

Terveydenhuollon alustat ja tekoäly



Informaatioteknologian tiedekunnan julkaisuja
No. 48/2018

Editor: Pekka Neittaanmäki

Covers: Petri Vähäkainu ja Matti Savonen

Copyright © 2018

Petri Vähäkainu, Pekka Neittaanmäki ja Jyväskylän yliopisto

ISBN 978-951-39-7366-7 (verkkokj.)

ISSN 2323-5004

Jyväskylä 2018

Terveydenhuollon alustat ja tekoäly

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

LYHENNELISTA

AI	Artificial Intelligence eli tekoäly
ANN	Artificial Neural Network eli keinotekoinen neuroverkko
BLE	Bluetooth Low Energy tarkoittaa lyhyen kantaman vähän virtaa kuluttavaa langatontasensoriverkkotekniikkaa
BP	The Back Propagation Neural Network Algorithm on iteratiivinen, laskevan
CNN	Convolutional Neural Network eli konvoluutioneuroverkko
COPD	Chronic Obstructive Pulmonary Disease tarkoittaa yleensä tupakointiin liittyvää, hitaasti etenevää keuhkosairautta, keuhkoauhtaumatautia
CAM	Content Addressable Memory eli muistityyppi, joka toimii hakukoneen tavoin
CPU	Central Processing Unit eli keskusyksikkö
DARPA	Defence Advanced Research Projects Agency on Yhdysvaltain puolustusministeriön tutkimusta tekevä ja rahoittava organisaatio
DNN	Deep Neural Networks ovat monikerrosjärjestelmiä, jotka koostuvat datamuunnoksia suorittavista yhdistetyistä ja interaktiivisista neuroneista
DTMF	Dual-tone Multi-Frequency on puhelinlaitteissa käytetty numeroiden äänitaajuustapa, jossa kukin numero on koodattu kahdeksi ääneksi
EHR	Electronic Health Record eli digitaalinen potilaskertomusjärjestelmä
FFN	Feed Forward Neural Network tarkoittaa eteenpäin syöttävää neuroverkkoa
GPU	Graphical Processing Unit eli grafiikkaprosessori
HDP	Health Device Profile eli terveyslaitteprofiili
HDSM	Healthcare Decision Support System on terveydenhuollon päätöksentekijärjestelmä
HIPAA	Health Insurance Portability and Accountability Act on Yhdysvaltojen terveystakuutuksen siirrettävyyys- ja vastuullisuuslaki
HRV	Heart Rate Variation tarkoittaa sydämen sykkeen vaihtelua
HTTPS	Hypertext Transfer Protocol Secure on HTTP- ja SSL-protokollan yhdistelmä, jota käytetään tiedon suojattuun siirtoon Internetissä (WWW)
IDE	Integrated Development Environment on integroitu kehitysympäristö, joka tarjoaa työkaluja kliinisten protokollien ja moottoreiden rakentamiseen
IoT	Internet of Things eli teollinen Internet tarkoittaa Internet-verkon laajentumista laitteisiin ja koneisiin, joita voidaan ohjata Internet-verkon yli
IoMT	Internet of Medical Things tarkoittaa esineiden Internetiä lääketieteellisessä kontekstissa
IVR	Interactive Voice Response tarkoittaa automatisoitua vastausjärjestelmää, jossa asiakasta opastetaan näppäimin hoitamaan palvelunsa itsenäisesti
MLP	Multi-Layered Perceptron eli monikerrosperseptroni on eteenpäin syöttävän FFN-verkon perseptroni, jossa on yksi tai useampia piilokerroksia
NFC	Near Field Communication on lyhyen matkan langaton tiedonsiirtoteknologia, joka hyödyntää RFID-tekniikkaa

PHD	Private Health Device tarkoittaa henkilökohtaisia terveysteknologisia laitteita
PPT	Push-to-talk on yhteysmuoto, jolla voidaan luoda yksisuuntaisia (half-duplex) puheyhteyksiä joko henkilöiden välillä tai broadcast-muotoisesti lähettämällä
RFID	Radio Frequency Identification on radiotaajuinen etätunnistuksen menetelmä tiedon etälukuun ja –tallentamiseen käyttäen RFID-tunneisteita eli tägejä.
RTLS	Real Time Location System tarkoittaa reaaliaikaista paikannusjärjestelmää
SaaS	Software as a Service tarkoittaa ohjelmiston hankkimista palveluna perinteisen lisenssipohjaisen tavan ja ohjelmiston asentamisen sijaan
SAMI	Samsung Architecture for Multimodal Interactions on Applen Siriä muistuttava alusta, joka yhdistelee, kerää, analysoi ja jakaa käyttäjiensä terveysdataa
SDK	Software Development KIT on sovellussuunnittelijoille tarkoitettu ohjelmistokehityspaketti
SGD	Stochastic Gradient Descent tarkoittaa gradientin laskemista, jossa neuroverkolle annetaan esimerkkisyöte ja verrataan tulostetta haluttuun
SIP	Session Initiation Protocol on IP-puhelinyhteyksien luonnista vastaava tietoliikenneprotokolla, joka on korvaamassa aiemman H.323-protokollan
SLP	Single-Layer Perceptron tarkoittaa yksikerroksista perseptronia, joka tarkoittaa neuroverkkoa, jossa on vain feedforward-yhteyksiä
SPP	Serial Port Profile of Bluetooth perustuu ETSI 07.10- ja RFCOMM-protokolliin ja se emuloi RS-232 toimintaa muodostaen virtuaalisen Bluetooth-yhteyden
SSL	Secure Sockets Layer on tietoverkkosalausprotokolla
SVM	Support Vector Machine on 1990-luvulla kehitetty lineaarinen luokitinmalli, joka soveltuu luokitteluun ja käyränsovitustehtävään
TDA	Topological Data Analysis viittaa aineistojen analyysiä varten kehitettyihin topologiaa hyödyntäviin teknologioihin
VMS	Voice Messaging System vastaa Inhealthcare-alustan soittojen hallinnasta
WHO	World Health Organization on ihmisten terveyteen keskittyvä Yhdistyneiden kansakuntien järjestö, joka perustettiin Genevessä 1948

KUVIOT

KUVIO 1. KEHITYSKULKU TEKOÄLYSTÄ SYVÄOPPIMISEEN.	3
KUVIO 2. TEKOÄLYN HYÖDYNTÄMISEN ALUEITA.	4
KUVIO 3. TURINGIN TESTI.	5
KUVIO 4. TEKOÄLYN JAKO SOVELLUSALUEISIIN JA NIIDEN KÄYTTÄMIÄ MENETELMIÄ.	5
KUVIO 5. TEKOÄLYN JAKAUTUMINEN ERILAISIEN MENETELMIEN OSA-ALUEISIIN.	7
KUVIO 6. HERMOSOLUN SEMANTIikka.	9
KUVIO 7. ETEENPÄIN SYÖTTÄVÄ NEUROVERKKO.	10
KUVIO 8. TAKAISINKYTKETTY NEUROVERKKO.	10
KUVIO 9. YKSINKERTAINEN KEINOTEKOINEN NEUROVERKKO.	10
KUVIO 10. ESIMERKKI YHDEN PIILOKERROKSEN JA NELJÄN NEURONIN NEUROVERKOSTA.	11
KUVIO 11. YKSIKERROKSIINEN PERSEPTRONI JA VIESTIN VÄLITYS NEURONIEN VÄLILLÄ.	12
KUVIO 12. AKTIVOINTIFUNKTION LASKEMINEN VERKON PARAMETREISTA.	12
KUVIO 13. KEINOTEKOINEN NEUROVERKKO SIGMOID-FUNKTIOLLA JA PAINOKERTOIMET.	13
KUVIO 14. ESIMERKKI ANN-NEUROVERKOSTA KÄSIALALLA KIRJOITETUN NUMERON TUNNISTAMISESSA.	13
KUVIO 15. NEUROVERKON TESTAAMINEN ERILAISELLA DATALLA KUIN OPETUSDATA.	14
KUVIO 16. OHJATUN OPPIMISEN PERIAATE.	15
KUVIO 17. LOKAALIN MINIMIN ONGELMA JA GLOBAALI MINIMI.	17
KUVIO 18. CNN-NEUROVERKKO.	17
KUVIO 19. KONVOLUUTIOVERKKOJEN TOIMINTA KUVANTUNNISTUKSESSA.	18
KUVIO 20. CNN-NEUROVERKON OPETTAMINEN KUVADATAN PERUSTEELLA.	19
KUVIO 21. KONVOLUUTIONEUREVERKON OPETTAMINEN AIEMMAN DATAN AVULLA.	19
KUVIO 22. KONVOLUUTIONEUREVERKON OPETTAMINEN OMINAISUUKSIA POIMIMALLA.	20
KUVIO 23. NEUROVERKKOJEN KOKO.	20
KUVIO 24. DEDUKTIIVISTA PÄÄTTELYÄ HYÖDYNTÄVÄ PUU.	21
KUVIO 25. KONEOPPIMISEN ALGORITMIEN YLEISIMMÄT TYYPIT.	22
KUVIO 26. OPPIMISEN TYYPEJÄ JA KONEOPPIMISEN MENETELMIEN LUOKITTELU.	23
KUVIO 27. YKSINKERTAINEN PÄÄTÖSPUU.	24
KUVIO 28. ESIMERKKI BAYERS-VERKOSTA.	25
KUVIO 29. KONEOPPIMISEN SOVELLUSALUEITA ERI TEOLLISUUDENALOILLA.	25
KUVIO 30. SYVÄOPPIMISEN PROSESSI.	26
KUVIO 31. SYVÄOPPIMISEN VS VANHEMPIEN TEKNOLOGIOIDEN SKAALAUTUVUUS.	27
KUVIO 32. TEKOÄLYJÄRJESTELMÄN OSIEN YHTEYS TOISIINSA.	28
KUVIO 33. CONTACT HEALTHCARE DIGITAALINEN TERVEYDENHUOLLON ALUSTA.	32
KUVIO 34. DIGITAALISET LOMAKKEET.	33
KUVIO 35. TIETOVARASTOINTIRATKAISU JA DATAN VISUALISOINTI KOJELAUTOIHIN.	33
KUVIO 36. PAIKKATIETOINEN VIESTITYSPALVELU.	34
KUVIO 37. BLE-YHTEYDELLÄ TOIMIVA LÄÄKITYSHOITOON SITOUTUMISTA TUKEVA DOSETTI.	35
KUVIO 38. POTILAAN JA THL-AMMATTILAISEN KOMMUNIKOINTI ALUSTAN AVULLA.	37
KUVIO 39. INHEALTHCARE-ALUSTAN TOIMINTA JA AMAZON POLLY.	39
KUVIO 40. INHEALTHCAREN KANSALLINEN DIGITAALINEN TERVEYSALUSTA.	41
KUVIO 41. MINING MINDS-ALUSTAN ARKKITEHTUURIKAAVIO.	43
KUVIO 42. SAMI-ALUSTAN MITTAUSSENSOREITA.	44

KUVIO 43. SAMI-ALUSTAN TOIMINTAPERIAATE.	45
KUVIO 44. U-HEALTH-ALUSTAN ARKKITEHTUURI.	46
KUVIO 45. KODIN JA U-HEALTH-ALUSTAN VÄLISEN YHDYSKÄYTVÄN TOIMINTAPERIAATE.	47
KUVIO 46. ACCOLADEN TEKOÄLYÄ JA KONEOPPIMISTA HYÖDYNTÄVÄ ALUSTA.	48
KUVIO 47. AKILAN TEKOÄLYÄ HYÖDYNTÄVÄ KOGNITIIVINEN OPPIMISSILMUKKA.	49
KUVIO 48. ALERTEN TEKOÄLYÄ HYÖDYNTÄVÄ REAALIAIKAINEN DATA-ANALYTIikka.	50
KUVIO 49. APIXIO HCC-PROFILERIN TOIMINTAPERIAATE.	51
KUVIO 50. HCC-PROFILERIN KOJELAUTANÄKYMÄ.	52
KUVIO 51. AYASDIN ARKKITEHTUURI.	54
KUVIO 52. NELJÄ ESIMERKKIÄ DATAN MUODOISTA.	54
KUVIO 53. CARESKORE-ARKKITEHTUURIKAAVIO.	55
KUVIO 54. DIABNEXT-ALUSTAN KÄYTTÖLIITTYMÄ.	57
KUVIO 55. DIABNEXT-ALUSTAN TARJOAMAT PALVELUT.	58
KUVIO 56. SYÖTYJEN HIILIHYDRAATTIEN MÄÄRÄN ARVIOINTI DIABNEXT-ALUSTAN AVULLA.	59
KUVIO 57. DOC.AI-TEKOÄLYALUSTAN MOBIILISOVELLUKSEN KÄYTTÖLIITTYMÄ.	61
KUVIO 58. MORPHEO-ALUSTAN MONITOROINTI-IKKUNA.	62
KUVIO 59. SYVIEN NEUROVERKKOARKKITEHTUURIEN VISUALISOINTI KÄYTTÖLIITTYMÄ.	64

SISÄLLYSLUETTELO

1	Johdanto	1
2	Tekoäly – koneoppimisesta syväoppimiseen	3
2.1	Tekoälyn määritelmä	4
2.2	Tekoälyn hyötyjä ja haittoja	6
2.3	Tekoäly ja oppiminen	6
2.3.1	Neuroverkot	8
2.3.2	Koneoppiminen	20
2.3.3	Syväoppiminen	25
2.4	Tekoälyn hyödyntämisen alueita	28
3	Terveydenhuollon alustat ja tekoäly	30
3.1	Terveydenhuollon alustan määritelmä	30
3.2	Tekoälyn hyötyjä terveydenhuollon ekosysteemeissä	31
3.3	Terveydenhuollon alustoja ja mobiiliteknologiaa	32
3.3.1	Comtact Healthcaren digitaalinen alusta	32
3.3.2	HealthSaaS kognitiivinen IoT-alusta potilasmonitorointiin	35
3.3.3	Inhealthcare digitaalinen terveydenhuoltoalusta	38
3.3.4	Mining Minds-alusta	41
3.3.5	Samsung SAMI terveydenhuollon palvelualusta	44
3.3.6	U-Health Platform Using Home Health Gateway	45
3.4	Tekoälyä hyödyntäviä terveydenhuollon alustoja	47
3.4.1	Accolade Intelligence Platform	47
3.4.2	Akila Health Coach esidiabeteksen ehkäisyyn	48
3.4.3	Alerte Mobile Health Platform	50
3.4.4	Apixio Iris-tekoälyalusta ja HCC-profiler	50
3.4.5	Ayasdi Envision-tekoälyalusta	53
3.4.6	CareSkore	55
3.4.7	Diabnext-tekoälyalusta diabeteksen hallintaan	56
3.4.8	Doc.ai hajautettu tekoälyalusta	59
3.4.9	Morpheo-tekoälyalusta unihäiriöiden diagnosoinnissa	61
3.4.10	Morpheo-tekoälyalusta unihäiriöiden diagnosoinnissa	63
4	Tulevaisuus	65
5	Yhteenveto	66
	Lähteet	68

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. (Kannan, 2017)

Tekoäly mahdollistaa suurten datamäärien varastoinnin ja prosessoinnin älykkäällä tavalla sekä nimenomaan relevanttiutta informaation muuntamiseen funktionaaliseksi työkaluiksi. Tekoälyä on käytetty hyvin monella sovellusalueella, joista tunnetuimpia kenties ovat puolustus ja avaruuden tutkimus. Niissä menestys ongelmien ratkaisemisessa tietyillä osa-alueilla on ollut menestyksestä. Tekoälyn sovellusalue on sittemmin laajentunut terveydenhuoltoon, jossa sitä hyödynnetään muun muassa diagnosoinnissa, hoitosuosituksen tekemisessä, leikkaushoidossa. (Kannan, 2017)

Tekoälyä ei kuitenkaan voida terveydenhuollossa hyödyntää, ellei sitä ennen ole kerätty riittävästi potilasdataa. Tarvitaan myös olemassa olevia IT-alustoja, joiden päälle voidaan rakentaa myös tekoälyä hyödyntäviä sovelluksia ja palveluita, joita voidaan hyödyntää terveydenhuollon palveluissa. Alussa keskityttiin palveluiden keskittämiseen yhteen paikkaan. Siten kehittyi muun muassa erikoissairaanhoidon, kuvantamispalvelut, kliininen tutkimus ja koulutus, datan kerääminen ja tiedon varastointi. Nyt ollaan uudessa muutosvaiheessa, jossa palveluita pikkuhiljaa eriytetään. Uusia eriytettyjä palveluita on esimerkiksi kotimonitorointi, langattomat lääketieteen laitteet ja mobiilit hoitopalvelut. Seuraavaksi alkaa vähän kerrassaan tapahtua palvelujen hajauttamista, jolloin eriytetään muun muassa palveluita, kuten kotimonitorointi, langattomat lääketieteelliset laitteet, hyvinvointiohjelmat, etäterveydenhoito, automatisoidut kioskit, mobiilit hoitopalvelut.

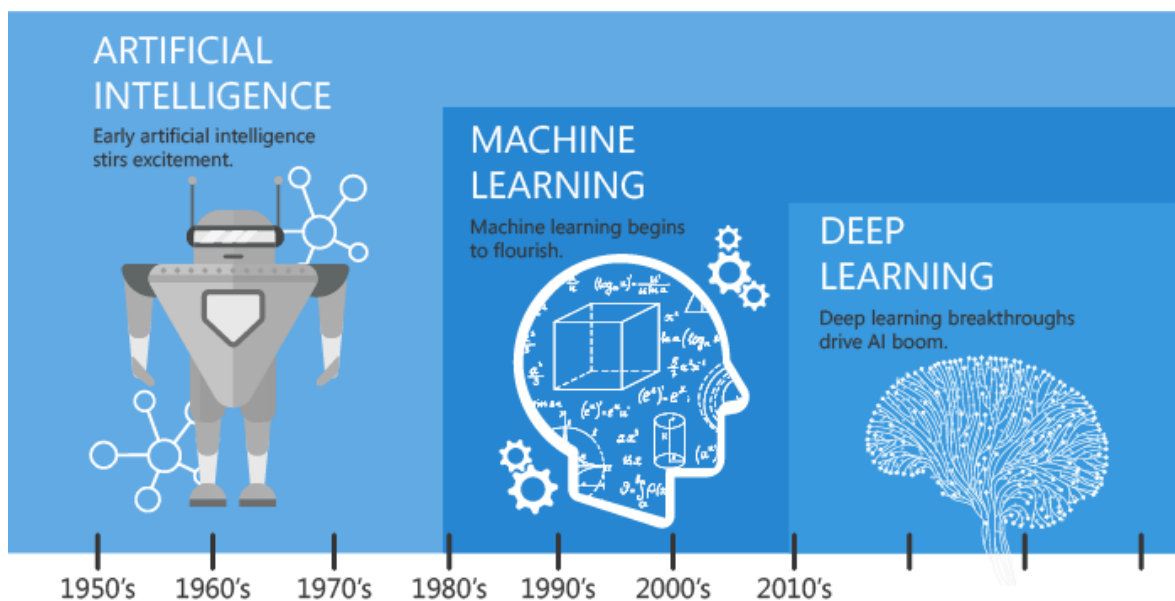
Tällä hetkellä ihmisistä kerätään paljon informaatiota, joka on hajautettua useisiin eri paikkoihin ja se olisi tarpeen yhdistää. Informaatio on hajaantunut esimerkiksi finanssipalveluihin, tavanomaiseen ruokakauppaan, kotihoitoon, sairaaloihin, apteekkiin, kuntokeskuksiin ja erilaisille asiantuntijapalveluita tarjoaville tahoille. Erilaisilta toimijoilta tulevan datan yhdistäminen yhteen paikkaan ja sen hyödyntäminen aivan uudenlaisten myös tekoälyä hyödyntävien palveluiden toteuttamisessa voi johtaa huomattaviin parannuksiin potilashoidon ja turvallisuuden parantumisessa. Lisäksi se voi tuottaa huomattavia kustannussäästöjä. Edellä mainitun toteuttamiseen tarvitaan toimivia terveydenhuollon IT-alustoja, joihin terveydenhuollon palvelujen tarjoajat voivat toteuttaa sovelluksia kyeten tehokkaasti hyödyntämään eri lähteistä tulevaa dataa.

Tämän raportin tarkoituksena on esitellä terveydenhuollon informaatioteknisiä alustoja ja mobiiliteknologiaa sekä tekoälyä hyödyntäviä terveydenhuollon IT-alustoja. Tekoälystä esitellään sen hyötyjä ja haittoja, tekoälyn kykyä oppia, muutamia tekoälyn tärkeimpiä menetelmiä ja niiden hyödyntämisen alueita. Raportissa myös määritellään sekä tekoäly että terveydenhuollon IT-alustat. Lisäksi lopuksi luodaan lyhyt katsaus terveydenhuollon alustojen tulevaisuuteen.

2 Tekoäly – koneoppimisesta syväoppimiseen

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

Kuviosta 1 havainnollistuu tekoälyn kehityskulku aina 50-luvulta nykypäivään. Käsite tekoäly on hyvin laaja, joka tarkoittaa tietokoneiden kykyä matkia ihmisten älykkyyttä. Koneet käyttävät avukseen logiikkaa, ehtolauseita, päätöspuita sekä kone- ja syväoppimista, mitkä alkoivat jo 50-luvulla. Tekoälyn termi on kyseisen aihealueen termeistä laajin, joka mahdollistaa tietokoneille matkia ihmisten älykkyyttä käyttämällä logiikkaa, jos-sitten (If-Then) -sääntöjä, päätöspuita, kone- ja syväoppimista. Koneoppiminen on tekoälyn osa-alue, joka hyödyntää tilastollisia menetelmiä teknologioissa, jotka mahdollistavat koneiden oppimisen kokemuksista. Syväoppiminen on koneoppimisen osa-alue muodostuen algoritmeista, jotka mahdollistavat ohjelmiston itseoppimisen tehtävien suorittamiseksi. Näitä tapoja ovat esimerkiksi puhe- ja kuvantunnistus. Niitä käytetään hyväksi neuroverkkoja suuren datamäärän käsittelemiseen. (Parloff, 2016)



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


2.1 Tekoölyn määritelmä

Tekoöly voidaan määritellä keinotekoisena älykkyytenä, jonka avulla voidaan ratkaista monimutkaisia ongelmia koneiden avulla. Tekoöly on tietotekniikan ja fysiologisen älykkyyden yhdistelmä, jonka avulla voidaan laskennallisesti päästä tavoitteisiin. Älykkyyden on kyky ajatella luomalla muistia ja ymmärrystä, tunnistamalla malleja, tekemällä muutokseen sopeutuvia valintoja ja oppimalla kokemuksista. Tekoölyn avulla voidaan saada koneet käyttäytymään jopa ihmismäisemmin ja tehokkaammin kuin ihmiset. (Borana, 2016)

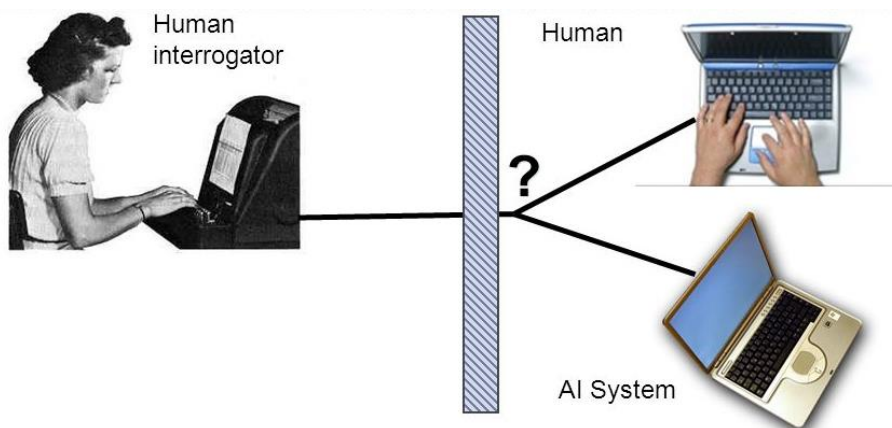
Tekoölyn juuret ovat pitkälti useilla eri tieteenaloilla, kuten:

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

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

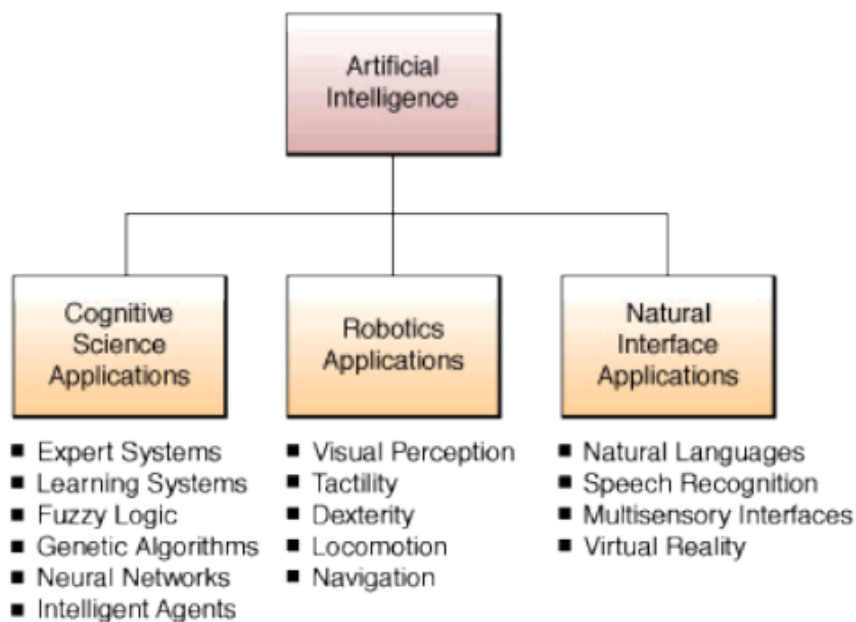


KUVIO 2. Tekoölyn hyödyntämisen alueita. (Borana, 2016)



KUVIO 3. Turingin testi. (Borana, 2016)

Tekoäly voidaan jakaa sovellusalueisiin esimerkiksi seuraavasti (Kuvio 4). 1. Kognitiivisen tieteen sovellukset, 2. Robottiikan sovellukset ja 3. Luonnollisen kielen sovellukset. Kuviosta 4 havainnollistuu tekoälyn jako erilaisiin sovellusalueisiin sekä sovellusalueen käyttämiä menetelmiä.



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

2.2 Tekoälyn hyötyjä ja haittoja

Tekoälyn hyötyjä (Borana, 2016):

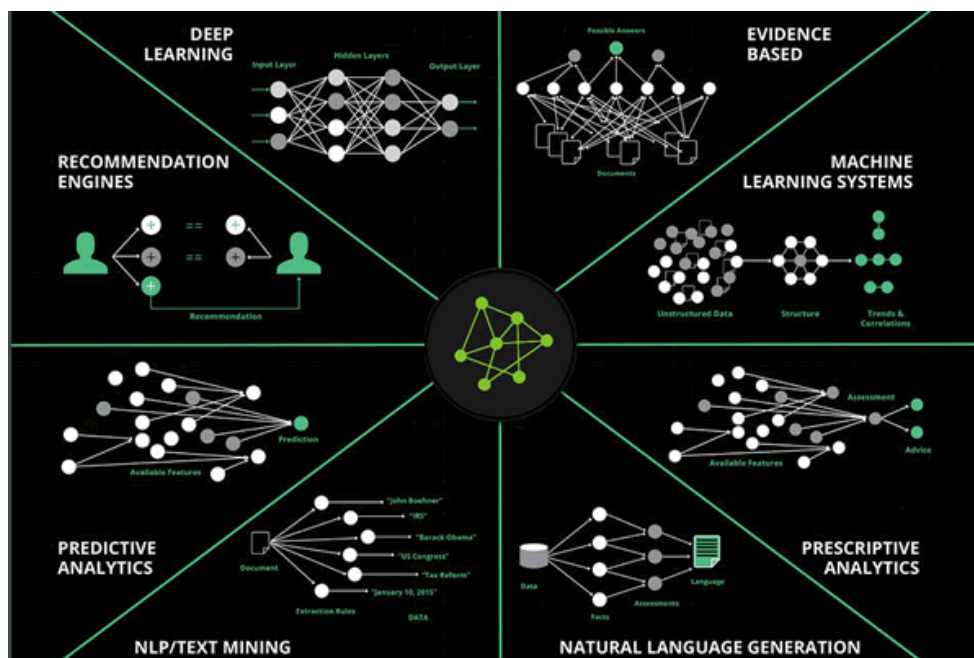
- Tiedon jakaminen on helpompaa. Koneen oppima asia voidaan helposti kopioida koneelta toiselle, eikä jo opittua tarvitse kouluttaa muille.
- Koneet eivät tarvitse unta ja voivat työskennellä silloinkin, kuin ihmiset ovat jo väsyneet.
- Yksi parhaita etuja on, että päätökset tehdään aina perustuen faktoihin, eikä tunteisiin. Tunnetusti ihmisten 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.
- Väärissä käsissä tekoäly voi aiheuttaa massiivisia tuhoja.

2.3 Tekoäly ja oppiminen

Tekoäly on kulkenut pitkän tien aina Alan Turingin koneesta nykypäivän kognitiivisiin tekoälyä hyödyntäviin innovaatioihin saakka. Alan Turing jo aikoinaan alkoi kehittää teknologioita, kuten neuroverkoja, jotka mahdollistavat tekoälyn. Tekoäly on laaja yläkäsite, joka kattaa monia menetelmiä, joiden tarkoituksena on saada tietokoneet ajattelemaan, kuten ihmiset. Tarkoitus on saada koneet ajattelemaan ja simuloimaan asioita, joita ihmiset tekevät sekä lopulta ratkaisemaan ne paremmin ja nopeammin kuin ihmiset. Tehtävyyppit voivat olla muun muassa luovia tehtäviä, suunnittelua, liikkumista, puhumista, objektien ja äänien tunnistamista ja sosiaalisten ja liiketoiminnallisten transaktioiden suorittamista. (Buczowski, 2017) Edellä mainittujen tehtävyyppien suorittamiseksi tekoälyä voidaan hyödyntää erilaisilla menetelmillä (Kuvio 5), joita ovat esimerkiksi kone- ja syväoppiminen, prediktioivinen ja preskriptiivinen analytiikka, tekstin louhinta, todistepohjaiset menetelmät ja luonnollisen kielen prosessointi.



KUVIO 5. Tekoälyn jakautuminen erilaisien menetelmien osa-alueisiin. (I-Scoop)

Nykyään tekoäly on kaikkialla ympärillämme. Suuret yritykset käyttävät tekoälyä palveluidensa parantamiseksi. Esimerkiksi Google käyttää koneoppimisen menetelmiä 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 päätöksi, kuten mitä asiakkaat haluavat katsoa tai ostaa seuraavaksi. Kone- ja syväoppimisen menetelmien hyödyntäminen tekoälyn kehittämiseksi on tuottanut lupaavia tuloksia ja niiden idea on periaatteessa yksinkertainen. Perinteisen ohjelmoinnin sijasta, tietokoneelle annetaan pääsy laajaan datamäärään ja ne ohjelmoidaan löytämään malleja sekä oppimaan itsenäisesti, miten vaadittu tehtävä suoritetaan. (Buczowski, 2017)

Terveydenhuollon sektorilla 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 diagnosoituihin sairastapauksiin tai taudinkuviin. Se myös vertaa niitä maailmalla oleviin lääketieteellisiin tutkimuksiin, auttaa lääkäreitä tekemään oikeita potilaille personoituja hoitosuunnitelmia suhteellisen paljon pienemmällä vaivalla, mikä on aiemmin ollut mahdotonta. (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. Järjestelmät laajentavat käsittelykykyämme ja tarjoavat mahdollisuuksia laajamittaiselle yhteistyölle.

2.3.1 Neuroverkot

Ihmisen aivojen toimintaa jäljittelevät keinotekoiset neuroverkot keksittiin jo 1940-luvulla. Neuroverkkojen uusi aalto alkoi 1990-luvulla, mutta niiden käyttöön ottoon into hiipui nopeasti siihen, että ne eivät olleet muita menetelmiä parempia ja silloisilla tietokoneilla ei ollut mahdollisuutta käsitellä neuroverkkojen koulutuksessa tarvittavia suuria datamääriä. Koneiden nopeutuminen ja datan määrän valtava kasvaminen 2010-luvulla ovat kasvattaneet innostusta syväoppimiseen (Deep Learning). Neuroverkkoja käytetään esimerkiksi kuvantunnistuksessa, konenäössä, puheentunnistuksessa, kielenkääntäjissä, peleissä ja lääketieteellisessä diagnostiikassa.


Keinotekoiset neuroverkot (Artificial Neural Networks eli ANN) on informaation prosessointiparadigma, jota inspiroivat biologiset hermojärjestelmät, kuten aivot. Paradigman avainelementtinä on informaation prosessoinnin järjestelmän uusi malli, jossa neuroverkot muodostuvat suuresta määrästä toisiinsa yhteen liittyneitä prosessointielementtejä (neuronit), jotka toimivat yhdessä tiettyjen määriteltyjen ongelmien ratkaisemiseksi. Keinotekoiset neuroverkot oppivat esimerkeistä. Neuroverkko on voitu esimerkiksi konfiguroida oppimisprosessin kautta jollekin tietylle sovellusalueelle, kuten mallien tunnistamiselle tai datan luokittelulle. 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 (ANN) perustuvat ajatukselle, että ihmisaivojen toimintaa oikeiden yhteyksien luomisessa voidaan jäljitellä keinotekoisesti käyttämällä piitä ja johtoja elävien neuroneiden ja dendriittien sijasta. Ihmisaivot koostuvat noin sadasta miljardista hermosolusta, joita kutsutaan neuroneiksi. Neuronit voivat olla motorisia tai sensorisia. 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 neuronია kohti. Viejähaarakke eli aksoni on kaapelin kaltainen letka, jonka pituus voi ihmiskehossa olla yli metrin mittainen.


Aksonin tehtävänä on kuljettaa neuroniin tullut hermoimpulssi eteenpäin synapsin välityksellä toiseen neuroniin tai kohde-elimeen. Aivojen toimintaa havainnollistetaan kuviossa 6. (Tutorialspoint, 2017)




KUVIO 6. Hermosolun semantiikka. (Tutorialspoint, 2017)

Keinotekoiset neuroverkot koostuvat useista solmuista (syöte-, piilo- ja ulostulokerrokset), 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 paino ja sen muutos vaikuttaa keinotekoisien neuroverkkojen kykyyn oppia. (Tutorialspoint, 2017)

Keinotekoiset neuroverkot jakautuvat eteenpäin syöttäviin (FNN) ja takaisin kytkettyihin neuroverkkoihin (FeedBack) (Kuvio 7 ja Kuvio 8), ja ne toimivat luonnostaan assosiatiivisena muistina eli syöte voi olla epätäydellistä sisältäen kohinaa. (Bask ym., 1998) Informaation virta on yksisuuntainen 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)



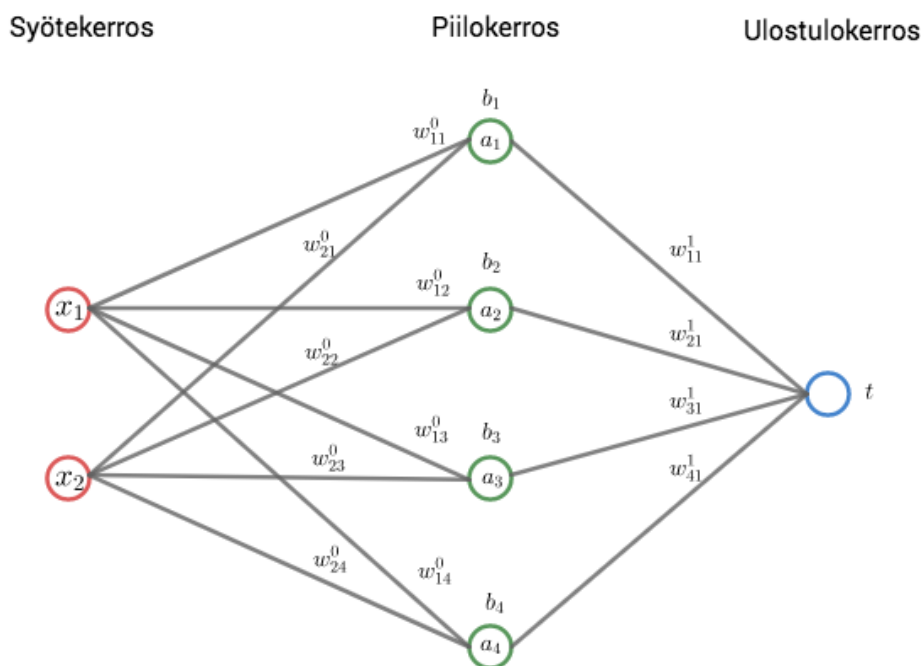
KUVIO 8. Takaisinkytketty neuroverkko.(Tutorialspoint, 2017)

Neuroverkkoa voidaan ajatella funktiona $f : \mathfrak{R}^n \rightarrow \mathfrak{R}^m$; syöte on n -ulotteinen vektori $x = (x_1, x_2, \dots, x_n)$, piilokerrokset hoitavat laskutehtävän ja funktion arvo $f(x) = y = (y_1, y_2, \dots, y_m) \in \mathfrak{R}^m$ saadaan ulostulokerroksesta. Verkon käyttötarkoitus määrää, miten funktion arvo y tulkitaan. Syväoppis-termi on saanut nimensä siitä, että neuroverkoissa käytetään monia piilokerroksia, joilla on kullakin oma tehtävänsä. Kuvista 9 havainnollistuu yksinkertainen keinotekoinen neuroverkko.



KUVIO 9. Yksinkertainen keinotekoinen neuroverkko. (Tutorialspoint, 2017)

Esimerkiksi (Kuvio 10) verkossa on yksi piilokerros, jossa on neljä neuronia. Syötteenä on vektori $x = (x_1, x_2) \in \mathbb{R}^2$. Ulostulokerroksessa on yksi neuroni.



KUVIO 10. Esimerkki yhden piilokerroksen ja neljän neuronin neuroverkosta. (Tuominen, 2018)

Syötevektorin komponentit kerrotaan piilokerroksen neuroneiden painoilla ω_{ij}^0 , lasketaan yhteen ja summaan lisätään piilokerroksen neuronin i vakiotermi b_i (bias):

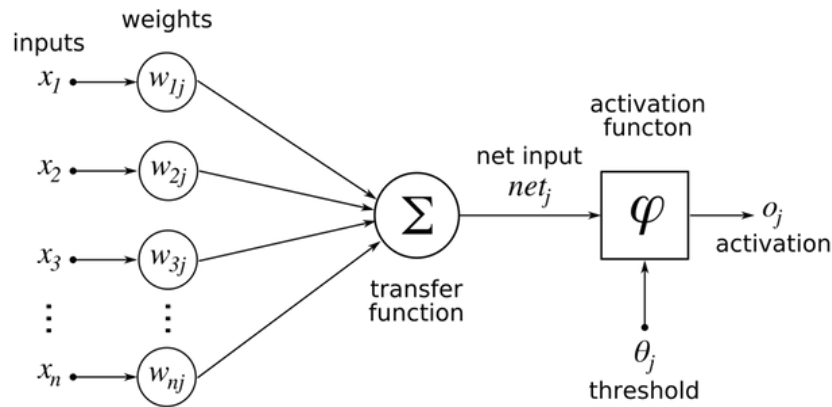
$$Z_1^1 = \omega_{11}^0 x_1 + \omega_{21}^0 x_2 + b_1 = \sum_{i=1}^2 \omega_{i1}^0 x_i + b_1,$$

$$Z_2^1 = \omega_{12}^0 x_1 + \omega_{22}^0 x_2 + b_2 = \sum_{i=1}^2 \omega_{i2}^0 x_i + b_2,$$

$$Z_3^1 = \omega_{13}^0 x_1 + \omega_{23}^0 x_2 + b_3 = \sum_{i=1}^2 \omega_{i3}^0 x_i + b_3,$$


$$Z_4^1 = \omega_{14}^0 x_1 + \omega_{24}^0 x_2 + b_4 = \sum_{i=1}^2 \omega_{i4}^0 x_i + b_4.$$

Kuvio 11 ilmentää yksikerroksista perseptronia (Single Layer Perceptron), joka on yksinkertaisin FFN-neuroverkon ilmentymä. Yksittäinen neuroni välittää viestin seuraavalle neuronille, jos yhden tai useamman neuronin syötteiden painojen summa on riittävän suuri mahdollistaakseen viestin välittämisen. Edellä mainittua prosessia kutsutaan aktivoinniksi, mikäli kynnyisarvo (threshold) ylittyy ja viesti välitetään seuraavalle neuronille.



KUVIO 11. Yksikerroksinen perseptroni ja viestin välitys neuronien välillä. (Castrounis, 2016)

Piilokerroksien ja ulostulokerroksen neuroneissa lasketaan syöte- tai piilokerroksesta tulleiden syötteiden painotettu summa ja lisätään siihen neuronin vakiotermi. Neuronien painoja w_i ja vakiotermejä b sanotaan verkon parametreiksi. Ennen neuronin tuloksen lähettämistä seuraavalle neuronille yhteenlaskettu summa viedään aktivointifunktioon (Kuvio 12).



KUVIO 12. Aktivointifunktion laskeminen verkon parametreista. (Tutorialspoint, 2017)

Esimerkkinä olevassa neuroverkossa summien piilokerroksen aktivointifunktiolle viemisen jälkeen neuronien syötteet ulostulokerrokselle ovat seuraavat:

$$a_1 = \phi(z_1), a_2 = \phi(z_2), a_3 = \phi(z_3) \text{ ja } a_4 = \phi(z_4).$$

Verkon antama tulos saadaan käyttämällä piilokerroksen ja ulostulokerroksen välisiä painoja ja aktivointifunktioita:

$$t = \phi(z_1^2) = \phi\left(\sum_{i=1}^4 \omega_{i1}^1 a_{i1}\right).$$


Neuroverkkojen neuroni on tavallaan kuin funktio, joka ottaa vastaan syötteitä (input) ja laskee niiden perusteella ulostulon (output). Kuvio 13 esittää keinotekoisista neuronia, jonka

syöte on yksi ja ulostulo viisi. Syöte koostuu kolmesta synapsista, jotka ovat yhteyksissä neuroniiin (vasemmalla olevat nuolet). Verkon syötteen on kuvattu vihreällä ja vääristymää (bias) on kuvattu ruskealla. Syötteen kerrotaan painoilla, jotka kuvan 13 neuronin suhteen ovat 7 ja 3. Syötteen ja painokertoimien tulon lisätään vääristymä (-2), jolloin lopputuloksena jää jäljelle 5.



KUVIO 13. Keinotekoinen neuroverkko Sigmoid-funktiolla ja painokertoimet. (Borgen, 2016)


Neuroneita voidaan yhdistää toisiinsa, jolloin saadaan neuroverkko (Kuvio 14). Kuvan neuroverkossa on useita eri kerroksia ja syötteenä 784 neuronia. Toisessa ja kolmannessa kerroksessa on yhteensä 32 neuronia ja viimeisessä kerroksessa 10 vääristymää, jolloin tuloksi tulee $784 \times 32 \times 10 \Rightarrow 13\,002$ erilaista painokerrointa/vääristymää. Verkon oppiminen perustuu oikeiden painojen ja virheiden löytämiseen.



KUVIO 14. Esimerkki ANN-neuroverkosta käsialalla kirjoitetun numeron tunnistamisessa. (Bursuc ym.)

Neuroverkkoa voidaan hyödyntää tunnistamaan esimerkiksi käsialalla kirjoitettuja numeroita, joka tässä yhteydessä on numero 9. Verkko tarkastaa, löytyykö seuraavalta verkon kerrokselta palasia, joista voidaan muodostaa numero 9. Kolmas kerros saattaa pystyä jo tunnistamaan ympyrät ja viivat. Viimeinen kerros todennäköisesti osaa jo yhdistää palaset numeroksi 9. Verkkoa voidaan opettaa antamalla verkolle riittävä määrä opetusdataa, kuten käsin kirjoitetut numerot ja niitä vastaavat tulkinnot eli esimerkiksi käsin kirjoitettu numero 4 ja sitä vastaava numero 4 selväkielisenä. Tämän jälkeen verkko saattaa kyetä tekemään yleistyksiä

syötetyn datan ulkopuolelle ja tunnistamaan sellaisia numeroita, joita sille ei ole opetettu. Asia voidaan testata opettamalla verkkoa erilaisella datalla, kuin sitä on opetettu. (Kuvio 15)



KUVIO 15. Neuroverkon testaaminen erilaisella datalla kuin opetusdata. (Bursuc ym.)

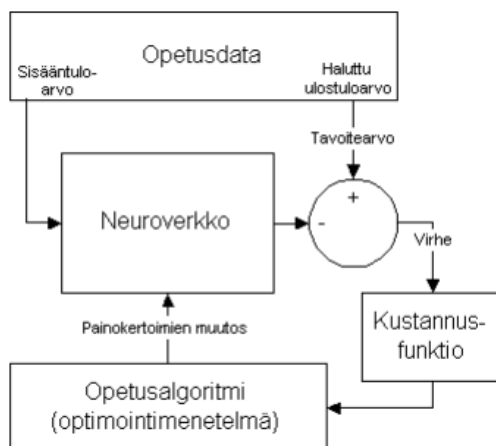
Verkkoa voidaan testata laskemalla niin sanottu kulufunktio (cost function). Edellä mainitun verkon tapauksessa syötteenä saadaan verkon tulo (13 002), jolloin ulostuloksi tulee vain yksi numero (kulu) ja josta voidaan nähdä verkon suorituskyky. Parametreina kulufunktion laskemisessa käytetään huomattava määrä harjoitus-esimerkkejä.

Neuroverkkojen vahvuudeksi voisi mainita, että ne voivat ratkaista epätarkkoja ongelmia epätäydellisillä syötteillä. Neuroverkoilla on kyky oppia vastaanottamiensa syötteiden perusteella uusia ratkaisutapoja, jolloin opittujen ratkaisutapojen myötävaikutuksesta ne voivat ratkaista uusia 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 päättelemällä. 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)

Eteenpäin syöttävät neuroverkot koulutetaan useimmiten ohjatulle oppimiselle (Kuvio 16) tyypillisellä takaisinvälityksellä (Back-Propagation), jossa verkolle annetaan esimerkisyöte ja verrataan sen antamaa tulostetta haluttuun tulosteeseen. Tämän jälkeen lasketaan kerrallaan tulostuserrokselta taaksepäin edeten, kuinka paljon kunkin synapsin painokerrointa on muutettava ja mihin suuntaan, jotta tulos olisi halutun kaltainen. Sisään tulevien ja haluttujen ulostuloarvojen funktionaalaisia riippuvuuksia ei usein tiedetä. Matemaattisesti tätä voidaan kutsua gradientin seuraamiseksi ja siinä hyödynnetty algoritmi on SGD (Stochastic Gradient Descent).

Fyysisessä mielessä oppiminen tapahtuu solujen liitosten painoarvojen muutoksina. Oppimissääntö on neuroverkon keskeisin ominaisuus ja sen valintaan vaikuttaa se, kuinka nopeasti verkon halutaan oppivan ja kuinka nopeasti verkolta halutaan vastaus annettuun

ongelmaan. Edellä kuvatun (Kuvio 16) kaltaisella neuroverkolla voidaan päästä suhteellisen suuriin (96 %), kuvan tunnistamistarkkuuksiin, joka tässä tapauksessa oli numeron tulkitsemista käsin kirjoitetuista numeroista. Muuntelemalla piilokerroksien toimintaa, voidaan tarkkuutta nostaa vielä hieman, jopa 98 % saakka.



KUVIO 16. Ohjatun oppimisen periaate. (Keltanen, 2006)

Menetelmä, jossa saatuja arvoja verrataan haluttuun arvoon ja arvioidaan, mitkä yhteyksistä aiheuttavat virheellisen tuloksen, kutsutaan virheenjako-ongelmaksi (blame assignment problem). Tämän tyllysiä menetelmiä on ollut olemassa ilman piilokerroksia oleville neuroverkoille jo kauan, mutta tulokset yleisissä tapauksissa ovat olleet huonoja. Ongelmaan kehitettiin 80-luvulla tehokas ja yksinkertainen menetelmä, jossa ideana on mitata koko järjestelmän suoriutumisen ja sen jälkeen optimoida sitä, jolloin syntyi vastavirta-algoritmi (Back-propagation algorithm).

Back Propagation (BP) on amerikkalaisten v. 1986 julkaisema menetelmä, jonka vahvin etu on sen lähtöfunktion jatkuvuus BP:ssä. Tässä algoritmista ihmisen tuottamaa tietoa on tosin vaikea yhdistää neuroverkon informaatioon, joka laskee sen 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)

Neuroverkkoa voidaan alkaa opettaa sen jälkeen, kun on valittu ongelman ratkaisua varten sopiva arkkitehtuuri. Vastavirta-algoritmi on yleisin MLP (Multi-Layer Perceptron Network) opetukseen käytetty algoritmi. Opetukseen käytettävästä datasta syntyy ulostulona neuroverkon avulla ulostuloarvoja, joita verrataan haluttuihin arvoihin. Näiden kahden arvon

eli neuroverkon tuloksena antaman arvon ja tavoitearvon erosta lasketaan virhe. Virhesignaali lähetetään ulostulokerrokselta sitä edeltävälle piilokerrokselle ja prosessia jatketaan niin kauan kuin jokainen verkossa oleva solmu on tullut tietoiseksi omasta osuudestaan kokonaisvirheessä. Tämän tiedon perusteella päivitetään yhteyksien painokertoimia niin, että ulostulon arvo lähenee tavoitearvoa.

Neuroverkkoa opetetaan opetusesimerkeillä, jotka ovat syöte-tavoite-pareilla (x,y) eli opetusesimerkeillä. Verkon syötteelle x antamaa tulosta t verrataan valitulla virhefunktiolla tavoitteeseen y . Opettamisessa minimoidaan virhefunktiota esimerkiksi gradienttimenetelmällä. Jokaisen neuronin vaikutus virheeseen ja virhefunktion E osittaisderivaatat $\frac{\partial E}{\partial w}$ ja $\frac{\partial E}{\partial b}$ verkon kaikkien painojen w ja vakiotermin b suhteen lasketaan usein vastavirta-algoritmeilla. Piilokerroksen parametreja muutetaan niin, että verkko toimii halutulla tavalla opetusesimerkeille. Tämän jälkeen sen toimintaa voidaan tarkastella testiesimerkeillä. (Meeden, 2010)

Syötettä x vastaavan tavoitteen $y \in \mathbb{R}^m$ ja verkon antaman tuloksen $t \in \mathbb{R}^m$ virhefunktiona käytetään erotuksen normin neliötä

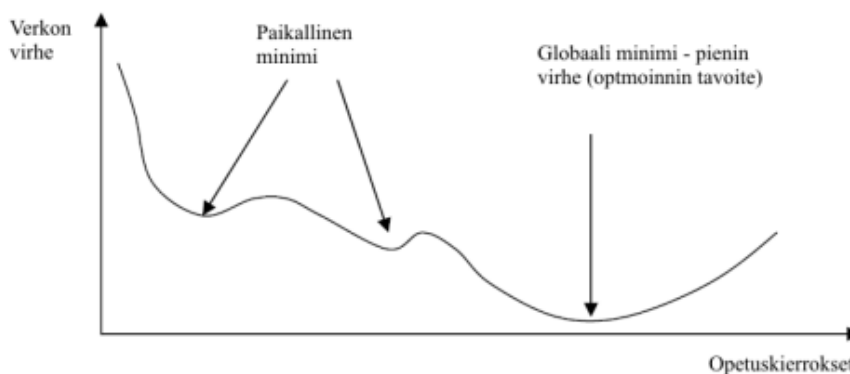
$$E = \frac{1}{2} \| t - y \|^2 = \frac{1}{2} \sum_{k=1}^m (t_k - y_k)^2$$

ja opetusesimerkkijoukon A virhefunktiona keskineliösummaa

$$E_A = \frac{1}{2N} \sum_{x \in A} \| t(x) - y(x) \|^2$$

Jossa N on joukon A opetusesimerkkien lukumäärä.


Neuroverkon virhefunktiota voidaan koettaa minimoida gradienttimenetelmällä, joka riippuu neuronien painoista ja vakio-termistä. Minimien etsiminen aloitetaan laskemalla virhefunktion arvo aloitusparametreilla. Virhefunktion gradientti kertoo nopeimman kasvun ja siten gradientin vastavektori nopeimman vähenemisen suunnan. Sopivin askelin siirtymällä nopeimman vähenemisen suuntaan voidaan löytää lokaali minimi (Kuvio 17). Gradienttiin tarvitaan virhefunktion E osittaisderivaatat $\frac{\partial E}{\partial w}$ ja $\frac{\partial E}{\partial b}$ verkon kaikkien painojen w ja vakiotermin b suhteen. (Vasilev, 2017)



KUVIO 17. Lokaalin minimin ongelma ja globaali minimi. (Vasilev, 2017)

Verkon painokertoimien optimoimiseksi muodostetaan gradientin perusteella kustannusfunktio, jolla voidaan ilmaista ratkaisun suorituskykyä tai hyvyyttä. Kustannusfunktioihin vaikuttavien tekijöiden ollessa säännömukaisia, on menetelmien havaittu lähenevän lokaaleja minimeitä asymptoottisesti ja jossain tapauksissa eksponentiaalisella nopeudella. Esimerkki tämänkaltaisesta menetelmästä on vastavirta-algoritmi. Toisinaan lokaalin minimin ongelma saattaa muodostua ratkaisevaksi esteeksi menetelmän käyttöönotossa. Optimoinnin tavoitteena olisi löytää globaali minimi, joka on optimoinnin tavoitteena. Menetelmän heikkouksiin kuuluu suuri laskentatehon tarve, josta johtuen algoritmi voi toisinaan olla hidask. (Pagelis & Kim)

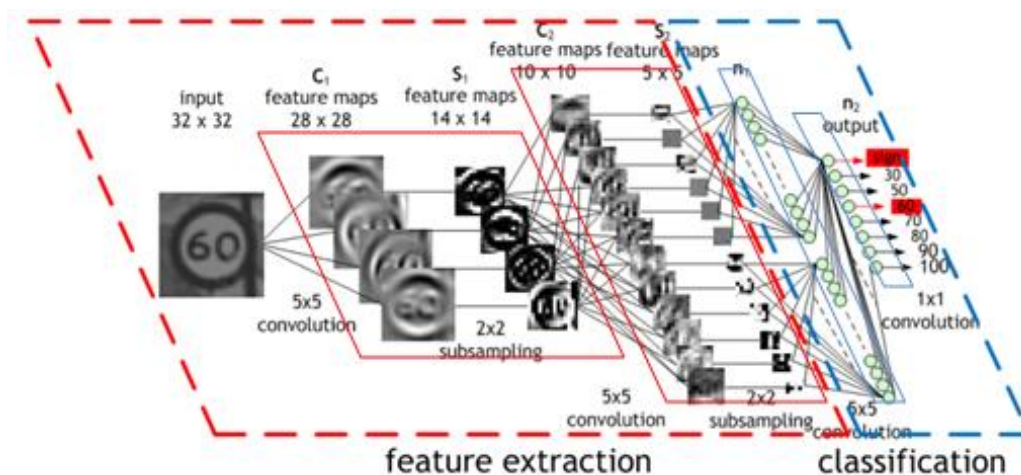
Koneoppimisessa konvoluutioneuroverkot (Convolutional Neural Network eli CNN) ovat tyypiltään monikerroksisia eteenpäin syöttäviä eli Feed Forward keinotekoisia neuroverkkoja. Verkot koostuvat yhdestä tai useammasta konvoluutiokerroksesta, joita seuraa yksi tai useampi täysin yhdistynyt kerros standardoidussa monikerroksisessa neuroverkossa. Ne kuitenkin eroavat normaaleista FNN-verkoista siten, että CNN-verkoissa (Kuvio 18) joidenkin kerroksien neuronit eivät ole kaikkien seuraavien kerroksien neuronien kanssa yhteyksissä. Konvoluutioverkkojen arkkitehtuuri on suunniteltu hyötymään syötteenä lähetetyn kuvan (tai muun 2D-syötteen, kuten puhesignaali) 2D-rakenteesta. CNN-verkot ovat myös helpompia opettaa ja niillä on huomattavasti vähemmän parametreja kuin täysin yhdistyneillä verkoilla, joilla on sama määrä piilotettuja yksiköitä. (UFLDL Tutorial, 2017)



KUVIO 18. CNN-neuroverkko. (Patel & Pingel, 2017)

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. Esimerkiksi yleisesti esineitä tunnistettaessa voi olla hyödyllistä suodattaa tietoa esineen muodosta, koska pääsääntöisesti esineiden muodot vaihtelevat. Kuitenkin esimerkiksi lintujen tunnistuksessa voi hyödyllisempää olla tunnistaa lintujen värejä, koska linnut saattavat hyvinkin olla samanmuotoisia, mutta niiden värit usein vaihtelevat. (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 muistinkulutusta ja useiden eri konvoluutiokerroksien hyödyntämistä. Kuviosta 19 havainnollistuu konvoluutioverkkojen toiminta kuvantunnistuksessa (liikennemerkki). Liikennemerkki suodatetaan neljällä 5x5 konvoluutioytimen avulla, jotka luovat neljä ominaisuuskarttaa, ja ne osanäytteistetään. Seuraavalla tasolla on 10 kpl 5x5 konvoluutioydintä, joilla osanäytteet uudistuvat. Viimeisellä tasolla on yhdistelmäkerros, johon yhdistetään kaikki generoidut ominaisuudet. (Dettmers, 2015)




KUVIO 19. 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. Konvoluutioneuroverkot 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, koska osassa verkkoja voi olla jopa 140 miljoonaa liukulukuparametria ja ne voivat suorittaa yli 15 miljardia liukulukuoperaatiota

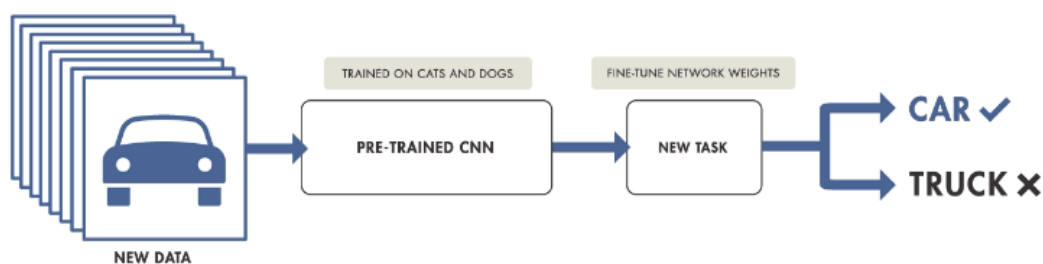
yhden kuvan luokitteluksi. Modernien CNN-verkkojen opetus tehdään lähes aina suurissa CPU- ja GPU-klustereissa. Hyötynä tästä on muun muassa yhteensopivan syväoppimisen viitekehysten, kuten Caffen käyttömahdollisuus. (Zhao ym., 2017)

Konvoluutioneuroverkon opettamisessa on useita eri vaihtoehtoja. Työläin niistä on verkon opettaminen tyhjästä (Kuvio 20), jolloin tarvitaan suuri määrä opetusdataa, kuten kuvia. Kuvat voivat olla esimerkiksi ajoneuvoista ja CNN-verkko voidaan opettaa tunnistamaan niitä. Mitä enemmän dataa on, sen suurempi on tunnistamisen todennäköisyys. Ongelmana tässä menetelmässä on, että suuren opetusdatamäärän lisäksi se vaatii merkittävästi laskentakykyä.



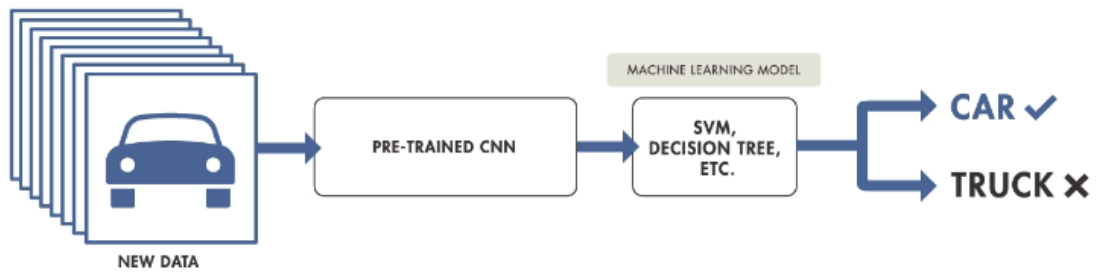
KUVIO 20. CNN-neuroverkon opettaminen kuvadatan perusteella. (Patel & Pingel, 2017)

Toinen vaihtoehto on ns. opitun siirtäminen toiseen tarkoitukseen. Konvoluutioneuroverkko voi olla opetettu esimerkiksi datalla, joka koostuu kissojen ja koirien kuvista (Kuvio 21). Verkon painoja voidaan hienosäätää ja saada se tunnistamaan esimerkiksi haluttuja auton malleja ja tyyppjä. Tämä menetelmä vaatii huomattavasti vähemmän dataa ja laskentaresursseja.



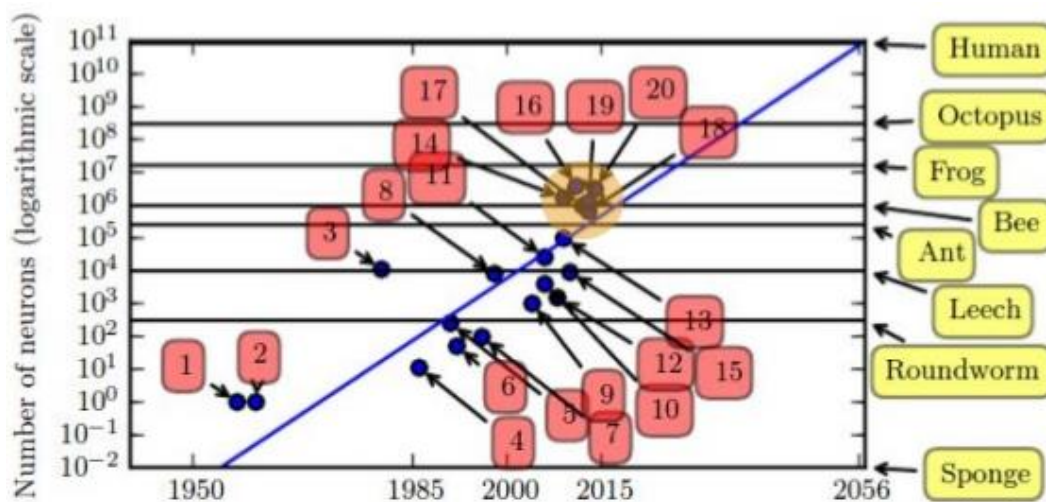
KUVIO 21. Konvoluutioneuroverkon opettaminen aiemman datan avulla. (Patel & Pingel, 2017)

Kolmas vaihtoehto on, että käytetään aiemmin opetettua konvoluutioneuroverkkoa (Kuvio 22), jonka avulla voidaan hyödyntää sen ominaisuuksia opettaessa koneoppimisen mallia CNN-verkolle, kuten tukivektorikone (Support Vector Machine eli SVM), päätöspuu (Decision Tree). Tämä menetelmä vaatii vähiten uutta dataa ja laskennallisia resursseja.



KUVIO 22. Konvoluutioneuroverkon opettaminen ominaisuuksia poimimalla. (Patel & Pingel, 2017)

Neuroverkkojen kehitys ajan myötä (Kuvio 23) on mahdollistanut aina vain uusia kehittyneempiä verkkoja. Alussa, 1950-luvulla kyettiin mallintamaan vaatimattomia neuroverkkoja, jotka olivat sienieläinten tasolla ja niissä neuronien lukumäärä oli 10^2 . Vuonna 2017 kyettiin pääsemään mehiläisen tasolle, jossa neuronien lukumäärä on 10^6 . Vuoteen 2056 mennessä saatetaan kyetä jäljittelemään ihmisaivojen neuronien lukumäärää 10^{11} , johon on tosin vielä matkaa. Neuronien välisten yhteyksien määrät ovat myös kasvaneet yli 20-kertaiseksi 50-luvulta nykypäivään.



KUVIO 23. Neuroverkkojen koko. (Goodfellow, 2016, 22)

2.3.2 Koneoppiminen

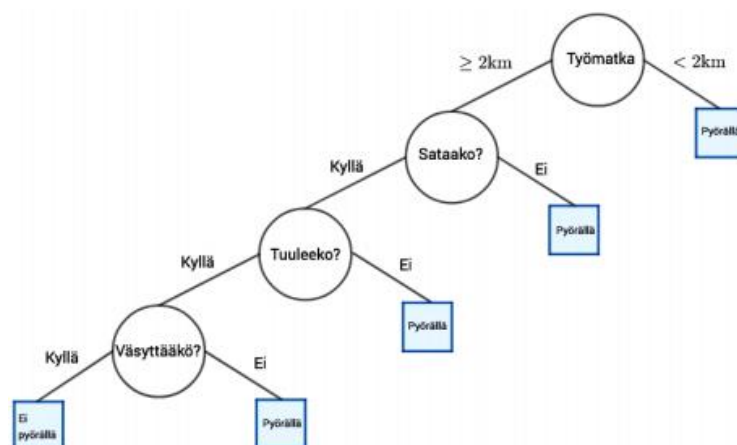
Oppimista on kahdenlaista, eli induktiivista ja deduktiivista. Induktiiviset koneoppimisen menetelmät muodostavat sääntöjä ja malleja suurista tietojoukoista. Induktiivinen päättely tarkoittaa yleistä teoriaa ja yleistystä. Induktiivinen yksittäisistä havainnoista tuotettu yleisty nähdään tietoa lisäävänä prosessina. Deduktiivinen päättely etenee johtamalla yleistyksestä yksittäistapausta koskevaa johtopäätöstä ja se nähdään päättelynä tunnetuista tapauksista toisiin tunnettuihin tapauksiin, eikä se lisää tietoa. (Saarinen 1999, 39 – 42)

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. Deduktio on vastakkainen oppimistapa induktioon verrattuna. Ongelmana deduktiivisessa prosessissa on sen vaikuttaminen teennäiseltä, valmis teoria ei kaikissa tapauksissa ilman omakohtaista tiedon tarvetta kosketa oppijaa tai herätä mielenkiintoa. Eikä oppiminen silloin aktivoi oppijan jo aiemmin mahdollisesti aivoissaan muodostamia tietorakenteita ja opiskeltava asia voi jäädä irralliseksi, eikä pysyviä tietorakenteita välttämättä pääse muodostumaan. (Prince ym., 2007)

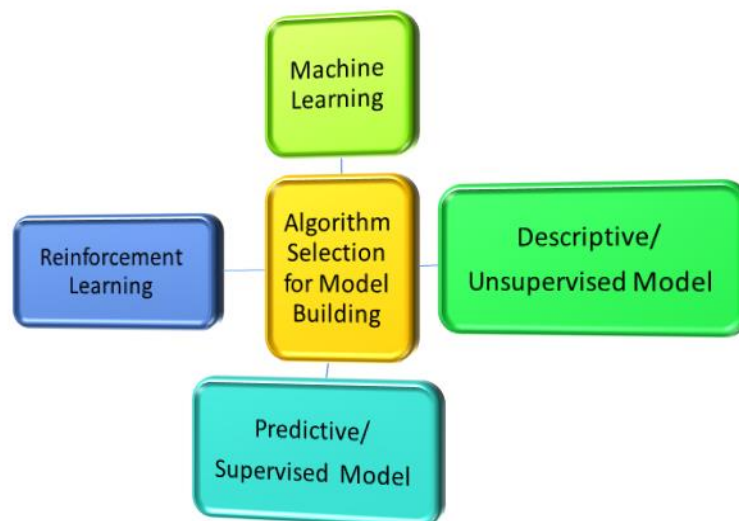
Tekoälyn varhaiset versiot, joita käytettiin esimerkiksi automaattiseen todistamiseen ja erilaisten loogisten ongelmien ratkaisemiseen, pohjautuvat logiikkaan. Logiikan deduktiivisen päättelyn (Kuvio 24), jossa väitelauseilla on vain kaksi mahdollista totuusarvoa: tosi tai epätosi. Perinteinen deduktiivinen päättely laajentui 1960-luvulla alkunsa saaneen sumea logiikan myötä, jossa käytetään totuusarvoina reaalitylukuja välillä $[0, 1]$. Asioita luokiteltaessa niitä ei jaotella täsmälleen yhteen luokkaan kuuluviksi vaan kerrotaan, kuinka paljon asia kuuluu kuhunkin luokkaan. Esimerkiksi mietittäessä, mitkä lämpötilat ovat lämpimiä ja mitkä kylmiä, luokittelu kahteen on vaikeaa. Esimerkiksi 16 astetta voisi olla 0,5 verran lämmintä ja 0,5 verran kylmää. Sumea logiikkaa voi löytyä esimerkiksi autojen automaattivaihteiden ja itsestään säätyvien ilmastoitien taustalta.



KUVIO 24. Deduktiivista päättelyä hyödyntävä puu. (Tuominen, 2018)

Koneoppiminen on tekoälyn osa-alue ja data-analyysimetodi, joka automatisoi analyttistä 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 yleisimmät algoritmien tyypit ovat (Kuvio 25):

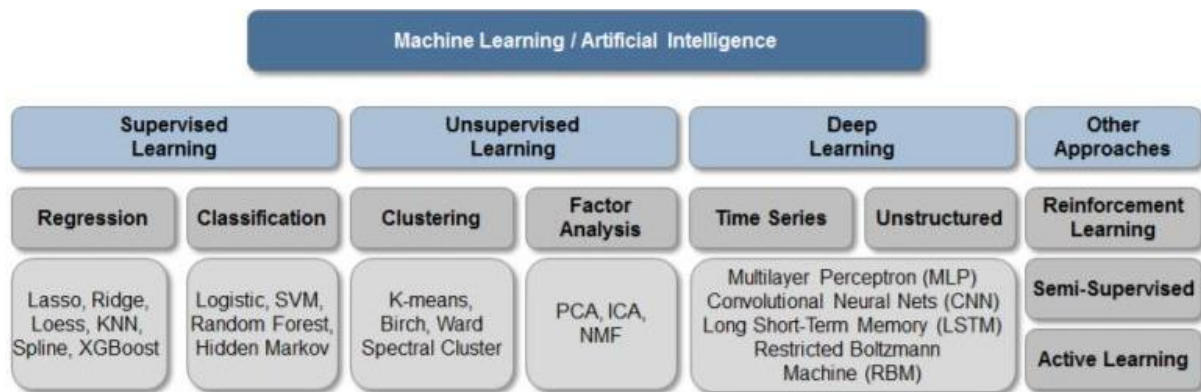


KUVIO 25. Koneoppimisen algoritmien yleisimmät tyypit. (Jain, 2015)

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)

Ohjatussa oppimisessa konetta opetetaan luokitellun aineiston avulla ja pyritään siihen, että kone osaa tehdä halutun luokittelun samankaltaiselle aineistolle. Klassinen esimerkki ohjatussa oppimisesta on käsinkirjoitettujen numeroiden tunnistus (Kuvio 14). Ohjaamaton oppiminen jäljittelee ihmisen oppimista. Siinä opettamiseen käytetään raakadataa, josta

pyritään löytämään samankaltaisuuksia ja suhteita eri syötteiden välillä, samankaltaiset asiat hakeutuvat toistensa läheisyyteen. Esimerkki ohjaamattomasta oppimisesta on akateemikko Teuvo Kohosen (1934) 1980-luvulla kehittämä itseorganisoituva kartta, jonka sovelluksia on käytetty tuhansissa julkaisussa. Kolmas oppimisen tyyppi on vahvistettu oppiminen, jossa kone oppii ympäristön antaman palautteen perusteella. Oppimisen tyyppejä ja niihin liittyviä koneoppimisen menetelmiä on havainnollistettu kuviossa 26. Käytetään mitä tahansa oppimismenetelmää, niin tekoälystä on hyötyä vasta sitten, kun opettaminen on hoidettu hyvin.



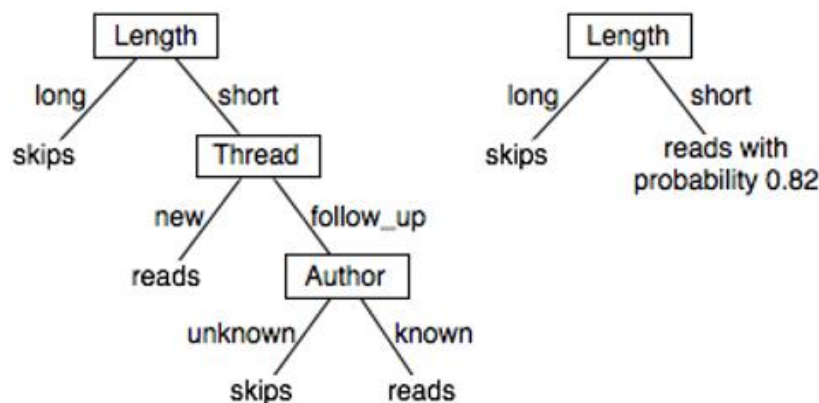
KUVIO 26. Oppimisen tyyppejä ja koneoppimisen menetelmien luokittelu. (Butcher, 2017)

Koneoppimisessa toteutuvat seuraavat viisi vaihetta (Jain, 2015):

- 1. Datan kerääminen:** Data voi olla esimerkiksi raakadataa Excelistä, Accessista tai se voi olla tekstitiedostoista muodostunutta dataa. Datan keräämisen vaihe muodostaa perustan tulevalle oppimiselle. Tärkeää on datan määrä, laatu ja relevanttius.
- 2. Datan valmistelu:** Analyttisten prosessien menestyminen perustuu käytetyn datan laatuun. Aikaa voi kulua datan laadun määrittämiseen ja korjaavien toimenpiteiden suorittamiseen, kuten kadoksissa oleva data tai poikkeavuuksien korjaaminen. Tutkiva analyysi on yksi datan vivahteiden ja yksityiskohtien tutkimiseen menetelmistä.
- 3. Mallin opettaminen:** Tämä vaihe sisältää soveltuvan menetelmän ja datan esitysmuodon valitsemisen mallin muodossa. Käsitelty data jaetaan kahteen osaan, jotka ovat opetus ja testaus. Ensimmäistä osaa käytetään mallin kehittämiseen ja toista osaa käytetään referenssinä.
- 4. Mallin arviointi:** Tarkkuuden testaaminen. Datan toista osaa eli testiosaa hyödynnetään mallin arvioinnissa. Tämä vaihe määrittää ulostuloon perustuen menetelmän valinnan tarkkuuden.
- 5. Tehokkuuden parantaminen:** Tämä vaihe saattaa sisältää erilaisen mallin valinnan tai muuttujien lisäämisen tehokkuuden parantamiseksi. Tästä johtuen merkittävä määrä aikaa tulee käyttää datan keräämiseen ja valmisteleminen.


Koneoppimisen kenties tunnetuimpia ohjatun oppimisen malleja ovat päättelypuut (Decision Trees), jotka ovat yksinkertaisia binääripuita, joiden avulla järjestelmä kykenee tekemään päätöksiä. Yksittäiset puut eivät itsessään ole oppivia järjestelmiä, sillä niiden luonne on staattinen. Oppiva järjestelmä voidaan saavuttaa useiden puiden (nk. metsä) yhteiskäyttöllä ja luomalla uusia puita. Yksinkertainen päättelypuu voisi kuvata esimerkiksi sitä, lähteekö ihminen aamulla töihin tai kouluun pyörällä. Kulkuvälineen valintaan vaikuttavia asioita päätöspuussa ovat matkan pituus, sää ja ihmisen 1 virkeys. Päätöspuun antamaa tulosta voisi esimerkiksi soveltaa bussiaikataulujen lähettämiseen puhelimeen siinä tapauksessa, että pyöräily ei kyseisenä päivänä huvita.

Kuvion 27 oikealla puolella oleva päätöspuu on oppiva todennäköisyyden muuttuessa päätöksien perusteella. Päätöspuiden toimivuus yksinkertaisissa järjestelmissä on hyväksi havaittu, mutta isommissa järjestelmissä ne eivät ole enää nykyään paras menetelmä.



KUVIO 27. Yksinkertainen päätöspuu. (Poole & Mackworth, 2010)

Koneoppimisessa voidaan käyttää myös graafiteoriaan ja todennäköisyyslaskentaan perustuvia malleja, esimerkiksi Bayers-verkkoja. Ne ovat suhteellisen yksinkertaisia, suunnattuja syklittömiä verkkoja. Niiden logiikan myötä voidaan tehdä johtopäätös, että jos henkilöllä on koomaan johtava päänsärky (Kuvio 28), 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 Bayers-verkkoja käytetään silloin, jos halutaan kerätä tietoa tuntemattomasta systeemistä, jolloin voidaan aloittaa pienellä verkolla ja lähteä laajentamaan sitä.



KUVIO 28. Esimerkki Bayers-verkosta. (Fukushige)

Koneoppimista käytetään useilla eri sektoreilla, kuten finanssipalvelut, hallitusten toiminnot, terveydenhuolto, markkinointi ja myynti, öljy- ja kaasuteollisuus, kuljetusala. Todennäköisesti tunnetuimpia koneoppimisen käyttötavoista nykypäivänä on mallien tunnistaminen (Pattern Recognition), koska sitä voidaan käyttää monenlaisen kuvan tunnistukseen. Esimerkiksi USA:n posti käyttää koneoppimista tunnistamaan käsialakirjoitusta. (SAS) Koneoppimisen sovellusalueita on monia. (Kuvio 29)




KUVIO 29. 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. Syväoppimisessa käytetään

useita epälineaarista informaation prosessoinnin tasoja ja hierarkisia arkkitehtuureita. Tavoitteena on luoda sopivaa syväoppimisen algoritmia käyttäen neuroverkko, joka tähtää soveltuvan ongelman ratkaisemiseen. (Kuvio 30) Ongelmia, joiden ratkaisemiseen syväoppimista käytetään, on perinteisiä menetelmiä käyttäen vaikea ratkaista toteuttaa, sillä ne vaativat monimutkaisten sääntöjen käyttöä. Syväoppimista hyödynnetään muun muassa lääketieteen diagnostiikassa, puheen, kuvien ja tekstien tunnistamiseen ja käsittelyyn. Monille tunnetuimpia hyödyntämisen alueita ovat Applen Siri, joka käyttää puheentunnistusta, tai Googlen Street View-karttapalvelu. (Tjoa, 2013)



KUVIO 30. Syväoppimisen prosessi. (Jagreet, 2017)


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, kun dataa lisätään (Kuvio 31). Dataa tuottamalla suorituskykyä voidaan myös parantaa ja esimerkiksi kuvadatan ollessa kyseessä, jo olemassa olevien kuvien kääntäminen tai kääntäminen ja 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. Tietyillä malleilla on mahdollista nähdä uudelleen skaalatun datan höydyt ja puutteet. Dataa muuntamalla neuroverkot voidaan saada oppimaan nopeammin, jos ratkaistavan ongelman rakenne on paremmin oppivien verkkojen käytössä. (Brownlee, 2016)



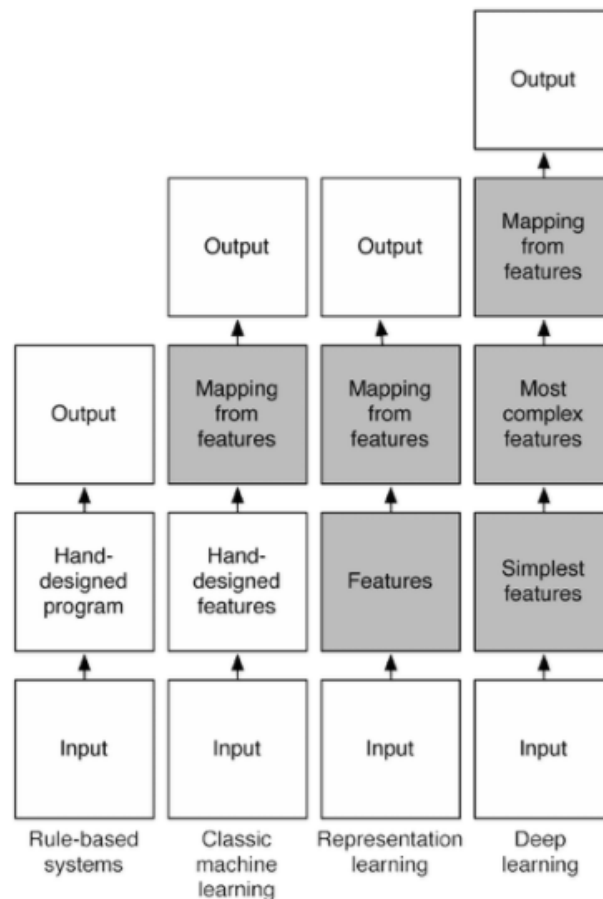
KUVIO 31. Syväoppimisen vs vanhempien teknologioiden skaalautuvuus. (Brownlee, 2016)

Syväoppiminen voidaan nähdä koneoppimisen algoritmien haarana (Kuvio 1) perustuen useiden eri tasojen kykyyn oppia, jotka samanaikaisesti vastaavat useita eri abstraktiotasoja. Kuvio 32 ilmenee, miten tekoälyjärjestelmän eri osat ovat yhteyksissä toisiinsa. Tummennetut laatikot ilmentävät komponentteja, jotka kykenevät oppimaan datasta. Lisäksi Kuvio 32 havainnollistaa, miten tekoäly on kehittynyt sääntöpohjaisista järjestelmistä sen koneoppimisen kautta syväoppimiseen saakka.

Sääntöpohjaiset järjestelmät ovat soveltuvia ohjelmointialgoritmeja noudattaen toteutettuja tekoälyohjelmia. Niiden vaatiman tietämyksen tuottavat kyseiseen alaan perehtyneet asiantuntijat, minkä vuoksi sääntöpohjaisia järjestelmiä kutsutaan asiantuntijajärjestelmiksi. Kyseiset järjestelmät sisältävät faktoja ja logiikkaa. Ne yhdistävät faktat kysymyksiin vastaamiseksi. Klassisessa koneoppimisessa syötteenä tulevat ominaisuudet suunnitellaan manuaalisesti ja järjestelmä automaattisesti oppii hyödyntämään niitä ulostuloihin. Tämänkaltaista koneoppimista käytetään. Se toimii hyvin yhden mallin (single pattern) tunnistamisen ongelmissa. Käytännössä suurin osa ajasta kuluu optimaalisten ominaisuuksien suunnitteluun, minkä jälkeen voidaan käyttää generistä luokittelijaa ulostulon saavuttamiseksi.

Vähäistä esityötä vaativaa ja koneoppimista painottavaa lähestymistapaa kutsutaan representaation oppimiseksi (representation learning). Representaation oppiminen menee yhden askeleen eteenpäin ja eliminoi ominaisuuksien manuaalisen suunnittelun tarpeen, Tärkeimmät ominaisuudet kyetään löytämään datasta automaattisesti. Neuroverkkojen ollessa kyseessä, ominaisuuksia voidaan automaattisesti oppia raakadatasta. Syväoppiminen on myös tietynlaista representaation oppimista, jossa on useita ominaisuustasoja. Nämä ominaisuudet voidaan löytää automaattisesti ja ne kootaan yhteen eri tasoilla ulostuloa varten. Jokainen taso edustaa abstrakteja ominaisuuksia, jotka perustuvat aina aiemman tason ominaisuuksiin. Tällöin abstraktiivisuus taso kasvaa aina jokaisella tasolla.

Tämänkaltainen oppiminen mahdollistaa korkeamman tason abstraktioiden löytämisen ja hyödyntämisen. Neuroverkoissa useampi taso vastaa useampaa ominaisuustasoa ja nämä useat kerrokset kokoavat ominaisuudet ulostuloa varten.



KUVIO 32. Tekoälyjärjestelmän osien yhteys toisiinsa. (Goodfellow, 2016)

2.4 Tekoälyn hyödyntämisen alueita

Tekoälyä on hyödynnetty viime vuosina useilla eri alueilla aina terveydenhuollosta sotilaskäyttöön ja älykkääseen infrastruktuuriin saakka. Tekoälyn hyödyntäminen terveydenhuollossa painottuu farmasian, insomnian, kardiologian, onkologian ja pulmonologian alueille. Erityisesti onkologian alueella on toteutettu merkittäviä diagnosoivia tekoälysovelluksia, joiden avulla on kyetty diagnosoimaan muun muassa ihosyöpiä, aivokasvaimia ja rinta- sekä keuhkosyöpiä. Tekoälyllä on myös muita lääketieteellisiä sovellusalueita ja sen avulla voidaan tunnistaa muun muassa silmäsairauksia, kuten kaihia ja sitä voidaan hyödyntää myös mielenterveydellisiin diagnosoointeihin, 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 diagnosoiteja, löytää uusia lääkeaineyhdistelmiä, tehdä hoitosuosituksia ja säästää kustannuksissa. Tulevaisuudessa sairaalat tulevat olemaan täynnä teknologiaa ja robotiikkaa tullaan hyödyntämään yhä enemmän. Sitä tullaan hyödyntämään leikkauksia suoritettaessa ja jatkossa myös logistiikassa, kuten sairaalasänkyjen ja tarvikkeiden automaattisessa kuljetuksessa. Sairaalasängyt voivat jatkossa kuljettaa potilasta itsenäisesti aina ensiapuhuoneesta operointihuoneeseen saakka, tarvittaessa kuvantamisen kautta. Tämä auttaa osaltaan vähentämään henkilöstön tarvetta.

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 diagnosoituihin sairastapauksiin tai taudinkuviin ja maailmalla oleviin lääketieteellisiin tutkimuksiin. Se 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.

Tekoälyä on hyödynnetty ja tullaan hyödyntämään yhä lisääntyvässä määrin myös muilla sovellusalueilla, kuten sotilaskäytössä. IBM Watsonin tarjoamaa tekoälyä onkin jo hyödynnetty Yhdysvaltain Pentagonissa hankintaprosessin toteuttamisessa hyödyntäen luonnollisen kielen prosessointikykyä. Tekoälyä voidaan käyttää myös taistelukentillä, jossa sitä ollaan hyödynnetty muun muassa oppimaan ihmisiltä tarkka-ampujan taitoja. Tekoäly yhdistyy hyvin myös robotiikkaan ja Yhdysvallat ovat hyödyntäneet tekoälyn mahdollisuuksia Perdix-lennokeissaan, jotka ovat toisiinsa mukautuvia kollektiivisia organismeja, joilla on hajautettu älykkyys päätöksentekoa varten. Ne kykenevät tulevaisuudessa suorittamaan tiedustelutehtäviä ja kohdistettuja hyökkäyksiä. Lennokkeja voidaan hyödyntää puolustushallinnossa valvomaan taistelukenttien muuttuvia tilanteita, generoimaan dataa muun muassa tekoälyä hyödyntävien järjestelmien seulottaviksi reaaliaikaisen automaattisen tilannekuvan muodostamiseksi.

3 Terveydenhuollon alustat ja tekoäly

3.1 Terveydenhuollon alustan määritelmä

Terveydenhuollon alusta voidaan Netscapen & Opswaren perustajan Marc Andreesonin mukaan määritellä seuraavasti: ”Alusta on järjestelmä, joka voidaan ohjelmoida ja siten räätälöidä ulkopuolisten kehittäjien toimesta”. Avaintermi alusta määritetään, että mikäli sen voi ohjelmoida, se on alusta. Alustan ulkopuolisen henkilön tulee voida ohjelmoida myös alustaa. Mikäli vain alustan kehittäjä voi ohjelmoida ”alustaa”, se ei ole alusta. (Shah)

Ideaalinen terveydenhuollon alusta tarjoaa Shah mukaan seuraavia asioita:

- Tarjoaa tyyppin 1 liitettävyyden REST-rajapinnan kautta, jota kolmannen osapuolen palveluntarjoajat voivat hyödyntää (yleisin alustatyyppi nykyään)
- Tarjoaa tyyppin 2 liitettävyyden Javan, .NET:n, PHP:n tai muun ohjelmointikielen liitännäisen (plugin) kautta, jota kolmannen osapuolen palveluntarjoajat voivat kehittää (esimerkkeinä tämän tyyppin alustoista ovat muun muassa Facebook ja LinkedIn)
- Tarjoaa tyyppin 3 suorituskyvykkyydet antamalla kolmannen osapuolen palveluntarjoajille mahdollisuuden suorittaa ohjelmakoodia pilvipalveluympäristössä (tämän tyyppin alustaesimerkkejä ovat muun muassa Salesforce.com ja Amazon.com)

Purao (2014) määrittelee alustan seuraavasti: ”IT-alustat ovat perustuksia, joiden päälle suunnittelijat voivat rakentaa muita asioita. Ne voidaan ensisijaisesti määritellä ominaisuuksiensa perusteella, jotka voivat yhtäaikaaisesti olla mahdollistavia tai rajoittavia. IT-alustat voivat olla laitteisto-ohjelmisto-paketteja tai ensisijaisia ohjelmistoalustoja. Alustat ovat kehittyneet avoimemmiksi, vaikka on olemassa poikkeuksia, kuten Applen alustat. Informaatioteknisillä alustoilla on tärkeä merkitys, koska ne ovat läheisessä yhteydessä liiketoiminnallisiin strategioihin. Niitä voidaan käyttää haastamaan ekosysteemejä.

Tavanomaisen terveydenhuollon alustan lisäksi on tärkeää määritellä myös terveydenhuollon mobiilialusta, sillä nykyään yhä enemmän toimintoja integroidaan älypuhelimiin ja niistä on tullut osa ihmisten jokapäiväistä elämää ja niiden teknologia alkaa olla riittävää toimimaan osana terveydenhuollon alustaa. Ne ovat esimerkiksi osa potilaan vitaalin datan keräämistä ja lähettämistä terveydenhuollon järjestelmään ja siten asiantuntijoiden tarkasteltavaksi. Tämän lisäksi ne voivat toimia kommunikation sekä diagnoosien teon välineinä aiempaa huomattavasti paremmin.

Terveydenhuollon mobiilialusta voidaan määritellä keskipisteeksi (hub), joka vastaanottaa informaatiota kaikista sairaalajärjestelmän osista ja organisoii vastaanotetun informaation yhteen paikkaan mobiilisovellusta käyttävän loppukäyttäjän eli potilaan tarkasteltavaksi. Informaatio voi olla potilaan tietoturvallista viestittelyä lääketieteen ammattilaisen, kuten

lääkäriin tai hoitajan kanssa esimerkiksi vastaanottaen laboratoriotuloksia tai vaihtamalla potilasinformaatiota. (Barreau, 2015)

Tehokkaassa mobiilissa terveydenhuollon alustassa on kolme pilaria (Barreau, 2015):

- Laajennetut tietoturvalliset viesti- ja kommunikaatiotoiminnot tehden helpoksi palvelun tarjoajille ja hoitajille työskennellä yhdessä ja parantaa tehokkuutta
- Järjestelmien integrointi, tarjoten saumattoman integraation jo olemassa oleviin terveydenhoidon ohjelmistoihin ja järjestelmiin
- Kliinistä innovointia tuottamalla mobiilipalveluita ja ominaisuuksia, jotka parantavat lääketieteen ammattilaisen työnvirtaa ja lopulta potilashoitoa

3.2 Tekoälyn hyötyjä terveydenhuollon ekosysteemeissä

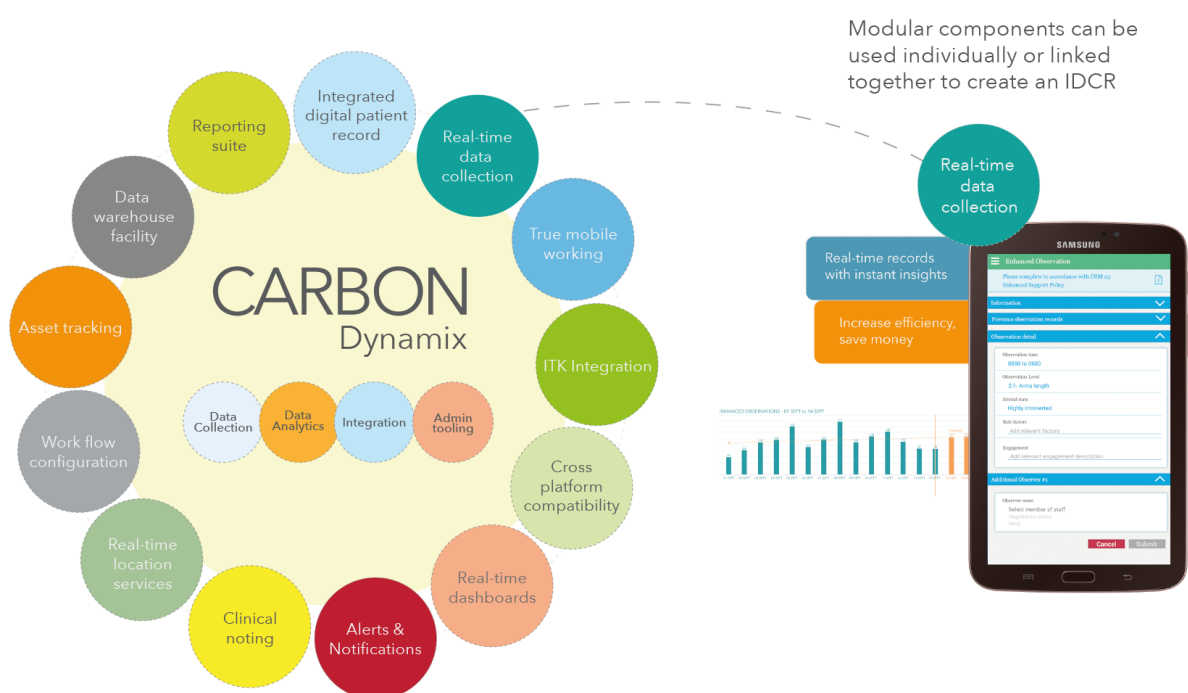
Tekoälyn hyötyjä terveydenhuollossa Eubanks (2017) mukaan ovat:

- Kustannustehokkuus, joka realisoituu tekoälyä hyödyntävän järjestelmän kehittämisen ja opettamisen jälkeen. Tekoäly kykenee prosessoimaan miljoonia tietueita lähes reaaliajassa ja pienemmin kustannuksin.
- Tekoälyn avulla voidaan tehokkaasti toteuttaa laajojen aineistojen keräämistä ja lähes reaaliaikaista prosessointia. Aineistoa voidaan kerätä muun muassa päälle puettavista laitteista, kuntoiluun tarkoitettuista seurantalaitteista tai IoMT (Internet of Medical Things)-laitteista, jotka keräävät pitkittäistä dataa henkilön terveydentilasta. Tulevaisuudessa ihmisistä tulee tietynlaisia datakeskuksia, jotka tuottavat huomattavan määrän dataa elämänsä aikana. Tekoälyä hyödyntäviltä digitaalisilta assistenteilta voidaan pyytää päivityksiä terveyteen liittyvistä asioista ja suosituksia dieettiä, elämäntyyliä ja hoitoihin sitouttamiseen liittyvien protokollien suhteen.
- Tekoälyn konfiguroinnin ja testaamisen jälkeen se kykenee tuottamaan toistettavia ja luotettavia tuloksia. Ihmisiin vaikuttavat tekijät, kuten väsymys, stressi ja tunteet eivät vaikuta algoritmin tehokkuuteen. Tekoälyä tullaan käyttämään lievittämään uhkaavaa lääkäripulaa ja parantamaan hoidon laatua. Röntgenlääkärit ovat teknologian aikaisia omaksujia ja he kykenevät hyödyntämään sitä yhä monimutkaistuvien lääketieteellisten kuvien analysointiin, tarjoamaan alkuvaiheen suosituksia sekä vähentämään ihmisten tuottamia virheitä.
- Ideaalitulanteessa tekoäly tarjoaa puolueettoman analyysin. Tekoäly, toisin kuin ihmiset, ei tee tahallisia virheitä. Mahdollista kuitenkin on, että virhe tai virheet ovat jo luonnostaan suunniteltuina malliin. Tällaisia voivat olla esimerkiksi ihmisten mielipiteet, joita on ilmaistu matemaattisten mallien avulla.

3.3 Terveydenhuollon alustoja ja mobiiliteknologiaa

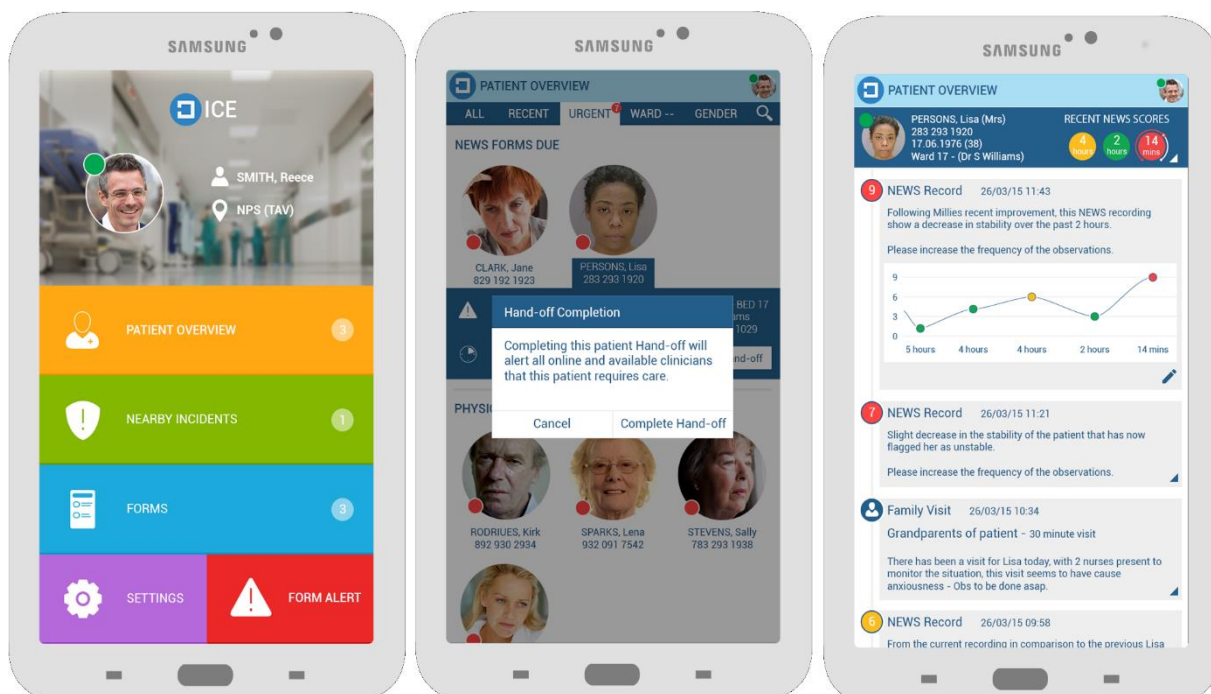
3.3.1 Comtact Healthcaren digitaalinen alusta

Terveydenhuollon organisaatiot voivat parantaa prosessejaan merkittäväällä tavalla ja saada aikaiseksi huomattavia säästöjä operationaalisissa kuluissa tunnistamalla prosesseja, jotka johtavat päällekkäisiin toimintoihin, heikkoon varojen hyödyntämiseen, hitaaseen informaatiovirtaan sekä hitaaseen potilaiden paranemiseen. Ratkaistakseen ongelman, Comtact Healthcare on kehittänyt joustavan pilvipohjaisia terveydenhuollon sovelluksia sisältävän digitaalisen alustan (Kuvio 33). Terveydenhuollon palvelujen tuottajat voivat ottaa sovelluksia käyttöön taktisesti terveydenhuoltoa mobilisoidakseen ja bolla tyytyväisiä siihen, että aiemmin sirpaleinen terveydenhuollon informaatioteknologia voidaan yhdistää yhdeksi yhdistyneeksi IT- ja palveluinfrastruktuuriksi. (Comtact Healthcare, 2016)



KUVIO 33. Comtact Healthcare digitaalinen terveydenhuollon alusta. (Comtact Healthcare, 2016)

Comtact-alusta mahdollistaa digitaalisten lomakkeiden hyödyntämisen (Kuvio 34), mikä tarjoaa tehokkaan ja saumattoman tavan vähentää paperipohjaisten lomakkeiden käyttöä ja lisäksi mahdollistaa sairaalan henkilöstölle digitaalisen työskentelyn reaaliajassa, tuoden mukanaan kustannussäästöjä kaikilla sairaalan yksiköiden tasoilla. Digitaalisten lomakkeiden myötä dataa voidaan kerätä digitaalisesti sekä integroida ja analysoida sopivalla tavalla. Alusta mahdollistaa esimerkiksi yleiskuvan saamisen potilaista, tarjoaa tietoa läheisistä tapahtumista ja tekee hälytyksiä, jolloin terveydenhuollon henkilöstön on mahdollista reagoida tilanteen niin vaatiessa. (Comtact Healthcare, 2016)




KUVIO 34. Digitaaliset lomakkeet. (Comtact Healthcare, 2016)

Comtact Healthcaren digitaalinen alusta sisältää myös mahdollisuuden hyödyntää tietovarastointiratkaisua, joka reaaliajassa yhdistää kojelauta-näkymään (Kuvio 35) dataa useista erillisistä tietolähteistä ja sovelluksista koko sairaalan ympäristöstä. Tämänkaltainen sisällön hallintaratkaisu antaa mahdollisuuden muodostaa raportteja ja visualisoida informaatiota kojelautoihin nopeasti ja helposti ja siten tarjota oleellista tietoa esimerkiksi sairaalan johdolle, jotta he voivat tehdä tilanteen vaatimia tarkkoja ja nopeita päätöksiä sekä parantaa potilashoitoa yleensä. (Comtact Healthcare, 2016)



KUVIO 35. Tietovarastointiratkaisu ja datan visualisointi kojelautoihin. (Comtact Healthcare, 2016)

Alustaan sisältyy myös reaaliaikainen paikannusjärjestelmä (Real Time Location System eli RTLS). Järjestelmä hyödyntää RFID (Radio Frequency Identification)-teknologiaa, jonka avulla paikannusjärjestelmä kykenee välittämään reaaliaikaista informaatiota lääketieteellisten, sairaalan henkilöstön, potilaiden ja potilastietojen tietueiden käytöstä ja sijainnista. Paremman paikannettavuuden myötävaikutuksesta terveydenhuollon ammattilaiset kykenevät tuottamaan parempaa potilashyvinvointia, reagoimalla tilanteisiin nopeammin. Paikannettavuus lisää myös henkilöstön hyvinvointia, sillä heidän ei tarvitse turhautua joutuessaan etsimään laitteita niitä tarvittaessa. Palvelu pitää lisäksi sisällään tehokkaan hälytysratkaisun henkilöstöön kohdistuvan hyökkäyksen (Kuvio 36). Se mahdollistaa pikayhteyden (Push to talk eli PPT) kommunikaation yksittäisten henkilöiden välillä tai broadcast-lähetysperiaatteella koko henkilöstölle. (Comtact Healthcare, 2016)



KUVIO 36. Paikkatietoinen viestityspalvelu. (Comtact Healthcare, 2016)

Reaaliaikainen paikannus tarjoaa kaksisuuntainen kommunikaation ja tarkan työkalun jäljittämiseen metrin tarkkuudella. Hälytyksen tultua saa tiedon hälytyksestä ja sijainnista, josta hälytys on tullut. Näin he voivat vastata tilanteeseen nopeammalla vasteajalla. Useimmiten sairaalat luottavat liikaa useisiin eri hälytysjärjestelmiin. Henkilöstöön kohdistuviin hyökkäyksiin liittyvissä hälytyksissä ja usein koko henkilöstö RTLS:n kanssa sekä hälytyksen tehnyt henkilö pitää vielä paikantaa sairaalan tiloista. Reaaliaikainen paikantamisjärjestelmä kitkee pois epä johdonmukaisuuksia, standardisoi prosesseja ja vähentää tehottomuutta. (Comtact Healthcare, 2016)

Digitaalisen jäljityksen avulla voidaan myös helposti löytää sairaalan laitteistoja, mikä johtaa suurempaan potilashoidon tehokkuuteen ja parantuneeseen henkilöstön moraalisiin. Lääketieteellisten laitteiden tai välineiden katoaminen kuten pyörätuoli voi viivästyttää potilashoitoa, joka voi osaltaan vaikuttaa muiden potilaiden tai henkilöstön aikatauluihin sekä yleiseen potilaalle tarjottuun hoidon tasoon. (Comtact Healthcare, 2016)

3.3.2 HealthSaaS kognitiivinen IoT-alusta potilasmonitorointiin

HealthSaaS on kognitiivinen potilasmonitorointiin tarkoitettu alusta (avainominaisuudet ovat esiteltyinä taulukossa 1), joka kerää kliinistä dataa potilaille määräytyistä laitteista ja siirtää mitatun informaation terveydenhuollon ammattilaisille kliinisiä tarkastuksia, potilastoimenpiteitä ja koulutusta varten. Laajalle levinnyt teknologian käyttöönotto voi johtaa merkittäviin kustannussäästöihin johtuen vähentyneistä potilaiden uusintajaksoista sairaaloissa, tarpeettomien lääkärikäyntien vähenemisistä, parantuneesta lääkityksen soveltuvuudesta potilaille sekä kommunikaatiosta potilaiden ja terveydenhuollon ammattilaisten välillä. (HealthSaaS)

HealthSaaS-alusta on helppokäyttöinen, kotona hyödynnettävä IoT-monitorintiratkaisu potilaille, joilla on krooninen tai kriittinen lääketieteellinen tila, kuten diabetes, verenpainetauti, eteisvärinä, sydämen vajaatoiminta, astma tai keuhkohtaumatauti. Alusta integroituu helposti kotiolosuhteissa käytettäviin lääketieteellisiin laitteisiin, kuten verenpaine- ja aktiivisuusmittareihin, pulssioksimetreihin ja kehon koostumusta mittaaviin vaakoihin. Eräs uusimmista HealthSaaS-alustaan liitettävissä olevista lääketieteellisistä laitteista (Kuvio 37) on matalaenergistä bluetooth-protokollaa (BLE eli Bluetooth Low Energy) hyödyntävä lääkerasia, joka tukee lääkityshoitoon sitoutumista. (HealthSaaS)



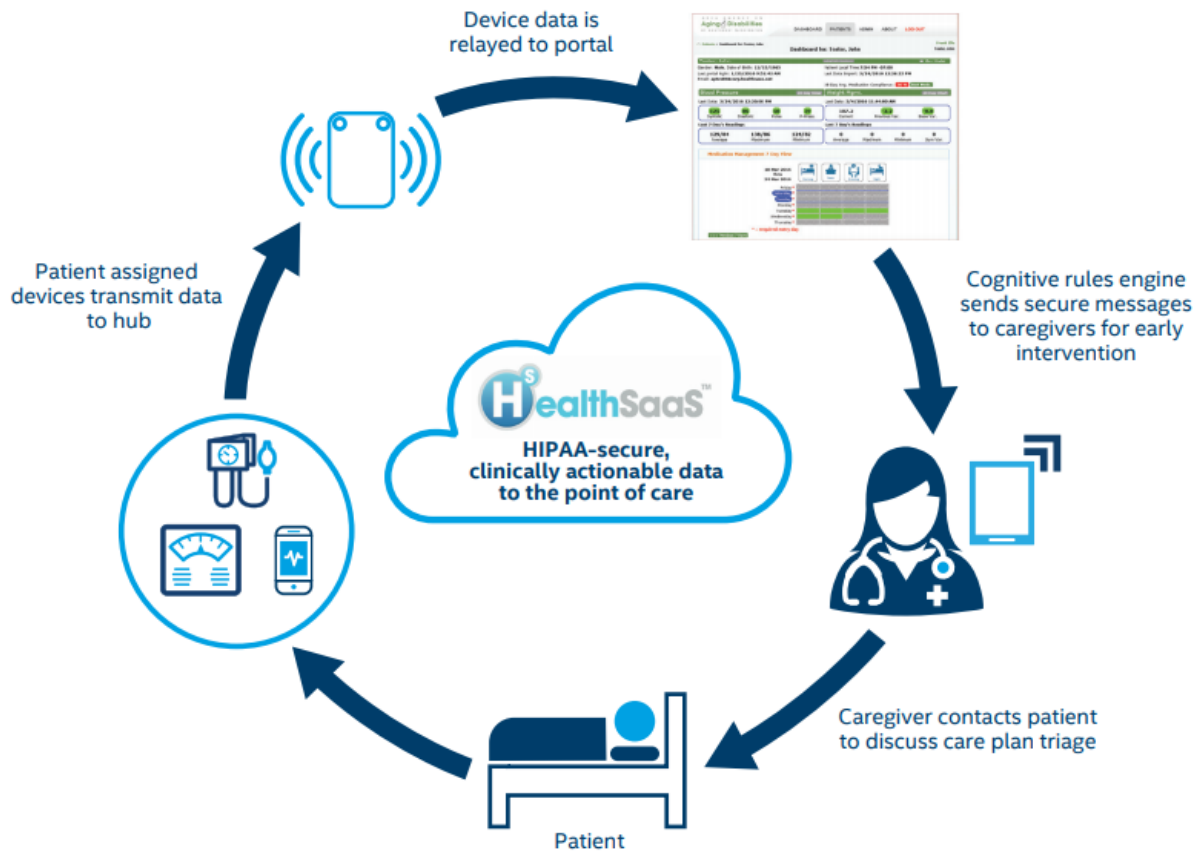
KUVIO 37. BLE-yhteydellä toimiva lääkityshoitoon sitoutumista tukeva dosetti. (HealthSaaS)

HealthSaaS-alustan avainominaisuuksia ovat seuraavat:

Potilaille	Palvelun tarjoajille	Terveydenhuollon IT:lle
Järjestele, yhdistää ja hallitsee potilaslaitteita	Lääkärit voivat määrätä potilaille laitteita	Terveydenhuollon IT-datan viestipalvelut
Lääkityksen hallinta	HIPAA-yhteensopiva klinikon/palvelutarjoajan portaali, joka on linjassa terveydenhuollon parhaiden käytänteiden kanssa	BLE-älylaittekeskus (tuki Androidille, Windowsille ja iOS:lle)
Potilasportaali, joka tarjoaa helposti ymmärrettävän visuaalisen datan	Kojelaudat ja raportointityökalut datan visualisointiin terveydenhuollon ammattilaisille	Hierarkkiset turvallisuusominaisuudet portaaliin pääsyn hallintaan
-	Kognitiivisen triage-ilmoituspalvelut	Kustomoitu uniikkeja vaatimuksia varten
-	HIPAA-turvallinen viestintä	-

TAULUKKO 1. HealthSaaS-alustan avainominaisuudet. (HealthSaaS)

HealthSaaS yhdistää siiloutunutta dataa useista eri lähteistä ja järjestelmistä (Kuvio 38) tarjotakseen yhdistetyn ja kliinisesti relevanttia dataa terveydenhuollon ammattilaisille ja heidän asiakkailleen. Kodeissa käytetyistä sairauksien monitorointilaitteista tulevan datan tietoturva ja suodatus on varmistettu Intel Health Application-alustan ohjelmistolla, jolloin se voidaan turvallisesti siirtää HealthSaaS-portaaliin tai muihin pilvipohjaisiin palveluihin. Mittalaitteistoista siirretty data kerätään, varastoidaan ja siirretään eteenpäin lähes reaaliajassa ilman, että potilaan tarvitsee huolehtia asiasta laitteen käyttöä lukuun ottamatta. Data jäsenellään ja esitetään visuaalisessa muodossa, jotta terveydenhuollon ammattilaisten päätöksenteko voi nopeutua.



KUVIO 38. Potilaan ja THL-ammattilaisen kommunikointi alustan avulla. (HealthSaaS)

Teknisesti HealthSaaS-alusta on toteutettu hyödyntäen Microsoftin .NET-työkaluja ja Azure-pilvipalvelua. Ratkaisu yksinkertaistaa palvelun toteuttamista tarjoten muun muassa terveydenhuollon organisaatioiden sensitiivisen datan kontrolloinnin, HIPAA-yhteensopivuuden ja sertifiointit, kuten SAS 70 Type II, FISMA ja ISO 27001. Alusta kykenee hyödyntämään Bluetooth- ja BLE-datasiiirtoa potilaiden laitteista älypuhelimien, tablettien ja Intelin IoT-alustan kautta HealthSaaS-portaaliin tai muihin pilvipohjaisiin palveluihin. Alusta tukee myös liitettävyyttä useiden muiden laitevalmistajien laitteiden kanssa. HealthSaaS:n jokainen yhteys on autentikoitu ja salattu ja kaikki datasiirto tapahtuu SSL (HTTPS)-protokollaa käyttäen. Tämä on oleellista sensitiivisen datan käsittelyssä, jolloin arkaluonteisen tiedon vuotaminen julkisuuteen voi olla merkittävä riskitekijä. Alustan tietoturva- ja tietojärjestelmäkokonaisuudet ovat asioita erillään, käyttämään erillisiä tietokantapalvelimia, millä pyritään parantamaan tietoturvaa. (HealthSaaS)

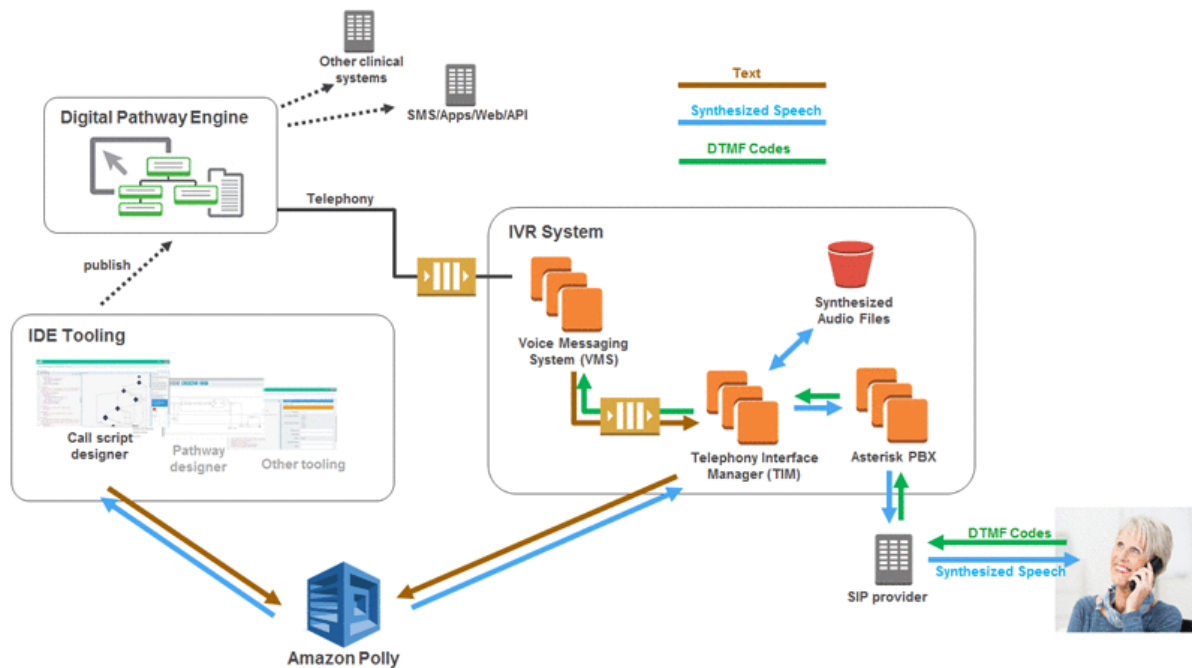
HealthSaaS on edullinen alustaratkaisu esimerkiksi älykodin terveydenhuollon palveluita järjestettäessä. Alustan hyödyntäminen tuo monia etuja, kuten vähentää sairaalavierailujen uusiutumista, uudelleenohjaa asiaan kuulumattomia vierailuja ensiavussa ja vähentää kuluja. Yhdysvalloissa yksi viidestä Medicare-vakuutukseen kuuluvasta potilaasta palaa sairaalaan 30 päivän aikana aiemmasta sairaalajaksosta. Uusiutuneet sairaalajaksot aiheuttavat 17 miljardin yhdysvaltain dollarin vuosittaiset kulut. Ensiapuvierailuista 14 - 27% ovat kiireettömiä. Vaihtoehtoiset hoitopalvelut voisivat säästää 4.4 miljardia dollaria vuosittain

terveydenhuollon kuluina. Etähoito laajentaa ja helpottaa hoidon saatavuutta sekä vähentää kuluja, koska ei tarvita investointeja rakennuksiin. HealthSaaS-alusta mahdollistaa laajojen hallintakyvykkyyksien saatavuuden ja mikäli palveluita kehitetään yhteistyössä terveydenhuollon organisaatioiden kanssa, ne vaikuttavat kotona tapahtuvan potilashoidon vaatimuksiin. HealthSaaS:n tarjoaman teknisen tuen lisäksi palveluntarjoaja tarjoaa asiantuntemusta alustan kehittämiseksi terveydenhuollon organisaatioiden tarpeisiin. (HealthSaaS)

3.3.3 Inhealthcare digitaalinen terveydenhuoltoalusta

Inhealthcare tarjoaa digitaalisen terveysteknologiaan erikoistuneen alustan, erikoistuen tarjoamaan terveydenhoitoa koko Britanniassa. Inhealthcare-alusta (Kuvio 39) yhdistyy aiemmin toteutettuihin terveydenhuollon ohjelmistojärjestelmiin ja mahdollistaa kliinisten protokollien ja reittien mallintamisen, luonnin, testaamisen, toteuttamisen ja monitoroinnin. Tärkeää on valita oikeanlainen kommunikaatiotapa etäpalveluita toteutettaessa. Ihmisille sovellukset, päälle puettavat laitteet ja palvelut ovat sopivin tapa toisille palveluita hyödyntää, mutta toisille niiden käyttö voi olla haastavaa. Tekstiviestit tai automatisoidut puhelinpalvelu voivat olla toisille parempia vaihtoehtoja. (Wray, 2017)

Interaktiivisia ääniohjattuja vastauspalveluita (IVR eli Interactive Voice Response) on ollut olemassa jo kauan, miksi jokainen osaakin käyttää niitä. Ne mahdollistavat kaksisuuntaisen kommunikaation, jossa tietokone voi kommunikoida ihmisen kanssa käyttämällä syntetisoitua ääntä ja ihminen voi kommunikoida tietokoneen kanssa. Puhelimen näppäimet lähettävät tietokoneelle DTMF (Dual Tone Multi Frequency) –koodeja, jotka voivat ihminen voi myös kuulla näppäilemällä puhelimen kirjaimia tai numeroita. IVR-palveluita voidaan käyttää esimerkiksi mobiilissa kaupankäynnissä, pankkimaksujen ja palveluiden hyödyntämisessä tai hankittaessa lisätietoa esimerkiksi säästä tai matkoista. (Wray, 2017)



KUVIO 39. Inhealthcare-alustan toiminta ja Amazon Polly. (Wray, 2017)

Inhealthcare-alusta sisältää digitaalisen reitti, joka automaattisesti hallitsee ja organisoii etäyhteyksiä. Integroitu kehitysympäristö (IDE) tarjoaa työkalut kliinisten reittipalveluiden ja protokollien suunnittelua ja rakentamista varten, jotka julkaistaan digitaaliselle reittimoottorille. Skriptisuunnittelijaa, joka on IDE-kehitysympäristön elementti, käytetään automaattisten puhelinsoittojen rakentamiseen. Sopivana ajankohtana kliinisen protokollan julkaisemisen jälkeen lähetetään viesti VMS:lle (Voice Messaging System), joka on puhelinsoittojen hallinnasta vastuussa oleva palvelu. Puhelinsoitto voi kestää sekunneista useaan minuuttiin riippuen soittoskripteistä. Soittoskriptien tulkitseminen, soittojen tilan hallinta ja tilan raportointi takaisin reittimoottorille on VMS:n vastuulla. Soittoskriptien prosessoinnin aikana VMS laittaa käskyjä jonoon, joita TIM (Telephone Interface Manager) suorittaa. (Wray, 2017)

Ensimmäinen suoritettavista käskyistä on soittaa puhelu. Tämä toteutetaan Asteriskin avulla, joka on avoimen lähdekoodin PBX-järjestelmä. Kyseinen järjestelmä on konfiguroitu olemaan yhteydessä SIP-runkopalveluiden (Session Initiation Protocol) tarjoajaan, joka on puhelinjärjestelmissä yleisesti käytetty protokolla. Puhelun käynnistyttyä VMS käy läpi soittoskriptin ja informaatio toimitetaan syntetisoituneena puheena Amazon Polly hyödyntäen. Puhelun vastaanottajan vastaukset syötetään alustaan DTMF-koodeina, joita vastaanottaja lähettää puhelimen näppäimistöä numeroita tai kirjaimia valiten. Realistiselle keskustelulle oleellista on, että Polly vastaa nopeasti eli sen latenssin (viive) tulee olla pieni. Viiveet voivat aiheuttaa käyttäjissä turhautumista ja saada aikaan puhelun lopettamisen. Testien mukaan Amazon Pollyn latenssi on 50 ms, joka on hyvin pieni. Silloin keskustelu on toimivaa. (Wray, 2017)

Inhealthcaren alustan käyttäminen sisältää seuraavia vaiheita:

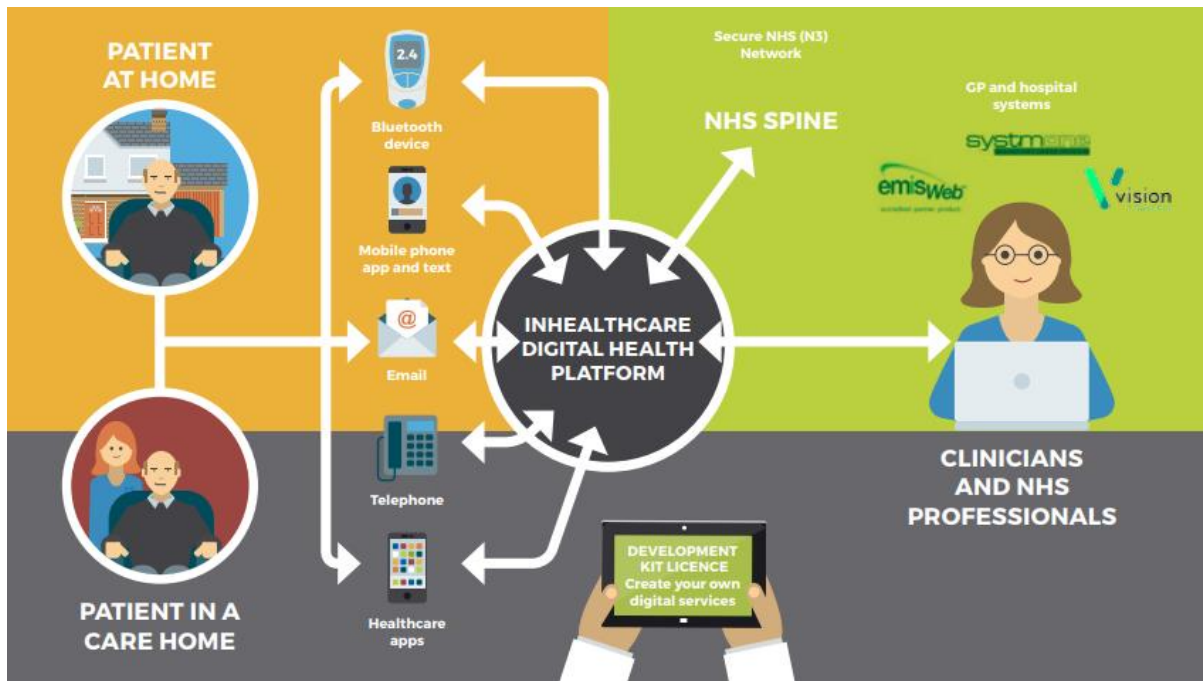
1. Rakennemoottorin rakentamisen työkalut
 - Suunniteltu nopeaan innovointiin
 - Mahdollistaa terveydenhuollon toimijoille omien digitaalisten palveluiden nopean kehittämisen

2. Aiemmat digitaaliset terveyspalvelut
 - NHS:n lääkäreiden jo aiemmin suunnittelemat palvelut, joita Inhealthcaren alustan käyttöönoton yhteydessä voidaan hyödyntää
 - NHS:n suunnittelemissa palveluissa on muun muassa seuraavilla alueilla:
 - o Aliravitsemus
 - o Diabetes
 - o Keuhkoastma
 - o Krooninen kipu
 - o Leikkauksen lopputuloksen seuranta
 - o Lääkityksen muistuttajat
 - o Mielenterveys
 - o Painonhallinta

3. Kommunikaatiokanavat
 - Potilas valitsee, miten hän lähettää mitatut terveystiedot lääkärille. Mahdollisia tapoja (Kuvio 40) ovat muun muassa:
 - o Bluetooth-protokollaa hyödyntävät laitteet
 - o Inhealthcare älypuhelinsovellus
 - o Kolmannen osapuolen sovellukset
 - o Puhelinsoitto
 - o Tekstiviesti
 - o Web-portaali

4. Kolmannen osapuolen hyväksytyt terveydenhuollon sovellukset (viitekehys)
 - Kolmannen osapuolen sovelluksille tietoturallinen ympäristö NHS:n infrastruktuuriin
 - Inhealthcare auttaa datan hallinnan käytänteissä sallien tietoturallisen potilasdatan tiedonsiirron terveydenhuollon järjestelmiin

5. Täysi integraatio sairaala- tai muihin terveydenhuollon järjestelmiin
 - Kaikki Inhealthcaren palvelut sisältävät täyden integraation terveydenhuollon järjestelmiin



KUVIO 40. Inhealthcaren kansallinen digitaalinen terveysalusta. (Inhealthcare)

3.3.4 Mining Minds-alusta

Mining Mind on innovatiivinen digitaalinen terveydenhuollon puitteissa toimiva viitekehys, joka on erikoistunut yksilölliseen terveydenhoitoon ja hyvinvoinnin tukemiseen. Alusta huomioi teknologioiden ja sovellusten tuomia oleellisia digitaalisen terveyden ja hyvinvoinnin vaatimuksia. Alusta on toteutettu monikerrosarkkitehtuurin avulla, joka on suunniteltu tarjoamaan tarvittavan toiminnallisuuden yksilökeskeisen terveydenhuollon ja hyvinvoinnin tarpeet huomioiden. Arkkitehtuuri on tulosta sekä teknisestä että liiketoimintasuuntautuneesta tutkimuksesta ja voi olla hyödyksi uuden liiketoimintaekosysteemin luonnissa terveydenhuollossa, hyvinvoinnissa ja muilla osa-alueilla. Mining Minds-alusta koostuu kokoelmasta innovatiivisia palveluita, työkaluja ja tekniikoita, joita voidaan hyödyntää ihmisen päivittäin eri monipuolisista lähteistä tuottaman datan tutkimisessa. Alusta jakaantuu kolmeen kerrokseen (Kuvio 41), jotka ovat Data Curation Layer (DCL), Information Curation Layer (ICL) ja Service Curation Layer (SCL) sekä lisäksi on Supporting Layer (SL). (Banos ym., 2015)

Data Curation Layer eli DCL on vastuussa sensorikerrokselta tulevan datan tietojen käsittelystä ja edelleen lähettämisestä Information Curation Layerille (ICL). Sensorikerros määrittelee mahdolliset käyttäjän terveys- ja hyvinvointidatan lähteet. Niitä ovat esimerkiksi kysymykset ja päälle puettavat biolääketieteelliset laitteet. DCL on vastuussa useasta eri lähteestä tulevan yhteydellisen ja yhteydettömän datan hankinnasta, nimeämisestä ja analyysistä. Vastaanotetun datavirran formaatit riippuvat lähteinä olevien sensorilaitteista. Rakenteeton data konvertoidaan DCL-kerroksella puolistrukturoituun formaattiin. Datan määrän ollessa suuri ja monimuotoista, mahdollisuus redundanssiin ja kohinaan on suuri,

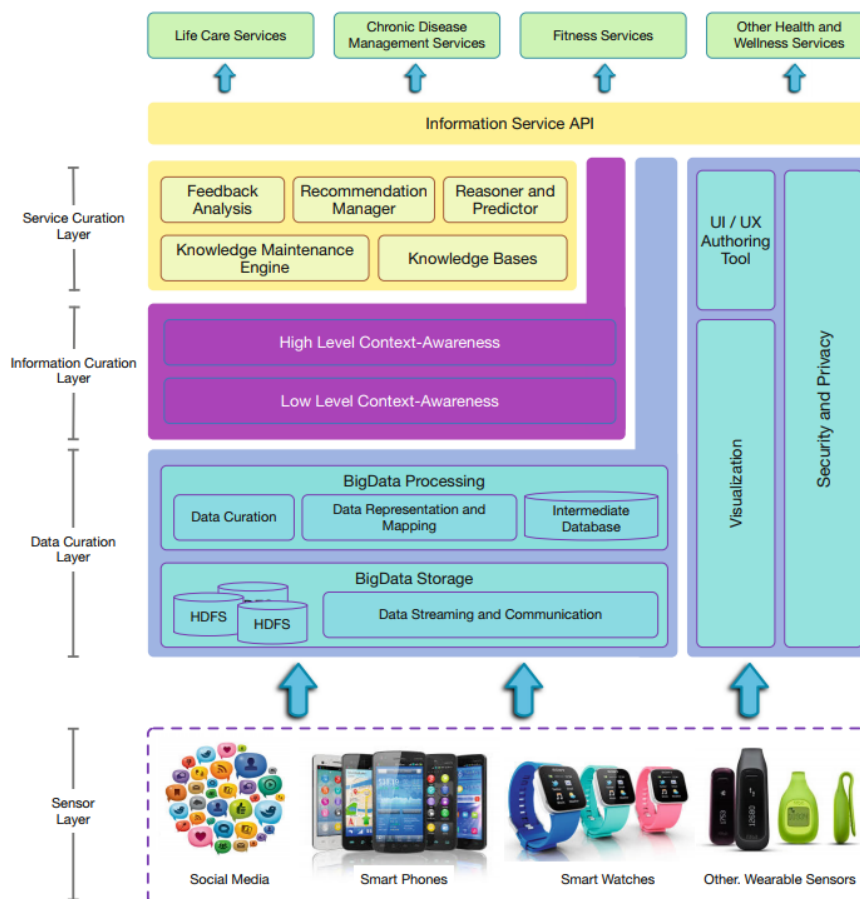
jolloin datavirta analysoidaan käyttäen useita erilaisia suodattimia, jotta datan luotettavuus voidaan taata. Reaaliaikaisen datan analysoinnin lisäksi DCL-kerros varmistaa myös jo aiemmin tallennetun datan luotettavuuden. Analysoinnin jälkeen datavirrat ohjataan Data Representation ja Mapping-komponenteille, joiden rooli on sopeuttaa data standardien määritelmien mukaiseksi. Standardoitua dataa voivat myös muut Mining Mind-alustan kerrokset ja kolmannen osapuolen komponentit ja sovellukset ymmärtävät ja jakavat. Määritelmä perustuu ontologiaan, jossa data on merkitty ja analysoitu sekä virta on yhdistetty ontologisiin resursseihin, jotka edustavat dataa hierarkkisine resursseina. Tämä ns. sopeutettu malli lähetetään edelleen persistenssille tietojen varastoinniseksi. Varastoitu data on sen jälkeen muiden Mining Mind-kerroksien saatavilla Intermediate-tietokannan kautta. Intermediate-tietokanta on nopean varastoinnin yksikkö, joka väliaikaisesti varastoi dataa, jota tarvitaan nopeasti käyttöön. (Banos ym., 2015)

ICL-kerros edustaa Mining Mindsin ydintä käyttäjäkontekstin ja käyttäytymisen mallinnuksissa. Kerros jakautuu kahteen alikerrokseen, jotka ovat LLCA (Low Level Context Awareness) ja HLCA (High Level Context Awareness). LLCA vastaa käyttäjäinteraktioiden sekä reaali- ja kybermaailman kanssa konvertoitunutta dataa abstrakteiksi konsepteiksi ja kategorioiksi, kuten fyysisiksi aktiviteeteiksi, tunnepohjaisiksi tiloiksi, sijainneiksi ja sosiaalisiksi malleiksi. Nämä kategoriat on yhdistetty älykkäästi tavalla ja ne prosessoidaan HLCA-kerroksessa, jotta käyttäjän normaalia käyttäytymistä voidaan seurata. LLCA-kerros rakentuu neljästä komponentista, joissa on useita toimintoja, kuten SNS-analyysi eli sijainnin tunnistamista. SNS-analyysi viittaa käyttäjän interaktioon some-verkkojen, kuten Facebookin ja Twitterin kanssa, jolloin generoituu analysoitavaa dataa. Tämä sisältää esimerkiksi käyttäjän itsensä generoimat postitukset ja Twiitit, käyttäjien maininnat, globaalit sosiaaliset trendit ja teksti- ja multimediamuotoisena datana. (Banos ym., 2015)

Toiminnan tunnistusprosessi viittaa primitiivisten fyysisten toimintojen tunnistamiseen, joita käyttäjä suorittaa, kuten seisominen, käveleminen ja juokseminen. Prosessi rakentuu useisiin modalityetteihin, kuten päälle puettaviin inertiaalisensoreihin, videoon ja audioon. Tunteiden tunnistamisen prosessi on määritelty osoittamaan käyttäjän emotionaalisia tiloja, kuten iloisuus ja ahdistuneisuus, hyödyntämällä sensoridataa. Käyttäjän tilanteen määrittämiseksi on tärkeää seurata myös käyttäjän liikettä, joka voidaan toteuttaa sisä- ja ulkotiloja varten suunniteltuja sensoreita hyödyntäen, kuten esimerkiksi GPS. LLCA-kerroksella generoitu data yhdistetään ja välitetään DCL-kerrokselle, Mining Minds komponentteja ja sovelluksia varten. LLCA- ja HLCA-kerroksien informaatio tallennetaan säännöllisesti Intermediate tietokantaan, jossa se on hyödynnettävissä muun muassa SCL-kerrokselle ja muille potentiaalisille tahoille. (Banos ym., 2015)

SCI-kerros tarjoaa keinot, joiden avulla DCL- ja SCL-kerroksien generoima data ja informaatio voidaan siirtää todellisille palveluille. Kerros tukee automaattista ja asiantuntijapainotteista tietämyksen luontia ja ylläpitoa, personoituja suosituksia, ennakoitua sekä käyttäjien

palauteanalyysia. Tietämyksen luonti-kyvykyys aktivoidaan hyödyntäen datapohjaista, tietoon perustuvaa tai hybridiä lähestymistapaa. Luotu tietämys, joka sijaitsee SCL-kerroksen tietämyskannoissa, vaihtelee abstraktista tai yleisestä tietämyksestä käyttäjäkohtaiseen tietämykseen. SCL-kerroksessa hallittua tietämystä käytetään generoimaan yksilöllisiä terveys- ja hyvinvointisuosituksia. Ensiksi Reasoner-komponentti hyödyntää tietämyksen abstraktia tasoa generoimaan yleisiä suosituksia, jotka myöhemmin Recommendation Manager personoi, kun seuraavaksi recommendation manager hyödyntää personoitua tietämystä, joka koodaa käyttäjien mieltymyksiä ja kontekstietoja. Personoitujen suosituksien käyttäjälle lähettämisen jälkeen, voidaan saada palaute joko niiden hyväksymisestä tai hylkäämisestä. Esimerkiksi suosituksia ei seurata. Lopuksi palaute analysoidaan ja analysoituja tuloksia voidaan hyödyntää varmistamaan yhä personoidumman sekä riittävän terveyden- ja hyvinvoinnin tuen. (Banos ym., 2015)

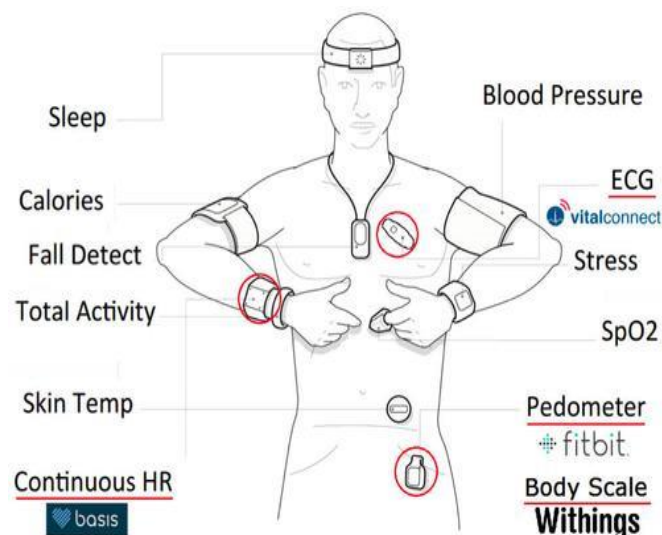


KUVIO 41. Mining Minds-alustan arkkitehtuurikaavio. (Banos, 2015)

3.3.5 Samsung SAMI terveydenhuollon palvelualusta

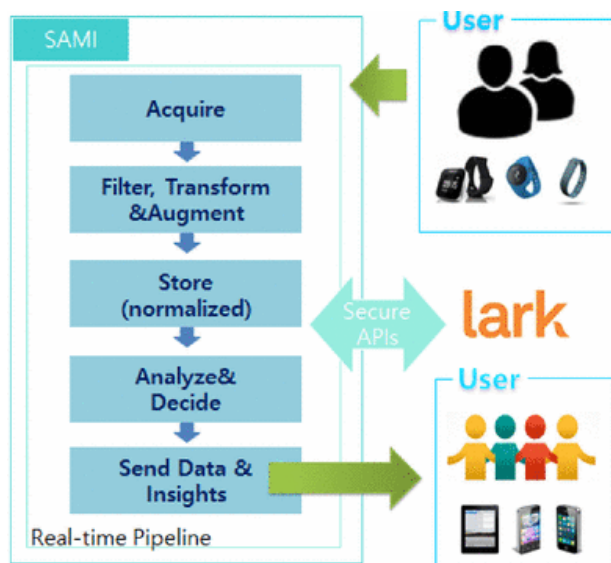
Samsung on kehittänyt pilvipohjaisen laitteisto- ja ohjelmistoalustan, SAMI (Samsung Architecture for Multimodal Interactions). Se on Applen Siriä muistuttava alusta, joka yhdistelee, kerää, analysoi ja jakaa käyttäjiensä henkilökohtaista terveysdataa. Erilaisia bioinformaatiota mittaavia laitteita (kuten IoT-laitteet) voidaan hyödyntää keräämään sekä analysoimaan biosignaaleita, joista muodostettu data välitetään Samsungin alustaa käyttävällä henkilöllä mobiililaitteen välityksellä. SAMI-alustan tietovarasto sijaitsee pilvipalvelimella, johon on kerätty terveysdataa useista eri lähteistä. Alusta käsittelee dataa kontekstintunnistus- ja analysointiprosessin kautta ennen sen toimittamista käyttäjille. (Chung & Park, 2017)

SAMI-alustan kanssa samaan aikaan julkaistiin SimBand. SimBand on laitteistoalusta, jota hyödynnetään erilaisten biosignaalien mittaukseen keskittyvien sensoreiden kehitystyössä (Kuvio 42). Simband sisältää valoanturin, jota käytetään mittaamaan sydämen sykettä, sydämen sykkeen vaihtelua (Heart Rate Variation eli HRV), happisaturaatiota (SpO2) ja nesteytysastetta. Simband kykenee mittaamaan sekä lämpötilaa että elektronista ihoreaktiota ja siinä on kiihtyvyyssanturi, jota käytetään mittaamaan fyysistä aktiiviteettia. Lisäksi laitteessa on sensori EKG:n mittaamista varten. Simbandin mittaama data siirretään SAMI-alustalle langattomasti. SAMI tarjoaa avoimen sovellusohjelmistorajapinnan, jotta kerätty data voidaan prosessoida ja analysoida mahdollistaen jatkuvan datan keräämisen ja hallinnan prosessit. (Chung & Park, 2017)



KUVIO 42. SAMI-alustan mittaussensoreita. (Zibreg, 2013)

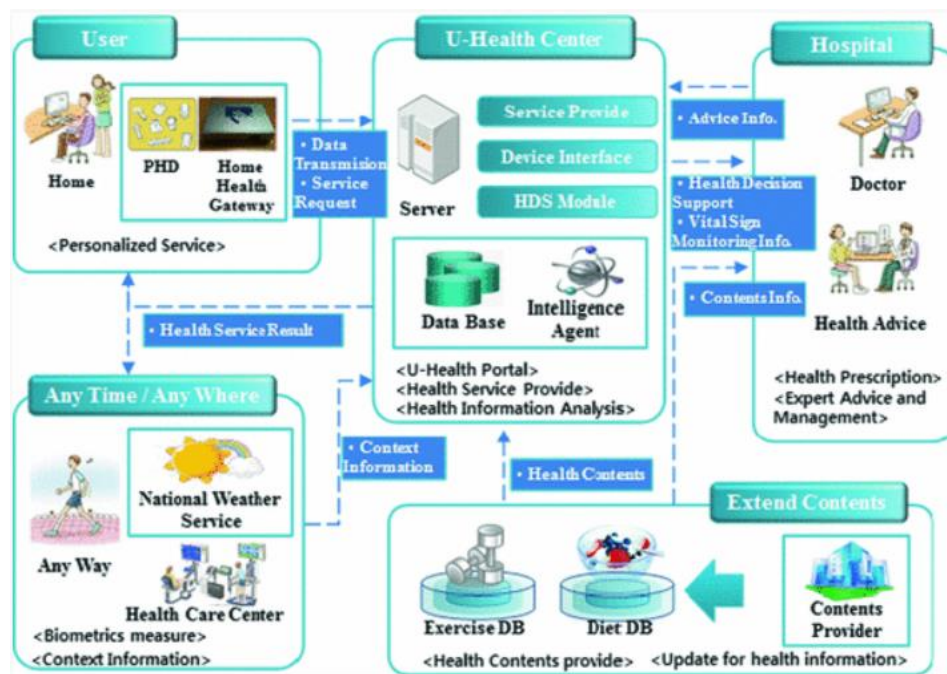
SAMI-alustan toimintaperiaate on esitetty kuviossa 43. Henkilöltä kerätään dataa, joka suodatetaan ja muunnetaan sopivaksi. Tämän jälkeen data varastoidaan, analysoidaan ja sen pohjalta havaitut ideat välitetään takaisin alustaa käyttävälle henkilölle mobiililaitteen välityksellä.



KUVIO 43. SAMI-alustan toimintaperiaate. (Zibreg, 2013)

3.3.6 U-Health Platform Using Home Health Gateway

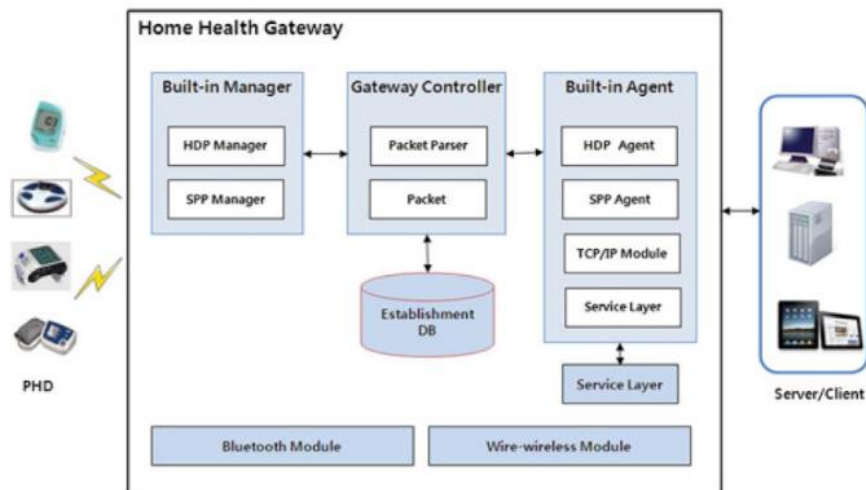
U-Health (Kuvio 44) on terveydenhuollon alustaratkaisu, joka tarjoaa räätälöityjä lääketieteellisiä palveluita potilaille riippumatta ajasta ja paikasta. Alusta voi tarjota terveydentilan ja ruokavalion sekä fyysisten harjoitteiden monitorointia hyödyntämällä HSDM-ympäristöä (Healthcare Decision Support Module). Kroonisia sairauksia sairastaville potilaille U-Health sisältää sairaalan tarjoamia lääketieteellisiä palveluita ja lääketieteellisiä ohjeita, jotta potilaat voisivat rohkaistua parantamaan terveytensä liittyviä asioitaan omatoimisesti. Potilaat voivat mitata terveydentilaansa henkilökohtaisilla langattomaan tiedonsiirtoon (esimerkiksi Bluetooth) kykenevillä mittalaitteilla (PHD eli Personal Health Device), josta on apua esimerkiksi diabetesta tai korkeaa verenpainetta sairastaville potilaille. Kodissa olevaan laitteistoon kuuluu yhdyskäytävä (Home Health Gateway), jonka kautta mitattu data siirretään alustan palvelimelle U-Health-keskukseen ja tietokantaan. (Jung ym., 2013)



KUVIO 44. U-Health-alustan arkkitehtuuri. (Jung ym., 2013)

Kodin yhdyskäytävä sisältää komponentteja, kuten "Built-in Manager", "Gateway Controller", "Built-in Agent" sekä tiedonsiirtoa varten toteutettuja moduuleita, kuten bluetooth- ja wireless-moduulit (Kuvio 45). Built-in Manager sisältää HDP- (Health Device Profile) ja SPP (Serial Port Profile) of Bluetooth-profiilit. Langatonta Bluetooth-tiedonsiirtoteknologiaa on aiemmin hyödynnetty itsenäisten U-Health-palvelujen toteutukseen sairaaloissa, kodeissa ja laitoksissa SPP-profiilia hyödyntäen. Itsenäiset sovellukset kuitenkin hyödyntävät varsin erilaista dataa, joten ne eivät ole yhteensopivia. Ongelman hoitamiseksi kehitettiin IEEE 11073-standardi, jossa esitellään agentin (PHD) ja managerin määrittely. Kaikki agentit kommunikoivat yhden managerin kanssa ja yksi manageri kommunikoiki useamman agentin kanssa. Mikäli manageri vaihtuu, joudutaan yhteys muodostamaan uudelleen. (Jung ym., 2013)

U-Health-järjestelmä on yhteydessä PHD-laitteisiin ja kodin terveysyhdyskäytävä toimii agenttina sekä yhdyskäytävä-tilassa toimittaen dataa Built-in Managerille. Palvelukerros vastaanottaa terveydenhuollon datapaketteja PHD:lta ja yhdyskäytävä ottaa yhteyttä PHD-laitteeseen Built-In-Managerin kautta. Paketin, joka siirretään Built-in-Managerin välityksellä PHD:lta, terveysdata puretaan ja data lähetetään Built-in-Agentille, josta se siirtyy palvelimelle. (Jung ym., 2013)



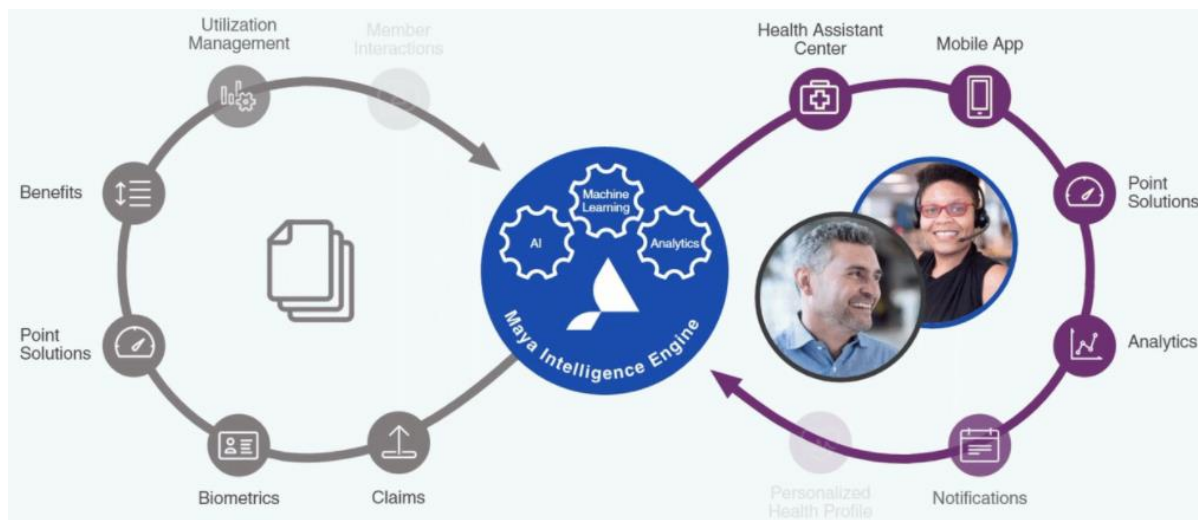
KUVIO 45. Kodin ja U-Health-alustan välisen yhdyskäytävän toimintaperiaate. (Jung ym., 2013)

Potilas voi kirjautua U-Health-keskukseen tietokoneen tai älylaitteen kautta ja saada sieltä henkilökohtaista palvelua. Näin menettelemällä potilas voi tarkastella alustan tietokantaan tallennettuja vitaleja terveystietoja. Terveyskeskuksissa kerätty informaatio analysoidaan HDSM-moduulin avulla ja potilaille voidaan tarjota viimeisin lääketieteellinen informaatio älylaitteiden kautta ajasta ja paikasta riippumatta. Lääkärit voivat alustan kautta tarjota potilaalle lääketieteellisiä palveluita U-Health-alustan kautta, kun lääkärit ovat tarkastelleet monitoroitua ja kliinistä informaatiota potilaasta. HDSM:n kautta lääkärit voivat myös hankkia informaatiota, jota he tarvitsevat lääketieteellisiä tutkimuksia varten. (Jung ym., 2013)

3.4 Tekoälyä hyödyntäviä terveydenhuollon alustoja

3.4.1 Accolade Intelligence Platform

Accolade on terveydenhuollon teknologioihin keskittynyt yritys, joka on kehittänyt Maya Intelligence Engine-moottorin (Kuvio 46). Se tarjoaa tekoälyä ja koneoppimista hyödyntäen tarjoten personoidun terveydenhoidon tuen potilaille ja heidän perheilleen. Maya toimii Accoladen alustan ytimessä ja auttaa potilaita tekemään ratkaisuja, jotka parantavat heidän terveydenhuollon palvelukokemuksiaan ja hoitojen lopputuloksia. Lisäksi Accolade tähtää alustallaan sekä potilaiden että heidän työnantajiansa kustannuksien pienentämiseen. Yhtiö on myös julkaissut mobiilisovelluksen, jonka välityksellä reaaliaikainen yhteydenpito terveydenhuollon henkilöstön kanssa mahdollistuu kaikissa terveyteen ja hyvinvointiin liittyvissä kysymyksissä. (Accolade, 2017)



KUVIO 46. Accoladen tekoälyä ja koneoppimista hyödyntävä alusta. (McGrane, 2017)

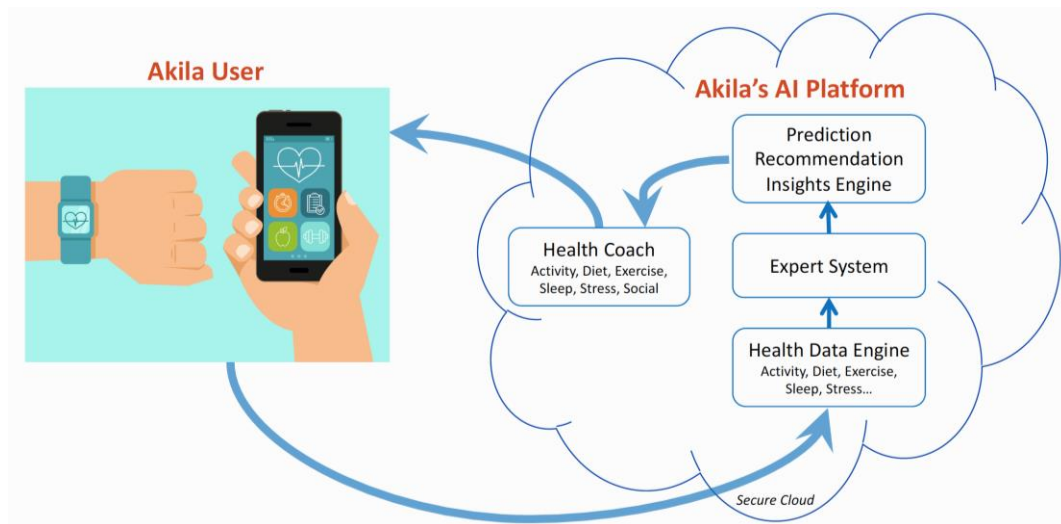
Accoladen alusta kykenee integroimaan suuria määriä potilaiden henkilökohtaista terveydenhuollon dataa, kuten biometriset tulokset, riskiarviot, demograafiset tiedot, potilaiden ja terveydenhuollon välillä tapahtuvat interaktiot. Edellä mainittua dataa yhdistellen ja hyödyntämällä Accoladen Maya Intelligence Engine kykenee muodostamaan personoituja hoitosuosituksia terveydenhuollon ammattilaisten käyttöön, joita he voivat hyödyntää potilashoidoissa. Potilaat voivat hyödyntää Mayan prosessoimaa data-aineistoa myös mobiilisovelluksen kautta ja saada personoituja hoitosuosituksia. Mayan hyödyntäminen on mahdollistanut työnantajille 5 % säästöt ensimmäiselle käyttövuodelle ja säästöt 15 % viidelle vuodelle. Käyttäjättyytyväisyys on myös ollut 98%, joten se on korkealla tasolla. (Accolade, 2017)

Accoladen mobiilisovelluksen välityksellä potilaat voivat olla reaaliaikaisesti yhteydessä terveydenhuollon ammattilaisiin. Heillä voi olla kysymyksiä esimerkiksi laskutuksesta, terveydellistä huolista tai oikeanlaisen lääkärin löytämisestä. Sovelluksen välityksellä potilaat voivat saada tukea myös hoitosuunnitelmassa pysymisessä tai he voivat saada apua lääkärivierailuihin valmistautumisessa, joihin hoitajat, voivat antaa kysymysehdotuksia. (Accolade, 2017)

3.4.2 Akila Health Coach esidiabeteksen ehkäisyyn

Yhdysvalloissa 30 miljoonaa henkilöä kärsii diabeteksestä aiheuttaen 322 miljardin Yhdysvaltain dollarin vuosittaiset kulut terveydenhuollolle. Hoitamattomana se aiheuttaa terveydenhuollon kustannusten nousua arviolta 514 miljardiin dollariin vuoteen 2025 mennessä. Esidiabetes on vahva indikaattori puhkeavasta diabeteksestä ja se voi johtaa myös muihin terveydellisiin ongelmiin, kuten sydänsairauksiin, halvauksiin ja lihavuuteen. Esidiabeteksen ehkäisy voi lisätä elinaikaa ja parantaa elämänlaatua sekä vähentää terveydenhuollon kuluja sadoilla miljardeilla vuosittain. (Anantharamu, 2017)

Akila Labs on kehittänyt alustan, joka toimii virtuaalivalmentajan tavoin hyödyntäen tekoälyä ja koneoppimista, jotka tarjoavat huomattavasti enemmän hyötyjä, mitä terveystieteilijä voisi tarjota. Akilan kognitiivisen oppimisen silmukka (Kuvio 47) hyödyntää tekoälyn ja koneoppimisen algoritmeja sekä sensoreista, päälle puettavista laitteista, terveystieteilijästä ja vastaavista lähteistä saatua dataa muokkaamaan henkilön käyttäytymistä. Alusta kykenee tuottamaan dataan pohjautuvia malleja, jotka eivät muuten olisi havaittavissa ja joihin ei ihmisten tekemät virheet ole vaikuttaneet. Akila Health Coach on skaalautuva ja proaktiivinen alusta. Se on toteutettu Amazonin Web Services-pilvipalveluun (AWS). Se käyttää kaikkia saatavilla olevia tekoälyn ja koneoppimisen teknologioita tarjotakseen ajoissa herätteitä ja hälytyksiä koskien ruokavaliota, liikuntaa, Mindfulness-harjoitteita, stressiä ja unta. (Anantharamu, 2017)



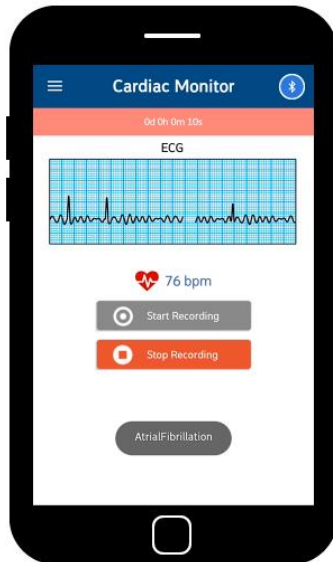
KUVIO 47. Akilan tekoälyä hyödyntävä kognitiivinen oppimissilmukka. (Anantharamu, 2017)

Akilan alustaa käyttävät henkilöt hyötyvät alustan käytöstä 16 käyttöviikon jälkeen, jolloin riittävä määrä dataa on kerätty. Henkilöt voivat asettaa henkilökohtaisia terveystavoitteita ja käyttää päälle puettavia laitteita toimintojensa seuraamiseen. Alustan käyttäjille on tarjolla proaktiivinen etäkäytettävä älykäs valmentaja, eikä henkilökohtaista terveystieteilijää tarvita. Käyttäjien motivoimiseksi heille tarjotaan konkreettisia palkintoja heidän saavuttaessaan tavoitteita. Tavoitteiden saavuttamisen jälkeen käyttäjät voivat jatkaa alustan käyttöä pysyäkseen terveisinä. Lääketieteen ammattilaiset hyötyvät alustasta asettamalla mittareita, joilla he voivat ajoissa puuttua ongelmiin. Alustan käyttö mahdollistaa myös säännöllisten terveystarkastusten ja terveydentilan seurannan parantamisen. Vuorovaikutus potilaiden kanssa paranee, koska terveystiedot ovat helposti saatavilla. (Anantharamu, 2017)

3.4.3 Alerte Mobile Health Platform

Alerte on kehittänyt mobiiliterveysalustan, joka yhdistää suoratoistotekniikkaa tekoälyyn reaaliaikaista monitorointia varten. Alustaa voidaan laajentaa digitaalisilla lääketieteellisillä laitteilla, jotka voivat kommunikoida langattomasti alustan kanssa tai jotka kykenevät hyödyntämään mobiililaitteiden sensoreita. Alusta sisältää älypuhelimien asennettavan mobiilisovelluksen, jossa on sisäänrakennettu tekoälyalgoritmi ja tiedonhallintaan liittyvät rutiinit. Tekoälyalgoritmin opettamiseen uusia laitteita varten on kehitetty WEB-alusta, joka ei tarvitse internet-yhteyttä ollenkaan tai leveää kaistanleveyttä tiedonsiirtoa varten vaan sisäänrakennettu tekoäly analysoi suoratoistetun informaation välittömästi. Tämä on oleellista laajamittaisessa mobiiliterveyssovelluksien omaksumisessa. (Alerte, 2017)

Kerätty data voidaan visualisoida reaaliajassa (Kuvio 48), jotta voidaan varmistua siitä, että signaalit ovat mitattu oikein, lisäksi lääkärit voivat diagnosoida potilaan paikasta riippumatta. Tekoälyä hyödyntävät algoritmit voivat analysoida datavirtoja reaaliajassa tarjoten informaatiota ja hälytyksiä käyttäjille ja heidän lääkäreilleen, mikäli he havaitsevat poikkeavuuksia, joihin on syytä puuttua ajoissa. Alerte hyödyntää myös tehokkaita datan yhdistämisen tekniikoita dataa analysoidessaan, jolloin potilaat voivat seurata edistymistään ja tehdä suunnitelmia paremman terveydentilan saavuttamiseksi ja ylläpitämiseksi. (Alerte, 2017)



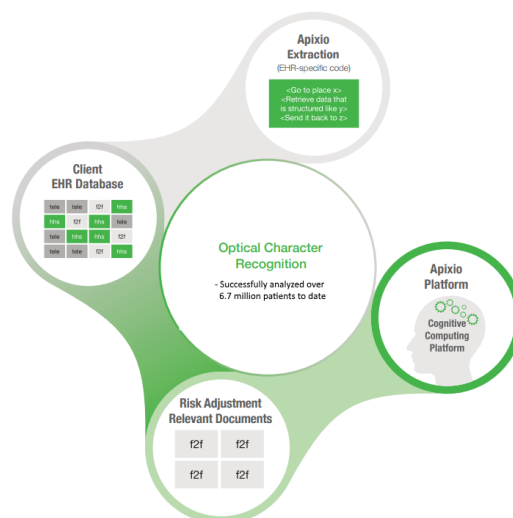
KUVIO 48. Alerten tekoälyä hyödyntävä reaaliaikainen data-analytiikka. (Alerte, 2017)

3.4.4 Apixio Iris-tekoälyalusta ja HCC-profiler

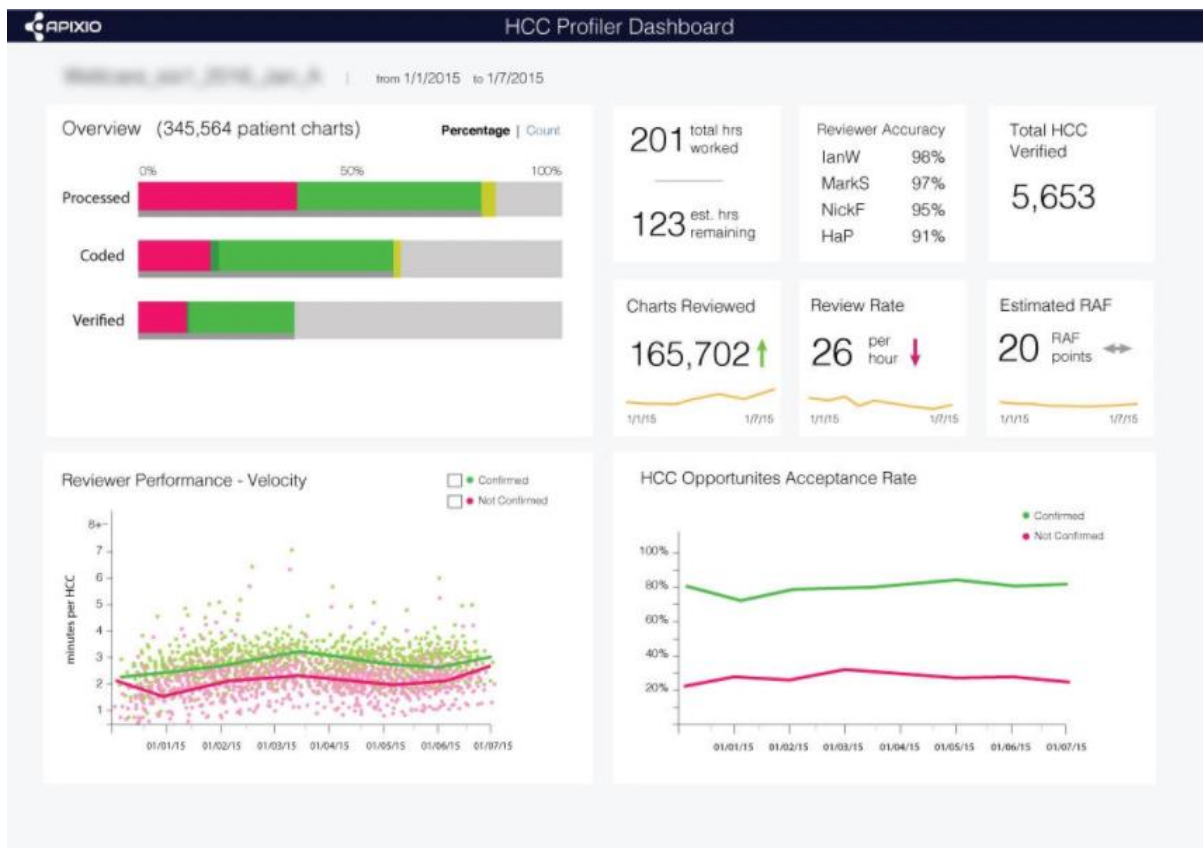
Apixion kehittämä kognitiivista tietojenkäsittelyä hyödyntävä Iris-tekoälyalusta toimii pohjana Apixion HCC-profilerille, joka kykenee louhimaan kliinistä dataa ja potilaiden riskiprofiileiden laskemiseksi jopa kolme kertaa nopeammin kuin perinteiset menetelmät.

Iristä on opetettu tulkitsemaan lääketieteellistä dataa hyödyntäen yli 500 miljoonaa lääkärin kirjoittamaa kliinistä muistiinpanoa. Terveystieteiden palvelutarjoajat kykenevät paremmin koordinoimaan ja tarjoamaan hoitoa, kun heillä on käytössään tarkempi kuva potilaan terveydentilasta ja riskeistä. (Apixio, 2015)

HCC-profiler kykenee sähköisten potilastietojen (EHR) ja skannatun kaaviomuotoisen datan louhimiseen (kuvio 49), joka takaa tarkemmat kliiniset tietueet ja tarjoaa mahdollisuuden tarjota korkealaatuista potilashoitoa. HCC-profiler lukee tekstimuotoista dataa suoraan sairaalan tai vastaanoton lääketieteellisistä kaavioista, jotka on tallennettu erilaisiin potilastietojärjestelmiin. HCC-profiler osaa myös validoida aiempia diagnoosikoodeja ja löytää aukkoja potilasdokumentaatioista. HCC-profiler kykenee lisäksi tuottamaan ymmärrettäviä raportteja lääketieteellisistä kaavioista, jotka on tulostettu, skannattu tai lähetetty faksilla. (Apixio, 2015) Kuviossa 50 on havainnollistettu HCC-profilerin kojelautanäkymää (dashboard).



KUVIO 49. Apixio HCC-profilerin toimintaperiaate. (Apixio, 2017)



KUVIO 50. HCC-profilerin kojelautanäkymä. (Kulkarni, 2015)

Apixion HCC-profilerin taustalla oleva IRIS-tekoälyalusta hyödyntää tehokasta datan integroinnin ja noutamisen työkaluja. Se ohjaa uudelleen strukturoidun datan koneoppimisen malliin, jonka tehtävänä on tarjota terveydenhuollon palvelutarjoajille mahdollisuus ymmärtää paremmin potilaiden terveydentilaa. Apixion Iris-alustaratkaisussa korostuu digitaalisten potilastietojen ja lääkärien muistiinpanojen merkitys. Kilpaileva IBM Watson Health-järjestelmä sen sijaan hyödyntää lääketieteellistä kirjallisuutta oireiden korreloimiseksi tulosten kanssa. Ongelmia on aiheuttanut lääkäreiden tapa tuottaa huomattavia määriä käsin kirjoitettuja muistiinpanoja potilaista. Data on usein siiloutuneena erilaisissa tietokannoissa ja jossain tapauksissa saavuttamattomissa myös uudemmissa digitaalisissa järjestelmissä. Lisäksi data, johon voidaan päästä käsiksi, on koneille vaikeasti luettavissa ja harvemmin indeksoitua. (Kulkarni, 2015)

Apixion toiminta keskittyy sen kykyyn käsitellä digitoimatonta dataa, jota se jäsentee. Jäsennetyistä datasta voidaan saada uusia ideoita ja oivalluksia hyödyntämällä luonnollisen kielen prosessointitekniikoita, joita hyödynnetään yhdessä koneoppimisen algoritmien kanssa. Se, miten hyvin koneoppimisen algoritmit tässä tapauksessa toimivat, riippuu paljolti kuluttajista. Kuluttajien tulee jakaa riittävästi dataa tai metadataa, jotta koneoppimisen algoritmien avulla ideat ja oivallukset voivat nousta pinnalle datan joukosta. Suuret terveydenhuollon palvelutarjoajat, voivat kuitenkin aiheuttaa ongelmia rajoittamalla datan jakamista. Välttyäkseen siltä, että heillä ei olisi tarpeeksi dataa käyttöön, Apixio rakentanut

vaikuttavan verkoston terveydenhuollon tarjoajista, kuten Scipps Health, HealthNet ja WellCare. Kaikilla näistä toimijoista on omistuksessaan monipuolisia data-aineistoja, jotka ovat kriittisiä Iriksen kaltaisen terveydenhuollon tekoälyalustan täysimittaiselle hyödyntämiselle. (Kulkarni, 2015)

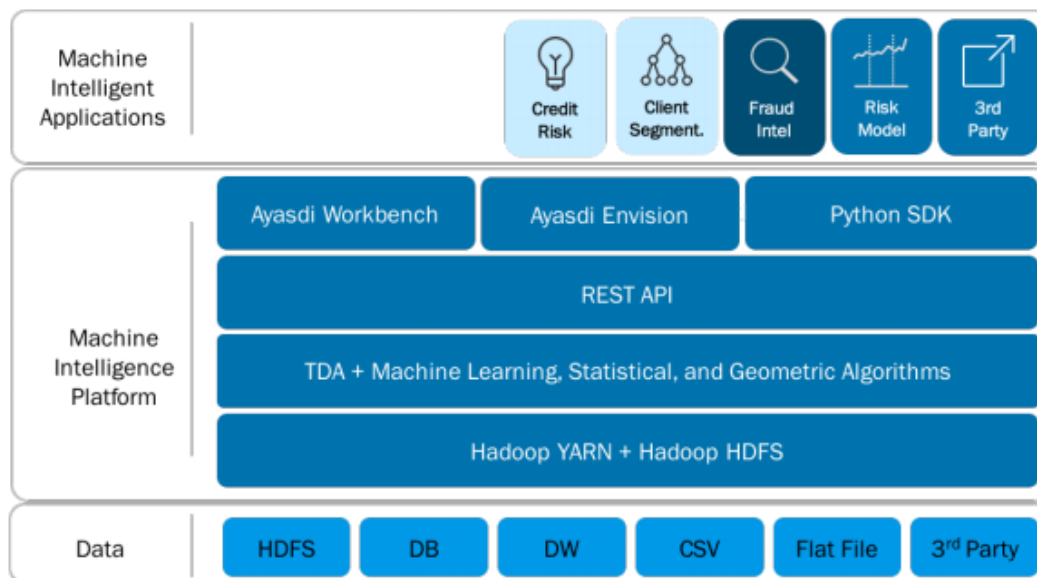
3.4.5 Ayasdi Envision-tekoälyalusta

Ayasdi on Meno Parkissa Yhdysvaltain Kaliforniassa toimiva teknologiayritys, joka hyödyntää koneoppimisen algoritmeja suurien datamassojen käsittelyssä. Tämän teknologian avulla on mahdollista löytää malleja organisoimattomasta datasta, jota vähemmän kehittyneet algoritmit eivät kykene toteuttamaan. Ayasdi on kehittänyt Ayasdi Envision-alustan, johon terveydenhuollon palvelujen tuottajat voivat kehittää omia sovelluksiaan. Envision auttaa terveydenhuollon organisaatioita luomaan nopeasti kuluttajaystävällisiä sovelluksia, joiden tarkoituksena on ratkaista laajoja määriä kliinisiä ja liiketoiminnallisia ongelmia. Konsulttiyritys Gartner odottaa maailman 200 suurimman yrityksen hyödyntävän älykkäitä sovelluksia, Big Dataa ja analytiikkatyökaluja parantamaan toimintaansa ja asiakaspalveluaan. Älykkäät sovellukset eivät kuitenkaan rajoitu vain uusiin digitaalisiin apulaisiin, vaan kaikkiin jo olemassa oleviin ohjelmistokategorioihin. Turvallisuustyökaluista yrityskäyttöön, kuten markkinointiin ja resurssienhallintaan. (Hit Consultant, 2017)

Ayasdin kehittämä Envision-alusta tasapuolistaa ja kiihdyttää älykkäiden sovelluksien kehittämistä. Alusta suunniteltiin iteratiiviseen kehitystyöhön. Sen yhteistoiminnalliseen työkulkuun suuntautunut lähestymistapa hyödyntää kliinisten loppukäyttäjien osallistumisen työhön koko prosessin elinkaaren ajaksi. Siten varmistetaan, että asiantuntijoiden vaatimukset täyttyvät. Analyttikot, datatieteilijät ja IT-ryhmittymät voivat rakentaessaan liiketoimintaansa hyödyntää tekoälyalustaa käyttämällä alustan tarjoamia palveluita, kuten esikäännettyjä käyttöliittymäkomponenttikirjastoja. Alustaa käytetään Web-pohjaisen käyttöliittymän avulla, jonka helppokäyttöisyys ja opittavuus tekevät siitä helposti hyödynnettävän kliinisen- ja talousosaston henkilöille sekä data-analyttikoille. (Hit Consultant, 2017)

Kuviosta 51 havainnollistuu Ayasdin machine intelligence-alusta, johon Envision-alusta sijoittuu. Ayasdin-alusta kykenee keräämään dataa useista eri lähteistä, mutta useimmiten se konvertoi dataa muotoon, jossa se voidaan säilyttää Hadoop-palvelussa. Mikäli data on jo Hadoop-palvelussa, sitä voidaan hyödyntää kyseisestä palvelusta suoraan. Intelligence-alusta yhdistää TDA:n (Topological Data Analysis), koneoppimista, statistiikkaa ja geometriaa ja algoritmeja, mikä mahdollistaa mallien löytämiseen, mitä muut eivät tiedä. REST-rajapinnan päällä on kehitysympäristö Ayasdi Workbench, Ayasdi Envision ja Python SDK (Software Development KIT eli ohjelmistokehitysympäristö). (Ayasdi)

Python SDK tarjoaa ohjelmointikielen tasolla olevan pääsyn teknologiaan, jota hyödyntämällä on tarkoitus rakentaa älykkäitä sovelluksia. Python-ohjelmointikieltä ohjelmoivat ohjelmistokehittäjät ja datatieteilijät voivat rakentaa sovelluksia tästä näkökulmasta käsin. Ayasdi Workbench on data science-sovellus, joka antaa käyttäjälleen mahdollisuuden luoda topologisia malleja datasta ja visuaalisesti tarkastella näiden mallien luonnetta. Analyysi voidaan suorittaa ohjaamattomana tai ohjattuna. Edellä mainittu Ayasdi Envision on kehitysympäristöstä uusin ja se nopeuttaa älykkäiden sovelluksien luomista.



KUVIO 51. Ayasdin arkkitehtuuri. (Ayasdi)

REST-rajapinnan alapuolella on TDA eli topologisen datan analysointiin erikoistunut analytiikkamooottori. TDA on yksi merkittävimmistä DARPA:n rahoittamista kehitysaskelista ja se on saavuttanut laajasti palkintoja ja tunnustuksia. TDA perustuu topologiaan, matemaattiseen osa-alueeseen, joka tutkii muodon käsitettä. TDA viittaa tämän periaatteen omaksumiseen monimutkaisen datan analysoinnissa. Periaatteen mukaisesti, kaikella datalla on muoto ja muodoilla on merkitys. Datan muotoja (Kuvio 52) ovat esimerkiksi regressio (regression), klusteri (cluster), silmukka (loop) tai soihtu (flare). (Ayasdi)

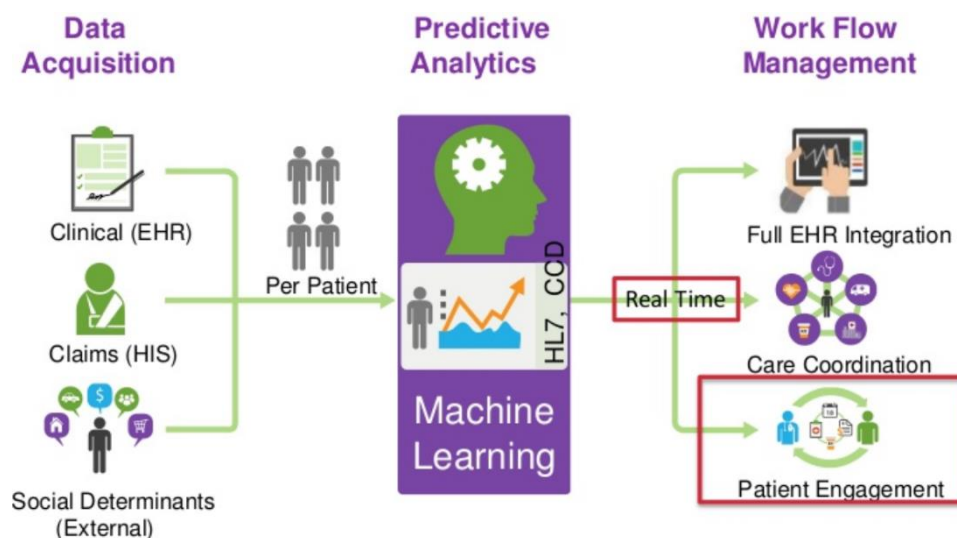


KUVIO 52. Neljä esimerkkiä datan muodoista. (Ayasdi)

TDA hyödyntää useita koneoppimisen algoritmeja muodostaessaan parasta datan muotoa. Näin menetelmällä se kykenee paljastamaan monivivahteisia malleja, joita muut yhteen algoritmiseen dimensioon tukeutuvat mallit eivät ole kyenneet havaitsemaan. TDA nopeuttaa prosessia, kun etsitään datasta oleellisia ja merkitsemättömiä asioita. Prosessi toteutetaan ilman ohjausta tarkoittaen, että käyttäjät usein löytävät vastauksen kysymykseensä, jota eivät välttämättä ole osanneet kysyä. TDA laajentaa ja parantaa kaikkien koneoppimisen algoritmien suorituskykyä luomalla mittareita, joita ei ole muissa ratkaisuissa. (Ayasdi)

3.4.6 CareSkore

CareSkore on Mountain Viewissä 2014 perustettu Yhdysvaltain Kaliforniassa toimiva terveydenhuoltoalan yritys, joka on erikoistunut muun muassa väestön terveydenhuoltoon, riskien hallintaan, terveydenhuollon analytiikkaan, kustannuksien sekä resurssien hallintaan, ICD10-suositukseen, hoitosuunnitelmien tekemiseen ja toteuttamiseen, kroonisen hoidon hallintaan. Yritys hyödyntää koneoppimisen algoritmeja (Kuvio 53) reaaliaikaisesti ennustavaa ja ennakoivaa analytiikkaa käyttävän alustan toteutuksessa. Analytiikkaa hyödynnetään hoidettavien potilaiden parempaan ymmärtämiseen ja laadukkaampaan hoitoon. (LinkedIn)



KUVIO 53. CareSkore-arkkitehtuurikaavio. (Diabnext, 2017)

CareSkore yhdistää kliinistä, sosioekonomista, demografista ja käyttäytymiseen liittyvää dataa muodostaakseen holistisen kuvan potilaasta, mitä lääkärit sekä vakuutusyhtiöt voivat käyttää tarjotakseen parempaa ennaltaehkäisevää hoitoa. CareSkoren alusta hyödyntää Googlen TensorFlowia sekä Hadoop-palvelua. TensorFlow on avoimen lähdekoodin ohjelmistokirjasto numeerista laskentaa varten, joka hyödyntää datavirtakaavioita. Tensorflow suunniteltiin alun perin koneoppimisen ja syvien neuroverkkojen tutkimusta varten, mutta sitä voidaan hyödyntää myös muissa konteksteissa. Hadoop on avoimen lähdekoodin ohjelmisto luotettavaa, skaalautuvaa ja hajautettua tietojenkäsittelyä varten.

CareSkoren alusta hyödyntää näitä palveluita suurien kolmansien osapuolten data-aineistojen käsittelyssä. Lisäksi tarkoitus on löytää ideoita ja oivalluksia etsimällä suhteita kliinisen sekä ympäristöön liittyvän datan väliltä. (Mannes, 2016)

CareSkore hyödyntää oppimismenetelmiä, kuten Random Forest-analyysiä yhdistääkseen useita tilastollisia malleja tuottaakseen vähemmän kohinaa sisältävän ja tarkemman tuloksen. Alusta voi informoida lääkäreitä potilaista, jotka todennäköisesti jättävät tapaamisen väliin ja jotka myös todennäköisesti unohtavat tai tarkoituksenmukaisesti jättävät lääkkeet ottamatta ajallaan. Kuoleman riskin ennustamisen lisäksi alusta analysoi potilaan sairaalaan uudelleen kirjautumisen riskiä, kaatumis- ja infektoriskiä huomioimalla sairaaloiden ja muiden terveydenhoidon yksiköiden potilastietokantoja. Lääkärit voivat hyödyntää näitä tietoja, jotta he voivat ennakoivasti informoida potilaita sekä toimittaa heille asianmukaiset hoitosuosituksen ja muita relevantteja palveluita. (Mannes, 2016)

Potilat saavat yksilöidyn tekstiviestin tai puhelinoiton, jotta he voivat toimia ajoissa, mikäli uusi riskitekijä ilmenee. CareSkore tarjoaa tautispesifisiä malleja tilanteisiin, kuten keuhkohtaumatauti tai diabetekseen, jotta tarvittavat hoitosuositukset voidaan tehdä. Potilaat voivat myös käyttää järjestelmää informoimaan lääkäreitä uusista oireista tai kysyä heiltä oireista tai hoitosuunnitelmista. Informaatio välittyy myös sosiaalityöntekijöille, jotka varmistavat, että se kulkeutuu oikealle henkilölle. Useimmissa tapauksissa tiedot syötetään takaisin järjestelmän läpi, jotta tulevia CareSkore ennusteita voidaan paremmin toteuttaa. (Mannes, 2016)

3.4.7 Diabnext-tekoälyalusta diabeteksen hallintaan

Diabnext on tekoälyä hyödyntävä J.A.R.V.I.S.-käyttöliittymää (Kuvio 54) käyttävä älypuhelimella tai tietokoneella toimiva alusta, jonka avulla voidaan monitoroida esidiabetesta ja diabetesta (Mack, 2017). Alusta tarjoaa personoidun metrisen analysoinnin ja päätöksentekotyökalun potilaille sekä diabetekseen perehtyneille terveydenhuollon ammattilaisille (lääkärit), jotta he voisivat paremmin hallita sekä esidiabetesta että diabetesta. Diabnext hyödyntää avointa rajapintaa ja innovatiivisia sensoreita, jotka päivittäin mittaavat metriikoita ja siirtävät mitatun datan Diabnext-sovelluksen logikirjaan. Toimenpide vapauttaa potilaan datan manuaaliselta syöttämiseltä järjestelmään. (Issuu, 2017)



KUVIO 54. Diabnext-alustan käyttöliittymä. (Diabnext, 2017)

Diabnext-alusta sisältää tietoturvallisen rajapinnan parantaakseen kommunikaatiota diabetespotilaiden ja sairauten erikoistuneiden ammattilaisten välillä. Alusta kerää ja esianalysoi potilaisiin liittyviä metriikoita ja muuta informaatiota. Terveysthuollon ammattilaiset käyttävät sitä tarjoamaan potilaiden eri osa-alueisiin suuntautuvaa monitorointia ja valmennusta, kuten insuliini-injektioon liittyvä reagointi, glukoosin päivittäinen arviointi, titraus, hiilihydraattien saanti ja dieetti, elämäntyyli. Diabetekseen erikoistuneet terveydenhuollon ammattilaiset voivat lähettää tekstiviestejä, organisoida puhelinsoittoja ja videotapaamisia potilaiden kanssa kaikille sopivaan aikaan riippumatta siitä, missä potilas asuu. (Issuu, 2017) Diabnext sisältää useita erilaisia palveluita, kuten insuliinin (Clipsulin), glukoosin (Gluconext), lääkityksen (Vigicap), kehon koostumuksen mittaamisen (Vigifit), kehon aktiiviteetin mittaamisen, hiilihydraattien (Snapcarbs) arviointiin suunnatut palvelut (Kuvio 55).



KUVIO 55. Diabnext-alustan tarjoamat palvelut. (Issuu, 2017)

Diabnext-alustaan toteutettu palvelu, insuliinin injektioalustan Clipsulin, täyttää automaattisesti potilaan logikirjan informaatiolla insuliini-injektioista sisältäen insuliini-injektion ajankohdan, insuliinin tyyppin ja injektioitujen insuliiniyksiköiden määrän. Clipsulin voidaan yhdistää mihin tahansa insuliinikynään. Injektiodatan tallentamisen jälkeen data siirretään potilaan älypuhelimien logikirjaan, joka synkronoi sen reaaliaikaisesti Diabnext-tekoälyalustan kanssa. Tekoälyalusta mahdollistaa diabeteksen paremman hallinnan taulukoiden ja graafien avulla, jotka visualisoivat mitatun datan ja helpottaen siten tulkintaa. Alustan avulla potilas tietää, milloin viimeisin injektio on tehty ja kuinka monta yksikköä insuliinia on injektioitu. Seurannan avulla voidaan välttää virheiden tekemistä, mitkä johtaa alhaiseen verensokeripitoisuuteen (hypoglykemiaa) tai korkeaan verensokeripitoisuuteen (hyperglykemiaa). (Issuu, 2017)

Diabnextin tarjoama glukosimittareihin kiinnitettävän laitteen avulla voidaan automaattisesti siirtää glukosimonitoreista tuleva data Diabnext-tekoälyalustaan, joka analysoi siirretyn datan ja tuottaa graafeja, laskee keskiarvoja, trendejä, alueita ja arvioita datasta. Data päivittyy automaattisesti järjestelmän logikirjaan. Diabeteksen lääkitystä voidaan seurata Vigicap-palvelulla, joka monitoroi potilaan lääkkeiden käyttöä helpottaen diabeteksen hallitsemista. Diabnext muistuttaa potilasta lääkkeiden ottamisesta tekstiviestein tai puhelinoitoin. Järjestelmä kykenee myös varoittamaan tupla-annostuksesta perustuen kerättyyn lokidataan. Vigicap kykenee automaattisesti seuraamaan lääkkeiden ottamista ja lähettämään tiedon siitä Diabnext-alustaan. Diabnext-alustan tukemiin mittalaitteisiin kuuluu myös kehon koostumuksen mittaava vaaka. Kehon koostumuksesta mitataan paino, rasvaprosentti, lihasmassa ja veden määrä. Mitattu data lähetetään automaattisesti Bluetooth-protokollan välityksellä Diabnext-alustalle. (Issuu, 2017)

Diabnext-tekoälyalusta mahdollistaa myös potilaan syömien hiilihydraattien (Kuvio 56) määrän laskemisen perustuen kuvan ottamiseen lautasella olevasta ruoka-annoksesta. Kuvan prosessointi perustuu kuvan tunnistukseen ja tiedonlouhintateknologiaan, joiden avulla arvioidaan hiilihydraattien määrä. Syötyjen hiilihydraattien määrän monitorointi on tärkeässä roolissa, jotta useat erilaiset näkökulmat potilaan terveydentilasta voidaan huomioida. Useiden tieteellisten ja kliinisten tutkimuksien mukaan diabeteksen monitorointi ja kehon aktiivisuus on yhteyksissä toisiinsa. Syötyjen hiilihydraattien määrän arvioinnin lisäksi on siksi tärkeää mitata myös potilaan kehon liikettä, askellusta ja poltettuja kaloreita. Vigifit mahdollistaa edellä mainittujen mittauksien suorittamisen reaaliajassa ja datan siirtämisen Diabnext-alustalle analyysia ja arviointia varten. Kyseessä on pieni yhden euron kolikon kokoinen laite, jota voidaan kantaa, vaikka taskussa päivittäisissä aktiviteeteissa tai urheilusuorituksien aikana. Laitteessa on tekoälyalustaan datan siirtoa varten tuet Bluetooth ja NFC-protokollille. (Issuu, 2017)



KUVIO 56. Syötyjen hiilihydraattien määrän arviointi Diabnext-alustan avulla. (Issuu, 2017)

3.4.8 Doc.ai hajautettu tekoälyalusta

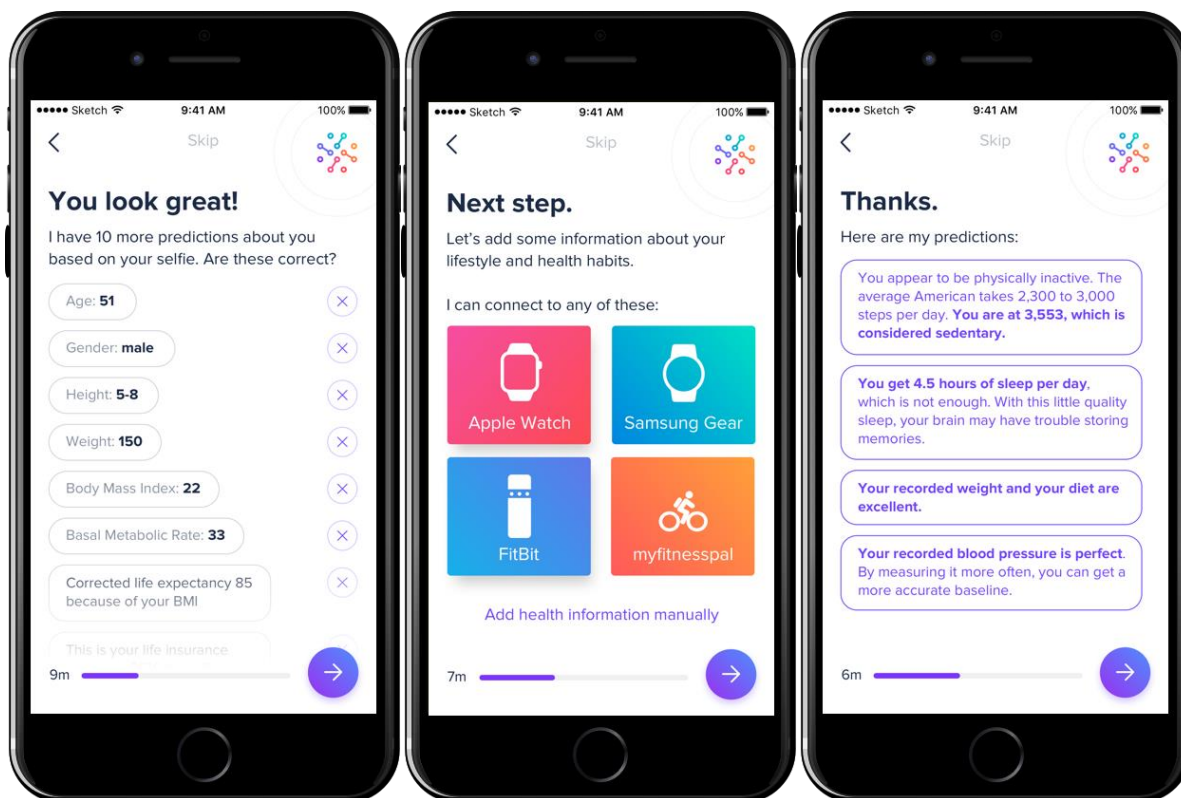
Doc.ai on lohkoketjuihin perustuva hajautettu tekoälyalusta, joka hyödyntää syväoppimista terveydenhuollon parantamisessa. Doc.ai on eräänlainen robottilääkäri, joka koostuu useista tekoälyä hyödyntävistä keskusteluroboteista (chatbots). Nämä keskustelurobotit toimivat tietynlaisina virtuaalisina lääkäreinä ja antavat potilaille mahdollisuuden rakentaa nopeasti terveysprofiilin ja saada uusia ideoita niiden tuottamaan dataan perustuen. Alusta hyödyntää kehittyntä luonnollisen kielen prosessointiteknologiaa ja lohkoketjuihin perustuen alusta kykenee aikaleimaamaan aineistoja ja hajauttamaan tekoälyä. Alustaa ovat kehittäneet

tutkijat Stanfordin ja Cambridgen yliopistoista tarkoituksenaan parantaa potilashoitoa ja kokemusta kehittyneen luonnollisen dialogijärjestelmän avulla, joka kykenee tuottamaan aivan uudenlaisia oivalluksia yhdistettyyn lääketieteelliseen dataan perustuen. (Storj Labs, 2017)

Maailman terveysjärjestön WHO:n mukaan maailmassa on pulaa jopa seitsemästä miljoonasta terveydenhuollon ammattilaisesta ja pula on vain kasvamassa. Lääkäreihin kohdistuu yhä suurempia paineita väestön terveyspalveluiden haasteista ja terveydenhuollon sekä lääketieteen ja lääkityksen kehityksestä. Lääketieteen ammattilaisten kouluttaminen on vuosia kestävä työ, joka vaatii niin opintoja kuin kokemusta. Doc.ai-alustan avulla on tarkoituksena tarjota parempi hoitokokemus muun muassa hyödyntämällä tekoälypohjaisia lääkäreitä, jotka kykenevät vastaamaan terveysaiheisiin kysymyksiin. Potilaat voivat kysyä siltä kysymyksiä, kuten: ”Miten voin vähentää kolesterolitasoani seuraavan kolmen viikon aikana?” tai ”Miksi glukoositasoni on yli 100 ja viikko sitten se oli 93?”. Tämä mahdollistaa aiempaa personoidumman terveydenhuoltopalvelun kehittämisen. (Vitaris, 2017)

Doc.ai toimii SaaS-palveluna (Software as a Service) tarjoten palvelua lääketieteen alan yrityksille, jotka mahdollistavat terveyden tilaan liittyvät personoidut tekoälyä hyödyntävät keskustelut potilaille kellonajasta riippumatta. Potilaat voivat ottaa osaa keskusteluun mobiilisovelluksen välityksellä. Doc.ai tarjoaa asiakkailleen kolme luonnollisen kielen prosessointimoduulia, jotka ovat: Robo-genomics, Robo-hematology ja Robo-anatomics. Lisäksi palveluun sisältyy interaktiivinen moduuli, joka tarjoaa potilaalle mahdollisuuden rakentaa nopeasti itselleen terveysprofiilin ja saada profiilin kautta informaatiota sekä ideoita palveluun kerätystä häntä koskevasta henkilökohtaisesta datasta. Moduuli hyödyntää prediktiivistä teknologiaa, joka tekee terveysprofiilin (Kuvio 57) rakentamisesta paljon helpompaa kuin hyödyntämällä perinteisiä datan keräämisen metodeita. (Vitaris, 2017)

Doc.ai tekee ennusteen perustuen henkilöstä otettuun selfie-kuvaan. Ennuste sisältää informaatiota, kuten ikä, sukupuoli, paino, pituus, painoindeksi (BMI), eliniän ennuste. Potilas voi yhdistää alustaan myös päälle puettavaa teknologiaa, kuten älykelloja ja rannekeita sekä MyFitnessPal-kalorilaskurin. Potilas voi syöttää alustaan myös terveydentilaan liittyvää informaatiota manuaalisesti. Alustaan syötetyn datan perusteella doc.ai antaa terveyteen liittyviä ohjeita koskien muun muassa verenpainetta, fyysistä aktiivisuutta, unen määrää, kehon koostumusta ja ravitsemusta. (Stuart, 2017)



KUVIO 57. Doc.ai-tekoälyalustan mobiilisovelluksen käyttöliittymä. (Stuart, 2017)

Doc.ai-alustaan kuuluu moduulina Robo-Genomics-agentti, joka on tietynlainen keskusteluagentti ja joka on suunniteltu parantamaan geneettisen datan ymmärtämistä ja tarjoamaan käyttäjille päätöksenteon tukipalveluita. Agentti kykenee keskustelemaan useista erilaisista aiheista, kuten sairauksista, luonteenpiirteistä, farmakologiasta ja perhesuunnittelusta. Agentti tukee testituloksien ymmärtämistä, geneettistä koulutusta, geneettisen neuvonnan valmistelua ja sovelluksen sisäisiä tapaamisia. Doc.ai-alustassa on myös Robo-Hematology-agentti, joka on suunniteltu vastaamaan mihin tahansa kysymykseen koskien yli 400 bioindikaattoria, jotka indikoivat potilaan biologista tilaa, useimmiten sairauksia. Agentti on opetettu hyödyntäen satoja tuhansia lääketieteellisiä dokumentteja ja yleisiä ohjeistuksia. Agentti personoi vastaukset perustuen käyttäjän ikään, sukupuoleen, lääketieteelliseen historiaan ja se kykenee personoimaan kattavalla sisällöllä, kuten kuvilla ja videoita. Doc.ai-alustaan sisältää lisäksi Robo-Anatomics-moduulin, joka neuroverkkoa ja optimointitekniikoita hyödyntäen kykenee ennustamaan erilaisia anatomisia ominaisuuksia, kuten pituus, paino, sukupuoli ja kasvot. Tämä mahdollistaa nopean ja kitkattoman sekä älykkään tiedonkeruun. (Doc.ai, 2017)

3.4.9 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 Rhythm julkaisi vuonna 2016 päälle puettavan unidiagnostiikkaan liittyvän laitteen (Dreem), joka parantaa unen laatua. Rhythm 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 sekä 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 koneoppimisten 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)

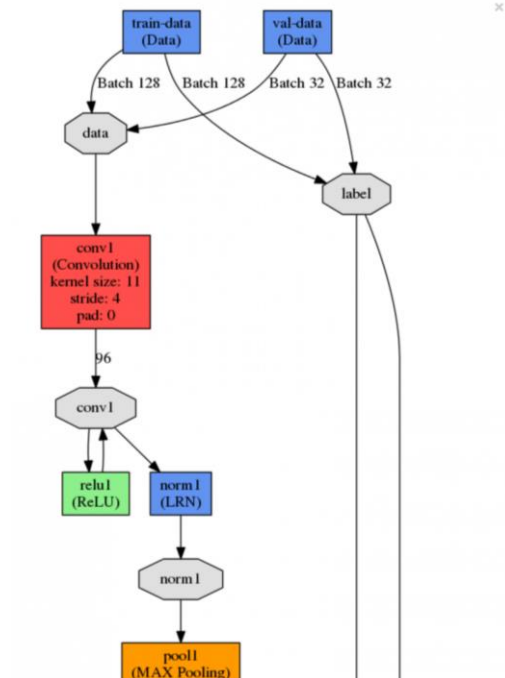


KUVIO 58. Morpheo-alustan monitorointi-ikkuna. (Bell, 2017)

3.4.10 Morpheo-tekoälyalusta unihäiriöiden diagnosoinnissa

Tekoälyn vaikuttaessa tieteellisiin tutkimuksiin, lääketieteeseen ja terveydenhuoltoon teollisuudenalana, NVIDIA on pureutunut syväoppimiseen tarjoamalla tekoälyä hyödyntävän terveydenhuollon tarpeisiin suunnitellun alustan. NVIDIA:n alusta on käyttänyt GPU-prosessoreiden tuomaa laskentatehoa, jota voidaan hyödyntää yhä parempien neuroverkkojen kehittämiseen terveydenhuollon ja lääketieteellisen tutkimuksen konteksteissa. Tekoälyyn liittyvät innovaatiot edistävät täsmälääketieteen tulevaisuutta ja väestön terveyden hallintaa erinomaisilla tavoilla. (NVIDIA, 2017)

NVIDIA:n kehittämä GPU-prosessoreita hyväkseen käytävä syväoppimisjärjestelmä (NVIDIA Digits) tarjoaa mahdollisuuden tutkijoille ja datatieteilijöille kehittää syväoppimista ja nopeasti suunnitella toimivia syviä neuroverkkoja (Deep Neural Network eli DNN) lääketieteellisten kuvien luokitteluun, tunnistamiseen ja segmentointiin. DIGITS tarjoaa käyttäjilleen mahdollisuuden kirjoittaa ja integroida plug-in-palveluita, jotta he voivat hyödyntää järjestelmässä mukautettuja data-formaatteja, kuten DICOM, joita käytetään laajalti lääketieteellisessä kuvantamisessa. DIGITS yksinkertaistaa yleisien syväoppimisen tehtävien, kuten datan hallinnan, suunnittelun ja neuroverkkojen opettamisen tehtäviä usean grafiikkaprosessorin (GPU) järjestelmissä monitoroimalla suorituskykyä reaaliajassa kehittynyttä visualisointia hyödyntäen. Se valitsee suorituskykyisimmät mallit hyötykäyttöön. Lisäksi järjestelmä mahdollistaa täydellisen TensorFlow-tuen. TensorFlow on avoimen lähdekoodin kirjasto, joka on tarkoitettu numeerista laskentaa varten datavirtakaavioita hyödyntäen. Kuvio 59 havainnollistaa syvien neuroverkkoarkkitehtuurien visualisointia DIGITSiä hyödyntäen. (NVIDIA, 2017)



KUVIO 59. Syvien neuroverkkoarkkitehtuurien visualisointi käyttöliittymä. (Stuart, 2017)

4 Tulevaisuus

Globaalit terveydenhoitokulut on ennakoitu kasvavan 8,7 triljoonaan Yhdysvaltain dollariin vuoteen 2020 mennessä vuoden 2015 7 triljoonasta dollarista. Samanaikaisesti työvoimakustannukset lisääntyvät ja elinajan odote kasvaa. Samalla aiheutuu myös suuria kustannuksia. Organisaatioiden ja varsinkin terveydenhuollon tulevaisuus on kuitenkin digitaalisesti toisiinsa yhteydessä oleva tulevaisuus, jossa hallitsevina ovat alustat. Uudenlaisia terveydenhuollon malleja ohjaa edistys koneoppimisessa, alustoissa, mobiililaitteissa, sensoreissa ja lohkoketjuissa. Terveydenhuolto ei kehity hyödyntämällä vain yhtä teknologiaa vaan useat eri teknologiat yhdistyvät voimistaen skaalaa ja muutosnopeutta. Data, koneoppiminen, IoT-sensorit, alustat, lohkoketjut ja verkot yhdessä tiedon varastoinnin ja prosessoinnin laskevien kustannuksien kanssa ovat voimia, jotka luovat uusia malleja ja digitaalisia ekosysteemeitä. (Fox, 2017)

Mobiilia hyödyntävä terveysala ja terveyttä mittaavista sensoreista on tulossa yhä merkittävämpiä. Mobiili on epäilemättä avain siihen, miten käyttäjät toimivat vuorovaikutuksessa sensorien kanssa seuratessaan terveydentilaansa. Markkina on kuitenkin ruuhkautumassa ja viime vuosina niiden lukumäärä on yltänyt jo satoihin tuhansiin sovelluksiin. MarketResearch.com:n raportin mukaan terveydenhuollon IoT-markkinasegmentti kykenee saavuttamaan 117 miljardin dollarin määrän vuoteen 2020 mennessä. Yhä enemmän terveydentilaa mittaavia mobiililaitteita tulee saataville ja ihmisen fysiologisten ominaisuuksien mittaamisen lisäksi voidaan kerätä dataa koskien henkilön syömis-, ostos- tai ruokavaliota koskevista tavoista. Silloin saadaan parempi kokonaiskuva henkilön terveydentilasta. Terveydenhuollon sovelluksista tulee yhä henkilökohtaisempia ja sensorien mittaamaa sekä muista lähteistä kerättyä dataa voidaan hyödyntää yksilöllisten ohjeiden ja terveyttä koskevien ratkaisujen tekemiseksi. Tämä kehittää terveydenhuoltoa prediktiiviseen suuntaan, jolloin sairauksiin voidaan puuttua hyvissä ajoin. (Fox, 2017)

Kroatiassa on kehitteillä sovellusalusta sairauksien, kuten astman, kroonisen keuhkohtaumataudin, verenpainetaudin ja diabeteksen hallintaan. Alustaa voivat hyödyntää kentällä toimivat hoitajat ja se integroidaan kansalliseen digitaaliseen terveydenhuollon järjestelmään. Sovellukset, joita integroidaan digitaaliseen potilaskertomusjärjestelmään, ovat hyödyllisiä sekä potilaille että lääketieteen ammattilaisille. Esimerkkinä tämänkaltaisista mobiilisovelluksista on tanskalaisen yrityksen, Hedian, kehittämä sovellus, joka auttaa potilaita tyyppin 1 diabeteksen hoidossa. (Fox, 2017)

5 Yhteenveto

Tämän raportin tarkastelun kohteena ovat terveydenhuollon alustaratkaisut, joiden avulla organisaatiot voivat parantaa prosessejaan merkittävästi ja saavuttaa huomattavia säästöjä operationaalisissa kuluissa tunnistamalla muun muassa prosesseja, jotka johtavat päällekkäisiin toimintoihin, tehottomaan resurssien hyödyntämiseen, hitaaseen informaation virtaan ja heikkoon sekä hitaaseen potilaiden paranemisprosessiin. Ratkaistakseen kyseisenlaisia ongelmia, yritykset ovat kehittäneet joustavia pilvipohjaisia terveydenhuollon alustoja, joiden avulla aiemmin sirpaleinen terveydenhuollon informaatioteknologia voidaan yhdistää yhdeksi IT- ja palveluinfrastruktuuriksi. Laajalle levinnyt teknologian onnistunut käyttöönotto sekä siilomaisen datan yhdistäminen yhteen järjestelmään voi vähentää kustannuksia vähentäen potilaiden uusintajaksoja sairaaloissa, tarpeettomia lääkärissä käyntejä ja parantuneesta lääkityksen soveltuvuutta potilaille sekä kommunikaatiota potilaiden ja terveydenhuollon ammattilaisten kesken. Tärkeässä osassa tulevaisuuden terveydenhuollon tietojärjestelmiä ovat myös alustat, jotka kykenevät yhdistämään, keräämään, analysoimaan ja jakamaan potilaiden henkilökohtaista terveysdataa, jotta terveydenhuollon ammattilaiset voivat niiden kautta tarjota potilaille lääketieteellisiä palveluita monitoroitua ja kliinistä informaatiota tarkasteltuaan.

Tässä raportissa paneudutaan tekoälyyn ja terveydenhuollon alustoihin. Raportissa määritellään tekoälyn käsite, esitellään sen hyötyjä ja haittoja sekä menetelmiä, joita tekoälyn opetusprosessissa voidaan käyttää, kuten muun muassa neuroverkot sekä kone- ja syväoppiminen. Näitä menetelmiä hyödyntää tässä raportissa esitellyt tekoälyä hyödyntävät alustaratkaisut. Alustaratkaisut on jaettu kahteen osa-alueeseen, joista ensimmäisessä käsitellään terveydenhuollon alustaratkaisuja, jotka eivät ainakaan vielä hyödynnä tekoälyä. Toisessa osassa tarkastelun kohteena ovat alustaratkaisut, jotka hyödyntävät tekoälyä, kuten esimerkiksi koneoppimisen algoritmeja. Raportin lopussa luodaan lyhyt katsaus alustaratkaisujen ja terveydenhuollon kustannuksien tulevaisuudenkuvaan.

Tekoäly on käsitteenä suhteellisen vanha ja sen kehityskaaressa voidaan palata taaksepäin aina 1950-luvulle saakka. Tekoäly kehittyi 50-luvulta nykypäivään melko hitaasti, vaikka sen kehityksessä on ollut aika ajoitin lupaavia edistysaskeleita. Koneoppiminen ja sen menetelmät kehittyivät 80-luvulla ja teknologian kehittyessä niitä seurasivat syväoppimisen menetelmät 2010-luvulla, jolloin tekoälyn kehitys sai uutta vauhtia. Syväoppimisen tavoitteena on luoda soveltuvaa algoritmia hyödyntäen neuroverkko, joka tähtää jonkin tietyn valitun ongelman ratkaisemiseen. Syväoppimista on käytetty useiden eri lääketieteen ongelmien ratkaisemiseen muun muassa diagnostiikassa, puheiden, kuvien sekä tekstien tunnistamisessa ja käsittelyssä. Useat tuntevat Applen Sirin ja Googlen Street View-palvelut, joissa kyseisiä menetelmiä on hyödynnetty. Datan määrien räjähdysmäisesti kasvaessa erityisesti lääketieteen sektorilla tarvitaan uudenlaisia hyödyntämisen tapoja ja tähän

tarkoitukseen syväoppiminen tarjoaa uudenlaisia ratkaisumalleja, sillä sen on todettu olevan aiempia menetelmiä suorituskykyisempi.

Tekoäly tarjoaa oikein hyödynnettynä huomattavia mahdollisuuksia, sillä varsinkin lääketieteen sektorilla tekoäly on onnistunut paikoitellen diagnosoinneissa ylittämään jopa ammattilaisten diagnosointikyvyn ja kehitystyö tekoälyn ja sitä hyödyntävien järjestelmien sekä palveluiden suhteen on vasta aluillaan tietokoneiden prosessointikyvyn kasvaessa. Kvanttitietokoneen tullessa tulevaisuudessa tekoälyn kehitystyö nopeutuu yhä huomattavasti nykyisestä, sillä ne kykenevät suorittamaan laskutoimituksia ja ratkaisemaan monimutkaisia ongelmia vain sekunneissa tavanomaisten tietokoneiden suorittaessa operaatioita jopa 10 000 vuoden ajan. Tekoälyn sovellusalueet ovat laaja-alaiset ja vaihtelevat aina lääketieteestä sotilaskäyttöön saakka. Konsulttiyritys Gartner on arvioinut kvanttitietokoneiden tulemisen noin 10 vuoden päähän nykypäivästä.

Perinteisten terveydenhuollossa käytettyjen IT-alustojen lisäksi suosiota ovat lisänneet tekoälyä muun muassa koneoppimista hyödyntävät terveydenhuollon alustaratkaisut, sillä datan määrän yhä kasvaessa terveydenhuollon palvelutarjoajilla ei käytännössä ole mahdollisuuksia analysoida mitä tapahtuu, mikä osa datasta on hyödyllistä ja kuinka ihmiset käyttävät ja kokevat terveydenhuollon palveluita. Koneoppimisen algoritmeja hyödyntämällä potilas voidaan heti ohjata oikeaan paikkaan. Lisäksi on mahdollista nähdä, mitkä digitaaliset työkalut toimivat parhaiten, jolloin toimimattomat voidaan hylätä ja keskittyä vain lupaavimpiin. Soveltuvien terveydenhuollon alustalla toimivien työkalujen (kuten Googlen DeepMind Stream) avulla terveydenhuollon ammattilaiset kykenevät sovelluksen ja verikokeiden avulla löytämään potilaat, joilla on korkea riski akuuttiin munuaistoiminnan häiriötilaan.

Tekoälyä hyödyntäviä alustaratkaisuja tarvitaan yhä enemmän, sillä mitä enemmän kerätyn datan määrä lisääntyy, sitä vaikeampaa sitä on hyödyntää ja analysoida. Vuosien 2010 – 2015 välillä kerätyn potilasdatan määrä lisääntyi peräti 700 % ja kerätystä datasta 91 % oli rakenteetonta dataa, kuten kuvia, videoita, fyysisiä muistiinpanoja, sensoridataa ja genomi-informaatiota. Rakenteeton data usein sijaitsee organisoitujen tietokantojen ulkopuolella, kuten digitaaliset potilastiedot ja laboratorioraportit. Prosessointitehon kasvaessa dataa on helpompi sekä nopeampi jäsentää, arvioida ja kategorisoida, jolloin kyetään diagnosoimaan, ennustamaan ja tekoälyn sekä robotiikan avulla hoitamaan ihmisiä paremmin. Yhä kasvava määrä ihmisiä ympäri maailmaa ovat jo valmiita olemaan vuorovaikutuksessa lääketieteellisen laitteen, alustan, tai tekoälyohjatun robotin kanssa, joka kykenee vastaamaan kysymyksiin, suorittamaan testejä, tekemään diagnooseja perustuen testituloksiin sekä tarjoamaan hoitosuosituksia ja kontrolloimaan potilashoitoa. Tämä voi osaltaan helpottaa maailmanlaajuisesti lisääntyvää pulaa terveydenhuollon ammattilaisista sekä helpottaa heihin jo kohdistuvaa painetta.

Lähteet

Banos, O., Amin, M.B., Khan, W.A., Afzel, M., Ahmad, M. A. T., Ali, R., Bilal, M., Han, M., Hussain, J., Hussain, M., Hussain, S., Hur, T., H., Bang, J., H., Huynh-The, T., Idris, M., Kang, D. W., Park, S. B, Siddiqui, H., Vui, L., B., Famih, M., Khattak, A., M., Kang, B., H. & Lee, S. 2015. An Innovative Platform for Person-Centric Health and Wellness Support. *Bioinformatics and Biomedical Engineering, 3rd International Conference, IWBBIO, Spain.*

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.*

Chung, K. & Park, R., C. 2017. *Cloud Based u-Healthcare Network with QoS Guarantee for Mobile Health Service.* *Cluster Computing, The Journal of Networks, Software Tools and Applications, 1 – 15.*

Goodfellow, Bengio & Courville. 2016. *Deep Learning.* MIT Press, 755.

Jung, E-Y., Kim, J-H., Chung, K-Y. & Park D., K. 2013. *Home Health Gateway Based Healthcare Services Through U-Health Platform.* *Wireless Personal Communications, 73(2), 207 – 218.*

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.

Keltanen, T. 2006. *Vertaisverkkojen Topologian Hallinta Neurooverkoilla.* *Tietotekniikan Pro gradu-tutkielma.* Jyväskylän yliopisto, tietotekniikan laitos.

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

Purao, S. 2014. *IT Platforms.* *Wiley Encyclopedia of Management. Volume 7,* Wiley & Sons.

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

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:

Accolade. 2017. Accolade Introduces the Maya Intelligence Engine, Using AI and Machine Learning to Deliver the Most Personalized Healthcare Experience. Viitattu 2.1.2018

<https://www.accolade.com/press-releases/accolade-introduces-the-maya-intelligence-engine>

Akagi, D. 2014. A Primer on Deep Learning. Viitattu 16.5.2017

<https://www.datarobot.com/blog/a-primer-on-deep-learning>

Alerte. 2017. Mobile Health Platform. Viitattu 9.12.2017

<https://www.alertedh.com/products/mobile-health-platform>

Anantharamu, L. 2017. Akila Labs: Akila Health Coach to Reverse Prediabetes. MedStartr.

Viitattu 8.12.2017 <http://www.medstartr.com/project/detail/935>

Apixio. 2015. Apixio Iris Platform Powers Accurate Patient Risk Adjustment for Improved

Healthcare. Viitattu 2.1.2018 <http://www.marketwired.com/press-release/apixio-iris-platform-powers-accurate-patient-risk-adjustment-for-improved-healthcare-2075396.htm>

Apixio. 2017. Apixio HCC Profiler – Reimagining Risk Adjustment. Viitattu 2.1.2018 [https://](https://www.apixio.com/wp-content/uploads/2016/02/Apixio_HCC_Profiler_Brochure_052617.pdf)

www.apixio.com/wp-content/uploads/2016/02/Apixio_HCC_Profiler_Brochure_052617.pdf

Ayasdi. Understanding Ayasdi: What We Do, How We Do It, Why We Do It. Viitattu

15.12.2017 [https://s3.amazonaws.com/cdn.ayasdi.com/wp-](https://s3.amazonaws.com/cdn.ayasdi.com/wp-content/uploads/2017/06/20174822/UnderstandingAyasdi_WP_061617v011.pdf)

[content/uploads/2017/06/20174822/UnderstandingAyasdi WP_061617v011.pdf](https://s3.amazonaws.com/cdn.ayasdi.com/wp-content/uploads/2017/06/20174822/UnderstandingAyasdi_WP_061617v011.pdf)

Barreau, J. 2015. Defining the Mobile Health Platform. Healthcare DIVE. Viitattu 10.12.2017

<https://www.healthcaredive.com/news/defining-the-mobile-health-platform/372228>

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

Borgen, H. 2016. Learning to Code Neural Networks. KDnuggets. Viitattu 8.3.2018
<https://www.kdnuggets.com/2016/01/learning-to-code-neural-networks.html>

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>

Butcher, S. 2017. J.P.Morgan's Massive Guide to Machine Learning and Big Data Jobs in Finance. Efinancial Careers. Viitattu 27.12.2017 <https://news.efinancialcareers.com/uk-en/285249/machine-learning-and-big-data-j-p-morgan>

Castrounis, A. 2016. Artificial Intelligence, Deep Learning, and Neural Networks, Explained. KD Nuggets. Viitattu 19.12.2017 <https://www.kdnuggets.com/2016/10/artificial-intelligence-deep-learning-neural-networks-explained.html>

Comtact Healthcare. 2016. Digital Platform: Taking the NHS on the Digital Journey. Viitattu 9.12.2017 <http://www.comtacthealthcare.com/digital-platform.html>

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>

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

Diabnext. 2017. Technology That Smoothly and Accurately Supports your Diabetes Decisions. Viitattu 9.12.2017 <https://diabnext.com>

Doc.ai. 2017. If Medical Data Could Talk, What would It Say? Viitattu 9.12.2017
<https://doc.ai>

Eubanks, R. 2017. AI and the Healthcare Ecosystem – Why Use Articial Intelligence. Viitattu 27.12.2017 <https://www.capgemini.com/2017/11/ai-and-the-healthcare-ecosystem-why-use-artificial-intelligence/#>

Fox, G. 2017. Healthcare As a Platform – The Future of Healthcare. Viitattu 11.12.2017
<https://www.garyefox.com/thinking/healthcare-as-a-platform-future-healthcare>

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

HealthSaaS. Helthcare Cognitive Patient Monitoring System. HealthSaaS Delivers Cognitive Patient Monitoring with the Intel Health Application Platform. Intel Corporation. Viitattu 9.12.2017 https://www.healthsaas.net/wp-content/uploads/2017/10/13132-14_Intel_IoT_HealthSaas_SolutionBrief-FINAL-092717.pdf

HIT Consultant. 2017. Ayasdi Launches New AI Platform That Turns Health Systems Into AI App Incubators. Viitattu 15.12.2017 <http://hitconsultant.net/2017/06/21/ayasdi-ai-app-incubators>

i-Scoop. Artificial Intelligence (AI) and Cognitive Computing: What, Why and Where. Viitattu 21.12.2017 <https://www.i-scoop.eu/artificial-intelligence-cognitive-computing>

Inhealthcare. National Digital Health Platform. The Inhealthcare National Digital Platform Supports Remote Home Monitoring at Scale. Viitattu 10.12.2017
<http://www.inhealthcare.co.uk/wp-content/uploads/2017/08/Digital-health-platform-brochure-1.pdf>

Issuu. 2017. Diabnext – The World’s First Diabetes Management A.I. Platform. Viitattu 9.12.2017 <https://issuu.com/isabelle347/docs/catalogue-10>

Jagreet. 2017. Log Analytics with Deep Learning and Machine Learning. Xenonstack. Viitattu 19.12.2017 <https://www.xenonstack.com/blog/log-analytics-with-deep-learning-and-machine-learning>

Jain, K. 2015. Machine Learning Basics for a Newbie. Analytics Vidhya. Viitattu 27.12.2017
<https://www.analyticsvidhya.com/blog/2015/06/machine-learning-basics>

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>

Bursuc, A., Krzakala, F. & Lelarge, M. Convolutions, CNN Architectures, Visualizations, GPU, Training, NNs in Practice. Viitattu 8.3.2018
http://www.di.ens.fr/~lelarge/dldiy/slides/lecture_7/index.html#92

Kulkarni, N. 2015. Apixio's New Iris Platform Uses Your Doctor's Notes to Derive Insights. Viitattu 2.1.2018 <https://techcrunch.com/2015/11/19/apixios-new-iris-platform-uses-your-doctors-notes-to-derive-insights>

Mack, H. 2017. 31 New Digital Health Tools Showcased at CES 2017. Mobi Health News. Viitattu 9.12.2017 <http://www.mobihealthnews.com/content/31-new-digital-health-tools-showcased-ces-2017>

Mannes, J. 2016. CareSkore Gets \$4.3M to Bring Machine Learning to Preventive Care. Viitattu 27.12.2017 <https://techcrunch.com/2016/08/10/careskore-gets-4-3m-to-bring-machine-learning-to-preventive-care>

Meeden, L. 2017. Deviation of Backpropagation. Viitattu 19.12.2017
<https://www.cs.swarthmore.edu/~meeden/cs81/s10/BackPropDeriv.pdf>

Mcgrane, C. 2017. The Amazon of Healthcare? Accolade Unveils AI Platform and App that Personalize Healthcare Assistance. GeekWire. Viitattu 2.1.2018
<https://www.geekwire.com/2017/amazon-healthcare-accolade-unveils-ai-platform-mobile-app-personalize-healthcare-assistance>

NVIDIA. 2017. Deep Learning for Healthcare: Building a Common Platform for AI Across Healthcare. Viitattu 9.12.2017 <https://www.nvidia.com/en-us/deep-learning-ai/industries/healthcare>

Pagelis, A., J. & Kim, D., S. Backpropagation. Viitattu 19.12.2017
<https://www.cse.unsw.edu.au/~cs9417ml/MLP2/BackPropagation.html>

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

Patel, S. & Pingel, J. 2017. Introduction to Deep Learning. What are Convolutional Neural Networks? Viitattu 19.12.2017 <https://se.mathworks.com/videos/introduction-to-deep-learning-what-are-convolutional-neural-networks--1489512765771.html>

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

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>

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

Shah, S., N. What is a Healthcare IT Platform? Viitattu 10.12.2017 <https://www.slideshare.net/eddodds/shahslides1>

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

Storj Labs. 2017 Doc.ai Integrates Storj to Help Decentralize and Secure Medical Data. Cision Newswire. Viitattu 9.12.2017 https://www.prnewswire.com/news-releases/docai-integrates-storj-to-help-decentralize-and-secure-medical-data-300566966.html?tc=eml_cleartime

Stuart, S. 2017. The Robo-Doctor Will See you Now. PC News. Viitattu 9.12.2017 <http://uk.pcmag.com/news/90873/the-robo-doctor-will-see-you-now>

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

Tuominen, H. 2018. Johdatus tekoälyn taustalla olevaan matematiikkaan. Jyväskylän yliopisto. Viitattu 27.2.2018 <https://helituominen.wordpress.com/kurssit-it/johdatus-tekoalyn-taustalla-olevaan-matematiikkaan-tiep1000-syksy-2017>

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>

Vasilev, I. 2017. A Deep Learning Tutorial: From Perceptrons to Deep Networks. Viitattu 19.12.2017 <https://www.toptal.com/machine-learning/an-introduction-to-deep-learning-from-perceptrons-to-deep-networks>

Vitaris, B. 2017. The Next Doctor You Consult Could be a Robot: Healthcare Meets AI and the Blockchain. BitcoinMagazine. Viitattu 9.12.2017 <https://bitcoinmagazine.com/articles/next-doctor-you-consult-could-be-robot-healthcare-meets-ai-and-blockchain>

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>

Wray, M. 2017. Using Amazon Polly to Deliver Health Care for People with Long-Term Conditions. AWS AI Blog. Viitattu 10.12.2017 <https://aws.amazon.com/blogs/ai/using-amazon-polly-to-deliver-health-care-for-people-with-long-term-conditions>

Zibreg, C. 2013. Samsung Said to Develop Galaxy Band Wearable Device, Headed by Apple's Former Siri Engineer. Viitattu 20.12.2.2017 <http://www.idownloadblog.com/2013/12/20/samsung-galaxy-band>

Informaatioteknologian tiedekunnan julkaisuja
No. 48/2018

ISBN 978-951-39-7366-7 (verkkoj.)
ISSN 2323-5004