

Koneoppimismenetelmät uniapnean tunnistamisessa aivosähkökäyrästä

TURUN YLIOPISTO
Tietotekniikan laitos
TkK-tutkielma
Lääketieteellinen tekniikka ja terveysteknologia
Maaliskuu 2026
Sara Lampinen

TURUN YLIOPISTO

Tietotekniikan laitos

SARA LAMPINEN: Koneoppimismenetelmät uniapnean tunnistamisessa aivosähkökäyrästä

TkK-tutkielma, 34 s.

Lääketieteellinen tekniikka ja terveysteknologia

Maaliskuu 2026

Tämä tutkielma käsittelee uniapnean tunnistamiseen kehitettyjä EEG-signaaliin perustuvia menetelmiä sekä vertailee niitä. Tutkielmassa käsitellään myös menetelmiin liittyviä haasteita ja tulevaisuuden näkymiä. EEG-signaalin hyödyntämisessä uniapnean tunnistamiseen on suuri potentiaali, sillä sen avulla saadaan kattavaa tietoa aivojen aktiivisuudesta unen aikana. EEG-signaalin avulla pystytään tunnistamaan uniapneapotilaan hengityskatkokset unen aikana, ja niiden määrän perusteella pystytään tekemään diagnoosi. Tutkielma suoritettiin kirjallisuuskatsauksena, ja se perustuu ajankohtaisiin akateemisiin julkaisuihin. Tavoitteena on tarjota katsaus nykyisiin menetelmiin sekä arvioida niitä.

Tutkielma painottuu koneoppimiseen perustuvien menetelmien käsittelyyn. Menetelmät voidaan jakaa pääpiirteittäin perinteiseen koneoppimiseen perustuviin menetelmiin, neuroverkkoihin perustuviin menetelmiin sekä muihin menetelmiin. Menetelmissä toistui paljon samankaltaisuuksia sekä samoja algoritmeja. Tutkielmassa vertaillaan tutkimuksissa käytettyä dataa, menetelmien tarkkuutta sekä niissä käytettyjä ratkaisuja.

Tutkielman perusteella havaittiin, että EEG-signaalin käsittelyyn on kehitetty paljon erilaisia koneoppimista hyödyntäviä menetelmiä uniapnean tunnistamiseen. Löydettyjen aineistojen perusteella ei pystytty toteamaan yhtä parhaiten suoriutuvaa menetelmää. Menetelmissä toistui samankaltaisia haasteita sekä niihin liittyviä ongelmia. Menetelmien vertailu osoittautui myös monelta osalta haastavaksi. Hyvin suoriutuvia menetelmiä on kehitetty paljon, mutta niiden parantamisessa on vielä potentiaalia.

Asiasanat: aivosähkökäyrä, uniapnea, koneoppiminen, neuroverkko, algoritmi, signaalinkäsittely

Sisällys

1	Johdanto	1
2	Uniapnea	3
2.1	Obstruktiivinen uniapnea	4
2.2	Sentraalinen uniapnea	5
2.3	Sekamuotoinen uniapnea	6
2.4	Uniapnean diagnosointiin käytettävät menetelmät	7
3	EEG:n toimintaperiaate	9
3.1	EEG:n fysiologinen tausta	9
3.2	EEG:ssä käytettävä laitteisto	10
3.3	EEG-signaali ja sen tulkinta	10
4	EEG-signaaliin perustuvat koneoppimismenetelmät uniapnean tunnistamisessa	14
4.1	Perinteiseen koneoppimiseen perustuvat menetelmät	14
4.2	Neuroverkkoihin perustuvat menetelmät	18
4.3	Muihin menetelmiin perustuvat menetelmät	23
4.4	Menetelmien vertailu ja analysointi	26
5	Pohdinta	31
6	Yhteenveto	33
	Lähdeluettelo	35

Termistö

ABC	artificial bee colony
AD	analog-to-digital, analogia-digitaali
AHI	apnea hypopnea index, apnea-hypoapneaindeksi
ANFIS-ICOA	adaptive neuro-fuzzy interface with an improved cheetah optimization algorithm, adaptiivinen neuro-fuzzy-päätelmäjärjestelmä parannetulla gepardioptimointialgoritmillä
ASV	adaptive-servo ventilation, adaptiivinen-servo ventilaatio
BiLSTM	bidirectional long and short-term memory
BiPAP	bi-level positive airway pressure, kaksoispainehengityshoito
CNN	convolutional neural network, konvoluutioneuroverkko
CPAP	continuous positive airway pressure, ylipainehengityshoito
CRF	conditional random fields
DNN	deep neural network, syväneuroverkko
DT	decision tree, päätöspuu
DWT	discrete wavelet transform, diskreetti wavelet-muunos
EAN	efficient attention network
EEG	electroencephalogram, aivosähkökäyrä
EESOSAD	ensemble expert system for obstructive sleep apnea detection
EKG	electrocardiogram, sydänsähkökäyrä
ELM	extreme learning machine
EMD	empirical mode decomposition, empiirinen moodihajotelma
EMG	electromyogram, lihassähkökäyrä
ET	extra tree, extra-puu
FCNN	fully convolutional neural network, täysin konvolutiivinen neuroverkko

FPGA	field programmable gate array
GCN	graph convolutional network, graafinen konvoluutioverkko
HCEAN	hybrid convolution efficient attention network
HF	Hermite function, Hermiten funktio
IEOO	improved eurasian oystercatcher
IESOSAD	intelligent expert system for the obstructive sleep apnea detection
IF	isolation forest
IIR	infinite impulse response, ääretön impulssivaste
IMF	intrinsic mode function, intrinsinen moodifunktio
KNN	k-nearest neighbors, k-lähin naapuri
LCNN–GCNN	local convolutional neural network – global convolutional neural network
LPDVG	limited penetrable difference visibility graph
LSTM	long and short-term memory
LSVM	linear support vector machine, lineaarinen tukivektorikone
mRMR	maximal relevance minimal redundancy
NB	naive Bayes
OISOSA	optimized intelligent system for obstructive sleep apnea
OSA	obstructive sleep apnea, obstruktiivinen uniapnea
PSG	polysomnogram, polysomnografia
PSO	particle swarm optimization
ResNet	residual neural network, residuaalineuroverkko
RF	random forest
RFE	recursive feature elimination
RNN	recurrent neural network, toistuva neuroverkko
SSDM	swarm-sparse decomposition method
SVM	support vector machine, tukivektorikone
TCNN	engl.temporal convolutional neural network, ajallinen konvoluutioneuroverkko
TSmRMR	threshold search maximal relevance minimal redundancy
VG	visibility graph, näkyvyysgraafi
VMD	variational mode decomposition, variaatiomoodihajotus
YOLO	you only look once

1 Johdanto

Uniapnea on sairaus, jossa potilaalla ilmenee hengityskatkoksia unen aikana. Uniapneaa voidaan diagnosoida unitutkimuksilla, joissa mitataan monia fysiologisia arvoja. Uniapneapotilaat kärsivät päivän aikaisesta väsymyksestä, joka vaikuttaa suorituskykyyn [1]. Yksi tärkeimmistä mitattavista arvoista on aivojen aktiivisuutta mittaava aivosähkökäyrä (*engl.* electroencephalogram, EEG). EEG:n avulla pystytään arvioimaan aivojen toimintaa ja sen häiriöitä unen aikana. Tämän johdosta siitä saadaan tärkeää tietoa uniapnean hengityskatkoksisista diagnosoinnin tueksi [2].

EEG-signaali on hyvin epäsäännöllinen, ja jotta siitä saadaan diagnosoinnin kannalta hyödyllistä tietoa, se vaatii paljon signaalinkäsittelyä [3]. Erilaisia menetelmiä uniapnean tunnistamiseen on kehitetty, ja tässä tutkielmassa keskitytään arvioimaan niiden tehokkuutta ja hyödyllisyyttä uniapnean tunnistamisessa. Tarkastelun kohteena ovat erilaiset koneoppimismenetelmät. Tämä tutkielma on toteutettu kirjallisuuskatsauksena ja se pyrkii vastaamaan seuraaviin tutkimuskysymyksiin:


TK1: Millaisia koneoppimismenetelmiä tarvitaan uniapnean tunnistamisessa EEG-signaalista?

TK2: Mitkä koneoppimismenetelmät ovat tehokkaimpia uniapnean tunnistamisessa EEG-signaalista?

TK3: Mitä ongelmia ja virhearviota koneoppimismenetelmiin liittyy?

Tutkielman tiedonhaku suoritettiin kolmesta eri tietokannasta: Web of Science, PubMed ja IEEE Xplore. Tiedonhakuprosessi on kuvattu kaaviossa 1.1. Kaikissa

kolmessa tietokannassa aineiston hakemiseen käytettiin hakulauseketta "EEG AND ('sleep apnea' OR 'sleep apnoea') AND ('signal processing' OR 'algorithm*')" sekä haku rajattiin aluksi aikavälille 2015–2025. Hakutuloksia rajattiin läpikäynnin yhteydessä koskemaan vain uniapneaa käsitteleviä sekä koneoppimiseen perustuvia menetelmiä. Web of Science -tietokannasta saatiin hakulausekkeella ja aikarajauksella 238 hakutulosta. Hakutulosten läpikäynnin jälkeen näistä 20 hakutulosta päädyttiin käyttämään tutkielmassa. PubMed-tietokannasta saatiin 97 hakutulosta, joista 12 hyödynnettiin tutkielmassa. IEEE Xplore -tietokannasta hakutuloksia saatiin 212 kappaletta. Niiden läpikäynnin jälkeen tutkielman kannalta hyödyllisiksi valikoitui 14 hakutulosta. Tietokannoista saatiin samoja hakutuloksia, jotka otettiin huomioon aineistojen yhteismäärää laskiessa. Aikarajaus tehtiin vielä lopuksi uudelleen aikavälille 2020–2025. Yhteensä kaikista tietokannoista saatiin hakulausekkeella ilman rajauksia 840 hakutulosta, joista 31 päädyttiin hyödyntämään tässä kirjallisuuskatsauksessa.



Kuva 1.1: Aineiston haku ja -valintaprosessi.

Tutkielmassa on kuusi lukua, joista ensimmäinen on johdanto. Toisessa luvussa käsitellään uniapnean eri muotoja ja niiden diagnosointiin käytettäviä menetelmiä. Kolmannessa luvussa keskitytään EEG:n fysiologiseen taustaan sekä EEG-signaaliin. Neljännessä luvussa käsitellään koneoppimismenetelmiä, joita tarvitaan uniapnean tunnistamiseen EEG-signaalista sekä vertaillaan niitä. Viidennessä luvussa analysoidaan menetelmien hyödyllisyyttä ja tehokkuutta sekä pohditaan saatuja tuloksia ja tulevaisuuden näkymiä. Viimeisessä luvussa vastataan tutkimuskysymyksiin ja tehdään yhteenveto tutkielmasta.

2 Uniapnea

Uniapnea on sairaus, jossa potilaan hengitys katkeilee unen aikana. Uniapneaa sairastavilla esiintyy apneoita eli hengityksen pysähtymisiä sekä hypopneoita eli osittaisia ilmvirran katkoksia unen aikana [4]. Apneoiden kesto voi vaihdella muutamasta sekunnista yli minuuttiin [1]. Uniapnea voidaan luokitella sen syntymekanismin mukaan kolmeen eri muotoon, joita käsitellään seuraavissa alaluvuissa. Yleisimpiä oireita uniapneapotilailla ovat kuorsaaminen, unen katkonaisuus, väsymys, nukahdeltu kesken päivän, muistihäiriöt sekä yölliset rytmihäiriöt. Uniapneaa sairastavilla rytmihäiriöiden ja verisuonisairauksien riski on kohonnut huomattavasti. Unen katkonaisuus ja tästä johtuva väsymys altistaa potilaan myös auto-onnettomuuksille sekä työtapaturmille. Uniapnea on yleisempi vanhoilla ja ylipainoisilla ihmisillä [1].

Uniapnea diagnosoidaan unitutkimuksella. Mittaus tehdään usein kotona yöunen aikana. Tutkimuksen voi myös suorittaa sairaalaolosuhteissa. Unitutkimuksista saadaan mittaustuloksia monista ihmiskehon fysiologisista toiminnoista [5]. Tässä tutkielmassa keskitytään EEG-signaalin hyödyntämiseen uniapnean tunnistamisessa.

Uniapnea voidaan luokitella obstruktiiviseen uniapneaan (*engl.* obstructive sleep apnea, OSA), sentraaliseen uniapneaan (*engl.* central sleep apnea) ja sekamuotoiseen uniapneaan (*engl.* complex sleep apnea). Uniapnean muodot eroavat toisistaan niiden aiheuttajamekanismien perusteella. Obstruktiivinen uniapnea on uniapnean muodoista yleisin. Sentraalinen uniapnea on paljon harvinaisempi kuin obstruktiivinen uniapnea. Sekamuotoinen uniapnea on vielä harvinaisempi, ja sen diagnosointi

on monivaiheinen prosessi. Hoitomenetelmät eri muodoilla ovat hyvin samanlaisia. Hoidon tarve kuitenkin vaihtelee yksilöllisesti. Eri muotojen perimmäiset syyt ovat usein tuntemattomia, mutta niiden hoitoon on löydetty hyödyllisiä menetelmiä. [6], [7]

2.1 Obstruktiivinen uniapnea

Obstruktiivista uniapneaa sairastavilla hengityksen pysähtyminen unen aikana johtuu ylähengitysteiden häiriöistä. Kuorsaaminen, hengityksen pysähtyminen unen aikana sekä siitä johtuva unen katkonaisuus ovat obstruktiivisen uniapnean keskeisimpiä oireita. Obstruktiivisessa uniapneassa hengityskatkokset johtuvat ylähengitysteiden ahtaudesta ja rakenteesta, joka estää ilman virtaamisen hetkellisesti keuhkoihin [1]. Ylähengitysteiden sulkeutuminen tai tukkeutuminen voi tapahtua joko kokonaan tai osittain. Apneat voivat johtua myös ylähengitysteiden lihastoiminnan häiriöistä. Tarkkaa ja perimmäistä syytä obstruktiivisen uniapnean ilmenemiselle ei tiedetä [8].

Obstruktiivista uniapneaa hoidetaan unenaikaisen hengityksen helpottamisella ja apneoiden estämisellä ylipainehengityshoidolla (*engl.* continuous positive airway pressure, CPAP). CPAP on yleisin hoitomuoto obstruktiivista uniapneaa sairastavilla potilailla. Hoito toteutetaan laitteella, jota potilas käyttää jatkuvasti nukkessaan. Maski asetetaan potilaan kasvoille kuvan 2.1 esittämällä tavalla. Unen aikana laite puskee huoneilmaa suodattimen läpi potilaan hengitysteihin, estäen nielun seinämien painumisen yhteen ja siten apneat ja hypopneat. CPAP-laite on usien riittävä hoitomuoto hengityskatkokosten estämiseksi ja unen laadun parantamiseksi. [1]



Kuva 2.1: CPAP-laite. CC BY-SA 3.0. [9]

2.2 Sentraalinen uniapnea

Sentraalinen uniapnea on paljon harvinaisempi uniapnean muoto kuin obstruktiivinen uniapnea. Sentraalista uniapneaa sairastavilla apneat johtuvat keskushermoston toiminnasta, joka pysäyttää hengityksen unen aikana. Keskushermostosta tuleva hengityksen laukaiseva hermoimpulssi estyy ja aiheuttaa hengityksen pysähtymisen. Potilaan ylähengitystiet ovat avoimena, mutta hengitysrefleksiä ei tapahdu keskushermostollisen häiriön johdosta. Oireet ovat sentraalisessa uniapneassa samanlaiset kuin obstruktiivisessa uniapneassa. Sentraalisen uniapnean syitä ovat sydämen vajaatoiminta, aivohalvaus, eteisvärinä, selkäydin vammat, munuaisten vajaatoiminta sekä krooninen opioidien käyttö. [6]

Sentraalinen uniapnea voidaan jakaa edelleen useaan eri muotoon. Ensimmäistä muotoa ilmenee potilailla, jotka elävät korkealla merenpinnasta alhaisessa ilmanpaineessa. Alhainen ilmanpaine lisää aivojen hengityskeskuksen herkkyyttä verenkierron hiilidioksidi- ja happipitoisuuksien muutoksille. Näillä potilailla ilmenee hy-

perapneaa eli hengitystahdin nopeutumista, ja tämä vuorottelee usein apneoiden kanssa. Toista sentraalisen uniapnean muotoa aiheuttaa elimistön häiriö hengityksen säätelyreaktiossa hiilidioksidipitoisuuden nousuun, joka ohjaa hengitystä. Tätä muotoa sairastavilla on verenkierrossa vähän hiilidioksidia, mikä johtaa unen aikana apneoihin, kun hengitysvastetta ei tapahdu. Kolmatta sentraalisen uniapnean muotoa esiintyy potilailla, joilla on sydämen vajaatoiminta, keuhkopöhö tai pitkittynyt verenkierron aika. Potilailla esiintyy hengitysmalli, jossa hengityksen nopeus ja syvyys vaihtelee jaksoittain ja aiheuttaa apneoita. Syyt hengityksen epätasaisuudelle ja apneolle ovat sydämen vajaatoiminta ja keskushermoston häiriöt. [10]

Sentraalista uniapneaa voidaan hoitaa CPAP-laitteella kuten obstruktiivista uniapneaa. Mikäli CPAP-laite ei auta apneoiden estämiseen, toinen käytetty menetelmä on kaksoispainehengityshoito (*engl.* bi-level positive airway pressure, BiPAP). BiPAP-laite mahdollistaa ilman puskemisen hengitysteihin kahdella eri paineella ohjaten siten sekä sisään- että uloshengitystä. Laite ohjaa ilmaa sisäänhengittäessä korkeammalla paineella ja uloshengittäessä matalemmalla paineella. [11]

2.3 Sekamuotoinen uniapnea

Sekamuotoinen uniapnea on obstruktiivisen ja sentraalisen uniapnean yhdistelmä. Sekamuotoisessa uniapneassa potilaalla ilmenee ylähengitysteiden ahtautta yhdessä hermostollisen häiriön kanssa. Sekamuotoinen uniapnea diagnosoidaan yleensä potilaille, joilla on todettu aluksi obstruktiivinen uniapnea. Tällöin hoidon aikana potilaalla ilmenee apneoita ylähengitysteiden avaamisesta huolimatta. Sekamuotoisessa uniapneassa yhdistyvät obstruktiivisen uniapnean ylähengitysteiden rakenteellinen ongelma sekä sentraalisen uniapnean hermostollinen häiriö. On myös todettu, että sekamuotoista uniapneaa sairastavilla molemmat aiheuttajamekanismit vaihtelevat unen vaiheiden aikana. Hengityksen säätely vaihtelee siis unen eri vaiheissa

perustuen valveillaolon, REM-unen (*engl.* rapid eye movement sleep) ja syvänunen eroihin. [12]

Ensisijaisena hoitomuotona sekamuotoiseen uniapneaan käytetään CPAP-laitetta. Sekamuotoista uniapneaa hoidetaan myös BiPAP-laitteella. Jos CPAP- tai BiPAP-laitteilla ei saada tarvittavaa apua, adaptiivista-servo ventilaatiota (*engl.* adaptive-servo ventilation, ASV) voidaan käyttää hoitomuotona. ASV on uusi hoitomuoto, joka perustuu ilman puskemiseen hengitysteihin. ASV:ssa laite ohjaa hengitystä algoritmien avulla tietokoneohjatusti vaihdellen hengityksen tiheyttä ja painetta. ASV:tä on käytetty myös obstruktiivisen uniapnean hoidossa. [12]

2.4 Uniapnean diagnosointiin käytettävät menetelmät

Yleisin uniapnean tunnistamiseen käytetty menetelmä on polysomnografia (*engl.* polysomnogram, PSG). PSG on monikomponenttinen unitutkimus, jolla voidaan tunnistaa unihäiriöitä ja muun muassa uniapneaa. Mittaus tehdään unen aikana ja se suoritetaan sairaalaympäristössä. PSG tallentaa sähköisesti mitattavia ihmiskehon fysiologisia arvoja eli biosignaaleja. Laite mittaa sydänsähkökäyrää (*engl.* electrocardiogram, EKG), EEG:tä, lihassähkökäyrää (*engl.* electromyogram, EMG) sekä silmien liikettä ja happisaturaatiota. [7]

Mittaus uniapnean diagnosoimiseksi voidaan suorittaa myös kotiin vietävällä laitteella. Kotona tehtävä testi on tarkoitettu käytettäväksi vähemmän monimutkaisissa tapauksissa, ja sen avulla saadun datan määrä on pienempi kuin PSG-tutkimuksessa. Mitattujen arvojen määrä vaihtelee paljon laitekohtaisesti. Yksinkertaisin laite mittaa kahta arvoa, joista ensimmäinen on happisaturaatio ja toinen kuorsaus, hengitys tai sydämensyke. Monimutkaisempi kotona käytettävä laite mittaa kolmea arvoa, joita voivat olla hengitys, kuorsaus, hengityслиikkeet, kehon asento, syke tai hap-

pisaturaatio. Obstruktiivinen uniapnea pystytään diagnosoimaan kotitestin avulla, mutta sentraalista tai sekamuotoista uniapneaa epäiltäessä PSG on paras vaihtoehto sairauden diagnosoimiseksi. [7]

Uniapnea voidaan diagnosoida mittaustuloksista tunnistamalla apneoiden ja hypopneoiden määrät. Apnea-hypopneaindeksiä (*engl.* apnea hypopnea index, AHI) on yleisesti käytetty mittari uniapnean tunnistamisessa. AHI kertoo apneoiden ja hypopneoiden määrät yhden tunnin aikana [13]. Uniapnea voidaan diagnosoida toteamalla potilaalla riittävästi uniapnean oireita sekä tunnistamalla PSG- tai kotimitauksen avulla AHI-arvo vähintään viideksi [7]. Lievä uniapnea voidaan diagnosoida, kun AHI-arvo on 5–14. Keskivaikeassa uniapneassa AHI on 15–29 ja vaikeassa yli 30 [13].

3 EEG:n toimintaperiaate

EEG on ei-invasiivinen menetelmä, jolla mitataan aivojen sähköistä aktiivisuutta potilaan päähän asetettavilla elektrodeilla. Aivojen sähköinen aktiivisuus tarkoittaa hermosolujen aktiopotentiaaleja eli jännite-eroja, joita syntyy hermoimpulssien kulkiessa hermosolusta toiseen. EEG mittaa elektrodien avulla ihon pinnalta näitä aivojen läpi kulkevia sisäisiä ionivirtojen potentiaalieroja ja muuntaa ne digitaaliseksi signaaliksi. [3]

3.1 EEG:n fysiologinen tausta

Keskushermosto koostuu pääasiassa hermosoluista sekä niiden välissä olevista gliasoluista. Jokaisella hermosolulla on monia tuojahaarakkeita, joiden kautta hermoimpulssit kulkeutuvat hermosoluihin. Jokaisella hermosolulla on myös yksi viejähaarakke, jonka ansiosta yhteys muihin hermosoluihin tai elimiin on mahdollista. Yhteys muihin hermosoluihin tapahtuu synapsien ansiosta ja yhdellä hermosolulla on tavallisesti useita synapseja. [14]

Hermosolun lepopotentiaali on negatiivinen noin 60–70 mV. Hermosolun potentiaalimuutokset johtuvat pääasiassa niiden synaptisesta toiminnasta. Hermosolujen synapseissa tapahtuu sähköisen hermoimpulssin muuntuminen kemialliseksi viestiksi välittäjäaineiden avulla. Tämä tapahtuma muuttaa hermosolun potentiaalia. Tätä potentiaalimuutosta kutsutaan postsynaptiseksi potentiaaliksi ja sitä voidaan mitata EEG:n avulla. Myös itse hermoimpulssin kulku viejähaarakkeessa toiseen her-

mosoluun aiheuttaa aktiopotentiaaleja, jotka voidaan mitata EEG:llä [14]. Sähköisen aktiivisuuden on kuitenkin oltava tarpeeksi pitkäkestoista ja voimakasta, jotta sitä voidaan tallentaa EEG:n avulla [15].

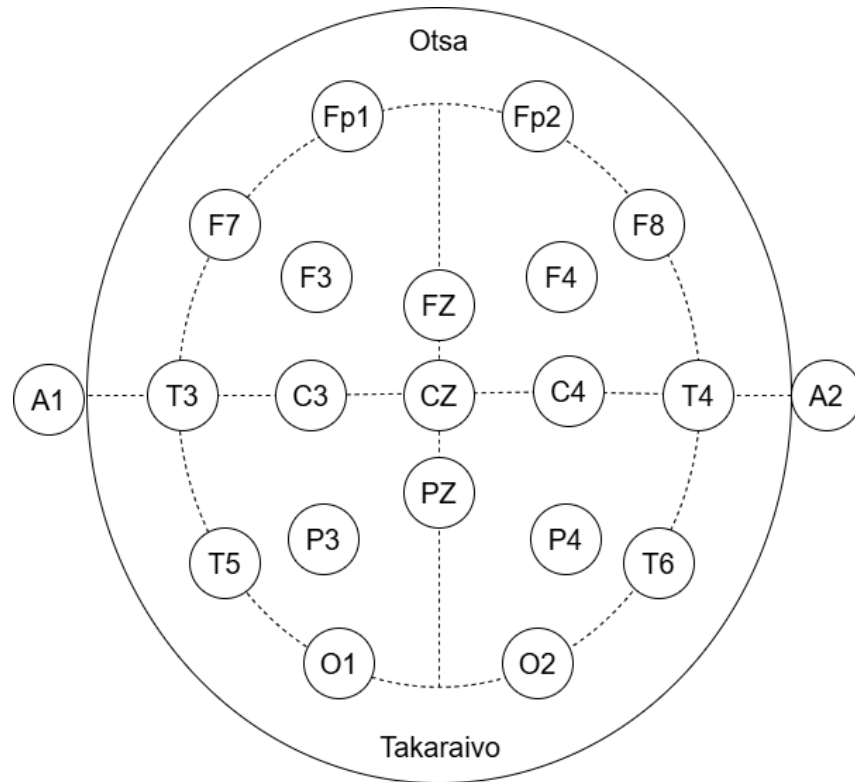
3.2 EEG:ssä käytettävä laitteisto

EEG:n elektrodit voivat olla joko unipolaarisia tai bipolaarisia. Unipolaariset elektrodit mittaavat jännite-eron vertaamalla yhden elektrodin jännitettä joko kaikkien elektrodien keskiarvoon tai niin kutsuttuun neutraaliin elektrodiin. Bipolaariset elektrodit toimivat elektrodipareina ja jännite-ero saadaan vertaamalla kahden elektrodin arvoja keskenään. Bipolaariset elektrodit ovat EEG:n mittauksessa yleisempiä kuin unipolaariset elektrodit. [3]

Elektrodien määrä vaihtelee laitekohtaisesti. Yleensä käytetään vähintään 21:tä elektrodia. Elektrodit voidaan kiinnittää yksitellen, verkon avulla tai myssyn avulla. Verkkoa tai myssyä käytetään erityisesti tilanteissa, joissa elektrodeja on paljon. Jokaiselle elektrodille on oma paikkansa päässä, jotka ovat esitetty kuvassa 3.1. Paikat ovat merkitty siten, että oikealla puolella on parilliset, vasemmalla puolella parittomat ja Z-kirjaimella tarkoitetaan keskellä päätä olevia elektrodeja. Kirjaimilla osoitetaan minkä aivolohkon päällä elektrodit sijaitsevat: F on otsalohko, T on ohimolohko, P on päälaenlohko ja O on takaraivolohko. Elektrodien materiaalina käytetään usein hopeakloridi-levyelektrodeja ja ne kiinnitetään päänahkaan geelin tai tahnan kanssa sähkönjohtavuuden parantamiseksi. [16]

3.3 EEG-signaali ja sen tulkinta

EEG-signaali on stokastinen (*engl.* stochastic) eli se ei toistu säännöllisenä ajan kuluessa. Käsittelemätön signaali on hyvin epäsäännöllinen ja usein myös kohinainen, eikä siitä ilman käsittelyä saada hyödyllistä tietoa. Kohinalla tarkoitetaan häiriösig-



Kuva 3.1: EEG-mittauksessa käytettävien elektrodien paikat päässä. Kuva muokattu lähteestä [17].

naaleja, jotka aiheutuvat ulkopuolisista häiriötekijöistä [3]. EEG-signaalissa vaakakselilla näkyy aika ja pystyakselilla jännite. Aaltojen korkeutta voidaan muuttaa herkkyys-säätimen avulla. Suodattimien käyttö on usein hyödyllistä, mutta vaarana voi olla tärkeiden tietojen suodattuminen pois. Näytön nopeuden säätäminen voi myös parantaa aaltojen tunnistamista. Digitaalisten suodattimien käyttö voi olla hyödyllistä, mutta se saattaa vääristää signaalin aaltomuotoa tai hävittää kiinnostuksen kohteena olevan poikkeaman [16].

Yksi käytetyimmistä suodattimista EEG:n signaalinkäsittelyssä on Butterworth-suodatin (*engl.* Butterworth filter). Butterworth-suodattimella on maksimaalisen tasainen vaste päästökaistalla. Suodattimen kanavien määrä voi vaihdella, ja sitä voidaan soveltaa käyttötarkoituksen mukaan sopivaksi. [3]

EEG-signaalin aaltomuotoja voidaan luokitella sijainnin, taajuuden, amplitudin, morfologian, jatkuvuuden, synkronian, symmetrian ja reaktiivisuuden perusteella.

Olennaista EEG-signaalin tulkinassa ja käsittelyssä on saada näkyviin poikkeamat normaaleista aaltomuodoista. Yleinen tapa käsitellä EEG-signaalia on taajuuden perusteella. Taulukossa 3.1 on esitetty EEG-signaalin taajuuskaistat, niiden arvot sekä esiintyminen unen ja valveillaolon välillä. EEG-signaalin keskeisimpiä aaltomuotoja ovat delta-, theeta-, alfa-, sigma-, beeta- ja gamma-taajuuskaistat. Normaalit EEG:n aallot jaetaan valveillaolorytmin ja unirytmien mukaan. Perinteinen kliininen EEG keskittyy 0.5–70 Hz aaltomuotoihin, joita analysoidaan kaistanpäästösuodatintekniikoilla. Joissain tapauksissa myös tämän alueen ulkopuolisia tai kaikkia taajuuksia on hyödyllistä analysoida. Syvän unen aikana esiintyy delta-aaltoja, ja varhaisen unenvaiheiden aikana esiintyy theeta- ja sigma-aaltoja. Sigma-aaltoja esiintyy myös kevyen unen aikana. Hereilläollessa esiintyy alfa-, beeta- ja gamma-aaltoja. Alfa-aaltoja esiintyy uneliaisuuden aikana erityisesti kun silmät ovat kiinni ja potilas on rentoutunut. Beeta-aaltoja esiintyy useimmiten hereilläollessa, mutta myös aivan unen varhaisimmissa ja kevyimmissä vaiheissa [18]. Uniapneaa diagnosoidessa tutkitaan usein kaikkia viittä taajuuskaistaa, sillä apneat aiheuttavat suurta vaihtelua taajuusalueilla [19].

Taulukko 3.1: EEG-signaalin taajuuskaistat, niiden arvot sekä esiintyminen unen ja valveillaolon välillä. [18]

Nimi	Taajuuskaista (Hz)	Esiintyminen
delta	0.5-4	syvä uni
theeta	4-7	varhainen uni
alfa	8-12	valveillaolo
sigma	12-16	varhainen uni
beeta	13-30	valveillaolo
gamma	30-80	valveillaolo

EEG-signaalin taajuuskaistojen avulla voidaan tarkastella aivojen aktiivisuudessa tapahtuvia muutoksia tarkemmin [18]. Uniapneapotilailla hypoksian eli ha-

penpuutteen aikana delta- ja theeta-taajuusalueiden aktiivisuus lisääntyy ja alfa-taajuusalueen aktiivisuus laskee. Yleisesti uniapneapotilailla havaitaan EEG:n hidastumista verrattuna terveisiin. Lisäksi REM-unen aikana ja valveilla ollessa hitaat EEG-rytmit lisääntyivät uniapneapotilailla [20].

Uniapneapotilas kärsii usein verenkierron hiilidioksidipitoisuuden noususta apneoiden johdosta. Kemoreseptorit reagoivat tähän herättämällä potilaan hengittämään, jotta elimistön happitaso saataisiin nostettua normaalille tasolle. Tämä nopea muutos unen aikana aiheuttaa EEG-aalloissa jyrkkää vaihtelua, mikä voidaan havaita EEG-signaalin taajuus-spektrillä. Muutokset apneoiden ja normaalin hengityksen välillä voivat aiheuttaa vaihtelua EEG:n delta-, theeta-, alfa-, sigma- ja beeta-taajuuskaistoilla. [19]

4 EEG-signaaliin perustuvat koneoppimismenetelmät uniapnean tunnistamisessa

EEG-signaalin käsittelyyn on kehitetty monia menetelmiä uniapnean tunnistamiseen. Perinteisen koneoppimisen, syväoppimisen, tekoälyn sekä neuroverkkojen avulla on kehitetty tehokkaita menetelmiä uniapnean luokitteluun EEG-signaaliin perustuen. EEG-signaalin taajuuskaitojen hyödyntäminen on yleinen menetelmä uniapnea taphtumien tunnistamisessa. Kaikissa menetelmissä taajuuskaistoja ei kuitenkaan eroteta, vaan luokittelussa on käytetty muita menetelmiä. Tässä tutkielmassa menetelmät ovat jaoteltu perinteiseen koneoppimiseen, neuroverkkoihin sekä muihin menetelmiin perustuviin menetelmiin. Seuraavissa alaluvuissa käydään läpi löydetty menetelmät vuosilta 2020–2025.

4.1 Perinteiseen koneoppimiseen perustuvat menetelmät

Perinteiseen koneoppimiseen perustuville menetelmille on lähteiden [21], [22], [23], [24], [2], [25] ja [26] mukaan yhteistä koulutusdatan, eli datan jonka luokittelu jo tiedetään, hyödyntäminen algoritmin muodostamisessa. Koulutusdatan hyödyntämi-

sen jälkeen lajittelu pystytään suorittamaan halutulle datalle. Menetelmät käyttävät EEG:stä laskettuja tilastollisia ominaisuuksia luokittelun toteuttamiseen. Esikäsitelyssä käytetään usein suodatinta sekä signaali jaetaan viiteen eri taajuuskaistaan. Yleisimmät menetelmissä käytetyt taajuuskaistat ovat alfa, beeta, delta, gamma ja theeta. Luokittelussa on käytetty 10 sekunnin pituisia ajallisia kehyksiä apnea- ja ei-apneajaksojen erottamiseen. Menetelmissä käytetty data on mitattu PSG-laitteella, joka on useissa tapauksissa löydettävissä julkisista tietopankeista. Mittauksessa käytettyjen elektrodiparien määrä on kaksi ja niiden paikat ovat usein kuvan 3.1 mukaan C3-A2 ja C4-A1.

Khurshedien et al. tutkimuksessa esitettiin päätöspuu-algoritmi (*engl.* decision tree, DT) uniapnean tunnistamiseen. Signaalin esikäsitelyssä käytettiin IIR Butterworth-suodattinta (*engl.* infinite impulse response Butterworth filter). Jokaiselta taajuuskaistalta erotettiin neljä ominaisuutta, joilla pystyttiin ilmentämään EEG-signaalin vaihtelua. DT:ssä vuokaavion jokainen solmu merkitsi testiä tietylle ominaisuudelle, jonka perusteella ominaisuus siirrettiin alempiin solmuihin kunnes se saavutti luokkatunnisteen. DT sai tarkkudeksi 99,2 %. Samassa tutkimuksessa käytettiin myös random forest -luokitinta (*engl.* random forest, RF). RF-luokitin perustuu useiden päätöspuiden yhdistämiseen [21]. Siinä koulutusdatalla saadut päätöspuiden tulokset yhdistetään bootstrap-aggregaattipäätöspuun (*engl.* bootstrap-aggregated decision tree) avulla, ja lopullinen luokittelu tehdään parhaiten suoriutuvalla luokittelijalla [22]. RF saavutti tarkkuuden 99,68 % [21].

Rajeswarin et al. tutkimuksessa käytettiin myös RF-luokitinta, ja sen tarkkuudeksi saatiin 60 %. Erotten edellisessä kappaleessa mainittuun tutkimukseen tässä tutkimuksessa erotetut luokat olivat normaalit ja uniapneapotilaat apneajaksojen sijaan. Esikäsitely tehtiin kapealla kaistanestosuodattimella (*engl.* notch filter) 30 sekunnin pituisista EEG-signaalin kehyksistä. Ominaisuudet laskettiin EEG:n taajuuskaistoista sekä niiden välisistä suhteista. Toisena luokittelijana tutkimuksessa

käytettiin tukivektorikonetta (*engl.* support vector machine, SVM), joka muodostaa koulutusdatasta tukivektoreita ominaisuuksien avulla. Näistä tukivektoreista muodostetaan hypertaso, joka luo eron kahdelle eri luokalle. SVM:n tehon parantamiseksi voidaan käyttää ydinfunktioita tehostamaan luokittelua. Tässä tutkimuksessa käytettiin lineaarista funktiota, radiaalista perusfunktiota (*engl.* radial basis function) sekä toisen ja kolmannen asteen polynomifunktioita. Näistä parhaimmaksi osoitettiin toisen asteen polynomifunktion käyttäminen. SVM sai tutkimuksessa tarkkuusarvoksi 90 %. [22]

Onargan et al. esittivät empiiristä moodihajotelmaa (*engl.* empirical mode decomposition, EMD) ja intrinsisiä moodifunktioita (*engl.* intrinsic mode function, IMF) hyödyntävän menetelmän. EMD on laajennus signaalin erottelumenetelmästä, jossa hyödynnetään monimuuttujaisia IMF:iä. EEG-signaalin jokaiselle taajuuskaistalle laskettiin viisi eri IMF:ää. Menetelmän luokittelu perustui signaalista erotettuihin kolmeen eri tapahtumaan: apneoita edeltäviin hetkiin, apneahetkiin ja apneoiden jälkeisiin hetkiin. Luokitteluun käytettiin monia eri luokittelijoita ja saatuja tuloksia vertailtiin keskenään. Gaussisella SVM:llä saatiin parhaat tulokset, kun luokitteluun käytettiin apneahetken ja apnean jälkeisen hetken tietoja. Tarkkuusarvoksi menetelmälle saatiin 71,9 %. [23]

Wangin et al. tutkimuksessa esitetyssä diskreettiä wavelet-muunosta (*engl.* discrete wavelet transform, DWT) hyödyntävässä menetelmässä suoritettiin aika-taajuusanalyysi (*engl.* time-frequency analysis). Menetelmässä käytettiin kahdella elektrosiparilla mitattua EEG-signaalia, esikäsittelyssä Butterworth-suodatinta sekä viiden sekunnin ajallisia kehyksiä. Tämän jälkeen DWT:llä suoritettiin aika-taajuusanalyysi apnea- ja hypoapneajaksojen tunnistamiseksi. Ominaisuuksien valinta ja lopullinen luokittelu tehtiin SVM-RFE-algoritilla (*engl.* support vector machine recursive feature elimination algorithm), joka perustuu vähemmän hyödyll-

listen ominaisuuksien poistamiseen luokittelun edetessä. Menetelmä saavutti tarkkuuden 94,33 %. [2]

Kolmikanavaista EEG-signaalia hyödyntävässä Shahin et al. tutkimuksessa 10 sekunnin ajalliset kehykset jaettiin vielä yhden sekunnin pituisiin kehyksiin. Taajuuskaistoista erotettiin ajallisia ja spektraalisia ominaisuuksia luokittelua varten. Luokittelijoina käytettiin DT:tä ja RF:ää. Lisäksi tutkimuksessa käytettiin Naive Bayes -luokittelijaa (*engl.* Naive Bayes classifier, NB-classifier) sekä K-lähimmän naapurin luokittelijaa (*engl.* K-nearest neighbors classifier, KNN-classifier). NB on Bayesin lauseeseen perustuva todennäköisyyslukittelija, joka perustuu ominaisuuksien riippumattomuuteen. KNN luokittelee datan verraten sitä koulutusdatan datapisteiden etäisyyksiin ja löytämällä lähimmän samankaltaisen datapisteen eli niin sanotun naapurin. NB saavutti kyseisen tutkimuksen vertailussa korkeimman tarkkuusarvon, 82,76 %. [25]

Aqueelin et al. kehittämässä menetelmässä hyödynnettiin painotettua KNN-algoritmia, joka on edistyneempi versio perinteisestä KNN:stä. Siinä datapisteille annetaan eri painoarvot riippuen niiden etäisyyksistä toisiinsa. Luokittelu perustui apnea- ja ei-apneajaksoihin. Aluksi EEG-signaali esikäsiteltiin IIR Butterworth-suodattimella ja jaettiin delta-, theeta-, alfa-, sigma- ja beeta-taajuuskaistoihin. Menetelmässä ominaisuudet laskettiin Shannonin entropian (*engl.* Shannon's entropy) ja log-energiaentropian (*engl.* log energy entropy) avulla. Tutkimuksessa käytettiin kaksikanavaista EEG-signaalista laskettua keskiarvoa, joka ilmensi käytännössä yksikanavaista signaalia. Painotettu KNN saavutti tarkkuuden 94,46 %. [26]

Guptanin et al. tutkimuksessa käytettiin ensemble-DT-luokittelijaa. Ensemble-DT yhdistää päätöspuita kuten RF-luokittelija sekä lisäksi se hyödyntää bagging-tekniikkaa, jossa koulutusdataa toistetaan algoritmille uudelleen paremman luokittelun saavuttamiseksi. Tutkimuksessa EEG-signaali käsiteltiin aluksi IIR Butterworth-suodattimella sekä jokaisesta ajallisesti erotetusta taajuuskaistasta erotettiin neljä

ominaisuutta kuvaamaan apnea- ja ei-apneajaksoja. Ensemble-DT saavutti tarkkuuden 95,10 %. [24]

4.2 Neuroverkkoihin perustuvat menetelmät

Neuroverkkoihin perustuvilla menetelmillä on lähteiden [27], [28], [29], [30], [31], [13], [32], [33], [34], [35], [36] ja [37] perusteella yhteistä neuroverkon kouluttaminen erillisellä koulutusdatalla ennen varsinaista luokittelua. Mallit perustuvat ominaisuuksien erotteluun erilaisin menetelmin. Useimmissa menetelmissä käytettiin PSG:llä mitattua EEG-signaalia. Signaalista hyödynnettiin yhtä elektrodikanavaa kuvan 3.1 mukaan paikoilta C4-A1 tai C3-A1. Menetelmissä signaalia ei yleensä jaettu taajuuskaistoihin, vaan EEG-signaali syötettiin ominaisuuksien valinta-algoritmillemme sellaisenaan. Signaali jaettiin ajallisiin kehyksiin, jotka olivat usein 30 sekunnin pituisia. Lähes kaikissa menetelmissä EEG-signaalista luokiteltiin apnea- ja ei-apneajaksoja.

Neuroverkot ovat tekoälyverkkoja, jotka matkivat aivokuoren neuronien hierarkiaa. Barnesin et al. tutkimuksessa käytettiin konvoluutioneuroverkkoa (*engl.* convolutional neural network, CNN) uniapnean tunnistamiseen EEG-signaalista. CNN on tekoälyverkko, jossa konvoluutiokerrokset erottavat datasta olennaiset piirteet, jonka jälkeen täysin kytketyt kerrokset yhdistävät ne ja tuottavat lopullisen luokittelun. CNN:ssä ominaisuudet tunnistetaan signaalista muotona eli neuroverkko oppii harjoittelun aikana tunnistamaan signaalin muodosta luokittelun kannalta hyödylliset ominaisuudet. Menetelmässä esitetty CNN sisälsi kolme konvoluutiokerrosta. Ajallisista 30 sekunnin kehyksistä etsittiin 10 sekunnin apneajaksoja. Tarkkuudeksi ehdotettu CNN-malli sai 69,9 % [27]. Bonnerin et al. tutkimuksessa uniapnean luokitteluun käytettiin ajallista konvoluutioneuroverkkoa (*engl.* temporal convolutional neural network, TCNN). TCNN pystyy CNN:stä poiketen tallentamaan ajallisia suhteita ja muotoja peräkkäisestä datasta. TCNN saavutti tarkkuuden 85 % [28].

Mahmudin et al. tutkimuksessa esitettiin EEG-signaalin alikehyksiä hyödyntävä menetelmä, jossa käytettiin täysin konvolutiivista neuroverkkoa (*engl.* fully convolutional neural network, FCNN). Tutkimuksessa FCNN:ää käytettiin erottamaan ominaisuuksia raa'asta EEG-datasta koostuvista yhden sekunnin ajallisista kehyksistä, joista muodostettiin viiden peräkkäisen alikehyksen sarjoja apnea- ja ei-apneajaksojen tunnistamiseksi. FCNN:n koulutusvaiheessa syötettyjen ominaisuuksien määrää ei ole rajattu, toisin kuin CNN:ssä. FCNN:llä saadut ominaisuudet yhdistettiin ja käsiteltiin monia kerroksia sisältävässä syväneuroverkossa (*engl.* deep neural network, DNN). Tämän avulla saatiin tietoa yksittäisten alikehysten piirteisistä ja lopullinen luokittelu voitiin suorittaa yhdistämällä kehykset globaaliksi ominaisuusvektoriksi (*engl.* global feature vector). Tämä ominaisuusvektori syötettiin tiheälle luokittelijalle (*engl.* dense classifier), joka optimoi FCNN:llä saatuja ominaisuuksia apneajaksojen tunnistamiseksi. Menetelmän tarkuusarvo oli 80,2 %. [29]

Taranin et al. tutkimuksessa hyödynnettiin Hermiten funktioihin (*engl.* Hermite functions, HF) pohjautuvaa adaptiivista hajotelmaa. EEG-signaalin sopivan esityksen valitsemiseksi käytettiin evoluutiotekniikoita (*engl.* evolutionary techniques), joista parhaiten suoriutui ABC-algoritmi (*engl.* artificial bee colony algorithm) [30]. ABC-algoritmi on parviällyyn perustuva optimointimenetelmä, joka soveltuu hyvin monimutkaisen EEG-signaalin käsittelyyn [38]. ABC:n avulla valittiin sopivimmat ominaisuudet luokittelua varten. Aluksi erotettiin 14 ominaisuutta apnealuokkien ja kontrolliluokkien erottamiseksi, mutta lopulta ominaisuuksien määrä vähennettiin kuuteen. Ominaisuudet syötettiin kahdelle eri luokittelijalle, joista paremmin suoriutui ELM (*engl.* extreme learning machine) tarkkuudella 99,53 %. ELM on yksikerroksinen neuroverkko, joka perustuu piilotettuun kerrokseen mahdollistaen tulosvektorin nopean laskennan [30].

Tancin et al. tutkimuksessa esitettiin residuaalineuroverkko (*engl.* residual neural network, ResNet) uniapnean luokitteluun. ResNet pystyy oppimaan monimut-

kaisempia kuvioita, ja se on siten tehokkaampi neuroverkko kuin CNN. Tutkimuksessa käytettiin ResNet64:ää, joka sisälsi 64 residuaalikerrosta. Menetelmä perustuu residuaalilohkojen yhdistämiseen. ResNet-mallien etuja ovat koulutuksen yksinkertaisuus, verkon laajentaminen, siirto-oppimiskyky sekä taaksepäin sopeutumiskyky. Tarkkuudeksi ResNet64:lle saatiin 93 %. [31]

Samassa Tancin et al. tutkimuksessa sekä samalla datalla esitettiin myös kaksi YOLO-mallia (*engl.* you only look once). YOLO-mallit perustuvat konvoluutiokerroksiin. Ensin mallissa tunnistetaan ominaisuudet signaalista. Ne tallennetaan ja lähetetään syvälle kerrokselle, jossa niitä käytetään luokittelutunnisteina. YOLOv8 on parannettu versio YOLOv5:stä, ja siihen on lisätty edistyneempiä ominaisuuksia ja optimointeja. YOLOv8:n parempi teho perustuu pienempään määrään parametreja, joka samalla parantaa kerrosten välistä tiedonvaihtoa. Mallissa on myös parannettu koulutustietojen monimuotoisuutta. Tarkkuusarvot YOLOv5:lle ja YOLOv8:lle olivat 88,2 % ja 93,7 %. [31]

Zhangin et al. tutkimuksessa esitetty LPDVG-malli (*engl.* limited penetrable difference visibility graph) pohjautuu näkyvyysgraafialgoritmiin (*engl.* visibility graph algorithm, VG-algorithm). VG-algoritmin avulla voidaan esittää tilastolliset piirteet geometrisessa muodossa aikasarjoina, jolla voidaan kvantifioida pitkän aikavälin korrelaatioita. VG soveltuu hyvin EEG:n epälineaaristen ominaisuuksien selvittämiseen. EEG-signaali oli mitattu kuudella elektrodilla ja se esikäsiteltiin aluksi äärellisen impulssivasteen kaistanpäästösuodattimella (*engl.* finite impulse response bandpass filter). Mallissa esikäsitelty signaali jaettiin delta-, theeta-, alfa- ja beeta-taajuuskaisoihin nopean Fourier-muunnoksen (*engl.* fast Fourier transform) avulla sekä ajallisesti viiden sekunnin pituisiin kehyksiin. Uniapneatapahtumien aikana EEG-signaalin taajuuskaista siirtyi delta-taajuuskaistalta alfa- ja theeta-kaistoille. Tutkimuksessa luokittelua varten muodostettiin graafinen konvoluutioverkko (*engl.* graph convolutional network, GCN), joka soveltui hyvin LPDVG:n graafisten se-

kvenssien käsittelyyn. GCN on CNN:n kaltainen, mutta se käyttää syötteenään graafista dataa ja tässä tapauksessa se koostuu kahdesta konvoluutiokerroksesta. Tutkimuksen tuloksena todettiin LPDVG-indeksin kasvavan uniapnean asteen kasvaessa. Tällöin potilaan koko aivot toiminta häiriintyi enemmän, ja EEG:n theeta-aaltojen aktiivisuus lisääntyi. Tarkkuudeksi LPDVG-menetelmä sai 82,95 %. [13]

LCNN-GCNN-malli (*engl.* local convolutional neural network global convolutional neural network) on Khanin et al. tutkimuksessa esitetty menetelmä, joka erottaa ominaisuuksia paikallisesti ja yhdistää ne kokonaiskuvan muodostamiseksi. Ajalliset 10 sekunnin mittaiset kehykset jaettiin alfa-, beeta-, delta-, theeta- ja sigma-taajuuskaistoihin. LCNN-GCNN-malli sisältää paikallisen CNN:n (*engl.* local convolutional neural network), globaalin CNN:n (*engl.* global convolutional neural network) ja lopuksi tiheän CNN-luokittelijan (*engl.* dense neural network classifier). Paikallinen CNN erottaa ominaisuudet kustakin kehyksestä, jonka jälkeen kehykset yhdistetään ja käsitellään globaalissa CNN:ssä. Globaalin CNN:n lopputuloksena saadaan ominaisuusvektori käyttämällä globaalia keskiarvojen yhdistämiskerrosta, joka syötetään tiheälle CNN-luokittelijalle. Tarkkuudeksi malli sai 80,05 %. [32]

Wangin et al. kehittämä BiLSTM-malli (*engl.* bidirectional long and short-term memory network) perustuu kaksisuuntaiseen pitkä- ja lyhytkestoiseen muistiverkoon. EEG-signaali suodatettiin IIR-suodattimella. Mallin LSTM-osa (*engl.* long and short-term memory) on kaksikerroksinen, ja se käsittelee eteen- ja taaksepäin suuntautuvaa dataa. Tämän ansiosta mallilla on samaan aikaan pääsy sekä aiempaan että tulevaan dataan. BiLSTM-malli saavutti tarkkuuden 84,21 %. [33]

Mahmudin et al. tutkimuksessa esitetyssä mallissa käytettiin räätälöityä syväkonvoluutio-BiLSTM-neuroverkkoa (*engl.* deep convolutional-BiLSTM neural network, CNN-BiLSTM). Esikäsittelyssä signaali hajotettiin käyttäen variaatiomoodihajotus algoritmia (*engl.* variational mode decomposition, VMD), joka erottaa EEG-signaalin taajuuskaistoihin keskitaajuuden perusteella. Tämän jälkeen signaa-

lin ajallisten ominaisuuksien poimimiseen käytettiin FCNN:ää. Lopuksi BiLSTM-malli käsitteli ja luokitteli datan saaden parhaimmillaan tarkkuuden 93,22 % [34].

Kolmas samankaltainen menetelmä CNN-BiLSTM-RNN-malli esitettiin Spandan et al. tutkimuksessa. Malli yhdistää CNN:n, BiLSTM:n ja toistuvan neuroverkon (*engl.* recurrent neural network, RNN) kerrokset. RNN mallintaa peräkkäisiä malleja apneatapahtumien tarkkaan luokitteluun, eli se perustuu kykyyn muistaa edellistä dataa. Tutkimuksessa CNN-BiLSTM-RNN-malli sai tarkkuudeksi 87,8 % [35].

Nandakumarin et al. tutkimuksessa automaattiseen uniapnean tunnistamiseen kehitetty IEEO:ta (*engl.* improved eurasian oystercatcher) ja HCEAN:ää (*engl.* hybrid convolution efficient attention network) yhdistävä malli perustuu sektogrammikuviin. Menetelmä hyödynsi kolmekanavaista EEG-signaalia. Signaali käsiteltiin suodatintekniikoilla ja jaettiin delta-, theeta-, alfa-, beeta- ja gamma-taajuuskaistoihin. Sektogrammin ominaisuudet erotettiin lyhytaikaisen Fouriermuunnoksen avulla. Tämän jälkeen käytettiin DRBM:ää (*engl.* deep restricted Boltzmann machine) ominaisuuksien erottamiseen. Ominaisuudet yhdistettiin käyttäen IEEO-algoritmia, joka arvioi ominaisuuksien hyödyllisyyttä ja antoi sen mukaan ominaisuuksille eri painoarvoja. Tämän jälkeen saadut ominaisuudet syötettiin HCEAN-luokittelijaan, joka hyödyntää luokittelussa EAN:ää (*engl.* efficient attention network). Malli saavutti tutkimuksessa tarkkuuden 95,9 %. [36]

Wanin et al. tutkimuksessa kehitetty transformer-pohjainen CNN:ää hyödyntävä malli yhdistää CRF:ää (*engl.* conditional random fields) ja itsetarkkailumekanismeja. Mallissa EEG-signaali käsiteltiin moniytimisellä CNN:llä ominaisuuksien erottamiseksi. Saatuja ominaisuuksia kalibroitiin uudelleen paremman unen vaiheiden tunnistamiseksi. Transformer-pohjainen moduuli mallintaa tallennetun EEG-signaalin eri segmenttien välisiä ajallisia suhteita. CRF:n avulla pyritään mallintamaan ajalliset dynamiikat ja parantamaan mallin kykyä luokitella unen vaiheet tarkasti. Tä-

mä on hyödyllistä, sillä vakavaa uniapneaa sairastavilla esiintyy tiheämpiä siirtymiä unen vaiheiden välillä. Transformer-malli saavutti tarkkuuden 81,6 %. [37]

4.3 Muihin menetelmiin perustuvat menetelmät

Tässä alaluvussa tarkastellaan menetelmiä, jotka yhdistävät useita algoritmeja ja lähestymistapoja. Kyseiset menetelmät eivät perustu suoraan perinteiseen koneoppimiseen tai neuroverkkoihin, vaan hyödyntävät muita lähestymistapoja. Mukana on myös menetelmiä, jotka on kehitetty vain obstruktiivisen uniapnean tunnistamiseen.

Alamin et al. kehittämä FPGA-pohjainen-malli (*engl.* field programmable gate array) hyödynsi esikäsittelyssä Butterworth-suodatinta. Jokaisesta ajallisesta aikaistasta erotettiin ominaisuusvektorin muodostamista varten seitsemän tilastollista ominaisuutta. Apnean aikana havaittiin EEG-signaalin kokonaisenergian tai -tehon purkautumista ja pysähtymistä, erityisesti korkeimmilla taajuuskaistoilla. Lineaarisen tukivektorikoneen (*engl.* linear support vector machine, LSVM) syötteeksi valittiin neljä parhaiten sijoittunutta ominaisuutta. LSVM on SVM:n alatyyppejä ja se on suunniteltu erityisesti lineaarisesti erotettavissa oleville tietojoukoille. Tarkkuudeksi menetelmä sai 94 %. [39]

Ramkumar et al. kehittivät ANFIS-ICOA-mallin (*engl.* adaptive neuro-fuzzy interface with an improved cheetah optimization algorithm) uniapnean vakavuuden diagnosoimiseen EEG-signaalista. Menetelmässä signaalin esikäsittely suoritettiin IIR Butterworth-suodattimella ja Hilbert-Huang-muunnoksella (*engl.* Hilbert-Huang transform). Tämän jälkeen signaali jaettiin viiteen taajuuskaistaan wavelet-pakettien hajotelmalla (*engl.* wavelet packet decomposition). Tilastollisia ominaisuuksia erotettiin kahdeksan kappaletta. ANFIS-ICOA luokitteli datan kolmeen eri luokkaan: normaaleihin, lieviin sekä vakaviin uniapnealuokkiin. Mallin ANFIS-osassa lasketaan ominaisuuksien perusteella pistemäärä, jonka avulla luokittelu suorite-

taan. ICOA-osa valitsee parametrit optimaalisesti, mikä parantaa ANFIS-osan suorituskykyä. Mallin tarkkuus uniapnean havaitsemiseen oli 98,26 %. [40]

Khanin et al. tutkimuksessa esitetty IESOSAD-malli (*engl.* intelligent expert system for the OSA detection) on obstruktiivisen uniapnean tunnistamiseen kehitetty malli. Tilastolliset ominaisuudet sekä viisi taajuuskaistaa erotettiin DWT:llä. Yksikanavainen EEG-signaali esikäsiteltiin vielä Gaussian-suodattimella (*engl.* Gaussian filter) kohinan poistamiseksi, isolation-forest-mallilla (*engl.* isolation forest, IF) poikkeamien havaitsemiseksi ja ABC-algoritilla epäolennaisten ominaisuuksien poistamiseksi. IESOSAD-mallissa luokitteluun käytettiin ekstra-puu-luokitinta (*engl.* extra tree, ET), joka perustuu joukkotekniikkaan yhdistäen päätöspuiden kokonaisuuksien ennusteet. ET-luokittelija luokitteli datan apnea- ja ei-apnealuokkiin. IESOSAD-malli sai tarkkuudeksi 88,12 % [38]. EESOSAD-I (*engl.* ensemble expert system for obstructive sleep apnea detection-I) keskittyy myös obstruktiivisen uniapnean tunnistamiseen EEG-signaalista. Verrattuna IESOSAD-malliin, EESOSAD-I:ssa ei käytetä ABC:tä. Muuten menetelmät ovat lähes samanlaisia. EESOSAD-I:n keskimääräinen tarkkuus oli 82 % [41].

EESOSAD-II-menetelmä on edistyneempi versio EESOSAD-I-menetelmästä. EESOSAD-II:n alkuvaiheet ovat samat kuin EESOSAD-I:ssa. Erona on ominaisuuksien valintaan käytetty algoritmi, joka tässä mallissa on RFE (*engl.* recursive feature elimination, RFE). RFE on mukautuva erilaisten koneoppimismallien kanssa, mikä helpottaa integrointia ja mahdollistaa sen hyödyntämisen valitun obstruktiivisen uniapnean tunnistusmallin erityistarpeisiin. Tarkkuudeksi EESOSAD-II sai 86 % [42]. Khanin et al. kehittivät OISOSA-mallin (*engl.* optimized intelligent system for obstructive sleep apnea), joka on hyvin samankaltainen kahden edellisen menetelmän kanssa. Erona edellisiin malleihin tässä mallissa käytettiin PSO-algoritmia (*engl.* particle swarm optimization algorithm) ominaisuuksien optimoimiseksi. OISOSA-malli saavutti tarkkuuden 86 % [43].

Gholamin et al. tutkimuksessa kehitetyssä mRMR-algoritmissa (*engl.* maximal relevance minimal redundancy) signaali jaettiin kuuteen taajuuskaistaan äärellisen impulssivasteen kaistanpäästösuodattimella. Tämän jälkeen signaali jaettiin viiden sekunnin kehyksiin ja jokaisesta taajuuskaistasta erotettiin 12 eri tavoin laskettua entropiaa signaalin monimutkaisuuden ilmentämiseksi. Lopuksi mRMR-algoritmi valitsi luokittelun kannalta tehokkaimmat ominaisuudet ja poisti häiriötä tai epäoleellista tietoa sisältävät ominaisuudet. Menetelmä priorisoi ominaisuuksia niiden merkityksen perusteella maksimoimalla relevanssin eli oleellisuuden kohdeluokalle ja minimoimalla redundanssin eli toisteisuuden. Lopuksi ominaisuudet syötettiin radiaalista perusfunktiota ydinfunktiona käyttävään SVM-luokittimeen apneajaksojen luokitteluksi. Tutkimuksessa todettiin alfa-taajuuskaista hyödyllisimmäksi uniapnean tunnistamisen kannalta. Tarkkuudeksi mRMR-algoritmi sai 87,94 % ja siinä hyödynnettiin kolmea kaistaa EEG-signaalista. [44]

Hsiehin et al. kehittämä TSmRMR-malli (*engl.* threshold search mRMR) on jatkokehitemä mRMR-algoritmista. Viisi taajuuskaistaa erotettiin IIR Butterworth-suodattimella sekä signaali jaettiin 10 sekunnin kehyksiin. Ominaisuuksia eroteltiin 50 kappaletta. Tässä mallissa ennen datan syöttämistä mRMR-algoritmille käytettiin kynnysarvohakumenetelmää. Tämä poisti ongelman mRMR-algoritmin korkean tai matalan relevanssin ja redundanssin samanaikaisesta esiintymisestä sekä esti siten ominaisuuksien kumoutumisen. Luokittelu suoritettiin KNN:llä. Tutkimuksessa käytettiin 10-kertaista ristivalidointia ylikoulutuksen riskin vähentämiseksi. TSmRMR-malli saavutti tarkkuuden 96,67 %. [45]

Bhaleraon et al. tutkimuksessa esitettiin swarm-sparse decomposition -menetelmä (*engl.* swarm-sparse decomposition method, SSDM), joka on adaptiivinen aika-taajuusanalyysimenetelmä. Menetelmä yhdistettiin eri luokittimien kanssa ja niistä todettiin parhaimmiksi SSDM-TFR-CNN ja SSDM-FF-LSTM uniapnean luokittelussa tarkkuusarvoilla 96,24 % ja 95,86 %. SSDM-TFR-CNN:ssä SSDM:llä

saadut apnea- ja ei-apnealuokkien aika-taajuusesitykset syötettiin erilaisille CNN:ille ja niistä valittiin parhaiten suoriutuva. SSDM-FF-LSTM:ssä erotettiin 72 eri ominaisuutta, joista valittiin merkittävimmät ja nämä syötettiin BiLSTM-luokittelijaan. [46]

4.4 Menetelmien vertailu ja analysointi

Lähes kaikissa menetelmissä uniapnean luokittelu suoritettiin, joko erottamalla EEG-signaalista apneahetket ja normaalin hengityksen hetket lyhyistä ajallisista kehyksistä tai suoraan kouluttamalla luokittelija erottamaan uniapneapotilaat ja terveet potilaat koko EEG-signaalista. Apneoiden ja normaalin hengityksen erottaminen on diagnosoinnin kannalta hyödyllistä, sillä sen avulla voidaan määrittää potilaan AHI ja tutkia uniapnean vakavuutta.

Eri menetelmien tarkkuusarvoissa oli paljon vaihtelua, mikä käy ilmi taulukosta 4.1. Tarkkuusarvot olivat laskettu menetelmissä eri tavoilla. Ne antavat suuntaa menetelmien tarkkuudesta, mutta eivät ole suoraan vertailukelpoisia keskenään. Vertailukelpoisuuden ongelmallisuus johtuu lasketavan lisäksi myös käytetyn datan määrän vaihtelusta tutkimusten välillä. Osassa tutkimuksista oli käytetty suuria määriä EEG-dataa eri potilailta ja monista eri tietokannoista. Toisissa menetelmissä käytettiin alle kymmenen potilaan tietoja ja otanta jäi hyvin suppeaksi. Joissakin tutkimuksissa dataa ei oltu eritelty tarkasti. Tarkkuusarvojen vertailua hankaloitti myös tutkimuksissa luokiteltujen luokkien erot. Menetelmiä arvioitiin tarkkuusarvon lisäksi myös muilla suureilla, mutta ne vaihtelivat suuresti eri tutkimusten välillä.

RF- DT-, HF-ELM- sekä TSmRMR-menetelien kohdalla käytettiin täysin tai osittain samaa dataa [47] luokittelussa. Kyseisten menetelmien tarkkuusarvot olivat korkeita, vaikka menetelmät erosivat toisistaan. Transformer-, IESOSAD-, EESOSAD-I-, EESOSAD-II- ja OISOSA-menetelmät käyttivät kaikki samaa dataa [48] ja näistä parhaiten tarkkuudeltaan suoriutui IESOSAD. CNN-BiLSTM, CNN-

Taulukko 4.1: Menetelmien tarkkuudet prosentteina (%), elektrodien lukumäärät (kpl) ja taajuuskaistojen lukumäärät (kpl) taulukoituna tarkkuuden mukaan suurimmasta pienimpään.

Menetelmä	Tarkkuus	Elektrodikanavat	Taajuuskaistat
RF [21]	99,68	2	5
HF-ELM [30]	99,53	3	-
DT [21]	99,2	2	5
ANFIS-ICOA [40]	98,26	-	5
TSmRMR [45]	96,67	3	5
SSDM-TFR-CNN [46]	96,24	3	5
IEOO-HCEAN [36]	95,9	3	5
SSDM-FF-LSTM [46]	95,86	3	5
Ensemble-DT [24]	95,1	2	5
KNN [26]	94,46	2	5
SVM-RFE [2]	94,33	2	5
LSVM [39]	94	2	5
YOLOv8 [31]	93,7	1	-
CNN-BiLSTM [34]	93,22	1	-
ResNet64 [31]	93	1	-
SVM [22]	90	2	5
YOLOv5 [31]	88,2	1	-
IESOSAD [38]	88,2	1	5
mRMR [44]	87,94	3	6
CNN-BiLSTM-RNN [35]	87,8	3	-
EESOSAD-II [42]	86	1	5
OISOSA [43]	86	1	5
TCNN [28]	85	1	-
BiLSTM [33]	84,21	2	5
LPDVG [13]	82,95	6	4
NB [25]	82,76	3	5
EESOSAD-I [41]	82	1	5
Transformer [37]	81,6	1	-
FCNN [29]	80,2	1	5
LCNN-GCNN [32]	80,05	1	5
EMD-IMF [23]	71,9	7	5
CNN [27]	69,9	1	-
RF [22]	66	2	5

BiLSTM-RNN ja HF-ELM käyttivät myös samaa dataa [49] ja näistä parhaiten suoriutui HF-ELM. Myös ensemble-DT-, FCNN-, LCNN-GCNN- sekä CNN-BiLSTM-menetelmät käytettiin täsmälleen samaa dataa [50] luokittelussa. Näitä menetelmiä

vertailtaessa voidaan todeta, että ensemble-DT ja CNN-BiLSTM-menetelmät ovat tarkempia uniapnean tunnistamisessa kuin LCNN-GCNN ja FCNN.

EEG:n mittauksessa käytettyjen elektrodien määrä vaihteli suurimassa osassa menetelmistä yhdestä elektrodiparista kolmeen. Aqueelin et al. tutkimuksessa käytettiin kahta elektrodikanavaa, jotka yhdistettiin yksikanavaiseksi laskemalla niiden ajallinen keskiarvo [26]. Taulukon 4.1 perusteella voidaan todeta, että yhtä elektrodikanavaa hyödyntävät menetelmät suoriutuivat keskimäärin huonommin kuin useampia elektrodikanavia käyttävät menetelmät. Yksikanavaista EEG-signaalia hyödyntävien menetelmien etuna on kuitenkin niiden soveltaminen laajemmasti kotona käytettävillä laitteilla saatavaan dataan.

Ominaisuuksien avulla saadaan arvokasta tietoa aivojen tilasta sekä apneoiden ja normaalin hengityksen välisistä eroista [39]. Erityisesti entropia-arvojen hyödyntäminen osoittautui hyödylliseksi. Koska EEG-signaali on epälineaarinen, entropian avulla pystytään ilmentämään epäjärjestyksen määrää ja saamaan signaalista hyödyllistä tietoa apnea- ja ei-apneajaksojen luokittelua varten [44]. Luokittelualgoritmeille syötettyjen ominaisuuksien määrä vaikutti suuresti saatuihin tuloksiin. Suurella määrällä ominaisuuksia ei aina saavutettu parempaa luokittelutarkkuutta.

Ominaisuuksien valintaan käytettiin monissa menetelmissä erilaisia valinta-algoritmeja ennen niiden syöttämistä luokittelualgoritmile. Tämä vaikutti positiivisesti tuloksiin, sillä monet ominaisuudet sisälsivät epäoleellista tai tulosta vääristävää tietoa. Toisaalta ongelmaksi saattoi koitua hyödyllisten tietojen karsiutuminen pois, mutta tämä pystyttiin estämään luokittelijan paremmalla koulutuksella. Aqueelin et al. tutkimuksessa eri menetelmiä vertailtaessa todettiin, että yhtä ominaisuutta käyttävä menetelmä suoriutui luokittelussa paremmin kuin monia ominaisuuksia käyttävä menetelmä [26]. Toisaalta tässä tapauksessa ei käytetty ominaisuuden valintaan menetelmää, vaan se oli ennalta valittu. Myös Nandakumarin et al. tutkimuksessa ominaisuuksien valinnan parantaminen vaikutti positiivisesti luo-

kittelun tulokseen ja tarkkuuteen [36]. Wangin et al. tutkimuksessa taas todettiin BiLSTM-mallin eduksi datan syöttäminen luokittelijalle ilman ominaisuuksien valitsemista verrattuna muihin menetelmiin. Tämä teki menetelmästä kevyemmän, joka osoittautui mallin eduksi vertailtaessa menetelmiin tarvittavaa laitteistoa [33].

Samaa luokittelualgoritmia käyttävät menetelmät saivat osassa tapauksista hyvin erilaisia tarkkuusarvoja. Taulukosta 4.1 huomataan, että paras ja huonoin tarkkuusarvo saatiin samalla luokittelijalla, RF-luokittelijalla. Khursheedin et al. tutkimuksessa RF:lle syötettiin eri ominaisuuksia, jotka olivat valittu valintamenetelmien avulla luokittelua varten [21]. Rajeswarin et al. tutkimuksessa RF:lle syötettiin taas eri ominaisuudet ilman niiden hyödyllisyyden arvioimista [22]. Jälkimmäinen menetelmä sai huomattavasti huonomman tarkkuusarvon kuin menetelmä, jossa ominaisuudet valittiin erilaisten valinta-algoritmien avulla ennen RF-luokittelijalle syöttämistä.

Neuroverkoissa muistin hyödyntäminen osoittautui hyväksi ominaisuudeksi luokittelun kannalta. Tällöin jo luokiteltua dataa pystyttiin hyödyntämään seuraavissa luokitteluissa, eikä luokittelu perustunut vain koulutusdatasta opittuihin ominaisuuksiin. Muistia hyödyntävät menetelmät ottivat aiemmat luokittelut huomioon luokittelun edetessä. Pelkät neuroverkot eivät kuitenkaan saavuttaneet kovin hyviä tarkkuusarvoja. Kun neuroverkkoja yhdistettiin, esimerkiksi SSDM-TFR-CNN-menetelmässä eri ominaisuuksien erottelemiseen EEG-signaalista, tulokset olivat huomattavasti parempia.

Neuroverkkojen ylikoulutusta pyrittiin estämään monessa menetelmässä. Mahmudin et al. tutkimuksessa testattiin FCNN-luokittelijaan eri pituisia ajallisia kehyksiä. Siinä todettiin, että tulokset paranivat kehyksen lyhentyessä viiteen sekuntiin asti, jonka jälkeen luokittelija alkoi ylisovittua. Liian pitkä kehys vaati myös suhteellisesti suuremman verkon, mikä johti heikompaan suorituskykyyn [29]. Myös luokittelijan ylikouluttuminen johtaa suorituskyvyn heikkenemiseen erityisesti uusissa

ja ennalta arvaamattomissa tapauksissa sekä heikentää siten yleistymistä [31]. Signaalin jakaminen ajallisiin kehyksiin mahdollistaa lisäksi virheiden tunnistamisen ja vähentää niiden merkitystä. Virhe kohdistuu tällöin vain pieneen pätkään analysoitavasta signaalista eikä se vaikuta tällöin muihin kehyksiin lainkaan [32]. Ajallisten kehysten hyödyntäminen oli hyödyllistä erityisesti menetelmissä, joissa luokiteltiin apnea- ja ei-apneajaksoja.

Taulukosta 4.1 huomataan, että lähes kaikissa menetelmissä hyödynnettiin EEG-signaalista viittä eri taajuuskaistaa. Viiden taajuuskaistan hyödyntäminen on monissa menetelmissä tarpeellista, sillä uniapneapotilailla EEG-aalloissa on paljon vaihtelua hereilläolon ja unen sekä normaalin hengityksen ja apneoiden johdosta. Osa menetelmistä ei hyödyntänyt taajuuskaistoja, vaan luokittelu tehtiin joko raa'an EEG-signaalin avulla tai käyttäen muita suodattimia. Taajuuskaistoihin jakaminen tai raa'an EEG-signaalin hyödyntäminen riippui menetelmässä käytettävistä tekniikoista ja algoritmeista.

5 Pohdinta

EEG-signaalin hyödyntämisessä uniapnean tunnistamiseen on suuri potentiaali. EEG:n avulla pystytään tunnistamaan unen eri vaiheita ja niissä tapahtuvia muutoksia, joiden avulla saadaan hyödyllistä tietoa uniapnean ja sen vakavuusasteen diagnosointiin. Automaattisten ja reaaliaikaisten menetelmien kehittämisellä on tärkeä rooli diagnosoinnin helpottamisessa. Tutkielman perusteella voidaan todeta, että hyödyllisiä ja tehokkaita menetelmiä on kehitetty paljon lähivuosina. Monet menetelmät ovat tehokkaita ja luotettavia, mutta niistä löytyy myös kehityksen kohteita.

Menetelmien vertailu osoittautui niiden erilaisuuden vuoksi haastavaksi. Tarkkuusarvoja vertailtaessa ongelmaksi koitui eroavaisuudet niiden laskutavassa tutkimusten välillä. Monissa menetelmissä toistui samankaltaisia algoritmeja, mutta tarkkuusarvot erosivat niiden välillä paljon toisistaan. Taulukon 4.1 arvoista nähdään, että osa menetelmistä sai lähes 100 % tarkkuuden. Erittäin korkea tarkkuusprosentti voi kertoa siitä, että testauksessa käytetty data on ollut hyvin suppea, eikä laajemmalla datalla päästäisi samoihin tarkkuusarvoihin. Liian korkea tarkkuusarvo saattaa herättää epäilyksen käytetyn datan valikoinnista.

Tutkielman perusteella ei pystytty nimeämään yhtä parhaiten suoriutuvaa tai tehokkaimpaa menetelmää. Monissa menetelmissä oli hyviä ominaisuuksia sekä haasteita. Osa menetelmistä saavutti paremman tarkkuuden, kun osa taas oli kevyempiä vähäisemmän parametrimäärän ansiosta. Yksinkertaisia ja perinteisiä menetelmiä räätälöitiin ja jatkokehitettiin uniapnean tunnistamiseen sopivammiksi, samalla

tehden niistä tarkempia ja tehokkaampia. Datassa, jota menetelmissä käytettiin, oli runsaasti eroja tutkimusten välillä, mikä teki vertailusta haastavaa. Tutkimuksissa käytetty data ja sen laajuus vaikuttavat paljon menetelmän luotettavuuteen. Hyvin siistillä ja valikoidulla datalla saadaan menetelmille korkeita tarkkuusarvoja, vaikka menetelmän toimivuutta ei voida taata käytännön tasolla tai toisella datalla.

Monessa tutkimuksessa mainittiin jatkokehitysmien ja -tutkimusten toteuttamisesta tulevaisuudessa. Tehokkaampien neuroverkkojen hyödyntämistä ehdotettiin kehityksen kohteena, ja siinä nähdään suuri potentiaali parempien menetelmien kehittämiseksi. Myös yhdellä elektrodikanavalla mitattu EEG mainittiin kehityksen kohteeksi vedoten kotimittauslaitteistojen yleistymiseen. Tämä helpottaa uniapnean tunnistamista lisäämällä unitutkimuksissa käytettävän laitteiston saavutettavuutta.

Pelkästään obstruktiivisen uniapnean tunnistamiseen on kehitetty erillisiä menetelmiä sen yksinkertaisemman diagnosoinnin ansiosta. Kuten 2 luvussa mainittiin sentraalisen ja sekamuotoisen uniapnean diagnosointi on monivaiheisempi prosessi, joten niiden kohdalla on hankalampi kehittää automaattisia ja pelkästään EEG:tä hyödyntäviä menetelmiä. Obstruktiivinen uniapnea voidaan diagnosoida pelkän AHI:n perusteella, joka saadaan kyseisillä menetelmillä selville.

PSG mittaa EEG:n lisäksi muitakin arvoja, ja niiden analysointi yhdessä EEG:n kanssa tuottaa parempia tuloksia diagnosoinnin kannalta. Diagnosoinnin tehokkuuden ja resurssien vähentämisen kannalta on kuitenkin tärkeää löytää automaattisia menetelmiä. Pelkkä EEG on hyvä lähestymistapa yksinkertaisten, yhteen arvoon perustuvien menetelmien kehittämiseksi. EEG mahdollistaa unen vaiheiden analysoinnin ja uniapnean tunnistamisen, kun taas muilla PSG-mittauksen arvoilla se voi olla yksinään vaikeaa. Tutkimuksissa ehdotettiin menetelmien kehittämistä hyödyntämällä EKG:tä tai EMG:tä EEG:n rinnalla. Eri menetelmistä saatujen arvojen yhdistämisellä saadaan tarkempia tuloksia, mutta mittaamiseen tarvitaan monimutkaisempi laitteisto ja datan käsittelyyn enemmän resursseja.

6 Yhteenveto

Tutkielman tavoitteena oli käydä läpi löydetyt EEG-signaalin käsittelyyn kehitetyt koneoppimismenetelmät uniapnean tunnistamiseksi vuosilta 2020–2025. Menetelmiä vertailtiin keskenään, sekä pohdittiin niiden hyödyllisyyttä ja tehokkuutta. Lisäksi pohdittiin menetelmien nykytilannetta ja tulevaisuutta.

Tutkimuskysymyksessä 1 pyrittiin selvittämään millaisia koneoppimismenetelmiä uniapnean tunnistamiseen tarvitaan EEG-signaalista. Pääpiirteittäin löydetyt menetelmät pystyttiin jakamaan perinteistä koneoppimista, neuroverkkoja sekä muita menetelmiä hyödyntäviin menetelmiin. Menetelmät hyödynsivät taajuuskaistoihin erottelua, eri ominaisuuksien määrittämistä sekä signaalin muodon hyödyntämistä luokittelussa. Osa menetelmistä hyödynsi lajittelussa käytettävien ominaisuuksien valitsemiseen erilaisia algoritmeja ja menetelmiä.

Yleisimpiä uniapnean tunnistamiseen käytettyjä koneoppimismenetelmiä EEG-signaaliin perustuen olivat neuroverkot, sekä perinteistä koneoppimista hyödyntävät mallit. Osa menetelmistä on keskittynyt hyödyntämään yksikanavaista EEG-signaalia, joka mahdollistaa yksinkertaisesta kotona tehtävästä mittauksesta saatavan EEG-signaalin analysoinnin, kun taas toiset menetelmät hyödynsivät useampaa EEG:n elektrodikanavaa. Menetelmät luokittelivat EEG-signaalista yleensä apnea- ja ei-apneajaksoja.

Tutkimuskysymyksen 2 tavoitteena oli tutkia koneoppimismenetelmien tehokkuutta. Tehokkuuden arviointi osoittautui haastavaksi menetelmien erilaisuuden

johdosta, eikä tutkielman tuloksena löydetty yhtä parhaiten suoriutuvaa menetelmää. Yleisesti voidaan todeta, että monella menetelmällä on hyviä puolia sekä puutteita. Menetelmiä, jotka suoriutuvat hyvällä tarkkuudella ja tehokkuudella uniapnean luokittelusta on kehitetty paljon. Yleistämällä hyvin suoriutuvia menetelmiä voidaan todeta, että menetelmät joissa hyödynnettiin luokittelussa käytettävien ominaisuuksien valintaan erilaisia algoritmeja osoittautuivat tehokkaiksi.

Tutkimuskysymyksessä 3 pyrittiin etsimään ongelmia ja virhearvioita, joita liittyy löydettyihin koneoppimismenetelmiin. Menetelmissä toistui samankaltaisia haasteita. Osassa menetelmistä luokittelua varten kerättyjen ominaisuuksien valikoinnissa saattoi poistua hyödyllistä tietoa sisältäviä ominaisuuksia. Tutkimuksissa käytetty vähäinen datan määrä väärästi myös saatuja tuloksia, ja siten esimerkiksi heikensi tarkkuusarvon luotettavuutta. Kaikissa menetelmissä ominaisuuksien valitsemiseen ei käytetty algoritmeja, vaan ne syötettiin luokittelijalle ilman niiden hyödyllisyyden arviointia. Tämä osaltaan saattoi vaikuttaa negatiivisesti tuloksiin, sillä mukaan joutui tällöin luokittelun kannalta haitallisia ominaisuuksia, jotka eivät liittyneet uniapnean luokitteluun. Luokittelualgoritmien ylikouluttautuminen oli myös haaste menetelmissä.

Tämä kirjallisuuskatsaus osoittaa, että EEG:n hyödyntämisessä uniapnean tunnistamiseen on paljon potentiaalia. Hyvin toimivia menetelmiä on jo kehitetty diagnosoinnin tehostamiseksi. Tulevaisuudessa menetelmien kehittämisessä on kuitenkin parannettavaa, jotta menetelmistä saadaan luotettavampia ja entistä tehokkaampia.

Lähdeluettelo

- [1] A. Honkanen, ”Uniapnea, unenaikaiset hengityskatkot”, *Duodecim Terveyskirjasto*, 2023. viitattu 16. lokakuuta 2025. url: <https://www.terveyskirjasto.fi/dlk00712>.
- [2] Y. Wang, S. Ji, T. Yang, X. Wang, H. Wang ja X. Zhao, ”An Efficient Method to Detect Sleep Hypopnea- Apnea Events Based on EEG Signals”, *IEEE Access*, vol. 9, s. 641–650, 2021. DOI: 10.1109/ACCESS.2020.3038486.
- [3] A. G. Webb, ”Principles of Biomedical Instrumentation”, *Cambridge Texts in Biomedical Engineering*, 2018. DOI: 10.1017/9781316286210.
- [4] J. V. Summer, ”Apnea-Hypopnea Index (AHI)”, *Sleep Foundation*, 2021. viitattu 13. joulukuuta 2025. url: <https://www.sleepfoundation.org/sleep-apnea/ahi>.
- [5] B. Gholami, M. H. Behboudi, A. Khadem, A. Shoeibi ja J. M. Gorriz, ”Sleep Apnea Diagnosis Using Complexity Features of EEG Signals”, *Artificial Intelligence in Neuroscience: Affective Analysis and Health Applications*, vol. 13258, J. M. Ferrández Vicente, J. R. Álvarez-Sánchez, F. De La Paz López ja H. Adeli, toim., s. 74–83, 2022. DOI: 10.1007/978-3-031-06242-1_8.
- [6] E. G. Roberts, J. R. Raphaelson, J. E. Orr, J. N. LaBuzetta ja A. Malhotra, ”The Pathogenesis of Central and Complex Sleep Apnea”, *Current Neurology and Neuroscience Reports*, vol. 22, nro 7, s. 405–412, 2022. DOI: 10.1007/s11910-022-01199-2.

- [7] C. R. Laratta, N. T. Ayas, M. Povitz ja S. R. Pendharkar, "Diagnosis and treatment of obstructive sleep apnea in adults", *CMAJ : Canadian Medical Association Journal*, vol. 189, nro 48, 2017. DOI: 10.1503/cmaj.170296.
- [8] S. B.H., D. G., A. Sawal ja T. P. Balwir, "Anatomical Basis of Obstructive Sleep Apnoea: A Review of Randomized Controlled Trials", *Cureus*, vol. 15, nro 9, DOI: 10.7759/cureus.44525.
- [9] PruebasBMA, "Español: Máquina CPAP", *Wikimedia Commons*, 2012, Public domain. viitattu 25. tammikuuta 2026. url: <https://commons.wikimedia.org/wiki/File:CPAP.png>.
- [10] D. P. White, "Pathogenesis of Obstructive and Central Sleep Apnea", *American Journal of Respiratory and Critical Care Medicine*, vol. 172, nro 11, s. 1363–1370, 2005. DOI: 10.1164/rccm.200412-1631SO.
- [11] A. M. Rana ja A. Sankari, "Central Sleep Apnea", *StatPearls*, 2025. url: <http://www.ncbi.nlm.nih.gov/books/NBK578199/>.
- [12] R. J. Castriotta ja R. Majid, "Complex Sleep Apnea", *Sleep Medicine Clinics*, vol. 8, nro 4, s. 463–475, 2013. DOI: 10.1016/j.jsmc.2013.07.006.
- [13] Y. Zhang, Z. Li, Y. Lu, Y. Zhang, G. Liu ja C. Wang, "An EEG Screening Method for Severe Obstructive Sleep Apnea Based on Limited Penetrable Difference Visibility Graph and Graph Convolutional Network", *IEEE Journal of Biomedical and Health Informatics*, vol. 29, nro 11, s. 8011–8021, 2025. DOI: 10.1109/JBHI.2025.3579556.
- [14] E. Niedermeyer ja F. L. Da Silva, "Electroencephalography: Basic Principles, Clinical Applications, and Related Fields", *Wolters Kluwer*, 2004, ProQuest Ebook Central.

- [15] P. Olejniczak, "Neurophysiologic Basis of EEG", *Journal of Clinical Neurophysiology*, vol. 23, nro 3, s. 186, 2006. DOI: 10.1097/01.wnp.0000220079.61973.6c.
- [16] A. M. Feyissa ja W. O. Tatum, "Chapter 7 - Adult EEG", *Handbook of Clinical Neurology*, Clinical Neurophysiology: Basis and Technical Aspects, vol. 160, K. H. Levin ja P. Chauvel, toim., s. 103–124, 2019. DOI: 10.1016/B978-0-444-64032-1.00007-2.
- [17] Tomaton124, "Electrode locations of International 10-20 system for EEG (electroencephalography) recording", *Wikimedia Commons*, 2010, Public domain. viitattu 19. helmikuuta 2026. url: https://commons.wikimedia.org/wiki/File:21_electrodes_of_International_10-20_system_for_EEG.svg.
- [18] C. S. Nayak ja A. C. Anilkumar, "EEG Normal Waveforms", *StatPearls*, 2025. viitattu 6. marraskuuta 2025. url: <http://www.ncbi.nlm.nih.gov/books/NBK539805/>.
- [19] A. Bhattacharjee, S. Saha, S. A. Fattah, W.-P. Zhu ja M. O. Ahmad, "Sleep Apnea Detection Based on Rician Modeling of Feature Variation in Multiband EEG Signal", *IEEE Journal of Biomedical and Health Informatics*, vol. 23, nro 3, s. 1066–1074, 2019. DOI: 10.1109/JBHI.2018.2845303.
- [20] A. G. Xiromeritis, A. A. Hatziefthimiou, G. M. Hadjigeorgiou, K. I. Gourgoulianis, D. N. Anagnostopoulou ja N. V. Angelopoulos, "Quantitative spectral analysis of vigilance EEG in patients with obstructive sleep apnoea syndrome", *Sleep Breath*, vol. 15, nro 1, s. 121–128, 2011. DOI: 10.1007/s11325-010-0335-6.

- [21] M. D. Khursheed, S. Parveen ja O. Farooq, "Machine Learning Based System for Sleep Apnea Classification using EEG Signal", s. 1–5, 2022. DOI: 10.1109/ICCSEA54677.2022.9936304.
- [22] R. Jayaraj ja J. Mohan, "Classification of Sleep Apnea Based on Sub-Band Decomposition of EEG Signals", *Diagnostics*, vol. 11, nro 9, s. 1571, 2021. DOI: 10.3390/diagnostics11091571.
- [23] A. Onargan, B. Gavcar, G. Çalışkan ja A. Akan, "Prediction of Sleep Apnea Using EEG Signals and Machine Learning Algorithms", *Medical Technologies Congress (TIPTEKNO)*, s. 1–4, 2021. DOI: 10.1109/TIPTEKN053239.2021.9632895.
- [24] R. Gupta, T. F. Zaidi ja O. Farooq, "Automatic Detection of Sleep Apnea Using Sub-Band Features from EEG Signals", *International Conference on Signal Processing and Information Security (ICSPIS)*, s. 1–4, 2020. DOI: 10.1109/ICSPIS51252.2020.9340133.
- [25] R. Shah, D. Gaur ja G. Premalatha, "Machine Learning Based Sleep Apnea Detection Using EEG Signals", *IEEE International Conference on Smart Power Control and Renewable Energy (ICSPCRE)*, s. 1–5, 2024. DOI: 10.1109/ICSPCRE62303.2024.10674811.
- [26] A. Aqueel, O. Farooq ja Y. U. Khan, "Sleep Apnea Event Detection Using EEG Band Entropy Features and Machine Learning", s. 699–704, 2023. DOI: 10.1109/REEDCON57544.2023.10150973.
- [27] L. D. Barnes, K. Lee, A. W. Kempa-Liehr ja L. E. Hallum, "Detection of sleep apnea from single-channel electroencephalogram (EEG) using an explainable convolutional neural network (CNN)", *PLoS ONE*, vol. 17, nro 9, 2022. DOI: 10.1371/journal.pone.0272167.

- [28] M. Bonner, B. Nikolai, Q. Glovier, A. Lamb ja A. Gambhir, "Deep Learning-based EEG Analysis for Sleep Apnea Detection", *Systems and Information Engineering Design Symposium (SIEDS)*, s. 376–381, 2024. DOI: 10.1109/SIEDS61124.2024.10534725.
- [29] T. Mahmud, I. A. Khan, T. Ibn Mahmud, S. A. Fattah, W.-P. Zhu ja M. O. Ahmad, "Sleep Apnea Event Detection from Sub-frame Based Feature Variation in EEG Signal Using Deep Convolutional Neural Network", *Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, s. 5580–5583, 2020. DOI: 10.1109/EMBC44109.2020.9176433.
- [30] S. Taran ja V. Bajaj, "Sleep Apnea Detection Using Artificial Bee Colony Optimize Hermite Basis Functions for EEG Signals", *IEEE Transactions on Instrumentation and Measurement*, vol. 69, nro 2, s. 608–616, 2020. DOI: 10.1109/TIM.2019.2902809.
- [31] K. Tanci ja M. Hekim, "Classification of sleep apnea syndrome using the spectrograms of EEG signals and YOLOv8 deep learning model", *PeerJ Computer Science*, vol. 11, 2025. DOI: 10.7717/peerj-cs.2718.
- [32] I. A. Khan, T. I. Mahmud, T. Mahmud ja S. A. Fattah, "Deep Convolutional Neural Network Based Sleep Apnea Detection Scheme Using Spectro-temporal Subframes of EEG Signal", *International Conference on Electrical and Computer Engineering (ICECE)*, s. 463–466, 2020. DOI: 10.1109/ICECE51571.2020.9393059.
- [33] Y. Wang, Z. Xiao, S. Fang, W. Li, J. Wang ja X. Zhao, "BI - Directional long short-term memory for automatic detection of sleep apnea events based on single channel EEG signal", *Computers in Biology and Medicine*, vol. 142, s. 105211, 2022. DOI: 10.1016/j.combiomed.2022.105211.

- [34] T. Mahmud, I. A. Khan, T. I. Mahmud, S. A. Fattah, W.-P. Zhu ja M. O. Ahmad, "Sleep Apnea Detection From Variational Mode Decomposed EEG Signal Using a Hybrid CNN-BiLSTM", *IEEE Access*, vol. 9, s. 102 355–102 367, 2021. DOI: 10.1109/ACCESS.2021.3097090.
- [35] B. S. Spandana, J. Keerthana, T. Rajitha ja K. S. Ramtej, "Enhanced Central Sleep Apnea Detection Using a Hybrid Deep Learning Model with EEG Signals", *International Conference on Signal Processing, Computing and Control (ISPCC)*, s. 758–763, 2025. DOI: 10.1109/ISPCC66872.2025.11039602.
- [36] R. Nandakumar, R. Arunachalam, R. Pugalenti ja K. Arunachalam, "Automatic model of sleep apnea detection using optimized weighted fusion process of hybrid convolution (1D/2D) efficient attention network from EEG signals", *EURASIP Journal on Advances in Signal Processing*, nro 1, s. 18, 2025. DOI: 10.1186/s13634-025-01226-7.
- [37] C. Wan, M. C. Nnamdi, W. Shi, B. Smith, C. Purnell ja M. D. Wang, "Advancing Sleep Disorder Diagnostics: A Transformer-Based EEG Model for Sleep Stage Classification and OSA Prediction", *IEEE Journal of Biomedical and Health Informatics*, vol. 29, nro 2, s. 878–886, 2025. DOI: 10.1109/JBHI.2024.3512616.
- [38] A. Khan, S. K. Biswas, C. Chunka ja B. Baruah, "Intelligent Sleep Apnea Detection by Advanced ML Using Single-Lead EEG Signal Data", *IEEE Sensors Journal*, vol. 25, nro 2, s. 3859–3866, 2025. DOI: 10.1109/JSEN.2024.3506057.
- [39] M. S. Alam, Y. Siddiqui, M. Hasan, O. Farooq ja Y. Himeur, "Energy-Efficient FPGA Based Sleep Apnea Detection Using EEG Signals", *IEEE Access*, vol. 12, s. 40 182–40 195, 2024. DOI: 10.1109/ACCESS.2024.3374223.

- [40] P. Ramkumar ja E. Saravana Kumar, "Adaptive neuro-fuzzy inference system with an improved cheetah optimization based sleep apnea severity detection using EEG signal", *OPSEARCH*, 2025. DOI: 10.1007/s12597-025-00992-0.
- [41] A. Khan, S. K. Biswas ja C. Chunka, "An Ensemble Learning-Assisted Obstructive Sleep Apnea Detection Model Using EEG Physiological Signals and Improved Extra Tree Classifier", *IEEE Sensors Letters*, vol. 8, nro 7, s. 1–4, 2024. DOI: 10.1109/LSENS.2024.3406446.
- [42] A. Khan, S. K. Biswas, C. Chunka ja A. Kumar Das, "A Machine Learning Model for Obstructive Sleep Apnea Detection Using Ensemble Learning and Single-Lead EEG Signal Data", *IEEE Sensors Journal*, vol. 24, nro 12, s. 20 266–20 273, 2024. DOI: 10.1109/JSEN.2024.3397395.
- [43] A. Khan, S. K. Biswas ja C. Chunka, "An Optimized Obstructive Sleep Apnea Detection Model Using Particle Swarm Optimization and Machine Learning", *IEEE International Conference on Integrated Circuits, Design, and Verification (ICDV)*, s. 1–6, 2025. DOI: 10.1109/ICDV66179.2025.11135291.
- [44] B. Gholami, M. H. Behboudi, M. G. Mahjani ja A. Khadem, "Diagnosis of Sleep Apnea Syndrome from EEG Signals using Different Entropy measures", *International Conference on Signal Processing and Intelligent Systems (ICSPIS)*, s. 1–6, 2021. DOI: 10.1109/ICSPIS54653.2021.9729367.
- [45] C.-T. Hsieh ja Y.-H. Huang, "TSmRMR Feature Selection Method for Detecting Sleep Apnea Episodes Based on EEG Signals", *IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES)*, s. 103–107, 2024. DOI: 10.1109/IECBES61011.2024.10991314.
- [46] S. V. Bhalerao ja R. B. Pachori, "Sparse spectrum based swarm decomposition for robust nonstationary signal analysis with application to sleep apnea detec-

- tion from EEG”, *Biomedical Signal Processing and Control*, vol. 77, s. 103–792, 2022. DOI: 10.1016/j.bspc.2022.103792.
- [47] A. L. Goldberger et al., ”PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals”, *Circulation*, 2000. DOI: 10.1161/01.CIR.101.23.e215.
- [48] G.-Q. Zhang et al., ”The National Sleep Research Resource: towards a sleep data commons”, *Journal of the American Medical Informatics Association*, vol. 25, nro 10, s. 1351–1358, 2018. DOI: 10.1093/jamia/ocy064.
- [49] Y. Ichimaru ja G. Moody, ”Development of the polysomnographic database on CD-ROM”, *Psychiatry and Clinical Neurosciences*, vol. 53, nro 2, s. 175–177, 1999. DOI: 10.1046/j.1440-1819.1999.00527.x.
- [50] W. McNicholas, L. Doherty, S. Ryan, J. Garvey, P. Boyle ja E. Chua, ”St. Vincent’s University Hospital / University College Dublin Sleep Apnea Database”, *PhysioNet*, 2004. DOI: 10.13026/C26C7D.