

Laura Kurkinen

**Rytmihäiriöiden havaitseminen sydänsähkökäyrästä
neuroverkoilla**

Tietotekniikan kandidaatintutkielma

30. huhtikuuta 2019

Jyväskylän yliopisto

Informaatioteknologian tiedekunta

Tekijä: Laura Kurkinen

Yhteystiedot: laura.e.kurkinen@student.jyu.fi

Työn nimi: Rytmihäiriöiden havaitseminen sydänsähkökäyrästä neuroverkoilla

Title in English: Detecting heart arrhythmia in the electrocardiogram using neural networks

Työ: Kandidaatintutkielma

Sivumäärä: 24+0

Tiivistelmä: Tässä kandidaatintutkielmassa perehdytään rytmihäiriöiden havaitsemiseen sydänsähkökäyrästä neuroverkkojen avulla. Tietokoneavusteisella sydänsähkökäyrän käsittelyllä voidaan tehostaa tulkintaprosessia ja saada objektiivisempia tuloksia erityisesti suurista datamassoista käsiteltäessä. Tutkimustulokset osoittavat, että etenkin syvät neuroverkot ja näistä konvoluutioverkot soveltuvat hyvin sydänsähkökäyrän tulkintaan.

Avainsanat: sydänsähkökäyrä, neuroverkko, rytmihäiriö, konvoluutioverkko

Abstract: This bachelor's thesis studies detecting heart arrhythmia in the electrocardiogram making use of neural networks. By computer-aided processing of the electrocardiogram can its interpretation process be enhanced, and the following results are more objective especially when dealing with massive amounts of data. The research findings indicate that particularly deep neural networks and among these convolutional networks are well-suited for interpreting the electrocardiogram.

Keywords: electrocardiography, neural network, arrhythmia, convolutional neural network

Kuviot

Kuvio 1. Sydänsähkökäyrän rakenne (Sannino ja Pietro 2018).	4
Kuvio 2. Neuroverkko.	10
Kuvio 3. Neuron.	11

Taulukot

Taulukko 1. Tutkimustuloksia neuroverkoilla.	14
---	----

Sisältö

1	JOHDANTO	1
2	SYDÄMEN TOIMINTA	3
	2.1 Sydänsähkökäyrä	3
	2.2 Rytmihäiriö	4
3	SIGNAALIN KÄSITTELY	6
	3.1 Datan hankkiminen.....	6
	3.2 Signaalin esikäsittely.....	6
	3.3 Piirteiden erottelu	7
	3.4 Piirteiden valitseminen.....	8
4	NEUROVERKKO	10
	4.1 Luokittelu ja verkon opettaminen	12
	4.2 Tulosten tarkastelu	13
5	KONVOLUUTIOVERKKO.....	15
6	YHTEENVETO.....	17
	LÄHTEET	18

1 Johdanto

Sydänsähkökäyrä on yksi käytetyimmistä menetelmistä sydämen toimintahäiriöiden kuten rytmihäiriöiden diagnosointiin. Perinteisesti sydänsähkökäyrän tulkinta on ollut alan asiantuntijoiden vastuulla, mutta viime aikoina kiinnostus on kohdistunut kasvavissa määrin myös tietokoneavusteisen diagnosoinnin mahdollisuuteen.

Automatisoitu sydänsähkökäyrän tarkastelu vähentää käyrän käsittelyyn kuluvaan aikaa ja mahdollistaa objektiivisemmän tulkinnan (Isin ja Ozdalili 2017). Erityisen hyvin tietokoneavusteinen diagnosointi soveltuu tilanteisiin, joissa käsitellään suuria datamassoja, kuten ympärivuorokautisesta monitoroinnista peräisin olevia sydänsähkökäyriä (Acharya ym. 2017). Automatisoidun sähkökäyrän käsittelyn avulla voidaan nopeuttaa esimerkiksi alkuvaiheen diagnosointia, jolloin potilas saadaan nopeammin tarkempiin tutkimuksiin (Oh ym. 2018). Mahdollisimman aikainen diagnosointi on tärkeää, koska pahimmillaan sydämen toiminnan häiriöt voivat johtaa sydänlihaksen vaurioitumiseen tai potilaan kuolemaan.

Sydämen häiriöistä erityisesti rytmihäiriöt ovat suhteellisen yleisiä ja rytmihäiriön tyypistä riippuen tavallisesti melko vaarattomia. Riski rytmihäiriöiden ilmenemiseen kasvaa merkittävästi ihmisen ikääntyessä, joten rytmihäiriöt ovat selvästi muita ikäryhmiä yleisempiä vanhemmalla väestöllä. Väestön ikääntyessä myös rytmihäiriöiden määrä ja tämän seurauksena niiden diagnosoinnin tarve tulee kasvamaan tulevaisuudessa (Oh ym. 2018). Tästä johtuen rytmihäiriöt ovat erityisen kiinnostavia automatisoidun diagnosoinnin sovelluskohteita.

Tietokoneavusteisen diagnosoinnin toteuttamiseksi voidaan käyttää lukuisia eri menetelmiä, toisinaan myös näiden menetelmien yhdistelmiä. Esimerkiksi Asgari, Mehrnia ja Moussavi (2015) tutkivat tukivektorikoneen hyödyntämistä eteisvärinän tunnistuksessa. Yeh, Wang ja Chiou (2009) hyödynsivät sydänsähkökäyrien luokittelussa lineaarista diskriminanttianaalyysia (engl. *linear discriminant analysis*, LDA). Martis ym. (2014) puolestaan vertailivat tutkimuksessaan päätöspuuta, neuroverkkoa ja k:n lähimmän naapurin menetelmää.

Neuroverkot ja varsinkin syvät neuroverkot ovat viime vuosina kasvattaneet suosiotaan automatisoidun diagnosoinnin menetelminä. Tässä kandidaatintutkielmassa perehdytään rytmihäiriöiden havaitsemiseen sydänsähkökäyrästä neuroverkkojen avulla. Tutkielmassa pyri-

tään selvittämään miten neuroverkoilla suoritettava tunnistuspressi etenee, ja millaiset neuroverkot soveltuvat erityisen hyvin sydänsähkökäyrän tulkintaan. Tutkielma on toteutettu pienimuotoisena kirjallisuuskartoituksena keskittyen kohtuullisen tuoreisiin aiheesta tehtyisiin tutkimuksiin. Taustatietoa aiheesta on etsitty myös muista materiaaleista, kuten kirjoista.

Luvussa 2 käsitellään lyhyesti sydämen toimintaa sydänsähkökäyrän näkökulmasta määrittellen sydänsähkökäyrän ja rytmihäiriön käsitteet. Luvuissa 3 ja 4 luvussa esitellään neuroverkoilla suoritettavaa sydänsähkökäyrän tulkintaa vaihe vaiheelta, ensin keskittyen signaalin käsittelyyn ja sitten varsinaiseen neuroverkon toimintaan. Luvussa 5 esitellään lyhyesti esimerkkinä konvoluutioverkko. Luvussa 6 kootaan tutkielman tärkeimmät johtopäätökset ja pääkohdat yhteenvedon muodossa.

2 Sydämen toiminta

Tässä luvussa käsitellään sydämen toimintaa sydänsähkökäyrän näkökulmasta keskittyen siihen, millä tavoin sydämen toiminnan eri vaiheet ilmenevät sydänsähkökäyrässä. Lisäksi määritellään lyhyesti rytmihäiriön käsite ja annetaan muutamia esimerkkejä erilaisista rytmihäiriön ilmenemismuodoista.

2.1 Sydänsähkökäyrä


Sydänsähkökäyrä tai elektrokardiogrammi, lyhyemmin EKG, kuvaa sydämen sähköistä toimintaa, joka säätelee sydämen sykkeen nopeutta ja rytmiä (Isin ja Ozdalili 2017). Sydänsähkökäyrä voidaan muodostaa rintaan ja raajoihin asetettavilla kahdellatoista elektrodilla, joiden avulla tunnistetaan ja mitataan sydämessä tapahtuvia sähköisiä ilmiöitä (Green ja Chiaramida 2015, s. 17–19). Mittaus perustuu elektrodien välisiin sähköisiin potentiaalieroihin (Scharf ja Scharf 2010). Jokainen elektrodeista muodostaa oman sähkökäyränsä, jonka muoto vaihtelee hieman mittauskohdan mukaan (Green ja Chiaramida 2015, s. 17–19).

Sydänsähkökäyrää on jo pitkään hyödynnetty sydämen toiminnan tutkimuksessa ja nykyään se on yksi käytetyimmistä diagnosointimenetelmistä. Vasta viime aikoina on tarkemmin ymmärretty, miten mikroskooppisessa mittakaavassa ilmenevät tilanteet näkyvät makroskooppisissa signaaleissa. Mikroskooppisessa mittakaavassa esitettyjen mallien keskiarvoituksena saadaan Maxwellin yhtälöt, jotka mallintavat sähkömagneettisia ilmiöitä makroskooppisessa mittakaavassa (Scharf ja Scharf 2010).

EKG-käyrä muodustuu tietyin ajanjaksoin toistuvista aalloista, jotka kuvaavat sydämen toiminnan vaihteita. Nämä aallot voidaan jakaa kuvion 1 mukaisesti P-, Q-, R-, S- ja T-aaltoihin (Sannino ja Pietro 2018). T-aallon lopun ja P-aallon alun yhdistävä käyrän osa on keinotekoinen ja kuvaa sydänsähkökäyrän normaalitasoa, johon aaltoja suhteutetaan. Normaalisissa sydämen rytmisissä P-aallot toistuvat säännöllisin välimatkoin ja sykkeen nopeus vaihtelee kuudestakymmenestä sataan lyöntiin minuutissa. (Green ja Chiaramida 2015, s. 20–26, 128).

Sydämen sähköistä toimintaa kontrolloi oikean eteisen yläosassa sijaitseva sinussolmuke,

jonka luoma sähköimpulssi saa eteiset supistumaan aloittaen näin sydämen lyönnin. Sydän-sähkökäyrässä eteisten supistuminen havaitaan P-aaltona (Green ja Chiaramida 2015, s. 24–26, 127). P- ja R-aallon välinen sähkökäyrän osa kuvaa sähköimpulssin johtumista eteisestä kammioihin (Kalgotra ym. 2019). Tämä aiheuttaa kammioiden sähköisen aktivoitumisen eli depolarisaation, joka saa kammiot supistumaan. Kammioiden supistuminen ilmenee EKG-käyrässä selvästi havaittavana QRS-kompleksina, joka seuraa P-aaltoa tietyn mittaisen ajanjakson jälkeen (Green ja Chiaramida 2015, s. 128). QRS-kompleksin jälkeen sijaitseva T-aalto kuvaa kammioiden repolarisaatiota, jolloin kammiot palaavat lepotilaan ja valmistautuvat uuteen lyöntiin (Green ja Chiaramida 2015, s. 26–30, 127). Kammioiden sähköinen toiminta sijoittuu kokonaisuudessaan Q-aallon alusta T-aallon loppuun.



Kuvio 1. Sydänsähkökäyrän rakenne (Sannino ja Pietro 2018).

2.2 Rytmihäiriö

Sydämen sähköinen toiminta ei ole täysin virheetöntä ja voi altistua häiriöille esimerkiksi sydän- ja verenkiertoelimistön sairauden seurauksena. Häiriöt voivat ilmetä lukuisin eri tavoin, kuten kaoottisina sähköimpulsseina tai impulssien johtumisen muutoksina. Nämä normaalista toiminnasta poikkeavat tilanteet johtavat helposti sydämen rytmihäiriöihin.

Rytmihäiriö tarkoittaa sydämen sykenopeudessa tai sykkeen säännöllisyydessä esiintyvää häiriötä (Hagiwara ym. 2018). Rytmihäiriöiden taustalla on yleensä sydämen sähköisen toiminnan poikkeama, joten ne on usein mahdollista havaita tarkastelemalla sydänsähkökäyrää (Acharya ym. 2017). Syke voi olla poikkeuksellisen nopea, jolloin kyseessä on takykardia, tai epätavallisen hidas, jolloin käytetään bradyarytmia-nimitystä. Molemmissa tapauk-

nessa sydämen rytmi on tasainen ja ainoastaan sykkeen nopeus poikkeaa normaalista sinusrytmistä (60–100 lyöntiä / minuutti levossa) (Green ja Chiaramida 2015, s. 129).

Takykardiasta ja bradyarytmiasta poiketen esimerkiksi eteisvärinän ja kammiovärinän aikana sydämen rytmi on epätasainen poikkeuksellisen sykenopeuden lisäksi. Eteisvärinässä eteisten supistuminen on epäsäännöllistä ja leposyke noin 150–220 lyöntiä minuutissa (Acharya ym. 2017). Riski eteisvärinään kasvaa merkittävästi ihmisen ikääntyessä, mistä johtuen kyseinen häiriö on suhteellisen yleinen varsinkin vanhemmalla väestöllä (Green ja Chiaramida 2015, s. 131). Koska eteisvärinä vaikuttaa erityisesti eteisten toimintaan, kyetään se sydänsähkökäyrästä havaitsemaan P-aallon muutoksina. Epäsäännöllinen rytmi ilmenee käyrässä R-aaltojen vaihtelevana välimatkana. Eteisvärinä itsessään ei uhkaa potilaan henkeä, mutta pitkittyessään se voi altistaa muille sydämen toiminnan häiriöille (Hagiwara ym. 2018).

Toisin kuin eteisvärinä, kammiovärinä voi hoitamattomana osoittautua nopeasti hengenvaaralliseksi. Kammiovärinässä sydämen sähköinen toiminta on kaoottista, jolloin kammiot eivät kykene normaalilla tavalla depolarisoitumaan ja supistumaan (Green ja Chiaramida 2015, s. 142). Kammiovärinän aikana sydänsähkökäyrästä ei voida havaita QRS-kompleksia (Acharya ym. 2017).

3 Signaalin käsittely

Rytmihäiriöiden havaitseminen sydänsähkökäyrästä neuroverkoilla voidaan jakaa tässä työssä tarkastellun kirjallisuuden perusteella karkeasti kuuteen vaiheeseen: datan hankkiminen, signaalin esikäsittely, piirteiden erottelu, piirteiden valitseminen, luokittelu ja verkon opettaminen ja tulosten tarkastelu. Nämä vaiheet vaihtelevat hieman mallista ja menetelmästä riippuen, jolloin osa vaiheista voidaan sisällyttää johonkin toiseen tai ohittaa täysin. Tässä luvussa keskitytään neljään ensimmäiseen vaiheeseen, jotka sisältävät tarvittavan datan käsittelyn ennen varsinaista luokittelua.

3.1 Datan hankkiminen

Neuroverkkojen hyödyntäminen luokittelutehtävissä vaatii suuren määrän lajiteltua dataa tutkittavasta aihepiiristä. Rytmihäiriöitä käsiteltäessä datan sisältämien normaalien sydänsähkökäyrien määrän ei tulisi olla liian suuri suhteessa epänormaaleihin käyriin, jotta vältetään tulosten vääristymiseltä (Sannino ja Pietro 2018).

Rytmihäiriöiden tapauksessa datan lähteenä on hyvin usein käytetty MIT-BIH Arrhythmia-tietokantaa (Hagiwara ym. 2018). Tämä tietokanta sisältää yhteensä 48 digitalisoitua sydänsähkökäyrätallennetta, jotka on valittu neljäntuhannen Beth Israel -sairaalan rytmihäiriölaboratoriosta peräisin olevan pitkäaikaisen EKG-tallenteen joukosta. Alkuperäiset tallenteet ovat vuosilta 1975–1979. Tietokannan sisältämistä sydänsähkökäyristä 23 on valittu lähdeaineistoista sattumanvaraisesti ja loput 25 niiden sisältämien häiriöiden ja poikkeamien vuoksi. Jokainen tallenteista on pituudeltaan yli kolmekymmentä minuuttia (Moody 1997).

3.2 Signaalin esikäsittely

Sydänsähkökäyrä sisältää yleensä ulkopuolisista lähteistä peräisin olevia häiriöitä, joita kutsutaan kohinaksi (engl. *noise*). Kohina voi vaikuttaa käyrän rakenteeseen ja vaikeuttaa sen tulkintaa. Tästä johtuen EKG-käyrä usein esikäsitellään ennen sen varsinaista käyttöä.

Sydänsähkökäyrässä ilmenevät jännitteet ovat kooltaan vain millivolteja ja käyrässä havait-

tavat aallot kestoiltaan hyvin lyhytikäisiä. Tällöin kohinan merkitys kasvaa ja jo pienet häiriöt saattavat aiheuttaa haitallisia muutoksia EKG-käyrään. Kohinaa voivat aiheuttaa esimerkiksi häiriöt laitteiston virtajohdoissa ja elektrodien kontakteissa (Hagiwara ym. 2018). Myös potilaan hengitys ja lihasten liikkeet sekä mahdolliset lähiympäristössä sijaitsevat elektroniset laitteet voivat vaikuttaa sydänsähkökäyrän mittaamiseen (Isin ja Ozdalili 2017). Häiriöistä, erityisesti hengityksestä, johtuen EKG-käyrä ei yleensä pysy sille määritellyssä normaalitasossa (engl. *baseline*) vaan liikkuu sen ympäristössä (Sannino ja Pietro 2018).

Kohinan vaikutuksen minimoimiseksi käyrä voidaan pilkkoa pienempiin osiin, joista suodatimien avulla pyritään poistamaan tiettyjä taajuuksia. Tämän jälkeen signaali kootaan uudelleen suodatinkäsittelyn läpikäyneistä osista. Edellä kuvattua menetelmää hyödyntävät esimerkiksi diskreetti aallokemuunnos (engl. *discrete wavelet transform*, DWT) ja empiirinen moodihajotelma (engl. *empirical mode decomposition*, EMD) (Hagiwara ym. 2018). Molempia menetelmiä voidaan käyttää myös signaalin käsittelyn seuraavassa vaiheessa, piirteiden erottelussa.

Kohinan minimoinnin lisäksi esikäsittelyvaiheen aikana voidaan pyrkiä havaitsemaan ja tunnistamaan EKG-käyrän muodostavia aaltoja, kuten QRS-kompleksi (Acharya ym. 2017). Hyvin paljon käytetty algoritmi tähän tarkoitukseen on Pan-Tompkinsin algoritmi (Pan ja Tompkins 1985). QRS-kompleksista on mahdollista erottaa R-aallon piikki, jonka avulla kyetään edelleen selvittämään muita sähkökäyrän ominaisuuksia (Isin ja Ozdalili 2017). Esimerkiksi yksittäiset sydämen lyönnit voidaan erottaa toisistaan R-aaltojen perusteella. Myös muiden sähkökäyrän osien, kuten P- ja T-aaltojen, tunnistamista voidaan hyödyntää selvittäessä sydämen toiminnan vaiheita tai näihin vaiheisiin kulunutta aikaa (Sannino ja Pietro 2018).

3.3 Piirteiden erottelu

Piirteiden erottelussa (engl. *features extraction*) pyritään valitsemaan esikäsitellystä sydänsähkökäyrästä ne käyrän piirteet ja ominaisuudet, jotka todennäköisesti vaikuttavat tutkittavaan ilmiöön. Tämä on mahdollista suorittaa muokkaamalla EKG-käyrää sen ajan, taajuuden tai ajan sekä taajuuden suhteen. Lisäksi käyrän piileviä ominaisuuksia voidaan etsiä epäli-

neearisilla menetelmillä (Hagiwara ym. 2018). Tarkastelu voidaan halutessa myös rajoittaa jollekin erityisen mielenkiintoiselle sähkökäyrän osalle, kuten R- ja T-aaltojen välille (Isin ja Ozdalili 2017).

Pääkomponenttianalyysi (engl. *principal componen analysis*, PCA) on lineaarinen aikaperusteinen menetelmä, jonka avulla pyritään pienentämään tarkasteltavan datan dimensiota. Käsitelty data projisoidaan sellaisille avaruuden pinnoille, joiden avulla saadaan aikaiseksi mahdollisimman suuri varianssi. Lopulta projisoidun datan perusteella valitaan käytettävät piirteet (Martis, Acharya ja Min 2013). Taajuusperusteinen menetelmä on esimerkiksi Fourier-muunnos (engl. *Fourier transform*). Muunnoksen avulla signaali voidaan muuntaa ajasta riippuvasta taajuuden funktioksi (Hagiwara ym. 2018).

Toisin kuin kaksi edellistä, diskreetti aallokemuunnos käsittelee signaalia sekä ajan että taajuuden suhteen pilkkoen signaalin matalan ja korkean taajuuden komponentteihin (Martis, Acharya ja Min 2013). Piirteiden erottelun lisäksi diskreetti aallokemuunnos soveltuu myös kohinan poistoon signaalia esikäsiteltäessä. Epälineaarisiin menetelmiin lukeutuu esimerkiksi korkean asteen kumulanteja hyödyntävä korkea-asteinen spektrianalyysi (engl. *highed order spectra*, HOS). Kumulantit kuvaavat poikkeamaa normaalijakaumasta ja niitä voidaan hyödyntää signaalin epälineaaristen ominaisuuksien havaitsemiseen. (Martis ym. 2013).

Piirteiden erottelu ei aina ole välttämätöntä ja se on mahdollista erillisenä vaiheena ohittaa erityisesti syviä neuroverkkoja käytettäessä, jolloin se sisältyy varsinaiseen luokittelun suorittavaan malliin (Acharya ym. 2017). Piirteiden erottelu voidaan myös suorittaa omalla, luokittimesta erisellä neuroverkollaan (Isin ja Ozdalili 2017).

3.4 Piirteiden valitseminen

Piirteiden erottelussa valituksi voi tulla hyvin suuri määrä piirteitä, joista kaikilla ei lopulta ole merkittävää vaikutusta tutkittavaan ilmiöön. Piirteiden valitsemisessa (engl. *features selection*) poistetaan ylimääräiset ja tarpeettomat piirteet ottaen piirteiden erottelussa valikoituneista ominaisuuksista huomioon vain ne, joilla on eniten merkitystä. Nämä piirteet toimivat lopulta luokittelun suorittavan neuroverkon syötteenä.

Piirteiden valitseminen voidaan jakaa esimerkiksi suodattimeen (engl. *filter*), kääreeseen (engl. *wrapper*) ja upotettuun (engl. *embedded*) menetelmään. Suodatinta käytettäessä pyritään valitsemaan merkitsevimmät piirteet hyödyntäen datan tilastollisia ominaisuuksia (Hagiwara ym. 2018). Esimerkki tällaisesta menetelmästä on Fisherin pisteytys (engl. *Fisher score*), joka laskee jokaiselle piirteelle pisteet käyttäen laskutoimituksissa datan hajontaa. Pisteytyksen perusteella piirteet voidaan asettaa niiden merkitsevyyden mukaiseen järjestykseen, mistä lopulta valitaan haluttu määrä piirteitä luokittimen syötteeksi (Yılmaz 2013).

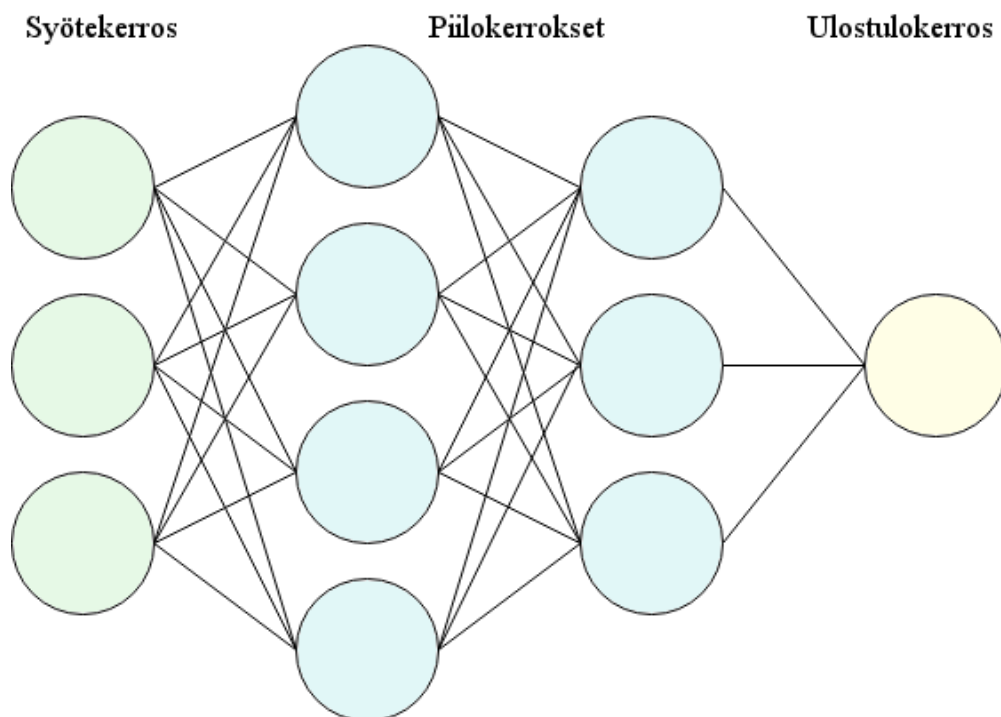
Toisin kuin suodattimen tapauksessa, kääreen suorittama piirteiden vertailu perustuu opettavan mallin toimintaan (Hagiwara ym. 2018). Tämän tyyppisiin menetelmiin lukeutuu rekursiivinen piirteiden eliminointi (engl. *recursive feature elimination*), jossa mallia opetetaan käyttäen piirteiden erottelussa valittuja piirteitä. Piirteet pisteytetään ja jokaisen opetuskierroksen jälkeen vähiten pisteitä saanut piirre poistetaan käytettävien piirteiden joukosta. Mallin opetusta jatketaan, kunnes piirteet on saatu järjestettyä niiden merkitsevyyden perusteella (Shi ym. 2019).

Piirteiden valitseminen voi myös sisältyä suoraan käytettävään malliin, jolloin sitä kutsutaan upotetuksi (Hagiwara ym. 2018). Tällöin piirteiden käsittelyä ei ole tarpeellista suorittaa erillisellä menetelmällä suodattimen tai kääreen tavoin. Neuroverkkojen joukosta upotettua piirteiden valintaa hyödyntävät erityisesti syvät neuroverkot, kuten konvoluutioverkot. Konvoluutioverkossa piirteiden valitsemisen mahdollistavat konvoluutio- ja pakkauskerrokset, joita käsitellään tarkemmin luvussa 5.

4 Neuroverkko

Tässä luvussa käsitellään aiemmin mainituista neuroverkoilla tapahtuvan rytmihäiriöiden tunnistamisen vaiheista kahta viimeistä, luokittelua ja neuroverkon opettamista sekä tulosten tarkastelua. Aluksi esitellään lyhyesti neuroverkon rakennetta ja toimintaa, minkä jälkeen siirrytään varsinaisten vaiheiden tarkasteluun.


Murphy (2012) määrittelee koneoppimisen menetelmäksi, joka etsii automaattisesti rakenteita datasta ja muodostaa näiden perusteella ennusteen tai päätöksiä dataan liittyen. Neuroverkko on koneoppimismenetelmä, jossa verkko muodostetaan neuroneiksi kutsutuista laskentayksiköistä. Nimensä ja inspiraationsa neuronit ovat saaneet biologisista aivojen neuroneista. Tässä käsitellään vain eteenpäin syöttäviä (engl. *feedforward*) neuroverkkoja, jotka eivät sisällä esimerkiksi silmukoita tai muita datan takaisinpäin syöttämistä sallivia rakenteita (Abdi, Valentin ja Edelman 1999, s. 1–3).



Kuvio 2. Neuroverkko.

Kokonaisuudessaan verkko muodostuu syötekerroksesta, joka ottaa vastaan verkon syötteen, laskentaa suorittavista piilokerroksista sekä ulostulokerroksesta, joka muodostaa lopullisen tuloksen (Hagiwara ym. 2018). Verkon rakenne nimettyine kerroksineen on esitetty kuvion 2 esimerkiverkossa. Suuren määrän piilokerroksia sisältävää verkkoa kutsutaan syväksi neuroverkoksi. Piilokerrosten määrän lisäksi myös yksittäisten neuronien lukumäärä jokaisella piilokerroksella voi vaihdella (Sannino ja Pietro 2018). Esimerkiksi kuvion 2 neuroverkko sisältää kaksi erillistä piilokerrosta, joista ensimmäinen muodostuu neljästä ja jälkimmäinen kolmesta neuronista.

Neuronit asetetaan verkkoon kerroksittain, jolloin edellisen kerroksen neuronien ulostulo toimii seuraavan kerroksen neuronien syötteenä (Murphy 2012, s. 563–564). Kerrosten neuronit ovat yhteydessä toisiinsa painotettujen yhteyksien välityksellä. Yksinkertaisimmillaan verkko oppii näiden painojen arvoja muuttamalla (Abdi, Valentin ja Edelman 1999, s. 5, 68–69). Kuviossa 3 neuronien välisten yhteyksien painot on merkitty kirjaimella w ja neuronin saamat syötteet kirjaimella x . Lisäksi neuronilla on bias- tai kynnystermi, jota tässä on merkitty b -kirjaimella.



Kuvio 3. Neuron.

Neuroni kertoo saamansa syötteet niitä vastaavien yhteyksien painoilla ja summaa nämä kerrotut termit yhteen. Summaan lisätään vielä bias- tai kynnystermi (Abdi, Valentin ja Edelman 1999, s. 4–5). Tätä on kuvattu alle merkityssä kaavassa kuvion 3 mukaisesti, jolloin saadaan

$$a = w_1x_1 + w_2x_2 + w_3x_3 + b.$$

Lopuksi summa annetaan epälineaarilla aktivaatiofunktiolle, jonka tulos toimii neuronin ulostulona (Abdi, Valentin ja Edelman 1999, s. 5, 68–69). Kuviossa 3 f kuvaa aktivaatiofunktiota, jonka syötteenä summa a toimii.

4.1 Luokittelu ja verkon opettaminen

Luokittelussa ja verkon opettamisessa piirteiden valinnassa valikoituneet piirteet syötetään luokittimena toimivalle neuroverkolle. Neuroverkko pyrkii näitä piirteitä hyödyntäen luokittelemaan sydänsähkökäyrät joko normaaleihin tai rytmihäiriöitä sisältäviin. Rytmihäiriöluokkia voi olla yksi tai useampia, jos rytmihäiriöt on jaettu tarkemmin esimerkiksi eteisvärinä ja kammiovärinä.

Luokittimet voidaan jakaa yleisesti kolmeen ryhmään. Valvotussa oppimisessa (engl. *supervised learning*) mallille syötetään valitut piirteet, joiden perusteella se muodostaa tuloksen. Malli oppii vertaamalla saamaansa tulosta haluttuun lopputulokseen (Hagiwara ym. 2018). Valvomattomassa oppimisessa (engl. *unsupervised learning*) mallille syötetään dataa, josta verkko pyrkii löytämään piileviä rakenteita. Käytettäviä piirteitä ei tällöin ole tarpeellista erotella ja valita erikseen, sillä nämä vaiheet sisältyvät suoraan verkkoon. Toisin kuin valvotussa oppimisessa, valvomattomassa oppimisessa ei tunneta tarkkoja syöte-ulostulopareja. (Murphy 2012, s. 9). Vahvistetussa oppimisessa (engl. *reinforcement learning*) verkkoa rangaistaan tai palkitaan sen antamien tulosten perusteella (Murphy 2012, s. 2).

Luokittimen tyypistä riippumatta eteenpäin syöttävissä neuroverkoissa oppiminen perustuu lopulta neuronien välisten yhteyksien painojen päivittämiseen. Esimerkiksi valvotussa oppimisessa verkko vertaa tietyllä syötteellä saatua ulostuloa haluttuun tulokseen. Tuloksia vertaamalla voidaan laskea virhe, jota pyritään minimoimaan. Tämän perusteella voidaan antaa verkon painoille uudet arvot päivittämällä ne vastavirta-algoritmin (engl. *backpropagation*) avulla (Abdi, Valentin ja Edelman 1999, s. 5, 68–74).

Mallia opetettaessa data jaetaan opetus- ja testidataan esimerkiksi siten, että 90 % datasta käytetään varsinaiseen opetukseen ja loput 10 % opetetun mallin testaamiseen (Oh ym. 2019). Tällöin koko data jaetaan kymmeneen osaan, joista yhdeksää käytetään mallin opettamiseen ja yhtä testaamiseen. Testiosuutta vaihdetaan jokaisen opetuskierroksen jälkeen siten, että jokainen kymmenestä osasta toimii vuorollaan testidatana. Tätä kutsutaan kymmenkertaiseksi ristiinvalidoinniksi (engl. *ten-fold cross-validation*) (Acharya ym. 2017). Opetuksen aikana edellisessä vaiheessa valittu opetusdata voidaan jakaa vielä erikseen varsinaiseen opetusdataan ja validointidataan. Validointidatan avulla pyritään arvioimaan mallin tietyn hetkistä ti-

laa opetusprosessin aikana. Esimerkiksi Oh ym. (2018) käyttivät 80 % datasta opetukseen ja 20 % validointiin.

Neuroverkot ovat yleensä nopeita käyttää, mutta niiden opettaminen on hidasta ja vaatii paljon dataa ja laskentatehoa (Acharya ym. 2017). Esimerkiksi Oh ym. (2019) käyttivät kahta Intel Xeon E5620 -prosessoria ja 24 GB:n keskusmuistia, jolloin kaiken opetusdatan syöttäminen ja verkon opettaminen vei aikaa noin 120,13 sekuntia kerta. Kun tämä toistettiin 200 kertaa, kului aikaa yhteensä noin 24026 sekuntia, toisin sanoen noin 6,67 tuntia.

4.2 Tulosten tarkastelu

Neuroverkoilla saavutettuja tuloksia voidaan arvioida esimerkiksi tarkkuuden (engl. *accuracy*), herkkyyden (engl. *sensitivity*) ja täsmällisyyden (engl. *specifity*) avulla. Seuraavaksi esitetään Sanninon ja Pietron (2018) mukaan yksinkertaiset matemaattiset kaavat kunkin arvon muodostamiseksi. Kaavoissa käytetyt muuttujat ovat seuraavat:

- tp = todellinen positiivinen, oikein luokitellut epänormaalit
- tn = todellinen negatiivinen, oikein luokitellut normaalit
- vp = väärä positiivinen, väärin luokitellut normaalit
- vn = väärä negatiivinen, väärin luokitellut epänormaalit.

Tarkkuus kertoo, millä todennäköisyydellä neuroverkko luokittelee saamansa syötteen oikein joko normaaliksi tai tavallisesta poikkeavaksi. Tämä voidaan laskea seuraavasti:

$$\text{Tarkkuus} = \frac{tp + tn}{(tp + tn) + (vp + vn)}.$$

Herkyys kuvaa sitä todennäköisyyttä, jolla rytmihäiriöitä sisältävät epänormaalit sydänsähkökäyrät on luokiteltu oikein,

$$\text{Herkyys} = \frac{tp}{tp + vn}.$$

Täsmällisyydellä tarkoitetaan todennäköisyyttä, jolla normaalit rytmihäiriöitä sisältämättömät käyrät on luokiteltu oikein,

$$\text{Täsmällisyys} = \frac{tn}{vp + tn}.$$

Taulukkoon 1 on listattu muutamia kohtuullisen tuoreita neuroverkoilla saatuja tuloksia tarkkuuden, herkkyuden ja täsmällisyyden avulla esitettynä. Näissä tutkimuksissa saavutettu tarkkuus vaihtelee pääasiassa välillä 92–99 %, herkkyys 94–99 % ja täsmällisyys 93–99 %. Tutkimuksissa käytettyjen verkkojen tyypit ja rakenteet vaihtelevat, samoin kuin niissä käsitellyt rytmihäiriöiden tyypit. Myös signaalin esikäsittelyssä mahdollisesti hyödynnetyt menetelmät voivat poiketa toisistaan.

Taulukko 1. Tutkimustuloksia neuroverkoilla.

Tutkimus	Tarkkuus	Herkkyys	Täsmällisyys
Acharya ym. (2017) (A)	92,09 %	98,09 %	93,13 %
Acharya ym. (2017) (B)	94,90 %	99,13 %	81,44 %
Oh ym. (2018)	98,10 %	97,50 %	98,70 %
Oh ym. (2019)	97,32 %	94,44 %	98,26 %
Sannino ja Pietro (2018)	99,68 %	99,48 %	99,83 %
Xia ym. (2018)	98,63 %	98,79 %	97,87 %

5 Konvoluutioverkko

Neuroverkkojen joukosta varsinkin syvät neuroverkot ovat osoittautuneet toimiviksi tietokoneavusteisen sydänsähkökäyrän käsittelyn menetelmiksi. Konvoluutioverkko (engl. *convolutional neural network*) on syvä neuroverkko, jota voidaan käyttää erityisesti tekstin ja kuvien tunnistamiseen (Murphy 2012, s. 563). Sen on havaittu soveltuvan hyvin myös lääketieteelliseen diagnosointiin (Acharya ym. 2017). Suurimmassa osassa tässä tutkielmassa käsitellyistä neuroverkkoista hyödyntävistä tutkimuksista käytetäänkin menetelmänä konvoluutioverkkoa.

Konvoluutioverkko koostuu syötekerroksesta, konvoluutiokerroksista, pakkauskerroksista (engl. *pooling layer*) ja täysin yhdistetyistä kerroksista (engl. *full-connected layer*) (Jiang 2019). Esimerkki Acharya ym. (2017) muodostivat verkon kahdestatoista kerroksesta. Konvoluutioverkon syöte annettiin syötekerrokselle, minkä jälkeen sitä käsitelivät vuorottelevat konvoluutio- ja pakkauskerrokset. Verkon loppuun oli asetettu neljä täysin yhdistettyä kerrosta, joilla käytettiin aktivaatiofunktioita.

Konvoluutioverkon syöteenä voidaan käyttää esimerkiksi kuvaa, jota verkko käsittelee pikseleiden muodostamana matriisina (Jiang 2019). Kuten muidenkin verkkojen tapauksessa, data voidaan ennen verkolle syöttämistä esikäsitellä ja etsiä esimerkiksi QRS-kompleksi (Isin ja Ozdalili 2017). QRS-kompleksin tai muiden aaltojen kuten R-piikin etsiminen eivät kuitenkaan ole välttämättömiä konvoluutioverkkoja käytettäessä. Konvoluutioverkko ei tavallisesti ole kovin herkkä kohinalle, joten esikäsitely ja kohinan poisto on mahdollista ohittaa täysin keventäen näin osaltaan EKG-käyrien käsittelyn prosessia (Acharya ym. 2017).

Konvoluutioverkko kykenee itse tunnistamaan saamastaan syötteestä luokitteluun tarvittavat piirteet. Tästä on erityisesti hyötyä esimerkiksi kuvien tunnistamisessa, jolloin käsin tehtävä piirteiden erottelu voi olla haastavaa (Murphy 2012, s. 564). Verkko etsii saamastaan syötteestä abstrakteja piirteitä käyttäen suodattimena tietynkokoisia matriiseja (Jiang 2019). Tämän mahdollistavat konvoluutio- ja pakkauskerros, jotka suorittavat piirteiden etsimisen (Acharya ym. 2017). Jokainen kerroksen neuronit käyttävät laskutoimituksissaan tiettyä osaa erillisen kerroksen ulostulosta, jolloin kaikki perättäisten kerrosten neuronit eivät ole yhteydessä toisiinsa. Pakkauskerroksen tehtävä on konvoluutiokerrosten välissä pienentää käsiteltävää

matriisia, mikä vähentää tarvittavan laskennan määrää (Jiang 2019).

Konvoluutioverkon viimeiset kerrokset muodostuvat yleensä täysin yhdistetyistä kerroksista, jolloin kerrosten kaikki neuronit ovat yhteydessä toisiinsa. Nämä kerrokset suorittavat varsinaisen luokittelun (Jiang 2019). Kuten muidenkin verkkojen tapauksessa, voidaan konvoluutioverkon opetuksessa käytettävä data jakaa opetus- ja testidataan ja näistä opetusdata vielä erikseen opetus- ja validointidataan (Acharya ym. 2017).

Konvoluutioverkkoja ja muita syviä neuroverkkoja käytettäessä verkon läpinäkyvyys voi osoittautua ongelmalliseksi. Syvissä neuroverkoissa piirteiden erottelu ja valinta sisältyvät suoraan verkkoon, jolloin ne sydänsähkökäyrän ominaisuudet ja piirteet joihin verkko päätöksensä perustaa, voivat jäädä epäselviksi. Myös syvien neuroverkkojen mahdollisesti monimutkainen rakenne vaikeuttaa verkon toiminnan syvällisempää ymmärtämistä.

6 Yhteenveto

Rytmihäiriöiden tunnistamiseen sydänsähkökäyrästä voidaan hyödyntää lukuisia eri menetelmiä, esimerkiksi neuroverkkoja. Erityisesti syvät neuroverkot ja näiden joukosta konvoluutioverkot soveltuvat hyvin tietokoneavusteiseen diagnosointiin. Yleisesti neuroverkoilla suoritettava rytmihäiriöiden tunnistaminen sydänsähkökäyrästä voidaan jakaa kuuteen vaiheeseen: datan hankkimiseen, signaalien esikäsittelyyn, piirteiden erotteluun, piirteiden valitsemiseen, luokitteluun ja verkon opettamiseen ja tulosten tarkasteluun. Syviä neuroverkkoja käytettäessä piirteiden erottelu ja valitseminen sisältyvät suoraan verkkoon, jolloin niitä ei erikseen tarvitse suorittaa. Konvoluutioverkkojen tapauksessa myös signaalin esikäsittelyyn sisältyvä kohinan poisto voidaan joissain tapauksissa ohittaa kokonaan.

Tietokoneavusteisena menetelmänä neuroverkot soveltuvat hyvin sellaisten suurten datamassojen käsittelyyn, joiden tulkitseminen olisi ihmiselle hyvin työlästä tai käytännössä lähes mahdotonta. Ihmiseen verrattaessa neuroverkkojen etuja ovat myös erityisesti niiden nopeus ja tulkinnan objektiivisuus. Vaikka verkkojen käyttö on nopeaa, niiden opettaminen on aikaa vievää ja vaatii runsaasti dataa sekä laskentatehoa. Lisäksi syviä neuroverkkoja käytettäessä verkon toiminnan ja päätösten läpinäkyvyys voi aiheuttaa ongelmia niiden luotettavuuden suhteen.

Neuroverkkoja voitaisiin tällä sovellusalueella hyödyntää esimerkiksi asiantuntijoiden avustamiseen, tulosten vertailuun tai sydänsähkökäyrän tulkinnan opetukseen. Lisäksi neuroverkot mahdollistaisivat tehokkaamman alustavan diagnosoinnin, jonka perusteella potilas voitaisiin ohjata mahdollisimman nopeasti tarkempiin tutkimuksiin. Suurten datamassojen yhteydessä neuroverkot soveltuisivat hyvin ympärivuorokautisesta monitoroinnista tai massa-seulonnoista peräisin olevan datan käsittelyyn. Ala on jatkuvassa kehityksessä, joten uusia menetelmiä ja sovelluskohteita tulee tulevaisuudessa varmasti syntymään runsaasti.

Lähteet

Abdi, Hervé, Dominique Valentin ja Betty Edelman. 1999. *Neural networks*. 89. Sage university papers series. Quantitative applications in the social sciences. Thousand Oaks, Calif. ; London: SAGE. doi:10.4135/9781412985277.

Acharya, U. Rajendra, Hamido Fujita, Oh Shu Lih, Yuki Hagiwara, Jen Hong Tan ja Muhammad Adam. 2017. “Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network”. ID: 271625, *Information Sciences* 405:81–90. doi://doi.org/10.1016/j.ins.2017.04.012.

Asgari, Shadnaz, Alireza Mehrnia ja Maryam Moussavi. 2015. “Automatic detection of atrial fibrillation using stationary wavelet transform and support vector machine”. *Computers in Biology and Medicine* 60:132–142. ISSN: 0010-4825. doi:https://doi.org/10.1016/j.combiomed.2015.03.005.

Green, Jacqueline M., ja Anthony J. Chiaramida. 2015. *12-lead EKG confidence : a step-by-step guide*. Third edition. New York, New York: Springer Publishing Company. ISBN: 9780826119056 -.

Hagiwara, Yuki, Hamido Fujita, Shu Lih Oh, Jen Hong Tan, Ru San Tan, Edward J. Ciaccio ja U. Rajendra Acharya. 2018. “Computer-aided diagnosis of atrial fibrillation based on ECG Signals: A review”. ID: 271625, *Information Sciences* 467:99–114. doi://doi.org/10.1016/j.ins.2018.07.063.

Isin, Ali, ja Selen Ozdalili. 2017. “Cardiac arrhythmia detection using deep learning”. ID: 280203, *Procedia Computer Science* 120:268–275. doi://doi.org/10.1016/j.procs.2017.11.238.

Jiang, Yuantao. 2019. “Research on road extraction of remote sensing image based on convolutional neural network”. *EURASIP Journal on Image and Video Processing* 2019, numero 1 (helmikuu): 31. ISSN: 1687-5281. doi:10.1186/s13640-019-0426-7.

- Kalgotra, Pankush, Ramesh Sharda, Bryan Hammer ja David E. Albert. 2019. “Sensor analytics for interpretation of EKG signals”. ID: 271506, *Expert Systems with Applications* 123:377–385. doi://doi.org/10.1016/j.eswa.2018.12.056.
- Martis, Roshan Joy, U. Rajendra Acharya, Hojjat Adeli, Hari Prasad, Jen Hong Tan, Kuang Chua Chua, Chea Loon Too, Sharon Wan Jie Yeo ja Louis Tong. 2014. “Computer aided diagnosis of atrial arrhythmia using dimensionality reduction methods on transform domain representation”. *Biomedical Signal Processing and Control* 13:295–305. ISSN: 1746-8094. doi:https://doi.org/10.1016/j.bspc.2014.04.001.
- Martis, Roshan Joy, U. Rajendra Acharya ja Lim Choo Min. 2013. “ECG beat classification using PCA, LDA, ICA and Discrete Wavelet Transform”. *Biomedical Signal Processing and Control* 8 (5): 437–448. ISSN: 1746-8094. doi:https://doi.org/10.1016/j.bspc.2013.01.005.
- Martis, Roshan Joy, U. Rajendra Acharya, Hari Prasad, Chua Kuang Chua, Choo Min Lim ja Jasjit S. Suri. 2013. “Application of higher order statistics for atrial arrhythmia classification”. *Biomedical Signal Processing and Control* 8 (6): 888–900. ISSN: 1746-8094. doi:https://doi.org/10.1016/j.bspc.2013.08.008.
- Moody, George B. 1997. “MIT-BIH Arrhythmia Database Directory - Introduction”. Viitattu 21. maaliskuuta 2019.
- Murphy, Kevin P. 2012. *Machine Learning : A Probabilistic Perspective* [kielellä English]. ID: 3339490. Cambridge: MIT Press. ISBN: 9780262305242.
- Oh, Shu Lih, Eddie Y. K. Ng, Ru San Tan ja U. Rajendra Acharya. 2018. “Automated diagnosis of arrhythmia using combination of CNN and LSTM techniques with variable length heart beats”. ID: 271150, *Computers in Biology and Medicine* 102:278–287. doi://doi.org/10.1016/j.combiomed.2018.06.002.
- . 2019. “Automated beat-wise arrhythmia diagnosis using modified U-net on extended electrocardiographic recordings with heterogeneous arrhythmia types”. ID: 271150, *Computers in Biology and Medicine* 105:92–101. doi://doi.org/10.1016/j.combiomed.2018.12.012.

- Pan, J., ja W. J. Tompkins. 1985. "A Real-Time QRS Detection Algorithm". *IEEE Transactions on Biomedical Engineering* BME-32, numero 3 (maaliskuu): 230–236. ISSN: 0018-9294. doi:10.1109/TBME.1985.325532.
- Sannino, G., ja G. De Pietro. 2018. "A deep learning approach for ECG-based heartbeat classification for arrhythmia detection". ID: 271521, *Future Generation Computer Systems* 86:446–455. doi://doi.org/10.1016/j.future.2018.03.057.
- Scharf, Günter, ja Christoph Scharf. 2010. "Electrophysiology of living organs from first principles". *arXiv preprint arXiv:1006.3453*.
- Shi, Haotian, Haoren Wang, Yixiang Huang, Liqun Zhao, Chengjin Qin ja Chengliang Liu. 2019. "A hierarchical method based on weighted extreme gradient boosting in ECG heartbeat classification". *Computer Methods and Programs in Biomedicine* 171:1–10. ISSN: 0169-2607. doi:https://doi.org/10.1016/j.cmpb.2019.02.005.
- Xia, Yong, Naren Wulan, Kuanquan Wang ja Henggui Zhang. 2018. "Detecting atrial fibrillation by deep convolutional neural networks". *Computers in Biology and Medicine* 93:84–92. ISSN: 0010-4825. doi:https://doi.org/10.1016/j.combiomed.2017.12.007.
- Yeh, Yun-Chi, Wen-June Wang ja Che Wun Chiou. 2009. "Cardiac arrhythmia diagnosis method using linear discriminant analysis on ECG signals". *Measurement* 42 (5): 778–789. ISSN: 0263-2241. doi:https://doi.org/10.1016/j.measurement.2009.01.004.
- Yılmaz, Ersen. 2013. "An Expert System Based on Fisher Score and LS-SVM for Cardiac Arrhythmia Diagnosis". *Computational and Mathematical Methods in Medicine* 2013:1–6. doi:https://doi.org/10.1155/2013/849674.