Diabetes Spectrum : A Publication of the American Diabetes Association*, vol. 32, s. 194–204, 2019. DOI: 10.2337/ds18-0091.
- [36] G. K. Jena, C. N. Patra, S. Jammula, R. Rana ja S. Chand, "Artificial Intelligence and Machine Learning Implemented Drug Delivery Systems: A Paradigm Shift in the Pharmaceutical Industry", *Journal of Bio-X Research*, vol. 7, s. 1–15, 2024. DOI: 10.34133/jbioxresearch.0016.
- [37] D. Khullar, L. P. Casalino, Y. Qian, Y. Lu, H. M. Krumholz ja S. Aneja, "Perspectives of patients about artificial intelligence in health care", *JAMA Network Open*, vol. 5, e2210309, 2022. DOI: 10.1001/jamanetworkopen.2022.10309.
- [38] S. Reddy, "Global harmonization of artificial intelligence-enabled software as a medical device regulation: Addressing challenges and unifying standards",

Mayo Clinic Proceedings: Digital Health, vol. 3, s. 100–191, 2025. DOI: 10 .
1016/j.mcpdig.2024.100191.