


Tekoäly terveydenhuollossa



Informaatioteknologian tiedekunnan julkaisuja
No. 45/2018

Editor: Pekka Neittaanmäki

Covers: Petri Vähäkainu ja Matti Savonen

Copyright © 2018

Petri Vähäkainu, Pekka Neittaanmäki ja Jyväskylän yliopisto

ISBN 978-951-39-7360-5 (verkkoj.)

ISSN 2323-5004

Jyväskylä 2018

Tekoäly terveydenhuollossa

Petri Vähäkainu
Pekka Neittaanmäki

Tämä julkaisu on toteutettu osana Watson Health Cloud-hanketta, johon Jyväskylän yliopisto on saanut rahoituksen Business-Finlandilta.

Business Finland-hanke: Watson Health Cloud

KUVIOT

KUVIO 1. KEHITYSKULKU TEKOÄLYSTÄ SYVÄOPPIMISEEN.	4
KUVIO 2. TEKOÄLYN HYÖDYNTÄMISEN ALUEITA.	5
KUVIO 3. TURINGIN TESTI.	6
KUVIO 4. TEKOÄLYN JAKO SOVELLUSALUEISIIN JA NIIDEN KÄYTTÄMIÄ MENETELMIÄ.	6
KUVIO 5. HERMOSOLUN SEMANTIikka.	9
KUVIO 6. YKSINKERTAINEN KEINOTEKOINEN NEUROVERKKO.	9
KUVIO 7. ETEENPÄIN SYÖTTÄVÄ NEUROVERKKO.	10
KUVIO 8. TAKAISINKYTKETTY NEUROVERKKO.	11
KUVIO 9. KONVOLUUTIOVERKKOJEN TOIMINTA KUVANTUNNISTUKSESSA.	12
KUVIO 10. YKSINKERTAINEN PÄÄTÖSPUU.	14
KUVIO 11. ESIMERKKI BAYERS-VERKOSTA.	15
KUVIO 12. KONEOPPIMISEN SOVELLUSALUEITA ERI TEOLLISUUDENALOILLA.	15
KUVIO 13. SYVÄOPPIMISEN VS VANHEMPIEN TEKNOLOGIOIDEN SKAALAUTUVUUS.	17
KUVIO 14. NEUROVERKKOJEN PÄÄSOVELLUSALUEITA LÄÄKETIETEESSÄ. (AMATO YM. 2013)	19
KUVIO 15. EVE-TUTKIMUSROBOTTI.	22
KUVIO 16. TUTKIMUSMALLI: MESH- JA LINGS-TIETOKANNAT SEKÄ DNN-NEUROVERKKO.	26
KUVIO 17. MORPHEO-ALUSTAN MONITOROINTI-IKKUNA.	28
KUVIO 18. LSTM-ARKKITEHTUURI.	32
KUVIO 19. SOMNOX-ÄLYTYNYN JA AIVOJEN MANTELITUMAKE.	34
KUVIO 20. CARDIOSMART365 KOMPONENTTIEN ARKKITEHTUURI.	36
KUVIO 21. CARDIOSMART365 TARJOAMIEN PALVELUIDEN ARKKITEHTUURI.	37
KUVIO 22. CARDIOSMART365 MOBIILISOVELLUKSEN KÄYTTÖLIITTYMÄ MITTAUKSIA VARTEN.	38
KUVIO 23. CARDIOSMART365-JÄRJESTELMÄN POTILAAN LÄÄKETIETEELLISET HISTORIATIEDOT.	39
KUVIO 24. POTILAIDEN LÄÄKITYSHISTORIA JA INFORMAATIO KARDIOLOGIN NÄKYMÄSTÄ.	40
KUVIO 25. SYDÄN- JA VERISUONISAIRAUKSIEN TUTKIMUKSEN TOTEUTTAMINEN.	41
KUVIO 26. HÄTÄTILANTEITA VARTEN TARKOITETTU CHIEF COMPLAIN-OMINAISUUS.	42
KUVIO 27. ESIMERKKI NORMAALISTA JA VIOITTUNEESTA SYDÄMESTÄ.	43
KUVIO 28. SYDÄMEN VAJAATOIMINNAN ENNUSTAMISEEN KÄYTETTY TUTKIMUSMALLI.	44
KUVIO 29. CAD-PROTOTYYPPIJÄRJESTELMÄN TOIMINTA.	46
KUVIO 30. AINEISTON RAKENNE.	46
KUVIO 31. CAD-JÄRJESTELMÄN TEKOÄLYTEKNOLOGIOIDEN SUORITUSKYKYMITTAUKSIA.	47
KUVIO 32. MRI-KUVAUKSIIN PERUSTUVA 3D-VIRTUAALIMALLI SYDÄMESTÄ.	47
KUVIO 33. HAVAINTOKUVA IHOLEESIESTA.	51
KUVIO 34. AIVOKASVAIMIEN DIAGNOSOINTIJÄRJESTELMÄN ARKKITEHTUURIN KAAVIO.	53
KUVIO 35. TYYPILLISEN MLP-NEUROVERKON RAKENNE.	55
KUVIO 36. JOHTAVAT KUOLINSYYT MAAILMASSA.	58
KUVIO 37. CNN-NEUROVERKKOMALLI INTERSTITIAALISEN KEUHKOSAIRAUDEN LUOKITTELUUN.	61
KUVIO 38. ILD-LUOKITTELUKUMATRIISI.	62
KUVIO 39. ILD-LUOKITTELUKUMATRIISI (KORJATTU).	62
KUVIO 40. ENNUSTAVAT TEKIJÄT OPETUSPROSESSISSA.	65
KUVIO 41. PEDIATRISEN ASTMAN DIAGNOSOINNIN ENNUSTEMALLI.	65

KUVIO 42. NANOTEKNOLOGIAAN PERUSTUVAN PUHALLUSLAITTEEN TOIMINTAPERIAATE.	68
KUVIO 43. GRAAFINEN ESITYS SAIRAUKSIEN TODENNÄKÖISYYKSISTÄ.	70
KUVIO 44. FUJITSUN KLIINISEN PÄÄTÖKSENTEON HIKARI-TYÖKALU JA TYÖNKULUN SKENAARIO.	73
KUVIO 45. CC-CRUISER TEKOÄLYALUSTAN FUNKTIONAALINEN ARKKITEHTUURI.	74
KUVIO 46. USEAMMAN SAIRAALAN KATTAVA ÄLYKÄS PILVIPALVELUALUSTA.	75
KUVIO 47. YOUR.MD-SOVELLUKSEN KÄYTTÖLIITTYMÄ.	80

LYHENNELISTA

AI	Artificial Intelligence eli tekoäly
AIM	Artificial Intelligence in Medicine tarkoittaa tietojenkäsittelyn hyödyntämistä älykkäänä työkaluna kliinisessä arvioinnissa ja päätöksenteossa
ALS	Amyotrophic Lateral Sclerosis eli motoneuronisairaus, joka rappeuttaa sekä ylempiä että alempia liikehermoja
ANN	Artificial Neural Network eli keinotekoinen neuroverkko
API	Application Programming Interface on määritelmä, jonka mukaan ohjelmat voivat tehdä pyyntöjä ja vaihtaa tietoja eli keskustella keskenään
ASD	Autism Spectrum Disorder eli autismikirjon häiriö (ASD-häiriö)
BMI	Body Mass Index eli painoindeksi
BP	The Back Propagation Neural Network Algorithm on iteratiivinen, laskevan gradientin oppimisalgoritmi
CAD	Computer Aided Diagnosis eli tietokoneavusteinen diagnosointijärjestelmä
CAD	Coronary Artery Disease eli sepelvaltimotauti
CAM	Content Addressable Memory eli muistityyppi, joka toimii hakukoneen tavoin ja etsii kokonaisia sisältöjä yhden kellojakson aikana
CDS	Clinical Decision Support System tarkoittaa Big Dataa hyödyntävää järjestelmää, joka tekee yksilöllisiä lääketieteellisiä hoitosuosituksia potilaille
CGM	Continuous Glucose Monitoring eli jatkuva glukoositasapainon monitorointi
CNN	Convolutional Neural Network eli konvoluutioneuroverkko
CPU	Central Processing Unit eli keskusyksikkö
CT	Computer Tomography eli tietokonetomografiakuvaus kuvantamisessa
CTM	Clinical Trial Matching on IBM:n kehittämä IBM Watsonia hyödyntävä syöpähoitosuositukseen kehitetty ratkaisu
DCNN	Deep Convolutional Neural Network eli konvoluutiollinen syvä neuroverkko
DL	Deep Learning eli syväoppiminen
DNN	Deep Neural Networks ovat monikerrosjärjestelmiä, jotka koostuvat datamuunnoksia suorittavista yhdistetyistä ja interaktiivisista neuroneista
DSS	Decision Support System eli päätöksenteon tuen järjestelmä
EBP	Error Backpropagation-algoritmi on vastavirta-algoritmi, joka perustuu kaarten optimointiin verkon tuloksen ja viitearvon välisen virheen perusteella
EEG	Electroencephalogram eli aivosähkökäyrä
EHR	Electronic Health Record eli digitaalinen potilaskertomusjärjestelmä
EKG	Elektrokardiografia eli sydänfilmi
EM	Emphysema eli keuhkolaajentuma
EMR	Electronic Medical Record eli digitaalinen potilasjärjestelmä
FB	Fibroosi tarkoittaa sidekudostumista, arpeutumista; tiiviin sidekudoksen muodostumista muun kudoksen rinnalle

fMRI	Functional Magnetic Resonance Imaging eli fMRI-kuvantaminen tarkoittaa toiminnallista magneettikuvausta, jolla tutkitaan aivojen toimintaa
GG	Ground glass eli mattalasimuutos tarkoittaa läiskäistä samentumaa, joka näkyy joidenkin lobulusten alueella
GPU	Graphical Processing Unit eli grafiikkaprosessori
HRCT	High Resolution Computer Tomography eli radiologian ohutleikekuvantamismenetelmä
HRV	Heart Rate Variability eli sykevaihtelu
IHR	Instantaneous Heart Rate eli hetkellinen syke
ILD	Interstitial Lung Disease eli Interstitiaalinen keuhkosairaus, jotka aiheuttavat keuhkokudoksen progressiivista arpeutumista
JASC	Judgement Correlation System eli korrelaatioiden arviointijärjestelmä
LSTM-RNN	Long Short-term Memory – Recurrent Neural Network on korkealla tarkkuudella aikasarjoja mallintava syväoppimiseen perustuva algoritmi
MLP	Multilayer Perceptron on tyypillinen Feedforward-neuroverkkomalli, jossa on kolme kerrosta: syöte, piilotettu ja ulostulo
MN	Micronodule eli mikronoduuli tarkoittaa pientä jyväistä tiivistymää, joka voi esiintyä sekä interstitiumissa että ilmateissä
NM	Normaali keuhkokudoksen luokittelu
MRI	Magnetic Resonance Imaging eli magneettikuvaus
NCPA	National Center for Policy Analysis on voittoa tavoittelematon Yhdysvaltalainen organisaatio, joka pyrkii uudistamaan terveydenhuoltoa
PH	Pulmonary Hypertension eli keuhkoverenpainetauti
PPG	Photo-Plethysmogram on teknologia, joka tunnistaa veren tilavuuden muutoksia käyttämällä analyyysimetodeja
ROI	Return on Investment eli sijoitetun pääoman tuottoaste
RNN	Recurrent Neural Network eli uusiutuva neuroverkko
SVM	Support Vector Machine-malli eli tukivektorikone on neuroverkolla toteutettavissa oleva lineaarinen luokitinmalli
VOC	Volatile Chemical Components eli haihtuva komponentti
WHO	World Health Organization eli maailman terveysjärjestö

SISÄLLYSLUETTELO

1	Johdanto	1
1.1	Raportin rakenne	2
2	Tekoäly – koneoppimisesta syväoppimiseen	4
2.1	Tekoälyn määritelmä	4
2.2	Tekoälyn hyötyjä ja haittoja	7
2.3	Tekoäly ja oppiminen	7
2.3.1	Neuroverkot	8
2.3.2	Koneoppiminen	13
2.3.3	Syväoppiminen	16
3	Tekoälyä hyödyntäviä ratkaisuja terveydenhuollossa	18
3.1	Tekoäly ja farmasia	20
3.1.1	Koneoppiminen ja tekoäly lääkkeiden sekä diagnosointialgoritmien kehityksessä	20
3.1.2	Tutkimusrobotti 'Eve' hyödyntää tekoälyä lääketutkimuksessa	22
3.1.3	Tekoäly auttaa tunnistamaan tehokkaasti yhdistelmä-lääkityksen syövän hoidossa	23
3.1.4	Syväoppiminen lääkkeiden farmakologisten ominaisuuksien ennustamisessa	24
3.2	Tekoäly ja insomnia	26
3.2.1	Mortheo-tekoälyalusta unihäiriöiden diagnosoinnissa	27
3.2.2	SleepASAP-sovellus etsii personoituja ratkaisuja unihäiriöihin	29
3.2.3	Syväoppiminen ja hetkellinen syke uniapnean vakavuuden tunnistamisessa	30
3.2.5	Tekoäly ja Somnox-älytyyny unihäiriöiden hoitamisessa	33
3.3	Tekoäly ja kardiologia	34
3.3.1	Integroitu CardioSmart365-järjestelmä sydänsairauspotilaiden monitorointiin	35
3.3.2	Tekoäly ja EHR sydämen vajaatoiminnan ennustamisessa	43
3.3.3	Tekoälyä hyödyntävä CAD-järjestelmä sydämen vajaatoiminnan diagnosointiin	44
3.3.4	Tekoäly ja koneoppiminen apuna sydänsairaiden eliniän ennustamisessa	47
3.4	Tekoäly ja onkologia	48
3.4.1	Ihosityövän diagnosointi älypuhelimien avulla	50
3.4.2	Neuroverkot aivojen MRI-kuvantamisessa aivokasvaimien tunnistamiseksi	51
3.4.3	Rintasyövän diagnosointi tekoälyä hyödyntämällä	53
3.4.4	Sovellusmalli keuhkosityövän diagnosointiin neuroverkkoja hyväksikäyttämällä	54
3.4.5	Watson for Clinical Trials Matching-ratkaisu	56
3.5	Tekoäly ja pulmonologia	58

3.5.1	Interstitiaalisten keuhkosairauksien CT-mallien luokittelu neuroverkkojen avulla	59
3.5.2	Tekoälyn hyödyntäminen keuhkotoimintotestien diagnosoinnissa	62
3.5.3	Tekoälyä hyödyntävä ennakoiva järjestelmä pediatriksen astman diagnosointiin	63
3.5.4	Tuberkuloosin diagnosointi tekoälyn avulla	66
3.6	Tekoälyn hyödyntäminen muissa sairauksien diagnosoinneissa	66
3.6.1	Nanotekninen puhalluslaite hyödyntää tekoälyä sairauksien diagnosoinnissa	67
3.6.2	Tekoälyä hyödyntävä HIKARI-rajapinta kliinisen päätöksenteon parantamiseen	70
3.6.3	Tekoälyalusta synnyynnäisen kaihin diagnosointiin	73
3.6.4	Tekoälyn hyödyntäminen skitsofrenian diagnosoinnissa	76
3.6.5	Tekoäly ja Your.MD-sovellus auttavat sairauksien diagnosoinnissa	78
4	Terveystuollon tulevaisuus	81
4.1	IoT – Internet of Things	83
4.2	Kyberturvallisuus	83
4.3	Telelääketiede	84
4.4	Robottiikka ja tekoäly	84
4.5	Virtuaalitodellisuus	87
5	Yhteenveto	89
	LÄHTEET	92

1 Johdanto

Tekoäly (Artificial Intelligence eli AI) oli alkujaan muotisana, joka tarkoitti ihmisaivojen jäljittelemistä ja reaali maailman ongelmien tutkimista holistisen ihmiskeskeisen lähestymistavan kautta. Tutkijat ja tiedemiehet ympäri maailman ovat innoissaan innovaation kehitysaskelista, jotka ovat nousseet ihmiselle luontaisesta halusta kehittää uusia ja parempia teknologioita, jotka tekevät mahdolliseksi ihmiskunnalle ylittää sen jäsenten fyysiset kyvyt. Lupaus tekoälyn käsitteestä on aina ollut horisontissa reaalityodellisuuden tiedemaailmasta aina elokuvaan ja kirjallisuuteen saakka. (Kannan, 2017)

Tekoäly mahdollistaa suurien varastoitujen datamäärien (tietovarastot) prosessoinnin älykkäällä tavalla ja relevantin informaation muuntamisen funktionaaliseksi työkaluiksi. Tekoälyä on käytetty hyvin monella sovellusalueella, joista tunnetuimpia kenties ovat puolustuksen ja avaruuden tutkimuksen alueet, joissa menestys ongelmien ratkaisemisessa tietyillä osa-alueilla on ollut menestyksekkästä. Tekoälyn sovellusalue on sittemmin laajentunut terveydenhuoltoon, jossa sitä hyödynnetään muun muassa diagnosoinnissa, hoitosuosituksien tekemisessä ja leikkaushoidossa. (Kannan, 2017)

Tekoäly on monin tavoin yhä hyvin aikaisessa kehitysvaiheessa, eikä se ainakaan vielä pärjää ihmisten älykkyydelle. Tekoäly ei vielä korvaa lääkäreitä tai hoitajia, mutta nykyajan koneet kykenevät käsittelemään valtavia määriä dataa ja tunnistamaan malleja, joita ihmiset eivät kykene löytämään. Tekoäly on pohjimmiltaan joukko monimutkaisia algoritmeja, jotka analysoivat dataa ja voivat olla työkalu, joka osaa ottaa täyden hyödyn digitaalisista potilastietojärjestelmistä muuntamalla ne sähköisistä lipastoista täysiverisiksi lääkäreiksi, jotka kykenevät tarjoamaan relevanttia kliinistä ja korkealuokkaista dataa reaaliajassa. (Hernandes, 2016)

Vuonna 1990 Garry Kasparov saavutti lähes rock-tähden aseman Shakkimaailmassa vapaatyylisellä strategiallaan pelata Shakkia ja voittaen maailmanlaajuisesti siihen mennessä kaikki hänet kohdanneet vastustajat ja tietokoneen algoritmit. Vuonna 1997 tapahtui kuitenkin käänne ja IBM:n Deep Blue-supertietokone kykeni voittamaan ihmiskunnan parhaan Shakin pelaajan. Tilanne ei jäänyt kuitenkaan ainutkertaiseksi, vaan kehityksen myötä IBM Watson-supertietokone voitti kaikki vastustajansa Jeopardy TV-tietovisassa. (Freiherr, 2015) Tämä avasi tietä Watsonin hyödyntämiselle myös terveydenhuollon kentässä, johon IBM on panostamassa voimakkaasti.

Tekoälyä on koetettu hyödyntää lääketieteessä jo pitkään ja ensimmäiset järjestelmät olivat sääntöpohjaisia tekoälyä hyödyntäviä asiantuntijajärjestelmiä, jotka rakennettiin diagnostiikka-algoritmeja käyttäen perustuen ihmisten kokemuksiin. Ne olivat osa isompaa SUMEX-AIM (Stanford University Medical Experimental Computer – Artificial Intelligence in Medicine)-kokonaisuutta. Eräs niistä oli MYCIN, joka kehitettiin 1970-luvulla ja sen tehtävänä

oli tunnistaa infektoita aiheuttavia bakteereita sekä suositella antibiootteja infektioiden hoitoja varten. MYCIN oli kuitenkin vain tutkimuskäyttöön suunniteltu ja toteutettu järjestelmä, eikä sitä koskaan käytetty kliinisessä diagnosoinnissa.

Kyseiset järjestelmät olivat kuitenkin todiste, että älykkäitä koneita voidaan rakentaa ja ne voivat vetää datan perusteella lääketieteellisiä johtopäätöksiä. Nykyään insinöörit työskentelevät syväoppimista hyödyntävien tekoälyjärjestelmien parissa, jotka voivat paljastaa hienovaraisia malleja lääketieteellisistä kuvista, laboratoriotesteistä ja potilaan historiatiedoista. Näitä malleja voidaan sitten käyttää diagnosoimaan sairauksia. Kehitteillä on myös useita erilaisia CDS (Clinical Decision Support)-järjestelmiä, jotka hyödyntävät Big Dataa tekemällä personoituja lääketieteellisiä hoitosuosituksia esitellen ne lääkäreille. (Freiherr, 2015)

Kuuluisat julkisuuden henkilöt, kuten Stephen Hawking, Elon Musk ja Bill Gates ovat olleet skeptisiä tekoälyn suhteen, vaikka tekoäly on kenties ihmiskunnan tämän hetken parhaita mahdollisuuksia ratkaista monia lääketieteellisiä pulmia, säästää kustannuksissa ja mahdollisesti jopa pelastaa ihmishenkiä. Tekoäly kykenee käsittelemään niin valtavia tietomääriä ja nopeassa tahdissa, ettei edes koulutettu lääketieteen asiantuntija siihen pysty. Tekoäly ja sen sovellukset eivät kuitenkaan vielä kykene lääketieteen alueella toimimaan täysin itsenäisesti ja tekemään päätöksiä, vaan jonkun täytyy tuottaa lääketieteellistä tietämystä tietovarastoihin, joita tekoälyjärjestelmät voivat sitten hyödyntää. Lisäksi tekoälyä hyödyntävien järjestelmien tekemät diagnosoinnit tarkistavat ja päätökset tekevät ihmislääkärit, tosin kaukaisessa tulevaisuudessa asia voi olla toisin.

1.1 Raportin rakenne

Luvussa 2 käsitellään tekoälyn kehityskaarta aina koneoppimisesta syväoppimiseen saakka. Kyseisessä luvussa esitellään tekoälyn määritelmä ja tekoälyn hyötyjä sekä haittoja. Lisäksi luvussa käsitellään tekoälyä ja oppimista neuroverkkoihin, kone- ja syväoppimiseen pureutuen. Luku antaa yleiskäsityksen tekoälystä ja sen kehityksestä 50-luvulta aina nykypäivään saakka. Luvussa käsitellään myös tässä raportissa esiteltyjen terveydenhuollon ratkaisujen menetelmiä, jotka ovat usean tekoälyä hyödyntävän lääketieteellisen IT-ratkaisun taustalla.

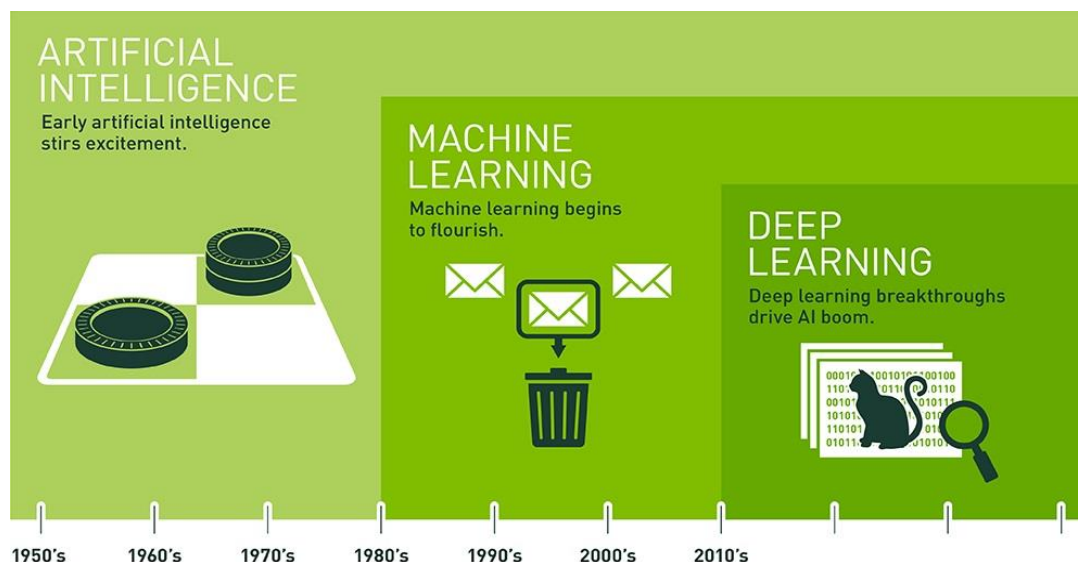
Luku 3 on tämän raportin keskeisin luku eli ydinluku, jossa esitellään tekoälyä hyödyntäviä ratkaisuja terveydenhuollon kentässä. Luku on jaettu lääketieteellisiin osa-alueisiin, jotka ovat farmasia (lääkitykset), insomnia (unihäiriöt), kardiologia (sydänsairaudet), onkologia (syöpätapaukset), pulmonologia (keuhkosairaudet) ja lisäksi muut tarkemmin luokittelemattomat sairaudet. Luku käsittelee terveydenhuollon ratkaisuja, jotka hyödyntävät tekoälyä sekä, kone- ja syväoppimista lääketieteellisten IT-ratkaisujen toteuttamisessa.

Luku 4 käsittelee terveydenhuollon tulevaisuuden näkymiä lähinnä teknologisesta näkökulmasta. Luvussa käsitellään terveydenhuollon tulevaisuutta koskien IoT (Internet of Things)-ratkaisuja, telelääketiedettä, robotiikkaa ja tekoälyä sekä virtuaalitodellisuutta. Luvussa esitellään erilaisia tulevaisuuden skenaarioita, tekoälyn hyötyjä tulevaisuudessa, teknologisia tekoälyä hyödyntäviä ratkaisuja jne. Kantaa otetaan myös kyberturvallisuushkiin, sillä ne muodostavat vakavan tietoturvan sairaalan tietojärjestelmien suhteen, jotka ovat monia muita järjestelmiä haavoittuvampia.

2 Tekoäly – koneoppimisesta syväoppimiseen

Neuroverkoista tulee mieleen helposti ajatus, että ne ovat uusimpien tietoteknisten innovaatioiden joukossa, mutta niiden kehitys alkoi jo samaan aikaan kuin ensimmäisten tietokoneiden eli 1950-luvulla. Tarve neuroverkkojen kehitykselle oli saada kielenkääntäminen automatisoitua, tosin merkittävää kehitystä kyseisellä alueella ei saatu aikaan, jolloin kehitys hidastui. Neuroverkkojen kehitys alkoi kukoistaa uudelleen 1980-luvulla, jolloin oli mahdollista saada uutta tietoa ihmisaivojen rakenteesta ja toiminnasta. Tämän lisäksi tietokoneiden suorituskyvyn nopea paraneminen on vaikuttanut neuroverkkojen kehitykseen positiivisella tavalla. (Bask ym., 1998)

Kuviosta 1 havainnollistuu tekoälyn kehityskulku, joka alkoi jo 50-luvulla. Tekoälyn termi on kyseisen aihealueen termeistä laajin, joka antaa tietokoneille mahdollisuuden matkia ihmisten älykkyyttä käyttämällä logiikkaa, jos-sitten (If-Then) -sääntöjä, päätöspuita, kone- ja syväoppimista. Koneoppiminen on tekoälyn osa-alue, joka käyttää tilastollisia teknologioita, jotka mahdollistavat koneiden oppivan kokemuksista. Kategoria sisältää myös syväoppimisen. Syväoppiminen on koneoppimisen osa-alue muodostuen algoritmeista, jotka mahdollistavat ohjelmiston itseoppimisen tehtävien suorittamiseksi, kuten puhe, kuvantunnistus jne. käyttämällä hyväksi neuroverkkoja suuren datamäärän käsittelemiseksi. (Parloff, 2016)



KUVIO 1. Kehityskulku tekoälystä syväoppimiseen. (Copeland, 2016)

2.1 Tekoälyn määritelmä


Tekoäly voidaan määritellä keinotekoisena älykkyytenä, jonka avulla voidaan ratkaista monimutkaisia ongelmia kyseisen järjestelmän ollessa tietokone tai kone. Tekoäly on tietotekniikan ja fysiologisen älykkyyden yhdistelmä, joiden avulla voidaan laskennallisesti päästä tavoitteisiin. Älykkyys on kyky ajatella luomalla muistia ja ymmärrystä, tunnistamalla

malleja, tekemällä muutokseen sopeutuvia valintoja ja oppimalla kokemuksista. Tekoäly voi saada koneet käyttäytymään kuten ihmiset vieden paljon vähemmän aikaa, mitä ihmiset käyttäisivät jonkin tietyn asian ratkaisemiseen. (Borana, 2016)


Tekoälyn juuret ovat pitkälti useilla eri tiedonaloilla, kuten:

- Biologia/neurotiede
- Filosofia
- Laskenta
- Logiikka
- Psykologia/kognitiotiede

Tekoälyä on sovellettu ja tullaan soveltamaan monella alueella (Kuvio 2), joista tämän raportin kannalta oleellisimpia ovat neuroverkot, sumea logiikka ja asiantuntijajärjestelmät. Tekoäly alkoi kehittyä Turingin koneesta (Kuvio 3), jolla mitattiin koneen kykyä älykkääseen käyttöön. Turingin koneen esitteli Alan Turing julkaisussaan: ”Computing Machinery and Intelligence”. Testin peruskysymyksenä on: ”Voivatko koneet ajatella?”. Testissä asetelmana on kuulusteleva ihminen ja toisella puolella tietokone ja toinen ihminen, joita kuulustelija ei voi nähdä. Keskustelu käydään luonnollisella kielellä ja mikäli kuulustelija ei voi luotettavasti todentaa, onko kuulusteltava ihminen vai kone, kone on läpäissyt testin. Testi tehdään tekstimuodossa, jotta puheesta ei voi päätellä, kummasta on kyse. (Borana, 2016)



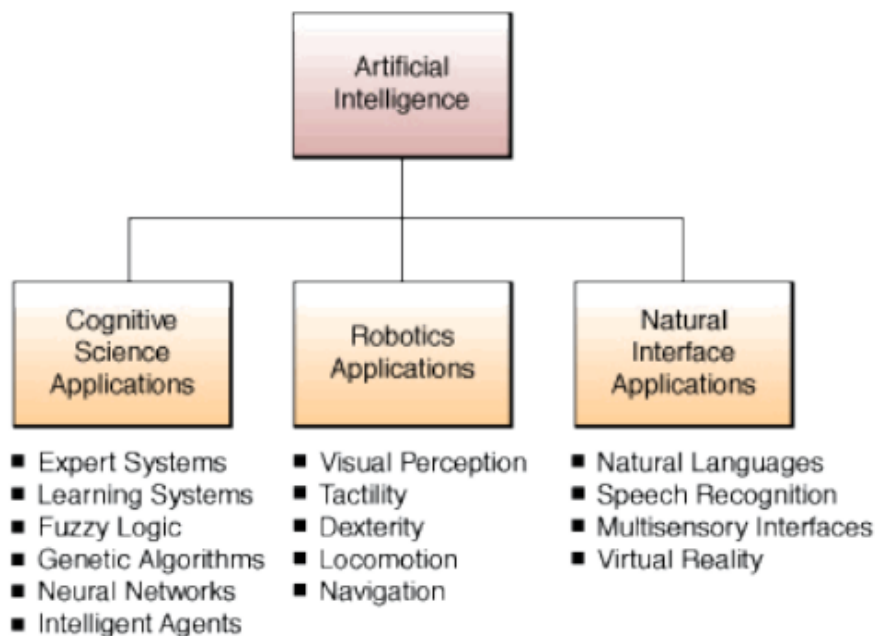
KUVIO 2. Tekoälyn hyödyntämisen alueita. (Borana, 2016)



KUVIO 3. Turingin testi. (Borana, 2016)

Tekoäly voidaan jakaa esimerkiksi seuraavalla tavalla sovellusalueisiin (Kuvio 4):

1. kognitiivisen tieteen sovellukset, 2. Robotiikan sovellukset ja 3. Luonnollisen kielen sovellukset. Kuvio 4 havainnollistuu tekoälyn jako erilaisiin sovellusalueisiin ja sovellusalueen käyttämiä menetelmiä.



KUVIO 4. Tekoälyn jako sovellusalueisiin ja niiden käyttämiä menetelmiä. (Borana, 2016)

2.2 Tekoälyn hyötyjä ja haittoja

Tekoälyn hyötyjä (Borana, 2016):

- Tiedon jakaminen on helpompaa, sillä kun tekoäly on opetettu tietyn asian suhteen, se voidaan helposti kopioida, eikä ole tarpeen järjestää koulutuksia, kuten ihmisille
- Toisin kuin ihmiset, koneet eivät tarvitse unta ja voivat työskennellä silloinkin, kuin ihmiset ovat jo väsyneet
- Yksi tekoälyn parhaita hyötyjä on, että päätökset tehdään perustuen faktoihin, eikä tunteisiin, sillä tunnetusti tunteet vaikuttavat ihmisten tekemiin päätöksiin negatiivisella tavalla

Tekoälyn haittoja (Borana, 2016):

- Kykenemättömyys selittää tietyn päätöksen takana olevaa logiikkaa ja päättelyä
- Luovuuden puute vastauksissa
- Nykyinen kehitys on vielä sillä tasolla, että tekoäly ei kykene päättämään, milloin tiettyyn ongelmaan ei ole ratkaisua
- Terveen järjen puute päättelyssä voi johtaa suuriin ongelmiin
- Toimintakyvyn häiriöt voivat johtaa tilanteeseen, jolloin tekoäly tuottaa vääriä ratkaisuja, sillä tekoäly ei kykene selittämään ratkaisuihin johtavaa päättelyä ko. tapauksessa
- Väärissä käsissä tekoäly voi aiheuttaa massiivisen mittakaavan ongelmia

2.3 Tekoäly ja oppiminen

Tekoäly on kulkenut pitkän tien aina Alan Turingin koneesta nykypäivän kognitiivisiin tekoälyä hyödyntäviin innovaatioihin saakka. Alan Turing aikoinaan alkoi kehittää teknologioita, kuten neuroverkot, jotka tekevät tekoälyn, jona sen nykyään tunnemme, mahdolliseksi. Tekoäly on laaja sateenvarjotermi, jonka tarkoituksena on saada tietokoneet ajattelemaan, kuten ihmiset ajattelevat ja simuloimaan asioita, joita ihmiset tekevät ja lopulta ratkaisemaan ongelmia paremmin ja nopeammin kuin ihmiset kykenevät ratkaisemaan. Tehtävyyt voivat olla muun muassa luovia tehtäviä, suunnittelua, liikkumista, puhumista, objektien ja äänien tunnistamista, sosiaalisten ja liiketoiminnallisten transaktioiden suorittamista. (Buczowski, 2017)

Nykyään tekoäly on kaikkialla ympärillämme ja suuret yritykset, kuten Google käyttää koneoppimisen menetelmiä esimerkiksi suodattaessaan roskapostia Gmail-palvelustaan. Facebook on opettanut tietokoneita tunnistamaan tiettyjä ihmisen kasvojen piirteitä lähes yhtä tarkasti kuin ihmiset tekevät. Netflix ja Amazon käyttävät syväoppimista tekemään päätöksiä, mitä asiakkaat haluavat katsoa tai ostavat seuraavaksi jne. Kone- ja syväoppimisen menetelmien hyödyntäminen tekoälyn kehittämiseksi on tuottanut lupaavia tuloksia ja niiden idea on periaatteessa yksinkertainen. Traditionaalisen tietokoneiden ohjelmoinnin ja älykkääksi tekemisen yrittämisen sijasta tietokoneelle annetaan pääsy laajaan datamäärään

ja ne ohjelmoidaan löytämään malleja sekä oppimaan itsenäisesti, miten vaadittu tehtävä suoritetaan. (Buczowski, 2017)

Lääketieteen alueella nykyisin lääkärit hyödyntävät tietokoneen tarjoamia neuvoja 2/3 tapauksista esimerkiksi selvittäessään vaihtoehdoisen lääkityksen riskejä potilaalle. Tietokoneet ovat erityisen hyviä jäsentelemään niin sanottua rakenteellista (Structured) dataa eli informaatiota, jota voidaan helposti sijoittaa kategorioihin. Terveystieteiden kentässä data on usein varastoitu laskutuskoodeina tai laboratoriotestien tuloksina. Tämä data ei tosin kykene vangitsemaan potilaan kaikkia oireita tai niiden hoitomahdollisuuksia- ja suosituksia. Kuvat, radiologian raportit ja lääkärin muistiinpanot potilaista ovat käyttökelpoisempia, mutta ne ovat rakenteetonta (Unstructured) dataa, jollaista tietokoneet eivät niin hyvin osaa käsitellä, koska se vaatii päättelyjen tekemistä ja tietynlaista ymmärrystä kontekstista ja asian tarkoituksesta. Ihmiset ovat parempia rakenteettoman tiedon käsittelyssä kuin koneet, mutta tutkimusryhmät ja tiedemiehet koettavat opettaa koneet toimimaan paremmin myös rakenteettoman datan käsittelyssä. (Hernandez, 2014) Tähän prosessiin tarvitaan tässä luvussa esiteltyjä menetelmiä.

2.3.1 Neuroverkot


Keinotekoiset neuroverkot (Artificial Neural Networks eli ANN) ovat informaation prosessointiparadigma, jota inspiroivat biologiset hermojärjestelmät, kuten aivot. Paradigman avainelementtinä on informaation prosessoinnin järjestelmän uusi malli. Neuroverkot muodostuvat suuresta määrästä toisiinsa yhteen liittyneitä elementtejä (neuronit), jotka toimivat yhdessä tiettyjen määriteltyjen ongelmien ratkaisemiseksi. Keinotekoiset neuroverkot, kuten myös ihmiset, oppivat esimerkeistä. Neuroverkko on voitu esimerkiksi konfiguroida oppimisprosessin kautta jollekin tietylle sovellusalueelle, kuten mallien tunnistaminen tai datan luokittelu. Biologisten järjestelmien oppimiskyky on samankaltainen, sisältäen sovittelua neuronien välisiin synaptisiin yhteyksiin. (Stergiou ym.)

Ensimmäisen neuroverkkotietokoneen kehittäjä, Robert Hecht- Nielsen, määrittelee neuroverkot seuraavalla tavalla:

”Neuroverkot ovat tietotekninen järjestelmä, joka on rakentunut suuresta määrästä toisiinsa kiinteästi liittyneitä prosessointielementtejä, jotka prosessoivat informaatiota dynaamisen tilanvasteen kautta ulkoisille syötteelle”. (Bell, 2014, 91)


Keinotekoiset neuroverkot perustuvat ajatukselle, että ihmisaivojen toimintaa oikeiden yhteyksien luomisessa voidaan jäljitellä käyttämällä piitä ja johtoja elävien neuroneiden ja dendriittien sijasta. Ihmisaivot koostuvat sadasta miljardista hermosolusta, joita kutsutaan neuroneiksi. Neuronit voivat olla motorisia tai sensorisia ja informaation välistys hermostossa voi olla kemiallista tai sähköistä (hermoimpulssit). Dendriitit taas ovat haarautuneita ristikkosolun haarakkeita ja niiden muodostamaa rakennetta kutsutaan dendriittipuuksi, joka

toimii kehon tiedonkeräämisvälineenä. Neuronilla on monia dendriittejä, keskimäärin yli 10 000 yhtä neuronin kohti. Viejähaarake eli aksoni on kaapelin kaltainen letka, jonka pituus voi ihmiskehossa olla yli metrin mittainen. Aksonin tehtävänä on kuljettaa neuronin tulleita hermoimpulsseja eteenpäin synapsin välityksellä toiseen neuroniin tai kohde-elimeen. Aivojen toimintaa havainnollistetaan kuviossa 5. (Tutorialspoint, 2017)



KUVIO 5. Hermosolun semantiikka. (Tutorialspoint, 2017)

Keinotekoiset neuroverkot koostuvat useista solmuista, jotka jäljittelevät ihmisaivojen biologisia neuroneita. Neuronit ovat yhdistetty toisiinsa linkkien kautta ja ne ovat vuorovaikutuksessa toistensa kanssa. Solmut voivat vastaanottaa yksinkertaista syöttödataa ja ne voivat suorittaa yksinkertaisia operaatioita datalla. Kyseisten operaatioiden tulokset välitetään toisille neuroneille ja jokaisen solmun ulostuloa kutsutaan solmun arvoksi. Jokaiseen linkkiin liittyy painokerroin ja sen muutos vaikuttaa keinotekoisien neuroverkkojen kykyyn oppia. (Tutorialspoint, 2017) Kuviossa 6 havainnollistuu yksinkertainen keinotekoinen neuroverkko.




KUVIO 6. Yksinkertainen keinotekoinen neuroverkko. (Tutorialspoint, 2017)


Neuroverkkojen vahvuudeksi voisi mainita, että ne voivat ratkaista ei-eksakteja ongelmia epätäydellisillä syötteillä. Neuroverkoilla on kyky oppia vastaanottamiensa syötteiden perusteella uusia ratkaisutapoja, jolloin opittujen ratkaisutapojen myötävaikutuksesta ne voivat ratkaista samankaltaisia ongelmia. Neuroverkoilla on useita erilaisia oppimistapoja, joista yksi tapa on antaa ongelman lisäksi sen ratkaisu, jolloin verkko voi tarkistaa ratkaisun, johon se päätyi omatoimisesti pääättelemällä. Toinen mahdollinen tapa on tuoda verkolle sopiva määrä dataa ja antaa sen ratkaista ongelmia itsenäisesti, jolloin oppiminen tapahtuu yrityksen ja erehdyksen kautta. (Bask ym., 1998)

Muita oppimisen tapoja ovat kilpailuoppiminen ja error back propagation, jossa tarkoituksena on laskea virhegradienttia. Fyysisessä mielessä oppiminen tapahtuu solujen liitosten painoarvojen muutoksina. Oppimissääntö on neuroverkon keskeisin ominaisuus ja sen valintaan vaikuttaa kuinka nopeasti verkon halutaan oppivan ja kuinka nopeasti verkolta halutaan vastaus annettuun ongelmaan. Neuroverkot jakautuvat Feed-Forward- ja FeedBack-verkkoihin ja ne toimivat luonnostaan assosiativisena muistina eli syöte voi olla epätäydellistä sisältäen kohinaa. (Bask ym., 1998)

Kuten edellä mainittiin, keinotekoisia neuroverkkoja on kahta tyyppiä: Eteenpäin syöttävä eli Feed Forward (Kuvio 7) ja takaisinkytketty (Kuvio 8) eli Feedback neuroverkko. Eteenpäin syöttävässä verkossa informaation virta on yksisuuntaista ja yksikkö lähettää informaatiota toiselle yksikölle, jolta se ei vastaanota yhtään informaatiota. Eteenpäin syöttävässä neuroverkossa ei ole paluusiilmukkaa. Tätä neuroverkkotyyppiä käytetään mallien generointiin, tunnistamiseen ja luokitteluun. Niillä on kiinteä syöte ja ulostulo. Takaisinkytkettyjä neuroverkkoja käytetään esimerkiksi CAM (Content Addressable Memory) -muistien yhteydessä. (Tutorialspoint, 2017)



KUVIO 7. Eteenpäin syöttävä neuroverkko. (Tutorialspoint, 2017)



KUVIO 8. Takaisinkytketty neuroverkko. (Tutorialspoint, 2017)

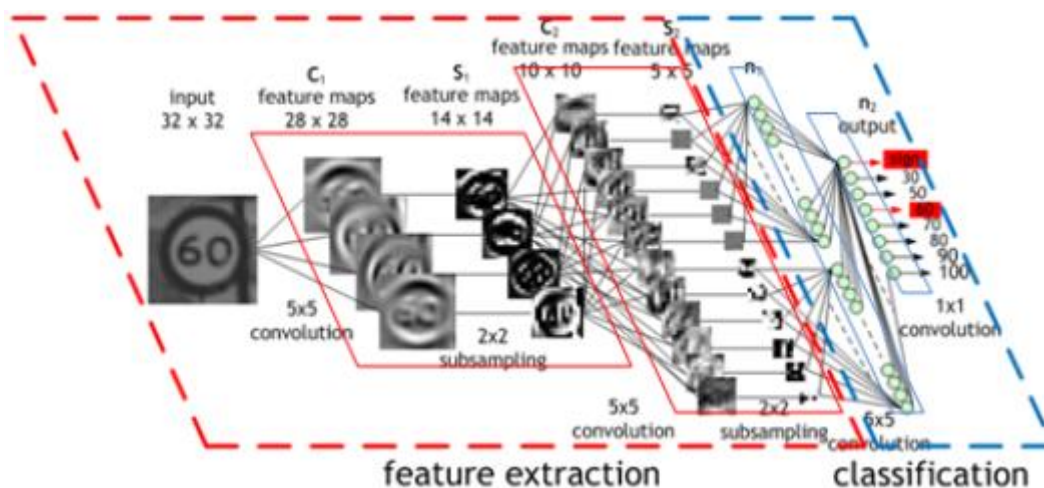
Back Propagation (BP) eli vastavirta-algoritmiin perustuva neuroverkko on amerikkalaisten v. 1986 julkaisema menetelmä, jonka vahvin etu on sen lähtöfunktion jatkuvuus BP:ssä. BP:ssä ihmisen tuottamaa tietoa on vaikea yhdistää neuroverkon informaatioon, joka laskee BP:n käyttöarvoa. BP-verkon topologiaa määrittäessä on tarpeen ratkaista, mitkä suureet ovat tuloja ja mitkä lähtöjä (Bäck ym. 1996) Muodoltaan Back Propagation-neuroverkot ovat monikerroksisia eteenpäin syöttäviä verkkoja, jotka on opetettu back propagation-algoritmia käyttäen ja ne ovat yksi laajimmin käytetyistä neuroverkkomalleista. BP-verkkoja voidaan käyttää oppimaan ja varastoimaan suuria määriä sisään-ulostulomallin kartoitussuhteita. Periaatteessa BP-algoritmi on paljon laskemista vaativa oppimisen monitoroinnin algoritmi, joka oppii vain jonkin funktion syötteen ja ulostulon välillä. (Li ym., 2012)

Koneoppimisessa konvoluutioneuroverkot (Convolutional Neural Network eli CNN) ovat tyypiltään eteenpäin syöttäviä eli Feed Forward keinotekoisia neuroverkkoja, jotka koostuvat yhdestä tai useammasta konvoluutiokerroksesta, joita seuraa yksi tai useampi täysin yhdistynyt kerros standardoidussa monikerroksisessa neuroverkossa. CNN-verkkojen arkkitehtuuri on suunniteltu hyötymään syötteenä lähetetyn kuvan (tai muun 2D-syötteen, kuten puhesignaali) 2D-rakenteesta. CCN-verkot ovat myös helpompia opettaa ja niillä on huomattavasti vähemmän parametreja kuin täysin yhdistyneillä verkoilla, joilla on sama määrä piilotettuja yksiköitä. (UFLDL Tutorial)

Konvoluutioverkot käyttävät hyväkseen konvoluutiokerroksia, jotka suodattavat sisääntulon dataa hyödylliseksi informaatioksi. Näillä konvoluutiokerroksilla on parametreja, jotka on opetettu niin, että ne suodattavat automaattisesti hyödyllisimmän informaation valitun tehtävän suorittamiseksi. Joissain tapauksissa voi olla hyödyllistä suodattaa informaatiota objektin muodosta (objekteilla useimmiten on eri muotoja). Esimerkiksi linnun

tunnistamistehtävässä voi olla sopivinta poimia tietoa linnun väristä, sillä useimmilla linnuilla on samankaltainen muoto, mutta ei värit. Konvoluutioverkot mukautuvat automaattisesti löytämään parhaat ominaisuudet tehtävän suorittamiseksi. (Dettmers, 2015)

Useimmiten on tarpeen käyttää useita konvoluutiokerroksia suodattamaan kuvista enemmän ja enemmän abstraktia informaatiota. Konvoluutioverkot käyttävät yleensä yhdistelmäkerroksia (Pooling Layers) objektin tunnistamiseksi, vaikka se sijaitisi epätavallisessa paikassa. Pooling-kerroksien käyttäminen vähentää myös muistinkulutusta ja useiden eri konvoluutiokerroksien hyödyntämisen. Kuvista 9 havainnollistuu konvoluutioverkkojen toiminta kuvantunnistuksessa (liikennemerkki). Liikennemerkki suodatetaan neljällä 5x5 konvoluutioytimen avulla, jotka luovat neljä ominaisuuskarttaa, jotka osanäytteistetään. Seuraavalla tasolla on 10 kpl 5x5 konvoluutioydintä, jotka osanäytteistävät ja tehdään ominaisuuskartat. Viimeisellä tasolla on yhdistelmäkerros, johon yhdistetään kaikki generoidut ominaisuudet. (Dettmers, 2015)



KUVIO 9. Konvoluutioverkkojen toiminta kuvantunnistuksessa.(Dettmers, 2015)

Konvoluutioneuroverkot tarjoavat uusinta teknologiaa ja ne voittavat aiemmat menetelmät tarkkuudessa, mutta vaativat huomattavia määriä laskentatehoa ja muistia. Tämä johtaa tilanteeseen, jossa CNN:t toimivat CPU (Central Processing Unit)- tai GPU (Graphics Processing Unit)-klustereissa. CNN:iä voidaan hyödyntää kuvien luokittelussa, tunnistamisessa ja lokalisaatiotehtävissä. Tutkimus CNN-verkkojen (ja muiden syväoppimisen teknologioiden) alueella jatkuu nopeana satojen julkaisujen vuosivauhdilla. Ongelmia tosin aiheuttavat valtavat laskentatehon ja muistin vaatimukset, joissa osassa verkkoja voi olla jopa 140 miljoonaa liukulukuparametria ja ne voivat suorittaa yli 15 miljardia liukulukuoperaatiota yhden kuvan luokitteluksi. Hyötynä tästä on muun muassa yhteensopivan syväoppimisen viitekehysten (kuten Caffe) käyttömahdollisuus. (Zhao ym., 2017)

2.3.2 Koneoppiminen

Oppimista on kahdenlaista induktiivista ja deduktiivista. Induktiiviset koneoppimisen menetelmät muodostavat sääntöjä ja malleja suurista tietojoukoista. Induktiivinen päättely tarkoittaa yleistä teoriaa ja yleistystä ja induktiivinen yksittäisistä havainnoista tuotettu yleistys nähdään tietoa lisäävänä prosessina. Deduktiivinen päättely etenee johtamalla yleistyksestä yksittäistapausta koskeva johtopäätös ja se nähdään päättelynä tunnetuista tapauksista toisiin tunnettuihin tapauksiin, eikä se lisää tietoa. (Saarinen, 1999)

Induktiivinen oppiminen voidaan induktiivisen päättelyn määrittelyn pohjalta nähdä siten, että opiskeltavaa aihetta lähestytään yksittäisen havaitun ilmiön kautta ja oppimisprosessin aikana oppija saa uutta tietoa. Oleellista on omakohtaisuuden korostuminen ja omakohtainen kokemus sekä havainto yhdistettynä johonkin ongelmaan saa aikaan halun tutkia ja tietää asiasta lisää. Syntyy aktiivinen oppimisprosessi, jossa opitut asiat yhdistyvät aiempaan jo kerättyyn informaatioon ja kokemuksiin. Tällöin oppimista syntyy syvätasolla ja näin opitut asiat jäävät oppijalla pitkäkestoiseen muistiin, jolloin ne on helppo palauttaa mieleen tarpeen mukaan.

Deduktiivisessa menetelmässä opetus alkaa esimerkiksi opettajan luennoilla luennoimien periaatteiden kautta ja se on perinteinen opintomaailmassa käytettävä lähestymistapa. Deduktiivinen on vastakkainen oppimistapa induktiiviseen verrattuna eli aloitettaessa opiskelu teoreettiselta tasolta, siitä voidaan edetä yksittäisiin asioihin. Ongelmana tässä lähestymistavassa on deduktiivisen prosessin vaikuttaminen teennäiseltä. Valmis teoria ei kaikissa tapauksissa ilman omakohtaista tiedon tarvetta kosketa oppijaa tai herätä mielenkiintoa, eikä se aktivoi oppijan jo aiemmin mahdollisesti aivoissaan muodostuneita tietorakenteita, jolloin opiskeltava asia voi jäädä irralliseksi, eikä pysyviä tietorakenteita välttämättä muodostu. (Prince ym., 2007)

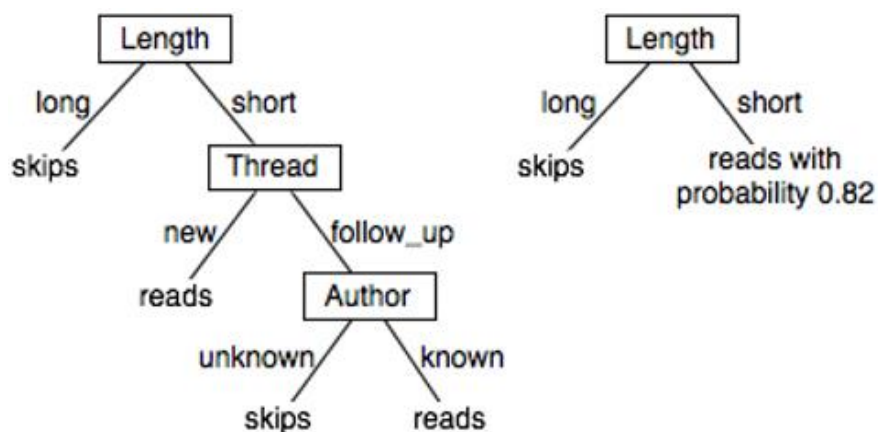
Koneoppiminen on tekoälyn osa-alue ja data-analyysimetodi, joka automatisoi analyyttistä mallin rakentamista. Käyttämällä algoritmeja, jotka iteratiivisesti oppivat käyttämällä dataa, koneoppiminen tarjoaa tietokoneille mahdollisuuden löytää piilossa olevia oivalluksia ja ideoita, vaikkei niiden kohdetta välttämättä edes oltu algoritmiin ohjelmoitu. Koneoppimisessa ohjelmistolle ei aina ole kirjoitettuna algoritmia kaikkia tilanteita varten, vaan kone oppii itsenäisesti ja päätyy haluttuun lopputulokseen. Toiminta on hieman samankaltaista kuin hakukoneilla, jotka tarjoavat niin osuvia- ja oikeita hakutuloksia käyttäjilleen kuin mahdollista. Koneen oppimiskyky kehittyy itsestään aina kun tietoa lisätään tietokantaan. (SAS)

Koneoppimisella on yhteisiä piirteitä tilastotieteen kanssa, sillä molemmissa tehdään päätelmiä aineistoihin perustuen, mutta koneoppimisessa tarkastelun kohteena on ohjelmallisten toteutusten laskennallinen vaativuus. Useat eri päättelyongelmat ovat NP-

kovia tai jopa vaikeampia, joten koneoppimisen tutkimiseen kuuluu lisäksi likimääräisten päättelyalgoritmien kehitystyö. Koneoppimisen algoritmit luokitellaan niille annettavan opetusdatan perusteella ja yleisemmät algoritmien tyypit ovat:


1. Ohjaamaton oppiminen (opetusdatasta ei tiedetä mitään aiemmin)
2. Ohjattu oppiminen (opetusdatasta tiedetään haluttu ulostulo)
3. Vahvistusoppiminen (oppiminen tapahtuu mallin ja ympäristön jatkuvan vuorovaikutuksen seurauksena)

Koneoppimisen kenties tunnetuimpia ohjatun oppimisen malleja ovat päätöspuut (Decision Trees), jotka ovat yksinkertaisia binääripuita, joiden avulla järjestelmä kykenee tekemään päätöksiä. Yksittäiset puut eivät pelkästään ole oppivia järjestelmiä, sillä niiden luonne on staattinen, mutta useiden puiden (metsä) yhteiskäyttö ja uusien puiden luomisen avulla voidaan saavuttaa oppiva järjestelmä. Kuvion 10 oikealla puolella oleva päätöspuu on oppiva todennäköisyyden muuttuessa päätösten perusteella. Päätöspuiden toimivuus yksinkertaisissa järjestelmissä on hyväksi havaittu, mutta isommissa järjestelmissä ne eivät ole enää paras menetelmä.



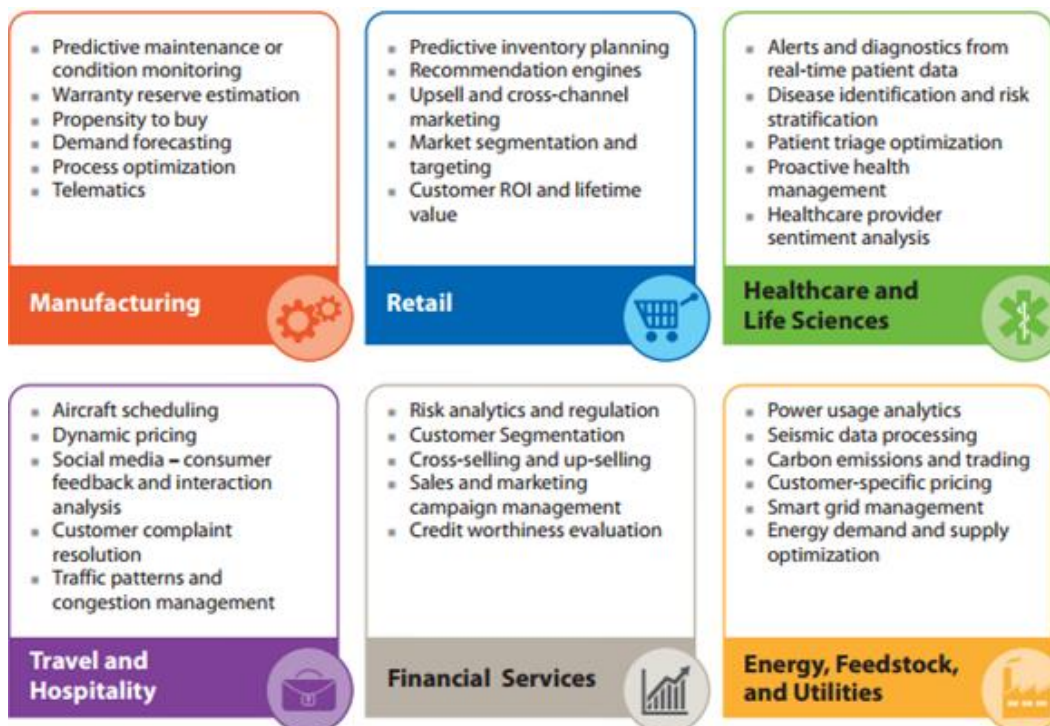
KUVIO 10. Yksinkertainen päätöspuu.(Poole & Mackworth, 2010)

Koneoppimisessa voidaan käyttää myös graafiteoriaan ja todennäköisyytlaskentaan perustuvia malleja, esimerkiksi Bayes-verkkoja. Ne ovat suhteellisen yksinkertaisia, suunnattuja syklittömiä verkkoja, jotka toimivat siten, että jos henkilöllä on koomaan johtava päänsärky (Kuvio 11), hänellä on todennäköisesti myös aivokasvain. Tämä ei kuitenkaan tarkoita, että tulos on täysin varma eli on mahdollista, että henkilö on kärsinyt päänsärystä ja joutunut koomaan, vaikka hänellä ei ole aivokasvainta. Koneoppimisen yhteydessä Bayes-verkkoja käytetään silloin, jos halutaan kerätä tietoa tuntemattomasta systeemistä, jolloin voidaan aloittaa pienellä verkolla ja lähteä laajentamaan sitä.



KUVIO 11. Esimerkki Bayers-verkosta.(Fukushige)

Koneoppimista käytetään useilla eri sektoreilla, kuten finanssipalvelut, hallituksen toiminnot, terveydenhuolto, markkinointi ja myynti, öljy- ja kaasuteollisuus, kuljetusala jne. Ehkä kuitenkin tunnetuimpia koneoppimisen käyttötavoista nykypäivänä on mallien tunnistaminen (Pattern Recognition), koska sen avulla voidaan tunnistaa useita eri tyyppisiä kuvia. Esimerkiksi USA:n posti käyttää koneoppimista tunnistamaan käsialakirjoitusta. (SAS) Koneoppimisen sovellusalueita on tarkemmin esiteltynä kuviossa 12.



KUVIO 12. Koneoppimisen sovellusalueita eri teollisuudenaloilla. (Sarkar, 2016)

2.3.3 Syväoppiminen

Syväoppiminen (Deep Learning) on koneoppimisen osa-alue, joka alkoi kehittyä vuodesta 2006 ja se on tullut pinnalle yhä enemmän vuoden 2012 jälkeen. Kyseisellä osa-alueella käytetään useita epälineaarisia informaation prosessoinnin tasoja ja hierakkisia arkkitehtuureita. Syväoppimisen tavoitteena on luoda sopivaa algoritmia käyttäen neuroverkko, joka tähtää soveltuvan ongelman ratkaisemiseen. Ongelmia, joiden ratkaisemiseen syväoppimista käytetään, ovat perinteisiä menetelmiä käyttäen vaikeita toteuttaa, sillä ne vaativat monimutkaisten sääntöjen käyttöä. Syväoppimisen hyödyntämisen alueita ovat muun muassa lääketieteen diagnostiikka, puhe, kuvat, tekstien tunnistaminen ja käsittely. Ehkä monelle tunnetuimpia hyödyntämisen alueita ovat puheentunnistuksen palvelu, kuten Applen Siri ja Googlen Street View-karttapalvelu. (Tjoa, 2013)


Syväoppiminen (Akagi, 2014) on:

- Kokoelma tilastollisia koneoppimisen teknologioita
- Käytetään oppimaan toimintohierarkioita
- Perustuvat keinotekoisiiin neuroverkkoihin

Syväoppimisen algoritmien suorituskykyä voidaan parantaa muun muassa:

1. Lisäämällä dataa
2. Tuottamalla/generoimalla lisää dataa
3. Dataa uudelleen skaalaamalla
4. Dataa muuntamalla

Syväoppiminen ja lisäksi muut modernit epälineaariset koneoppimisen teknologiat tulevat suorituskykyisemmiksi, mikäli dataa lisätään (Kuvio 13). Dataa tuottamalla/generoimalla suorituskykyä voidaan myös parantaa ja esimerkiksi kuvadatan ollessa kyseessä, jo olemassa olevien kuvien kääntäminen tai kohinan (Jitter) lisääminen voi parantaa mallin yleistettävyyttä. Datan uudelleen skaalaus on tärkeä vaihe ennen kone- ja syväoppimisen algoritmien käyttämistä. Data-aineistosta voidaan tehdä uudelleen skaalattuja kopioita ja niitä voidaan kilpailuttaa toisiaan vastaan, jolloin on mahdollista nähdä hyödyt ja puutteet datan uudelleen skaalauksesta tietyillä malleilla. Dataa muuntamalla neuroverkot voidaan saada oppimaan nopeammin, jos ratkaistavan ongelman rakenne on paremmin oppivien verkkojen käytössä. (Brownlee, 2016)



KUVIO 13. Syväoppimisen vs vanhempien teknologioiden skaalautuvuus.(Brownlee, 2016)


3 Tekoälyä hyödyntäviä ratkaisuja terveydenhuollossa

Tutkimuksien mukaan 88 % diagnosointitilanteista arvioita pyydetään myös toiselta lääketieteen ammattilaiselta, kuten lääkäriltä. Diagnosointivirheistä 10 % johti potilaiden kuolemaan ja 17 % komplikaatioihin. Huolimatta jo pitkään kehittyneestä sairauksien paremmasta ymmärtämisestä sekä testien kehittymisestä, diagnosointi on silti myös osittain niin taidetta kuin tiedettä ja alttiina epätarkkuuksille, ja jopa henkeä uhkaaville virheille. (13D Research)

Teknologiayritysten ja yliopistojen tutkimuslaboratorioiden sekä urauurtavien sairaaloiden koneoppimisen algoritmeja hyödyntävät diagnostiikkasovellukset ovat nopeassa tahdissa siirtymässä teoriasta käytäntöön. Muutospotentiaali on valtava ja koneoppiminen tarjoaa välittömän toisen mielipiteen diagnoosista, se voi toimia kotiolosuhteissa varhaisen vaiheen tunnistuksen työkaluna sairastapauksissa ja tarjota tähän mennessä tarkimman diagnoosimenetelmän historiassa. Koneoppiminen diagnoosityökaluna on tehokas ja säästää potilaiden, lääkäreiden ja sairaalan kustannuksia sekä mikä tärkeintä, elämiä. (13D Research)

Koneoppimisen menetelmiä on käytetty tehokkaasti erityisesti syövän tunnistamisessa ja esim. tutkijaryhmä Stanfordin yliopistosta opetti neuroverkolle, miten löytää 130 000 kuvan tietokannasta syöpätapauksia ja tehdä diagnooseja. Tutkijaryhmä testasi neuroverkkoa myös 14 000 iholeesioista koostuvan tietokannan kanssa, jolloin koepaloja ei tarvinnut ottaa, vaan neuroverkkoa opetettiin koneoppimisen avulla, jolloin se osasi opettamisen jälkeen tehdä päteviä diagnooseja 72 % tarkkuudella. Vertailukohtana olivat ihotautilääkärit, jotka kykenivät diagnosoimaan pienemmällä 66 % tarkkuudella. Testiä laajennettiin kattamaan 25 lääkäriä ja käytössä oli 2000 iholeesio kuvaa, joissa kaikissa tapauksissa oli otettu koepalat. Neuroverkko kykeni päihittämään asiantuntijalääkärit kaikissa tilanteissa. (13D Research) Kuvioista 14 ilmenee neuroverkkojen tyypillisiä sovellusalueita, jotka ovat kuva-analyysi, biokemiallinen analyysi, lääkesuunnittelu ja diagnostiikkajärjestelmä.

Tekoäly terveydenhuollossa eli AIM (Artificial Intelligence in Medicine) on tietojenkäsittelyn hyödyntämistä älykkäänä työkaluna, joka auttaa kliinisessä arvioinnissa ja päätöksenteossa (Rodriguez, 2016). Tutkijoiden tuodessa lisää dataa algoritmeille, työkaluista tulee yhä tarkempia ja niistä tulee olemaan entistä enemmän hyötyä sairaaloille ja lääkäreille. Tekoäly on vaikuttanut useaan alueeseen sairaalamaailmassa aina yksilökeskeisestä lääketieteestä operationaalisten ja ennustavien kustannusten hallinnan parantamiseen asti. Myös laitteistovalmistajat hyötyvät, sillä sairaalaympäristöt vaativat tehokkaita informaatioteknologisia laitteistoja ja laskentakykyä. Suurimmat toimijat, kuten IBM, Microsoft ja Amazon ovat vahvasti läsnä terveydenhuollon sektorilla, sillä sairaalat ja vakuutusyhtiöt tarvitsevat Big Data-analytiikan infrastruktuuria. (13D Research)



KUVIO 14. Neuroverkkojen pääsovellusalueita lääketieteessä. (Amato ym. 2013)

Nykyään tekoälyä voidaan hyödyntää useilla terveydenhuollon sektoreilla, joista syöpätutkimus on yksi oleellisimmista. Syöpä on yksi tappavimmista sairauksista ja sen hoidossa sekä tutkimuksessa ollaan edistytty viime aikoina. Tekoälyä on käytetty ennustamaan, minkälaiset yhdistelmä lääkkeet voivat auttaa taistelussa erilaisia syövän tyyppäjä vastaan. Tutkimuksien mukaan 100 lääkeainetta voidaan käyttää luomaan 5000 erilaista kahden lääkkeen yhdistelmä lääkettä ja mitä useampi lääkeaine on kyseessä, sen enemmän yhdistelmiä voidaan luoda. Tekoälyn avulla on voitu tehokkaasti ennustaa ja tunnistaa lääkeaineiden yhdistelmiä, joita on myöhemmin voitu varmistaa toimiviksi kokeellisilla testeillä. (Murphy, 2015)

Syöpään menehtyneiden määrä on vähentynyt vuodesta 1991 25 % ja useimpina menneistä vuosista, mahdollisuuksia tehokkaiden menetelmien, kuten geenien muokkaus ja tekoäly, hyödyntäminen ei ole ollut vielä mahdollista. Edellä mainittujen teknologioiden hyödyntäminen auttaa parantamaan hoitoja huomattavasti nopeammin kuin aiempina vuosikymmeninä on nähty. On ennustettu, että vain viiden seuraavan vuoden aikana tekoälyä hyödyntävä tutkimus tulee todennäköisesti tarjoamaan tehokkaita hoitoja lähes kaikkiin syövän tyyppäihin ja mahdollisesti parantamaan osan niistä. Syöpään menehtyneiden määrä todennäköisesti tulee jatkamaan laskuaan uusien teknologioiden myötä. (Murphy, 2015)

Tekoälyn kehityksestä on ennustettu, että 30 – 50 seuraavan vuoden aikana tekoäly auttaa voittamaan syövän geenien manipuloinnin, nanorobottien, tekoälyn itsensä jne. avulla. Kaikkia elintärkeitä elimiä voidaan monitoroida 24 tuntia vuorokaudessa seitsemänä päivänä viikossa nanorobottien uidessa suonien sisällä. Geeniterapia tulee myös radikaalisti vähentämään sairauksien haittoja ja määrää, ellei kokonaan eliminoimaan ne. Tekoälyn älyn kehitys on ennustettu saavuttavan keskinkertaisen ihmisen älykkyyden, joka antaa tekoälyn hyödyntämiselle aivan uudenlaisia mahdollisuuksia ja varmasti myös uhkia. (Murphy, 2015) Tulevaisuuden ennustaminen on kuitenkin vaikeaa ja voi olla, että kehitys ei edistyäkään ennakoitua vauhtia tai sitten vauhti on ennakoitua huimempaa, se jää nähtäväksi.

3.1 Tekoäly ja farmasia

Farmasia tarkoittaa lääkkeen valmistuksen taitoa ja on myös monitieteinen, soveltava ja laaja-alainen tieteenala, joka tutkii lääkeaineiden- ja valmisteiden ominaisuuksia, lääkehoitoa sekä lääkkeiden valmistamista ja käyttöä luonnontieteiden, yhteiskuntatieteiden ja terveystieteiden näkökulmasta. Alun perin lääkärit valmistivat itse määräämänsä lääkkeet, mutta lääkehoito ja niiden valmistus eriytyivät 1200-luvulle mennessä Euroopassa. Vastuukysymykset eriytyvät siten, että lääkärit eivät vastaa lääkkeiden valmistuksesta, eikä apteekkarit potilaan hoidosta.

Nykyajan lääkeyhdisteiden etsintäprosessin täytyy kehittyä dramaattisesti, jotta on mahdollista täyttää 2010-luvun potilaiden ja yhteiskunnan tarpeet. Koneoppiminen ja tekoäly yleensäkin tarjoavat lääketeollisuudelle todellisen tilaisuuden tehdä tuotekehitystä eri tavalla, jotta se voi toimia tehokkaammin ja merkittävästi parantaa menestystä alkuvaiheen lääkekehityksessä. Pitkäaikaiset hyödyt kattavat suuremmat kehitysresurssit, paremman ROI:n (Return on Investment) eli sijoitetun pääoman tuottoasteen sekä säästävät kustannuksia ja mahdollistavat vakavia sairauksia vastaan kehitettyjen uusien lääkkeiden huomattavasti paremmat toimitusmahdollisuudet. (Hunter, 2016)

Tavanomaisesti voi kestää peräti 15 vuotta, jotta lääkekehitysprosessi saadaan ideatasolta markkinoille toimitettavaksi tuotteeksi asti. Kehitysprosessi käsittää oikeanlaisen sairautta manipuloivan proteiinin löytämisen, konseptin testaamisen, potilaalle toimitettavan molekyylin optimoinnin, prekliinisen ja kliinisen turvallisuuden ja tehokkuuden testaamisen jne. Prosessi on kuitenkin liian paljon aikaa vievä. Oikeanlaisten vaikuttavien molekyylien etsintä saattaa kestää kahdesta viiteen vuotta, ennen kuin niitä voidaan testata eläimillä ja myöhemmin vapaaehtoisilla ihmisillä. Lisäksi vaikka lääkeyhdiste olisi päässyt tähän saakka, sen pääsyn todennäköisyys markkinoille on vähemmän kuin 1/10, vaikka etsintään olisi käytetty vuosia aikaa. Tämänkaltaisiin prosesseihin lääkeyritykset käyttävät peräti miljardi euroa per lääke. Summaan on laskettu myös epäonnistuneet lääkkeiden testaamiset, sillä myös ne täytyy rahoittaa.

3.1.1 Koneoppiminen ja tekoäly lääkkeiden sekä diagnosointialgoritmien kehityksessä

Lääkkeiden kehitysprosessi ja oikeiden yhdisteiden etsintä sekä tutkijat, jotka ovat kehitysprosessissa mukana, hyötyvät suuresti viimeisimmistä tekoälyn ja koneoppimisen teknologian innovaatioista. Biolääketieteen tutkijat joutuvat tekemisiin erittäin suuren informaatiomäärän kanssa päivittäin ja on arvioitu, että biolääketieteen teollisuus saa 10 000 uutta julkaisua päivittäin ympäri maailman erilaisista lähteistä, kuten biolääketieteelliset tietokannat ja tieteelliset lehdet sekä muut julkaisut. Informaation määrän ollessa niin valtavaa, tutkijoille on mahdoton tehtävä yhdistää, korreloida ja omaksua sitä. Informaation määrän laajuus voi vaikuttaa niin, että oikean yhdisteen löytäminen ja kehittäminen lääkeaineeksi ei ilman tekoälyä ja koneoppimisen algoritmeja mahdollistu. (Hunter, 2016)

BenevolentBio-yritys on tehnyt tutkimustyötä ALS-taudin (Amyotrophic Lateral Sclerosis tarkoittaa motoneuronisairautta, joka rappeuttaa sekä ylempää että alempia liikehermoja) ja se on kehittänyt tekoälyä, joka on yhdistetty yrityksen JACS-järjestelmään (Judgement Correlation System), joka käyttää NVIDIA DGX-1 tekoälyä hyödyntävää supertietokonetta. JACS kykenee käymään läpi miljardeja lauseita ja kappaleita miljoonista tieteellisistä tutkimuspapereista ja abstrakteista. Tämän jälkeen JACS linkittää datan väliset suhteet ja ohjaa dataa tunnettuihin faktoihin, jolloin joukko mahdollisia hypoteeseja voidaan muodostaa tutkijoiden kriteereihin perustuen. ALS-tautia varten niitä on ollut noin 200. Tutkijoista koostuva asiantuntijatiimi sitten arvioi hypoteesien validiteetin ja joukosta valikoituvat ensisijainen luettelo prioriteeteista, joita on mielekästä tutkia enemmän. Lopulta tutkijat rajaavat joukon viiteen hypoteesiin, jotka sitten testataan laboratoriossa. (Hunter, 2016)

IBM on kehittänyt koneoppimiseen perustuvan algoritmin, joka ennustaa sydämen vajaatoiminnan jo kaksi vuotta ennen kuin se tyypillisesti diagnosoidaan. Tutkijat opettivat algoritmia digitaalisten potilastietojärjestelmiin ja lääkäreiden muistiinpanoihin perustuen. Sydämen vajaatoiminnassa sydänlihaksen ei ole tarpeeksi vahva pumppaamaan tarpeeksi verta kehon tarpeisiin. Vajaatoiminta on vaikea ennustaa ja usein potilas päätyy yhtäkkiä sairaalaan, jolloin ongelmia on jo kertynyt ja peruuttamattomia vammoja on syntynyt. (Waltz, 2017)

Tutkimusryhmä tarkasteli digitaalisten potilastietojärjestelmien informaatiota muista vastaavista tilanteista, lääkityksiä sekä sairaalassaolojaksoja, jotka tarjosivat parhaan signaalin sydämen vajaatoiminnan ennustamiseksi. Kerätty digitaalisten potilastietojärjestelmien data tuli 10 000 potilaalta, jolloin luotu malli oli erittäin tarkka ennustamaan sydämen vajaatoiminnan vuotta aikaisemmin ja lopulta kahteen vuoteen saakka. (Waltz, 2017)

Stanfordin yliopiston tutkijat ovat kehittäneet syväoppimiseen perustuvan algoritmin, joka kykenee ennustamaan potentiaalisen lääkeaineen ominaisuuksia käyttämällä hyvin pientä määrää datapisteitä. Usein lääkeyritykset käyttävät valtavan määrän aikaa seulomalla molekyyliyhdisteitä yrittämällä löytää erilaisia kemiallisia rakenteita löytääkseen turvallisen, tehokkaimman yhdisteen, joka tulee valituksi ja kehitetyksi valmiiksi lääkkeeksi saakka. Prosessin aikana testataan myrkyllisyys, sivuvaikutukset ja epävakaus, jotka voivat aiheuttaa ongelmia kliinisissä testeissä tai valmiissa lääkkeissä. (Waltz, 2017)

Algoritmi, joka ennustaa näitä ominaisuuksia, voi lyhentää ja parantaa lääkeyhdisteen seulontaprosessia. Syväoppimista hyödyntävät neuroverkot ja koneoppimisen algoritmit ovat osoittautuneet hyväksi tällä alueella. Ongelmana tosin on, että kyseiset algoritmit täytyy ensin opettaa käyttämällä satoja miljoonia datapisteitä. Kuitenkin ajanjakson aikana, jolloin

lääkeyritys on käyttänyt yhdisteen etsimiseen, koneoppimisen algoritmeja käyttävät tiedemiehet saattavat jo tietää hyvän lääkeainekandidaatin. (Waltz, 2017)

3.1.2 Tutkimusrobotti 'Eve' hyödyntää tekoälyä lääketutkimuksessa

Aberystwythin ja Cambridgen yliopiston tutkijat kehittivät vuonna 2009 tutkimusrobotin (Adasm), joka kykeni itsenäisesti omaksuma uutta tieteellistä tietämystä. Myöhemmin sama tutkimustiimi kehitti Eve-tutkimusrobotin (Kuvio 15) Manchesterin yliopistossa, jonka tarkoituksena on nopeuttaa lääkeaineiden etsintäprosessia uusien lääkkeiden kehittämiseksi ja lisäksi säästää kuluja. Uusi robotti kykenee auttamaan uusien lääkeainekandidaattien löytämisestä esimerkiksi malarian tai muiden trooppisten tautien, kuten afrikkalaisen trypanosomiaksen (unisairaus) alueella. Trooppiset taudit infektoivat satoja miljoonia ihmisiä vuosittain ja tappavat miljoonia, joten kyse ei ole aivan pienestä ilmiöstä. (Oliver, 2015)



KUVIO 15. Eve-tutkimusrobotti. (Oliver, 2015)

Eve-tutkimusrobotti käyttää tekoälyä oppiakseen aiemmista onnistuneista löydöksistä ja valitsemalla yhdisteitä, joilla on korkea todennäköisyys olla aktiivinen tutkittua sairautta vastaan. Robotti käyttää hyväkseen älykästä seulontajärjestelmää, joka auttaa Eveä seulomaan yhdisteet, jotka ovat myrkyllisiä soluille ja valitsemaan ne, jotka estävät parasiittiproteiinien toiminnan ja jättävät oleelliset ihmiselle tärkeät proteiinit vahingoittumattomiksi. Menetelmä vähentää kustannuksia, epävarmuutta ja lääkkeiden seulontaan kuluva aikaa sekä parantaa miljoonien ihmisten elämää maailmanlaajuisesti. (Oliver, 2015)

Eve on suunniteltu automatisoimaan alkuvaiheen lääkekehitystä ja alkuun robotti systemaattisesti testaa jokaisen jäsenen suuresta yhdistejoukosta standardilla Brute-Force-tavalla, jossa kaikki vaihtoehdot käydään lävitse. Yhdisteet seulotaan analyyssejä (testit) vastaan ja ne voidaan generoida huomattavasti nopeammin sekä halvemmalla kuin mittatestit, jotka ovat aiemmin olleet standardina. Tämä mahdollistaa useammanlaiset

analyysit ja tehokkaammat seulontamenetelmät, jotka parantavat mahdollisuuksia löytää oikeanlainen lääke annetulla budjetilla. (Oliver, 2015)

Tyypillisesti Eve-tutkimusrobotti seuloo 10 000 yhdistettä päivässä. Huolimatta siitä, massaseulonta on silti suhteellisen hidas prosessi ja se tuhlaa paljon resursseja, sillä jokainen yhdiste testataan. Lisäksi siitä puuttuu älykkyyttä, koska Eve ei käytä tietoa, mitä se on oppinut seulontojen aikana. Parantaakseen prosessia Eve valitsee satunnaisen osajoukon yhdisteistä löytääkseen yhdisteet, jotka voivat läpäistä ensimmäisen määrityksen. Mahdolliset löydökset testaan uudelleen useamman kerran, jotta väärin positiivisten löydösten todennäköisyys vähenee. Eve käyttää tilastotiedettä ja koneoppimista ennustaakseen uusia rakenteita, jotka voivat onnistua paremmin suhteessa analyyseihin. Tällä hetkellä robotti ei kuitenkaan osaa vielä syntetisointeja yhdisteistä, tulevaisuudessa se tulee olemaan mahdollista. (Oliver, 2015)

3.1.3 Tekoäly auttaa tunnistamaan tehokkaasti yhdistelmä-lääkityksen syövän hoidossa

Tekoäly voi auttaa tutkijoita ennustamaan, mitkä yhdistelmät jo olemassa olevissa lääkeyhdistelmässä voivat tehotta erilaisiin syöpätyyppeihin säästämällä aikaa ja tuoden mahdollisuuksia kehittää uusia hoitomuotoja potilaille yhä nopeampaan tahtiin. Tehokkaiden uusien lääkeyhdistelmien löytäminen on tällä hetkellä vaikeaa useasta eri syystä johtuen. Esimerkiksi 100 lääkettä voidaan käyttää luomaan 5000 kahden lääkkeen kombinaatiota. Mikäli halutaan testata kolmen tai neljän lääkeyhdistelmän vaikutuksia, potentiaaliset ryhmittymät kasvavat nopeasti ja niiden kokeellinen testaus tulee yhä vaikeammaksi. (Elemento, 2017)

Tutkimuksien mukaan tekoäly kykenee ehdottamaan tehokkaita syöpään tehoavia lääkekombinaatioita. Olemassa on useita lääkkeitä, joita voidaan käyttää erilaisia syöpätyyppejä vastaan ja yksi haasteista on löytää keinoja yhdistää ne. Yhdistelmä-lääkkeet voivat tuottaa tehokkaampia hoitoja potilaille. Uudet lääkeyhdisteet voivat myös auttaa voittamaan lääkeresistenttiongelman, kun lääkitys lakkaa toimimasta tavalla, jolla ne aiemmin toimivat tietyille potilaalle. (Elemento, 2017)

Tutkijat ovat käyttäneet tekoälytekniikoita rakentaakseen malleja, jotka ennustavat synergistisiä lääkekombinaatioita. Tutkijat opettivat tekoälyä hyödyntävää mallia tunnistamaan jo testatut yhdisteet ja sovelsi mallia arvioimaan suurempia yhdistelmäjoukkoja, jotta oli mahdollista nähdä, mitkä yhdisteet saattaisivat olla tehokkaita. Tutkijat käyttivät algoritmipohjaista lähestymistapaa ennustamaan, mitkä lääkkeet saattaisivat toimia hyvin yhdessä melanooman hoidossa, jolla on yhteys BRAF-mutaatioon, joka esiintyy 60 % potilaista tämänkaltaisessa ihosyöpätyypissä. (Elemento, 2017)

Mutaatio luo poikkeuksellisen proteiinin, joka auttaa melanoomasoluja kasvamaan hallitsemattomasti. Samanaikaisesti kun lääkitys voi auttaa estämään kyseisen proteiinin

toiminnan, resistenssi säännöllisesti kasvaa johtuen muista mutaatioista. Lääkkeiden yhdistäminen on tehokas lähestymistapa, joka ei vain tee hoidosta tehokkaampaa, vaan myös vähentää resistenssin todennäköisyyttä. Tutkijat käyttivät tekoälyteknologiaa, jota kutsutaan nimellä: "Random Forest", joka on oppiva algoritmi koostuen monimutkaisista säännöistä, joiden avulla kaksi lääkettä voi toimia tehokkaasti yhdessä. (Elemento, 2017)

Toteutettujen tutkimusten mukaan laboratorio-olosuhteissa testatut lääkeyhdisteet osoittivat olevansa synergistisiä ja osoittavat kohti uudenlaista melanooman hoidon strategiaa. Eräs kombinaatio kyseisen sairauden alueella on kemoterapialääkitys ja kohdennettu lääkitys, jota kutsutaan nimellä PLX4720. Näiden yhdistelmä oli toimiva ratkaisu kyseiseen ongelmaan. Tutkijat koettavat löytää keinon, jolla lääkeyhdistelmiä voidaan menestyksekkäästi tunnistaa tekoälyn avulla, jotta voidaan välttää tuhansien lääkeyhdistelmien brute force-tyyppinen testaaminen laboratoriossa. Tekoälyä voidaan opettaa tunnistamaan pieneen lääkeyhdistelmien määrään perustuen, mikä tekee kahdesta lääkkeestä synergistisiä, jolloin on mahdollista löytää uusia lääkeainekombinaatioita, joilla on potentiaalia melanooman hoidossa. (Elemento, 2017)

Tutkijat käyttivät tekoälyä hyväkseen luodessaan yksityiskohtaisen mallin, joka sisälsi sarjoja biologisista ja molekulaarisista tapahtumista, jotka vaikuttavat B-solulymfooman kehitykseen. Käyttäen mallia tutkijat kykenivät löytämään kuinka erilaiset geenit vaikuttavat yhdessä syövän kehittymiseksi. Tietokonesimulaatiolla tutkijat tunnistivat erilaisia lääkekombinaatioita, jotka tähtäsivät näihin kyseisiin geneihin luomalla synergistisen vaikutuksen B tyyppin lymfooman ehkäisemiseksi. Perustuen näihin tietoihin, tutkijat päättelivät, mitkä lääkeyhdisteet olisivat todennäköisesti tehokkaita ja testasivat sitten niitä laboratoriossa varmistaen, että oletukset olivat oikeat. (Elemento, 2017)

Tutkijat kykenivät myös löytämään lääkkeitä, jotka suoriutuivat huonommin, jos niitä käytettiin yhdessä, kuin erikseen. Tämä antoi tutkijoille mahdollisuuden käyttää aikansa merkittävämpään tutkimukseen, eikä tehottomien hoitojen tutkimiseen. Hyvien testauksiin soveltuvien lääkeainekandidaattien löytäminen on oleellista, sillä ei ole mahdollista kokeellisesti testata kaikkia niitä. Tekoäly voi auttaa poimimaan pienen määrän yhdisteitä, jotka hyvin todennäköisesti ovat tehokkaita, jolloin sekä aikaa että varoja säästyy muuhun käyttöön ja resurssit ovat paremmin kohdennettavissa. (Elemento, 2017)

3.1.4 Syväoppiminen lääkkeiden farmakologisten ominaisuuksien ennustamisessa


Syväoppiminen kehittyi nopeasti useilla tieteen ja teknologian alueilla. Onnistuneita tuloksia on saavutettu kuvan, tekstin, äänen ja videon tunnistuksessa, robotiikassa ja ilman ihmistä tapahtuvassa itsenäisessä ajamisessa jne. Lääkkeiden etsiminen ja kehittäminen ovat monimutkainen prosessi ja se vaatii paljon aikaa ja resursseja. Useita erilaisia laskennallisia lähestymistapoja on säännöllisesti kehitetty tilanteen parantamiseksi. Aiemmin menetelmät

saattoivat riippua aktiivisten aineosien tunnistamisesta perinteisillä tavoilla tai onnekaasta sattumasta. (Aliper ym., 2016)

Modernit menetelmät koostuvat tiedon louhinnasta, rakennemallinnuksesta (homologiamallinnus), perinteisestä koneoppimisesta (Machine Learning eli ML) ja sen osateknologiasta, syväoppimisesta (Deep Learning eli DL). Syväoppimisen menetelmät mallintavat korkeatasoisia kuvauksia datasta käyttämällä syviä neuroverkkoja (Deep Neural Networks, DNN). DNN-verkot ovat joustavia monikerrosjärjestelmiä, jotka koostuvat toisiinsa yhteydessä olevista ja interaktiivisista keinotekoisista neuroneista, jotka suorittavat erilaisia datan muunnoksia. Niillä on useita piilossa olevia neuronikerroksia, jotka mahdollistavat datan abstraktiotasojen järjestelemisen. DL-verkot ovat keskeisiä fysiikassa, signaalinkäsittelyssä sekä kuvien, videoiden, tekstien louhinnassa ja tunnistuksessa parantaen suorituskykyä yli 30 % aiempiin menetelmiin verrattaessa. (Aliper ym., 2016)

Perinteisillä koneoppimisen lähestymistavoilla on merkittävä tarkkuus luokittelun suhteen, mutta se tapahtuu manuaalisen valittujen ja säädettyjen ominaisuuksien hinnalla. Neuroverkkojen tehokkuus ilmenee siten, että ne kykenevät oppimaan automaattisesti käyttäen valtavia data-aineistoja. Neuroverkot eivät vain yksinkertaista manuaalista ja muuten työlästä oppimisprosessia, vaan ne myös mahdollistavat tehtäväkohtaisesti optimaalisen ominaisuuksien oppimisen. Neuroverkot sopivat hyvin laskennallisen biologian tarpeisiin, sillä ne kykenevät toimimaan niukan ja monimutkaisen informaation kanssa, joka tulee kyseeseen suuriulotteisen geenidatan kanssa toimiessa. (Aliper ym., 2016)

Tutkimusryhmä muodosti mallin (Kuvio 16), jossa oli aiemmasta LINCS-projektissa kerättyä geenidataa, terapeutteja MeSH-käyttökategorioita (Medical Subject Headings) ja lisäksi DNN-neuroverkko, jota opetettiin tarkoituksen mukaisesti. LINCS-tietokannasta analysoitiin 26 420 lääkenäytettä ja ne jaettiin 12 eri terapeutteeseen käyttökategoriaan tietyn lääkkeen lääketieteellisen MeSH-luokittelun perusteella. Kaikki valitut lääkenäytteet kerättiin kolmeen solulinjaan, jotka ryhmiteltiin seuraavien parametrien kombinaatioista: solulinja, lääke, häiriökoostumus (perturbation) ja häiriöaika. Menettelemällä tällä tavoin, saatiin yhteensä edellä mainitut 26 420 näytettä. Tutkimuksessa valittiin lääkkeet siten, että niillä oli yhteys sairauteen terapeutin käytön alueella luokittelupuussa. Useampaan kategoriaan kuuluvat lääkkeet poistettiin tutkimuksesta ja vain sellaiset valittiin, jotka kuuluivat vain yhteen kategoriaan. (Aliper ym., 2016)



KUVIO 16. Tutkimusmalli: MeSH- ja LINCS-tietokannat sekä DNN-neuroverkko.(Aliper ym. 2016)

Tutkimusryhmä opetti DNN-neuroverkkoalgoritmia käyttäen geenitason transkriptomista dataa sekä transkriptomista dataa, jota prosessoitiin käyttäen Pathway Scoring-algoritmia. Pathway ja geenitason luokittelussa, DNN-algoritmi saavutti korkean luokittelutarkkuuden ja päihitti SVM (Support Vector Machine)-mallin jokaisessa luokitteluongelmassa. SVM:t joustavia ja helppokäyttöisiä, mutta syväoppimisen teknologioihin perustuvat lähestymistavat rikkovat ennätyksiä monilla eri alueilla, kuten mallin tunnistamisessa (pattern recognition). (Aliper ym., 2016)

Tutkimuksessa käytetty DNN-verkon metodi oli standardi yhdistynyt MLP (Multilayer Perceptron), jossa oli 977 sisääntulosolmua geenidataa varten ja 271 polun aktivointipistettä (pathway activation scores). Tutkimusryhmä etsi optimaalista kerrosten ja piilotettujen yksiköiden määrää. Tutkimustuloksena havaittiin, että paras parametrien määrä oli kolme piilotettua kerrosta ja jokaisessa 200 lineaarista aktivointitoimintoa (linear activation function). Tutkimuksessa selvisi, että DNN-verkot kykenivät saavuttamaan 54.6 % tarkkuuden ennustaessaan yhtä kahdestatoista terapeuttisesta luokasta jokaiselle kyseessä olevalle lääkkeelle. (Aliper ym., 2016)

3.2 Tekoäly ja insomnia

Insomnia eli unettomuus voidaan määritellä muun muassa. depression, alkoholin ja lääkkeiden väärinkäyttöön, psyykkiseen stressiin ja moneen ruumiilliseen (erityisesti kipua aiheuttavaan) sairauteen liittyvänä yleisoireena, joka voi esiintyä nukahtamisvaikeutena, katkonaisena nukkumisena tai liian varhaisena heräämisena (Duodecim). Nukahtamisvaikeudet ja katkonainen yöuni ovat stressaavassa elämäntilanteessa yleisiä ja tilapäisesti kuuluvat elämään, mutta pidempiaikaisena se voi aiheuttaa vakavia ongelmia. Nykyisen näkemyksen mukaan se katsotaan itsenäiseksi tai muiden sairauksien kanssa yhtäaikaiseksi tilaksi, joka ei usein helpotu ilman spesifistä hoitoa.

Unettomuuden etiologia ja ilmiasu sekä oireiden esiintymisen tiheys, vakavuus ja kesto voivat vaihdella. Unettomuus voi ilmetä nukahtamisen vaikeutena, vaikeutena pysyä unessa, unen

virikistävyyden heikentymisenä tai erilaisina yhdistelminä. Suomen tautiluokituksen mukaan ei-elimellinen unettomuus ilmenee ainakin kolme kertaa viikossa ja vähintään kuukauden ajan. Unettomuus alkaa oireena ja voi kehittyä ajan myötä häiriötasoiseksi unettomuudeksi, jonka huolellisesti suoritettu diagnoosi ja hoito ovat oleellisia. (Järnefelt, 2017)

Insomnian hoitomuotona voidaan lääkehoidon lisäksi käyttää myös psykologisia hoitoja ja niiden hyödyt ovat parhailtaan jopa niin hyviä, että pitkäaikaisten unilääkkeiden käyttöä ollaan voitu vähentää tai jopa lopettaa. Tutkimuksien mukaan uniärsykkeiden hallintamenetelmä, rentoutus, paradoksaalinen interventio, vuoteessa olemisen ajan rajoittamismenetelmä ja kognitiivinen käyttäytymisterapia voivat täyttää empiirisesti tehokkaiksi todettujen hoitojen kriteerit. Psykologisten hoitomenetelmien tulokset ovat tutkimuksien mukaan vaikuttaneet pysyvän ainakin 12 kuukauden ajan. Eräs tekoälyä unettomuuden hoidossa hyväksikäyttävä sovellus on tässä raportissa esitelty SleepAsap. (Järnefelt, 2017)

Uni on tunnetusti tärkeää biologiselle toipumiselle ja siihen kuluu aikaa kolmasosa elinajasta, mutta modernissa yhteisössä yhä useammat kärsivät unettomuudesta. Esimerkiksi Saksassa unettomuuden oireista kärsiviä on peräti kolmasosa populaatiosta. Tutkimuksien mukaan unettomuuden oireiden ja kuolemaan johtavan sydänsairauden, kuten sydäinfarkti, sepelvaltimotauti, halvaus tai niiden yhdistelmällä on yhteys. Unettomuus voi myös muuttaa metabolisia ja endokrinologisia toimintoja, kasvattaa sympaattista aktivointia, nostaa verenpainetta jne., jotka kaikki ovat sydänsairauksien ja halvauksen riskitekijöitä. (He ym., 2017)

Tässä luvussa käsitellään tekoälyä käyttäviä ratkaisuja unihäiriöiden diagnosointiin ja monitorointiin, jolloin voi olla mahdollista löytää uniongelmiin ratkaisu, joita ei mahdollisesti olla kyetty lääkityksellä tai terapian keinoin parantamaan. Tekoäly voi auttaa unihäiriöiden diagnosoinnin lisäksi paljastamaan unihäiriöiden taustalla olevia syitä, jotka voivat olla jääneet huomaamatta käyttämällä muita menetelmiä. Tällöin terveydenhuollon henkilöstölle on huomattavasti helpompaa puuttua yhä laajenevaan ongelmaan, joka voi aiheuttaa niin työkyvyttömyyttä kuin jopa vakavia ongelmia terveyteen.

3.2.1 Morpheo-tekoälyalusta unihäiriöiden diagnosoinnissa

Neuroteknologian startup-yritys (Rythm) on esitellyt Morpheo-alustan, joka auttaa diagnosoimaan unihäiriöitä. Rythm tähtää terveyden ja elämänlaadun parantamiseen muuttamalla tavan, jolla ihmiset ymmärtävät aivoja. Yrityksen tiimi koostuu maailmanlaajuisista unilääketieteeseen, neurotieteeseen, insinööritieteisiin, suunnitteluun, koneoppimiseen ja kehittyneeseen tietojenkäsittelyyn erikoistuneista asiantuntijoista. Ennen Morpheo-alustan julkaisemista Rythm julkaisi vuonna 2016 päälle puettavan unidiagnostiikkaan liittyvän laitteen (Dreem), joka parantaa unen laatua. Rythm tekee

yhteistyötä tutkimusinstituuttien ja sairaaloiden kanssa, jotta neurotieteen mahdollisuuksia voitaisiin paremmin hyödyntää. (PR Newswire, 2017)

Morpheo-alustan on sanottu olevan ensimmäinen tekoälyä hyödyntävä alusta, jota voidaan hyödyntää unihäiriöiden diagnostiikassa. Alusta perustuu avoimeen lähdekoodiin ja on tietoturvallinen ratkaisu. Morpheo hyödyntää koneoppimisen malleja, jotta automaattinen ja ennustava unihäiriöiden diagnosointi mahdollistuu. Morpheo kehitettiin alun perin tutkimustyökaluksi, joka avaa tietä ennaltaehkäisevälle ja ennustavalle lääketieteelle antaen lääkäreille mahdollisuuden toteuttaa patologisten sairauksien hoitoa paremmin ja jopa tunnistaa ne ennen kuin ne puhkeavat. (Bell, 2017)

Alusta auttaa visualisoimaan lääkäreitä varten monimutkaista unesta mitattua dataa ja mahdollistaa koneoppimisen mallien kehityksen pohjautuen suuriin lääketieteellisiin aineistoihin. Morpheo integroi useita informaatiolähteitä, kuten perinteinen lääketieteellinen polysomnografia ja unen diagnosoimiseen tarkoitettuja päälle puettavat laitteet (kuten Dreem pääpanta), jotka yhdessä mahdollistavat unihäiriöitä luonnehtivien mallien sekä muiden unidataan pohjautuvien tilanteiden tunnistamisen. Lääkärit voivat hyödyntää ilmaista online-työkalua, jonka avulla on mahdollista automaattisesti analysoida unimalleja ja auttaa parantamaan sekä nopeuttamaan uneen liittyvää diagnoosia. Morpheo-alustaan on myös sisällytetty avoimeen lähdekoodiin perustuva lohkoketjuinfrastruktuuri, joka takaa datan yksityisyyden. Morpheon kehittäjän mukaan alusta voidaan yleistää osaksi muita terveydenhuollon ratkaisuja pidemmällä tähtäimellä. (Bell, 2017) Kuviosta 17 havainnollistuu Morpheon alustava monitorointi-ikkunan käyttöliittymä.



KUVIO 17. Morpheo-alustan monitorointi-ikkuna.(Bell, 2017)

3.2.2 SleepASAP-sovellus etsii personoituja ratkaisuja unihäiriöihin

Unen puute aiheuttaa negatiivisia vaikutuksia fyysiselle ja henkiselle terveydelle aiheuttaen pahimmillaan jopa kuolemaan johtavia liikenneonnettomuuksia. Unen puute vähentää lisäksi työtehoa ja tutkimusten mukaan lihottaa. Hyvän ja riittävän unen saaminen voi joskus olla vaikeaa ja se aiheuttaa ongelmia maailmaanlaajuisesti. Uniongelmiä korjaamaan kehitti Israelilainen startup-yritys SleepASAP-sovelluksen, joka on maailman ensimmäinen joukkovoimaan perustuva Big Data-ratkaisu, jonka avulla uniongelmiin voidaan puuttua. (Shamah, 2015)

Maailmassa on mahdollisesti satoja (tai enemmän) erilaisia sovelluksia uniongelmiin korjaamiseksi, mutta useimmat diagnostiikkatyökalut vaativat käyttäjän käyttämään sensoreita, hengityspotkia tai muita laitteita. SleepASAP poikkeaa tästä perustuen täysin tietoisuuteen (valveillaolo) sekä vuorovaikutukseen käyttäjän ja sovelluksen välillä. Sensoreiden käyttö unen aikana ei välttämättä ole tarkoin tai mukavaltakaan tuntuva vaihtoehto, sillä niiden käyttäjä saattaa liikkua tai irrottaa ne unen aikana. (Shamah, 2015)

Sensoreiden ja muun fyysisen päälle puettavan teknologian sijaan SleepASAP käyttäjät vastaavat joukkoihin erilaisia kysymyksiä käyttäen mobiilisovellusta. Vastaukset analysoidaan käyttäen luonnollisen kielen prosessointia ja niitä verrataan muilta käyttäjiltä saatuihin tuloksiin. Isolta käyttäjäjoukolta kerätty data on yksilön unihäiriöitä diagnosoidessa tarkempaa ja se on verrattavissa parhaisiin unihäiriöitä hoitaviin ratkaisuihin, kuten lääkitys, henkiset harjoitteet jne. (Shamah, 2015)

Sovellusta testattiin 2500 koehenkilöllä ja tutkijat havaitsivat, miten SleepASAP diagnosointimetodi kaivautui syvälle luonteenpiirteisiin, kuten uteliaisuus, kekseliäisyys, vastuuntuntoisuus, organisointikyky, itsevarmuus, ekstro- ja introverttiys, yhteistyökyky, turvattomuus jne. Menettelemällä näin, sovellus kykeni määrittämään, mikä tyyppinen unihäiriö henkilöllä oli ja unihäiriön tasot noin 99 % tarkkuudella. Sovellus onnistui myös tunnistamaan jo aiemmat lääkärin diagnosoimat tapaukset sekä informaatiota, jota potilas ei ollut aiemmin antanut järjestelmälle tutkimuksen aikana. (Shamah, 2015)

Sovelluksen käyttäjä vastaa kysymyksiin persoonallisuudestaan ja tavoistaan unen suhteen sekä uniongelmissa. Kysymykset on kehitetty käyttäen hyväksi tekoälyteknologiaa ja psykolingvistiikkaa, joiden avulla voidaan paremmin ymmärtää käyttäjän persoonallisuutta ja keskeisiä kysymyksiä, jotka aiheuttavat uniongelmiä. Perustuen edellä mainittuun prosessiin, sovellus suosittelee parasta tapaa auttaa käyttäjiä nukkumaan paremmin. (Shamah, 2015)

Sovellus tuottaa käyttäjästä uniDNA:n, joka on tietynlainen malli tilanteesta auttaen sovelluksen käyttäjää nukkumaan paremmin ja selvittämään mikä häiritsee heidän mahdollisuuksiaan nukkua hyvin. Tuloksia verrataan sitten muihin samankaltaisiin tapauksiin.

Ymmärrettäessä käyttäjän uniDNA:n toiminnan, voidaan heidän tilanteensa niin sanotusti ”joukkoistaa” eli verrata dataa muihin vastaaviin tapauksiin isommassa populaatiossa, jolloin voidaan määrittää, mikä voisi parhaiten auttaa tilanteeseen. (Shamah, 2015)

SleepApp-sovelluksen ominaisuuksia ovat:

1. Unihäiriöiden tunnistaminen perustuen psykolingvistiseen analyysiin.
2. SleepHealth psykologinen kartta.
3. Objekttiivinen käyttäytymisen arviointi.
4. Palaute käyttäytymisen muutoksista
5. Ei-parametrinen vuorokausirytmien analysointi.
6. Unen seuranta.
7. Äänen seuranta.
8. Yksityiskohtainen uniDNA perustuen tutkimuksiin.
9. Elämäntyylin päivittäinen-viikoittainen raportointi.
10. Personoitu hoidon suunnittelu.
11. Kustannustehokas esiseulonta:
 - Unettomuus
 - Unihäiriöt
 - Unihäiriöt koskien mielenterveyden häiriöitä
 - Unihäiriöt koskien neurologisia häiriöitä
 - Unesta johtuvat päänsäryt
 - Dyssomnia
 - Parasomnia

Tutkimustyöhön perustuen SleepAsap-sovelluksen luonut startup-yritys kehitti syväoppivan (Deep Learning) algoritmin, joka simuloi tapaa, jolla ihmiset opiskelevat heille kiinnostavaa aihealuetta ja tulevat asiantuntijoiksi sillä alueella. Sovelluksen kehitystyössä yritys yhdisti formaalin tieteellisen tietämyksen kokeelliseen empiiriseen tietämykseen, joka uniongelmistä kärsivillä ihmisillä oli. Eräs tärkeimmistä ominaisuuksista SleepAsap-sovelluksessa on se, että sovellus oppii jatkuvasti, jolloin käyttäjän palatessa käyttämään sovellusta, sovellus saattaa jo kattaa käyttäjän tarpeet aiempaa paremmin. (Idel, 2017)

3.2.3 Syväoppiminen ja hetkellinen syke uniapnean vakavuuden tunnistamisessa

Uniapnea on lääketieteellisesti merkittävä sairaus, joka vaikuttaa 24 % miehiin ja 9 % naisiin Yhdysvaltojen populaatiossa. Uniapnealla on todettu olevan suora korrelaatio muihin sydän- ja autonomisiin häiriöihin. Hoitamaton pitkäaikainen uniapnea aiheuttaa sydämen eteisvärinää, joka voi myöhemmin johtaa vakaviin seurauksiin, kuten sydänvika ja halvaus. Nykyään eniten käytetty kliininen tutkimusmetodi uniapnean tunnistamisessa on polysomnografia, joka on sekä aikaa vievä, että epämieluisa potilaille. Polysomnografia vaatii

potilaiden vierailua sairaalassa ja se myös vaatii manuaalista koulutetun lääketieteen ammattilaisen osallistumista kerättyjen mittaustuloksien luokitteluun. (Pathinarupothi ym., 2017)

Päälle puettavat sensorit, kuten happisaturaatiosensori (SpO₂), hengitystiheyden monitorointilaitteet, EEG-monitorit (Electroencephalogram eli aivosähkökäyrä), EKG ja ranteeseen puettavat mittalaitteet ovat olleet esillä aiemmissä tutkimuksissa. Nämä teknologiat vaativat kattavan kliinisen potilasarvion tekemisen, antaen mahdollisuuden lääketieteen ammattilaiselle diagnoosin tekemisen korkealla tarkkuudella. Viime aikoina laskennallisista teknologioista on tullut kuitenkin yhä tärkeämpiä uniapnean diagnosoimisessa. Laskennalliset teknologiat sisältävät luokittelun ja anomalioiden tunnistusalgoritmien, kuten SVM jne. käyttämisen. Monet potilaat ovat silti valinneet useiden sensorien menetelmän ja vierailleet klinikalla useissa eri testeissä mittaustuloksien saamiseksi. (Pathinarupothi ym., 2017)

Nykypäivään mennessä tarkimmat usean testin kombinaation suorittamisen jälkeen on ollut mahdollista ylittää 85 % tarkkuuteen viiden minuutin aikana. Nämä menetelmät eivät tosin ole ottaneet huomioon, että sydämen rytmi voi muuttua ja se voi johtua muista sydänvaivoista, eikä välttämättä uniapneasta. Syväoppimisen teknologioiden tultua, tutkijat ovat alkaneet löytää niille sovellusalueita useiden liittyvien sairauksien ja niitä seuraavien seurauksien tunnistamisessa. Tutkijat ovat kyenneet näyttämään, että syväoppiminen tarjoaa paljon vankemman tavan ennustaa unen laatua fyysiseen aktiiviteettiin perustuen. Tähän mennessä ei ole ollut vielä olemassa yhtä menetelmää, joka olisi kyennyt tunnistamaan uniapnean vaarallisuuden tason käyttämällä hetkellistä vain hetkellistä sykettä. Lisäksi ei ole tiedossa, että rytmihäiriöt ja uniapnea voitaisiin erottaa toisistaan luotettavasti riittävän korkealla tarkkuudella. (Pathinarupothi ym., 2017)

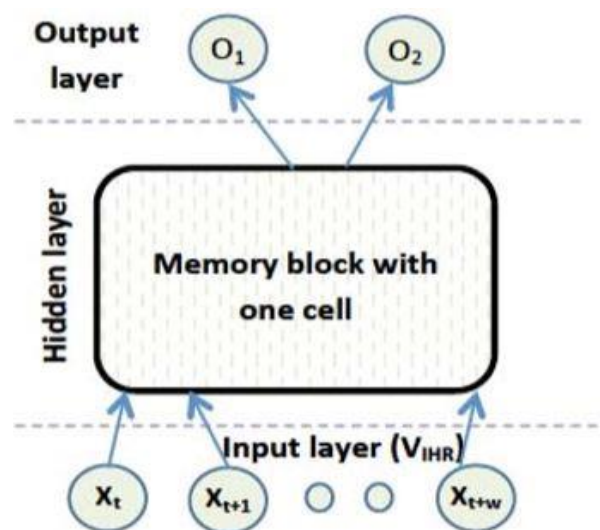
Uniapnean automatisoitu tunnistus ja vakavuuden tunnistaminen on aiempien vuosikymmenien aikana suurelta osin painottunut monimuuttujasensorien datan keräämiseen. Kliinisesti uniapnea tunnistetaan käyttämällä useiden eri testien yhdistelmää, kuten veren hapetusarvo, hengitystiheys jne. Viime aikoina tutkijat ovat alkaneet tutkia hetkellisen sykkeen (Instantaneous Heart Rate eli IHR) käyttöä uniapnean sekä sen vakavuuden tunnistamisessa. Tähän saakka parhaat teknologiat ovat yltäneet vain 85 % tarkkuuteen uniapneadatan luokittelussa. Tutkimusryhmä on kuitenkin tutkinut LSTM-RNN syväoppimisen algoritmiin pohjautuvan teknologian käyttöä tunnistamisprosessissa, jonka alustavat tulokset vaikuttavat lupaavilta, vaikka laajempia sairaalaympäristössä toteutettavia uniapneatestejä on tarpeen vielä suorittaa tuloksien varmistamiseksi. (Pathinarupothi ym., 2017)

Tutkimusryhmä päätyi käyttämään LSTM-RNN syväoppimisen algoritmia, joka kykenee mallintamaan aikasarjoja hyvin suurella tarkkuudella muodostamalla korkeampiulotteisia

malleja kyseisistä data-aineistoista. Tutkimusryhmä käytti IHR-mittauksia opettaessaan LSTM-RNN-algoritmia. Opetettua mallia voitiin sitten käyttää uniapneadiagnoosin saaneiden potilaiden IHR-datan testaamiseen sekä useiden kontrolliryhmien kanssa. Tutkimusryhmä toteutti mallin ja esitteli tulokset uniapnean vakavuuden tunnistamisprosessissa yli 8000 minuutin mittaisella datalla, joka sisälsi sekä uniapneapotilaat että kontrolliryhmiä. Tulokset testeistä olivat hyvin lupaavia ja diagnosointitarkkuus oli korkea. (Pathinarupothi ym., 2017)

Syväoppimisen teknologiat ovat saaneet viime aikoina yhä enemmän huomiota merkittävän suorituskyvyn ansiosta tekoälyä hyödyntävissä tehtävissä, kuten kuvantunnistus, luonnollisen kielen prosessointi, puheen prosessointi ja monet muut tehtävät. Tutkimusryhmän hyödyntämä LSTM-RNN-malli ratkaisee katoavan ja ”räjähtävän” gradientin ongelman esittelemällä muistilohkoja yksittäisten yksiköiden sijaan piilotetussa kerroksessa. Syötteenä voidaan antaa esimerkiksi sekvenssi $x = (x_1, x_2, \dots, x_t)$, jolloin LSTM-arkkitehtuuri laskee ulostulosekvenssin $O = (O_1, O_2, \dots, O_t)$ laskemalla portit (sisään, ulos ja unohda) ja muistisolujen aktivoinnit iteratiivisella tavalla $t = 1$:stä T asti piilotetun kerroksen alueella. (Pathinarupothi ym., 2017)

LSTM-arkkitehtuurissa on kolme kerrosta, joista sisääntulo (input)-kerros koostuu 61 neuronista (60 ominaisuutta ja 1 luokkanimi), salatusta kerroksesta, jossa on kaksi muistilohkoa ja ulostulokerroksesta (output), jossa on kaksi neuronia edustaen kahta luokkaa. Jokaisella muistilohkolla on muistisolu, johon tallentaa informaatiota sekvenssejä pitkin ja porttien avulla. Portit kontrolloivat muistisolujen käyttäytymistä kollektiivisella tavalla päivittämällä muistisolun tilaa. Kuvioista 18 havainnollistuu LSTM-arkkitehtuuri. (Pathinarupothi ym., 2017)




KUVIO 18. LSTM-arkkitehtuuri.(Pathinarupothi ym. 2017)

Useimmiten ja erityisesti kliinisissä tarkoituksissa sydämen lyöntinopeus lasketaan lyöntiä/ minuutti-tavalla, joka on useimmiten lyöntiä/kuusi sekuntia ekstrapoloituna yhtä minuuttia kohti. Uniapneatutkimuksissa sykevälivaihtelu (Heart Rate Variability eli HRV) on yksi ominaisuuksista, joita useimmiten analysoidaan. HRV voidaan myös käyttää IHR-muodossa. IHR voi myöskin olla peräisin EKG tai PPG (Photo-Plethysmogram) mittauksista. (Pathinarupothi ym., 2017)

LSTM-RNN-algoritmin oppimiseen, validoimiseen ja testaamiseen tutkimusryhmä käytti Physionet-työkalua ja CinC (Computing in Cardiology) ja uniapnea-tietokantaa. CinC-tietokannan data sisälsi kahdeksan tuntia EKG-dataa 35 potilaalta, joille on kirjattu uniapneamerkintä jokaisella minuutilla dataa kohden. Data koostui kolmesta ryhmästä, josta A-ryhmässä on 20 potilastietuetta, joilla on vakava uniapnea, B-ryhmässä on viisi potilastietuetta, joilla uniapnean diagnoosi menee rajalle ja ryhmällä C on vain 5 % uniapneaan viittaavia signaaleita. Tutkimusryhmä valitsi 10 tietuetta luokasta A ja 8 luokasta C opettamista ja validointia varten. Ryhmä käytti yhteensä 8640-minuuttia uniapneadataa luokista A ja C. Testit tehtiin kolmella erilaisella aineistolla ja lopputuloksena LSTM-malli kykeni luokittelemaan ja tunnistamaan koko uniapnean ja tapaukset, joissa ei ollut uniapneaa erinomaisella tarkkuudella. Tutkimustulokset myös osoittavat, että mahdollisuus laaja-alaiseen uniapnean tunnistamiseen käyttäen IHR-sykettä on toteutettavissa. (Pathinarupothi ym., 2017)

3.2.5 Tekoäly ja Somnox-älytyyny unihäiriöiden hoitamisessa

Tutkimuksien mukaan hengitys on yksi tärkeimmistä tekijöistä hyvään unen laatuun. Ajatuksena on, että jos henkilö kykenee sääntelemään hengitystään, hän voi nukahtaa helpommin ja herätä energisempänä. Hidas hengitysrhythmi voi auttaa henkilöä nukahtamaan minuuteissa, jolloin sydämen lyöntinopeus hidastuu ja henkilö rentoutuu lyhyessä ajassa. Ryhmä opiskelijoita Delft University of Technology:sta ovat kehittämässä ongelmaan tekoälyyn pohjautuvaa joukkorahoitusta hyödyntävää Somnox-älytyyny-ratkaisua (Kuvio 19) useiden unitutkijoiden kanssa. He tutkivat yhdessä Somnoxin kehittäjien kanssa unen ja hengityksen välistä suhdetta ja he havaitsivat, että manteliumake aivoissa on tärkeää tunteiden tunnistamisessa. Hengityksellä on suuri vaikutus manteliumakkeeseen ja siten se vaikuttaa mielen rauhallisuuteen. (Somnox, 2017)



KUVIO 19. Somnox-älytyyny ja aivojen mantelitumake. (Somnox. 2017)

Somnox on ensimmäinen ei-lääketieteellinen robotiikan ja tekoälyn yhdistävä ratkaisu uniongelmien ratkaisemiseksi. Somnox-robottityynyssä on useita erittäin herkkiä sensoreita, jotka keräävät paljon dataa, jota voidaan käyttää tarkastamaan, onko tyynyn käyttäjä hereillä vai syvässä unessa. Tekoälyalgoritmeja hyödyntämällä Somnox kykenee ”hengittämään” matkimalla käyttäjänsä hengityksen rytmiä ja sillä tavoin rauhoittaa käyttäjä, jotta hän voi helpommin nukahtaa. Tyyny on kuin korkean teknologian relaksantti (rentouttaja), jolla on hieman unilääkkeen kaltaisia ominaisuuksia. (Geniuspharm, 2017)

Tyynyssä on sisäänrakennettuna sensoreita, joilla se kykenee seuraamaan käyttäjänsä hengitystä ja tunnistaa, jos hän on jo unessa, vielä valveilla tai jossain niiden välillä. Tuloksista riippuen tyyny käynnistää rauhoittavien toimintojen prosessin, joka normalisoi käyttäjän hengitysrytmiä ja auttaa heitä nukahtamaan paremmin. Tyynyssä on sisäänrakennetut Bluetooth-kuulokkeet, joiden avulla se kykenee soittamaan musiikkia tai käyttäjän suosimaa äänikirjaa. Somnox kykenee myös luomaan keinotekoisen auringon nousun herätyksen lähestyessä ensin hieman hehkumalla ja sitten lisäämällä valoa vähitellen. Tyynystä on apua erityisesti niille, jotka nukkuvat täysin pimennetyssä huoneessa, joissa ikkunasta tuleva valo on estetty. (Tucker, 2017)

3.3 Tekoäly ja kardiologia

Kardiologia on tieteenala, johon kuuluu sydämen toiminta ja sydänsairaudet. Sydän vastaa verisuonten muodostamasta suljetun systeemin verenkierrosta ja sen pumppausvoima pitää verenpainetta yllä (Pharma Scandinavia). Kardiologian termi tulee Kreikan sanasta ”cardia”, joka viittaa sydämeen ja ”logy” tarkoittaa opiskelua ja tutkimusta. Kardiologia on lääketieteen haara, joka tutkii sydämen häiriöitä ja sairauksia, jotka ulottuvat aina synnynnäisistä

sairauksista saatuun sydänsairauteen saakka, kuten sepelvaltimotauti ja sydämen vajaatoiminta. Lääkärit, jotka erikoistuvat kardiologiaan kutsutaan kardiologeiksi ja he ovat vastuussa erilaisista sydänsairauksien lääketieteellisestä hoidosta. Sydänkirurgit sen sijaan ovat lääkäreitä, jotka suorittavat vaativia lääketieteellisiä menettelyitä sydänsairauksien korjaamiseksi. (Mandal, 2014)

Yleisimpiä sydän- ja verisuonisairauksia ovat sepelvaltimotauti (koronaaritauti), sydämen vajaatoiminta, aivoverenkiertohäiriöt (aivohalvaus tai ohimenevä verenkiertohäiriö), ääreisverenkierron häiriöt (katkokävely) ja laskimotukokset (tromboosi). Sydän- ja verisuonisairaudet ovat yksi keskeisistä sairastavuuden ja kuoleman aiheuttajista Suomessa ja muissa länsimaissa. Sydän- ja verisuonitaudeiksi kutsutaan sairauksia, jotka huonontavat sydämen tai muun verenkiertoelimistön (ääreisverenkierto tai keskushermosto) toimintaa. Riskitekijöitä ovat ylipaino, tupakointi, alkoholi, vääränlainen ruokavalio (rasva ja suola), liikunnan puute, korkea kolesteroli ja verenpaine sekä diabetes. Lisäksi geneettiset tekijät voivat olla sairastumiselle altistavia tekijöitä. (Sanofi, 2015)

Tässä luvussa esitellään muutamia järjestelmiä, ratkaisuja, sovelluksia, jotka hyödyntävät tekoälyä, koneoppimista ja niitä hyödyntäviä sovelluksia. Tekoälyä hyödyntävien sovelluksien avulla voidaan monitoroida sydänsairauteen sairastuneita potilaita, suorittaa päätöksentekoa käyttäen päätöksenteon tuen järjestelmiä, diagnosoida sairauden vakavuuden tilaa, seuloa, ennustaa elinikää jne.

3.3.1 Integroitu CardioSmart365-järjestelmä sydänsairauspotilaiden monitorointiin

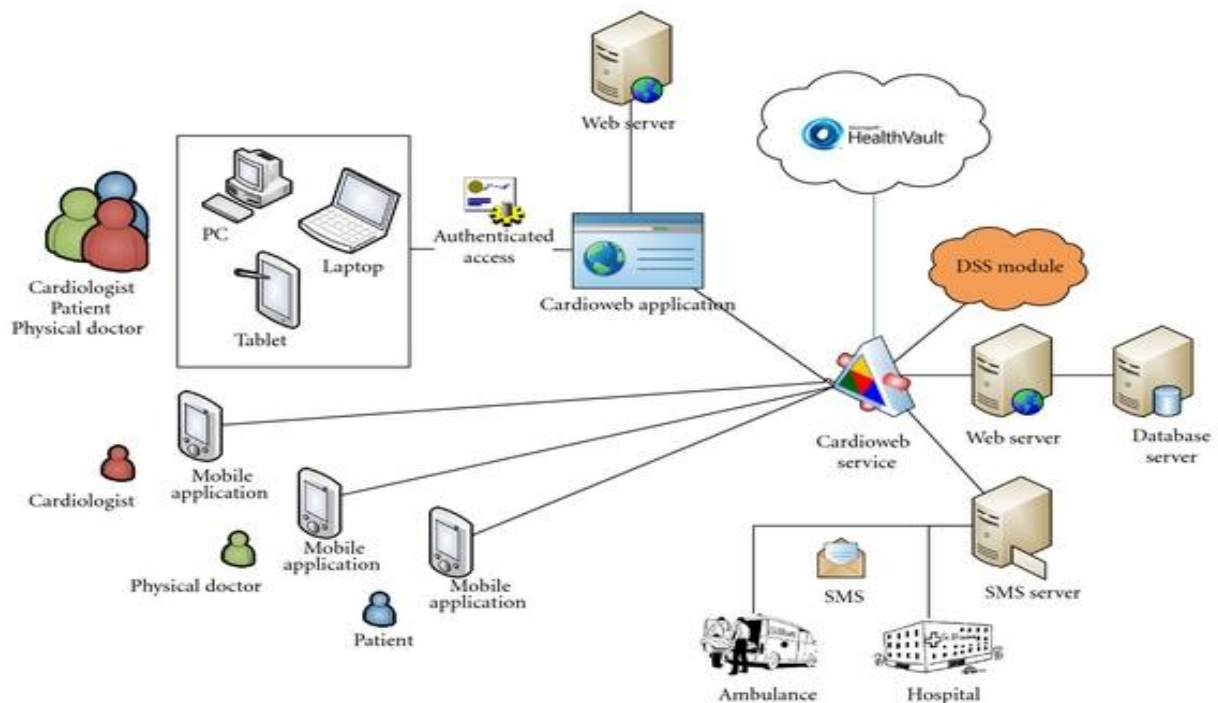
CardioSmart365 on integroitu järjestelmä, jonka avulla voidaan monitoroida potilaita, joille on todettu sydänsairaus. Järjestelmä koostuu WWW-sovelluksista, natiiveista älypuhelimien applikaatioista, päätöksentekijärjestelmästä (DSS eli Decision Support System) sekä Web-palveluista, joiden avulla on mahdollista kommunikoida loppukäyttäjien, kuten kardiologit, potilaat ja lääkärit. CardioSmart365 kehitettiin tarjoamaan lisäarvopalveluita kardiologisista sairauksista kärsiville potilaille ja lääkäreille nopealla, joustavalla ja helppokäyttöisellä integroidulla ratkaisulla. Alun perin motivaatio Cardiosmartin kehittämiseen lähti uuden teknologian hyödyntämisen tarpeesta kliinisessä lääketieteessä, tosin useita askelia järjestelmän optimoimiseksi on vielä tehtävä. (CardioSmart365)

Järjestelmän avainominaisuuksia (Sourla, 2012) ovat:

1. Hälytystapausten hallinta, joissa potilas lähettää valituksen ja kardiologi arvioi tilanteen sekä tekee tarvittavat toimenpiteet, kuten tilaa ja toteuttaa sydäntutkimukset.
2. Potilaiden kotona tehtävien tärkeiden elintoimintojen (verenpaine, veren sokeripitoisuus, hapetusarvo, paino ja pituus) mittauksien tallennus ja hallinta.
3. Potilaiden digitaalisen potilasjärjestelmän hallinta.
4. Kardiologiset potilasmoduulit yleisemmille sydänsairauksille.

5. Päätöksentekijärjestelmä (DSS), joka perustuu sumeaan logiikkaan (Fuzzy Logic).
6. Integroitu viestienhallinnan moduuli käyttäjien välistä optimoitua kommunikaatiota varten.
7. Liittymä Microsoftin HealthVault-alustaan.

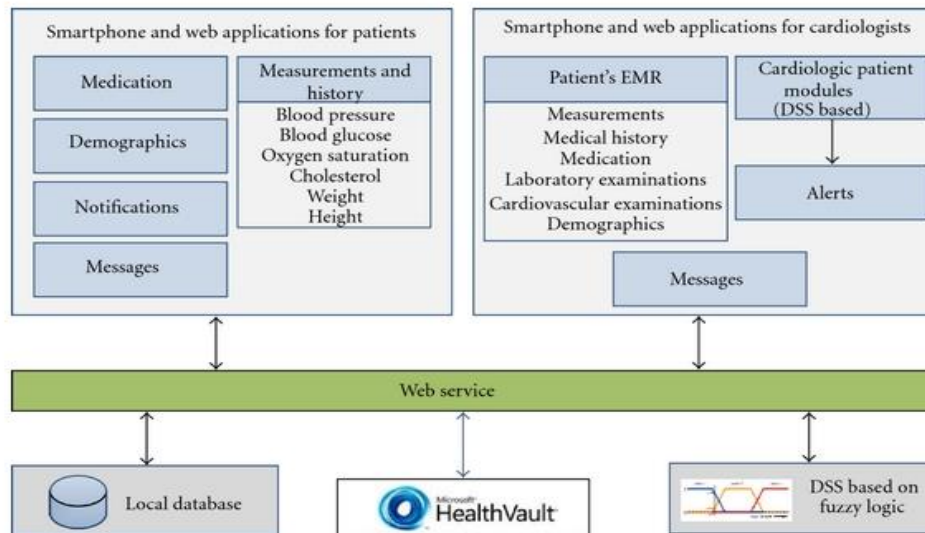
Kuviosta 20 havainnollistuu CardioSmart365 komponenttien liittymien arkkitehtuuri. Arkkitehtuuri on perinteinen asiakas-palvelin (Client-Server), jossa auktorisoiduilla käyttäjillä on pääsy integroituun järjestelmään käyttäen asiakassovelluksia, Web-aplikaatiota ja natiivia älypuhelimelle toteutettua helppokäyttöistä mobiilisovellusta. Mobiilisovelluksen käyttöliittymä on suunniteltu siten, että sovelluksen käyttö vaatii minimaalisen määrän dataa, jolloin käyttö on käyttäjäystävällistä. Asiakassovellukset kommunikoivat ja vaihtavat dataa tietokannan kanssa Web-palveluiden kautta, joka mahdollistaa datan vaihdon heterogeenisten järjestelmien kautta. Web-palvelut tarjoavat toiminnon, joka mahdollistaa tiettyyn tietoon pääsyn asiakassovelluksesta, kun autentikointi on suoritettu. Järjestelmä käyttää Microsoftin HealthVault-alustaa backend-alustana, johon järjestelmä varastoi (sekä hallinnoi) tärkeää potilasinformaatiota potilaiden EMR:stä sekä lisäksi mittaustuloksia. Järjestelmässä on myös SMS-palvelin, joka tarjoaa vaihtoehdoisen metodin tiedon siirtoa varten asiakkaan ja palvelimen välillä. (Sourla, 2012)



KUVIO 20. CardioSmart365 komponenttien arkkitehtuuri.(Sourla, 2012)

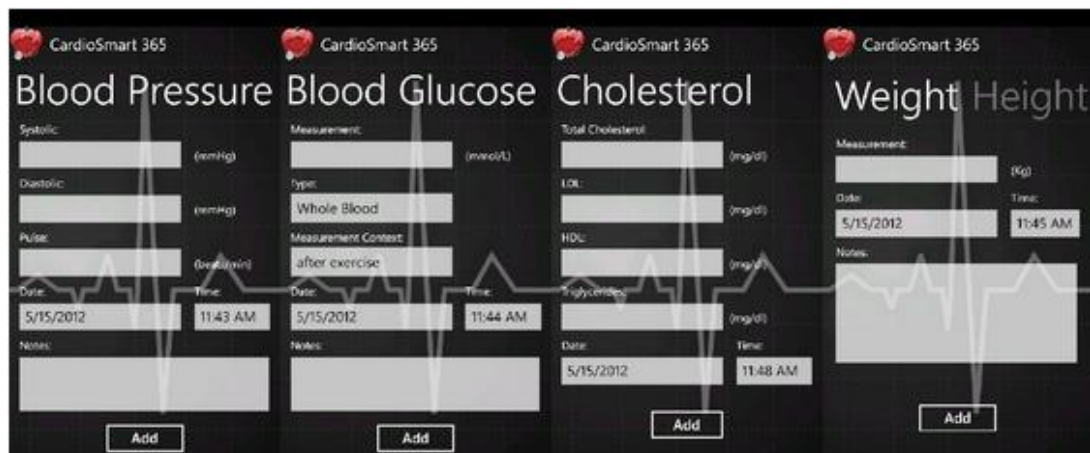
Kuviosta 21 ilmenee CardioSmart365-ratkaisun tarjoamat palvelut, jotka ovat:

1. Elintärkeiden toimintojen mittaaminen (Vital Signs Measurement).
2. Digitaalinen potilasjärjestelmä (EMR).
3. Kardiologinen potilasmoduuli.
4. Viestienhallinnan moduuli.



KUVIO 21. CardioSmart365 tarjoamien palveluiden arkkitehtuuri. (Sourla, 2012)

Potilaan terveydentilasta riippuen, kardiologit voivat neuvoa potilaitaan suorittamaan mittauksia säännöllisin väliajoin. Mittaustyypit voivat olla verenpainen, veren glukoosin, happisaturaation, painon ja pituuden mittaamista mittaustulosten riippuessa paljolti potilaiden terveydentilasta. CardioSmart365 tarjoaa potilaille työkaluja, jotta he voivat tallentaa mittaustuloksensa Web-käyttöliittymien ja mobiilisovelluksien (Kuvio 22) kautta sekä tallentaa ne järjestelmän tietokantaan. Mittaukset voidaan suorittaa kotona ja potilas voi toimittaa ne tallennettavaksi tai tallentaa automaattisesti, mikäli mittauslaite tukee Bluetooth- tai Wi-Fi-protokollaa. Potilas voi tarkkailla tietyn ajanjakson mittaustuloksiaan ja tehdä niistä kaavioita. Kardiologi, jolla on oikeudet tarkastella potilaan tietoja, voi käyttää niitä hyväksi tehdessään hoitosuunnitelmia. Tärkeiden elintoimintojen mittaustulokset tallennetaan myös Microsoftin HealthVault-palveluun. (Sourla, 2012)



KUVIO 22. CardioSmart365 mobiilisovelluksen käyttöliittymä mittauksia varten. (Sourla, 2012)

Järjestelmässä on myös sumeaan logiikkaan perustuva kontrollimoduuli, joka tarkastaa mittausalueen ulkopuolella olevia arvoja ja hälyttää tarvittaessa lääkärin. Jokainen vastuussa oleva lääkäri, kardiologi tai muu järjestelmää käyttävä lääketieteen ammattilainen voi asettaa sumean logiikan joukon koskien verenpainetta, glukoosia, kolesterolia ja painoa potilaan erikoistarpeisiin perustuen ja mahdollistaen tällä tavoin personoinnin. Arvot, kuten hyvin matala, matala, normaali, hieman korkea, keskimääräisesti korkea tai hyvin korkea ovat tavanomaisia kaikille potilaille, mutta kolmiarvoiset joukot tarjoavat enemmän. Lääkäri voi esimerkiksi määrittää hieman korkeana (little high) juuri sydänkohtauksen saaneelle potilaalle arvojoukon (100, 120, 140) sen ollessa sama erilaisen taustan omaavalle potilaalle, jolle arvo on määritelty normaaliksi. Sumean logiikan joukkojen käyttö ja kontrollimoduuli on toteutettu myös glukoositasapainon, kolesterolin ja painon monitoroimiseksi. (Sourla, 2012)

CardioSmart365-järjestelmän avulla kardiologeilla on pääsy potilaiden sairaskertomuksiin. CardioSmart365-järjestelmän digitaalinen potilasjärjestelmä (Kuvio 23) koostuu potilaan lääketieteellisestä historiasta, lääkityksestä, laboratoriotuloksista, sydäntutkimuksista (fyysiset tutkimukset), säännöllisistä vitaaalien elintoimintojen mittauksista ja demografiasta. Potilaan lääketieteellinen historiatieto kyseisessä järjestelmässä koostuu sepelvaltimotaudista (Coronary Artery Disease eli CAD), verenpainetaudista, sydämen vajaatoiminnasta, valtimoperäisestä sydänsairaudesta ja sydämen rytmihäiriöistä. Lisäksi se sisältää perustietoa kolesterolista, diabeteksestä, tupakoinnista, perheen historiatietoa sydänsairauksien suhteen, halvauksista, perifeerisestä valtimotaudista, kilpirauhasen vajaatoiminnasta, syövästä sekä keuhkojen, mahan, munuaisten taudeista ja neurologisista, autoimmunologisista, hematologisista, endokrinologisista ja psykiatrisista sairauksista. (Sourla, 2012)

Patient Medical History

Coronary Artery Disease | Hypertension | Heart Failure | Valvular Heart Disease | Heart Rhythm Disorders | Cholesterol | Diabetes | General Info

Coronary Artery Disease

Chronic CAD

Lesion in LM

Lesion in vessel(s)

Aborted Sudden Death

When: (year)

Acute Coronary Syndrome (ACS)

STEMI (elevation myocardial infarction)

When: (year)

UA (unstable angina) / NSTEMI (non elevation myocardial infarction)

When: (year)

other

When: (year)

Stable Angina

Class I (angina only with strenuous activity)

Class II (angina when climbing more than one flight of stairs)

Class III (angina when climbing 1 flight of stairs)

Class IV (angina at rest or with any physical activity)

Notes

< Enter your Notes Here >

Intervention for CAD

Primary PCI

LAD LCx RCA

ACS / elective PCI

PCI CABG

When: (year)

Valve replacement:

MVR

AOR

AOR+Bentall

Type of Grafts:

LIMA SVG

Number: (1-4)

LAD

LCx

RCA

LM

other

Notes

< Enter your Notes Here >

KUVIO 23. CardioSmart365-järjestelmän potilaan lääketieteelliset historiatiedot. (Sourla, 2012)

Järjestelmä sisältää informaatiota (Kuvio 24) potilaiden nykyisistä ja menneistä lääkityksistä, annostuksista, kestoista ja ohjeista. Lääketieteelliset tutkimukset sisältävät informaatiota täydestä verenkuvasta, hyytymisajoista ja biokemiallisista tutkimuksista. Sydän- ja verisuonitutkimus on fyysinen tutkimus, joka voidaan lääkärin tai kardiologin toimesta toteuttaa joko kotona tai klinikalla ja se sisältää informaatiota sydämen pulssista (myös reisiluun alueen ja jalan pulssi), kaulan suonien pulssista ja kuuntelusta. Järjestelmä tarjoaa käyttöliittymän informaation tallennukseen samanaikaisesti, kun se suoritetaan (Kuvio 25). Potilas suorittaa tärkeiden elintoimintojen mittauksen säännöllisesti ja se sisältää verenpaineen, glukoosin, happisaturaation, painon ja pituuden mittaukset. Demografiatiedot sisältävät yleisinformaatiota potilaista, kuten nimi, sukunimi, sukupuoli, ikä, vakuutusinformaatio ja yhteystiedot hätätilanteita varten.

CARDIOSMART365
Monitoring and Early Notification System
for Heart Diseases

Welcome [redacted] [Logout]

Home About

Summary Messages Patient Info

Medication

Measurements
Medical History
Medication
Demographics

Information for patient [redacted] [Logout]

Add Medication

Medication History

A/N	Name	Reason for Taking	Date Started	Date Discontinued	Route	Details
1	Euthyrox 0.025 MG Oral Tablet	hypothyroidism	13/10/2011	12/10/2012	By mouth	
2	Albuterol 0.5 MG/ML	Asthma	16/3/2011	6/12/2012	By mouth	
3	Depon	headache	no info	no info	By mouth	

Medication Details

Name: Euthyrox 0.025 MG Oral Tablet Strength: 0.025 Milligram (mg)

Dose: 1 Tablets Route: By mouth

Frequency: every morning

Reason (Indication): hypothyroidism

Date Started: 13/10/2011 Date Discontinued: 12/10/2012

Prescription Details

Prescribed By: Dr. Eleni Dimopoulou Date Prescribed: 12/10/2011

Prescription Quantity: 50 tablets

Instructions:
Take one tablet by mouth every morning for one year

Microsoft HealthVault

Copyright MMLAB 2010 - 2013. All rights reserved.

KUVIO 24. Potilaiden lääkityshistoria ja informaatio kardiologin näelmästä. (Sourla, 2012)

Enter Details for Cardiovascular Examination: 1

Pulses | Cardiac Palpation | Auscultation

Pulse	Presence / Absence	Jugular Venous Pulse
<input type="radio"/> Normal <input type="radio"/> Slow-rising Pulse <input type="radio"/> Collapsing Pulse <input type="radio"/> Bisferiens Pulse <input type="radio"/> Pulsus Paradoxus <input type="radio"/> Pulsus Alterans <input type="radio"/> Pulsus Bigeminus	<input type="checkbox"/> Femoral Pulses <input type="checkbox"/> Foot Pulses	<input type="radio"/> Normal <input type="radio"/> Not seen <input type="radio"/> Accentuated a Wave <input type="radio"/> Cannon a Wave <input type="radio"/> Accentuated v Wave <input type="radio"/> Particularly Prominent y Descent

Notes

< Enter your Notes Here >

Pulses | Cardiac Palpation | Auscultation

Apical Impulse	Presence / Absence
<input type="radio"/> Normal <input type="radio"/> Impalpable <input type="radio"/> Forceful or Thrusting Apex <input type="radio"/> Displaced to the Left/Diffuse Heaving Nature <input type="radio"/> Sharp Tapping Nature <input type="radio"/> Indrawing of the Intercostal Spaces during Systole	<input type="checkbox"/> Thrills <input type="checkbox"/> Left Parasternal Heave

Pulses | Cardiac Palpation | Auscultation

Heart Sounds	Murmurs Type	Intensity	Radiation
<input type="radio"/> Normal <input checked="" type="radio"/> Additional/Pathologic Additional / Pathologic <input type="checkbox"/> S3 <input type="checkbox"/> Ejection Sound <input type="checkbox"/> S4 <input type="checkbox"/> Gallop Rhythm <input type="checkbox"/> Opening Snap <input type="checkbox"/> Mid-Systolic Click <input type="checkbox"/> Prosthetic Valves <input type="checkbox"/> Pericardial Knock	<input type="checkbox"/> Innocent <input checked="" type="checkbox"/> Systolic <input type="radio"/> Crescendo/Decrescendo Character <input type="radio"/> Pan or Holosystolic <input type="checkbox"/> Diastolic <input type="checkbox"/> Early Diastolic <input type="checkbox"/> Continuous	<input type="radio"/> 1/6 <input type="radio"/> 2/6 <input type="radio"/> 3/6 <input type="radio"/> 4/6 <input type="radio"/> 5/6 <input type="radio"/> 6/6	<input type="checkbox"/> To the Carotids <input type="checkbox"/> To the Axilla <input type="checkbox"/> To the Back

KUVIO 25. Sydän- ja verisuonisairauksien tutkimuksen toteuttaminen.(Sourla, 2012)

Hätätilanteissa, potilas voi lähettää viestin (Chief Complain) potilaan hoidosta vastuussa olevalle kardiologille. Chief Complain on tavallaan subjektiivinen lausunto, jonka potilas tekee kuvaamalla merkittävimmät tai vakavimmat oireet tai merkit sairaudesta tai toimintahäiriöstä, joka sai potilaan etsimään hoitoa. Potilas valitsee yhden tai useamman valituksen, kuten esimerkiksi: rintavaivat, hengenahdistus, pyörtyminen, sydämenpysähdys,

sydämentykytys, jalkojen turvotus, kriittinen tila/sokki, vatsavaivat tai kuvailee, mitä hän tuntee. Lisäksi potilas voi lähettää mittaustuloksia, kuten verenpaine, happisaturaatio, hengitystiheys, paino ja pituus tai valita järjestelmän lähettämään viimeisimmät HealthVault-palveluun tallennetut arvot. (CardioSmart365) Kuviossa 26 havainnollistuu CardioSmart365-sovelluksen Chief Complain-toiminto.



KUVIO 26. Häätötilanteita varten tarkoitettu Chief Complain-ominaisuus.(Sourla, 2012)

CardioSmart365 sisältää sydäntauteihin erikoistuneita potilasmoduuleita (Cardiologist Patient Modules eli CPM), jotka sisältävät päätöksentuen järjestelmän (DSS), joka taas perustuu sumean logiikan hyödyntämiseen. Sumeaa logiikkaa käytetään, koska se tarjoaa ratkaisuja, kun järjestelmä on liian monimutkainen ja sitä ei voida mallintaa matemaattisesti tai jos järjestelmä esittää epätarkkuuksia (fuzziness). CPM:t sisältävät hälytysviestejä ja kriittiset viestit lähtevät automaattisesti, kun lääkäri tallentaa dataa päätöksentuen järjestelmään. Jotkin DSS:n päätökset ovat deterministisiä, kun taas toiset vaativat kvalitatiivisten muuttujien käyttöä. Kvalitatiiviset muuttujat muunnetaan sumean logiikan joukoiksi, joiden avulla voidaan tehdä sumean logiikan päätöksenteon sääntöjä. (Sourla, 2012)

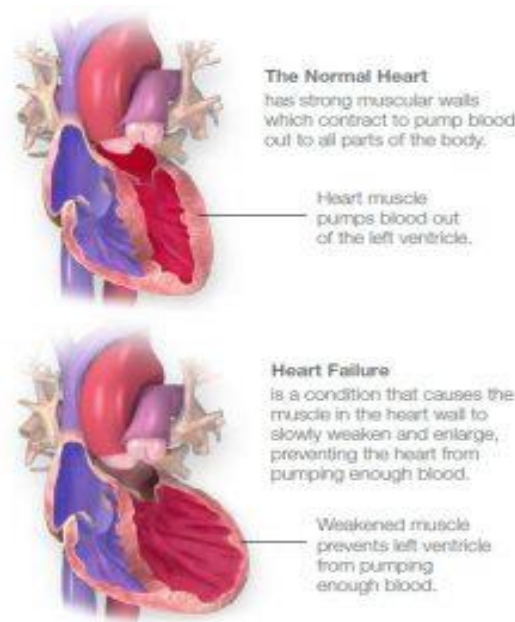
Esimerkkinä päätöksenteon lausekkeesta sumeaa logiikkaa käyttäen:

"If age is HIGH AND blood pressure is LITTLE HIGH AND coexisting disease is Chronic Kidney Disease THEN Medication is DIURETIC HIGH."

CPM-moduulit on suunniteltu lääkäreiden, kardiologien ja muiden lääketieteen ammattilaisten käytettäväksi. Kardiologit hyötyvät CPM:ien käytöstä ja yleislääketieteen ammattilaiset voivat kokea, että CPM:t ovat hyödyllisiä, kun he tekevät hoitopäätöksiä sydänsairauksista kärsiville potilaille. (Sourla, 2012)

3.3.2 Tekoäly ja EHR sydämen vajaatoiminnan ennustamisessa

Sydänsairaudet ovat olleet johtava kuolinsyy jo vuosikymmenien ajan länsimaissa (kuten USA). Sydämen vajaatoiminnasta eli sairaudesta, jossa sydänlihas (Kuvio 26) on liian heikko pumppaamaan tarpeeksi verta kehon läpi, kärsivien aikuisten määrä USA:ssa on ennakoitu kasvavan 46 % vuoteen 2030 mennessä, joka käsittää kahdeksan miljoonan ihmisen joukon. Tutkimuksien mukaan jopa puolet sydämen vajaatoiminnasta kärsivistä ihmisistä kuolee viiden vuoden sisällä diagnoosin saamisesta. (Ng, 2017) Kuviossa 27 alempana oleva sydän on voittunut ja se esittää sydämen vajaatoimintaa, ylempänä oleva sydän toimii normaalisti.

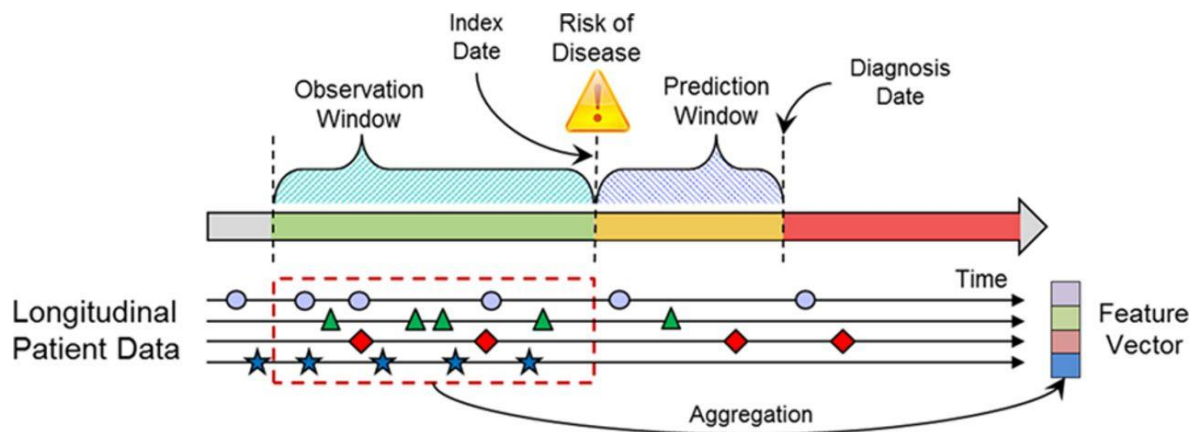


KUVIO 27. Esimerkki normaalista ja voittuneesta sydäimestä. (Ng, 2017)

Sydämen vajaatoiminta on hyvin vaikea diagnosoida, mutta IBM, kansallinen terveysinstituutti (National Institutes of Health eli NIH) ja Sutter Health-organisaation tutkijat sekä lääketieteen ammattilaiset Geisinger Health Systems terveysalan yrityksestä tekivät yhteistyötä sydämen vajaatoiminnan ennustamiseksi käyttämällä digitaalisia potilastietojärjestelmiä (EHR). Viimeisten kolmen vuoden aikana tekoälyn kehitys, kuten luonnollisen kielen prosessointi, koneoppiminen ja Big Data-analytiikka mahdollistivat mallien opettamisen, jotta sydämen vajaatoimintaa voitiin diagnosoida 1 – 2 vuotta aiemmin kuin nykypäivänä on totuttu. (Ng, 2017)

Huolimatta siitä, että lääkärit dokumentoivat potilaiden oireita etukäteen, äkillisen sydämen vajaatoiminnan puhkeamisen ennustaminen on vaikea tehtävä. Tarpeesta johtuen, tutkijat kehittivät tekoälyä hyödyntäen mallin (Kuvio 28), joka kykeni tunnistamaan sydämen vajaatoiminnan hyödyntämällä digitaalisia potilastietojärjestelmiä. Malli analysoi dataa niin sanottujen ennuste- ja tarkkailuikkunoiden pituudelta, eri data-alueiden määrän mukaan, opetettavan tietojoukon potilastietueiden lukumäärän mukaan ja potilaskohtaamisten

tiheyden mukaan ennustaakseen sydämen vajaatoimintaa. Ongelmia kuitenkin aiheuttavat digitaalisen potilaskertomusjärjestelmän potilasdata, sillä sen määrä ja diversiteetti ovat hyvin heterogeenisiä aiheuttaen potentiaalisia metodologisia haasteita EHR-datankäytölle mallinnustarkoituksiin. (Livernois, 2017)



KUVIO 28. Sydämen vajaatoiminnan ennustamiseen käytetty tutkimusmalli.(Ng, 2017)

Ennustettaessa dataa 1684 sydämen vajaatoiminnan tapauksesta, malli paljasti, että aiemmin sydämen vajaatoiminnan ennustamisessa käytetyt datatyypit olivat vanhentuneita ja vain 6/28 riskifaktoria Framinghamin sydämen vajaatoiminnan tunnusmerkeistä (Framingham Heart Failure Signs and Symptoms eli FHFSS) olivat tarkkoja tunnusmerkkejä tulevaisuuden sydämen vajaatoiminnan diagnosoinnissa. Malli paljasti myös, että muut datatyypit, joita on rutiininomaisesti käytetty keräämään dataa digitaaliseen potilastietojärjestelmään (kuten sairausdiagnoosi, reseptit ja laboratoriotestit) yhdistettynä FHFSS:n kanssa, voivat auttaa paremmin ennustamaan potilaan sydämen vajaatoiminnan puhkeamista. (Ng, 2017)

Tutkimuksissa selvisi, että mallin suorituskyky parani monipuolisten datatyyppien käytön myötä, tosin diagnosoinnin, lääkitysmääräyksien, sairaalajaksojen jne. data oli mallin kannalta oleellisinta. Tutkimusryhmä valitsi kaikkein merkitsevimmät muuttujat luodakseen pienemmän ja kestävämmän osajoukon muuttujista. Tämä auttoi kehittämään ennustavia malleja, jotka olivat sekä suorituskykyisiä että käytännöllisiä. Periaatteessa kliiniseltä kannalta katsottuna mallissa voisi olla yli 1000 faktoria, mutta tämän kaltaisen mallin käyttö olisi vaikeaa ja vaatisi paljon työtä. Sen sijaan sopivan pienen relevantin datamäärän löytäminen ennustavien mallien luomiseksi on oleellista. (Ng, 2017)

3.3.3 Tekoälyä hyödyntävä CAD-järjestelmä sydämen vajaatoiminnan diagnosointiin

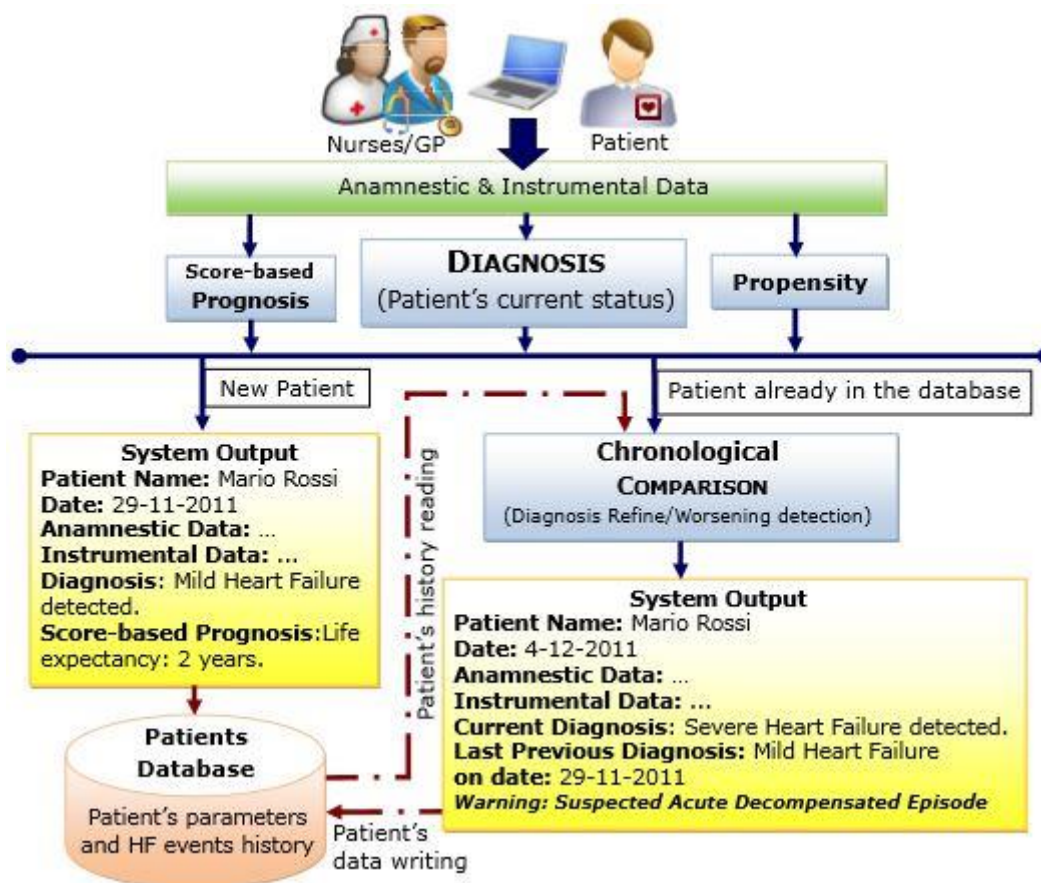
Italiassa tutkijat ovat kehittäneet prototyypin tekoälyä hyödyntävästä CAD (Computer Aided Diagnosis)-järjestelmästä, joka on tietokoneavusteinen diagnosointijärjestelmä sydänsairauksien todentamiseksi. Järjestelmän tarkoituksena on avustaa yleislääketieteen ammattilaisia ja hoitajia kliinisessä päätöksenteossa, jotka eivät ole erikoistuneet kardiologiaan. Järjestelmä vastaanottaa anamnestistä (esitietoihin liittyvää) ja

instrumentaalista (instrumentteihin liittyvää) dataa ja tekee diagnoosin ja ennusteen suhteessa potilaan nykyiseen terveydentilaan. Järjestelmä ottaa myös huomioon potilaan aiemman kliinisen historian diagnooseja tehdessään. Lisäksi järjestelmä rakentaa sydämen vajaatoiminnasta kärsivien potilaiden datasta tietokannan tarjoamalla arvokkaan tietovarannon tulevaisuuden hyödyntämistä varten. (Guidi ym., 2012)

Anamnestinen data syötetään järjestelmään manuaalisesti, mutta instrumentaalinen data vastaanotetaan automaattisesti lääketieteellisiltä instrumenteilta, jotta CAD-järjestelmä voi toimia. Järjestelmä voi toimia täydellisenä ratkaisuna sydämen vajaatoiminnasta kärsivien potilain etämonitoroinnissa tarjoamalla mahdollisuuden myös telelääketieteelle. Prototyypijärjestelmää käyttäen potilaat voivat saada suoraan ohjeita hoitajilta ja erityiset hälytykset asiantuntijoille lähtevät eteenpäin vain, mikäli kyseessä on vakava sydämen vajaatoiminta, potilaan tilan paheneminen tai kriittisen tilan pysyvyys. (Guidi ym., 2012)

Järjestelmässä on kolme pääosa-aluetta (Kuvio 29), jotka ovat: 1. diagnosointi (sydämen vajaatoiminnan vakavuuden arviointi), 2. ennustuksen hallinta sekä 3. seurannan hallinta (kronologinen vertailu). Järjestelmän toimintaa tutkittiin useilla tekoälytekniikoilla, kuten neuroverkot (Neural Network), SVM-koneella (Support Vector Machine), päätöspuilla (Decision Trees) ja sumeilla asiantuntijajärjestelmillä (Fuzzy Expert System). Järjestelmää opetettiin ja integroitiin diagnostiikkakojelautaan (Dashboard). Sumea asiantuntijajärjestelmä käyttää toimiakseen geneettistä algoritmia (Pittsburgin lähestymistapa) ja sitä ei ole oltu aiemmin hyödynnetty sydämen vajaatoiminnan kentässä. (Guidi ym., 2012)

Diagnostiikkaosuus sisältää kolmitasoisen arvioinnin potilaan nykyisestä tilasta: lievä, kohtalainen ja vaikea sydämen vajaatoiminta. Pisteytyksiin perustuva ennusteosuus antaa lopputuloksena prosentuaalisen tuloksen elinajanodotteesta seuraavien 1 – 4 vuoden välille. Tämä osuus käyttää toimiakseen aiemmin mainittuja tekoälytekniikoita. Seurannan hallinta koostuu kronologisesta potilaan nykyisen terveydentilan vertailusta aiemman potilaan kliiniseen tietokantaan tallennettuun tilaan verrattuna. Tämä osuus tarjoaa diagnostiikkatietoa sydämen vajaatoiminnan tyypistä, kuten krooninen ja vakaa sydämen vajaatoiminta, akuutti jakso jne. Lisäksi se tunnistaa tilan huononemisen. Prosessi on mahdollinen vain, jos potilas on aiemmin tunnettu, uuden potilaan tapauksessa voidaan suorittaa vain perusdiagnosointi. (Guidi ym., 2012)



KUVIO 29. CAD-prototyypijärjestelmän toiminta. (Guidi ym. 2012)

Kuviosta 30 havainnollistuu aineiston rakenne, jossa lievistä sydämen vajaatoiminnasta kärsiviä oli harjoitusjoukossa (Training Set) 35, kohtalaisessa 31 ja vakavassa 34 eli yhteensä 100. Testijoukossa vastaavasti 15, 8 ja 13 eli yhteensä 36.

Training - Test Set	N ^o of Mild HF patients	N ^o of Moderate HF patients	N ^o of Severe HF patients	Total
Training Set	35	31	34	100
Test Set	15	8	13	36

KUVIO 30. Aineiston rakenne. (Guidi ym. 2012)


Kuvio 31 havainnollistaa, että parhaat tulokset kaikista joukoista (lievä, kohtalainen ja vakava) tulivat käyttäen tekoälyn metodina neuroverkkoja, joka luokitteli oikein harjoitusjoukon potilaista 98/100 ja testijoukosta 31/36. Kokonaistarkkuus testijoukon potilaille oli 86.1 %, joka oli testin kaikista teknologioista paras. SVM-teknologia oli teknologioista epätarkin ja sen vastaavat arvot olivat 74/100 ja 25/36 kokonaistarkkuuden ollessa 69.4 %. Sumean logiikan geneettinen algoritmi antoi tulokseksi 74/100 ja 26/36 kokonaistarkkuuden ollessa 72.2 %. Päätöspuu oli jo selvästi tarkempi antaen tuloksiksi 84/100 ja 28/36, jolloin kokonaistarkkuus oli 77.8 %.

AI Technique	N° of correctly classified patients		Total Accuracy in classifying Test Set patients
	Training Set (100)	Test Set (36)	
Neural Network	98	31	86.1%
SVM	74	25	69.4%
Fuzzy - Genetic	74	26	72.2%
Decision Tree	84	28	77.8%

KUVIO 31. CAD-järjestelmän tekoälyteknologioiden suorituskykymittauksia. (Guidi ym. 2012)

3.3.4 Tekoäly ja koneoppiminen apuna sydänsairaiden eliniän ennustamisessa

Lontoon Imperial Collegen tiedemiesryhmä on kehittänyt ohjelmiston, jonka avulla voidaan luoda potilaista virtuaalisia 3D-sydänmalleja (Kuvio 32), jotka jäljittelevät tapaa, jolla sydänlihas toimii. Tekoäly kykenee oppimaan nopeasti, mitkä ominaisuudet sydämen toiminnassa parhaiten ennustavat sydämen vajaatoimintaa ja riskiä kuolemaan. Järjestelmä käyttää sydämen MRI-kuvausta yhdessä veri- ja muiden kokeiden informaation kanssa mallia muodostaessaan. Aiemmin tekoälyä on hyödynnetty tautien, kuten syöpä ja aivosairaudet, diagnosointiin sydämdiagnoosien ollessa vaikeampia diagnosoida ja ennustaa. (Brogan, 2017)



KUVIO 32. MRI-kuvauksiin perustuva 3D-virtuaalimalli sydäimestä.(Brogan, 2017)

Teknologiaa on testattu potilailla, joilla on keuhkoverenpainetauti (Pulmonary Hypertension eli PH), joka johtaa sydänvikaan, mikäli sitä ei hoideta oikealla tavalla. Riittävän hoidon tapaa päätettäessä on tarpeen määrittää, kuuluuko potilas korkean vai matalan riskin ryhmiin, joka on usein epätarkkaa käyttäen nykyisiä teknologioita. Radiology-lehdessä julkaistujen testituloksien mukaan koneoppimisen algoritmit ovat nopeampia ja tarkempia tekemään ennusteita kuin nykyiset metodit. Tutkijoiden mukaan tämä on ensimmäinen kerta, kun tietokoneet ovat kyenneet tulkitsemaan sydänkuvia ja ennustamaan tarkasti, kuinka kauan

potilas tulee elämään. Tämä voi muuttaa tapaa, jolla lääkärit kohtelevat sydänpotilaita. Tutkijoiden mukaan teknologiaa voidaan käyttää tulevaisuudessa myös muun tyyppisiä sydänsairauksia omaavien potilaiden diagnosointiin. (Brogan, 2017)

Keuhkoverenpainetauti vaikuttaa 7000 ihmiseen Isonsa Britannianssa ja sille on ominaista korkea verenpaine verisuolissa, jotka ovat keuhkojen kanssa tekemisissä. Olosuhde rasittaa sydämen oikeaa puolta ja aiheuttaa progressiivista vahinkoa ajan kanssa johtaen lopulta hoitamattomana sydänvikaan. Kolmasosa potilaista kuolee viiden vuoden sisällä diagnoosista. Hoidettuna keuhkoverenpainetauti sairastavat potilaat voivat elää pidempään, sillä lääkitys auttaa verta virtaamaan helpommin keuhkojen läpi. Tähän saakka radiologit ovat tehneet aikaa vieviä sydäntoimintojen kliinisiä mittauksia tunnistaakseen potilaat, joilla on suurin riski terveydentilan huonontumiseen. Uusissa tutkimuksissa tutkijat käyttivät tekoälyä ja koneoppimista ennustaakseen potilaan selviytymistä paremmin ja nopeammin kuin aiemmilla menetelmillä oli mahdollista. (Brogan, 2017)

Tutkimuksessa aineistona käytettiin historiallista Imperial College NHS Trust Hammersmith sairaalan 250 potilaan dataa. Ohjelmisto analysoi jokaisen potilaan liikkuvan MRI-kuvan ja replikoi yli 30 000 pistettä sydämen alueelta jokaisella sydämenlyönnillä. Käyttäen tätä informaatiota ohjelmisto loi jokaiselta potilaalta virtuaalisen 3D-sydämen ja oppi itsenäisesti sekä automaattisesti, mitkä ominaisuudet ennustivat sydänsairauksia ja kuolemaa. Tietokone kykenee tekemään analyysit vain sekunneissa ja samanaikaisesti tulkitsemaan kuvantamisdataa sekä informaatiota verikokeista ja muista testeistä ilman ihmisen puuttumista asiaan. Prosessi voi auttaa lääkäreitä tekemään oikeita hoitopäätöksiä oikeille potilaille ja vielä oikeaan aikaan. Teknologiaa voidaan käyttää ennustamaan muiden sydänsairauksien seurauksia täydentämään tapaa, jolla lääkärit tulkitsevat lääketieteellisten testien tuloksia. Tavoitteena on nähdä, jos paremmista ennusteista on ohjaamaan hoitoa, jotta ihmiset voisivat elää pidempään sekä kehittää ohjelmistoa tunnistamaan, minkä tyyppinen hoito toimii parhaiten kullekin potilaalle. (Brogan, 2017)

3.4 Tekoäly ja onkologia

Tässä raportin luvussa esitellään aivokasvaimen, iho- ja rintasyövän diagnosointiin liittyviä tekoälyä hyödyntäviä sovellusratkaisuja. Tekoälyn on tutkimuksien mukaan todettu lähentelevän jo ihmisten suorituskykyä syöpätapauksien diagnosoissa, näin on erityisesti rintasyöpien tapauksessa. IBM kehittämän ja tekoälyä hyödyntävän Watson-supertietokoneen on todettu diagnosoineen harvinaislaatuisia syöpätapauksia vain 10 minuutissa, joka ei lääkäreiltä onnistunut kuukausien työmäärällä. Watson oli jo vuoteen 2013 mennessä analysoinut 605 000 lääketieteellistä näytettä, kaksi miljoonaa sivua tekstiä ja käynyt lävitse 25 000 harjoitustapausta. Lisäksi työtunteja Watsonin hienosäätöön oli kulunut 14 700. Watson auttaa lääkäreitä tekemään parempia hoitopäätöksiä, sillä heillä on Watsonin kautta pääsy huomattavasti aiempaa kattavampaan informaatioon. Watson ei

kuitenkaan kykene kaikkeen, vaan sen oppiminen riippuu tietämyksestä, jonka lääkärit ja muut terveydenhuollon palveluntarjoajat tuottavat. Lisäksi sen päätöksenteon prosessit eivät kykene käsittelemään empatiaa potilaita kohtaan ja ottamaan kontekstia huomioon. (EIO, 2016)

Ennen tekoälyä ja nykyaikaista teknologiaa patologit ovat diagnosoineet sairauksia pitkälti samalla tapaa jo 100 viime vuoden ajan eli tarkastelemalla manuaalisesti kuvia mikroskoopin avulla. Nykyään tietokoneet, älykäs teknologia ja algoritmit voivat auttaa lääkäreitä parantamaan tarkkuutta ja merkittävästi muuttaa tapaa, jolla syöpä ja muut sairaudet on mahdollista diagnosoida. Patologiassa on tutkittu tekoälyyn pohjautuvia metodeita, joiden avulla on mahdollista tulkita patologisia kuvia ja tehdä diagnooseista yhä tarkempia. Diagnoosissa käytetyt menetelmät voivat pohjautua syväoppimiseen, joka on koneoppimisen algoritmi, jota on käytetty useissa erilaisissa sovelluksissa, kuten äänen- ja kuvan tunnistus. Tämänkaltaisen menettelytapa opettaa koneita tulkitsemaan monimutkaisia malleja ja rakenteita reaalityodellisuuden datasta rakentamalla monikerroksisia tekoälyyn pohjautuvia neuroverkkoja prosessissa, jonka on ajateltu olevan samankaltainen oppimisprosessin kanssa, joka tapahtuu aivojen neokortekstin neuronikerroksissa.

Neuroverkot ovat nykyään paljon julkisuudessa oleva tutkimusaihe lääketieteessä, erityisesti radiologiassa, urologiassa, kardiologiassa, onkologiassa jne. Sillä on laaja sovellusalue useilla eri alueilla, kuten koulutus, liiketoiminta, lääketiede, insinööritieteet ja valmistus. Neuroverkoilla on tärkeä vaikutus myös päätöksentekojärjestelmissä (DSS). Neuroverkot eivät kuitenkaan ole uusi keksintö, vaan niitä ollaan kehitetty jo puoli vuosisataa, tosin vasta viime vuosina koneoppimisen metodeita on laajemmin käytetty ennustuksessa, etenkin lääketieteellisessä diagnosoinnissa, jonka alueella niitä käytetään parantamaan tarkkuutta ja puolueettomuutta. Maailmanlaajuisesti on useita tutkimusryhmiä, jotka työskentelevät neuroverkkojen lääketieteellisen diagnosoinnin kehittämiseksi ja tulokset ovat olleet lupaavia teknologian kehittyessä. (Genesan ym., 2010)

Syövän muodostumisessa karsinogeneesi on pitkän aikavälin prosessi, johon vaikuttavat useat eri tekijät ja joka muodostuu peräkkäisistä vaiheista. Prosessin aikana normaalit solut muuntuvat syöpäsoluiksi, jotka ovat kasvavat kontrolloimatta ja hallitsemattomasti. Syöpä on yleisnimitys yli 100 lääketieteelliselle tilanteelle, jotka sisältävät kontrolloimatonta ja vaarallista solun kasvua. Olemassa on useita syöpiä, joihin ainoastaan miehet ovat taipuvaisia sairastumaan ja osaan lähinnä vain naiset. Lisäksi iällä on vaikutusta ja syövät eivät ole kovin yleisiä alle 30-vuotiaiden ikäryhmissä. Syövän esiintyvyys lisääntyy ihmisen siirtyessä keski-ikään ja vanhentuessa. Geneettinen alttius sairastua syöpää on merkittävä tekijä ja esimerkkinä tästä on keuhkosityöpä. Naisten rintasyöpien tapauksessa rintasyöpää sairastavan lähisukulaisilla voi olla peräti kaksi-kolminkertainen riski sairastua samaan tautiin. Lisäksi ympäristötekijät voivat altistaa syöpään sairastumiselle. (Genesan ym., 2010)

Tavanomaiset onkologian tutkimusmenetelmät, kuten tutkimalla suuria joukkoja (jopa miljoonia) normaaleita soluja, jotta voidaan tunnistaa vain muutamia pahanlaatuisia soluja, on erittäin työläs tapa. Tietokone ja soveltuvat algoritmit voivat auttaa tässä tehtävässä. Automatisoidut järjestelmät kykenevät 92 % tarkkuuksiin patologiien 96 % sijaan, tosin yhdistämällä patologiien analyysit ja automaattisen diagnostiikan, on mahdollista päästä 99.5 %, joka on jo lähes täydellinen tulos. Kuvien digitalisointi ja koneoppimisen algoritmien käyttäminen voisi auttaa patologeja toimimaan nopeammin, tarkemmin ja tekemään tarkempia potilasdiagnooseja. Lääketieteen ammattilaisen analyysien ja tietokoneen diagnoosien yhdistelmä tuottaa tarkempia ja kliinisesti arvokkaampia diagnooseja ohjaamaan hoito-ohjelmien päätöksenteossa.

3.4.1 Ihosyövän diagnosointi älypuhelimien avulla

Yhdysvaltalaisen Stanfordin yliopiston tutkijat ovat kehittäneet metodin ihosyövän diagnosointiin käyttäen tekoälyä, jota voidaan tulevaisuudessa myös hyödyntää älypuhelimissa. Käyttäen soveltuvaa tekoälyä hyödyntävää syöpädiagnosointialgoritmia, tutkimustiimi kykeni luomaan tietokannan, joka koostuu 130 000 ihosairauskuvasta. Algoritmi voitiin tämän jälkeen opettaa visuaalisesti diagnosoimaan potentiaalinen syöpätapaus. (Roberts, 2017)

Tiimi toteutti testejä, joissa ilmeni, että tekoäly suoriutui tehtävästä tarkasti. Testit suorittivat myös 21 ihotautilääkärinä, joiden diagnooseihin tekoälyn suoriutumista verrattiin. Tekoälyn tunnistamat ihovauriot eli leesiot (Kuvio 33) edustivat yleisintä ja tappavinta ihosyöpää ja näissä diagnosointitapauksissa algoritmin suorituskyky vastasi ihotautilääkärin suorituskykyä. Testituloksien ollessa hyviä, teknologiasta tuotiin myös mobiililaiterympäristöön älypuhelimilla käytettäväksi. (Roberts, 2017)

Ihosyöpä valittiin tutkimusalueeksi, sillä joka vuosi USA:ssa diagnosoidaan 5.4 miljoonaa uutta ihosyöpätapausta. Selviytymisprosentit ovat kuitenkin 97 % luokkaa, mikäli melanooma on tunnistettu ajoissa ja hoitoon pääsy mahdollistuu riittävän aikaiseen. Tekoälyalgoritmin kehitystyö perustui Googlen jo aiemmin kehittämään algoritmiin, jonka avulla kyettiin erottamaan esimerkiksi eläinten kuvia, kuten kissa tai koira, toisistaan. Ihosyöpien tunnistusta varten tietokantaan ladattiin 130 000 kuvaa iholeesioista, jotka edustivat 2000 erilaista sairautta. Tämän jälkeen tekoäly kykeni tunnistamaan pahalaatuiset melanoomat sekä karsinoomat ja algoritmin syöpien tunnistuskyky vastasivat ihotautilääkärin vastaavaa usean koetestin jälkeen. (Roberts, 2017)



KUVIO 33. Havaintokuva iholeesiosta.(Roberts, 2017)

Toistaiseksi algoritmi on toteutettu vain tietokoneelle, mutta jatkossa sen hyödyntämistä mobiililaitteissa, kuten älypuhelimet, on suunniteltu. Lisäksi algoritmin tarvitsee käydä läpi tiukat validointiprosessit, jotta sitä voidaan hyödyntää kliinisissä käytänteissä ja jotta sen avulla voidaan tehdä hoitopäätöksiä tulevaisuuden sairaalaympäristöissä. Ihotautilääkärit tulisi myös saada omaksumaan sovelluksen käyttö ja potilaiden ottamat kuvat ihomuutoksista, mikä ei tällä hetkellä useimmiten ole tilanne. Tulevaisuudessa tilanne voi kuitenkin muuttua ja algoritmin validoimisen, sopivan mobiilisovelluksen kehityksen ja lääkärin hyväksynnän jälkeen tekoälyä hyödyntävää syöpädiagnostiikkasovellusta voitaisiin käyttää syöpädiagnooseihin tai ainakin ihotautilääkärien tekemien diagnoosien varmistukseen, mikä voisi tuoda lisäarvoa syöpädiagnostiikkaan ja siten säästää ihmishenkiä. (Roberts, 2017)

3.4.2 Neuroverkot aivojen MRI-kuvantamisessa aivokasvaimien tunnistamiseksi

Aivosyöpä on tunnetusti hyvin vakava tauti ja aiheuttaa usein kuolemantapauksia. Tunnistus ja luokittelujärjestelmän täytyy olla toimiva ja saatavilla, jotta sitä voidaan hyödyntää aivokasvaimen diagnosoinnissa jo sen aikaisessa vaiheessa. Syövän luokittelu on ollut yksi haastavimmista tehtävistä kliinisessä diagnoosissa. Syövän luokittelu on tehty pääosin tarkastelemalla solujen morfologisia eroja, joka ei aina tuota oikeaa erottelua syövän alatyypeistä. Asialla on kuitenkin merkitystä potilaan paranemisen suhteen. Tilannetta helpottamaa on kehitteillä erilaisia ratkaisuja, kuten Intialaisen tutkimusryhmän ratkaisu, jossa tietokonepohjaista menettelyä käytetään hyväksi tunnistamaan kasvaimia ja luokittelemaan kasvaintyyppit käyttäen potilaista otettuja MRI-kuvantamista ja lisäksi neuroverkkoalgoritmia. (Shivajirao ym., 2017)

Aivot ovat ihmiskehon kriittisin ja elintärkein elin ja yleisin syy aivojen toiminnan häiriöön on aivokasvain. Aivokasvain on suuri määrä soluja ja kudosta, jotka kasvavat kontrolloimatta ja lopulta käyttävät kaikki terveille soluille ja kudoksille tarpeen olevat ravintoaineet, joka johtaa

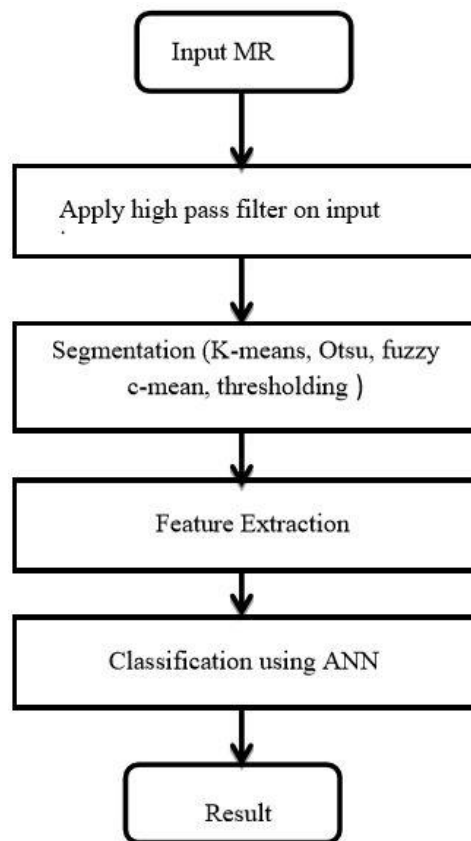
aivojen toimintahäiriöön. Pahanlaatuiset aivokasvaimet ovat kyseessä silloin kuin syöpäsolut laajenevat aivoihin muualla kehossa olevasta primääristä syövästä. Varsin ikäväksi aivosolujen tuhoutumisen tekee se, ettei aivosolut hitaasti uusiudu, kuten muut kehon solut. Nykyään lääkärit paikallistavat sijainnin ja aivokasvaimen alan tarkastelemalla potilaiden aivojen MRI-kuvia manuaalisesti, joka on niin epätarkkaa kuin aikaa vievää, jolloin tarvitaan lisäksi tehokkaampia ja tarkempia menetelmiä. (Shivajirao ym., 2017)

Olemassa on useita erilaisia metodeita aivokasvaimen tunnistamiseksi, kuten Otsu, K-means, Fuzzy-c-Means ja Thresholding. Italialaisen tutkimustiimin tarkoituksena oli kehittää täysin automaattinen järjestelmä, joka kykenee tunnistamaan ja erottelemaan aivokasvaimen potilaista otetuista MRI-kuvista. Järjestelmä käyttää neljää edellä mainittua erilaista segmentointimetodia erottelemaan aivokasvaimen MRI-kuvista. Metodeista K-means on tehokas segmentointimetodi, joka erottelee tiettyyn määrään klustereita. Jakaa kuvan kahteen alueelliseen luokkaan, jotka ovat etula ja taka-ala. Fuzzy c-means käyttää sumeaa logiikkaa osoittamalla arvot joka kuvapikselille. Thresholding määrittelee kynnyksarvon ja sitten testaa erilaisia kuvapikseleitä kynnyksarvoa vastaan. Tunnistamisprosessissa metodeita auttavat neuroverkot, jotka tarjoavat helpomman tavan tehdä analyyskejä, sillä biologisissa järjestelmissä datan klusterointi ja epälineaariset suhteet voivat johtaa tilanteeseen, jossa syntyy hyvin monimutkaisia matemaattisia malleja, jolloin työmäärä on huomattavasti suurempi. (Shivajirao ym., 2017)

Järjestelmän arkkitehtuurin vaiheet ovat:

1. Kuvan esiprosessointi: Järjestelmä vastaanottaa syötteenä MRI-kuvantamisesta skannatun kuvan sisältäen kohinaa, joka on poistettava. Järjestelmässä on sisäänrakennettuna suodatin (High Pass Filter), joka poistaa kohinan ja suorittaa esiprosessoinnin.
2. Segmentointi: Segmentoinnissa suoritetaan nimensä mukaisesti kuvan segmentointi käyttäen metodeita, kuten K-means, Otsu, Fuzzy c-mean ja thresholding.
3. Yhdistetty komponenttien nimeäminen: Yhdistettyjen komponenttien kuvasta tunnistamisen jälkeen, jokaiselle yhdistettyjen pikselien joukolle, joilla on samat harmaan värin tason arvot, osoitetaan sama yksilöllisen alueen nimi.
4. Kasvaimen tunnistaminen: Tässä vaiheessa on jo olemassa data-aineisto, joka on aiemmin kerätty MRI-kuvista, joista tässä vaiheessa poimitaan ominaisuuksia. Lisäksi tietämuskanta luodaan vertailua varten.
5. Vaiheen tunnistaminen: Viimeksi mainitussa vaiheessa on jo tunnistettu, että potilas kärsii aivokasvaimesta, jolloin on myös tärkeää löytää vaihe, johon sairaus on edennyt. Sairauden vaiheen löytämiseksi neuroverkkoja opetetaan, jolloin on mahdollista saada tietää, onko sairaus pahanlaatuinen.

Kuviosta 34 havainnollistuu aivokasvaimien diagnosointijärjestelmän arkkitehtuurin vuokaavio:



KUVIO 34. Aivokasvaimien diagnosointijärjestelmän arkkitehtuurin kaavio.(Shivajirao ym. 2017)

3.4.3 Rintasyövän diagnosointi tekoälyä hyödyntämällä

Mammografia on yksi lääketieteen parhaista työkaluista rintasyövän tunnistamiseksi, mutta tyypillisesti kivuliaaksi luokitellun testin tunnistessa potentiaalisen ongelman, naiset säännöllisesti käyvät testeissä koepalojen ottamiseksi, joka ei aina olisi tarpeen. Tekoälyä hyödyntämällä testitoimenpiteitä voidaan huomattavasti vähentää. Yhdysvaltalaiset Houston Methodist tutkijat ovat kehittäneet tekoälyä hyödyntävän sovelluksen, joka voi tulkita mammografiatuloksia jopa 30 kertaa nopeammin kuin lääkärit ja 99 % tarkkuudella. Tutkimustulos on julkaistuna artikkelina (Correlating Mammographic and Pathologic Findings in Clinical Decision Support Using Natural Language Processing and Data Mining Methods) Cancer-lehdessä. Tutkimustuloksena oli, että ohjelmisto kykenee intuitiivisesti ja hyvin nopeasti muutamaaan potilaskaaviot diagnostiikkainformaatioksi, joita ihmiset voivat tulkita. Menetelmä tarjoaa lääkäreille luotettavan ja aikaa säästävän tutkimuksen arvioitaessa potilaiden syöpäriskiä ja tarvetta lisätesteille. (Burns, 2016)

Määrittääkseen ohjelmiston tehokkuuden rintasyöpätapausten riskiarvioinnissa, tutkimustiimi tallensi tietokantaan mammografian ja patologian raportteja 500

rintasyöpäpotilaista sekä informaatiota diagnostiikkaominaisuuksista ja rintasyövän alatyypin mammografialöydöksistä, jotka korreloivat. Algoritmilta vei vain muutaman tunnin aikaa tehdä syöpäriskiarviot koko ryhmälle, joka lääkäreiltä olisi vienyt 50 – 70 tuntia arvioida vain 50 potilasta manuaalisesti. Ohjelmisto säästää satoja tai jopa tuhansia lääkärin työtunteja muuta tarvetta varten. (Burns, 2016)

Amerikkalaisten CDC (Centers for Disease Control and Prevention) ja American Cancer Society, jotka keräävät tilastotietoa erilaisista sairauksista ja syövästä, ovat julkaisseet tilaston, jossa kerrotaan jopa puolen 12.1 miljoonasta vuosittaisesta USA:ssa suoritetusta mammografiatutkimuksesta aiheuttavan väriä positiivisia tuloksia. Kuitenkin, tutkimusten mukaan potilaat, joiden mammografiatutkimuksen tuloksena on 3 – 95 % syöpäriski, ovat säännöllisesti kutsuttu koepalojen ottoa varten, joka aiheuttaa 1.6 miljoonaa koepalan ottoa rintasyöpäriskiin liittyen. Näistä 20 % ovat tarpeettomia väriä tuloksia. (Burns, 2016)

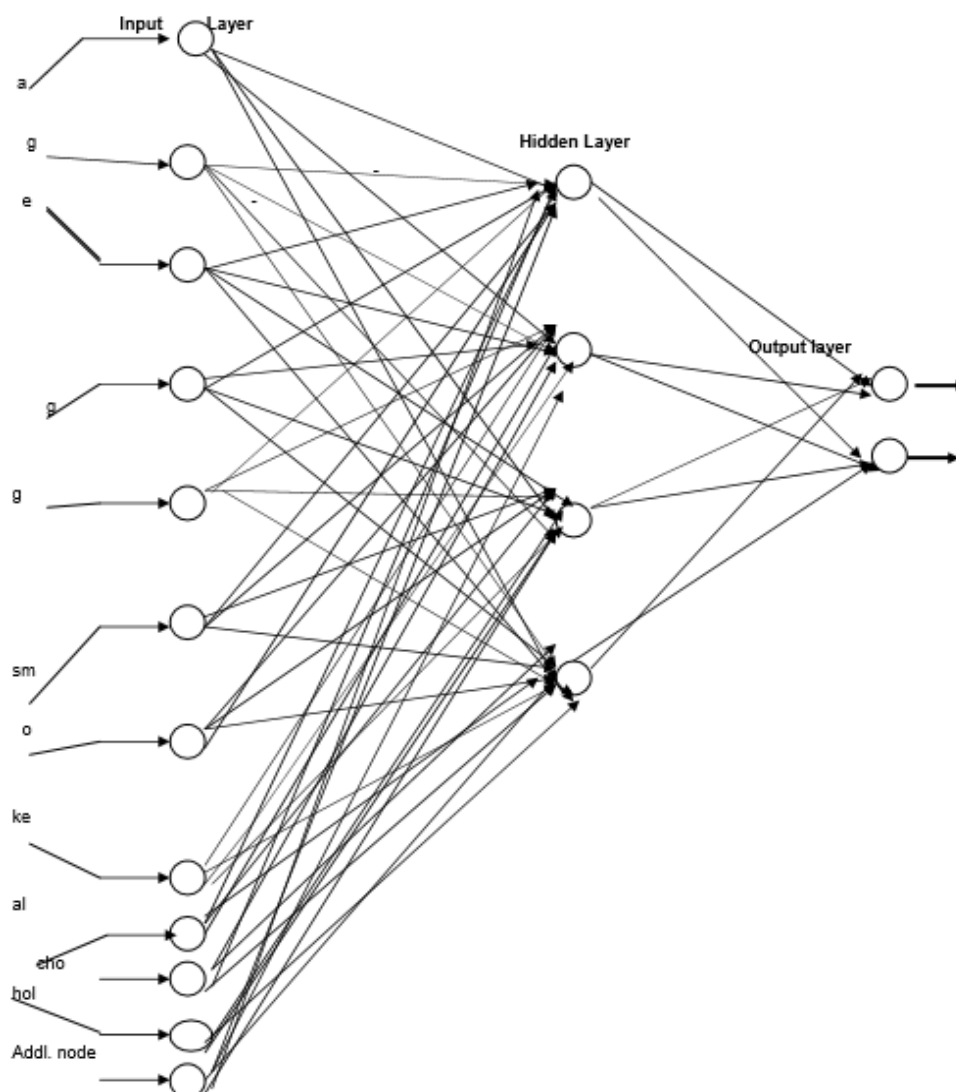
Kehitetyn sovelluksen käyttö minimoi potilaan kärsimyksiä ja maksimoi lääkärin ajankäyttöä. Lisäksi sovelluksen etuna on nousevien syövänhoitokulujen hillitseminen, jotka voivat nousta jopa 158 miljardiin USA:n dollariin vuoteen 2020 mennessä. Sovelluksen toivotaan helpottavan rintasyöpäriskin arviointia ja tarkentaa käytänteitä koepalojen otton suosituksista, jolloin turhalta koepalojen otolta voidaan välttyä. (Burns, 2016)

3.4.4 Sovellusmalli keuhkosyövän diagnosoimiseen neuroverkkoja hyväksikäyttämällä

Nykyään syöpä muodostaa oleellisen terveysongelman ja se on yksi yleisimmistä ja tappavimmista sairauksista maailmassa, sairauden ollessa toiseksi johtavin kuolinsyy. Yleisin riskitekijä keuhkosyövässä on tupakointi, johtuen haitallisista tupakan savussa olevista karsinogeeneista. Siten keuhkosyöpä onkin useimmiten yhteydessä tupakointiin ja tupakan käyttöön. Poltettu tupakka sisältää yli 4000 kemikaalia, joista yli 60 ovat tunnettuja karsinogeeneja. Tupakoiva henkilö on 23-kertaisessa riskissä sairastua keuhkosyöpään verrattuna tupakoimattomaan henkilöön. Tupakointi aiheuttaa noin 90 % keuhkosyöpäkuolemista miehillä ja lähes 80 % naisilla. Naisilla myös riski sairastua kohdunkaulan syöpään lisääntyy tupakoinnin myötävaikutuksesta. (Ganesan ym., 2010)

Neuroverkot ovat tärkeä työväline syövän tunnistuksessa ja monitoroinnissa. Lääkäreiden kyky tehokkaasti hoitaa ja parantaa syöpäsairauksia riippuu heidän kyvystään tunnistaa syövä t niiden alkuvaiheessa. Alkuvaiheen diagnoosi tehdään perustuen demograafiseen ja kliiniseen potilasdataan ja yli 30 % syöpäkuolemista on estettävissä. Syövän parantaminen on ollut lääketieteen tutkijoiden päätavoitteena vuosikymmeniä, mutta uusien hoitojen kehittäminen vie aikaa ja rahaa. Mahdollisesti tulevaisuudessa voidaan löytää keinoja syövän pohjimmaisten syiden löytämiseen ja siten estää syöpien leviäminen, jolloin paraneminen mahdollistuu. (Ganesan ym., 2010)

Neuroverkot tarjoavat uudenlaisen lähestymistavan ja niistä on tullut toteuttamiskelpoisia, monikäyttöisiä ja tehokkaita laskennallisia menetelmiä, joilla on taustalla vankka teoreettinen tausta ja vahva potentiaali olla tehokkaita erityisesti lääketieteen alueella. Useimmiten neuroverkko koostuu kolmesta kerroksesta (Kuvio 35), jossa ensimmäinen on syötekerros (input), seuraava piilotettu kerros (hidden layer) ja kolmas sekä viimeinen ulostulokerros (output layer). Usein ei ole tarpeen olla useampia piilotettuja kerroksia, vaan useimmat ongelmat voidaan ratkaista käyttämällä vain yhtä piilotettua kerrosta. Useampien piilotettujen kerroksien lisääminen on harvoin mielekästä ja lisäksi hidastaa verkon toimintaa huomattavasti. Usein tyypillinen tapa on aloittaa suureholla määrällä verkon solmuja (node) ja optimoida verkkoa käyttäen karsimiseen soveltuvia algoritmeja. (Ganesan ym., 2010)



KUVIO 35. Tyypillisen MLP-neuroverkon rakenne. (Ganesan ym. 2010)

Verkossa (ANN) syötesolmut koostuvat potilaan demografisesta datasta, kuten ikä, sukupuoli jne. Piilotetut solmut (neuronit) perustuvat vuosien aikana kerättyyn heuristiseen diagnosointitietämyksen keräämiseen ja ne koskevat tapoja, joilla asiantuntijat käyttävät

potilasdataa tehdessään diagnooseja. Heurestin tietämys on kerätty haastattelemalla asiantuntijoita kentällä, jolloin kerätystä datasta on voitu muodostaa diagnostinen puu kriteereihin perustuen. Verkon rakenteen ollessa valmis, sitä voidaan harjoituttaa, jolloin oppiminen alkaa. Opettaminen voidaan toteuttaa niin, että verkkoa opetetaan syöpäpotilaiden historiadataan, jossa lopputulos on jo tiedossa. Monikerroksisissa neuroverkoissa opettamiseen voidaan käyttää esimerkiksi Back-Propagation-algoritmia, joka on yksi tehokkaimmista koneoppimisen lähestymistavoista. (Ganesan ym., 2010)

ANN-verkon opettaminen tapahtuu tyypillisesti käyttämällä esimerkkejä ja iteraatioita niin kauan, että verkko voi konvergoitua tiettyyn tilaan, jossa laskentavirhe on hyvin pieni. Saavutettuaan tämän tilan voidaan sanoa, että verkko on oppinut jonkin tietyn halutun toiminnon. Oppimistekniikat voidaan jakaa valvottuihin, ei-valvottuihin ja vahvistettuihin oppimisen tekniikoihin. Laskentavirheen (Error Backpropagation eli EBP) laskeminen monikerroksisesta MLP-neuroverkosta voi vaatia hyvin suuren määrän opetuskerroksia, vaikka opetusaikaa voidaan vähentää huomattavasti omaksumalla on-line harjoitusparadigman. Kuitenkin, suurten verkkojen (suuret datamäärät) opettaminen voi olla hyvin työlästä. (Ganesan ym., 2010)

Opettaminen aloitetaan pienillä satunnaisilla reaaliluvuilla, jotka ovat mallin aloituspainoja. Jokaisessa harjoitusykyklissä lasketaan virhe ja painoja muutetaan suuntaan, joka minimoii virhettä. Virheellä on yhtä monta dimensiotta kuin painojen määrää ja kaikki painot mukailevat peruseriaatetta. Prosessia, jossa muutetaan painoja ja päivitetään painoja, kutsutaan oppimiseksi. Useimmissa tapauksissa ei ole tarpeen toteuttaa niin montaa iteraatiota, että virhe lakkaa vähentymästä, vaan haluttu lopputulos voidaan saavuttaa jo aiemmin ja vähemmällä iteraatiokerroksilla (noin 30 – 45 välillä). (Ganesan ym. 2010)

Kyetäkseen ennustamaan keuhkosityöpätalannetta, tutkijat keräsivät 100 keuhkosityöpäpotilaan datan eri sairaaloista ja opettivat neuroverkoja sen mukaisesti. Tarkkuudeksi saatiin 87 % ja algoritmin suoritus oli nopea, aikaa kului vain sekunteja. Tulokset osoittautuivat paremmiksi käyttäen Back-Propagation-algoritmia. Tulokset myös osoittivat, että neuroverkoja voidaan tehokkaasti käyttää hyväksi keuhkosityövän diagnosoinnissa, joka auttaa lääkäreitä suunnittelemaan parempia hoitoja ja tarjoamaan potilaille aikaisen vaiheen diagnosointimenetelmän, jolloin potentiaali sairauden hoitamiseen hyvissä ajoin kasvaa merkittävästi. (Ganesan ym., 2010)

3.4.5 Watson for Clinical Trials Matching-ratkaisu

IBM on yhteistyökumppaneidensa kanssa esitellyt vuotuisessa American Society Of Clinical Oncology – yhdistyksen ASCO 2017-tapahtumassa viimeisimpiä tutkimustuloksiaan hyödyistä syöpähoidoissa. Tutkimustulosten mukaan IBM:n kehittämä Watson päätyy peräti 96 % tarkkuudella samoihin suosituksiin keuhkosityövän hoidossa kuin onkologiaan erikoistuneet lääkärit ja lisäksi seuluntoihin käytettyä aikaa on kyetty vähentämään 78 %. Watsonia on myös

oppinut lisää syöpien diagnosoinneista ja uusimpia erikoistumisalueita ovat eturauhassyöpä ja sen hoitaminen. IBM:n kumppani, Memorial Sloan Kettering kognitiivinen digitaalinen sairaala on opettanut Watsonia syövän hoitomenetelmissä jo vuodesta 2012, jolloin ollaan päästy nykyiselle tasolle. (IBM, 2017)

Tutkimustulosten mukaan Watson Clinical Trials Matching-ratkaisun (CTM) avulla syövän seulontaan ja luotettavan tuloksen saamiseen kuluu aikaa vain 24 minuuttia aiemman 1h 50 minuutin sijasta ja tarkkuus on noussut 96 % vastaavuuteen syöpähoitosuosituksissa. Paksusuolen tapauksissa vastaava luku on 81 % ja peräsuolen syöpätapauksissa kyetään pääsemään 93 % saakka. Useita syövän tyyppisiä vastaan Watson kykenee antamaan suosituksen jopa 83 % vastaavuudella. Korkean riskin paksusuolensyövän tapauksissa hoitosuositus osuu oikeaan 73 % varmuudella. Watsonin tekemiä hoitosuosituksia on sittemmin verrattu alan ammattilaisten antamiin suosituksiin. (IBM, 2017)

Watson Clinical Trials Matching-ratkaisu vähensi Highlands Oncology Groupin ja Novartiksen esitutkimuksen mukaan potilaiden seulonta-aikaa 78 % 16 viikon pilottijakson aikana, jossa käsiteltiin 2620 potilaan keuhko- ja rintasyöpäpotilaiden dataa käyttämällä luonnollisen kielen prosessointikykyä. CTM luki Novartiksen tarjoamat kliiniset tutkimusprotokollat ja arvioi potilastietueiden dataa ja lääkäreiden muistiinpanoja protokollia vastaan, jolloin järjestelmä kykeni sulkemaan terveet potilaat pois ja näin vähentäen virhediagnooseja -94 prosenttia potilaiden määrästä. (IBM, 2017)

Intialaisessa Bangalossa toimivassa Manipal Comprehensive Cancer Centressä, Watson kykeni löytämään edellä mainitun 96 % vastaavuusasteen syöpähoitosuosituksiin, 81 % paksusuolen ja 93 % peräsuolen syövissä. Thaimaan Bumrungrad International Hospital-sairaalassa vastaavuusaste oli 83 % ja Etelä-Koreassa paksusuolen syövissä 73 %. Meksikolaiset onkologit havaitsivat, että Watson for Oncology voi olla hyvin käyttökelpoinen potentiaalisten hoitovaihtoehtojen löytämiseksi potilaille, erityisesti klinikoilla, joista puuttuu alan erikoisosaamista ja lisäksi lääketieteen opiskelijoiden koulutuksessa. (IBM, 2017)


Uusimpana syövän hoidon aluevaltauksena Watson on alkanut auttamaan eturauhassyöpäpotilaita. Muita syöpätyyppejä, joiden hoitosuosituksia Watson for Oncology-ratkaisu kykenee antamaan, ovat rinta-, keuhko-, paksusuolen-, peräsuolen-, kohdunkaulan-, munasarja- sekä vatsa- ja eturauhassyöpä. Kuluvan vuoden 2017 loppuun mennessä tavoitteena on saada tuki 12 syöpätyypin hoidolle, joka kattaa jopa 80 % maailman syöpätapauksista. (IBM, 2017)

IBM:n Watson for Oncology on jo 55 sairaalan ja terveydenhuollon organisaation käytössä maailmanlaajuisesti. IBM on lisäksi julkistanut yhdeksän uutta organisaatiota, jotka ottavat käyttöön Watson for Oncology-tekniikoita ja käyttäjiä on tulossa yhä jatkuvasti lisää. Esimerkkinä on Baheal Pharmaceutical Group, joka solmi monivuotisen strategisen

kumppanuuden IBM:n kanssa Watson for Oncology-ratkaisun tuomiseksi Kiinan markkinoille. IBM:llä on lisäksi menossa erilaisia yhteistyöprojekteja, kuten pilottiprojekti Cotan ja Hackensack Meridian Healthin kanssa. Watson for Oncologya on hyödynnetty myös Afrikassa, jossa on kemoterapian hoitomuodoista pulaa, auttamaan terveydenhuollon henkilöstöä tarjoamaan luotettavampaa lääkintämuotoa halvemmilla kustannuksilla. IBM:n asiantuntijat ovat kehittäneet tähän tarkoitukseen CHemoQuant-ohjelmiston, joka auttaa suunnittelijoita ja hankintahenkilöstöä terveysministeriössä tuottamaan tarkempia kemoterapian ennusteita, tarkastamaan lääkitysvarastoja, selvittää saatavilla olevia toimittajia, määrittää kustannuksia ja tehdä lääkeainetilauksia, joita voidaan hyödyntää volyymihinnoittelun alennuksissa. (IBM, 2017)

3.5 Tekoäly ja pulmonologia

Maailman terveysjärjestön eli WHO:n mukaan kolme viidestä kuolemaan johtavasta syystä maailmassa ovat yhteyksissä keuhkojen toimintahäiriöihin. Keuhkokuume on johtava kuolinsyy alle viisi vuotiailla lapsilla postneonataalisessa vaiheessa. Yli 300 miljoonaa ihmistä kokevat, että heidän on vaikea hengittää kroonisista hengitysoireista. Kuviosta 36 ilmenevät suurimmat kuolinsyihin johtavat sairaudet maailmassa, joista keuhkosairauksilla on suuri osuus. Muita vaikuttavia kuolemaan johtavia sairauksia ovat Alzheimer, iskeemiset sydänsairaudet, halvaus ja ripulisairaudet. Epätodennäköisintä on kuolla liikenneonnettomuudessa tai saada tuberkuloosi, joihin ei löydy hoitokeinoja. (Binetskaya)



KUVIO 36. Johtavat kuolinsyyt maailmassa. (Binetskaya)

Tutkimusten mukaan tekoäly voi parantaa keuhkotestien tulkitsemista ja tekoälyalgoritmien hyödyntäminen keuhkosairauksien yhteydessä on antanut lupaavia tuloksia ja sen avulla ollaan päästy lähes ihmisten tehokkuuteen tappavien sairauksien diagnosoinnissa. Nykyään testit pääosin suoritetaan mittaamalla hengityksestä ulos virtaavan ilman määrää ja nopeutta

ja spirometria on eniten käytetty keuhkotesti. Sitä on usein seurannut pletysmografinen testi, jossa mitataan, kuinka paljon ilmaa potilas kykenee pitämään keuhkoissaan. Viimeisin on diffuusiotesti, joka mittaa kuinka hyvin keuhkot prosessoivat potilaan hengittämää ilmaa ja sallivat hapen ja hiilidioksidin kulkeutua verenkiertoon ja pois sieltä. (CyberPsychology, 2016)

Tekoäly ja koneoppimisen algoritmit ovat uusia innovatiivisia sovellusalueita, joita voidaan hyödyntää myös keuhkotestien suorittamisessa. Koneoppiminen käyttää hyväksi algoritmeja, jotka voivat oppia ja suorittaa ennustavan datan analytiikkaa. Tutkimustuloksina on esitetty, että tekoäly voi tarjota tarkempia diagnostiikan tapoja ja algoritmi voi simuloida monimutkaisia päättelyketjuja standardisoidummalla sekä objektiivisemmalla tavalla, joita terveydenhuollon ammattilaiset, kuten lääkärit käyttävät diagnosoidakseen sairauksia. (CyberPsychology, 2016)

3.5.1 Interstitiaalisten keuhkosairauksien CT-mallien luokittelu neuroverkkojen avulla

Interstitiaaliset keuhkosairaudet (Interstitial Lung Disease eli ILD) aiheuttavat keuhkokudoksien progressiivista arpeutumista, joka lopulta vaikuttaa potilaan kykyyn hengittää ja saada riittävästi happea verenkiertoon. Asianmukaisen diagnoosin ja hoitopäätöksen tekemiseksi on yleisesti käytetty korkearesoluutioista tietokonetomografiaa (High-Resolution Computer Tomography eli HRCT) radiologian kuvantamismenetelmänä, jotta normaalit ja epänormaalit kuvantamismallit voidaan visualisoida ja ILD:n tyyppi ja luonne voidaan tunnistaa. Edellä mainitun menettelyn toteuttaminen vaatii tietokoneavusteisen luokittelujärjestelmän hyödyntämistä, joka mahdollistaa epänormaalien kuvantamisessa ilmaantuvien mallien määrien ja anatomisten sijaintien määrittämisen, jotta radiologit voivat optimoida hoitopäätöksiään. (Gao ym., 2016)

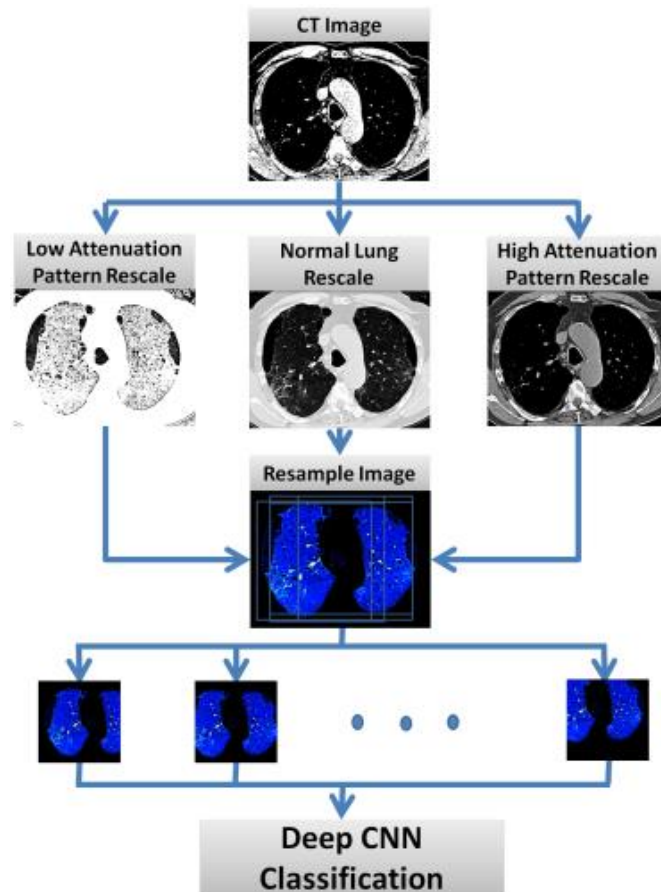
CT-kuvauksissa on todettu interstitiaalisilla keuhkosairauksilla olevan useita poikkeavia kuvantamisen malleja, joiden luokittelu on oleellista tarkassa kliinisessä päätöksenteossa, jotta sairauden laajuus ja luonne voidaan päätellä. Menettely on tärkeää kehitettäessä automattisia keuhkosairauksia tunnistavia tietokoneavusteisia tunnistusjärjestelmiä (Computer-aided Detection eli CAD). Tavanomaisesti menettely riippuu asiantuntijoiden manuaalisesta kiinnostuksen kohteena olevan alueen (Region of Interest eli ROI) tunnistamisesta edellytyksenä potentiaalisten sairauksien diagnosoimiseksi. Protokolla on aikaa vaativa ja estää automaattisen arvioinnin. (Gao ym., 2016)

Tutkimusryhmä on kehittänyt algoritmin, joka hyödyntää syviä konvoluutioneuroverkkoja luokittelemaan ILD-kuvantamismalleja CT-kuvista. Algoritmi käyttää koko CT-kuvaa holistisena syötteenä. Aiemmin kuvasyötteet ovat olleet resoluutioltaan liian pieniä (31 x 31 kuvapikseliä), jolloin kaikki yksityiskohdat eivät ole välittyneet oikein. Holistinen CT-kuva sisältää huomattavasti enemmän informaatiota, joka auttaa hoitopäätösten teossa. Manuaalista ROI:ta hyödyntävät kuvantamisen ratkaisut voivat olla helpompia hyödynnettäviä, mutta ne ovat työläitä ja vaativat ihmisen työpanosta, joten ne eivät ole

käyttökelpoisia suuren mittakaavan lääketieteellisessä kuvantamisprosessissa ja analyysissa. (Gao ym., 2016)

Konvoluutioneuroverkkoja (CNN) on onnistuneesti hyödynnetty erilaisissa luokitteluongelmissa ja ne ovat saavuttaneet uusimman teknologian suorituskyvyn kuvien luokittelussa, tunnistamisessa ja segmentoinnin haasteissa (kuten esimerkiksi ImageNet). Tyypillinen kuvan luokittelun lähestymistapa koostuu kahdesta askeleesta, jotka ovat ominaispiirteiden poimiminen ja luokittelu, joita CNN-verkot kykenevät oppimaan samanaikaisesti. CNN-verkot vaikuttavat lupaavilta lääketieteellisissä kuva-analyysisovelluksissa, kuten mitoosin, imusolmukkeiden kyhmyjen tai polvien ruston segmentoitumisen tunnistamisessa. (Gao ym., 2016)

Tutkimusryhmä muodosti aiheesta mallin (Kuvio 37), jossa CT-kuva uudelleen skaalattiin Hounsfieldin yksiköitä käyttäen 2-ulotteisiksi syötteiksi. Skaalauksessa muodostui kolme eri kuvaa: vähemmän vaimennettu (low attenuation pattern rescale), normaali (normal lung resale) ja enemmän vaimennettu (high attenuation pattern rescale) uudelleen skaalaus. Käyttämällä kolmea vaimennusaluetta on mahdollista saavuttaa parempi näkyvyys tai visuaalinen erottuvuus kaikissa kuudessa ILD-sairauksien kategorioissa. Lisäksi muun muassa ImageNet käyttää RGB-väriavaruutta, jossa on kolme eri väriä, joka on yksi syy kolmen eri alueen käyttämiseen. Lopuksi jokaisesta 2D-kuvasta otetaan satunnaisesti 10 näytettä rajaamalla ja niiden resoluutio muutetaan 224 x 244 pikseliin käyttämällä lineaarista interpolointia. Vaikka generoidut kuvat ovatkin toisistaan riippuvaisia, menettely parantaa opettamisen/testaamisen suorituskykyä 5 % luokittelussa. (Gao ym., 2016)



KUVIO 37. CNN-neuroverkkomalli interstiaalisen keuhkosairauden luokitteluun. (Gao ym. 2016)

Julkisesti on saatavilla ILD-tietokanta, joka parantaa keuhkojen epänormaalien kuvantamisen mallien tunnistamista ja luokittelua. Tietokanta sisältää 120 HRCT skannattua kuvaa 512 x 512 tarkkuudella, jossa 17 keuhkokudoksen tyyppiä on merkittyjä alueita (esimerkiksi ROI). Useimmat luokittelumetodit, joilla ILD-aineistoa on arvioitu poimivat ROI:sta useita näytteitä ja luokittelevat ne viiteen keuhkokudosluokkaan, jotka ovat: normaali (NM), keuhkolaajentuma (EM), mattalasimuutos (GG), fibroosi (FB) ja mikronoduuli (MN). Tutkijaryhmän mallissa otettiin huomioon myös konsolidaatio (CD), joka on vallitsevana tyyppinä ILD:ssä. Kaikki kuusi sairautta on vallitsevia ILD-sairauksien ominaisuuksia ja niiden tunnistaminen on kriittistä niiden ILD-tyyppien määrittämisessä. Tietokanta sisältää 120 potilaan sairastaman ILD-sairauden 2084 ROI-alueita, jotka on merkitty tietyn ILD-sairauden tyyppin mukaan. Kaikki potilaat on satunnaisesti jaettu kahteen alijoukkoon potilaan harjoitustason (100 potilasta) ja testauksen (20 potilasta) mukaan. Harjoitus/testausdata on erotettu potilastasolla eli saman potilaan data ei ole sekä harjoituksen että testauksen yhteydessä. Kaikki kuvat, jotka sisältävät kuusi sairauden tyyppiä valitaan, jolloin muodostuu yhteensä 1689 kuvaa harjoitusta ja testausta varten. (Gao ym., 2016)

Kuviosta 38 ilmenee, että keuhkolaajentuma voidaan täydellisesti luokitella muista sairauksista. Normaalit (terveet) ja mikronoduulia koskevat CT-kuvat ovat vaikeita erottaa muista sairauksista perustuen ILD-luokittelumatriisin tuloksiin. Mikronoduulikuviot ovat

visuaalisesti haastavia tunnistaa yhdestä staattisesta CT-kuvasta, jolloin mahdollisesti 3D-ristikuvantamisen ominaisuuksia voidaan tarvita. Fibroosi ja mattalasimuutos erottuvat myös melko hyvin muista taudinkuvista. Korjatussa (patched) ILD-matriisissa (Kuvio 39) tulokset ovat paremmat, jolloin CD on eliminoitu matriisista ja muut keuhkosairaudet erottuvat toisistaan hyvin suurella todennäköisyydellä. Tutkijaryhmän käyttämä malli implementoitiin Matlab-ympäristössä käyttäen MatConvNet-pakettia CNN-konvoluutioneuroverkon implementointiin. Laitteistona oli PC-tietokone, 3.10 GHz kaksiydinprosessorilla varustettuna ja 32 GB RAM-muistia. CNN-mallin opettaminen kesti 20 – 24 tuntia, jolloin uuden testikuvan luokittelu vie vain muutamia sekunteja.

Ground Truth	Prediction					
	EM	FB	GG	NM	MN	CD
EM	1	0	0	0	0	0
FB	0	0.7111	0.0889	0.0667	0	0.1333
GG	0	0	0.9375	0.0625	0	0
NM	0	0	0	0.5	0.5	0
MN	0	0	0	0.4615	0.5385	0
CD	0	0.2	0.3333	0	0	0.4667

KUVIO 38. ILD-luokittelumatriisi. (Gao ym. 2016)

Ground Truth	Prediction				
	EM	FB	GG	NM	MN
EM	0.9142	0.0078	0.0237	0.0047	0.0495
FB	0.0546	0.8270	0.0075	0.0464	0.0646
GG	0.0558	0.0025	0.8151	0.0930	0.0337
NM	0.0141	0.0108	0.0494	0.8910	0.0348
MN	0.0600	0.0070	0.0262	0.0268	0.8799

KUVIO 39. ILD-luokittelumatriisi (korjattu). (Gao ym. 2016)

3.5.2 Tekoälyn hyödyntäminen keuhkotoimintotestien diagnosoinnissa

Tekoäly voi auttaa parantamaan keuhkotoimintojen testejä pitkäaikaisten keuhkosairauksien diagnosoimiseksi. Euroopan Respiratory Society'n kansainvälinen kongressi on ensimmäinen, joka tutkii tekoälyn käyttöä keuhkosairauksien diagnosoimisen tarkkuuden parantamiseksi. Nykyiset testit vaativat useampien erilaisten metodien käyttöä, kuten spirometriatesti, joka mittaa keuhkoista virtaavan ilman määrää ja nopeutta sekä kehon pletysmografiatesti, joka mittaa staattista keuhkojen kokoa ja ilmanvastusta, ja diffuusiotesti, joka mittaa ilman ja muiden kaasujen määrää, jotka ohittavat keuhkojen ilmapussit. Näiden tuloksien analysointi perustuu paljolti asiantuntijamielipiteisiin ja kansainvälisiin ohjeistuksiin yrittäessään havaita malleja löydöksistä. (European Lung Foundation, 2016)

Tutkijat tutkivat 968 ihmistä, jotka kävivät ensimmäistä kertaa lävitse täydellistä keuhkotoimintotestiä. Kaikki osallistujat saivat ensimmäisen kliinisen diagnoosin perustuen keuhkotoimintotestiin ja muihin tarpeellisiin testeihin, kuten CT-kuvaukset ja EKG jne.

Lopullinen diagnoosi validoitiin yhteistyössä suuren lääketieteen asiantuntijajoukon kanssa. Tutkijat tarkastelivat, voisiko koneoppiminen auttaa analysoimaan täydellisen keuhkotoimintotestin tuloksia. (European Lung Foundation, 2016)

Tutkimusryhmä kehitti algoritmin rutiinien keuhkotoimintoparametrien ja kliinisten muuttujien (tupakointihistoria, BMI ja ikä) lisäksi. Algoritmi käyttää hyväkseen molempien, kliinisten- ja keuhkotoimintoparametrien dataa tehden ehdotuksia todennäköiseksi diagnoosiksi. Tekoälyn avulla on mahdollista saavuttaa tarkempia diagnosointituloksia ja sopiva tekoälyalgoritmi voi myös simuloida monimutkaista päättelyä, jota lääketieteen ammattilainen käyttää muodostaessaan diagnoosia, tosin standardoidulla ja objektiivisellä tavalla, joka vähentää puolueellisuutta. (European Lung Foundation, 2016)

Lääketieteen ammattilaisten täytyy luottaa tulosten analysointiin käyttäen väestöperusteisia parametreja. Tekoälyn avulla, kone voi tarkkailla mallien yhdistelmää yhtäaikaaisesti, jotta tarkempi diagnoosi mahdollistuu. Tämänkaltaista menettelytapaa on jo käytetty muilla terveydenhuollon sektoreilla, jossa automaattinen tulosten tulkitseminen EKG-laitteiden mittaustuloksista on rutiininomaisesti käytetty kliinisenä käytänteenä päätöksentuen järjestelmissä. Tämänkaltaisen menettelytapa tarjoaa tarkemman ja automaattisen keuhkotoimintojen testien tulkitsemisen sekä paremman sairauksien tunnistamisen. Menetelmä auttaa säästämään aikaa lopullisen diagnoosin saamiseksi ja se voi myös vähentää säännöllisten lisätestien määrää, joita on tarvittu varmistamaan diagnoosi. (European Lung Foundation, 2016)

3.5.3 Tekoälyä hyödyntävä ennakoiva järjestelmä pediatriksen astman diagnosointiin

Astmaoireiden ilmaantuessa henkilön hengitystiet turpoavat ja kapenevat, jolloin hengittäminen vaikeutuu. Astma vaikuttaa 1 – 2 lapseen kymmenestä ja se alkaa usein kehittyä lapsilla ennen viidettä ikävuotta. Sairaus on hyvin vaikea diagnosoida nuorella iällä ja oireet eri lapsilla voivat olla myös erilaisia. Lisäksi oireet saattavat vaihdella samallakin lapsella aina jaksoittain. Lapsilla iältään 0 - 17 vuotiaat, on korkeampi astman esiintyvyys (9.5 %) aikuisilla sen ollessa jonkin verran matalampi (7.7 %). Naisilla astman esiintyvyys on suurempi kuin miehillä ja eroa miehiin on 2.2 % yksikköä. (Rajan ym., 2017)

Astman diagnosoinnista tekee vaikeaa astman oireiden kaltaiset virustaudit, joita he voivat sairastaa. Lapsen täyttäessä viisi vuotta, hän voi käydä spirometritestissä, jotta keuhkojen toiminnot voidaan testata. Yli viisi vuotiaille on olemassa myös uloshengitysilman typpioksiditesti, joka antaa viitteitä hengitysteiden tulehduksista. Lapsilla, jotka eivät kykene suorittamaan muita keuhkotestejä, voidaan toteuttaa impulssioskillometria, joka mittaa hengitysilman resistanssia. Edellä mainitut testit ovat yleisesti käytettyjä testejä keuhkosairauksien diagnosointiin ja niitä käytetään harvemmin muutoin. Useimmiten suurin osa nuorista lapsista diagnosoidaan historialliseen dataan perustuen. (Rajan ym., 2017)

Datan määrän kasvaessa suhteellisesti populaatioon verrattuna on tärkeää, tietämyksen louhiminen datan joukosta tulee yhä oleellisemmaksi. Tiedonlouhinta (Data Mining) astuu kuvaan tässä yhteydessä ja sen hyödyntäminen terveydenhuollon alueella on kasvussa. Tiedonlouhinta on prosessi, jossa historiallista dataa seulotaan, jolloin voidaan löytää malleja suurista datajoukoista, jolloin niitä voidaan hyödyntää jokapäiväisessä elämässä. Tutkijoiden mukaan tiedonlouhinnan tekniikoiden soveltaminen sairauden tehokkaan esidiagnoosin tekemisessä voi parantaa lääkäreiden suorituskykyä. Esimerkiksi keuhkosyövän diagnoosissa historiallisen datan tutkiminen voi auttaa sen aikaisen vaiheen tunnistamisessa, jolloin sairauden hoito mahdollistuu, ennen kuin tila pahenee. (Rajan ym., 2017)

Testataksaan tiedonlouhinta hyödyntävää mallia pediatriksen astman diagnosoinnissa, he keräsivät kyselyin lapsipotilaiden sairaalajakson aikana 70 tietueen verran dataa, jotka sisälsivät potilaiden historiatietoja ja ennakoivaa informaatiota. Tietueet muodostuivat sekä astmapotilaista että astmaa sairastamattomista potilaista. 70 tietueesta 40 käytettiin opetukselliseen tarkoitukseen ja 30 jäi testijoukoksi. (Rajan ym., 2017)

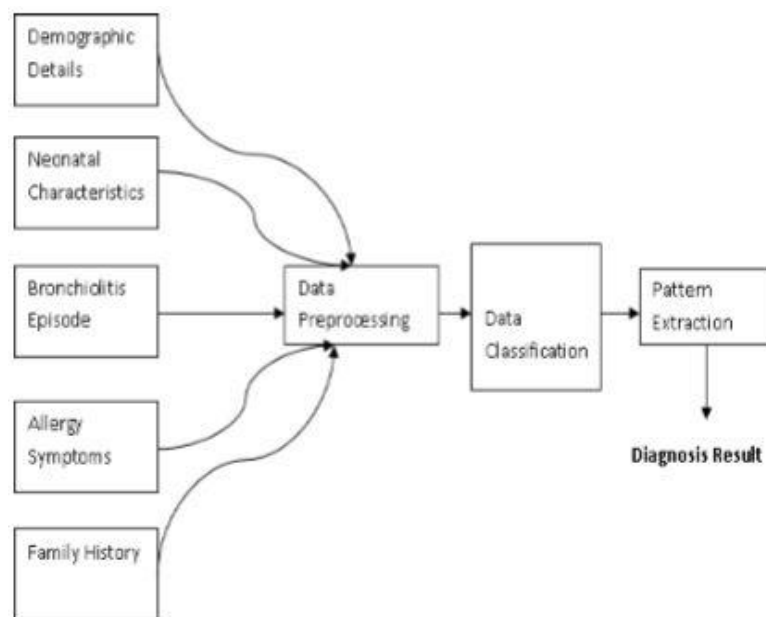
Ennakoivia tekijöitä kysymyksissä olivat muun muassa:

- Ihottuma (ekseema)
- Ikä
- Passiivinen tupakointi
- Perheen historia astman suhteen
- Raskauden kesto
- Ruoka-allergia
- Sukupuoli
- Taloudellinen tilanne
- Äidin tupakoinnin yleisyys

Tutkijat tunnistivat ja listasivat ennakoivat tekijät sekä taulukoivat. Kuviossa 40 esiintyvässä taulukossa tekijät on numeroitu ja kategorioitu. Kategoriat ovat demografiset tekijät, vastasyntyneiden ominaisuudet, bronkioliittijaksot, allergiaoireet ja perhehistoria. Tutkijat käyttivät mallin luomisessa BP-neuroverkkoa. Verkko oppii käyttäen opetukselliseen tarkoitukseen jätettyjä tietueita aina saturaatiopisteeseen saakka. Verkon oppimaa mallia voidaan käyttää luokittelemaan testidataa ja lopullista mallia voivat terveydenhuollon ammattilaiset ja lääkärit hyödyntävät analysoidessaan potilaiden hoitoja. (Rajan ym., 2017) Kuviossa 41 havainnollistuu kyseisen mallin prosessin arkkitehtuuri.

S. No.	Category	Prognostic Factor
1	Demographic Details	Age, Sex, Height, Weight
2	Neonatal Characteristics	Birth weight, Pregnancy duration, Mother smoking during pregnancy, Breast fed, Exposure to second hand smoke during pregnancy
3	Bronchiolitis Episodes	Frequency of Respiratory Infection, Frequency of cold and cough, Frequency of Wheeze
4	Allergy Symptoms	Food allergy, Eczema, Pharmaceutical allergy
5	Family History	Family history of asthma, Presence of asthma in mother, Presence of asthma in father.

KUVIO 40. Ennustavat tekijät opetusprosessissa. (Rajan ym. 2017)



KUVIO 41. Pediatriksen astman diagnosoinnin ennustemalli. (Rajan ym. 2017)

BP-neuroverkon toteutus pediatriksen astman datajoukossa suoritettiin Matlab-ympäristössä. Pediatriksen astman datajoukko koostui 70 potilastietueesta, joissa jokaisessa oli 12 attribuuttia. Puuttuvan datan täyttämiseksi käytettiin keskiarvoja. Kyseessä olevassa BP-neuroverkossa jokainen solmu (node) edustaa aina yhtä attribuuttia ja potilasinformaatio syötettiin verkolle tavalla, jossa jokainen ominaisuus laskee sijaintinsa vastaavaan solmuun. Verkon oppiminen lakkaa vasta saturaatiopisteessä ja lisäksi varmistetaan, ettei oppiminen lakkaa lokaalissa minimissä. Seuraavaksi lasketaan virhearvot ja ne lähetetään takaisin verkolle ja painoarvot säädetään siten, että yleinen virhe voidaan minimoida. (Rajan ym., 2017)

Tutkijat havaitsivat, että BP-neuroverkolle syötteenä annetuista potilastietueista ne, joilla oli suurin painoarvo, esiintyi perheen historiatiedoissa astmaa ja tähän altistavana tekijänä passiivinen tupakointi raskauden aikana. Malli suorittaa binaarisen luokittelun, johon kuuluvat positiivinen pediatriinen astma ja lyhytaikainen allergia. Tutkimusryhmän opettaessa verkkoa 40 sekunnin ajan ja käyttäen sitä 30 testitietueeseen, luokittelutulos nousi 100 %:iin, jolloin mallin käyttäminen terveydenhuollon ammattilaisten esi-diagnostiikkatyökaluna on perusteltua. (Rajan ym., 2017)

3.5.4 Tuberkuloosin diagnosointi tekoälyn avulla

WHO:n (World Health Organization) eli maailman terveysorganisaation mukaan tuberkuloosi on yksi 10 kuoleman aiheuttavasta sairaudesta maailmassa. Vuonna 2016 arviolta 10.4 miljoonaa ihmistä sairastui tautiin, joka aiheutti 1.8 miljoonaa ihmisen kuoleman. Tuberkuloosi voidaan diagnosoida kuvaamalla rintakehä, tosin yleensä tuberkuloosin esiintymisalueilla taudin diagnosoinnin asiantuntijuudesta on pulaa. Tekoäly ja sen soveltaminen tuberkuloosin diagnosoinnissa röntgenkuvista on tullut tarpeelliseksi alueilla, joissa on pulaa radiologeista. Tekoälyratkaisun avulla voidaan radiologeille toimittaa tietoa tuberkuloosin esiintymisestä, jolloin se voidaan hoitaa ja tunnistaa kustannustehokkaasti kehitysmaissa. (Lakhani, 2017)

Syväoppiminen (Deep Learning) on yksi tekoälyn muoto, joka mahdollistaa tietokoneille suorittaa tehtäviä, jotka perustuvat jo olemassa oleviin datan välisiin suhteisiin. Konvoluutiollinen syvä neuroverkko (Deep Convolutional Neural Network eli DCNN) koostuu useista piilossa olevista kerroksista ja malleista, jotka luokittelevat kuvia. Testejä tehtiin kahdella erilaisella DCNN-verkolla, jotka ovat AlexNet ja GoogLeNet, jotka oppivat tuberkuloosin suhteen positiivisista ja negatiivisista röntgenkuvista. (Lakhani, 2017)

Mallien tarkkuutta testattiin 150 tapauksella. Toimivin tekoälymalli oli AlexNetin ja GoogLeNetin yhdistelmä, jonka tarkkuus oli peräti 96 %. Kahdella DCNN-mallilla oli eroja 13 tapauksessa 150:stä. Radiologin diagnosointitarkkuus oli näissä tapauksissa 100 %. Aiemmin koneoppimisen avulla kyettiin saamaan vain 80 % tuloksia, mutta käyttäen syväoppimista potentiaali tarkkuuden suhteen on suurempi. Tekoäly tuberkuloosin diagnosoinnissa voi olla hyvin merkittävä asia tulevaisuuden taistelussa taudin voittamiseksi. (Lakhani, 2017)

3.6 Tekoälyn hyödyntäminen muissa sairauksien diagnosoinneissa

Aiemmin tässä raportissa viiteen kategoriaan jaoteltujen sairauksien lisäksi tekoälyä voidaan hyödyntää diagnosoinneissa myös muilla lääketieteen alueilla, kuten esimerkiksi mielenterveys, josta tässä raportissa käsitellään vaikeaa mielenterveydellistä sairautta, skitsofreniaa, jonka diagnosointiin tekoälyä voidaan hyödyntää. Raportissa esitellään myös tekoälyä hyödyntävä HIKARI-alusta, jota voidaan hyödyntää mielenterveyden sairauksien riskitekijöiden diagnosoinneissa. Tekoälyä voidaan käyttää apuna myös silmäsairauksien, kuten synnyntäisen kaihin diagnosoinnissa. Mielenkiintoinen tekoälyä hyödyntävä

innovaatio, jota tässä raportissa käsitellään, on tekoälyä hyödyntävä nanotekninen puhalluslaite, jota voidaan käyttää hyvin monen sairauden diagnosoinnissa, kuten Chronin tauti, parkinsonismi, eturauhassyöpä, haavainen koliitti, keuhkosyöpä, mahasyöpä jne.

Tekoälyä voidaan hyödyntää myös henkilökohtaisena terveysapulaisena, jota hyödyntäen potilaat voivat tehdä kotidiagnoseja. Tässä raportissa esitellään mobiililaitteille toteutettu tekoäly ja koneoppimista sekä kansallisen terveyspalvelun (NHS) dataa hyödyntävä henkilökohtainen älykäs terveysapulainen, Your.MD-sovellus, jonka avulla kotidiagnoseja voidaan tehdä. Sovelluksesta voi olla apua, mikäli perusterveydenhuollon tarjoamat palvelut eivät ole lähellä tai ei muuten ole pääsyä lääkärin tai muun terveydenhuollon ammattilaisen vastaanotolle.

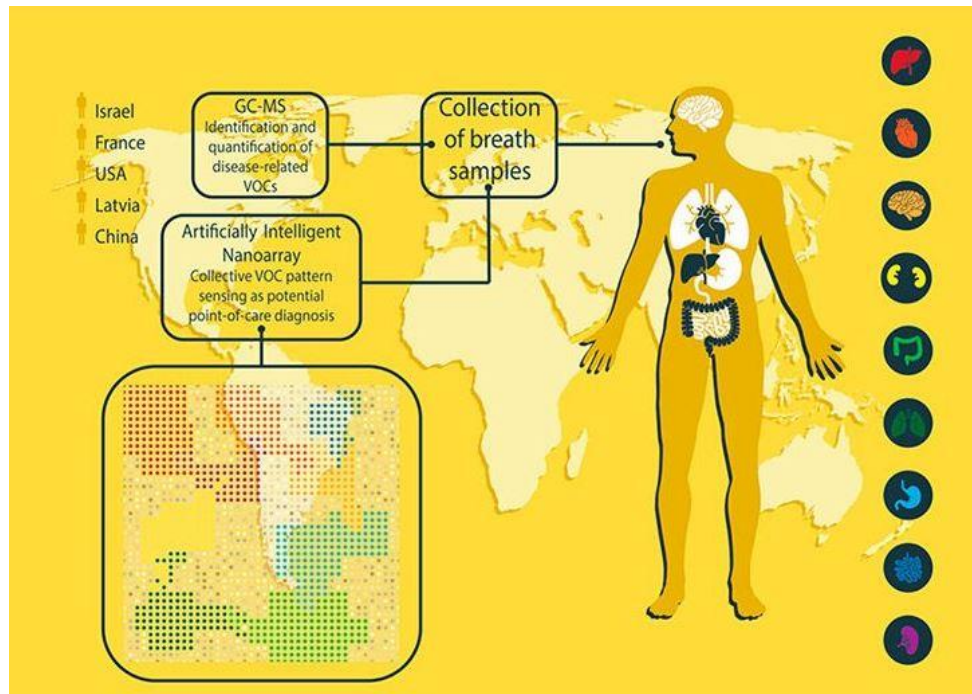
Tässä luvussa esitellyt diagnosointeihin tarkoitetut ratkaisut ja sovellukset ovat vain kursorinen tutustuminen tekoälyn mahdollisuuksiin sairauksien diagnosoinneissa ja muussa hyödyntämisessä lääketieteen alueella mahdollisuuksien kasvaessa jatkuvasti tekoälyalgoritmien sekä tietojenkäsittelyn ja prosessointikapasiteetin kehittyessä. Vaikka tekoäly on suhteellisen vanha käsite, sen kehitystaso on silti vielä vasta alkuvaiheessa ja se on pääsemässä vauhtiin viimeisimpien syväoppimisen läpimurtojen ja teknologisen kehityksen myötä. Tulevaisuudessa tullaan näkemään varmasti hyvin innovatiivisia ratkaisuja koskien tekoälyn hyödyntämisessä sairauksien diagnosoinnissa sekä hoitosuosituksen tarjoamisessa ja kenties jopa hoitopäätöksen tekemisessä.

3.6.1 Nanotekninen puhalluslaite hyödyntää tekoälyä sairauksien diagnosoinnissa

Uudenlainen nanoteknologiaan perustuva puhalluslaite auttaa haistamaan puhalluksesta ja diagnosoimaan erilaisia sairauksia. Tutkimuksessa näytteitä kerättiin 1404 koehenkilöltä, joiden joukosta voitiin löytää 17 erilaista sairautta käyttäen puhalluslaitetta. Diagnosointitarkkuus oli 86 % luokkaa ja voitiin saavuttaa tekoälyä hyödyntävällä nanoteknologisella puhalluslaitteella, joka mahdollisti erilaisten sairauksien diagnoosin ja erottelun toisistaan. Nanoteknisen laitteen analysoiminen osoitti, että jokaisella sairaudella on oma uniikki ”hengitysjälki” (Breathprint), jolloin yhden sairauden diagnoosi ei nosta esille muita sairauksia, ellei siihen ole aihetta. (Nakhleh ym., 2016)

Hengitys sisältää happea, hiilidioksidia ja typpeä sekä sen lisäksi 100 muuta haihtuvaa kemiallista komponenttia (Volatile Chemical Components eli VOC). VOC-komponenttien haihtuminen riippuu henkilön suhteellisesta terveydentilasta. Entisaikaan eli noin 2000 vuotta sitten lääkärit (kuten Hippocrates) saattoivat käyttää hajuaistia sairauden diagnosoinnissa, sillä hengitys sisältää VOC-komponentteja, jotka ovat yhteyksissä erilaisten sairauksien olemassaoloon. Aiemmin sairauksia ei ole voitu diagnosoida modernein teknologisin menetelmin, kuten nykyään lääketieteen, tekoälyn ja nanoteknologian kehittyessä. (Nakhleh ym., 2016)

Kuviosta 42 selviää nanoteknologiaan perustuvan puhalluslaitteen toiminta. Laite kerää VOC-komponenttinäytteitä henkäyksestä ja suorittaa sairauksien määrittämisen (kvantifiointi) ja tunnistuksen. Tekoälyalgoritmeihin perustuvan sovelluksen avulla diagnosointi voidaan tehdä ja jakaa sairaudet luokkiin. Tutkimusryhmän suorittamassa kokeellisessa tutkimuksessa oli mukana viisi maata, jotka olivat Israel, Ranska, USA, Latvia ja Kiina.




KUVIO 42. Nanoteknologiaan perustuvan puhalluslaitteen toimintaperiaate. (Nakhleh ym. 2016)

Tutkimuksen 1404 koehenkilöltä diagnosoitiin 17 sairautta, jotka olivat:

- Chronin tauti (Crohn's Disease)
- Epätypillinen Parkinsonismi (Atypical Parkinsonism)
- Eturauhassyöpä (Prostate Cancer)
- Haavainen koliitti (Ulcerative Colitis)
- Idiopaattinen Parkinsonin tauti (Idiopathic Parkinson's Disease)
- Keuhkosityöpä (Lung Cancer)
- Keuhkoverenpainetauti (Pulmonary Arterial Hypertension)
- Krooninen munuaissairaus (Chronic Kidney Disease)
- Mahasyöpä (Gastric Cancer)
- Multippeli Skleroosi (Multiple Sclerosis)
- Munasarjan syöpä (Ovarian Cancer)
- Munuaissyöpä (Kidney Cancer)
- Paksusuolen syöpä (Colorectal Cancer)
- Pää- ja niskasyöpä (Head and Neck Cancer)
- Raskausmyrkytys (Pre-eclampsia)
- Virtsarakon syöpä (Bladder Cancer)
- Ärtävän suolen oireyhtymä (Irritable Bowel Syndrome)

Jokaisella sairaudella on oma ainutlaatuinen kemiallinen piirustus, joka perustuu eri määriin 13 komponentista, jotka tunnistettiin massaspektrometrin avulla. Tunnistus on niin täsmällinen, ettei yksi sairaus estä toisten sairauksien diagnosointia. Teknologia esittelee käytännönläheisen tavan seuloa ja diagnosoida erilaisia sairauksia ei-häiritsevällä, halvalla ja myös kannettavalla tavalla. (Nakhleh ym., 2016)

Kuvio 43 ilmentää, että jokainen kuvion laatikko edustaa sokealla valinnalla valittua kohderyhmien paria. Vasemmalla puolella oleva lämpökartta antaa tuloksia potilasryhmien vertailujen tuloksista. Graafi oikealla puolella antaa tuloksia samoista luokittelijoista, joita sovellettiin vastaaville kontrolliryhmille. Keskimääräinen tarkkuus oli 86 % kaikille luokittelijoille (vasen graafi) ja 58 % oikealla puolella oleville ryhmille.



KUVIO 43. Graafinen esitys sairauksien todennäköisyyksistä. (Nakhleh ym. 2016)

3.6.2 Tekoälyä hyödyntävä HIKARI-rajapinta kliinisen päätöksenteon parantamiseen

Fujitsu on kehittänyt tekoälyä hyödyntävän terveydenhuollon HIKARI-rajapinnan (API), joka parantaa kliinistä päätöksentekoa sekä tarkkaa riskien arviointia potilaille. Ennen julkaisemista, terveydenhuollon ratkaisua koekäytettiin kenttäkokeissa San Carlosin kliinisessä sairaalassa Madridissa. San Carlosin kliininen sairaala (HCSC) on etsinyt ratkaisuja hoidon, opetuksen ja tutkimuksen parantamiseen jo vuodesta 1787 saakka, jolloin se perutettiin. Sairaala on onnistunut tyydyttämään Madridin alueen asukkaiden terveydenhuollon kysynnän ja sen korkealuokkaiset laitokset ja henkilökunta on tehnyt sairaalasta kansallisesti ja myös kansainvälisesti korkealuokkaisen sairaalan. HCSC-sairaala tukee ja mahdollistaa uusien ideoiden jalostamista tuotteiksi ja palveluiksi, jotka tarjoavat lisäarvoa potilaille, henkilökunnalle ja koko sairaalajärjestelmälle. (Fujitsu)

Perinteisissä sairaalaympäristöissä on usein valtava määrä dokumentteja paperimuodossa, joita on kerätty useita vuosia, ellei jopa pidempään. Paperimuotoinen arkistodata on vaikea systematisoida, paikallistaa ja tulkita. Digitaalisen kliinisen historiaprofiilin muodostaminen

potilaista on merkittävä prosessi, joka helpottaa datan analysointia tarjoamalla informaatiota helposti luettavassa muodossa, johon pääsy on keskitettyä. Nykyisin sairaaloissa on myös digitaalisia potilastietojärjestelmiä, mutta silti päivittäisen kerätyn informaation käyttö on vajaakäytöllä. Periaatteessa lääketieteen asiantuntijoilla on pääsy valtavaan määrään dataa, mutta relevantin informaation hyödyntäminen, joka parantaa hoidon laatua, on vaikeaa. (Aguilar, 2017)

Ratkaistakseen ongelman, Fujitsu lähestyi vuonna 2014 HCSC-sairaala ja esitteli sairaalan lääketieteen ammattilaisille työkaluja, joita Fujitsun innovointiin ja data-analyysiin erikoistunut tutkimusryhmä oli työstänyt. Työkalut oli toteutettu käyttäen avointa formaattia ja lisäksi oli mahdollisuus esittää kysymyksiä ja analysoida, jos Fujitsu voi auttaa vastaamaan niihin. Sittemmin Fujitsu ja HCSC-sairaala solmivat yhteistyösopimuksen kehittääkseen tekoälyä hyödyntävän HIKARI-rajapinnan, jonka tarkoitus oli avustaa kliinisen päätöksenteon parantamisessa. (Aguilar, 2017)

HIKARI, joka tarkoittaa Japaniksi valoa, kehitettiin yhteistyössä Fujitsun Euroopan laborion, Espanjan yksikön ja HCSC:n Madridin innovaatio yksikön kanssa. Ihmiskeskeinen järjestelmä auttaa lääkäreitä käsittelemään integroitua, ryhmiteltyä ja anonyymiä dataa, jota on vastaanotettu kliinisistä ja ei-kliinisistä lähteistä. HIKARI on uudenlainen kehittynyt kliininen tutkimustietojärjestelmä, joka tuo yhteen joukon mikropalveluita, jotka mahdollistavat relevantin informaation haun ja analyysien tekemisen lääkäreille käyttämällä useita datalähteitä, jotka liittyvät potilaiden terveysasioihin. Alusta tarjoaa perusteellisen tutkimusmahdollisuuden ja lisäksi mahdollisuuden hyödyntää kehittyntä data-analytiikkaa terveydenhuoltosektorilla. (Aguilar, 2017)

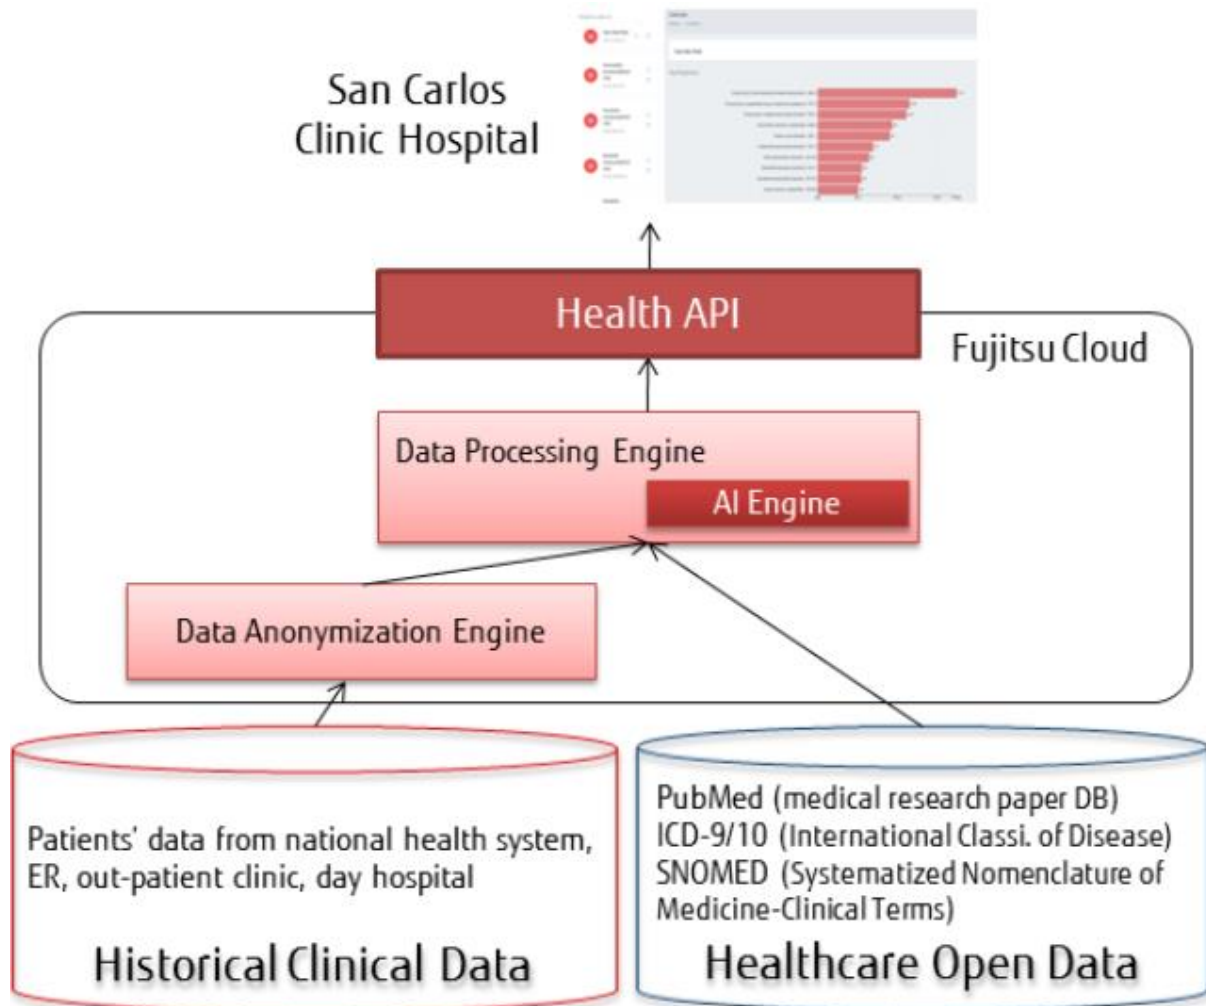
HIKARI:n kehittäminen yhteistyössä Fujitsun kanssa auttaa löytämään uusia tapoja kliinisiin päätöksentekoprosesseihin ja tulevaisuudessa tämän innovaation API-rajapinta tarjoaa terveydenhuollon henkilöstölle suoran pääsyn integroituun ja koottuun dataan, joka on kerätty kliinisistä ja ei-kliinisistä datalähteistä. Aiemmin tämä informaatio oli saatavilla ainoastaan paperimuodossa, joka ei ole niin helposti hyödynnettävissä. Kenttäkokeet osoittivat, että ratkaisu voi enemmän kuin puolittaa potilasrekistereiden suhteen käytetyn ajan, jolloin enemmän aikaa jää potilastyöskentelyyn. (Fujitsu)

Fujitsu ja HCSC-sairaala suorittivat kenttäkokeita 36 000 anonymisoidun potilastietueen avulla, kuuden kuukauden ajanjakson aikana ja mukana oli kokeneita mentaalisairauksiin erikoistuneita lääketieteen ammattilaisia. Fujitsu käytti tätä tietokantaa kehittäessään edistynyttä kliinistä tutkimustietojärjestelmää (Advanced Clinical Research Information System), jonka kehittämisessä käytettiin hyväksi Fujitsun asiantuntemusta tekoälyn, data-analytiikan ja semanttisen mallintamisen alueella. Kenttäkokeiden aikana jokainen lääketieteen ammattilainen tarkasteli tilanteita, jotka olivat yhteyksissä varsinaisen diagnoosin, sairauksien yhteisesiintymisen, potentiaalisen itsemurhariskin, alkoholin

väärinkäytön ja aiemmin tapahtuneen potilaiden sairaanhoitojärjestelmän käytön kanssa. Fujitsun järjestelmän todettiin toimivan hyvin tarkasti riskien arvioinnissa käyttäen kliinistä dataa ja tunnistamalla jo olemassa olevia kliinisiä ongelmia. Järjestelmää käyttämällä kyettiin pääsemään jopa 85 % tarkkuuteen tunnistettaessa itsemurhan tai alkoholin- ja huumeiden käytön riskejä. (Fujitsu)

Määritettäessä sopivaa hoitoa potilaalle, on tärkeää ymmärtää potilaaseen kohdistuvia potentiaalisia terveysriskejä. Tähän kuuluu potilaan lääketieteellisen historian ja nykyisen tilanteen arviointi sekä riittävä terveysriskien ja diagnoosien arvioinnit. Kyseisenlaisia kriittisiä toimenpiteitä suorittavat päivittäin yli 250 000 terveydenhuollon ammattilaista Espanjassa. Kyky integroida informaatiota eri osastoista, kuten esimerkiksi ensiapu tai mielenterveysosasto antaa välittömän kokonaiskuvan. Aikaa toimenpiteeseen kuluu vain sekunteja, verrattuna aiempiin tuntien käyttämiseen, joka antaa lääkäreille enemmän aikaa hoitaa potilaita. HIKARI-järjestelmä muuntaa toisinaan tietynlaista ”kohinaa” sisältävän ja erilaisissa sairaalan osastoissa olevan siiloutuneen raakadatan selkeäksi ja ymmärrettäväksi tietämykseksi, jota voidaan käyttää kliiniseen päätöksen tekemiseen uudella innovatiivisella tavalla. Se auttaa lääketieteen ammattilaisia tekemään tutkimusta tehokkaammalla tavalla, parantamalla hoitoprosessin lopputulosta ja tarjoamalla enemmän aikaa potilastyöhön. HIKARI tarjoaa myös hallinnollisia hyötyjä auttamalla ymmärtämään kuinka erilaiset resurssit ja käytänteet vaikuttavat potilaiden hoidossa. (Fujitsu)

Kuviosta 44 ilmenee HIKARI-järjestelmän toiminta. Potilasdataa kerätään kansallisesta terveydenhuollon järjestelmästä, digitaalisista potilastietueista tai muista terveydenhuollon palveluita tarjoavista keskuksista. Terveydenhuollon datan ollessa varsin arkaluonteista, se prosessoidaan ja saatetaan anonyymiin muotoon prosessia varten kehitettyä anonymisointiin kehitettyä moottoria käyttäen. Seuraavaksi data kerätään datan prosessointimoottorille, jossa sitä käsitellään tekoälyä hyödyntäen. Kyseiselle datan prosessointimoottorille kerätään myös avointa terveydenhuollon dataa. Prosessoitu data lähetetään rajapinnan kautta Fujitsun pilvipalveluun, jonka jälkeen siitä voidaan muodostaa visuaalisia näkymiä ja raportteja sairaaloille, kuten San Carlos Clinic Hospital.



KUVIO 44. Fujitsun kliinisen päätöksenteon HIKARI-työkalu ja työnkulun skenaario. (Aguilar, 2017)

HIKARI-järjestelmän kyky jakaa potilaita kategorioihin riippuen diagnoosin tyypistä tai yleisemmistä psykiatrisista riskeistä, on lääketieteen ammattilaisille tärkeää. Tällöin he voivat ymmärtää kaikki potilaan terveysriskit, jotta oikeanlainen hoito voidaan määrittää. Ennakoivien analysointimallien muodostaminen auttaa potilaita ottamaan aktiivisemmän roolin omasta terveydestään ja sen hoidosta. Potilaiden tulee voida tehdä päätöksiä, mitä he haluavat elämällään tehdä. Lääketieteen ammattilaiset toimivat eräänlaisina konsultteina, jotka tarjoavat potilaille neuvoja, mutta sallivat potilaan tekevän päätökset koskien omaa terveydenhoitoaan. Tekoälyn potentiaalia hyödynnettäessä voidaan kyetä liikkumaan kohti ennustavaa, osallistuvaa, ehkäisevää, henkilökohtaista terveydenhuoltoa, jossa potilas tekee päätökset ja ottaa vastuuta omasta elämästään. (Aguilar, 2017)

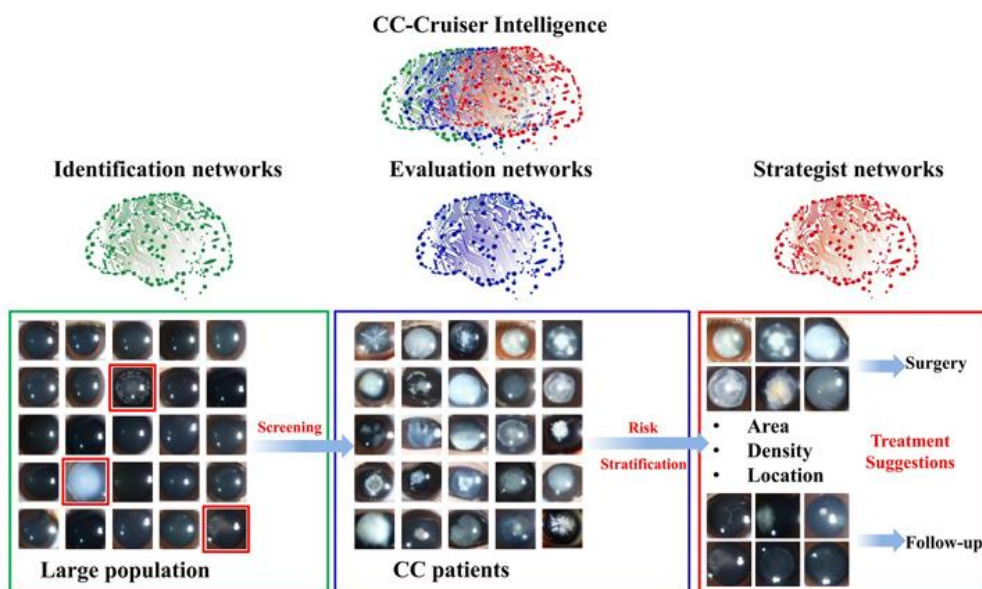
3.6.3 Tekoälyalusta synnyntäisen kaihin diagnosointiin

Kiinalaiset tutkijat ovat kehittäneet tekoälyalustan, joka kykenee diagnosoimaan synnyntäisen kaihin yhtä tarkasti kuin silmälääkärit. Synnyntäinen kaihi on harvinainen silmänsairaus, joka aiheuttaa peruuttamatonta näön menetystä. Aiheesta on julkaistu artikkeli Nature Biomedical Engineerin-julkaisussa vuoden 2017 alussa. Alustaa voidaan hyödyntää

myös muiden harvinaisten sairauksien diagnosoimiseen, jossa virhediagnoosit ovat yleisiä. Tämä on yleistä kehittyvissä maissa, joissa on suuri populaatio, kuten esimerkiksi Kiina. (Tan, 2017)

Synnynnäisen kaihin tapauksessa lapsilla on jo syntyessään sumeat silmien linssit, jotka voivat pimentää näkökyvyn. Sairaus on johtava syy lapsuudessa tapahtuvaan sokeutumiseen hoidon ollessa yksi vaikeimmista ja kalleimmista silmälääkärin suorittamista toimenpiteistä. Arviolta noin 200 000 lasta on sokeutunut sairaudesta johtuen ja monet muut kärsivät osittaisesta kaihista, joka etenee ja aiheuttaa visuaalisia vaikeuksia lapsen kasvaessa. Mahdollistaakseen synnynnäisen kaihin diagnoosin saatavuuden laajemmalle populaatiolle, kiinalainen tutkimusryhmä kehitti konvoluutiologisen neuroverkon, CC-Cruiser-tekoälyalustan, joka kykenee tunnistamaan, arvioimaan ja ehdottamaan hoitoja synnynnäisestä kaihista kärsiville. (Tan, 2017)

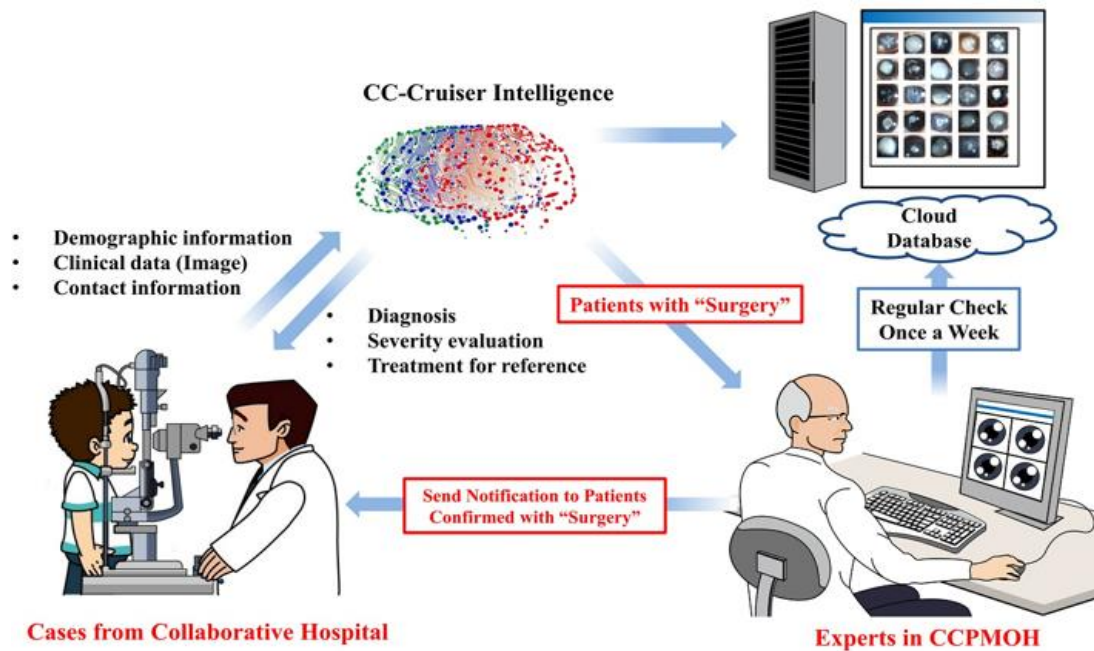
Kuviosta 45 ilmenee CC-Cruiser-alustan toiminnallinen arkkitehtuuri. Suuresta populaatiosta tunnistetaan seulonnalla synnynnäisestä kaihista kärsivät riskitapaukset. Käyttämällä alustan tekoälyä ja neuroverkkoja potilaille tehdään riskiarvio ja sen perusteella alusta kykenee antamaan potilaille hoito-ohjeita, joista osan kohdalle voi tulla seuranta ja osalle leikkaushoito.



KUVIO 45. CC-Cruiser tekoälyalustan funktionaalinen arkkitehtuuri. (Long, 2017)

Potilaiden tullessa yhteistyösairaalaan, jossa ei ole erikoisosaamista synnynnäisen kaihin vaatimiin operaatioihin heistä kerätään demografinen informaatio (nimi, sukupuoli, ikä), kliininen data (kuvantaminen) ja kontakti-informaatio, jotka lähetetään CC-Cruiser-pilvipalvelualustaan. CC-Cruiser lähettää automaattisesti hälytysviestin kiireellistä hoitoa tarvitsevista potilaista operoivalle silmälääkärille. Silmälääkärit suorittavat kaihitapausten seuranta ja tarkastavat kerran viikossa kaikki potilastapaukset, kuten normaali ja kaihia

sairastava potilas. Mikäli potilaille on varmistettu silmäoperointiaika, asiantuntijalääkärit kommunikoivat potilaan kanssa järjestelmän kautta, jotta potilas ymmärtää tilanteen kiireellisyyden ja operaation tärkeyden. CC-Cruiseriin Kiinassa kuuluu myös sähköposti- ja puhelinpalvelu, joiden kautta potilaat voivat olla yhteydessä. Edellä mainittu prosessi ilmenee kuvista 46.



KUVIO 46. Useamman sairaalan kattava älykäs pilvipalvelualusta. (Long, 2017)

Tutkijat käyttävät kiinan terveysministeriöltä kerättyä Childhood Cataract-ohjelmassa kerättyä tietokantaa ja opettivat tekoälyalustan (CC-Cruiser) 410 synnyntäisen kaihin kuvalla ja 476 kuvalla, jotka olivat otettu terveistä silmistä. Jokainen kuva oli erikseen nimetty silmälääkärit. Tutkijat testasivat CC-Cruiseria useissa monimutkaisissa, reaaliaikaisissa tilanteissa, kuten usean sairaalan kliinisissä kokeissa, WWW-pohjaisissa testeissä ja vertailevissa testeissä, joissa toisena osapuolena oli CC-Cruiser-alusta ja toisena silmälääkäri. Tuloksena ilmeni, että CC-Cruiserin suorituskyky oli verrattavissa silmälääkäriin vastaavaan ja CC-Cruiser kykeni onnistuneesti diagnosoimaan kaikki potentiaaliset potilaat 50 potilaan testijoukosta. Silmälääkäreillä tulos oli jopa hieman huonompi ja he tekivät virhediagnooseja muutamien potilaiden kohdalla. CC-Cruiser tarjosi tarkkoja hoito-ohjeita potilaille, jotka tarvitsivat leikkaushoitoa, eikä virhediagnooseja ilmennyt. (Tan, 2017)

CC-Cruiser-alustan suorituskykyä voidaan parantaa suuremmalla aineistolla. Tutkijat ovatkin rakentaneet pilvipalvelualustan datan integraatiota varten ja ovat tutkimassa CC-Cruiser-alustan implementointia vähemmän erikoistuneisiin sairaaloihin. Tämänkaltaiset pilvipohjaiset alustat voivat korvata tai täydentää resurssi-intensiivistä lähestymistapaa harvinaisten sairauksien diagnosoimisessa. Maailmanlaajuisesti harvinaiset sairaudet ovat tyypillisesti hoidettu niihin erikoistuneissa keskuksissa, jotka ovat kalliita ylläpitää ja voivat

olla maantieteellisesti sijoitettuna hajallaan, jolloin potilaiden voi olla toisinaan vaikeaa saada riittävää hoitoa. Rohkaisevista tuloksista huolimatta (Tan, 2017)

Tan (2017) mukaan CC-Cruiser tulee olemaan todennäköisesti täydentävä ratkaisu kuin lääkäreitä korvaava. Tutkimusryhmän rakentamaa pilvipalvelualustaa voivat lääkärit sairaaloissa ympäri Kiinaa käyttää ja alusta antaa mahdollisuuden lääkäreille syöttää potilaiden kuvantamisinformaatiota järjestelmään. CC-Cruiser-alusta hyötyy jatkuvasta datan keräämisestä ja tulevaisuudessa sitä täydennetään lisäksi laajemmalla aineistolla. Rajoitteita aiheuttavat kuitenkin resurssien puute ja datan erillään oleminen yksittäisissä sairaaloissa. Tämän vuoksi pilvipalvelualustan rakentaminen datan integraatiota varten ja potilaiden seulonta on olennainen askel. (Natural Biomedical Engineering, 2017)

3.6.4 Tekoälyn hyödyntäminen skitsofrenian diagnosoinnissa

Skitsofrenia eli jakomielitauti (ICD-10-diagnoosikoodi F20) on nuorella aikuisiällä alkava vakava psykiatrinen sairaus ja se on yleisin psykooseiksi eli mielisairauksiksi luokitelluista sairaustiloista. Sairaudelle on ominaista erilaiset ajattelun tai havaitsemisen vääristymät, aistiharhat ja harhaluulot, lisäksi usein tunneilmaisujen poikkeavuus tai latistuminen. Suunnilleen yksi prosenttia populaatiosta (USA:ssa 3.2 miljoonaa ihmistä) sairastuu skitsofreniaan elinaikanaan. Sairastuneet miespotilaat ovat usein 20 - 28 vuoden ikäisiä ja naiset muutaman vuoden vanhempia. Sairaus voi alkaa jo lapsena tai murrosiässä, joskus myös keski-iässä. (Huttunen, 2016)

Diagnoosi voi olla positiivinen, mikäli vähintään kuukauden ajan on ilmennyt ainakin kaksi sairaudelle ominaista piirrettä viidestä tyypistä:

1. Harhaluulot
2. Aistiharhat
3. Hajanainen puhe (toistuva selvä puheen epäyhtenäisyys)
4. Pahasti hajanainen tai outo käytös tai selvä motorinen jäykkyys tai kiihtyvyys
5. Negatiiviset eli puutosoireet (tunneilmaisujen selvä latistuminen, puheen selvä köyhtyminen tai tahdottomuus)

Edellä mainittujen oireiden lisäksi skitsofrenian diagnoosin edellytyksenä on sairastuneen sosiaalisen toimintakyvyn merkittävä heikentyminen ja toimintakyvyn heikkenemisen jatkuminen yhtäjaksoisesti useamman kuukauden pituisen ajan. (Huttunen, 2016)

Perinteisesti skitsofrenia diagnosoidaan siten, että psykologi tai psykiatri konsultoi potilasta, analysoi potentiaalisen mielenterveyden tunnusmerkit ja valitsee parhaan saatavilla olevan hoitomuodon potilaalle. Sigmund Freudin ajoista lähtien yleisenä diagnosointitapana ovat olleet potilaan terapiaistunnot, jotta potilasta hoitava asiantuntija on voinut saada käsityksen siitä, mitä potilaan mielessä liikkuu ja määrätä hoidon sen perusteella. Ongelmana on, että

asiantuntija (lääkäri) tekee virheellisen diagnoosin perustuen vain omaan ymmärrykseensä potilaasta, joka voi usein olla puutteellinen. (Huttunen, 2016)

Tekoälyn kehittyessä se ei tule keskittymään vain itsekseen ajeleviin autoihin tai muihin oletettavissa oleviin teknisten innovaatioiden toteuttamiseen, vaan myös lääketieteeseen ja esimerkiksi mielenterveydellisten sairauksien, kuten skitsofrenian, diagnosointiin. Skitsofrenian diagnosoinnin teknologia käyttää hyväkseen yksinkertaista maailmanlaajuisesti käytettyä psykologien ja psykiatrien tekniikkaa, puheterapiaa. Psykoosille, joka on yksi skitsofrenian esiasteita, on ominaista epäyhtenäiset ajatukset ja puhe. Nämä ovat niitä poikkeuksellisia merkkejä, jotka psykologit voivat tunnistaa rajataksaan todennäköisen diagnoosin tähän kyseiseen sairauteen ja aloittaakseen sopivan hoidon. Kaikki diagnoosit eivät ole tarkkoja ja kone ei välttämättä suoriudu diagnosoinnista ihmistä paremmin, mutta on useita tilanteita, joissa kone voi jo olla diagnosoinnissa ihmistä tarkempi. (Pate, 2017)

Tutkijat Columbian yliopistosta New Yorkin osavaltion psykiatrisesta instituutista ja IBM Watsonin tutkimuskeskuksesta ovat kehittäneet tekoälyä hyödyntävän sovelluksen, joka kykenee tunnistamaan 100 % tarkkuudella psykoosin kehittymisen henkilöille, joilla on siihen alttius. Perinteinen diagnosointi ylittää 79 % tarkkuuteen, joten tekoälyn hyödyntäminen kyseisen sairauden diagnosoinnissa on osoittautunut hyödylliseksi. Psykologien kaltaisesti, sovellus analysoi puheen malleja erottaakseen psykoosiin sairastumiselle alttiit potilaat terveistä. IBM:n tutkijat huomasivat, että mikäli haastattelijan (psykologi) mieli alkoi vaellella edes hetkeksi, he saattoivat olla huomaamatta psykoosin kehittymiselle oleellisia tunnusmerkkejä, tietokoneen huomattessa ne. Tekoälyä hyödyntävä diagnosointijärjestelmä eliminoi inhimillisen virheen ja on siten asiantuntijoita tarkempi diagnosoinnissa. (Pate, 2017)

Psykoosi saa potilaat tuntemaan eristyneisyyttä ympärillä olevasta maailmasta, joka johtaa jyrkkään tunnereaktioiden laskuun, joka on samankaltaista kuin reaktioiden puute autismitieteen eli ASD-häiriössä (Autism Spectrum Disorder). Mitsuo Kawato ATR laskennallisten neurotieteiden laboratorion Kiotosta, Japanista on käyttänyt tekoälyjärjestelmää, joka hyödyntää fMRI-kuvantamista aivojen ASD-potilaiden aivojen kuvantamiseen, jolloin tuloksia voidaan verrata henkilöihin, joilla on terveet aivot. fMRI-kuvantaminen tarkoittaa toiminnallista eli funktionaalista magneettikuvausta, jolla tutkitaan aivojen toimintaa. Se tehdään samalla laitteella kuin rakenteellinen magneettikuvaus (MRI). Samankaltaisia tunnusmerkkejä voidaan yleistää myös psykoosiin ja siten myös skitsofreniaan. (Pate, 2017)

Paikantamalla aivojen emotionaalisten reaktioiden puutteen, keinotekoisesti älykäs järjestelmä voi hälyttää lääkärin psykoottisten oireiden ilmaannuttua ja laskea potilaan skitsofreniaan sairastumisen todennäköisyyden analysoimalla fMRI-kuvantamisessa otettuja kuvia ja puhetta, jota sovellus on kerännyt. Tietokoneen keräämän informaation summa mahdollistaa täyden psyykkisen profiilin kehittämisen potilaasta, jota psykologi tai psykiatri

voi hyödyntää hoitoa määrittäessään. Profiilin hyödyntäminen diagnosoinnissa ja hoitosuosituksissa on merkittävä edistysaskel ja tarjoaa terveydenhuollon ammattilaisille uudenlaisen niin potilaita kuin ammattilaisiakin hyödyttävän työkalun. (Pate, 2017)

Epäyhtenäinen puhe saattaa alkaa muodostua jo vuosia ennen kuin potilas sairastuu skitsofreniaan ja katkokset puheen aikana voivat olla niin hienovaraisia, että edes koulutettu psykologi ei niitä huomaa. Tekoälyä hyödyntävä sovellus kykenee huomaamaan katkokset ja siten säästää aikaa, rahaa ja energiaa tunnistessaan potentiaaliset ongelmat jo ajoissa. Useimmiten sairastuminen tapahtuu 18 – 25 vuoden iässä ja jos psykoottinen potilas osallistuu yhteen terapiaistuntoon ja käy fMRI-testeissä, järjestelmä kykenee diagnosoimaan potilaan sairauden perustuen kahteen edellä mainittuun analyysiin, jolloin lääkäri voi päättää hoitostrategiasta, joka on mahdollisimman tehokas kyseiselle potilaalle. (Pate, 2017)

Edellä mainittua järjestelmää voidaan soveltaa yksittäiseen potilaaseen ja useat eri tietokoneet voivat olla yhteydessä toisiinsa auttaakseen potilaita ympäri maailman viimeisimpiä sairausdiagnooseja hyödyntäen. Potilaan tullessa esimerkiksi psykiatrin luo hakeakseen apua ja psykiatri toteaa tapauksen olevan laadultaan uniikki, hän voi tarkistaa tietokannasta, mikä on auttanut samankaltaisille potilaille menneisyydessä. Lisäksi hän voi tarkastaa uusia hoitomuotoja, jotka voisivat olla tehokkaita tässä tapauksessa. Tämänkaltainen menettely auttaa koko psyykkisen hoidon kenttää kehittämään ratkaisuja, jotka auttavat mahdollisimman monessa tilanteissa ja mahdollisimman montaa potilasta. (Pate, 2017)

Pate (2017) mukaan ongelmia voi tosin aiheuttaa potilaan yksityisyys ja sen vaatimukset, sillä tietoa tulisi voida jakaa maailmalle. Potilaiden yksityisyysvaatimukset ovat prioriteeteissa korkeat ja erityisesti psyykkisen terveydenhuollon kentässä, joka on aiheuttanut sen, että jotkut potilaat ovat kieltäytyneet siitä, että heidän tietojaan tallennetaan tiedostoihin. Lisäksi mikäli potilaat ottavat vastaan tekoälyjärjestelmän määrittämän diagnoosin, lääkäriä tarvitaan silti analysoimaan järjestelmän antamia tuloksia ja siten määrittämään tehokkaan hoidon potilaalle. Tietokoneet ja tekoälyjärjestelmät varmasti tehokkaasti avustavat lääkäreitä hoitopäätösten tekemisessä sekä diagnosoinnissa ja ne voivat kehittyä niin pitkälle, että niistä tulee jopa ensimmäinen lääketieteellinen mielipide, mutta lääkärit tekevät silti ainakin toistaiseksi ja lähitulevaisuudessa lopullisen päätöksen hoitoprosessista (Chan, 2016). Tulevaisuuden sukupolvet voivat sovelluksien kehittyessä hyötyä sairauksien ennakoidusta tunnistamisesta, ihmisen ja järjestelmän tarjoamasta yhteishoidosta ja oireiden ennaltaehkäisystä, mikäli järjestelmä voidaan toteuttaa eettisesti ja tehokkaasti.

3.6.5 Tekoäly ja Your.MD-sovellus auttavat sairauksien diagnosoinnissa

Norjalainen ja myöhemmin Iso-Britanniaan siirtynyt startup-yritys (Your.MD) kehitti henkilökohtaisen terveystietokoneen, joka kantaa samaa nimeä yrityksen kanssa. Your.MD kehitettiin parantamaan tapaa, jolla useat ihmiset hakevat terveyteen liittyvää tietoa

Internetistä tehden henkilökohtaisia kotidiagnoosejaan (O'Hear, 2015). Mobiililaitteille kehitetty sovellus käyttää tekoälyä ja tarjoaa perusterveydenhuollon palveluja. Sovellus tarjoaa potilaille mahdollisuuden päästä käsiksi perusterveydenhuollon tarjoamiin palveluihin, mikäli potilas ei pääse lääkäriin tai hänellä ei ole pääsyä perusterveydenhuollon ammattilaisen luokse. Sovelluksesta on sekä Android että IOS-versiot ja sen avulla on jo tehty 9.5 miljoonaa hakua ympäri maailman yli 100 maassa. (Your.MD)

Hakukoneiden, kuten esimerkiksi Googlen käyttäminen omaehtoiseen diagnosointiin voi aiheuttaa enemmän haittaa kuin hyötyä, sillä se voi aiheuttaa monenlaisia pelkotiloja oletetun sairauden oireiden etsinnässä. Lähteet eivät välttämättä ole luotettavia tai voi käydä niin, että osassa sairauksia Internetistä voi löytää lähinnä vain negatiivisia ja pelottaviakin sairaskertomuksia, mikä ei välttämättä kuvaa koko sairauden tilannetta potilailla. Helpommalla sairauksista selvinneet eivät välttämättä kirjoita kokemuksiaan Internetiin ollenkaan, jolloin päätelmät sairauksien vakavuuksista saattavat vääristyä. Your.MD-sovelluksen tarkoituksena on parantaa tilannetta tarjoamalla luotettavamman tavan saada tietoa lääketieteellisestä tilanteesta sovellukselle kerrottujen oireiden perusteella.

Toimiakseen Your.MD-sovellus käyttää tekoälyä ja koneoppimista sekä dataa, jonka sovelluksen kehittänyt yritys on lisensoinut kansalliselta terveystalolta (National Health Service eli NHS). Your.MD-sovellus tähtää tehokkaampaan potilaiden lääketieteellisen tilan diagnosointiin sekä tilaan johtaneiden syiden selvittämiseen ja lisäksi minkälaisia askelia potilaan pitäisi ottaa sairauden parantamiseksi ja milloin hänen tulee käydä lääkärissä. Your.MD ei ole ainoa tämänkaltaisen sovelluksen kehittäjä, vaan kilpailijoilla on jo markkinoilla vastaavia sovelluksia, kuten NHS 111, Symptomate, webMD ja Google Doctor. (O'Hear, 2015)

Your.MD-sovellus on älykäs terveysapulainen, joka mahdollistaa tarkan, ymmärrettävän ja nopean sekä relevantin terveystieteen tarjoamisen toimimalla ensimmäisenä vaihtoehtona sen sijaan, että potilas joutuisi odottamaan lääkäriä päiviä tai viikkoja tai luottamaan Internetin tarjoamaan informaatioon, joka on välitöntä, mutta jota eivät ole lääketieteen ammattilaiset seuloneet tai informaatio ei ole räätälöity potilaiden terveysprofiilin mukaisesti. Käyttäen tekoälyä hyväksi, ratkaisu on skaalautuva ja älykkäämpi kuin perinteiset tietokannat, jopa sellaiset, jotka on kehitetty asiakasystävällisiksi ja lääketieteen ammattilaisten toimesta. (O'Hear, 2015)

Your.MD-sovelluksen kehittäneellä startup-yrityksellä on tavoitteena demokratisoida terveydenhuolto ja tavallaan laittaa lääkäri ihmisten taskuun (mobiililaitte), joka olisi jokaisella kansalaisella maailmassa. Tekoälyn avulla sovellus oppii käyttäjiltään jatkuvasti ja joka päivä testien mukaisen lääketieteellisen tuloksen ollessa 85 % 20 yleisimpään sairauteen. Lääketieteellinen tarkkuus yli 500 sairauteen on tällä hetkellä 60 % luokkaa. Lääketieteellinen tarkkuus mitattiin käyttäen verifioituja Harvardin yliopiston ja Royal Collegen

yleislääketieteen lääketieteellisiä testitapauksia. Menetelmä on sama, jota käytetään testaamaan lääkäriharjoittelijoita. (Your.MD)

Kuviossa 47 ilmenee Your.MD-sovelluksen käyttöliittymä ja toiminta yksinkertaistettuna.

1. Oireiden tarkastus: Potilas kertoo, mikä on vialla ja Your.MD ehdottaa erilaisia sairauksia perustuen yksilöllisiin oireisiin ja henkilökohtaiseen profiiliin.
2. Informaation kysyminen: Potilas voi kysyä mitä tahansa terveyteen liittyviä kysymyksiä löytääkseen vastauksia, joita ovat kirjoittaneet lääkärit sekä tarkastaneet YK:n kansallinen terveystietopalvelu.
3. Avun löytäminen helposti: Mikäli potilas tarvitsee enemmän apua, Your.MD-sovelluksessa on valittuja kumppaneita, jotka tarjoavat asiantuntijapalveluita ja informaatiota.



KUVIO 47. Your.MD-sovelluksen käyttöliittymä.(Your.MD)

4 Terveydenhuollon tulevaisuus

Frost & Sullivanin markkinatutkimuksen mukaan tekoälymarkkinat terveydenhuollon alueella ylittävät kuuden miljardin rajan vuonna 2021. Tekoäly on jo ottanut suuria edistysaskelia automatisoidussa pehmytkudoskirurgiassa, lääketieteellisessä kuvantamisessa ja lääkeaineyhdisteiden etsinnässä. Kenties suurin onnistuminen tähän saakka on ollut Big Data-analytiikan hyödyntäminen diagnosoinnissa ja sairauksien hoidossa. IBM Watson-tekoälyä käytetään jo 16 syöpäinstituutissa ja se on onnistunut useissa eri lääketieteen alueen diagnosoinneissa, kuten harvinaisen japanilaisen naisen leukemian diagnosoinnissa, jossa tavanomaiset ihmisresursseja hyödyntävät menetelmät eivät ole onnistuneet. (Ziden, 2016)

Nykyään olemassa on liian paljon erilaisia sairauksia ja lääketieteellinen kirjallisuus muuttuu liian nopeasti, jotta hoidosta vastaava lääkäri kykenisi pysymään muutoksen perässä. Leukemian diagnosoinnin lisäksi lääketieteen kentässä on paljon tilanteita, joita ei olla voitu diagnosoida ennen koneiden ja tekoälyalgoritmien riittävää hyödyntämistä. IBM Watson-tutkimusryhmä on työskentelemässä algoritmin parissa seuloen lääkäreiden tekemiä muistiinpanoja MS-taudin löytämiseksi. Tavoitteena on toteuttaa ohjelma, joka voi laskea prosenteissa henkilön MS-tautiin sairastumisen riskin. Tulevaisuudessa ohjelmisto automattisesti analysoi digitaalista potilastietorekisteriä generoiden varoituksia ja hoitosuosituksia. (Rutkin, 2016)

Robottiikka ja tekoäly ovat muuttamassa terveydenhuollon kenttää. Lääkärit ovat avoimia tämänkaltaiselle muutokselle niin kauan kuin heillä on paikka järjestelmässä. Tästä herää kysymys, tarvitaanko lääkäreitä tulevaisuudessa yhtä paljon kuin aiemmin on tarvittu? Tulevaisuudessa mahdollisesti jo seuraavien 10 – 20 vuoden aikana on mahdollista, että on olemassa lääkärin päätöksentekoa tukeva ihminen-tekoäly-hybridijärjestelmä, jossa ihmiset kontrolloivat enemmän omaa terveydenhoitoansa. Tämänkaltaisen järjestelmän säästäisi huomattavasti henkilöstö- sekä muita kustannuksia ja jo tähän mennessä tekoälyalgoritmit ovat olleet useilla eri lääketieteen sovellusalueilla diagnosoinneissa lääketieteen ammattilaisia tarkempia. (Ziden, 2016)

Menestyäkseen lääkäreiden tulee muuttaa aiempia käytänteitään ja asennettaan pärjätäkseen uusien teknologioiden kanssa. Pidemmällä aikavälillä koko terveydenhoitojärjestelmä tulee todennäköisesti käymään läpi tekoälyllistymisen (AI-ification) ja ajatus ihmislääkäreistä ja kirurgeista voi alkaa tuntua vanhentuneelta. Mahdollisesti markkinat homeopatian ja vaihtoehdoisen lääketieteen alueella kasvaa, sillä kaikki potilaat eivät välttämättä ole valmiita näin suuriin muutoksiin. Ihmisluonteeseen kuuluu tässä asiassa tietynlainen optimismi ja tutkimuksien mukaan peräti 80 % kyselytutkimukseen vastanneista on sitä mieltä, että robotit ja tietotekniikka, kuten tekoälysovellukset ja automaatio, eivät vie juuri heidän työtään. (Ziden, 2016)

Suuret teknologia-alan yritykset, kuten Apple, Dell, Google, Hewlett-Packard, Hitachi ja IBM ovat kehittämässä tekoälyä hyödyntäviä sovelluksia, kuten virtuaaliset apulaiset (Virtual Assistants), terveydenhuollon kentässä. Seuraavien viiden vuoden aikana tekoälyn hyödyntäminen lääketieteessä on odotettu kasvavan kymmenkertaisesti. Olemassa on useita alueita, joissa tekoälyn on ennustettu mullistavan terveydenhuollon ja lisäksi alueita, joissa sitä jo käytetään. Joissain tapauksissa jo nykyään tekoälyn on todistettu suorittavan diagnooseja nopeammin kuin mitä ihmiset kykenevät tekemään. (Perry)

Lääketieteen ammattilaiset voivat joutua kokemaan vaikeitakin tilanteita, joissa potilas saattaa tulla vastaanotolle vaikeiden oireiden kanssa, jollaisia kyseinen asiantuntija ei ole aiemmin nähnyt. Oireiden tutkiminen ja sairauden diagnosointi hoitoa varten voi viedä niin paljon aikaa, että potilas saattaa ehtiä menehtymään. Nykyään lääketieteen ammattilaiset voivat kirjautua tietojärjestelmään selvittääkseen, mikä harvinainen oire on, mitä hoitomuotoja on tarjolla ja kirjoittaa sairauteen sopivan lääkityksen vain sekunneissa. Tekoäly voi diagnosoida sairauden, tarjota uusia hoitovaihtoehtoja, eliminoida ihmisten tekemät virheet ja hoitaa toistuvia tehtäviä, jotka tukkivat järjestelmän toiminnan. Nämä toimenpiteet tekevät toiminnasta tehokkaampaa ja säästävät kustannuksia. (Perry)

Nykypäivänä terveydenhuollon alueen informaation määrä on tähtitieteellinen ja tämän tietomassan analysoimisessa tekoälystä on hyötyä. Modernizing Medicine, joka on web-pohjainen lääketieteellisen informaation tietovarasto, kokoaa dataa 3700 palveluntarjoajalta ja yli 14 miljoonasta potilasvierailusta. (Perry) Tietovarastoa voidaan hyödyntää etsimään tietoa harvinaislaatuista sairauksista, joiden lääkitsemiseen lääketieteen ammattilaisilla ei ole välttämättä informaatiota, mutta järjestelmästä voi löytyä jo aiemmin tunnettu samanlainen diagnosoitu tapaus ja sopiva lääkitys siihen. (Hernandez, 2014) Lisäksi IBM on viime aikoina hankkinut terveydenalan yrityksen (Merge Healthcare Inc.), joka on varastoinut 30 miljardia kaiken tyyppistä lääketieteellistä kuvaa, joita tullaan käyttämään Watsonin opettamisessa sairauden diagnosointeja varten. (Perry)

Tekoälyä on hyödynnetty myös Vanderbilt University Medical Center ja St. Jude's Medical Center terveystieteissä, joissa digitaalisiin potilastietojärjestelmiin on sisällytetty tekoälyä, joka tarjoaa informaatiota muun muassa geneettisten piirteiden vaikutuksesta potilaiden sairauteen tai kuinka uusi lääke voisi parantaa heidän tilaansa. Pelkästään ponnahdusikkunaa (pop-up) klikkaamalla lääkäri voi saada lisäinformaatiota sairaudesta tai jopa määrätä erilaisen lääkityksen, mikäli aiempi ei toiminut oikealla tavalla. Nämä sähköiset tekoälyä hyödyntävät potilastietojärjestelmät eivät vain säästä aikaa ja tilaa, vaan ne aktiivisesti auttavat potilaita ja lääkäreitä löytämään vaihtoehtoja hoitomuodoissa myös personoimalla niitä, esimerkiksi suosittamalla potilaille heille parhaiten sopivia hoitovaihtoehtoja henkilön genomidataan perustuen. Tämä voi myös rajoittaa tai jopa kokonaan eliminoida sivuvaikutukset. (Perry)

4.1 IoT – Internet of Things

Useimmiten IoT-laitteita on käytetty lääketieteen alueella hyväksi diagnosointitarkoituksissa, mutta ne kykenevät auttamaan myös potilaan itsemonitoroinnissa kotiolosuhteissa, eikä vain sairaalaympäristössä. Esimerkkeinä itsemonitoroinnista on langatonta yhteyttä (Esimerkiksi Bluetooth tai Wi-Fi) hyödyntävä mobiililaitteeseen yhdistetty monitorointilaitte, joka mittaa veren glukoositasapainoa. Monitorointilaitte on yhteydessä taskukokoiseen insuliinipumppuun, joka on asennettu ihon alle katetrin avulla. Laitte pumppaa insuliinia tarvittavan ja juuri oikean määrän 24 tunnin aikana, jolloin potilaan ei tarvitse huolehtia siitä ja myös unohduksilta vältytään. (Desai, 2016)

IoT-laitteita hyödyntävien potilaiden päähyötynä on mukavuus ja nopea pääsy vitaaliin informaatioon, jolloin hätätilanteilta voidaan välttyä. Ihmiset tunnetusti ovat halukkaita monitoroimaan ja kontrolloimaan terveyttään, mikäli he tuntevat sen helpoksi, miellyttäväksi ja mikäli se sopii heidän kiireiseen nykyajan elämäntyyliinsä. (Desai, 2016)

Potilaiden lisäksi myös palvelujen tuottajat hyötyvät IoT-laitteiden tuomasta hyödyistä, jotka ovat muun muassa:

- Nopeammat vasteajat
- Palvelun tarjoajat kykenevät vastaanottamaan enemmän potilaita päivittäin
- Reaaliaikainen potilaan terveyden etämonitorointi
- Vähemmän ruuhkaa sairaaloissa, jolloin tilaa vapautuu kriittisesti sairaille

4.2 Kyberturvallisuus

Nykyään pinnalla on ollut paljon myös kyberturvallisuus ja kyberuhat. Sairaalat ja niiden tietojärjestelmät ovat haavoittuvampia kuin moni muu teollisuuden ala, kuten esimerkiksi pankit ja finanssiala, joka on investoinut kyberuhkien ennalta ehkäisyyn, niiden torjumiseen ja niihin reagoimiseen. Tietojärjestelmiin murtautuvat krakkerit ovat aggressiivisesti käyttäneet hyväksi tietoturvaluusaukkoja organisaatioiden tietojärjestelmissä ja viime vuonna jopa satoja sairaaloita on joutunut niin sanottujen ”ransomware”-hyökkäyksien uhreiksi. Ransomware-hyökkäys tarkoittaa tilannetta, jossa ulkopuolinen estää sairaalan tietojärjestelmien käytön vaatien sairaalaa maksamaan murtautujalle rahaa eli ns. ”lunnaita”. (Prevett, 2016)

Sairaaloiden tietojärjestelmien sekä lääketieteellisten laitteiden lisäksi sairaalarakennukset voivat olla kyberfyysisten hyökkäyksien kohteina. Aiemmin sairaaloihin kohdistui kyberfyysisiä hyökkäyksiä, kuten kiristysohjelmia, Web-sivustojen tuhoamista ja potilasdatan varastamista. Sairaalarakennuksiin kohdistuvat kyberfyysisillä hyökkäyksillä on potentiaalia aiheuttaa huomattavaa vahinkoa kriittisille sairaalalaitteistoille ja potilashoidolle. Hyökkääjät

voivat murtautua ja ottaa kontrollin jostain yksinkertaisesta laitteesta, kuten sairaalan jääkaapit, johon on sijoitettu verinäytteitä tai lääkkeitä. Hyökkääjät voivat sitten muuttaa esimerkiksi jääkaappien lämpötiloja aiheuttaen sisällön pilaantumista. Hakkeroinneille alttiin sairaalalaitteistoista tekee Web-käyttöliittymä ja Internet-yhteys, jolloin laitteen parametreja voidaan muuttaa ja aiheuttaa tuhoa. Eräs katastrofaalisimmista tuhoa aiheuttavista hakkerointitoimista on muuttaa elinsiirtoja varten varattujen elinten säilytykseen varattujen varastojen olosuhteita, joka voi pahimmillaan viedä potilaalta mahdollisuuden hengenpelastavaan hoitoon. (Ayala, 2016, 39) Tulevaisuudessa tekoälyä tullaan hyödyntämään yhä enemmän kyberfyysisten hyökkäyksien torjunnassa, jolloin mahdolliset kriittisiin järjestelmiin kohdistuvat vahingot voivat vähentyä.

4.3 Telelääketiede

Telelääketiede on kehittymässä yhä älykkäämmäksi sekä kypsemmäksi ja se on keräämässä yhä enemmän huomiota. Ihmisten ollessa yhä kiireisempiä, menevämpiä ja enemmän yhteydessä toisiinsa ja palveluihin kuin aiemmin, virtuaaliset lääkitapaamiset voivat olla käytännöllinen ratkaisu. National Center of Policy Analysis (NCPA)-organisaation mukaan seitsemän miljoonaa potilasta maailmalla tulee käyttämään telelääketieteen palveluita vuoteen 2018 mennessä. (Desai, 2016)

Hyötyinä telelääketiede tarjoaa muun muassa välittömän etäpalvelumahdollisuuden esimerkiksi lääkityksasioissa, mikäli henki on vaarassa. Lääkityksen etäpalvelu voi sisältää audio- ja videokonferenssisovellukset, joiden avulla potilas voi olla yhteydessä lääkäriin jopa julkiselta paikalta, jossa äkillinen henkeä uhkaava allergiareaktio on tapahtunut. Lääkäri voi tarkastaa tilanteen etänä ja määrätä lääkityksen, jolloin potilas pääsee hoitamaan tilanteen nopeammin kuin hakeutumalla hoitoon, johon voi olla etäisyyttä, jolloin hoidon saaminen voi viedä liikaa aikaa. (Desai, 2016)

4.4 Robotiikka ja tekoäly

Sairaalat maailmalla ovat olleet suhteellisen hitaita omaksumaan robotiikkaa ja tekoälyä potilaiden hoidossa, vaikka molempia osa-alueita on onnistuneesti testattu ja käytetty teollisuudessa. Lääketieteelle on ominaista hidas muuttumisprosessi ja turvallisuus on sen ydinajatuksia. Taloudelliset paineet todennäköisesti tulevat tulevaisuudessa yhä enemmän vaikuttamaan teollisuuteen sekä hallitukseen ja ne tulevat käyttämään robotiikkaa yhä enemmän, mikäli robotit tekevät asiat ihmisiä paremmin ja halvemmalla. (Jaiprakash ym., 2016) Roboteilla ja robotiikalla on vielä kuitenkin matkaa ihmisluonteelle ominaisen intuition kehittymiselle, mikäli se koskaan voi toteutua (Powell, 2015).

Osa sairaaloista ovat jo viimeisimmän kymmenen vuoden aikana tunnistaneet potentiaalinen toimimiseen tehtaan kaltaisella tavalla, joka on tehokkaampaa kuin aiemmat toiminnan

mallit. Kyseiset sairaalat ovat jopa kokeilleet teollisuudesta tuttua Lean-prosessia vapauttaakseen ihmisresursseja monimutkaisempien ongelmien ratkaisuihin. Lean-prosessin käytössä pelätään, että se tulee viemään työpaikkoja mahdollisen rahoituksen karsimisen myötä, mutta tilanne voi olla myös positiivisempi, eli työtehtävät muuttuvat niiden loppumisen sijaan. (Jaiprakash ym., 2016)

Muinaiset Egyptiläiset tekivät monimutkaisia leikkauksia käsityönä jo tuhansia vuosia sitten ja vaikka työvälaineet sekä tietämys on niistä ajoista kehittynyt, on leikkauksia silti tehty pääosin yhä käsin ennen robotiikkaa ja tekoälyä (McShane, 2016). Nykyään kirurgit käyttävät jo robotteja apunaan leikkauksia tehdessään, mutta kirurgeilla on silti kontrolli ja kone on vain apuvälaineenä. Tulevaisuudessa tilanne voi muuttua siten, että koulutettu järjestelmiin, kuten robotiikkaan ja tekoälyyn, erikoistunut asiantuntija voi seurata kirurgin suorittamaa leikkausta ja opettaa robotin suorittamaan leikkauksen jatkossa, jolloin sillä olisi kontrolli kirurgin sijasta. Tähän on kuitenkin vielä matkaa, tosin tekoäly voi kehittyä lähitulevaisuudessa nopeastikin, joten tilanne voi muuttua. (Jaiprakash ym., 2016) Tällä hetkellä tekoälyä hyödyntävät opetetavat järjestelmät ovat tosin jo saaneet aikaan tuloksia monimutkaisten hoitotoimenpiteiden alueella, kuten nivelen vaihtaminen, selkäydinleikkaus jne. tilanteen vaikuttaessa lupaavalta myös muiden alueiden hoitoprosesseissa (Desai, 2016).

Robotiikan käytöstä hyvänä esimerkkinä on Da Vinci-leikkausrobotti, joka kehitettiin 15 vuotta sitten ja se on osoittanut olevansa toimenpiteissä tarkka, ketterä ja käsivarsiltaan vakaa. Da Vincin jälkeen on julkisuuden nähnyt useita muita leikkausrobotteja ja niiden uudet sukupolvet. Uuden leikkausrobotisukupolven myötä leikkaukset ovat muuttuneet digiaikaan ja dataa on alettu kerätä ja analysoida robottijärjestelmien kautta, kuten liikkeen jäljittäminen. Roboteilla on kuitenkin vielä haasteita ihmisen älykkyyden ja liikkeen jäljittelyssä (Kannan, 2017). Tekoälyä, kuten IBM Watson, koneoppimisen algoritmit ja AlphaGo voidaan hyödyntää robotiikan apuna leikkauksissa. Watson varastoi lääketieteellistä dataa ja sitä voidaan hyödyntää käyttäen luonnollista kieltä (älykäs leikkausapulainen). Koneoppimisen algoritmeja taas voidaan käyttää tunnistamaan, milloin oireet täsmäävät tiettyyn sairauteen. AlphaGo-tekoälyalgoritmia voidaan hyödyntää opettamisen jälkeen uusien oppimisstrategioiden testaamisessa ja lisäksi leikkaussimulaatioissa tarkkailtaessa, kuinka ihmiset oppivat.

Mahdollista on, että tulevaisuuden sairaaloissa sairaalasängyt liikkuvat robotiikan avulla automaattisesti, kuten tavaroiden ja osien siirtäminen tapahtuu jo nykypäivänä valmistavassa teollisuudessa, kuten autotehtaat jne. Sairaalasängyt voivat kuljettaa potilaita ensiapuhuoneesta aina operointihuoneeseen saakka ja tarvittaessa kuvantamisen, kuten esimerkiksi röntgen kautta. Tämä on yksi skenaario, joka vaikuttaa myös henkilökunnan määrään pidemmällä aikavälillä ja saattaa aiheuttaa tilanteen, jossa tarvitaan vähemmän terveydenhuollon henkilökuntaa, kuten hoitajia ja jopa lääkäreitä. Tilanne jo toimesta olevien

terveydenhuollon alan henkilöstön suhteen ei todennäköisesti muutu ainakaan lähitulevaisuudessa alan ollessa yhä kasvussa. (McShane, 2016)

Radiologia on kenties yksi lääketieteellinen alue, jonka edustajat kaipaavat suuremman roolin terveydenhuollon sektorilta ja he kykenevät saavuttamaan sen vain, mikäli heidän osallisuutensa voidaan todeta kliinisesti arvokkaaksi. Potilaiden hoidon hyvä lopputulos voi olla tie siihen ja tekoälyn hyödyntämisessä on potentiaalia parempien radiologian diagnoosien aikaansaamiseksi. Kehittääkseen radiologisen tutkimuksien lopputuloksia, tutkijat ovat kehittäneet Swarm IT-algoritmin, joka yhdistää ryhmän radiologian eksperttejä ja heidän tietämyksensä yhteen muodostaen tietynlaisen asiantuntijatason yhteenliittymän. (Freiherr, 2016)

Tämä kollektiivinen älykkyys (Collective Intelligence) on tutkimuksien mukaan kyennyt vähentämään väärin positiivisten ja negatiivisten mammografiatuloksien diagnooseja ja juuri kollektiivisuus kykenee voittamaan perinteisen yhden radiologin tekemän diagnoosin tarkkuuden. Tämänkaltaisen älykkyys parantaa mammografian kuvantamismenetelmiä ja sillä on myös potentiaalia parantaa tulevaisuudessa myös muun tyyppistä lääketieteellistä päätöksentekoa, kuten useiden eri lääketieteen alueiden diagnostiset kuvantamiset. Menetelmää hyödyntäen, radiologit ovat kyenneet myös diagnosoimaan luuston epänormaaliuksia oikein. Tulevaisuudessa monimutkaisen sairaustapauksen ollessa kyseessä, radiologit voivat hyödyntää kyseistä algoritmia ja se saattaa parantaa diagnoosien tarkkuutta hyödyntämällä koko asiantuntijaryhmän tietämystä ja tehostamalla potilaan hoitoprosessia. (Freiherr, 2016)

Radiologian ja robotiikan lisäksi tekoälyä voidaan tulevaisuudessa yhä enemmän hyödyntää rutiinitehtävien automatisointiin ja muihin toimintoihin, kuten:

- Diagnostiikka-apu.
- Hoidon esisuunnittelu: Tietyt tilanteet, jotka vaativat hoitosuunnitelmien kehittämistä, voivat hyötyä tekoälytyökaluista hoidon suunnittelun aikana. Hyödyntämällä tekoälysovelluksia, jotka automaattisesti muodostavat hoitosuunnitelmia tiettyjen relevanttien potilastilanteiden pohjalta, voivat tuoda huomattavaa lisäarvoa lääkäreille ja potilaille itselleen.
- Hälytykset ja muistuttajat: Yleisimmissä tekoälyn integroinnin muodoissa tietokone tutkii potilaan laboratoriotulokset, lääkemääräykset ja pitää potilaan ajan tasalla sopivilla muistutuksilla. Muistutuksien lisäksi voidaan hyödyntää myös kehittyneempiä tekoälyohjelmistoja, jotka voivat tunnistaa muutoksia potilaiden terveydentilassa.
- Kuvan tunnistaminen: Usempia lääketieteellisiä kuvia voidaan tunnistaa samanaikaisesti, aina röntgenkuvista monimutkaisiin CT- ja MRI-kuviin saakka. Sovellukset, jotka osaavat tunnistaa ja tulkita kyseisiä kuvia, on jo omaksuttu kliiniseen käyttöön.

- Tiedon hakeminen: Sopivia tekoälyalgoritmeja hyödyntäviä hakuagentteja voidaan kehittää monimutkaisten lääketieteellisten sovellusten avuksi, jotka tehostavat informaation hakua uudelle tasolle verrattuna aiempiin Web-pohjaisten hakuagenttien suorituskykyyn.

Potilainen luokittelu kiireellisyyden mukaan eli Triage voidaan toteuttaa tekoälyn ja siihen tarvittavan laitteiston sekä järjestelmien avulla ja yhä useampi päätös tullaan tekemään älykkäiden laitteiden avulla. Potilaan lääketieteellinen informaatio tullaan lukemaan suoraan ihon alle asennetusta sirusta tai mobiililaitteista, esimerkiksi mobiilipuhelin tai esimerkiksi päälle puettavasta laitteesta, jotka toimivat välivaiheena ennen kehoon asennettavia siruja ja implantteja. Tulevaisuudessa ei ole enää tarpeen odotella potilastietoja sähköisistä järjestelmistä tai koettaa etsiä tietoa potilaan ollessa esimerkiksi tajuton tai muuten vakavassa tilassa. (Jaiprakash ym., 2016)

Tekoälyä ja koneoppimista voidaan jo lähitulevaisuudessa hyödyntää myös lääkityksen määrittämisessä. Aiemmin sairauksien lääkitysten määräämisessä (esimerkiksi psyykkiset sairaudet) on voinut olla niin, että potilaalle on määrätty lääkettä A ja mikäli lääkitys ei ole tehonnut viikkojen tai kuukausien aikana, niin lääkäri on voinut määrätä lääkettä B, jota on mahdollisesti tehonnut tai sitten ei. Lähitulevaisuudessa koneoppimisen algoritmit voivat lukea potilaiden genomitiedot, sairauden oireet ja erilaisia sairauden tunnusmerkkejä, jolloin ne voivat ehdottaa lääkitystä C jollekin potilaalle ja esimerkiksi lääkitystä D toiselle potilaalle saman sairauden ollessa kyseessä. Tämän jälkeen algoritmit voivat monitoroida potilaiden verenkiertoa ja tunnistaa siitä vaarallisten sivuvaikutusten varoitusmerkit. (Allen, 2016) Tulevaisuutta on, että potilaan etnisyyttä, aineenvaihdunta (metabolia) ja sukupuoli yhdistettynä genetiikkaan ja muuhun laboratorion mittaamaan dataan, jotka voidaan prosessoida tekoälyalgoritmeilla ja siten määrätä sopiva lääke tietylle potilaalle oikeaan aikaan (Pathway Genomics, 2016).

Tulevaisuudessa lääkäreiltä vaaditaan taitoja, joihin he eivät ole välttämättä tähän mennessä tottuneet, kuten teknologian ymmärtämistä, ohjelmointitaitoja ja muita tietoteknisiä taitoja jo ennen lääketieteen opintojen aloittamista. Ohjelmointitaidoista tulee yhä tärkeämpiä ja niistä on tulossa neljäs niin sanottu kansalaistaito lukemisen, kirjoittamisen ja matematiikan (laskemisen) lisäksi. Kirjoittamistaidon vaatimukset tosin ovat vähenemässä, mitä tulee käsin kirjoitettuun tekstiin. (Jaiprakash ym., 2016)

4.5 Virtuaalitodellisuus

Teknologisten innovaatioiden, kuten tekoäly (koneoppiminen, neuroverkot), robotiikka, telelääketiede jne. lisäksi virtuaalitodellisuus on tarjoavat aivan uudenlaisia mahdollisuuksia terveydenhoidon mullistamiseen kenties jo lähitulevaisuudessa. Eräs julkisuudesta uutistilaakin saanut virtuaalitodellisuuteen liittyvä innovaatio on Googlen kehittämät Google Glass-lasit,

joita on nyt hyödynnetty myös lääketieteen alueella. Lasit nousivat julkisuuteen 2012 Googlen toisen perustajan, Sergey Brinin, toiminnan myötä. Brin halusi myydä lasia 1500 Yhdysvaltain dollarin hintaan huippumuotituotteena tehden yhteistyötä suunnittelija Diane Von Funstenbergin kanssa, kuitenkin siinä onnistumatta. (Prevett, 2016) Vuonna 2015 Google lopetti lasien myynnin kuluttajille, mutta lääketieteen alueella niitä on kuitenkin hyödynnetty.

Googlen lasia käyttää suunnilleen 500 lääkäriä 27 osavaltiossa USA:ssa ja he pitävät niitä päässään työpäivän ajan, suoratoistamalla (streaming) videokuvaa reaaliajassa toimenpiteistä virtuaalisille puhtaaksi kirjoittajille, jotka voivat olla jopa hyvinkin kaukana toisessa maassa maailmalla. Googlen kanssa on asian tiimoilta lähtenyt yhteistyöhön San Fransiscossa toimiva startup-yritys, Augmedix. Yritys kouluttaa puhtaaksikirjoittajia kolmen kuukauden koulutusjaksoilla ja sillä on 200 puhtaaksikirjoittajaa, jotka ovat San Fransiscon alueella Yhdysvalloissa ja Bangaloren alueella Intiassa. Turvatoimet puhtaaksikirjoittajille ovat tiukat ja he joutuvat jättämään kaikki henkilökohtaiset tavaransa, kuten mobiililaitteet, kynät ja paperit jo ovella. Puhtaaksi kirjoittaminen säästää lääkärin työaikaa jopa kaksi tuntia päivittäin. Augmedix laskuttaa palveluistaan 1500 – 4000 Yhdysvaltain dollaria kuukaudessa. Puhtaaksi kirjoittamisessa ei saa tapahtua virheitä, koska seuraukset potilaan hoidossa voivat olla katastrofaaliset. Puhtaaksi kirjoittamisen jälkeen lääkärit tekevät puhtaaksi kirjoituksesta arvion, jotta voidaan olla varma, että se on tehty oikealla tavalla. (Prevett, 2016)

Toimenpiteestä Googlen lasia hyödyntäen esimerkkinä voi olla tilanne, jossa toimenpidettä tai tutkimusta tekevällä lääkärillä on Googlen lasit päässään ja hän tutkii tai operoi potilasta. Googlen lasien kautta lähetetään suoratoistona toimenpiteestä videokuvaa ja puhtaaksi kirjoittaja voi olla Intiassa, jossa Googlen kanssa yhteistyössä olevalla Augmedixillä on työntekijöitä. Tulevaisuudessa puhtaaksi kirjoitus voidaan varmasti hoitaa käyttämällä tekoälyä, joka tekee puhtaaksi kirjoittajan työn sekä lisäksi vertaa potilaan lääketieteellistä informaatiota diagnosoituihin, kenties miljooniin, tietovarastoihin tallennettuihin sairauskertomuksiin ympäri maailman ja tekee hoitoeennusteita, mitkä hoidot voisivat toimia kyseiselle potilaalle parhaiten. Edellä mainittu on tie personoituun lääketieteeseen, jossa aiempi vanhahtava ”yksi ja sama lääke kaikille potilaille” unohdetaan. (Prevett, 2016)

5 Yhteenveto

Tämä raportti käsittelee tekoälyä terveydenhuollon kentässä. Raportissa määritellään tekoälyn käsite, esitellään sen hyötyjä ja haittoja sekä menetelmiä, joita tekoälyn opettamisprosessissa voidaan käyttää, kuten muun muassa neuroverkot, kone- ja syväoppiminen. Näitä menetelmiä käyttävät tässä raportissa esitellyt tekoälyä hyödyntävät ratkaisut. Tässä raportissa tekoälyä hyödyntävät ratkaisut on jaettu viiteen eri osa-alueeseen, jotka ovat farmasia (lääkitys), insomnia (univaikeudet), kardiologia (sydänsairaudet), onkologia (syöpätapaukset) ja pulmonologia (keuhkosairaudet). Lisäksi raportissa on esitelty muutamia edellä mainittuihin kategorioihin liittymättömiä tekoälyä hyödyntäviä diagnosointiratkaisuja. Lopuksi raportissa on kursorinen katsaus terveydenhuollon tulevaisuuteen ja tulevaisuudessa oletettavasti esiintyvien teknistenkin ratkaisujen maailmaan. Tärkeitä teknologisia osa-alueita lääketieteessä ovat IoT (Internet of Things), telelääketiede, robotiikka ja tekoäly sekä virtuaalitodellisuus.

Tekoäly on periaatteessa melko vanha käsite ja se on lähtenyt kehittymään jo tietotekniikan alkuajoista saakka eli 1950-luvulta. 1980-luvulla koneoppiminen ja sen menetelmät alkoivat kukoistaa ja tietotekniikan kehittyessä mukaan tuli syväoppiminen 2010-luvulla. Syväoppiminen hyödyntää myös aiempia menetelmiä, kuten neuroverkot ja sen tavoitteena onkin luoda sopivaa algoritmia käyttäen neuroverkko, joka tähtää tietyn soveltuvan ongelman ratkaisemiseen. Syväoppimista käytetään muun muassa lääketieteen diagnostiikassa, puheen, kuvan, tekstien tunnistamisessa ja käsittelyssä. Tunnetuimpia hyödyntämisen alueita ovat Applen Siri ja Googlen Street View-palvelu. Syväoppimisen on havaittu olevan aiempia menetelmiä suorituskykyisempi datamäärän kasvaessa, joten sen suosio on kasvussa ja hyödyntäminen lääketieteen sovellusalueella on lisääntymässä uusien innovaatioiden myötä.

Tekoälyä on viime vuosina hyödynnetty useilla eri lääketieteen alueilla, joista tähän raporttiin on valittu farmasia, insomnia, kardiologia, onkologia ja pulmonologia. Farmasian alueella tekoälyä voidaan käyttää muun muassa lääkkeiden ja algoritmien kehittämisessä, uusien lääkeaineyhdisteiden etsimisessä, kuten esimerkiksi sopivan yhdistelmälääkityksen tunnistamiseen syöpätapauksien hoitamiseksi. Unihäiriöt (insomnia) on yhä useampaa aikuista vaivaava ongelma nykyajan yhteiskunnissa ja siihen on koetettu lääkehoidon lisäksi etsiä ratkaisuja. Tekoälyä on hyödynnetty unihäiriöiden ja uniapnean diagnosoinnissa, personoitujen ratkaisujen ja hoitomuotojen etsimisessä unihäiriöihin. Kardiologia eli sydänsairauksia tutkiva lääketieteen osa-alue on hyvin tärkeä, sillä sydänsairaudet etenkin länsimaissa aiheuttavat potilaille merkittävää haittaa ja ovat yksi johtavista kuolinsyistä. Tekoälyä hyödyntämällä on kehitetty tietoteknisiä järjestelmiä sydänsairauspotilaiden monitorointiin, sydämen vajaatoiminnan ennustamiseen ja diagnosointiin. Tekoälyä on voitu hyödyntää myös sydänsairaiden jäljellä olevan eliniän ennustamisessa.

Tekoälyn hyödyntäminen on laajentunut myös onkologian eli syöpätapauksien alueelle, jossa sen avulla on kyetty diagnosoimaan ihosyöpiä, aivokasvaimia, rinta- ja keuhkosyöpää. Pulmonologian alueella tekoälyä hyödyntämällä on kyetty tunnistamaan erilaisia keuhkosairauksia, kuten interstitiaalinen keuhkosairaus, pediatriinen astma ja tuberkuloosi. Lisäksi tekoälyä on voitu käyttää keuhkotoimintotestien diagnosoinnissa. Tekoälyllä on myös muita lääketieteellisiä sovellusalueita kuin edellä mainitut kategoriat ja sen avulla voidaan tunnistaa muun muassa silmäsairauksia, kuten kaihia ja sitä voidaan hyödyntää myös mielenterveydellisiin diagnooseihin, joista vaikeana mielenterveydellisenä sairautena pidetään skitsofreniaa.

Terveydenhuollon tulevaisuudesta on ennustettu, että tekoälymarkkinat terveydenhuollon alueella ylittävät kuuden miljardin rajan vuonna 2021 eli ala on vahvassa kasvussa. Tekoäly tulee muuttamaan terveydenhuollon kenttää tulevaisuudessa kenties huomattavastikin ja sen avulla voidaan tehdä tarkempia sekä nopeampia diagnooseja, löytää uusia lääkeaineyhdistelmiä, tehdä hoitosuosituksia ja myös säästää kustannuksissa. Tulevaisuudessa sairaalat tulevat olemaan täynnä teknologiaa ja robotiikkaa tullaan hyödyntämään yhä enemmän leikkauksia suoritettaessa ja jatkossa myös logistiikassa, kuten sairaalasänkyjen ja tarvikkeiden automaattiseen kuljetukseen. Sairaalasängyt voivat jatkossa kuljettaa potilasta aina ensiapuhuoneesta operointihuoneeseen saakka ja tarvittaessa kuvantamisen kautta. Tämä auttaa osaltaan vähentämään henkilöstön tarvetta.

Tulevaisuudessa tekoälyä voidaan hyödyntää myös tarvittavan hoitohenkilöstön lukumäärän määrittämiseen potilaan henkilökohtaisen tarpeen perusteella, joka voidaan määrittää käyttäen riskien monitorointia ja potilashoitoon kehitettyjä algoritmeja. Jokaisessa potilashuoneessa tulee mahdollisesti olemaan suuri näyttö seinällä, jossa on esillä potilaan digitaalinen potilastietojärjestelmä (EHR) ja interaktiiviset ohjeistukset ääniohjausta varten. Äänen tunnistusta käytetään myös lääkäreiden ohjeistuksien tallentamiseen potilaan EHR-rekisteriin käyttäen luonnollisen kielen äänentunnistusohjelmistoa. Potilaat kontrolloivat omaa EHR-rekisteriään ja toistuva informaatio tullaan poistamaan siitä. Useat kamerat tarjoavat laajan kuvakulman ja mahdollistavat potilaiden etätutkimukset. Lääkäreiden ei välttämättä tarvitse olla kaikissa tilanteissa fyysisesti läsnä, mutta heidän tulee olla kansallisesti tai kansainvälisesti lisensoituja. (Weber, 2015)

Kognitiiviset tietojenkäsittelyjärjestelmät, kuten IBM Watson auttavat lääkäreitä differentiaalisten diagnoosien tekemisessä ja näyttöön perustuvien hoitosuunnitelmien tekemisessä. Pilvipohjaista Big Dataa hyödyntävä tekoäly ja helppokäyttöinen käyttöliittymä, joka kykenee vertaamaan potilaan sairautta koskevaa informaatiota miljooniin anonyymeihin samankaltaisiin diagnoosituihin sairastapauksiin tai taudinkuviin ja maailmalla oleviin lääketieteellisiin tutkimuksiin, auttaa lääkäreitä tekemään oikeita potilaille personoituja hoitosuunnitelmia suhteellisen paljon pienemmällä vaivalla, mikä on aiemmin ollut mahdollista. (Weber, 2015) Kognitiiviset järjestelmät lisäksi oppivat jatkuvasti ja kehittyvät

jopa ”odottaessa”, sillä maailmanlaajuisesti järjestelmiin voidaan syöttää informaatiota jatkuvasti, jolloin järjestelmistä tulee yhä älykkäämpiä ja ne kykenevät diagnosoimaan sairauksia entistä paremmin ja tarjoamaan oikeanlaisia hoitosuosituksia. Tarkoituksena on hyödyntää kognitiivisia tietojenkäsittelyjärjestelmiä lääkäreiden ja muun terveydenhuollon henkilöstön apuna, jotta olisi mahdollista tehdä parempia hoitopäätöksiä tilanteissa, joissa ihmisten kyvyt eivät ole riittäviä eli järjestelmät laajentavat käsittelykykyämme ja tarjoavat mahdollisuuksia laajamittaiselle yhteistyölle.

LÄHTEET

Aliper, A., Plis, S., Artemov, A., Ulloa, A., Mamoshina, P. & Zhavoronkov, A. 2016. Deep Learning Applications for Predicting Pharmacological Properties of Drugs and Drug Repurposing Using Transcriptomic Data. American Chemical Society, Molecular Pharmaceutics, 13(7), 2524 – 2530.

Amato, F, Lopez, A., Pena-Mendez, E., M., Vanhara, P., Hampl, A. & Havel J. 2013. Artificial Neural Networks in Medical Diagnosis. Journal of Applied Biomedicine, 11(2), 47 – 58.

Ayala, L. 2016. Cybersecurity for Hospitals and Healthcare Facilities – A Guide to Detection and Prevention. USA: Apress.

Bell, J. 2014. Machine Learning: Hands-On for Developers and Technical Professionals. Wiley, 408.

Borana, J. 2016. Applications of Artificial Intelligence & Associated Technologies. Department of Electrical Engineering, Jodhpur National University. Proceeding of International Conference on Emerging Technologies in Engineering, Biomedical, Management and Science.

Bäck, A., Karttunen, A. & Pitkänen, M. 2012. Tuotantotietojen Keruu ja Hyödyntäminen Painotuotteiden Valmistuksessa. VTT Tietotekniikka.

Gao, M., Bagci, U., Lu, L., Wu, A., Buty, M., Shin, H., C., Roth, H., Papadakis, G., Z., Depeursinge, A., Summers, R., M., Xu, Z. & Mollura, D., J. 2015. Holistic Classification of CT Attenuation Patterns for Interstitial Lung Diseases via Deep Convolutional Neural Networks. Inproceedings of 1st Workshop on Deep Learning in Medical Image Analysis, 1 - 8.

Ganesan, N., Venkatesh, K., Rama, M., A. & Palani, A., M. 2010. Application of Neural Networks in Diagnosing Cancer Disease Using Demographic Data. International Journal of Computer Applications (0975 – 8887), (26)1, 76 – 85.

Guidi, G., Ladanza, E., Pettenati, M., C., Milli, M., Pavone, F. & Gentili, G., B. 2012. Heat Failure Artificial Intelligence-Based Computer Aided Diagnosis Telecare System. International Conference on Smart Homes and Health Telematics, Impact Analysis of Solutions for Chronic Disease Prevention and Management, 278 – 281.

He, Q., Zhang, P., Li, G., Dai, H. & Shi, J. 2017. The Association Between Insomnia Symptoms and Risk of Cardio-Cerebral Vascular Events: A Meta-Analysis of Prospective Cohort Studies. *European Journal of Preventive Cardiology*.

Lakhani, P. & Sundaram, B. 2017. Deep Learning at Chest Radiography: Automated Classification of Pulmonary Tuberculosis by using Convolutional Neural Networks. *Radiology*, 0(0), 1 – 9.

Li, J., Cheng, J., Shi, J. & Huang, F. 2012. Brief Introduction of Back Propagation (BP) Neural Network Algorithm and Its Improvement. *Advances in Computer Science and Information Engineering. Advances in Intelligent and Soft Computing*, 169. Springer, Berlin, Heidelberg.

Nakleh, M., K., Amal, H., Jeries, R., Broza, Y., Y., Aboud, M., Gharra, A., Ivgi, H., Khatib, S., Baderneh, S., Har-Shai, L., Glass-Marmor, L., Lejbkowitz, I., Miller, A., Badarny, S., Winer, R., Finberg, J., Cohen-Kaminsky, S., Perros, F., Montani, D., Girerd, B., Garcia, G., Simonneau, G., Nahhoul, F., Baram, S., Salim, R., Hakim, M., Gruber, M., Ronen, O., Marshak, T., Doweck, I., Nativ, O., Bahouth, Z., Shi, D., Zhang, W., Hua, Q., Pan, Y., Tao, L., Liu, H., Karban, A., Koifman, E., Rainis, T., Skapars, R., Sivins, A., Ancans, G., Liepniece-Karele, I., Kikuste, I., Lasina, I., Tolmanis, I., Johnson, D., Millstone, S., Z., Fulton, J., Wells, J., W., Wilf, L., H., Humbert, M., Leja, M., Peled, N. & Haick, H., 2017. Diagnosis and Classification of 17 Diseases from 1404 Subjects via Pattern Analysis of Exhaled Molecules. *ACS Publications, American Chemical Society*, 112 – 125.

Ng, K., Steven, R., deFilippi, C., Dey, S. & Walter, F., S. 2016. Early Detection of Heart Failure Using Electronic Health Records: Practical Implications for Time Before Diagnosis, Data Diversity, Data Quantity, and Data Density. *Circulation Cardiovascular Quality and Outcomes*, 9(6), 649 – 658.

Pathinarupothi, R., K., Vinayakumar, R., Rangan, E., Gopalakrishnan, E. & Soman, K., P. 2017. Instantaneous Heart Rate as a Robust Feature for Sleep Apnea Severity Detection Using Deep Learning. *IEEE EMBS International Conference on Biomedical & Health Informatics (BHI)*, 293 – 296.

Prince, M. & Felder, R. 2007. The Many Faces of Inductive Teaching and Learning. *Journal of College Science Teaching*, 36(5), 14 – 20.

Rajan, J. R. & Chelvan, C. A. 2017. Prognostic System for Early Diagnosis of Pediatric Lung Disease Using Artificial Intelligence. *Current Pediatric Research*, 21(1), 31 – 34.

Saarinen, E. 1999. Symposium. Helsinki: WSOY.

Shivajirao, S. & Tasgoankar. Y. 2017. Brain MR Image Segmentation for Tumor Detection Using Artificial Neural Network. International Journal of Engineering and Computer Science, 6(1), 20160 – 20163.

Sourla, E., Sioutas, S., Syrimpeis, V., Tsakalidis, A. & Tzimas, G. 2012. Cardiosmart365: Artificial Intelligence in the Service of Cardiologic Patients. Advances in Artificial Intelligence.

Zhao, R., Song, W., Zhang, W., Xing, T., Lin, J., Srivastava, M., Gupta, R. & Zhang, Z. 2017. Accelerating Binarized Convolutional Neural Networks with Software-Programmable FPGAs. Proceedings of the 2017 ACM/SIGDA International Symposium on Field-Programmable Gate Arrays, 15 – 24, Monterey, California, USA.

Internet-lähteet:

13D Research. Artificial Intelligence is on the Precipice of Revolutionizing Medical Diagnosis. Viitattu 21.4.2017 <https://latest.13d.com/artificial-intelligence-is-on-the-precipice-of-revolutionizing-medical-diagnosis-be6427239f58>

Aguilar. 2017. "Taking Advantage of the Possibilities Offered by Artificial Intelligence is Essential for Public Health to Stop Managing the Disease and Move Towards Generating Health". Customer Case Study, the Institute of Sanitary Research of the San Carlos Clinical Hospital, Madrid, Spain. Viitattu 6.6.2017 http://www.fujitsu.com/fi/Images/CS_2017Apr_IdISSC_San-Carlos-Hospital_Eng_v.1.pdf

Akagi, D. 2014. A Primer on Deep Learning. Viitattu 16.5.2017 <https://www.datarobot.com/blog/a-primer-on-deep-learning>

Allen, K. 2016. How Artificial Intelligence Could Transform the Medical World. Thestar. Viitattu 26.5.2017 <https://www.thestar.com/news/world/2016/05/09/the-power-of-artificial-thinking.html>

Bask, J. & Nuopponen, A. 1998. Neuroverkot. Teknillinen korkeakoulu. Viitattu 17.5.2017 http://www.tml.tkk.fi/Studies/Tik-110.300/1998/Newtech/neuroverkot_3.html

Bell, K. 2017. Rythm Unveils AI Platform Morpheo to Help Diagnose Sleep Disorders. Viitattu 3.5.2017 http://www.firstwordmedtech.com/node/995566?region_id=3

Binetskaya, H. How Artificial Intelligence Will Change Disease Diagnosis, Part 1: Where We Stand. Viitattu 27.4.2017 <https://vunela.com/how-artificial-intelligence-will-change-lung-disease-diagnosis-part-1-where-we-stand-52ce7827016d>

Brogan, C. 2017. Artificial Intelligence Creates 3D Hearts to Predict Patient Survival. Imperial College, London. Viitattu 3.5.2017 http://www3.imperial.ac.uk/newsandeventspggrp/imperialcollege/newssummary/news_16-1-2017-16-52-39

Brownlee, J. 2016. What is Deep Learning? Viitattu 16.5.2017 <http://machinelearningmastery.com/what-is-deep-learning>

Buczowski, A. 2017. What's the Difference Between Artificial Intelligence, Machine Learning and Deep Learning? Viitattu 31.5.2017 <http://geoawesomeness.com/whats-difference-artificial-intelligence-machine-learning-deep-learning>

Burns, J. 2016. Artificial Intelligence Is Helping Doctors Find Breast Cancer Risk 30 Times Faster. Viitattu 20.4.2017 <https://www.forbes.com/sites/janetwburns/2016/08/29/artificial-intelligence-can-help-doctors-assess-breast-cancer-risk-thirty-times-faster/#109a5bf75908>

CardioSmart365: Monitoring and Early Notification System for Heart Diseases. Viitattu 4.5.2017 <http://biodata.gr/cardiosmart365/website/About.aspx>

Chan, L. 2016. Will Robots In Healthcare Make Doctors Obsolete? Viitattu 26.5.2017 <http://www.techtimes.com/articles/131870/20160209/will-robots-in-healthcare-make-doctors-obsolete.htm>

Copeland, M. 2016 . What's the Differene Between Artificial Intelligence, Machine Learning, and Deep Learning. Viitattu 16.5.2017 <https://blogs.nvidia.com/blog/2016/07/29/whats-difference-artificial-intelligence-machine-learning-deep-learning-ai>

CyberPsychology. 2016. Mind, Cognition and Society in the Digital Age – Now, AI Helps in Diagnosing Lung Diseases. Viitattu 27.4.2017 <http://cyberpsychology.in/now-ai-helps-diagnosing-lung-diseases>

Desai, A. 2016. The Future of Healthcare: IoT, Telemedicine, Robots & Artificial Intelligence. eInfochips. Viitattu 26.5.2017 <https://www.einfochips.com/blog/the-future-of-healthcare-iot-telemedicine-robots-artificial-intelligence>

Dettmers, T. 2015. Deep Learning in a Nutshell: Core Concepts. Viitattu 17.5.2017 <https://devblogs.nvidia.com/paralleforall/deep-learning-nutshell-core-concepts>

Duodecim. 2016. Unettomuus. Viitattu 19.5.2017 http://www.terveyskirjasto.fi/terveyskirjasto/tk.koti?p_artikkeli=ltt03614

EIO. 2016. Artificial Intelligence: The Future of Medicine? Technology and Operations Management, Harvard Business School. Viitattu 29.5.2017 <https://rctom.hbs.org/submission/artificial-intelligence-the-future-of-medicine>

Elemento, O. 2017. Artificial Intelligence Helps Identify Effective Cancer Drug Combinations. Institute of Computational Biomedicine, Weill Cornell Medicine. Viitattu 9.5.2017 <https://news.weill.cornell.edu/news/2017/02/artificial-intelligence-helps-identify-effective-cancer-drug-combinations>

European Lung Foundation. 2016. Artificial Intelligence Could Improve Diagnostic Power of Lung Function Tests. Science Daily. Viitattu 26.4.2017 <https://www.sciencedaily.com/releases/2016/09/160904181255.htm>

Freiherr, G. 2015. Artificial Intelligence: Humankind's Best Chance for a Healthier Future. CIO, IDG Contributor Network. Viitattu 30.5.2017 <http://www.cio.com/article/2997174/big-data/artificial-intelligence-humankinds-best-chance-for-a-healthier-future.html>

Fujitsu. 2017. Fujitsu's Human-Centric AI Helps Enable Faster, Improved Clinical Decision-Making. Viitattu 6.6.2017 <http://www.fujitsu.com/fts/about/resources/news/press-releases/2016/emeai-03112016-fujitsu-enables-faster-improved-clinical.html>

Fukushige, Y. Representing Probabilistic Knowledge in the Semantic Web. Matsushita Electronic Industrial Co, Ltd. Viitattu 26.2.2018 <https://www.w3.org/2004/09/13-Yoshio/PositionPaper.html>

Geniuspharm. 2017. Cosy Robot Pillow Somnox Helps Fight Insomnia. Viitattu 23.5.2017 <http://geniuspharm.com/health-tips/cosy-robot-pillow-somnox-helps-fight-insomnia.html>

Hernandez, D. Artificial Intelligence is Now Telling Doctors How to Treat You. Kaiser Health News. Viitattu 26.5.2017 <https://www.wired.com/2014/06/ai-healthcare>

Hunter, J. 2016. How Artificial Intelligence is the Future of Pharma. Drug Target Review. Viitattu 26.4.2017 <https://www.drugtargetreview.com/news/15400/artificial-intelligence-drug-discovery>

IBM. 2017. At ASCO 2017 Clinicians Present New Evidence about Watson Cognitive Technology and Cancer Care. IBM News Releases. Viitattu 12.6.2017 <http://www-03.ibm.com/press/us/en/pressrelease/52502.wss>

Idel, H. 2017. SleepASAP – Sleep All Your Problems Away. Viitattu 5.5.2017 <https://www.indiegogo.com/projects/sleepasap-tailored-sleep-solutions#>

Jaiprakash, A., Roberts, J. & Crawford, R. 2016. Robots in Health Care Could Lead to a Doctorless Hospital. Viitattu 26.5.2017 <http://theconversation.com/robots-in-health-care-could-lead-to-a-doctorless-hospital-54316>

Järnefelt, H. 2017. Uni – Psykologiset Hoitomuodot Tehoavat Unettomuuteen. Tieteessä katsaus. Viitattu 19.5.2017 <http://www.potilaanlaakarilehti.fi/site/assets/files/0/10/60/889/sll122017-776.pdf>

Kannan, P., V. 2017. Artificial Intelligence – Applications in Healthcare. Asian Hospital & Healthcare Management. Viitattu 30.5.2017 <https://www.asianhnm.com/technology-equipment/artificial-intelligence>

Livernois, C. 2017. EHRs Could Be Crystal Ball in Predicting Heart Failure. Clinical Innovation+Technology. Viitattu 22.5.2017 <http://www.clinical-innovation.com/topics/ehr-emr/ehrs-could-predict-heart-failure>

Long, E. 2017. Artificial Intelligence for Diagnosing a Rare Eye Disease. Nature Biomedical Engineering. Viitattu 9.5.2017 <https://nbmecomcommunity.nature.com/users/24989-erping-long/posts/14653-translating-artificial-intelligence-into-a-rare-eye-disease>

Mandal, A. 2014. What is Cardiology? Medical Life Sciences. Viitattu 19.5.2017 <http://www.news-medical.net/health/Cardiology-What-is-Cardiology.aspx>

McShane. 2016. The Future of Surgery is Robotic, Data-Driven, and Artificially Intelligent. SingularityHub, Exponential Medicine. Viitattu 29.5.2017 <https://singularityhub.com/2016/10/11/the-future-of-surgery-is-robotic-data-driven-and-artificially-intelligent>

Murphy, B., J. 2015 Artificial Intelligence Combats Cancer by Identifying Effective Drug Combinations. Viitattu 26.4.2017 <http://www.seriouswonder.com/artificial-intelligence-combats-cancer>

Nature Biomedical Engineering. 2017. Artificial Intelligence Can Diagnose Congenital Cataract. American Academy of Ophthalmology. Viitattu 9.5.2017 <https://www.aao.org/headline/artificial-intelligence-can-diagnose-congenital-ca>

O'Hear, S. 2015. Your.MD Scores \$5M For Its AL-Driven Health Assistant. Viitattu 3.5.2017 <https://techcrunch.com/2015/07/01/your-md>

Oliver, S. 2015. Artificially-intelligent Robot Scientist 'Eve' Could Boost Search for New Drugs. University of Cambridge. Viitattu 26.4.2017 <http://www.cam.ac.uk/research/news/artificially-intelligent-robot-scientist-eve-could-boost-search-for-new-drugs>

Pathway Genomics. 2016. The Future of Medicine – The Next Ten Years. Viitattu 28.5.2017 <https://www.pathway.com/the-future-of-medicine>

Parloff, R. 2016. Why Deep Learning is suddenly Changing Your Life. Viitattu 16.5.2017 <http://fortune.com/ai-artificial-intelligence-deep-machine-learning>

Pate, B. 2017. How Artificial Intelligence Could Diagnose Schizophrenia. Viitattu 25.5.2017 <https://digitalculturist.com/how-artificial-intelligence-could-diagnose-schizophrenia-cda01ef9ba74>

Pharma Scandinavia. Kardiologia. Viitattu 19.5.2017 <http://www.poapharma.com/fi/departments/kardiologia>

Perry. How Artificial Intelligence Will Revolutionize Healthcare. Viitattu 26.5.2017 <http://bigthink.com/philip-perry/how-artificial-intelligence-will-revolutionize-healthcare>

Poole, D. & Mackworth, A. 2010. Artificial Intelligence – Foundations of Computational Agents. Viitattu 27.2.2018 http://artint.info/html/ArtInt_177.html

Powell, J. 2015. Do Robots Feature in the Future of Medicine? The Telegraph. Viitattu 30.5.2017 <http://www.telegraph.co.uk/sponsored/education/festival-of-the-imagination/11921755/will-robots-take-over.html>

Prevett, R. 2016. The Future of Health is in Artificial Intelligence and Virtual Reality – AR and AI Converge Offering More Accurate and Timely Diagnosis. Viitattu 28.5.2017 <https://disruptionhub.com/future-health-artificial-intelligence-virtual-reality>

PR Newswire. 2017. Rythm Unveils Morpheo, The First AI Platform That Helps Diagnose Sleep Disorders. Viitattu 3.5.2017 <https://finance.yahoo.com/news/rythm-unveils-morpheo-first-ai-171100856.html>

Roberts, F. 2017. AI Machine Diagnoses Skin Cancer, Could be Used in Smartphones. Viitattu 20.4.2017 <https://internetofbusiness.com/ai-machine-diagnoses-skin-cancer>

Rodriguez. 2016. Artificial Intelligence in Clinical Care: Promise and Caution. CardiologyAdvisor. Viitattu 26.5.2017 <http://www.thecardiologyadvisor.com/practice-management/artificial-intelligence-medicine/article/580470>

Rutkin, A. 2016. Smart Medicine is Coming of Age, But Will Doctors Bite? Technology News. <https://www.newscientist.com/article/mg23130892-500-smart-medicine-is-coming-of-age-but-will-doctors-bite>

Sanofi. 2005. Sydän- ja verisuonitaudit. Viitattu 19.5.2017 <http://www.sanofi.fi/l/fi/fi/layout.jsp?scat=B24F9335-4D38-4E42-87A6-9ACBE5322E6F>

Sarkar, S. 2016. How to Use Machine Learning in Today's Enterprise Environment. Viitattu 16.5.2017 <http://readwrite.com/2016/11/09/machine-learning-used-pl1>

SAS. Machine Learning – What It Is and Why It Matters. Viitattu 16.5.2017 https://www.sas.com/en_us/insights/analytics/machine-learning.html

Shamah, D. 2015. Israeli Tech Cracks 'sleep DNA' to Beat Insomnia. The Times of Israel. Viitattu 4.5.2017 <http://www.timesofisrael.com/israeli-tech-cracks-sleep-dna-to-beat-insomnia>

Stergiou, C. & Siganos, D. Neural Networks. Imperial College London, Department of Computing. Viitattu 15.5.2017 https://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html#Introduction%20to%20neural%20networks

Somnox. 2017. Somnox Realizing Dreams – The Best Night of Sleep Without Medication. Viitattu 23.3.2017 <https://www.somnox.nl>

Tan, R. 2017 AI Matches Doctor's Ability to Diagnose Rare Eye Disease. Asian Scientist – News and Information from the Asian Scientific Community. Viitattu 9.5.2017 <https://www.asianscientist.com/2017/02/tech/ai-diagnose-congenital-cataract>

Tjoa, S. Introduction to Deep Learning. Viitattu 16.5.2017 https://ccrma.stanford.edu/workshops/mir2013/CCRMA_MIR2013_DBN.pdf

Tucker, E. 2017. Robotic Somnox Pillow Gently "Breathes" to Soothe Users to Sleep. Viitattu 23.3.2017 <https://www.dezeen.com/2017/02/20/robotic-somnox-pillow-gently-breathes-soothe-users-sleep-design-technology>

Tutorialspoint. 2017. Artificial Intelligence – Neural Networks. Viitattu 15.5.2017 https://www.tutorialspoint.com/artificial_intelligence/artificial_intelligence_neural_networks.htm

UFLDL Tutorial. 2017. Convolutional Neural Network. Viitattu 17.5.2017 <http://ufldl.stanford.edu/tutorial/supervised/ConvolutionalNeuralNetwork>

Waltz, E. 2017. IBM, Intel, Stanford Bet on AI to Speed up Disease Diagnosis and Drug Discovery. IEEE Spectrum's biomedical blog. Viitattu 26.4.2017 <http://spectrum.ieee.org/the-human-os/biomedical/diagnostics/ibm-intel-stanford-bet-on-ai-to-speed-up-disease-diagnosis-and-drug-discovery>

Weber, D., O. 2015. 12 Ways Artificial Intelligence Will Transform Health Care. H&HN Hospitals & Health Networks. Viitattu 31.5.2017 <http://www.hhnmag.com/articles/6561-ways-artificial-intelligence-will-transform-health-care>

Your.MD. 2017. Take Control of Your Health – Your.MD Gives You Personal, Trusted and Actionable Information – Instantly. Viitattu 3.5.2017 <https://www.your.md>

Ziden, K. 2016 The Future of AI in Healthcare: No Doctors Required. CReST Blog, Potomac Institute for Policy Studies Center for Revolutionary Scientific Thought. Viitattu 26.5.2017 <https://potomacinstituteceo.wordpress.com/2016/09/12/the-future-of-ai-in-healthcare-no-doctors-required>

Informaatioteknologian tiedekunnan julkaisu
No. 45/2018

ISBN 978-951-39-7360-5 (verkkoj.)
ISSN 2323-5004