

Kannettavien EEG-laitteiden käyttö masennuksen diagnosoinnissa

TURUN YLIOPISTO
Tietotekniikan laitos
TkK-tutkielma
Lääketieteellinen tekniikka ja terveysteknologia
Huhtikuu 2026
Juho Yläjärvi

TURUN YLIOPISTO
Tietotekniikan laitos

JUHO YLÄJÄRVI: Kannettavien EEG-laitteiden käyttö masennuksen diagnosoinnissa

TkK-tutkielma, 23 s.

Lääketieteellinen tekniikka ja terveysteknologia
Huhtikuu 2026

Masennus on yksi yleisimmistä mielenterveyden sairauksia maailmassa. Sen objektii-
viseen arviointiin ei ole onnistuttu löytämään sopivaa menetelmää, mutta EEG voi
olla sopiva menetelmä tähän. Kannettavien EEG-laitteiden etuna on mahdollisuus
suorittaa mittauksia esimerkiksi kotona.

Tämän kirjallisuuskatsauksen tarkoituksena on tarkastella kannettavien EEG-
laitteiden mahdollista käyttöä masennuksen diagnosoinnissa. Lisäksi tutkielmassa
tarkastellaan masennuksen EEG-biomarkkereita sekä kannettavien laitteiden käy-
tön haasteita ja tulevaisuuden näkymiä. Tutkielmassa havaittiin lukuisen eri mene-
telmien saavuttavan yli 90 %:n tarkkuuden, ja erityisesti koneoppimista hyödyntävät
analyysimenetelmät olivat hyvin tarkkoja. Tulevaisuudessa kannettavien laitteiden
tutkimus tulisi keskittyä mittaustarkkuuden parantamiseen, suurempiin tutkimus-
ryhmiin sekä laitteistopuolen parannuksiin.

Asiasanat: elektroenkefalografia, kannettava, masennus, diagnosointi, biomarkkerit,
koneoppiminen

Sisällys

1	Johdanto	1
2	Masennus	3
3	Elektroenkefalografia	5
3.1	Elektrodit	5
3.2	EEG-signaalin käsittely, tulkinta ja analyysi	7
3.3	Kannettava EEG	9
4	Masennuksen diagnosointi kannettavalla EEG:llä	11
4.1	Masennuksen biomarkkerit	11
4.2	Diagnosointi kannettavilla laitteilla	13
4.2.1	Menetelmät	13
4.2.2	Menetelmien vertailu	15
5	Pohdintaa kannettavista laitteista	18
5.1	Haasteet	18
5.2	Tulevaisuus	19
5.3	Pohdinta	20
6	Yhteenveto	22
	Lähdeluettelo	24

1 Johdanto

Nykypäivän yksi yleisimmistä mielenterveyden sairauksista on masennus. Arvioiden mukaan joka kuudes ihminen sairastaa masennusta jossain vaiheessa elämää ja masennuksen arvioidaan olevan yleisin mielenterveyden sairaus vuoteen 2030 mennessä. [1] Masennuksen diagnosointiin on yleisesti käytetty erilaisia potilaskyselyitä ja lääkäreiden arviointeja, mutta objektiivisia tapoja mitata masennusta ei juurikaan ole. Elektroenkefalografiaa (engl. electroencephalography, EEG) on tutkittu mahdollisena tapana masennuksen objektiiviseen arviointiin, mutta perinteiset EEG-mittaukset ovat sidottuja sairaalaolosuhteisiin ja tiettyyn aikaan tehden niistä hankalia. Näiden sijaan viime vuosina on alettu tutkia mahdollisuutta kannettavien EEG-laitteiden käyttöä diagnostiikassa, erityisesti mielenterveyden sairauksen diagnosoinnissa. [2]

Tässä kirjallisuuskatsauksessa tutkitaan kannettavien EEG-laitteiden mahdollista käyttöä masennuksen diagnosoinnissa. Tutkimuksessa tutustutaan masennuksen biomarkkereihin, kannettaviin EEG-laitteisiin ja niissä käytettäviin signaalien analysointimenetelmiin. Lisäksi esitetään kannettavien laitteiden nykyisiä haasteita ja tulevaisuuden tutkimuskohteita. Näitä asioita varten muodostettiin seuraavat tutkimuskysymykset:

- **TK1:** Millaisia EEG-biomarkkereita masennuksessa voidaan havaita?
- **TK2:** Kuinka tarkkoja kannettavat EEG:t ovat masennuksen diagnosoinnissa?

- **TK3:** Millaisia haasteita kannettavilla EEG-laitteilla on ja mihin tulevaisuuden tutkimusten tulisi keskittyä?

Tutkimuksen tiedonhaku toteutettiin PubMed-tietokannalla. Tiedonhaussa käytettiin useita hakusanoja, kuten "*depress**", "*major depressive disorder*", "*MDD*", "*EEG*", "*electroencephalography*", "*portable*", "*wireless*", "*mobile*", "*diagno**", "*detect**" ja "*challenges*". Näitä yhdistelemällä muodostettiin eri hakulausekkeita. Hakutuloksista suodatettiin otsikon ja abstraktin perusteella aiheeseen soveltumattomat tutkimukset pois. Kirjallisuuskatsauksessa pyrittiin käyttämään tutkimuksia viimeisen 10 vuoden ajalta. Hakulauseiden lisäksi lähdemateriaaleja valittiin käytettyjen tutkimusten viittauksista sekä PubMedin samankaltaisista artikkeleista. Verkkosivujen osalta tietoa otettiin tunnetuista ja luotetuista lähteistä.

Tutkielman luku 2 käsittelee masennusta ja sen diagnosointia ja eri hoitomuotoja. Luvussa 3 käsitellään elektroenkefalografia tarkemmin, sen toimintaperiaatteita, elektrodeja sekä eri signaalin analysointimenetelmiä. Luvun 3 lopussa puhutaan myös kannettavista EEG-laitteista. Luvussa 4 käsitellään masennuksen EEG-biomarkkereita sekä menetelmiä masennuksen diagnosointia kannettavilla EEG-laitteilla. Menetelmien lisäksi luvussa verrataan menetelmistä saatuja tuloksia. Luvussa 5 käsitellään kannettavien laitteiden nykyisistä haasteista, tulevaisuuden tutkimussuunnista sekä omaa pohdintaa kannettavista laitteista yleisesti. Luku 6 on yhteenveto, jossa käydään läpi tutkielma ja vastataan tutkimuskysymyksiin.

2 Masennus

Masennus on yksi nykypäivän yleisimmistä mielenterveyteen vaikuttavista sairauksista. Maailman terveysjärjestön WHO:n (World Health Organization) arvion mukaan masennusta sairastaa noin 5,7 % aikuisväestöstä maailmanlaajuisesti. Vaikka masennusta on tutkittu paljon, jopa kolmannes masentuneista jää ilman diagnoosia tai hoitoa. [3]

Sairautena masennus määritellään yleensä pitkään jatkuneena alentuneena mielialana, voimattomuuden ja arvottomuuden tunteena sekä mahdollisesti itsetuhoisina ajatuksina. Masennukseen voi kuulua myös fysiologisia oireita, kuten painon ja ruokahalun muutoksia, unen tarpeen muutoksia sekä vaikeuksia ajatella tai suorittaa päivittäisiä askareita. [1], [3] Masennus on neurofysiologinen sairaus, joka muuttaa normaalia aivotoimintaa. Monet masennuksen oireista johtuvat muutoksissa aivojen sähköisessä toiminnassa. [2] Masennus voidaan jakaa vaikeusasteen perusteella lievään, keskivaikeaan, vaikeaan ja psykoottiseen masennukseen. Vaikeimmissa masennuksissa henkilön työkyky ja jokapäiväinen elämä ovat uhattuina, ja nämä masennustilat saattavatkin vaatia sairaalahoitoa. Psykoottisessa masennuksessa esiintyy myös aistiharhoja. [4]

Masennusdiagnoosin tekevät terveydenhuollon ammattilaiset. Potilas voi hakeutua hoitoon esimerkiksi kouluterveydenhuollon tai sairaanhoitajan kautta, minkä jälkeen hänet ohjataan psykiatrin tai psykologin arvioitavaksi. [4] Masennuksen diagnosointi on erilaista joka maassa, mutta siihen voi liittyä laboratoriotutkimuksia,

erilaisia potilaskyselyitä sekä lääkärin arviointeja. Esimerkkeinä potilaskyselyistä lyhyt masennuskysely (engl. Patient Health Questionnaire-9, PHQ-9), laajempi Beckin depressiokysely (BDI) sekä Yhdysvalloissa kehitetty HAMD-kysely (engl. Hamilton Rating Scale for Depression) ovat paljon käytettyjä masennuksen vakavuutta arvioivia potilaskyselyitä. [1]

Masennuksen hoito koostuu usein sekä psykoterapiasta että lääkehoidosta. Psykoterapia on ensisijainen hoitomuoto ja sen avulla potilas oppii elämään sairautensa kanssa sekä saa puhua tunteistaan ammattilaiselle. [3] Tyypillisimmät masennuslääkkeet ovat serotoniinin takaisinottoon vaikuttavat lääkkeet (SSRI ja SNRI), trisykliset masennuslääkkeet ja monoamino-oksidaasin estäjät (MAO-estäjät). Masennuslääkkeet ovat pitkäaikainen hoitomuoto ja saattavat aiheuttaa pahojakin sivuvaikutuksia. Vakavan masennuksen hoitoon on myös käytetty aivojen sähköhoitoa (engl. electroconvulsive therapy, ECT), magneettistimulaatiota (engl. transcranial magnetic stimulation, TMS) ja aivojen syvien osien stimulointia (engl. deep brain stimulation, DBS). [1], [4] Viime vuosina tutkimuksissa on pyritty löytämään erilaisia neurokuvantamisen biomarkkereita auttamaan täsmälääketieteen ja lääkkeiden hoitovasteen tutkimisessä. [5] Biomarkkereista puhutaan lisää luvussa 4.

3 Elektroenkefalografia

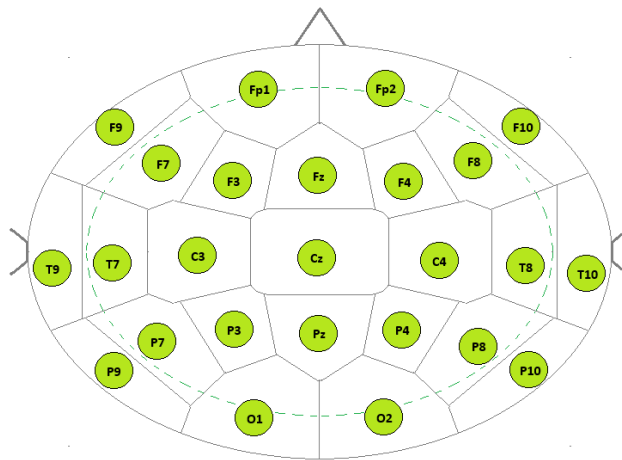
Elektroenkefalografia (engl. electroencephalography, EEG) eli aivosähkökäyrä on non-invasiivinen aivojen sähköisen toiminnan mittaamisen kehitetty menetelmä. EEG:tä on terveydenhuollossa käytetty kliinisessä diagnostiikassa etenkin epilepsian, dementian ja enkefalopatian diagnosoinnissa. Viime vuosina sille on löytynyt myös tutkimuskohteita aivokäyttöliittymissä ja kliinisessä neurofysiologiassa. [6]

EEG:n toimintaperiaate perustuu hermosolujen eli neuronien sähköisen toiminnan mittaamiseen päänahasta. Mittaustulokset saadaan hermosolujen postsynaptisista potentiaaleista. Postsynaptisia potentiaaleja esiintyy, kun aktiopotentialin saanut hermosolu päästää välittäjäaineita neuronin ja kohdesolun väliseen synapsiin. Nämä välittäjäaineet liittyvät reseptoreihin ja aikaansaavat sähköimpulssin kohdesolussa. Tätä kohdesolun sähköimpulssia kutsutaan postsynaptiseksi potentiaaliksi. Yksinään postsynaptiset potentiaalit ovat hyvin pieniä, mutta suuremmissa määrin ne voivat aikaansaada aktiopotentialin kohdesolussa. [7]

3.1 Elektrodit

EEG mittaa postsynaptisia potentiaaleja potilaan päänahkaan asetettavien elektrodien avulla. Tyypillisesti elektrodit ovat olleet geelipintaisia elektrodeja, jotka parantavat päänahan ja elektrodien välisiä kontakteja. Viimeaikaisissa tutkimuksissa on kuitenkin kehitelty kuivaelektrodeja, jotka olisivat pitkäaikaisissa mittauksissa parempia ja potilaille mukavempia käyttää. [8]

Elektrodit voidaan asettaa potilaan päänahkaan useilla eri tavoilla riippuen laitteesta, elektrodien määrästä sekä haluttavista tuloksista. Tyypillisesti elektrodit asetetaan standardisoidusti noudattaen Kansainvälisen Kliinisen Neurofysiologian Liiton (engl. International Federation of Clinical Neurophysiology, IFCN) ohjeistusta, siten että ne muodostavat tiiviin elektrodimontaasin [9]. Elektrodeja voi olla laitteesta riippuen yhdestä jopa 256:een. Elektrodit sijoitetaan pään anatomian mukaisesti eri alueille, kuten otsalle (frontaalinen, F), ohimoille (temporaalinen, T), päälle (parietaalinen, P) ja takaraivoon (okkipitaalinen, O). Tyypillinen asetelma on 10–10 tai 10–20, missä numerot viittavat elektrodien etäisyyksiin toisistaan. [10] Kuvassa 3.2 on esitetty IFCN:n suosittama 10–10-asetelmasta muokattu 25:n elektrodin montaasi, joka kattaa aiemmista standardeista poiketen myös inferiorisen ja anterioriset osat aivojen ohimolohkosta.



Kuva 3.1: IFCN:n standardoitu 25-kanavainen elektrodimontaasi. Kuva muokattu lähteestä [10].

Elektrodien käytön etuna on mahdollisuus hyödyntää usean eri fysiologisen toiminnan mittaamista samaan aikaan. EEG-tallenteisiin voidaan esimerkiksi lisätä muita elektrodeja mittaamaan eri kehontoimintoja: elektrokardiografielektrodi sydäntoimintaan, elektromyografialektrodi lihastoimintaan sekä hengitystiheyttä mittaavia elektrodeja. [9] Näitä voidaan sekä hyödyntää EEG-signaalissa poistamaan

kyseisten kyseisten fysiologisten toimintojen aiheuttamat melut raakadatasta sekä potilaan tilan mittaamiseen. Laitteet, jotka hyödyntävät useampia eri elektrodeja vaativat paljon komponentteja sekä monimutkaisia ohjelmistoja signaalien erottamiseksi ja analysoimiseksi. [10]

3.2 EEG-signaalin käsittely, tulkinta ja analyysi

Jotta EEG:tä voidaan käyttää terveydenhuollossa, tulee siitä saatava data käsitellä luettavaan muotoon. Koska postsynaptiset potentiaalit ovat hyvin pieniä, usein mikrovoltin tasoa, tulee raaka-dataan myös kohinaa muista sähköisistä lähteistä, kuten sydäimestä, lihaksista ja silmistä. Jotta EEG-dataa voidaan hyödyntää uskottavasti, tulee signaalia vahvistaa sekä ylimääräinen kohina suodattaa pois. Elektrodien signaalit kulkevat vahvistimen läpi, joka vahvistaa signaalia, suodattaa laskostumisen sekä muuntaa analogisen signaalin digitaalseksi. Tämän jälkeen digitaalista signaalia voidaan suodattaa lisää erilaisten suodattimien avulla, tyypillisesti ali- ja ylipäästösuodattimilla (engl. low-pass ja high-pass filters). [9]

Signaalin käsittelyn jälkeen siitä muodostetaan siniaaltomuotoinen kuvaaja ajakäynnitekoordinaatistossa. Kuvaajalla voidaan esittää joko kaikki tai tietyt, halutut elektrodikanavat. [11] Elektrodikanavista voidaan erottaa eri aivoaaltoja, joilla on omat sijainnit ja fyysiset ominaisuudet. Aivoaallot voidaan jakaa taajuuden perusteella delta-aaltoihin (n. 0,5-4 Hz), theeta-aaltoihin (n. 4-7,5 Hz), alfa-aaltoihin (n. 8-12 Hz), beeta-aaltoihin (n. 13-30 Hz) ja gamma-aaltoihin (n. 30-90 Hz). Näitä aivoaaltoja voidaan käyttää aivotointojen tarkasteluun. [8], [12]

Delta- ja theeta-aaltoja voidaan tyypillisesti havaita unen aikana. Niiden taajuuDET on pieniä, mutta amplitudit suuria. Näissä aivoaalloissa voidaan havaita myös muunnelma-aaltoja, kuten Wicket-aaltoja ja erilaisia piikkiaaltoja. Alfa-, beeta- ja gamma-aallot ovat tyypillisimmät hereillä havaittavat aallot. Alfa-aallot ovat aikuisen ihmisen perusaivotointia. Beeta-aaltoja havaitaan niin hereillä ollessa kuin

levossa. Niillä on tyypillisesti hereillä matala amplitudi, joka kasvaa rentoutuessa tai unessa. Gamma-aalloilla on suurin havaittu taajuusalue ja ne on liitetty tajuntaan ja aistimiseen. [12]

EEG:n käyttö diagnostiikassa perustuu kuvaajien tunnusmerkkien analysoimiseen. Erilaisia EEG-signaalin analysointitapoja ovat esimerkiksi taajuusanalyysi (engl. power spectrum analysis), aika-taajuusanalyysi (engl. time-frequency analysis) ja liitettävyyshanalyysi (engl. connectivity analysis). Myös koneoppimisella on enenevässä määrin käyttökohteita EEG-signaalin analysoinnissa. [11]


Taajuusanalyysia on paljon käytetty signaalinkäsittelyssä, joka perustuu taajuuskomponenttien energian muutoksiin. Käytetyimpiä taajuusanalyysialgoritmeja ovat Fourier-muunnos sekä Welch-metodi. Aika-taajuusanalyysi on taajuusanalyysiä kehittyneempi analysointitapa, missä hyödynnetään EEG:n aika-akselia. Wavelet-muunnos on näistä yksi käytetyimmistä tarkkuuden ja esitettävyyden takia. Liitettävyyshanalyysillä verrataan kahden tai useamman signaalin eroja. Tätä voidaan käyttää esimerkiksi aivojen kahden eri alueen funktionaalisten erojen havaitsemiseen. Koherenssianalyysit sekä vaiheisiin perustuvat analyysit ovat suosituimpia algoritmeja. [2], [11]

Koneoppimista on myös tutkittu EEG-datan analysoinnissa. Esimerkiksi konvoluutioverkot, syväoppiminen ja tukivektorikone ovat paljon käytettyjä koneoppimisalgoritmeja. Tähän mennessä koneoppimisella on saatu lupaavia tuloksia mielenterveysongelmien, Parkinsonin taudin ja kohtausoireiden diagnosoinnissa. [2] Tukivektorikoneilla on pystytty havaitsemaan masennukselle tyypillisiä EEG-biomarkkereita jopa 90 % tarkkuudella [13]. Koneoppimista on käytetty myös EEG-signaalin käsittelyyn ennen analysointia poistamaan artefakteja ja jakamaan signaalia eri osiin [14].

3.3 Kannettava EEG

Tyypillisesti EEG-mittauksia on suoritettu sairaalaolosuhteissa, sillä siihen tarvittavat laitteet ovat suuria ja niiden käyttö vaatii ammattiosaamista. Kuluneen vuosikymmenen aikana on kuitenkin otettu merkittäviä edistysaskeleita kannettavien EEG-laitteiden suunnittelussa. Nämä mahdollistavat EEG-mittaukset jopa kotiolo-suhteissa. [15]

Kannettavassa EEG:issä elektrodit on aseteltu jonkinlaiseen päähineeseen. Myös korviin asetettavia, kuulokkeiden tapaisia elektrodeja on kehitetty [2]. Päähinelaitteissa käytetyt elektrodit ovat nykyään kuivaelektrodeja, sillä ne mahdollistavat elektrodien käytön useampaan kertaan sekä vähentävät mittauksiin tarvittavaa valmistelu-aikaa. Elektrodit ovat laitekohtaisia ja jotkut laitteet käyttävät märkäelektrodeja. Myös elektrodien määrä vaihtelee muutamista jopa 64:ään. [15] Kuvassa 3.2 on esitetty neljä erilaista kaupallisen EEG-laitteen päähinettä.



Kuva 3.2: Esimerkkejä kaupallisten kannettavien EEG-laitteiden päähineistä. a) EMOTIV EPOC X-14 b) B-Alert X24 c) Enobio 8 d) NeuroNetrix The COGNITION System

Kannettavssa EEG:ssä signaalin käsittely on tärkeässä asemassa heikomman signaalin laadun takia. Aika-taajuusanalyysiä sekä liitettävyyssanalyysiä on käytetty kannettavan EEG-signaalin analysoinnissa. Eräs spatiaalinen suodatustapa nimeltään riippumattomien komponenttien analyysi (engl. independent component analysis, ICA). Sen on havaittu kuitenkin toimivan kannettavan EEG-laitteen signaalin käsittelyyn paremmin. ICA kykenee sekä korjaamaan signaalia että analysoimaan sitä. [15] Kannettavissa EEG-laitteissa tulee myös huomioida mahdollinen tarve datan tallennukselle sekä Wi-File, mikäli datan analysointi suoritetaan esimerkiksi pilvipalvelimella. [2]

4 Masennuksen diagnosointi kannettavalla EEG:llä

Kannettavien laitteilla diagnosoidessa on tärkeä, että saatu data on mahdollisimman puhdasta, jotta sitä voidaan analysoida. Kannettavissa laitteissa käytetyt analysointimenetelmät kuitenkin kehittyvät nopeasti ja uusia biomarkkereita masennukselle löydetään jatkuvasti. Tässä luvussa esitellään erilaisia masennuksen EEG-piirteitä sekä mittaustuloksia eri tutkimuksista.

4.1 Masennuksen biomarkkerit

Masennuksen objektiivinen diagnosointi sekä masennuksen hoidon lääkeväste ovat viimeisen vuosikymmenen aikana askarruttaneet tutkijoita. Useita eri kuvantamismenetelmiä on esitetty masennuksen biomarkkereiden löytämiseksi. Potentiaalisimmat näistä laitteista ovat funktionaalinen magneettiresonanssikuvantaminen, positroniemissiotomografia ja elektroenkefalografia. Näistä eniten tutkittu on EEG, jonka avulla on pystytty löytämään useita masennukselle tyypillisiä merkkejä aivojen sähköisessä toiminnassa.

Tyypillisimmät EEG-biomarkkerit pohjautuvat aivoaaltojen erilaisiin analysointitapoihin. Eri taajuusanalyysimenetelmillä on havaittu etenkin aivojen otsalohkon sähköisen toiminnan olevan liitoksissa masennukseen. Alfa-aaltojen aktiivisuuden laskua on esitetty selvänä merkinä masennuksesta. Alfa-aaltojen aktiivisuuden las-

ku ilmenee usein toispuoleisena vasemmassa otsalohkossa. Tätä ilmiötä kutsutaan otsalohkon alfaepäsymmetriaksi (engl. frontal alpha asymmetry, FAA). FAA:ta pidetään tällä hetkellä lupaavimpana biomarkkerina masennuksen diagnosointiin ja lääkevasteen mittaamiseen. [2], [16], [17] Myös beeta-aaltojen aktiivisuuden kasvua sekä theeta- ja delta-aaltojen aktiivisuuden muutoksia on tutkittu masennuksen diagnosointiin. Etenkin beeta-aaltojen aktiivisuuden kasvu on yhdistetty ahdistukseen ja masennukseen. [2], [16] Muutoksia gamma-aaltojen aktiivisuudessa on myös tutkittu masennuksen diagnosoimisessa, ja siitä on saatu kaksipuolisia tuloksia. Osassa tutkimuksissa on todettu gamma-aaltojen aktiivisuuden kasvun olevan tyypillinen merkki masennuksesta ja ahdistuksesta. [18], [19], [20] Kopanska ym. tutkimukseensa (2025) kuitenkin mainitsivat gamma-aaltojen aktiivisuuden laskun liittyvän masennukseen, mikä on ristiriidassa muiden tutkimuksien kanssa [16].

Tutkittaessa aivojen tapahtumasidonnaisia herätepotentiaaleja (engl. event-related potential, ERP) masennuspotilailla, voidaan havaita alentuneita ns. P300-aaltojen amplitudeja. P300-aaltojen amplitudeja pidetäänkin FAA:n ja beeta-aaltojen kanssa tärkeimpinä masennuksen biomarkkerina. [2], [16] Näiden lisäksi masennuspotilailla on havaittu alentumia palkitsemispositiivisuudessa ja reaktiot positiivisiin asioihin ovat merkittävästi vähentyneet aiheuttaen motivaatiopuutteita. [5], [17] Aika-taajuusanalyysillä voidaan havaita muutoksia eri aivoaaltojen aktiivisuuden välisistä suhteista. Wavelet-muunnoksilla voidaan erottaa taajuusanalyysissäkin havaitut alfa-aaltojen aktiivisuuden lasku ja beeta-aaltojen aktiivisuuden kasvu, mutta näiden lisäksi voidaan havaita muutoksia alfa/beeta aktiivisuuden sekä delta/theeta aktiivisuuden suhteissa. [2], [16], [18]

Liitettävyyksanalyysillä on kyetty havaitsemaan muutoksia aivojen etualueiden yhtenäisyydessä. Erityisesti otsa- ja ohimolohkoissa on erotettu alentuneita yhteneväisyyksiä aivopuoliskojen välisessä kommunikaatiossa masennuspotilailla. Tämä viittaa tunnetason häiriöihin aivoissa, mikä on yksi masennuksen oireista. [2], [18]

Epälineaarilla analyysillä pystytään havaitsemaan masennuksen tekijöitä, joita ei voi suoraan mitata. Näitä epälineaarisia mittauksia kutsutaan signaalin kompleksisuudeksi (engl. complexity) ja niiden avulla voidaan tarkastella aivojen reaktioita ärsykkeisiin tai toimintoihin. Kompleksisuuden mittaamisessa käytetään EEG-signaalin eri ulottuvuuksia tai tutkimalla signaalin entropiaa. [19] Yleisesti on havaittu, että masentuneiden ihmisten EEG-signaaleissa on matalampi kompleksisuus verrattuna terveisiin ihmisiin. Esimerkkeinä kompleksisuusanalyyseistä on spektraali- ja näyte-entropia (engl. spectral and sample entropy), Lempel-Zivin kompleksisuus (engl. Lempel-Ziv Complexity, LZC) ja Katzin fraktaalilottuvuus (Katz fractal dimension, KFD). [18], [20] Kompleksisuutta on kuitenkin vaikea tulkita, ja esimerkiksi Akar ym. tutkimuksessaan (2015) [19] esittää masennuspotilailla olevan tavallista korkeammat LZC- ja KFD-arvot otsa- ja ohimolohkoissa verrattuna terveeseen kontrolliryhmään. Tämä johtuu siitä, että kompleksisuus ei ole vain yksi tulkittava suure, vaan joukko useita eri suureita eri mittauspaikoista.

4.2 Diagnosointi kannettavilla laitteilla

Masennuksen diagnosointi kannettavilla laitteilla on vielä varhaisessa vaiheessa, mutta eri tutkimuksissa on saatu lupaavia tuloksia.

4.2.1 Menetelmät

Kawamura ym. esittivät vuoden 2025 tutkimuksessaan [21] tavan masennuksen arviointiin käyttäen kannettavaa, yksikanavaista EEG-laitetta unenaikaisessa mittauksessa. Tutkimuksessa tarkasteltiin erityisesti alfa- ja delta-aaltoja, joiden arvoja verrattiin masentuneen testiryhmän ja terveen vertailuryhmän kesken. Tutkimustuloksissa havaittiin alfa-aaltojen aktiivisuuden olevan selvästi alhaisempi masentuneilla potilailla kuin terveellä kohderyhmällä. Lisäksi havaittiin, että REM-unen ja REM-

unen ulkopuolisen unen suhde on tärkeämpi masennusta tutkittaessa kuin kumpikaan erikseen tarkasteltuna. Tuloksissa arvioidaan alfa-aaltojen olevan hyvä biomarkkeri masennuksen diagnosoinnissa, mutta vaatii lisätutkimuksia.

Wu ym. tutkivat vuonna 2022 [22] masennuksen diagnosointia käyttäen domeenin sopeuttamista (engl. domain adaptation). He käyttivät tutkimuksessaan datasarjaa, jonka on luonut ulkopuolinen laboratorio ja se on kerätty kannettavalla kolmikanaavaisella EEG-laitteella. Datasarja muunnettiin kahdella eri menetelmällä kuvamuotoon. Nämä menetelmät olivat perinteinen aika-taajuuskoordinaatisto sekä RGB-synteesi. Muunnettua dataa käytettiin opettamaan ja testaamaan konvoluutioverkopohjaisia domeenin sopeuttamismenetelmiä. Tutkimuksessa testattiin kolmea eri domeenin sopeuttamismallia kahdella eri datajaolla, ja tuloksissa parhaaksi mitausarvoksi saatiin 77 %:n tarkkuus käytettäessä 7:1 jakoa ja RGB-synteesiä. Kolmesta mallista testatusta domeenin sopeuttamismallista parhaan tarkkuuden saavutti AlexNet-pohjainen DAN (engl. domain adversarial network). Tutkimus esittääkin domeenin sopeuttamisen käyttämistä EEG-diagnostiikassa toimivana menetelmänä.

Vuonna 2022 B. Zhang ym. [23] tutkivat masennuksen kokonaisvaltaista tunnistamista käyttäen piirretasoista yhdistämistä (engl. feature-level fusion) aikavaruudessa. Tutkimuksessa data kerättiin kannettavalla kolmikanaavaisella EEG-laitteella, joka muokattiin ja niistä muodostettiin visuaalinen kuvaaja. Kuvaajista valittiin erilaisia piirteitä, joita hyödynnettiin sellaisenaan, yhdistelemällä piirretasoja keskenään sekä laskemalla apukertoimia masennustarkkuuden määrittämisessä. Lisäksi lukuisia eri algoritmejä käytettiin, mutta lopulta parhaan tarkkuuden antoi kolmesta päätöspuusta muodostettu algoritmi, joka käytti piirretasoja yhdistävää mallia ja apukertoimia. Tällä menetelmällä Zhangin ryhmä sai 92,96 % tarkkuuden masennuksen diagnosointiin. Tutkimus osoittaaakin potentiaalia EEG-diagnostiikkaan yleisesti.

X. Zhang ym. vuonna 2019 [24] tutkivat masennuksen havaitsemista käyttäen kannettavalla, kolmikanavaisella EEG-laitteella mitattua dataa sekä puheentunnistusjärjestelmää. EEG-datasta eristettiin eri aivoaaltojen aktiivisuudet sekä epälineaarisia ominaisuuksia, kuten Renyin entropia ja korrelaatioulottuvuus. Puheentunnistuksella erotetaan prosodinisia ominaisuuksia, kuten lausuntaa, pysähdyksiä ja äänen värinää. Nämä yhdistettiin moniagenttiseksi strategiaksi, joka kykenee analysoimaan jokaisen yksittäisen ominaisuuden ja yhdistämään sen muiden ominaisuuksien kanssa. Tällä strategialla tutkijat saavuttivat 76,41 % tarkkuuden masennuksen havaitsemiseen, ja se kykenee erottamaan tarkkuuden masennuksen diagnosoimiselle eri sukupuolille. Tutkimus osoittaa moniagenttisen strategian olevan myös mahdollinen masennuksen havaitsemiseksi kannettavilla laitteilla.

4.2.2 Menetelmien vertailu

Menetelmät kannettavilla laitteilla vaihtelevat hyvin paljon, mutta suurin osa hyödyntää eri koneoppimisalgoritmeja. Esimerkiksi konvoluutioverkkoja, päätöspuita ja k-lähimpiä naapureita käytetään paljon masennuksen EEG-piirteiden analysoinnissa. Edellisessä luvussa esiteltiin muutama eri tapa masennuksen havaitsemiseen kannettavilla EEG-laitteilla. Lisäksi taulukossa 4.1 esitetään tuloksia eri tutkimuksissa käytetyissä menetelmistä masennuksen diagnosointiin.

Luvussa 4.2.1 esitettyjen menetelmien ja edellisen taulukon tuloksia vertaamalla voidaan huomata koneoppimismenetelmien olevan hyvinkin tarkkoja masennuksen havaitsemisessa. Lähes kaikki koneoppimista käyttävät tutkimukset saivat luokitte-lutarkkuudeksi yli 90 %:a ja korkeita spesifisyyksiä. Parhaita tuloksia saavutettiin yhdistämällä kaksi tai useampaa koneoppimismallia, kuten Sharman ym. tutkimuksessaan [28] käyttämä konvoluutioverkon, lyhyen ajan Fourier-muunnoksen ja pitkäkestoisen lyhytkestomuistin kokonaisuus.

Taulukko 4.1: Tutkimusten tuloksia sekä niissä käytettyjä menetelmiä

Piirteet	Menetelmät	Tarkkuus	Lähdeviite
SAI, APV, RGP, HFD, DFA, LZC	Logistinen regressioanalyysi	Tarkkuus jopa 92 %	[20]
Mean-PSD, Max-PSD, Min-PSD, FAA, LZC, SampEn	k-NN, SVM, NB, DT, RF, Xgboost	90,70 % tarkkuus ja 96,53 % spesifisyys	[25]
HA, HM, HC, Kurt, Skewness, Entropia	k-NN, SVM	98,43 % tarkkuus ja 97,6 % spesifisyys	[26]
18 lineaarista ja epälineaarista EEG-piirrettä	DE + k-NN	Tarkkuus noin 96 %	[27]
Aika-taajuus piirteet	CNN + LSTM + STFT	99,9 % tarkkuus ja 99,8 % spesifisyys	[28]

Tutkimuksissa saatuja arvoja tulee kuitenkin tarkastella kriittisesti. Käytetyt testiryhmät olivat yleisesti pieniä, noin parikymmentä osallistujaa, joka saattaa kasvattaa testituloksia. Kaikissa tutkimuksissa testihenkilöt olivat määritelty ammattilaisten toimesta joko terveiksi tai masentuneiksi, joten niiden vaikutukset eivät pitäisi vaikuttaa suuresti tuloksiin. Merkittävin asia, mikä tuloksiin kuitenkin voi vaikuttaa on käytettiinkö tutkimusten testiaineistona koulutusaineiston osajoukkoa. Suurin osa tutkimuksista kertoo, että testiaineisto ja koulutusaineistot eivät ole samoja, vaan ne ovat eroteltu toisistaan. Kuitenkin pienissä tutkimusryhmissä tämä voi silti vaikuttaa tarkkuuteen, sillä pienet testiaineistot paisuttavat tarkkuutta suuremmaksi, mitä se todellisuudessa olisi. Kuitenkin saadut tulokset antavat viitteitä oikeaan suuntaan siitä, miten kyseinen menetelmä toimii masennuksen arvioinnissa.

Käytetyt menetelmät poikkesivat siinä, mitä EEG-piirteitä pyrittiin analysimaan. Useat tutkimukset hyödynsivät epälineaarisia piirteitä ja kompleksisia piirteitä. Esimerkiksi Lempel-Zivin kompleksisuutta ja signaalien entropiaa analysoitiin tutkimuksissa paljon. Lineaarisista piirteistä eniten käytettiin aika-taajuusdomeenin piirteitä.

Tutkimukset, joissa yhdistettiin EEG-mittausta ja muuta mittaustapaa, eivät antaneet yhtä suuria tarkkuuksia masennuksen diagnosointiin verrattuna pelkkiin EEG-laitteilla suoritettuihin mittauksiin. X. Zhangin ym. tutkimuksessa [24] hyödynnettiin puheentunnistusta EEG-mittauksen lisäksi, mutta tarkkuudeksi saatiin reilu 76 %. Tutkimus on hyvä lähtökohta moniagenttiselle ajattelulle masennuksen diagnosointiin. Tarkkuutta voitaisiin parantaa hyödyntämällä koneoppimista esimerkiksi piirteiden valinnassa.

5 Pohdintaa kannettavista laitteista

EEG-laitteiden käyttö on kasvanut viime vuosina. Niiden tulevaisuus näyttää kirkkaalta, ja niille löytyy erilaisia käyttökohteita useilta lääketieteen aloilta. Niiden käytössä on kuitenkin edelleen haasteita. Tässä luvussa käsitellään EEG-laitteiden yleisiä haasteita sekä niiden tulevaisuuden näkymiä.

5.1 Haasteet

Koska kannettavat EEG-laitteet ovat vielä verrattain uusia diagnostiikassa, niiden käytössä esiintyy erilaisia haasteita. EEG-laitteiden haasteet voidaan jakaa karkeasti kahteen luokkaan; laitteisto- ja ohjelmistohaasteisiin. EEG-laitteistoa parannetaan jatkuvasti, etenkin elektrodeja. Kuten luvussa 3.1 mainittiin, geelipohjaiset elektrodit ovat kertakäyttöisiä ja lisäävät mittaukseen tarvittavaa valmistautumisaikaa. [2] Markkinoilla olevat kuivaelektrodit voivat kuitenkin aiheuttaa ihoärsytyksiä pidempiaikaisissa mittauksissa. [15] Kannettavissa laitteissa voi myös olla ongelmia esimerkiksi akun keston sekä datan laskemisen ja tallentamisen kanssa. [2]

Merkittävämmät haasteet kannettavissa laitteissa ovat kuitenkin ohjelmistopuolella. Kannettavilla laitteilla saatu EEG-signaali on hyvin herkkä erilaisille häiriöille esimerkiksi liikkeestä tai ympäristöstä. [2], [15] Kannettavissa laitteissa käytetyt ohjelmistot ovat myös heikkoja. Etenkin masennuksen diagnosoinnissa käytetyt ohjelmat vaativat edistyneitä metodeja, eivätkä siten kykene monimutkaisen EEG-datan analysointiin. [14] Kannettavan laitteen dataa on myös usein vaikeaa verrata mui-

hin tutkimuksiin, sillä käytetyt algoritmit ovat usein suunniteltu vain tietyn tyyppisille datasarjalle ja laitteet voivat käyttää eri tiedostoformaatteja. [2], [14] Merkittävä haaste nimenomaan masennuksen diagnosoinnissa on oikeiden biomarkkereiden tunnistaminen sekä havaitseminen EEG-signaalista. [14]

Suuri haaste kannettavien laitteiden tutkimuksissa on käytettyjen datasarjojen koko. Lukuisissa tutkimuksissa tutkitut datasarjat olivat verrattain pieniä, jolloin niiden tulokset voivat olla hieman harhaanjohtavia. Pienet datasarjat eivät välttämättä kata kaikkia mahdollisia potilasryhmiä ja erikoistapauksia. Lisäksi suuret, yhtenäiset datasarjat auttaisivat muiden tutkimusten vertaisarvioinnissa, datan validoinnissa sekä dokumentoinnin kehittämisessä. [2], [15]

5.2 Tulevaisuus

Kannettavat EEG-laitteet vaativat edelleen lisätutkimusta usealla eri osa-alueella tarkkuuden parantamiseksi ja käyttömukavuuden edistämiseksi. Tärkeimmät tutkimuskohteet tulevaisuudessa painottuvat kannettavien laitteiden diagnoositarkkuuden parantamiseen kehittämällä uusia algoritmeja, optimoimalla käytettyjä EEG-kanavia sekä hyödyntämällä koneoppimismenetelmiä. [2], [14] Erityisesti kokonaisvaltaisten koneoppimismenetelmien kehittäminen on tärkeää, jotta tutkimuksissa voidaan hyödyntää sekä eri datamuotoja että masennuksen eri muotoja.

Tulevaisuudessa kannettavien laitteiden tutkimuksessa tulisi myös keskittyä tutkimusryhmien kokoon ja tutkimuksen olosuhteisiin. Useat tutkimukset mainitsevat yhteenvedossa tutkimusryhmien olleen pieniä ja tulevaisuudessa tutkimusten tulisi kasvattaa tutkimusryhmien kokoa, jotta saadaan laajempaa, monimuotoisempaa ja yhdenmukaisempaa mittausdataa. [14], [16], [17] Tutkimusten olosuhteissa tulisi keskittyä esimerkiksi eri psykotrooppisten lääkkeiden vaikutuksiin [16], ympäristökäyttäytymisiin [17], sekä muihin fysiologisiin mittaustuloksiin EEG-mittausten aikana [5].

Tärkeä osa masennuksen diagnosointia tulevaisuudessa on uusien biomarkkereiden löytäminen EEG:lle. Ne auttavat niin objektiivisessä arvioinnissa kuin myös masennuksen fysiologian ymmärtämisessä. [5], [14] Lisäksi tulevaisuudessa tulisi laitteiden kehitysvaiheessa tutkia potilasmukavuutta ja suorituskykyä parantavia tekijöitä. Mittauksissa käytetyt elektrodit tulisi olla tarkkoja, mutta kuitenkin mukavia potilaille. [2] Kannettavissa laitteissa tulisi myös huomioida mahdolliset tarpeet esimerkiksi potilaiden etäseurantaan. [14] Esimerkiksi mahdollisuudet tiedon varastointiin, dataturvallisuus ja internetin käyttö laitetta suunniteltaessa auttavat tässä huomattavasti. [2]

Viimeisenä tutkimusten tulisi tutkia potilaskyselyiden ja saadun mittausdatan korrelaatiota. [2] Tämä on tärkeää, jotta pystytään sekä arvioimaan mittalaitteen kykyä diagnosoida masennusta, mutta myös tulevaisuudessa päivittämään potilaskyselyt tarkemmiksi ja objektiivisemmiksi. Lisäksi tämä auttaisi dokumentoinnissa ja masennusdiagnoosien parantamisessa.

5.3 Pohdinta

Masennuksen objektiivinen diagnosointi ei ole helppoa. Vaikka viimeisen 10 vuoden aikana on kerätty paljon tutkimusdataa masennuksen havaitsemiseen niin elektroencefalografilla kuin muilla kuvantamislaitteilla kuten magneettiresonanssikuvantamisella ja molekulaarikuvantamislaitteilla, näitä menetelmiä ei ole vielä käytetty terveydenhuollossa masennuksen arvioinnissa. Syitä tähän voi olla useita, todennäköisimmin kustannussyyt, mutta kannettavien EEG-laitteiden kehitys voi mahdollistaa kustannustehokkaan ja tarkan tavan arvioida masennusta.

Kannettavien laitteiden kehityksessä pääpaino olisi syytä keskittää koneoppimismenetelmien käyttöön datan analysoinnissa. Kuten tutkimuksissa havaittiin, saavutettiin koneoppimisalgoritmeilla suuria tarkkuuksia. Erityisesti usean koneoppimisalgoritmin yhdistäminen mahdollistaa lähes 100 % luokittelutarkkuuden, mikä

mielestäni auttaa näyttämään suuntaa tutkimuksille. Moniagenttiset menetelmät, joissa yhdistetään EEG-dataa ja esimerkiksi puheen- tai kasvojentunnistusta voidaan myöhemmässä vaiheessa hyödyntää, mutta tärkeämpää olisi saada tavallisen EEG-datan analysointimenetelmät tarkoiksi ja kustannustehokkaiksi.

Itse laitteiden kehityksessä tulisi aina huomioida käyttömukavuus potilaille. Koska kannettavia EEG-laitteita voitaisiin käyttää esimerkiksi kotona, laitteiden tulisi olla yksinkertaisia, helposti puettavia ja mukavia pitää päällä. Elektrodeja tulisi voida käyttää useamman kerran nykyisten kertakäyttöisten sijaan. Laitteiden käytön tulisi myös olla mahdollisimman yksinkertainen, jotta jokainen kykenee käyttämään sitä myös kotiolosuhteissa. Ohjelmistojen kehittäminen vaatii siis mittavia käyttökokemussuunnitteluja yksinkertaisuuden takaamiseksi. Kerätty data voidaan esimerkiksi lähettää langattoman verkkoyhteyden avulla pilvipalveluun tai tallentaa laitteelle itselle, josta terveydenhuollon ammattilaiset voivat kerätä datan ja analysoida sitä. Laitteita suunniteltaessa on huomioitava myös virransaanti, esimerkiksi ladattavalla akulla. Verkkovirta voi myös olla vaihtoehto, mutta tämä rajoittaa laitteiden kannettavuutta.

Vaikka tämä tutkimus keskittyi masennuksen diagnosointiin, on kannettavilla EEG-laitteilla myös potentiaalista käyttöä muissa neurotieteiden aloissa. Esimerkiksi muut neuropsykiatriset sairaudet, erilaiset neurodegeneratiiviset sairaudet ja unen tutkimus ovat aiheita, joissa on tutkittu kannettavien EEG-laitteiden käyttöä. Kannettavat laitteet voivat siis sopia esimerkiksi uniapnean diagnosointiin kotona sairaalaolosuhteiden sijaan, joka voi monelle ihmiselle olla ahdistava tai stressaava ympäristö.

6 Yhteenveto

Tässä tutkimuksessa tutustuttiin kannettavien EEG-laitteiden käyttöön masennuksen diagnosoinnissa. Aihetta on tärkeä tutkia, sillä se mahdollistaa objektiivisen tavon masennuksen käsittelyyn, auttaa ymmärtämään masennuksen fysiologisia taustoja paremmin sekä parantaa potilasmukavuutta.

Tutkimuksessa esitettiin tutkimuskysymyksiin saatiin seuraavat vastaukset:

TK1: Millaisia EEG-biomarkkereita masennuksessa voidaan havaita? Tyypillisimmät EEG-biomarkkerit masennuspotilailla ovat otsalohkon alfaepäsymmetriä (FAA), beeta-aaltojen aktiivisuuden kasvu, muutoksia theta- ja gamma-aaltojen aktiivisuudessa, alentuneet P300-aaltojen amplitudit, alentunut kommunikaatio aivopuoliskojen välillä ja muutoksia signaalien monimutkaisuuksissa.

TK2: Kuinka tarkkoja kannettavat EEG:t ovat masennuksen diagnosoinnissa? Tutkimuksessa esitettyjen menetelmien tarkkuudet olivat välillä 76,4 % - 99,9 %, joista suurin osa sijoittui yli 90% tarkkuuteen. Lisäksi tietyissä tutkimuksissa joissa saavutettiin yli 90 %:n tarkkuus, ilmoitettiin yli 95 %:n spesifisyys. Nämä tutkimukset käyttivät analysointimenetelminä koneoppimista.

TK3: Millaisia haasteita kannettavilla EEG-laitteilla on ja mihin tulevaisuuden tutkimukset tulisi keskittyä? Kannettavien EEG-laitteiden haasteet tällä hetkellä ovat käytetyt elektrodit, signaalien heikko laatu sekä signaalin käsittelyn vaikeus, epäyhtenäiset data-analyysitavat, biomarkkereiden tunnistaminen sekä nykyisten tutkimusten datasarjojen liian pieni koko. Tulevaisuudessa kannettavien EEG-

laitteiden tutkimuksessa tulisi keskittyä diagnoositarkkuuden ja uusien menetelmien kehittämiseen, tutkimusryhmien koon kasvattamiseen ja monimuotoistamiseen sekä potilasmukavuuden parantamiseen.

Potilasmukavuus oli tärkeässä roolissa useassa lähdeaineiston tutkimuksessa ja kannettavat EEG-laitteet mahdollistavat mittaukset kotiolosuhteissa. Tämä tutkimus osoitti kuitenkin tarvetta jatkotutkimuksille usealla osa-alueella, mutta kaiken kaikkiaan kannettavat EEG-laitteet voivat lähitulevaisuudessa olla tärkeitä masennuksen, ja muiden mielenterveyden sairauksien, diagnosoinnissa terveydenhuollossa.

Lähdeluettelo

- [1] N. Bains ja S. Abdijadid, *Major Depressive Disorder*. StatPearls Publishing, 2023.
- [2] P. Wang, A.-L. Dai, X.-R. Guo ja H.-T. Jiang, ”Portable electroencephalography in early detection of depression: Progress and future directions”, *World journal of psychiatry*, vol. 15(8), nro 107725, 2025. DOI: 10.5498/wjp.v15.i8.107725.
- [3] World Health Organization. ”Depressive disorder (depression)”, viitattu 18.11.2025. url: <https://www.who.int/news-room/fact-sheets/detail/depression>.
- [4] A. Rovasalo. ”Masennustila eli depressio”, viitattu 21.11.2025. url: <https://www.terveyskirjasto.fi/dlk00389>.
- [5] S.-G. Kang ja S.-E. Cho, ”Neuroimaging Biomarkers for Predicting Treatment Response and Recurrence of Major Depressive Disorder”, *International journal of molecular sciences*, vol. 21(6), nro 2148, 2020. DOI: 10.3390/ijms21062148.
- [6] T. Salmi, ”Elektroenkefalografia päivystyslääketieteessä ja tajuttomuuden selvittämisessä”, *Lääketieteellinen Aikakauskirja Duodecim*, vol. 125, s. 1721–1726, 2009.
- [7] M. Brea, B. Connors ja M. A. Paradiso, *Neuroscience: Exploring the Brain, Enhanced Edition*, 4. painos. Jones & Bartlett Learning, LLC, 2020.

- [8] A. Biasucci, B. Franceschiello ja M. M. Murray, "Electroencephalography", *Current Biology*, vol. 29(3), R80–R85, 2019. DOI: 10.1016/j.cub.2018.11.052.
- [9] S. Beniczky ja D. L. Schomer, "Electroencephalography: basic biophysical and technological aspects important for clinical applications", *Epileptic disorders : international epilepsy journal with videotape*, vol. 22(6), s. 697–715, 2020. DOI: 10.1684/epd.2020.1217.
- [10] M. Seeck et al., "The standardized EEG electrode array of the IFCN", *Clinical Neurophysiology*, vol. 128(10), s. 2070–2077, 2017. DOI: 10.1016/j.clinph.2017.06.254.
- [11] H. Zhang et al., "The applied principles of EEG analysis methods in neuroscience and clinical neurology", *Military Medical Research*, vol. 10(1), nro 67, 2023. DOI: 10.1186/s40779-023-00502-7.
- [12] C. S. Nayak ja A. C. Anilkumar, *EEG Normal Waveforms*. StatPearls Publishing, 2025.
- [13] G. Kaur, H. Aggarwal ja N. Goel, "Artificial intelligence driven neuropsychiatry: a systematic review of electroencephalography-based computational techniques for major depressive disorder prediction", *Neuroscience*, vol. 581, s. 179–207, 2025. DOI: 10.1016/j.neuroscience.2025.07.010.
- [14] K. Elnaggar, M. M. El-Gayar ja M. Elmogy, "Depression Detection and Diagnosis Based on Electroencephalogram (EEG) Analysis: A Systematic Review", *Diagnostics (Basel, Switzerland)*, vol. 15(2), nro 210, 2025. DOI: 10.3390/diagnostics15020210.
- [15] A. Lau-Zhu, M. P. Lau ja G. McLoughlin, "Mobile EEG in research on neurodevelopmental disorders: Opportunities and challenges", *Developmental cognitive neuroscience*, vol. 36, nro 100635, 2019. DOI: 10.1016/j.dcn.2019.100635.

- [16] M. Kopańska, D. Ochojska, I. Sarzyńska, O. Bartkowska ja J. Szczygielski, "Quantitative and qualitative electroencephalography in the diagnosis and monitoring of depression. A modern approach to clinical neurophysiology", *Frontiers in human neuroscience*, vol. 19, nro 1624434, 2025. DOI: 10.3389/fnhum.2025.1624434.
- [17] E. Gkintoni, A. Vantarakis ja P. Gourzis, "Neuroimaging Insights into the Public Health Burden of Neuropsychiatric Disorders: A Systematic Review of Electroencephalography-Based Cognitive Biomarkers", *Medicina (Kaunas, Lithuania)*, vol. 61(6), nro 1003, 2025. DOI: 10.3390/medicina61061003.
- [18] G. Kaur, H. Aggarwal ja N. Goel, "Artificial intelligence driven neuropsychiatry: a systematic review of electroencephalography-based computational techniques for major depressive disorder prediction", *Neuroscience*, vol. 581, s. 179–207, 2025. DOI: 10.1016/j.neuroscience.2025.07.010.
- [19] S. A. Akar, S. Kara, S. Agambayev ja V. Bilgiç, "Nonlinear analysis of EEGs of patients with major depression during different emotional states", *Computers in Biology and Medicine*, vol. 67, s. 49–60, 2015. DOI: 10.1016/j.combiomed.2015.09.019.
- [20] M. Bachmann et al., "Methods for classifying depression in single channel EEG using linear and nonlinear signal analysis", *Computer Methods and Programs in Biomedicine*, vol. 155, s. 11–17, 2018. DOI: 10.1016/j.cmpb.2017.11.023.
- [21] A. Kawamura, K. Hiroshi, U. Makoto, N. Yamada ja K. Kuriyama, "Objective evaluation of major depressive disorder using sleep electroencephalography measured by an in-home portable one-channel device: a preliminary study", *Sleep & breathing (Schlaf & Atmung)*, vol. 29(2), nro 165, 2025. DOI: 10.1007/s11325-025-03329-9.

- [22] W. Wu, L. Ma, W. Cai ja X. Zhao, "Few-Electrode EEG from the Wearable Devices Using Domain Adaptation for Depression Detection", *Biosensors*, vol. 12(12), nro 1087, 2022. DOI: 10.3390/bios12121087.
- [23] B. Zhang, D. Wei, G. Yan, T. Lei, H. Cai ja Y. Zhifei, "Feature-level fusion based on spatial-temporal of pervasive EEG for depression recognition", *Computer Methods and Programs in Biomedicine*, vol. 226, nro 107113, 2022. DOI: 10.1016/j.cmpb.2022.107113.
- [24] X. Zhang, J. Shen, Z. u. Din, J. Liu, G. Wang ja B. Hu, "Multimodal Depression Detection: Fusion of Electroencephalography and Paralinguistic Behaviors Using a Novel Strategy for Classifier Ensemble", *IEEE Journal of Biomedical and Health Informatics*, vol. 23(6), s. 2265–2275, 2019. DOI: 10.1109/JBHI.2019.2938247.
- [25] F. Tian et al., "The Three-Lead EEG Sensor: Introducing an EEG-Assisted Depression Diagnosis System Based on Ant Lion Optimization", *IEEE Transactions on Biomedical Circuits and Systems*, vol. 17(6), s. 1305–1318, 2023. DOI: 10.1109/TBCAS.2023.3292237.
- [26] N. Sakib, M. K. Islam ja T. Faruk, "Machine Learning Model for Computer-Aided Depression Screening among Young Adults Using Wireless EEG Headset", *Computational intelligence and neuroscience*, vol. 2023, nro 1701429, 2023. DOI: 10.1155/2023/1701429.
- [27] Y. Li, B. Hu, X. Zheng ja X. Li, "EEG-Based Mild Depressive Detection Using Differential Evolution", *IEEE Access*, vol. 7, s. 7814–7822, 2019. DOI: 10.1109/ACCESS.2018.2883480.
- [28] G. Sharma, A. M. Joshi, R. Gupta ja L. R. Cenkeramaddi, "DepCap: A Smart Healthcare Framework for EEG Based Depression Detection Using

Time-Frequency Response and Deep Neural Network”, *IEEE Access*, vol. 11, s. 52 327–52 338, 2023. DOI: 10.1109/ACCESS.2023.3275024.