

Petri Vähäkainu, Antti Kariluoto ja
Pekka Neittaanmäki

Tekoäly ja rakennusten ennakoiva kunnossapito



HALLITUKSEN
KÄRKIHANKE



JYVÄSKYLÄN YLIOPISTO

 KIRA-digi

REGERINGENS
SPETSPROJEKT

Informaatioteknologian tiedekunnan julkaisuja
No. 79/2019

Editor: Pekka Neittaanmäki

Covers: Petri Vähäkainu ja Matti Savonen

Copyright © 2019

Petri Vähäkainu, Antti Kariluoto, Pekka

Neittaanmäki ja Jyväskylän yliopisto

ISBN 978-951-39-7730-6 (verkkokj.)

ISSN 2323-5004

Jyväskylä 2019

Tekoäly ja rakennusten ennakoiva kunnossapito

Petri Vähäkainu
Antti Kariluoto
Pekka Neittaanmäki



Tämä julkaisu on toteutettu osana KIRA-digi-hanketta, johon Jyväskylän yliopisto on saanut rahoituksen SYKiltä ja ympäristöministeriöltä toteuttaen hallituksen julkisten palveluiden digitalisoimisen kärkihanketta.



LYHENNELISTA

AI	Artificial Intelligence eli tekoäly
ANN	Artificial Neural Network eli keinotekoinen neuroverkko
BAM	Bundesanstalt für Materialforschung und -prüfung eli materiaalitutkimus- ja testauslaitos
BI	Business Intelligence tarkoittaa liiketoimintatiedon hallintaa
BIM-malli	Building Information Modeling eli BIM tarkoittaa rakennuksen rakenteen informaatiomallinnusta mahdollistaen datan samanaikaisen tarkastelun
BN	Batch Normalization –algoritmin avulla CNN –verkon odotusarvoa ja varianssin odotusarvoa kontrolloidaan ja korjataan arvot normaalijakaumaan
BP	The Back Propagation Neural Network Algorithm on iteratiivinen, laskevan gradientin oppimisalgoritmi
CAD	Computer Aided Design tarkoittaa tietokoneavusteista suunnittelua, jota hyödyntävät muun muassa insinöörit ja arkkitehdit
CAM	Content Addressable Memory eli muistityyppi, joka toimii hakukoneen tavoin
CCMS	Computerized Maintenance Management Systems tarkoittaa tietokoneohjattuja kunnossapidon hallintajärjestelmiä
CNN	Convolutional Neural Network eli konvoluutioneuroverkko
CPS	Cyber-Physical System eli kyber-fyysinen –järjestelmä
CPU	Central Processing Unit eli keskusyksikkö
CSV	Comma-separated values on tekstitiedostoformaatti, joka käyttää pilkkua numero- tai tekstidata-arvojen erottamiseen
CWI	Coda Wave Interferometry –tekniikalla (koda-aalto-häiriömittaus) voidaan tutkia esimerkiksi betonipalkkien halkeamien paikantamista 50 KHz–taajuudella
DAG's	Directed Asyclic Graphs eli suunnatut epäsykliset graafit
DL	Dropout Layer eli häipymäkerros pienentää riskiä mallin ylioppimiseen opetusdatasta, jolloin tarkkuuden yleistäminen validointidatalle mahdollistuu
DNN	Deep Neural Network eli syvä neuroverkko on keinotekoinen ANN-neuroverkko, jossa on useita sisääntulo- ja ulostulokerroksien välissä
DT	Digital Twin eli digitaalinen kaksonen
ELM	Extreme Learning Machine on yhden piilokerroksen sisältävä neuroverkko, jonka painot ja piilokerroksen noodien määrät valitaan satunnaisesti
FE-malli	Finite Element –mallia käytetään rakennelman vaurioiden suuruuden arviointiin ja poikkeamien paikkojen päättelyyn suhteessa rakennelmaan
GPS	Global Positioning System (Navstar) tarkoittaa USA:n puolustusministeriön kehittämää maailmanlaajuista satelliittipaikannusjärjestelmää
GPU	Graphical Processing Unit eli grafiikkaprosessori
GUI	Graphical User Interface tarkoittaa tekstiin, kuviin ja käyttöliittymä-elementteihin perustuvaa tapaa käyttää tietokoneohjattua laitetta
HF-WSN	High frequency Wireless Sensor Network tarkoittaa langatonta korkeita taajuuksia mittauksissa hyödyntävää sensoriverkkoa

HVAC	Heating, ventilation and air conditioning on teknologia, joka parantaa mukavuutta rakennusten sisätiloissa ja ajoneuvoissa
IIoT	Industrial Internet of Things eli teollinen esineiden Internet
IoT	Internet of Things tarkoittaa esineiden Internetiä, jossa Internet-verkko on laajentunut laitteisiin ja koneisiin, joita voidaan ohjata, mitata ja sensuroida Internet-verkon yli
JSON	JavaScript Object Notation on yksinkertainen avoimen standardin tiedostomuoto tiedonvälitykseen
LEED	Leadership in Energy and Environmental Design tarkoittaa suositua maailmanlaajuisesti käytettyä vihreiden rakennuksien sertifiointiohjelmaa
LF-WSN	Low frequency Wireless Sensor Network tarkoittaa langatonta matalia taajuuksia mittauksissa hyödyntävää sensoriverkkoa
MAE	Mean Average Error tarkoittaa keskimääräistä keskivirhettä
MCS	Monte-Carlo Sampling eli Monte-Carlo –otanta on joukko laskennallisia algoritmeja, jotka perustuvat toistuviin satunnaisotantoihin numeeristen tulosten saavuttamiseksi esimerkiksi determinististen ongelmien ratkaisemiseksi
MLF	Magnetic Flux Leakage on tekniikka, jonka avulla voidaan mitata poikkeamia metallisessa rakennuksessa noin oman kokoisensa pinnan alueelta
MLR	Multiple Linear Regression tekniikkaa käytetään ennuste- (riippumaton) ja kriteerimuuttujien (riippuva) välisten suhteiden tarkastelemiseen
MSE	Mean Structured Error tarkoittaa keskimääräistä neliöön korotettua virhettä
PCA	Principal Component Analysis eli pääkomponenttianalyysi on dimension redusointitekniikka, jolla voidaan monidimensioisesta datasta löytää ne komponentit, joiden avulla sen keskeisimmät piirteet voidaan esittää
PdM	Predictive maintenance eli ennakoiva kunnossapito
ReLU	Rectified Linear Unit on CNN –neuroverkkojen tasasuuntaus-funktio, joka tuottaa arvon 0, jos lähtö on negatiivinen, muuten tulo on muuttomaton
SfM	Structure-from-Motion –algoritmin avulla voidaan esimerkiksi tasaista reittiä lentävän lennokin ottamien kuvien perusteella muodostaa rakennemalli
SGD	Stochastic Gradient Descent tarkoittaa stokastista laskevan gradientin algoritmia, jota voidaan käyttää CNN –neuroverkkoa koulutettaessa
SHM	Structural Health Management tai Structural Health Monitoring tarkoittaa rakenteiden kunnossapitoa tai rakenteiden kunnon valvontaa
SOM	Self Organizing Map eli itsestään järjestyvä kartta
SQL	Structured Query Language on IBM:n kehittämä standardoitu kyselykieli, jolla relaatiotietokantaan voi tehdä erilaisia hakuja, muutoksia ja lisäyksiä
SM	Surrogate Model eli virtuaalinen sijaismalli
SR	Stepwise Regression on menetelmä regressiomallien sovittamiseksi, jossa ennustavien muuttujien valinta suoritetaan automaattisella menettelyllä
SW	Sliding Window eli liukuva ikkuna –tekniikka, jota voidaan hyödyntää esimerkiksi rakennuksissa olevien halkeamien kaksinkertaiseen tarkastamiseen

VT/IM	Virtual Tour tarkoittaa virtuaalikierrosta, jossa käyttäjä pystyy liikkumaan vapaasti eri suuntiin rakennuksen 3D –mallissa ja Information modelling tarkoittaa informaatiomallennus.
WSN	Wireless Sensor Networks on langaton sensoriverkkojärjestelmä, johon kuuluu reaaliaikaisuus, tunkeilemattomuus, halpa hinta, datan keräys ja analysointi

KUVIOT

KUVIO 1. SYK:N DATAN ANALYSOINTIPROESSIN VAIHEET	3
KUVIO 2. KEHITYSKULKU TEKOÄLYSTÄ SYVÄOPPIMISEEN	5
KUVIO 3. YKSINKERTAINEN KEINOTEKOINEN NEUROVERKKO	8
KUVIO 4. ETEENPÄIN SYÖTTÄVÄ NEUROVERKKO.....	9
KUVIO 5. TAKAISINKYTKETTY NEUROVERKKO	9
KUVIO 6. AUTOENKODERIN ARKKITEHTUURIKAAVIO.....	10
KUVIO 7. VERKKOTASON ESITYS AUTOENKODERI-NEUROVERKOSTA.....	10
KUVIO 8. YKSINKERTAINEN KEINOTEKOINEN NEUROVERKKO	12
KUVIO 9. YKSINKERTAINEN KEINOTEKOINEN NEUROVERKKO	13
KUVIO 10. ÄLYKKÄÄN KAUPUNGIN KONSEPTI.....	21
KUVIO 11. IOT-TOIMINTA JA SOVELLUSALUEITA.....	23
KUVIO 12. IOT YHDISTYY IHMISILLE LISÄARVOA TUOTTAVIIN PALVELUIHIN	24
KUVIO 13. IOT JA RAKENNUKSEEN ASENNETTAVIA ÄLYKKÄITÄ SENSOREITA.....	25
KUVIO 14. IOT-ANALYTIIKAN OMINAISPIIRTEITÄ	27
KUVIO 15. PÄÄLLE PUETTAVA TEKNOLOGIA JA SEN SOVELLUSALUEITA.....	28
KUVIO 16. ERILAISTEN KUNNOSSAPIDON OHJELMIEN HYÖTYJÄ JA HAITTOJA.....	34
KUVIO 17. SIJOITETUN PÄÄOMAN TUOTTO % KUNNOSSAPIDON OHJELMISSA.....	34
KUVIO 18. KUSTANNUKSET VIKAANTUMISEN FUNKTIONA KUNNOSSAPIDOSSA	35
KUVIO 19. KUNNOSSAPIDON YLLÄPITOKUSTANNUKSIA TEOLLISUUDEN ALOILLA.....	36
KUVIO 20. ENNAKOIVAN KUNNOSSAPIDON PROSESSI	37
KUVIO 21. DATAN HYÖDYNTÄMINEN ENNAKOIVASSA KUNNOSSAPIDOSSA	37
KUVIO 22. ESIMERKKI ENNAKOIVAN KUNNOSSAPIDON PROSESSISTA TEOLLISUUDESSA.....	38
KUVIO 23. PDM:ÄÄ OHJAAVAT TEKNOLOGIAT.....	39
KUVIO 24. ACMEN NELJÄ AVAINKOMPONENTTIA PDM:N TOTEUTUKSEEN	39
KUVIO 25. KONVOLUUTIONEUNROVERKON HYÖDYNTÄMINEN KUVAN LUOKITTELUSSA	40
KUVIO 26. NEUROVERKON HYÖDYNTÄMINEN ONGELMIEN ENNAKOINNISSA	41
KUVIO 27. TENSORFLOW-NEUROVERKON OPETTAMINEN JA ENNAKOIVA MALLI.....	42
KUVIO 28. VIBRAATIONÄYTTEEN LÄHETTÄMINEN KORJAUSTARPEEN ENNAKOINTI	42

KUVIO 29. SALESFORCE-TIKETIN AUKEAMINEN KORJAUSTARPEEN ILMAANNUTTUA	43
KUVIO 30. KAAVIOKUVA SHM-ALUSTAN KÄYTÖSTÄ	44
KUVIO 31. PILVENPIIRTÄJIEN VÄRÄHTELYMITTAUKSISSA KÄYTETTYJÄ ÄLYSENSOREITA	45
KUVIO 32. KERÄYSALUSTAN TOIMINTAMALLI.....	45
KUVIO 33. JÄRJESTELMÄN TOIMINTAMALLI	47
KUVIO 34. ST. THERESAN SHM-JÄRJESTELMÄ	48
KUVIO 35. DATA SIIRTYY DRONELTA SERVERIN KAUTTA ROBOTILLE	49
KUVIO 36. VINSSIROBOTTI, JOKA OSAA AUTOMAATTISESTI KIERTÄÄ ESTEITÄ	49
KUVIO 37. KESKIARVOISTAMISEN VAIKUTUS REITISSÄ	50
KUVIO 38. TUULIVOIMALAITOKSEN SHM-JÄRJESTELMÄN RAKENNEKUVA	50
KUVIO 39. LENNOKILLA ON SUOJAT PROPELLIENSA YMPÄRILLÄ.....	52
KUVIO 40. KÄYTTÄJÄN SAAMA NÄKYMÄ VT/IM-OHJELMASTA	53
KUVIO 41. KOKONAISSALTAISEN ARKKITEHTUURI BETONISEINÄN TILASTA.....	58
KUVIO 42. KUVAT KÄYTIIN LÄPI LIUKUVA IKKUNA-TEKNIIKALLA	59
KUVIO 43. PÄÄNEUROVERKON TULOKSET	61
KUVIO 44. APONEUROVERKON TULOKSET SIMULOIDULLA DATALLA JA VIRHEILLÄ.....	61
KUVIO 45. YHDISTETTYJEN NEUROVERKKOJEN TULOKSET	61
KUVIO 46. HAVAINTOKUVA KESKENERÄISESTÄ PÄÄKATSOMOSTA.....	62
KUVIO 47. VAURIOIDEN TODENNÄKÖISYYDET YHDEN PALKIN MITTAUKSESSA.....	63
KUVIO 48. KAHDEN VAURION TODENNÄKÖISYYS.....	63
KUVIO 49. SILLAN DATAN MATKA LUOKITELLUKSI.....	64
KUVIO 50. NELIÖMUODON, TRENDIN JA AJELEHTIVAN HÄIRIÖN HAVAINNOLLISTUS	65
KUVIO 51. ELM:N PERUSTEET	66
KUVIO 52. ELM:N PARAS TARKKUUS SAAVUTETTIIN 22-NODEN KOHDALLA.....	67
KUVIO 53. MLR OLI NOPEIN KOULUTTAA.....	68
KUVIO 54. RASITUKSEN TODELLISET JA ENNUSTETUT ARVOT	69
KUVIO 55. RAKENNUKSEN 1. KERROKSEN 1. LÄMPÖTILAT 1.8.2018 - 28.1.2019.....	72
KUVIO 56. RAKENNUKSEN 1. KERROKSEN 2. LÄMPÖTILAT 1.8.2018 - 28.1.2019.....	73
KUVIO 57. RAKENNUKSEN 1. KERROKSEN 3. ASUNTOJEN LÄMPÖTILAT 1.8.2018 - 28.1.2019.....	74

KUVIO 58. RAKENNUKSEN 2. KERROKSEN 1. LÄMPÖTILAT 24.9.2018 - 24.1.2019.....	75
KUVIO 59. RAKENNUKSEN 2. KERROKSEN 2. LÄMPÖTILAT 24.9.2018 - 24.1.2019.....	76
KUVIO 60. RAKENNUKSEN 2. KERROKSEN 3. LÄMPÖTILAT 24.9.2018 - 24.1.2019.....	77
KUVIO 61. RAKENNUKSEN 2. KERROKSEN 4. LÄMPÖTILAT 24.9.2018 - 24.1.2019.....	78
KUVIO 62. RAKENNUKSEN 1. TORNIN 2. LÄMPÖTILAT 24.9.2018 - 24.1.2019	79
KUVIO 63. RAKENNUKSEN 1. TORNIN 6. LÄMPÖTILAT 24.9.2018 - 24.1.2019	80
KUVIO 64. RAKENNUKSEN 2. TORNIN 1. LÄMPÖTILAT 24.9.2018 - 24.1.2019	81
KUVIO 65. RAKENNUKSEN 2. TORNIN 2. LÄMPÖTILAT 24.9.2018 – 24.1.2019.....	82
KUVIO 66. RAKENNUKSEN 2. TORNIN 3. LÄMPÖTILAT 24.9.2018 - 24.1.2019	83
KUVIO 67. RAKENNUKSEN 2. TORNIN 4. LÄMPÖTILAT 24.9.2018 – 24.1.2019.....	84
KUVIO 68. RAKENNUKSEN 2. TORNIN 5. LÄMPÖTILAT 24.9.2018 - 24.1.2019	85
KUVIO 69. RAKENNUKSEN 2. TORNIN 6. LÄMPÖTILAT 24.9.2018 - 24.1.2019	86
KUVIO 70. CONNECT LÄMMITYS MUUTTUJEN LÄMPÖTILA-ARVOT 14.12.2018 - 29.1.2019.....	87
KUVIO 71. CONNECT LÄMMITYS 1 –MUUTTUJEN LÄMPÖTILA-ARVOT 14.12.2018 - 29.1.2019.....	88
KUVIO 72. CONNECT LÄMMITYS 2 –MUUTTUJEN LÄMPÖTILA-ARVOT 14.12.2018 - 29.1.2019.....	89
KUVIO 73. CONNECT LÄMMITYS –MUUTTUJEN LÄMPÖTILA-ARVOT 14.12.2018 - 29.1.2019.....	90
KUVIO 74. CONNECT LÄMMITYS –MUUTTUJEN KORRELAATIOMATRIISI	91
KUVIO 75. PAINEILMA MAMA –MUUTTUJEN LÄMPÖTILA-ARVOT 7.10.2018 - 29.1.2019.....	92
KUVIO 76. PAINEILMA MAMA –MUUTTUJEN LÄMPÖTILA-ARVOT 7.10.2018 - 29.1.2019.....	93
KUVIO 77. PAINEILMA MAMA –MUUTTUJEN KORRELAATIOMATRIISI	94
KUVIO 78. RAKENNUS 2. KOOTTUJA POIKKEAMIA.....	95
KUVIO 79. RAKENNUS 2	96
KUVIO 80. ASUNTOJEN LÄMPÖTILAN KESKIARVON JA ULKOLÄMPÖTILAN KÄYTÖS (15.12.2018 - 7.1.2019)	96

KUVIO 81. ASUNTOJEN LÄMPÖTILAN KESKIARVON TUNNITTAINEN ETÄISYYS ULKOILMAN LÄMPÖTILAAN NÄHDEN	97
KUVIO 82. ASUNTOJEN LÄMPÖTILAN KESKIARVON JA MAMA KOLMEN TUNNIN S - MUUTTUJAN KÄYTÖS (23.10.2018 - 28.10.2018)	99
KUVIO 83. ASUNTOJEN LÄMPÖTILAN KESKIARVON TUNNITTAINEN ETÄISYYS MAMA KOLMEN TUNNIN S -MUUTTUJAAN NÄHDEN	100
KUVIO 84. RAKENNUKSEN 1. LÄMPÖTILA SUHTEESSA ULKOILMAN LÄMPÖTILAAN (16.11.2018 - 24.1.2019)	101
KUVIO 85. RAKENNUKSEN 1. ASUNTOJEN LÄMPÖTILAN MUUTOS SUHTEESSA ULKOLÄMPÖTILAAN (16.11.2018 - 24.1.2019)	102
KUVIO 86. RAKENNUKSEN 1. LÄMPÖTILAN MUUTOS SUHTEESSA ULKOILMAN LÄMPÖTILAN MUUTOKSEEN (16.11.2018 - 24.1.2019)	103
KUVIO 87. RAKENNUKSEN 1. LÄMPÖTILAN MUUTOS SUHTEESSA ULKOILMAN LÄMPÖTILAN MUUTOKSEEN (16.11.2018 - 24.1.2019)	104
KUVIO 88. LÄMPÖTILAN KESKIARVOT SUHTEESSA ULKOILMAN LÄMPÖTILAAN 1.11.2018 - 29.1.2019.....	105
KUVIO 89. RAKENNUKSEN 2. ASUNTOJEN LÄMPÖTILAMUUTOS SUHTEESSA ULKOILMAN LÄMPÖTILAAN	105
KUVIO 90. ASUNTOJEN LÄMPÖTILAMUUTOS SUHTEESSA ULKOLÄMPÖTILAN MUUTOKSEEN TUNNIN AIKANA.....	106
KUVIO 91. RAKENNUKSEN 2. ASUNTOJEN YHTEISEN LÄMPÖTILAN KESKIARVON MUUTOS SUHTEESSA ULKOLÄMPÖTILAN MUUTOKSEEN RAJATTUNA KAPEAMMALLE VÄLILLE (1.11.2018 - 29.1.2019).....	107
KUVIO 92. RAKENNUKSEN 2. CONNECT LÄMMITYS 1. MENO –MUUTTUJAN MUUTOS SUHTEESSA ULKOLÄMPÖTILAAN 1.11.2018 - 29.1.2019	108
KUVIO 93. RAKENNUKSEN 2. CONNECT LÄMMITYS 1. MENO –MUUTTUJAN MUUTOS SUHTEESSA ULKOLÄMPÖTILAAN 1.11.2018 - 29.1.2019	109
KUVIO 94. RAKENNUKSEN 2. CONNECT LÄMMITYS 1. PALUU –MUUTTUJAN MUUTOS SUHTEESSA ULKOLÄMPÖTILAAN 1.11.2018 - 29.1.2019	110
KUVIO 95. RAKENNUKSEN 2. CONNECT LÄMMITYS 1. PALUU –MUUTTUJAN MUUTOS SUHTEESSA ULKOLÄMPÖTILAAN 1.11.2018 - 29.1.2019	110
KUVIO 96. RAKENNUKSEN 2. CONNECT LÄMMITYS 2. MENO –MUUTTUJAN LÄMPÖTILA-ARVOT SUHTEESSA ULKOLÄMPÖTILAAN 1.11.2018 - 29.1.2019	111

KUVIO 97. RAKENNUKSEN 2. CONNECT LÄMMITYS 2. MENO –MUUTTUJAN MUUTOS SUHTEESSA ULKOLÄMPÖTILAAN 1.11.2018 - 29.1.2019	112
KUVIO 98. RAKENNUKSEN 2. CONNECT LÄMMITYS 2. PALUU –MUUTTUJAN LÄMPÖTILA SUHTEESSA ULKOLÄMPÖTILAAN 1.11.2018 - 29.1.2019	112
KUVIO 99. RAKENNUKSEN 2. CONNECT LÄMMITYS 2. PALUU –MUUTTUJAN MUUTOS SUHTEESSA ULKOLÄMPÖTILAN MUUTOKSEEN 1.11.2018 - 29.1.2019	113
KUVIO 100. RIOTS HUONEISTOHALLINTARATKAISU HUONEISTOTASOLLA.....	114
KUVIO 101. RIOTS-INFRAAN TOIMINTAPERIAATE	115
KUVIO 102. YRITYSTEN JULKISEN PILVIPALVELUN OMAKSUMISASTE PROSENTTEINA.....	117
KUVIO 103. GOOGLLEN PILVIPALVELUARKKITEHTUURI IOT-TOTEUTUKSESSA.....	120
KUVIO 104. DATAN LÄHETYS PUB/SUB JA DATAFLOW KAUTTA ANALYSOITAVAKSI	120
KUVIO 105. HAVAINTOKUVA TAMPEREEN KAMPUSAREENASTA	126
KUVIO 106. TAMPEREEN KAMPUSAREENAN FYYSINEN SIJAINTI	127
KUVIO 107. SYKIN IOT -ALUSTA (VIRPA C JA D)	129
KUVIO 108. RASPERRY PI3 JA ANTURIT	129
KUVIO 109. SYKIN IOT -ALUSTAN ARKKITEHTUURI	130
KUVIO 110. KAMPUSAREENAN SENSORIVERKON DATA ENNEN ESIPROSESSOINTIA	131
KUVIO 111. KAMPUSAREENAN SENSORIVERKON DATA ESIKÄSITELTYNÄ	131
KUVIO 112. KAMPUSAREENAN SENSORIVERKON DATAN LUKUMÄÄRIÄ	132
KUVIO 113. HUONEISTA 515. JA 534. TEHDYT LIIKETUNNISTUKSEN SENSORIMITTAUKSET	133
KUVIO 114. TAPAHTUMA-AREENAN TEHDYT ILMANKOSTEUDEN SENSORIMITTAUKSET	133
KUVIO 115. HUONEEN 515 PAINEEEN MITTAUKSET OVAT ALUSSA SELKEÄSTI JATKUVIA.	134
KUVIO 116. TAPAHTUMA-AREENAN EPÄJATKUVUUSKOHDAT	134
KUVIO 117. LÄMPÖTILAN KUVAAJAT	135
KUVIO 119. LIIKETUNNISTUKSEN MITTAUS ALKOI 12. PÄIVÄ MAALISKUUTA	137
KUVIO 120. PCA-MALLI JA KUMULATIIVINEN SUMMA	138
KUVIO 121. DATAN MITTAUKSIIN PERUSTUVA SOM-MALLIN MUODOSTAMINEN	138
KUVIO 122. DATAN MITTAUKSIIN PERUSTUVA KLUSTERIMALLIN MUODOSTAMINEN	139
KUVIO 123. DENDROGRAMMI SKAALATULLE DATALLE	140

KUVIO 124. DENDROGRAMMIN JUURI JA ALIPUIDEN KOOT.....	140
KUVIO 125. HÄRMÄLÄN NORMALISOITU SÄÄDATA.....	141
KUVIO 126. TAPAHTUMA-AREENAN KOSTEUS JA LÄMPÖTILA YHDESSÄ SÄÄDATAN KANSSA	142
KUVIO 127. KOSTEUDEN VUOROKAUSIKÄYTTÄYTYMINEN	142
KUVIO 128. PAINEEN KÄYTTÄYTYMINEN PÄIVIN JA ÖIN	143
KUVIO 129. LÄMPÖTILAKÄYTTÄYTYMINEN PÄIVIN JA ÖIN	143
KUVIO 130. PCA-ANALYSOINTI YHDISTETYLLLE HUONE- JA SÄÄDATALLE	144
KUVIO 131. TAPAHTUMA-AREENAN KOVARIANSSI JA OMINAISARVO-TAULUKKO	145
KUVIO 132. PRED-SARAKKEESSA ON MALLILLA ENNUSTETTU ARVO.....	146
KUVIO 133. KOSTEUDEN (A), PAINEEN (B) JA LÄMPÖTILAN (C) ENNUSTEIDEN EPÄTARKKUUS	146
KUVIO 134. LINEARREGRESSION (YLIN), BAYESIANRIDGE JA RIDGE-LSQR (ALIN) MALLIEN TULOKSET KOSTEUDEN ENNUSTUKSESSA	148
KUVIO 135. BAYESIANRIDGE (YLIN), LINEARREGRESSION JA RIDGE-CHOLESKY (ALIN). SISÄTILAN LÄMPÖTILAN ENNUSTAMINEN.....	149
KUVIO 136. LINEARREGRESSION (YLIN), LASSO, KERNELRIDGE-LINEAR (ALIN). PAINEEN ENNUSTEET.....	150
KUVIO 137. LINEARREGRESSOR (YLIN), RANSACREGRESSOR, SVR-RBF (ALIN)	151
KUVIO 138. KERNELRIDGE-LINEAR (YLIN), SVR-SIGMOID, SVR-RBF. SISÄTILAN LÄMPÖTILAENNUSTEET.....	152
KUVIO 139. LIIKETUNNISTUKSEN KESKIMÄÄRÄ 5 MINUUTIN AIKAJAKSOJEN FUNKTIONA	153
KUVIO 140. LIIKETUNNISTUSDATAN EROTUKSET SEKUNNEISSA EDELTÄVÄÄN ARVOON AIKAVÄLILLÄ 0 - 60 S.....	154
KUVIO 141. LIIKETUNNISTUSDATAN EROTUKSET SEKUNNEISSA EDELTÄVÄÄN ARVOON KOKO AIKAVÄLILTÄ.....	154
KUVIO 142. SIMULOIDUN DATAN CO ₂ –KASVU AJAN JA HENKILÖMÄÄRÄN KASVAESSA	157
KUVIO 143. KAIKEN SIMULOIDUN DATAN JAKAUMA ENSIMMÄISELTÄ 30 MINUUTILTA.....	158
KUVIO 144. LSTM –NEUROVERKON PIILOKERROKSET	158
KUVIO 145. PARHAIMMAN NN-VERKON ENNUSTEET.....	159

SISÄLLYSLUETTELO

1.	Johdanto	1
1.1	Yleistä KIRA-digi -hankkeesta	2
1.2	Jyväskylän yliopiston KIRA-digi -pilottihankkeen kuvaus	3
2.	Tekoälyn kehityspolku ja menetelmiä	5
2.1	Tekoälyn määritelmä	6
2.2	Tekoälyn menetelmiä	7
2.2.1	Neuroverkot	7
2.2.2	Koneoppiminen	14
2.2.3	Syväoppiminen	16
3.	Älykkäät rakennukset ja kaupungit	18
3.1	Älykkäät rakennukset ja niiden määritelmä	18
3.2	Älykkäät kaupungit ja hankkeet	19
3.3	Esineiden internet (IoT) ja sen sovellusalueita	22
3.3.1	Yleistä esineiden internetistä	22
3.3.2	Esineiden internet ja sensorit älykkäissä rakennuksissa	24
3.3.3	Esineiden internet analytiikassa	26
3.3.4	Esineiden internet ja päälle puettavat laitteet	27
3.3.5	Teollinen esineiden internet (IIoT) ja älykäs valmistaminen	29
4.	Älykkäiden rakennuksien ennakoiva kunnossapito	31
4.1	Ennakoivan kunnossapidon hyötyjä ja haittoja	32
4.2	Ennakoivan kunnossapidon kustannukset ja säästöt	34
4.3	Ennakoivan kunnossapidon prosessi	36
4.4	Esimerkkejä ennakoivan kunnossapidon ratkaisuksista	39
4.4.1	Acme Industrial	39
4.4.2	SHM-platform ja älykäs sensori	43
4.4.3	SHM-datan keräys vapaaehtoisten avulla	45
4.4.4	Historiallisen rakennuksen SHM	46
4.4.5	Drone ja robotteja SHM:ssä	48
4.4.6	Tuuliturbiinien SHM	50
4.4.7	Ultraääniämittaava drone	51
4.4.8	SHM-visualisointikeinoja 3D:ssä	52
4.4.9	Pikainen visuaalinen tarkastus ortokuvista	54

4.4.10	Lastausten ja halkeamien paikantaminen betonirakenteesta	55
4.5	Esimerkkejä tekoälyä hyödyntävistä ennakoivan kunnossapidon ratkaisuista	56
4.5.1	Urheiluhallien SHM	56
4.5.2	Koneoppivien mallien testausta kiinteistöalalla	57
4.5.3	Betonihalkeamien tunnistaminen kuvasta neuroverkon avulla	57
4.5.4	Neuroverkot ja vähentävä klusterointi HVAC-järjestelmässä	60
4.5.5	Hajautetun vaurion havainnointijärjestelmä	62
4.5.6	Datapoikkeamien havainnointi neuroverkoilla	64
4.5.7	Padon muodonmuutosten ennustuskeinojen vertailu	66
4.5.8	Sijaismalli reaaliaikaista SHM diagnosointi- ja ennustusjärjestelmää varten	68
4.5.9	Energian kulutuksen arviointi tekoälyllä	69
5.	Lehto Asunnot Oy:n IoT-datan analyysi	71
5.1	Analyysi	72
5.1.1	Kerrokset	72
5.1.2	Tornit	79
5.1.3	Connectit	87
5.1.4	Mama	92
5.1.5	Poikkeuksia	95
5.1.6	Aikaero	96
5.2	Tekoäly –ja teknologiakartoitus	101
5.2.1	Lämpötilat suhteessa ulkoilman lämpötilaan	101
5.2.2	Riots-ratkaisut ja pilvipalveluteknologia	113
5.2.3	Yrityksen julkisen pilvipalvelun omaksumisaste	116
5.2.4	Tekoälyä hyödyntävä IoT-esimerkkitoteutus Googlen pilvipalvelulla	118
5.2.5	Julkisten pilvipalveluiden hinnoittelu	121
5.2.6	Asiantutijajärjestelmän edellytykset	122
6.	Suomen Yliopistokiinteistöjen datan analyysi	126
6.1	Kampusareena-kiinteistön esittely	126
6.2	VIRPA C- ja D-projektien esittely	127
6.3	SYKin IoT-alusta ja sensoriverkko	128
6.4	Mittausdata-aineiston esittely	130
6.5	SYK:n datan analysointi ja visualisointi	132
6.5.1	Datan visualisointi	132
6.5.2	Sääinformaation tarkastelu	141

6.5.3	Sisäilman suureiden ennustaminen	145
6.5.4	SYK:n dataa hyödyntäviä tekoälyratkaisuja CO2-pitoisuuden arviointiin	153
6.5.5	Käytöksen simulointi ja LSTM-neuroverkko	156
6.5.6	Tulokset ja päätelmät	159
7	Yhteenveto	162
	Lähteet	167

1. Johdanto

Tämän raportin tarkoituksena on tarkastella tekoälyn hyödyntämistä rakennusten ennakoivassa kunnossapidossa. Raportissa esitellään KIRA-digi –hanke ja kuvataan Jyväskylän yliopiston KIRA-digi –pilottihanke. Raportin alussa on tekoälyn kehityspolku ja menetelmiä koskeva luku, jossa määritellään tekoälyn käsite ja tekoälyn menetelmiä, kuten neuroverkot, kone- ja syväoppiminen. Kolmas luku koskee älykkäitä rakennuksia ja kaupunkeja sekä esineiden internetiä (IoT), sensoreita, analytiikkaa, päälle puettavia laitteita ja teollista esineiden internetiä (IIoT). Neljännessä raportin luvussa tarkastellaan rakennuksien ennakoivan kunnossapidon hyötyjä ja haittoja, kustannuksia ja säästöjä, prosessia ja annetaan esimerkkejä ennakoivan kunnossapidon ratkaisuksista. Viides luku on analyysiluku, jossa esitellään ja analysoidaan Lehto Asunnot Oy:n asunnoista kerättyä IoT-sensoridataa. Lisäksi luvussa on osana tekoäly- ja teknologiakartoitus, jossa käsitellään pilvipalveluteknologiaa, sen hinnoittelua ja tekoälyä hyödyntäviä ratkaisuehdotuksia Lehto Asunnot Oy:n tarpeisiin.

Tekoäly (engl. 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. Kehitysaskleet ovat peräisin ihmiselle luontaisesta halusta kehittää uusia ja parempia teknologioita, jotka mahdollistavat ihmiskunnan ylittämään sen fyysiset kyvyt. Lupaus tekoälyn käsitteestä on aina ollut horisontissa sekä reaali todellisuuden tiedemaailmassa, että fiktiossa elokuvien ja kirjallisuuden kautta. (Kannan, 2017.)

Tekoäly mahdollistaa suurten datamäärien varastoinnin sekä prosessoinnin älykkäällä tavalla ja se nimenomaan muuntaa relevanttia informaatiota funktionaaliksi työkaluiksi. Tekoälyä on käytetty hyvin monella sovellusalueella, joista tunnetuimpia kenties ovat puolustuksen (kyberturvallisuus) ja avaruuden tutkimuksen alueet, joissa menestys ongelmien ratkaisemisessa tietyillä osa-alueilla on ollut erinomaista. Tekoälyn sovellusalue on sittemmin laajentunut terveydenhuoltoon, jossa sitä hyödynnetään muun muassa diagnosoinnissa, hoitosuosituksen tekemisessä, leikkaushoidossa ja niin edelleen. (Kannan, 2017.) Uusiin tekoälyä hyödyntäviin aluevaltauksiin kuuluu myös tekoälyn ja sen menetelmien hyödyntäminen rakennusterveystarkastelun (Structural Health Management eli SHM) tutkimisessa, jossa tekoälyn avulla voidaan tehdä tulevaisuutta koskevia ennusteita ja siten säästää korjauskustannuksissa.

Rakennusten kunnonvalvonnan ja ylläpidon monitoroinnista on tullut nykypäivänä yhä tärkeämpää ja tehokkaiden menetelmien hyödyntämisestä yhä oleellisempää. Rakennusterveystarkastelu perustuu rakennuksen rakenteisiin ilmaantuneiden vahinkojen tunnistamiseen ja luokitteluun, jossa voidaan käyttää apuna erilaisia antureita. Rakennusterveystarkastelu voi ulottua aina urheiluhallien, siltojen, patojen jne. tarkastelusta kiinteistö rakennusten tarkasteluun saakka. Tekoäly voi tuoda tähän merkittävän edun, jossa

ennustavaa analytiikkaa hyödyntäen voidaan ennustaa tulevaisuuden korjaustarpeita tai ennakoida esimerkiksi asunnon lämmityksen noston tai laskemisen tarvetta asuntokohtaisesti. Tekoälyä hyödyntävän analytiikan ja älykkäiden sensorien keräämän sensoridataa (kuten esimerkiksi hiilidioksidi) hyödyntäen voidaan myös automaattisesti säätää ilmanvaihtoa oikealle tasolle ja siten parantaa ilmanlaatua sekä asumismukavuutta.

1.1 Yleistä KIRA-digi -hankkeesta

Rakennetun ympäristön ja rakentamisen digitalisaatio -hanke, KIRA-digi, toteutti julkisten palveluiden digitalisoimisen kärkihanketta. Vuoden 2018 loppuun kestänyt KIRA-digin rahoitus oli yhteensä noin 16 miljoonaa euroa, josta puolet maksoi valtio ja puolet kiinteistö- ja rakentamisala.

Hanketta toteuttivat yhdessä Kiinteistö- ja rakentamisfoorumi (KIRA-foorumi), kunnat ja ministeriöt. Sitä veti digipäällikkö ja strategisesta ohjauksesta vastasi johtoryhmä. Hankkeen johtoryhmään nimitettiin edustajat kiinteistö- ja rakentamisfoorumista, ympäristöministeriöstä, valtiovarainministeriöstä, liikenne- ja viestintäministeriöstä, opetus- ja kulttuuriministeriöstä, Rakennustietosäätiöstä, Turun kaupungin kiinteistöliikennelaitoksesta, Espoon kaupungilta, Suomen Kuntaliitosta, Suomen ympäristökeskuksesta sekä Museovirastosta. Hankkeen vastuuministerinä oli ympäristöministeriö. Hankkeen käytännön toteutusta ohjasi 7 -henkinen ohjausryhmä, jossa oli edustajia ympäristöministeriöstä, valtiovarainministeriöstä, kuntaliitosta ja KIRA-alan järjestöistä. Ohjausryhmää veti erityisasiantuntija Minna Perähuhta ympäristöministeriön Rakennetun ympäristön osastolta.

KIRA -foorumin muodostivat neljätoista yhteisöä: Arkkitehtitoimistojen liitto ATL ry, Kiinteistöväälitysalan Keskusliitto KVKL ry, Kiinteistötyönantajat ry, Rakennusmestarit ja -insinöörit AMK RKL ry, Rakennusteollisuus RT ry, Rakennustietosäätiö RTS, RAKLI ry, Suomen Arkkitehtiliitto SAFA, Suomen Isännöintiliitto ry, Suomen Kiinteistöliitto ry, Suomen Rakennusinsinöörien Liitto RIL ry, Suunnittelu- ja konsultointiyrietykset SKOL ry, Sähkö- ja teleurakoitsijaliitto STUL ry ja Talotekniikkateollisuus ry.

KIRA-digi-hankkeen tavoitteena oli:

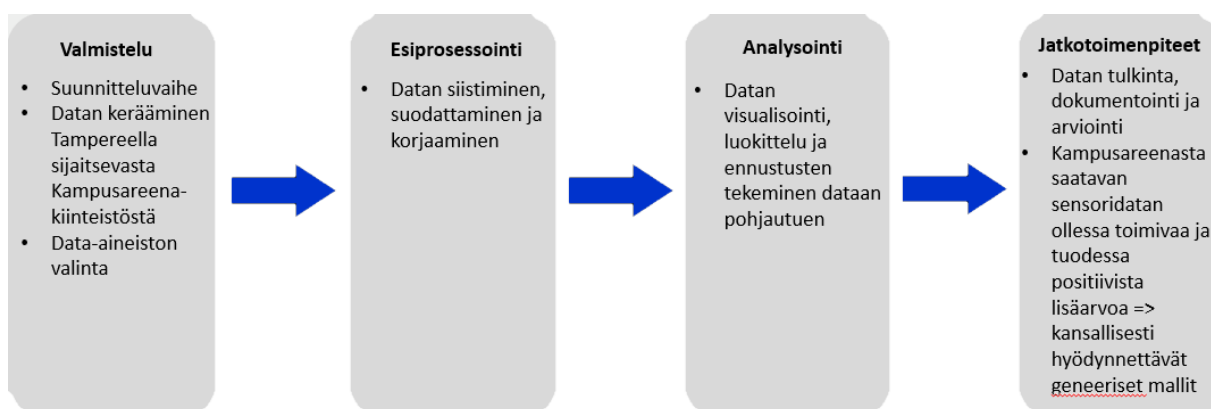
- Yhteen toimivuuden eri elementtien laajaa käyttöönotto alueiden käytön suunnittelun ja rakentamisen toimialalla ja siten eri tietoaaineistojen keskinäisten yhteyksien merkittävä lisääminen.
- Ratkaisujen kehittäminen suunnittelun ja rakentamisen sekä toisaalta rakennusaikaisen ja käytön aikaisen tiedon välittymisen nivelvaiheisiin ja siten keskeisten alan toimintatapojen muutoksen vauhdittaminen.
- Erilaisten mallien ja kehittämisspolkujen testaaminen ja kokeilut sekä standardien ratkaisujen sovittaminen käytäntöön.

- Yhtenäinen tietoaaineisto tukemaan tiedon teknistä ja semanttista yhteen toimivuutta sekä rakennetun ympäristön koko elinkaarta koskevien prosessien ja ajantasaisten tietojen jatkuvaa käytettävyyttä.
- Tiedon koneluettavuus tärkeimpien prosessien sisällä.
- Säädöspohjan varmistaminen rakennetun ympäristön prosessien ja tietojen yhteen toimivuudelle sekä toimialan digitalisaatiota hidastavien säädösten tunnistaminen ja karsiminen.
- Toimijoiden osaamisen (awareness) sekä toimialan prosessien ja ohjausmekanismien laajentaminen syntysähköisiin/digitaalisiin aineistoihin.

1.2 Jyväskylän yliopiston KIRA-digi -pilottihankkeen kuvaus

Jyväskylän yliopiston KIRA-digi-hankkeen tarkoituksena oli tutkia, kuinka tekoälypohjaisilla ennustemenetelmillä voidaan saada lisätietoa rakennusten ennakoivasta kunnossapidosta. Mikäli datan kerääminen ja analysointi onnistuvat tarkoituksenmukaisella tavalla, voidaan kansallisella tasolla etsiä geneerisiä menetelmiä kunnossapito-ongelman ratkaisemiseksi.

KIRA-digi-hankkeen aikana Jyväskylän yliopisto toteutti analyysejä Suomen Yliopistokiinteistölle (SYK) ja Lehto Asunnot Oy:lle. Jyväskylän yliopiston ja SYK:n yhteistyössä analysoitiin Tampereen Kampusareenasta kerättyä IoT-sensoridataa (KUVIO 56), kuten ilmanpaine, ilmankosteus, lämpötila, melu ja liiketunnistus. Hankkeessa oli alustavasti tarkoituksena analysoida myös Jyväskylässä sijaitsevan Ruusupuiston ja Tampereella sijaitsevan Medisiina D:n dataa ennakoivan kunnossapidon kannalta, tosin hankkeessa keskityttiin Kampusareenan datan analysointiin. Kampusareenan data oli hyödynnettävissä Polku Innovation Virpa C –projektin yhteydessä kehitetyn ”SYK:n avoimen IoT –alustan” ja Siemensin kanssa tehtyjen sopimusten ansiosta.



KUVIO 1. SYK:n datan analysointiprosessin vaiheet

KIRA-digi –hankkeen aikana toteutettiin myös analyysijä sekä toteutettiin tekoäly- ja teknologiakartoitus Lehto Asunnot Oy:lle. Datan analysoinnit perustuivat Lehdon toimittamiin lämpötila, ilmankosteus ja hiilidioksidimittauksiin. Mittaustuloksia täydennettiin ilmatieteen laitoksen (FMI.fi) keräämillä mittauksilla, kuten ulkoilman lämpötila ja ulkoilman suhteellinen ilmankosteus, jolloin muun muassa asuntojen lämpötilojen keskiarvoja suhteessa ulkoilman lämpötilaan voitiin vertailla. Analyysiosuus on jaettu osuuksiin, kuten kerrokset, tornit, connectit, Mama, lämpötilat suhteessa ulkoilman lämpötilaan, poikkeukset ja aikaero.


Lehto Asunto Oy:n analyysiosuudessa on analysoitu lisäksi tekoälyratkaisuja ja teknologiaa, jonka avulla tekoälyä hyödyntäviä ratkaisuja voitaisiin toteuttaa Lehto Asunto Oy:n rakennuttamiin kiinteistöihin. Soveltuvan tekoälyä hyödyntävän mallin avulla voidaan Lehto Asunto Oy:n tapauksessa esimerkiksi automaattisesti nostaa tai laskea kylpyhuoneen lattialämmitystä (tai muuta älykästä lämmityslaitetta) tilanteissa, joissa ulkoilman ja siitä johtuen huoneiston lämpötila laskee tai nousee. Tekoälyn hyödyntämistä ennustavan analytiikan mallin muodostuksessa voidaan käyttää myös esimerkiksi ilmastoinnin tai korjausilmaa tuovien venttiilien säätämisessä, joka parantaa asumismukavuutta.

Datan kerääminen, tallentaminen, tietoturva ja ennustava analytiikka vaativat resursseja, jolloin kysymyksiä herättävät: mihin data tallennetaan/varastoidaan, tarvittavat laskentaa vaativat resurssit tekoälyn hyödyntämiseksi ja miten paljon kuluja tästä aiheutuu sekä lisäksi onko data tallennettuna tietoturvallisesti, jotta sen joutuminen väärin käsiin voidaan estää. Asunnoista mitatun datan tallentaminen keskitetysti pilvipalveluihin rakennettuun tietovarastoon aiheuttaa epäilyksiä tietoturvallisuudesta, jolloin hyökkäys esimerkiksi pilvipalvelun rajapintojen kautta voi aiheuttaa merkittävän uhan. Pilvipalvelut ja ratkaisujen toteuttaminen tuovat mukanaan uudenlaisen hyökkäysvektorin muodostumisen kyberhyökkäyksiin.

2. Tekoälyn kehityspolku ja menetelmiä

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

KUVIO:sta 2 havainnollistuu tekoälyn kehityskulku, joka alkoi 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 käyttää tilastollisia teknologioita, jotka mahdollistavat koneiden oppivan kokemuksista. Kattegoria sisältää myös syväoppimisen. Syväoppiminen on koneoppimisen osa-alue muodostuen algoritmeista, jotka mahdollistavat ohjelmiston itseoppimisen tehtävien suorittamiseksi, kuten puhe, kuvantunnistus jne. käyttämällä hyväksi neuroverkkoja suuren datamäärän käsittelemiseksi. (Parloff, 2016; Copeland, 2016.)



KUVIO 2. Kehityskulku tekoälystä syväoppimiseen (Copeland, 2016)

Nykyään tekoäly on kaikkialla ympärillämme ja suuret yritykset, kuten 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 päätöksiä siitä, mitä asiakkaat haluavat katsoa tai voivat haluta ostaa seuraavaksi jne. Kone- ja syväoppimisen

menetelmien hyödyntäminen tekoälyn kehittämiseksi on tuottanut lupaavia tuloksia ja niiden idea on periaatteessa yksinkertainen. Traditionaalisen tietokoneiden ohjelmoinnin ja älykkääksi tekemisen yrittämisen sijasta tietokoneelle annetaan pääsy laajaan datamäärään ja ne ohjelmoidaan löytämään malleja sekä oppimaan itsenäisesti, miten vaadittu tehtävä suoritetaan. (Buczowski, 2017.)

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 ja maailmalla oleviin lääketieteellisiin tutkimuksiin, auttaa lääkäreitä tekemään oikeita potilaille personoituja hoitosuunnitelmia suhteellisen paljon pienemmällä vaivalla, mikä on aiemmin ollut mahdollista. (Weber, 2015.)

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

2.1 Tekoälyn määritelmä

Tekoäly voidaan nähdä keinotekoisena älykkyytenä, jonka avulla voidaan ratkaista monimutkaisia ongelmia kyseisen järjestelmän ollessa tietokone tai kone. Tekoäly on tietotekniikan ja fysiologisen älykkyyden yhdistelmä, jonka avulla voidaan laskennallisesti päästä tavoitteisiin. Älykkyyys on kyky ajatella luomalla muistia ja ymmärrystä, tunnistamalla malleja, tekemällä muutokseen sopeutuvia valintoja ja oppimalla kokemuksista. Tekoäly voi saada koneet käyttäytymään, kuten ihmiset, mutta paljon vähemmällä ajalla, mitä ihmiset käyttäisivät jonkin tietyn asian ratkaisemiseen. (Borana, 2016.)

Tekoälyn juuret ovat pitkälti useilla eri tiedonaloilla, kuten:

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

Tekoäly alkoi kehittyä Turingin koneesta, jolla mitattiin koneen kykyä älykkääseen käyttöön. Turingin koneen esitteli Alan Turing julkaisussaan: ”Computing Machinery and Intelligence”. Testin peruskysymyksenä on: ”Voivatko koneet ajatella?”. Testissä asetelmana on kuulusteleva ihminen ja toisella puolella tietokone ja toinen ihminen, joita kuulustelija ei voi nähdä. Keskustelu käydään luonnollisella kielellä ja mikäli kuulustelija ei voi luotettavasti todentaa, onko kuulusteltava ihminen vai kone, kone on läpäissyt testin. Testi tehdään tekstimuodossa, jotta puheesta ei voi päätellä, kummasta on kyse. (Borana, 2016.)

Tekoäly voidaan jakaa esimerkiksi seuraavalla tavalla sovellusalueisiin:

1. Kognitiivisen tieteen sovellukset
2. Robotiikan sovellukset
3. Luonnollisen kielen sovellukset

2.2 Tekoälyn menetelmiä

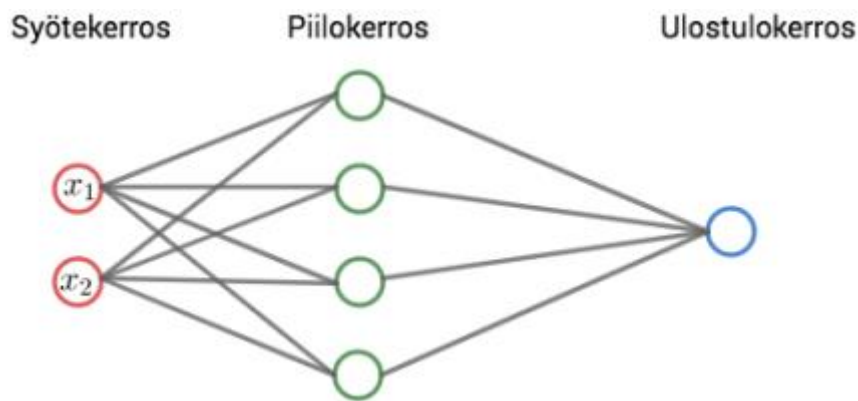
2.2.1 Neuroverkot

Ihmisen aivojen toimintaa jäljittelevät keinotekoiset neuroverkot keksittiin jo toisen maailmansodan jälkeen. Neuroverkkojen uusi aalto alkoi 1990-luvulla, mutta niiden käyttöönoton into hiipui nopeasti siihen, että ne eivät olleet muita menetelmiä parempia ja silloisilla tietokoneilla ei ollut mahdollisuutta käsitellä neuroverkkojen koulutuksessa tarvittavia suuria datamääriä. Neuroverkkoja käytetään esimerkiksi kuvantunnistuksessa, konenäössä, puheentunnistuksessa, kielenkääntäjissä, peleissä ja lääketieteellisessä diagnostiikassa.

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). Neuroverkot voidaan nähdä yhdistävään laskentaan perustuvina matemaattisina laskennallisina malleina, jotka hyödyntävät informaation käsittelyä.

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

Keinotekoiset neuroverkot koostuvat useista solmuista, jotka jäljittelevät ihmisaivojen biologisia neuroneita. Neuronit ovat yhdistetty toisiinsa linkkien kautta ja ne ovat vuorovaikutuksessa toistensa kanssa. Solmut voivat vastaanottaa yksinkertaista syöttödataa ja ne voivat suorittaa yksinkertaisia operaatioita datalla. Kyseisten operaatioiden tulokset välitetään toisille neuroneille ja jokaisen solmun ulostuloa kutsutaan solmun arvoksi. Jokaiseen linkkiin liittyy painokerroin ja sen muutos vaikuttaa keinotekoisien neuroverkkojen kykyyn oppia. (Tutorialspoint, 2017.) KUVIO:sta 3 havainnollistuu yksinkertainen keinotekoinen neuroverkko.




KUVIO 3. Yksinkertainen keinotekoinen neuroverkko

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


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

Kuten edellä mainittiin, keinotekoisia neuroverkkoja on kahta tyyppiä: Eteenpäin syöttävä eli Feed Forward (KUVIO 4) ja takaisinkytketty (KUVIO 5) eli Feedback neuroverkko. Eteenpäin syöttävässä verkossa informaation virta on yksisuuntaista ja yksikkö lähettää informaatiota toiselle yksikölle, jolta se ei vastaanota yhtään informaatiota. Eteenpäin syöttävässä neuroverkossa ei ole paluusiilmukkaa. Tätä neuroverkkotyyppiä käytetään mallien

generointiin, tunnistamiseen ja luokitteluun. Niillä on kiinteä syöttö ja ulostulo. Takaisinkytkettyjä neuroverkkoja käytetään esimerkiksi CAM (Content Addressable Memory) -muistien yhteydessä. (Tutorialspoint, 2017.)




KUVIO 4. Eteenpäin syöttävä neuroverkko (Tutorialspoint, 2017)



KUVIO 5. Takaisinkytketty neuroverkko (Tutorialspoint, 2017)


Autoenkooderi (KUVIO 6) on neuroverkko ja samanaikaisesti myös ohjaamattoman oppimisen algoritmi. Autoenkooderi hyödyntää vastavirta-algoritmia asettamalla tavoitearvon samaksi kuin syötearvo koettaen ennustaa x :ää x :stä ilman luokittelijan apua. Autoenkooderin keskustassa on kapea piilokerros (h), joka on enkooderin ja dekodlerin välissä. Keskellä oleva piilokerros on tiivistetty esitys (latentti tila) syötekerroksen datasta. Enkooderit ja dekodderit ovat eteenpäin syöttäviä neuroverkkoja. Enkooderia voidaan kuvata funktiolla $h = f(x)$, dekodderia $r = g(h)$ ja koko autoenkooderia funktiolla $g(f(x)) = r$, jossa r :n on tarkoitus olla mahdollisimman lähellä x :n arvoa. Verkkoa opetetaan minimoimalla erot syöte- ja ulostulokerroksen välillä. Mikäli syötteenä oleva data on täysin satunnaista, on tiivistäminen haastavaa. (Chandradevan, 2017.)



KUVIO 6. Autoenkooderin arkkitehtuurikaavio (Hubens, 2018)

Autoenkooderien avulla voidaan tunnistaa myös anomaliaita eli poikkeamia suuresta joukosta normaalia toimintaa. Prosessi voidaan toteuttaa esimerkiksi autoenkooderin avulla, mallintamalla normaali data/signaali ja rakentamalla se uudelleen malliin perustuen. Tämän jälkeen syntetisoitua ja oikeaa signaalia voidaan verrata keskenään ja mikäli ero ylittää raja-arvon, voidaan signaalista havaita poikkeavuuksia. Autoenkooderi ei kuitenkaan ole ainoa anomalioiden tunnistamiseen soveltuva tekniikka, vaan myös muita algoritmeja, kuten Isolation Forest, Gaussin jakaumaa hyödyntävä EllipticEnvelope ja K-lähimmän naapurin algoritmiin perustuva LocalOutlierFactor voidaan hyödyntää tässä tarkoituksessa. (Pedregosa ym., 2011, 2825.)

Anomalioiden tutkimisen lisäksi autoenkooderien avulla voidaan esimerkiksi värittää kuvassa olevia osa-alueita (KUVIO 7) tai koko kuva, lisätä pikseleitä kuvaan tai poistaa kuvasta esimerkiksi kohinaa. Autoenkooderien avulla voidaan myös datan visualisoinnin yhteydessä vähentää ulottuvuuksia (dimensioita), hyödyntää uudenlaisten ominaisuuksien opiskelemisessä tai luokittelussa. Autoenkooderit eivät kuitenkaan suoriudu kovin hyvin kuvan pakkauksesta, sillä autoenkooderit on opetettu tietyllä datasetillä, jolloin se kykenee tuottamaan kohtuullisia tuloksia samankaltaisilla dataseteillä, mutta suoriutuu heikosti monikäyttöisenä kuvanpakkaajana. (Hubens, 2018.)



KUVIO 7. Verkkotason esitys autoenkooderi-neuroverkosta (Chandradevan, 2017)

Back Propagation (BP) eli vastavirta-algoritmiin perustuva neuroverkko on amerikkalaisten vuonna 1986 julkaisema menetelmä, jonka vahvin etu on sen lähtöfunktion jatkuvuus BP:ssä. BP:ssä ihmisen tuottamaa tietoa on vaikea yhdistää neuroverkon informaatioon, joka laskee BP:n käyttöarvoa. BP-verkon topologiaa määritettäessä 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, 553.)

Koneoppimisessa konvoluutioneuroverkot (Convolutional Neural Network eli CNN) ovat tyypiltään monikerroksisia eteenpäin syöttäviä eli Feed Forward keinotekoisia neuroverkkoja, jotka 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. CNN-verkkojen 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.)

Konvoluutioverkot käyttävät hyväkseen konvoluutiokerroksia, jotka suodattavat sisääntulon dataa hyödylliseksi informaatioksi. Näillä konvoluutiokerroksilla on parametreja, jotka on opetettu niin, että ne suodattavat automaattisesti hyödyllisimmän informaation valitun tehtävän suorittamiseksi. Joissain tapauksissa voi olla hyödyllistä suodattaa informaatiota objektin muodosta (objekteilla useimmiten on eri muotoja). Esimerkiksi linnun tunnistamistehtävässä voi olla sopivinta poimia tietoa linnun väristä, sillä useimmilla linnuilla on samankaltainen muoto, mutta ei väriä. Konvoluutioverkot mukautuvat automaattisesti löytämään parhaat ominaisuudet tehtävän suorittamiseksi. (Dettmers, 2015.)


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

CNN-neuroverkon opettamisessa on useita eri vaihtoehtoja. Työläin on verkon opettaminen alusta alkaen, jolloin on tarpeen olla suuri määrä dataa, 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 se vaatii huomattavia määriä dataa (esimerkiksi kuvia) ja merkittävää laskentakykyä. Toinen vaihtoehto on niin sanotun opitun siirtäminen toiseen tarkoitukseen. CNN-neuroverkko voi olla opetettu esimerkiksi datalla, joka koostuu kissojen ja koirien kuvista. Verkon painoja voidaan hienosäätää ja saada se tunnistamaan esimerkiksi haluttuja auton malleja ja tyyppjä. Tämä menetelmä vaatii huomattavasti vähemmän dataa ja laskentaresursseja. Kolmannessa vaihtoehdossa voidaan käyttää aiemmin opetettua CNN-neuroverkkoa, jonka avulla voidaan hyödyntää sen ominaisuuksia opettaessa koneoppimisen mallia, kuten tukivektorikone (Support Vector Machine eli SVM), päätöspuu (Decision Tree) jne. Tämä menetelmä vaatii vähiten uutta dataa ja laskennallisia resursseja. (Patel & Pingel, 2017.)

DNN-verkot (KUVIO 8) eli syvät neuroverkot ovat joustavia monikerrosjärjestelmiä, jotka koostuvat toisiinsa yhteydessä olevista ja interaktiivisista keinotekoisista neuroneista, jotka suorittavat erilaisia datan muunnoksia. Syvät neuroverkot eroavat tavanomaisemmista yhden piilokerroksen neuroverkoista syvyydeltään. Syvissä neuroverkoissa on enemmän kuin yksi solmukerros (node layer), jonka läpi data kulkee moniosaisen prosessin aikana ja jotka mahdollistavat datan abstraktiotasojen järjestelemisen. Syvien neuroverkkojen tavoitteena on jäljitellä ihmisten aivojen rakennetta, joissa verkko koostuu suurista määrästä synapseja ja neuroneita. Neuronit toimivat siten, että ne vastaanottavat syötteen, prosessoivat sen ja lähettävät eteenpäin seuraavalle vuorossa olevalle neuronille.


Kuvantunnistuksessa neuroni kykenee esimerkiksi tunnistamaan, minkä värinen pikseli on. Neuronikerroksia lisättäessä muodostuu syviä neuroverkkoja, joissa jokaisella tasolla on oma tehtävänsä. Tätä seuraavat tasot tunnistavat muotoja, ääriivivoja ja lopuksi esineitä ja asioita. Abstraktion taso lisääntyy edetessä viimeisille tasoille verkossa. Syvät neuroverkot ovat keskeisiä fysiikassa, signaalinkäsittelyssä sekä kuvien, videoiden, tekstien louhinnassa ja tunnistuksessa parantaen suorituskykyä yli 30 % aiempiin menetelmiin verrattaessa. (Aliper ym., 2016.)



KUVIO 8. Yksinkertainen keinotekoinen neuroverkko

ELM-neuroverkot (Extreme Learning Machine eli ELM) on erittäin nopea oppimismenetelmä ja se tarjoaa tehokkaan välineen hahmontunnistukseen. ELM-verkot (KUVIO 9) ovat laajennus traditionaaliseen yhden piilokerroksen sisältävän eteenpäin syöttävän SLFN-neuroverkkoon (single-hidden layer feedforward neural network), jossa piilokerroksen parametrit generoidaan etukäteen satunnaisesti ja ainoastaan ulostulon neuroneiden painokertoimet ovat tarpeen laskea ennalta optimaalisesti pienemmän neliösumman menetelmällä. Tällöin on mahdollista saavuttaa parempi yleistettävyyys suuremmalla tarkkuudella. (Zhang ym., 2017, 1.) Verkko voidaan muodostaa hyvin pienin askelin ja laskennallisista kustannuksista. ELM-neuroverkot voidaan tulkita verkon approksimaatioksi, jossa on ääretön määrä piilokerroksen yksiköitä eli neuroneita. (Parviainen ym., 2010.)

ELM on erittäin nopea ja simulaatioissa ELM-neuroverkkojen oppimisvaihe on mahdollista toteuttaa vain sekunneissa useimmissa sovelluksissa. Tavanomaisien eteenpäin syöttävien neuroverkkojen opettaminen kestää huomattavasti pidempään jopa yksinkertaisissa sovelluksissa. Lisäksi ELM-verkot tuottavat parempaa tulosta kuin gradienttimenetelmään perustuva oppiminen, jota hyödynnetään muun muassa vastavirta (Back Propagation) – algoritmissa useimmissa tapauksissa. ELM-verkkojen oppimisalgoritmi on huomattavasti eteenpäin syöttävien neuroverkkojen oppimisalgoritmia yksinkertaisempi ja se toimii myös differentioitumattomien funktioiden aktivaatiofunktioiden kanssa. (Putra ym., 2015.)



KUVIO 9. Yksinkertainen keinotekoinen neuroverkko (Zhang ym., 2017, 1)

Neuroverkkojen kehitys on ajan myötä mahdollistanut aina uudempia ja kehittyneempiä verkkoja. 1950-luvulla pystyttiin mallintamaan vaatimattomia neuroverkkoja, jotka olivat sienieläinten tasolla ja niissä neuronien lukumäärä oli 10^{-2} . Vuonna 2017 pystyttiin 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. (Goodfellow, 2016, 22.)

2.2.2 Koneoppiminen

Koneoppiminen on tekoälyn osa-alue ja data-analyysimetodi, joka automatisoi analyyttistä mallin rakentamista. Käyttämällä algoritmeja, jotka iteratiivisesti oppivat käyttämällä dataa, koneoppiminen tarjoaa tietokoneille mahdollisuuden löytää piilossa olevia 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 ne ovat:

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

Ohjatussa oppimisessa konetta opetetaan luokitellun aineiston avulla ja pyritään siihen, että kone osaa tehdä halutun luokittelun samankaltaiselle aineistolle. Klassinen esimerkki ohjatusta oppimisesta on käsinkirjoitettujen numeroiden tunnistus. 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 itseorganisoiuva kartta, jonka sovelluksia on käytetty tuhansissa julkaisussa. Kolmas oppimisen tyyppi on vahvistettu oppiminen, jossa kone oppii ympäristön antaman palautteen perusteella. Käytetään mitä tahansa oppimismenetelmää, niin tekoälystä on hyötyä vasta sitten, kun opettaminen on hoidettu hyvin. (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 datassa olevien poikkeavuuksien korjaaminen. Tutkiva analyysi on yksi menetelmistä datan vivahteiden sekä yksityiskohtien tutkimiseen.
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. Tämän vuoksi on käytettävä aikaa merkittävästi datan keräämiseen ja valmisteleminen.

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

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

Koneoppimista käytetään useilla eri sektoreilla, kuten finanssipalvelut, hallitusten toiminnot, terveydenhuolto, markkinointi ja myynti, öljy- ja kaasuteollisuus, kuljetusala jne. Ehkä kuitenkin tunnetuimpia koneoppimisen käyttötavoista nykypäivänä on mallien tunnistaminen (Pattern Recognition), koska sen avulla voidaan tunnistaa useita eri tyyppisiä kuvia. Esimerkiksi USA:n posti käyttää koneoppimista tunnistamaan käsialakirjoitusta. (SAS; Sarkar, 2016.)

2.2.3 Syväoppiminen

Syväoppiminen (Deep Learning) on koneoppimisen osa-alue, joka alkoi kehittyä vuodesta 2006 ja se on noussut pinnalle yhä enemmän vuoden 2012 jälkeen. Kyseisellä osa-alueella käytetään useita epälineaarisia informaation prosessoinnin tasoja ja hierakkisia arkkitehtuureita. Syväoppimisen tavoitteena on luoda sopivaa syväoppimisen algoritmia käyttäen neuroverkkoa, joka tähtää soveltuvan ongelman ratkaisemiseen. Ongelmia, joiden ratkaisemiseen syväoppimista käytetään, ovat perinteisiä menetelmiä käyttäen vaikeita toteuttaa, sillä ne vaativat monimutkaisten sääntöjen käyttöä. Syväoppimisen hyödyntämisen alueita ovat muun muassa lääketieteen diagnostiikka, puhe, kuvat, tekstien tunnistaminen ja käsittely. Monelle tunnetuimpia hyödyntämisen alueita ovat puheentunnistus, kuten Applen Siri ja Googlen Street View-karttapalvelu. (Tjoa, 2013, 3 - 4; Jagreet, 2017.)

Syväoppiminen Akagin (2014) mukaan:

- On kokoelma tilastollisia koneoppimisen teknologioita
- On toimintahierarkioiden oppimiseen käytetty työkalu
- Perustuu keinotekoisiiin neuroverkkoihin

Syväoppimisen algoritmien suorituskykyä voidaan parantaa muun muassa:

- Lisäämällä dataa
- Tuottamalla/generoimalla lisää dataa
- Dataa uudelleen skaalaamalla
- Dataa muuntamalla

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

Syväoppiminen voidaan nähdä koneoppimisen algoritmien haarana perustuen useiden eri tasojen kykyyn oppia, jotka samanaikaisesti vastaavat useita eri abstraktiotasoja. Tekoäly on ajan saatossa kehittynyt sääntöpohjaisista järjestelmistä koneoppimisen kautta syväoppimiseen saakka. Sääntöpohjaiset järjestelmät ovat soveltuvia ohjelmointialgoritmeja, jotka noudattavat toteutettuja tekoälyohjelmia. Ohjelmien vaatiman tietämyksen tuottavat kyseiseen alaan perehtyneet asiantuntijat, jonka vuoksi sääntöpohjaisia järjestelmiä kutsutaan asiantuntijajärjestelmiksi. Kyseiset järjestelmät sisältävät faktoja ja logiikkaa, jotka yhdistävät faktat kysymyksiin vastaamiseksi. Klassisessa koneoppimisessa syötteenä tulevat ominaisuudet suunnitellaan manuaalisesti ja järjestelmä automaattisesti oppii hyödyntämään niitä ulostuloihin. Tämänkaltainen koneoppiminen toimii hyvin yhden mallin (single pattern) tunnistamisen ongelmissa. Tiedossa on, että käytännössä suurin osa ajasta siinä kuluu optimaalisten ominaisuuksien suunnitteluun. Ominaisuuksien suunnittelun jälkeen voidaan käyttää geneeristä 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 pystytään 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 abstraktion 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. (Goodfellow, 2016.)

3. Älykkäät rakennukset ja kaupungit

Yhdistyneiden kansakuntien vuoden 2014 raportin mukaan 54 % maailman populaatiosta asuu kaupunkialueilla ja määrän on ennustettu kasvavan 66 %:n vuoteen 2050 mennessä. Nopea kaupungistuminen tuo kuitenkin mukanaan useita erilaisia kestävän kehityksen haasteita. Kaupunkiväestön osuus energiankulutuksesta on 80 prosenttia, hiilidioksidipäästöistä 75 prosenttia ja maailman luonnonvarojen kulutuksesta 75 prosenttia. Samanaikaisesti yli 80 % bruttokansantuotteesta tuotetaan kaupungeissa. Kuitenkin, kaupungit tarjoavat useita sosioekonomisia hyötyjä ja niistä on tullut tutkimuksen ja koulutuksen keskuksia. (Zvolska, Lehner, Palgan, Mont & Plepys, 2018.)

Viime aikoina on syntynyt kaupunkien kestävän kehityksen haasteiden ratkaisemiseen käsite, joka tunnetaan älykkäänä kaupunkina. Älykäs kaupunki on yhä varsin nuori käsite ja se tuli tunnetuksi vuonna 1993, jolloin Singapore julkisti olevansa ”älykäs kaupunki”. Vuonna 2007 Giffinger julkaisi dokumentin, jossa esiteltiin yksi ensimmäisistä älykkään kaupungin määritelmistä, jona se voidaan ymmärtää nykypäivänä. Kirjoittajat esittävät älykkään kaupungin kaupunkina, joka aktiivisesti toimii niin teollisuuden kuin teknisen infrastruktuurin alueilla yhdistämällä ne älykkäillä tavoilla palvelemaan kansalaisia. 2010-luvulla kiinnostus älykästä kaupunkia kohtaan alkoi kasvaa, jolloin myös tavat määritellä älykäs kaupunki kasvoivat. Älykäs kaupunki ei ole vain pelkästään kaupunki, vaan se käsittää useita alueita asukkaiden jokapäiväisessä elämässä. (Chamoso, Gonzales-Briones, Rodriguez & Corchado, 2018.)

Väestön keskittyminen kaupunkien alueille on rohkaistut johtajia tukemaan digitaalista ja informaatioteknologiaa hyödyntävien älykkäiden kaupunkien kehittämistä, mitkä osaltaan auttavat tekemään kaupunkialueista yhtä elävämpiä, ketterämpiä ja kestävämpiä. Kaupunkien voidakseen olla älykkäitä, niiden on hyödynnettävä erilaisia sensoreita, langatonta tietojenkäsittelyä, sosiaalista mediaa, nopeita tietoliikenneverkkoja ja älykkäitä digitaalisia alustaratkaisuja. Ensimmäisiä älykaupunkiteknoologioita ovat omaksuneet alat, kuten kuljetus- ja logistiikka, paikallisten hallitusten palvelut, terveydenhuolto ja koulutus. (Lorica, 2015.)

3.1 Älykkäät rakennukset ja niiden määritelmä

Kyber-fyysinen-systeemi (”cyber-physical system”, CPS) kuvaa järjestelmää, joka kerää tietoa maailmasta fyysisten toimijoidensa avulla ja pystyy muuttamaan toimintaansa automaattisesti käsittelemänsä datan perusteelta sekä muuttamaan tai korjaamaan fyysisten osiensa toimintaa laskettujen ennusteiden pohjalta. (Jiang, 2018, 1.) Abaten, Budden, Cauchin, Hoquen ja Stoelingan mukaan, jotka julkaisivat artikkelinsa julkaisussa Proceedings of the European Conference of the PHM Society, CPS-järjestelmän on oltava luotettava,

käytettävissä, huollettavissa ja täytettävä turvallisuusvaatimukset ja –standardit. (Abate, Budde, Cauchi, Hoque & Stoelinga, 2018, 1.)

Älykäs rakennus on CPS –järjestelmä, jossa rakennukseen asennetut sensorit mittaavat automaattisesti älyrakennuksen käyttöä, rakennuksen toimintaa ja tilaa kuvaavia suureita (Legatiuk & Smarsly, 2018, 1). Näiden pohjalta rakennuksen energiankulutusta, sähkönkulutusta, sisälämpötilaa, kosteutta ja vedenkäyttöä sekä muita rakennuksen ja laitteiden toimintaan vaikuttavia suureita seurataan ja toimijoilla säädellään automaattisesti laskettujen ennusteiden perusteelta rakennuksen korkeatasoisen toimintakyvyn ylläpitämiseksi. Ennusteisiin vaikuttavat rakennuksen käyttöaste ja käyttäjien preferenssit, paikallisen ilmaston hetkittäiset sääolot ja rakennuksen sisäilmasto sekä fyysisten todellisten mittausten lisäksi virtuaaliset mallit, jotka voivat olla tekoälypohjaisia tai perustua FE-malleihin. Älykkään rakennuksen tarkoitus on tarjota turvaa, viihtyisyyttä ja virikkeitä käyttäjilleen mahdollisimman pienellä energiankulutuksella koko elinkaarensa ajan.

Älykkään rakennuksen ei tarvitse mitata kaikkea edellä mainittua ollakseen älykäs. Tyypillisesti riittää, että se on rakennettu ekologisesti vihreistä materiaaleista ja kykenee sensoreidensa avulla mittaamaan joitakin edellä mainittuja suureita. Sen myötä niiden energian kulutus on matala. IoT-laitteiston avulla rakennukseen on mahdollista lisätä älykkyyttä esimerkiksi automaattisen valaistuksen ja lämmityksen avulla. Näin rakennus voi vähentää energiankulutustaan pitkällä aikavälillä samalla lisäten ihmisten viihtyvyyttä.

Virtuaaliset mallit sisältävät useampia tietokoneella toteutettavia malleja, joilla ilmaistaan ja simuloidaan rakennuksen toimintaa käytön aikana. FE-malli (Finite Element, FE) tarkoittaa kappaleesta tehtyä yksinkertaistettua diskreettiä numeerista mallia, jonka avulla voi tarkastella kappaleen käytöstä erinäisten simuloitujen fyysisten voimien vaikutuksen alaisena (Petru, Novak, Herak & Simanjuntak, 2012, 413). Digitaalinen kaksonen (Digital twin, DT) on korkeatasoinen simuloitu visuaalinen malli, joka vastaa fyysistä esinettä, rakennusta tai rakennelmaa. Sitä käytetään kappaleen käyttäytymisen tarkasteluun ja testaukseen sekä suunnittelun ja valmistuksen optimointiin. (Qi, Tao, Zuo & Zhao, 2018, 237.)

3.2 Älykkäät kaupungit ja hankkeet

Ei ole olemassa mitään tiettyä käännekohtaa, jonka jälkeen informaatioteknologiaa hyödyntävää kaupunkia voidaan kutsua ”älykkääksi”. Kuitenkin on olemassa ratkaisuja, jotka voivat parantaa kaupunkien suorituskykyä ja infrastruktuurin hallintaa, jolloin ne kykenevät toimimaan hyvin. Älykaupunki voidaan katsoa olevan älykäs ympäristö. ”Älykkääseen ympäristöön on yhdistynyt pieni maailma, jossa esineet ovat toisiinsa yhteydessä sensoreiden avulla ja ne tekevät yhteistyötä ihmisten viihtyvyyden vuoksi.” (Ahmed, Yaqoob, Gani, Imran & Guizani, 2016, 1.) Älykkäissä kaupungeissa (KUVIO 10) on tärkeä kiinnittää huomiota asioihin, kuten energia, kuljetus, turvallisuus, jäte ja vesi. Edellä mainitut asiat voidaan

toteuttaa hyödyntäen älykkäitä ratkaisuja, jolloin ne yhdessä tekevät kaupungista älykkään. (Ramachandran, 2019, 3.)

Älykaupunki muodostuu älykkäistä palveluista (kuten koulutuksesta, hallinnosta ja terveydenhuollosta), älytaloista ja –rakennuksista, älykkästä liikenteestä, älykkästä rakennetusta ympäristöstä, älykkästä energiasta sekä entistä älykkäämmin toimivista ihmisistä (Kamoun, 2016). Älykaupunkeihin liittyvät myös älyopimukset, standardit, avoin data ja älykäs maanviljely sekä kasvatusta. Älykaupunkien ei tarvitse välttämättä toteuttaa kaikkia edellä mainittuja ollakseen älykäs. (Mohanty, ym., 2016, 61.) Älykaupunginosasta on mahdollista puhua, kun jokin kaupunginosa toteuttaa edellä mainittua älykaupungin määritelmää.


Älykkäiden kaupunkien ja kaupunginosien alkukustannukset ovat suuret, mutta näiden käyttöönotto voi vähentää energiankulutusta, vedenkulutusta ja jätteen syntyä sekä pienentää liikennejärjestelyiden kustannuksia ja hiilipäästöjä koko älykaupungin alueella. Älykkäiden kaupunkien kirjo on laaja, joten näitä ja käytettyjä tekniikoita on yritetty standardoimaan. Standardointi voi myöskin vähentää kulutusta, sillä se mahdollistaa parhaiten eri teknologioiden yhdistämisen ja älykaupunkien kasvun sekä yhteenliittymisen unohtamatta tehokasta informaation käsittelyä. (Mohanty, ym., 2016, 61.)

IoT ja Big Data ovat tekniikat, jotka muodostavat selkärangan älykaupunkien leviämiseksi (Mohanty, Choppali & Kougianos, 2016, 60). Älykaupungeiksi kutsutaan kaupunkeja, jotka pyrkivät joustavuuteen ja säästöihin energian sekä raaka-aineiden kulutuksessa hyödyntäen kertyvää ICT-alan tuottamaa informaatiota samalla maksimoiden asukkaidensa tyytyväisyyden kaupungin tarjoamiin palveluihin. Esimerkiksi pesulaa, jonka jokin pesukone on tyhjillään, voi kutsua älykkääksi rakennukseksi, mikäli sen pesukoneet ovat kytkettyinä internetiin ja ne pystyvät ilmoittamaan pesulan nettisivuilla vapaasta tai vapautuvasta pesukoneesta automaattisesti. Myös toimistorakennusta, joka säätelee ennakoivasti sisäilmastoa kosteuden ja pienhiukkaspitkkeleiden varalta, voi kutsua älykkääksi.

Älykäs ja säätelöihin mukautuva katuvalaistus, älykkäät energiamittarit kodeissa ja liiketoiminnoissa voivat tuoda säästöjä energiankulutuksessa. Kodit voivat myydä aurinkopaneeleilla tuottamaansa ylijäämäenergiaa sähköverkkoon uudelleen hyödynnettäväksi. Älykäs liikenteen hallinta voi etsiä mahdollisimman suoria ja nopeita reittejä hätätilanteita varten ja ohjata liikenne älykkäällä tavoin säätilat, onnettomuudet tai liikennepuhkat huomioon ottaen. Älykäs liikenne kykenee myös monitoroimaan ajoneuvojen ja jalankulkijoiden tasoja reittejä ja liikennevaloja optimoidakseen sekä etsimään parkkipaikoista vapaita paikkoja ja ohjaamaan ajajat niihin. (Ramachandran, 2019, 3.)

Älykkääseen kaupunkiin kuuluu tärkeänä osana myös turvallisuus. Videovalvontaratkaisujen avulla voidaan esimerkiksi monitoroida rikollisuuden tasoja. Lisäksi rakennusten, siltojen ja historiallisten monumenttien värinää ja aineellista kuntoa voidaan mitata. Jätetyyppien ja jätesäiliöiden täyttöasteiden mittaaminen jätteiden keräysreittien ja menetelmien optimoimiseksi on myös mahdollista toteuttaa. Jätteiden erottelu ja käsittelylaitosten automatisointi ovat oleellinen osa älykkään kaupungin ympäristöä. Lisäksi asunhuoneistosta voidaan rakentaa yhteys automaattiseen kompostointijärjestelmään. (Ramachandran, 2019, 3.)

Sensorien hyödyntäminen muun muassa vesivuotojen ja putkistoissa olevien paineiden vaihteluiden tunnistamisessa on tärkeä osa määrittäessä ikääntyvän infrastruktuurin korjaustarpeita. Veden laadun monitorointi vedessä olevien kemikaalien optimaalisen tason määrittämiseksi ja epäpuhtauksien tunnistamiseksi on myös tarpeen. Lisäksi älykkäitä vesimittareita hyödyntäen veden kulutuksen tasoja voidaan mitata. Älykäs kaupunki kykenee myös tarjoamaan palveluita, kuten melutasojen mittaus kouluissa, sairaaloissa ja muissa keskeisissä sijainneissa. (Ramachandran, 2019, 3.)



KUVIO 10. Älykkään kaupungin konsepti (Ramachandran, 2019, 3)

Maailmalla älykäs kaupunki –hankkeita on toteutettu hyödyntäen hyvin erilaisia strategioita. Eräs esimerkki on Rio de Janeiro, jossa keskeistä on keskitetty data-aggregointi. IBM:n rakentama Rio de Janeiron hanke on niin sanottu top-down lähestymistapa älykaupunkikonseptiin, jossa on toteutettu komentokeskus eli kaupungin hallintajärjestelmä. Keskuksessa työskentelee jopa 400 ihmistä ja sen ensisijainen tavoite on turvallisuuden parantaminen, kuten kaupungin turvallisuutta uhkaavien maanvyörymien haittojen vähentäminen. Mikäli kaupungilla sortuu rakennus, komentokeskuksella on tiedossaan

nopein reitti paloautoille ja lisäksi se voi sulkea alueen kaasun- ja sähkönsyötön ja ohjata liikennettä kiertoteille. Kaupunkiin on asennettu sensoreita valvontakameroista ilmanlaadun valvontaan, jotka syöttävät dataa järjestelmän käyttöön. (Mustonen, Koponen ja Spilling, 2014, 5.) Rio de Janeiron älykäs kaupunki -hankkeen voidaan katsoa olevan menestyksekkäs toteutus, sillä kaupungin muuttaminen älykaupungiksi paransi asukkaiden turvallisuutta lyhentämällä hälytysten vasteaikoja peräti 20 prosentilla (Ahmed & ym., 2016, 1.)

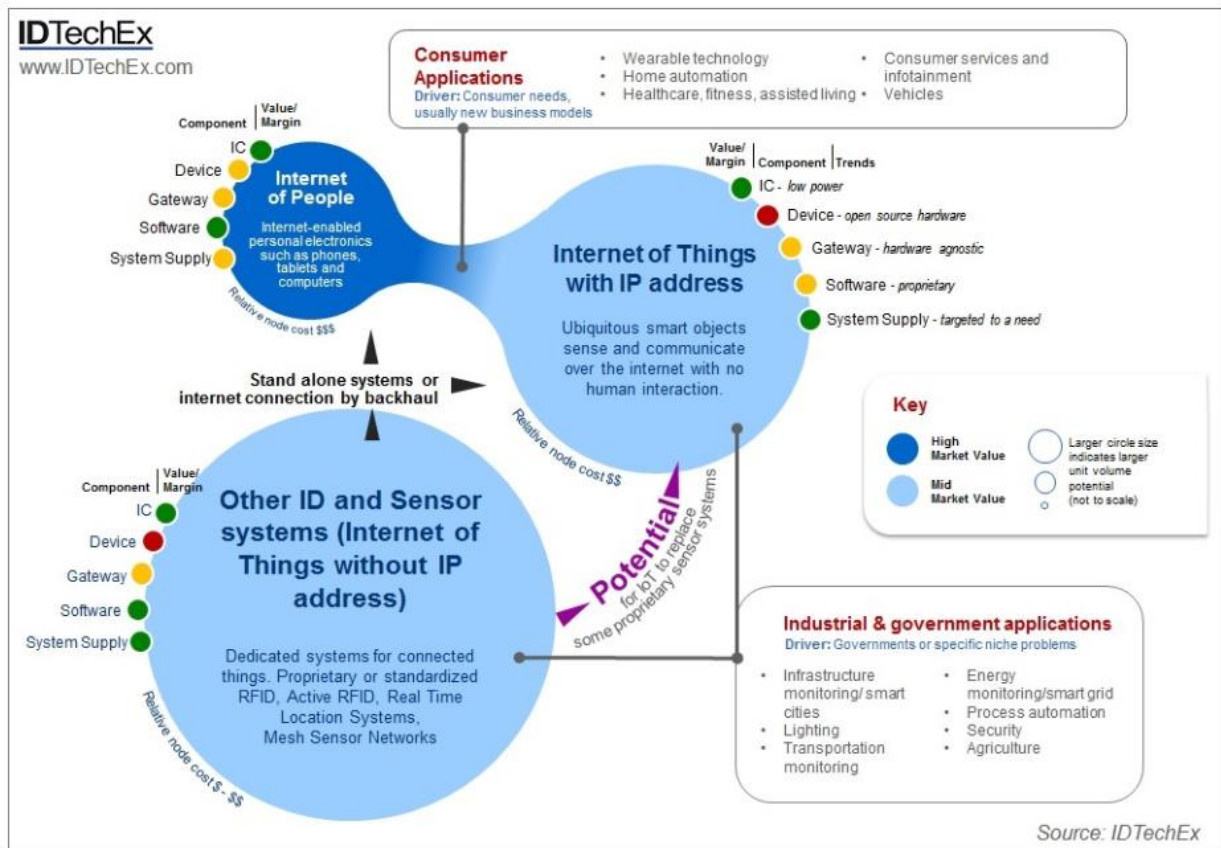
Sensoreista saatua informaatiota louhimalla on voitu tehdä havaintoja esimerkiksi huomaamalla, että suurin osa onnettomuuksista tapahtuu iltapäivisin. Valvontajärjestelmässä on kuitenkin havaittavissa myös varjopuolia, kuten valvontakameroiden toimimattomuus kriittisillä hetkillä, jolloin poliisi on käyttänyt väkivaltaisia otteita vuoden 2013 mielenosoituksissa. Rio de Janeiron älykaupunkia vastaavanlainen palvelu on otettu käyttöön myös New Yorkissa, jossa sen avulla voidaan selvittää lumimyrskyjen vaurioita. Amsterdamissa toimintafilosofia on erilainen ja sen tarkoituksena on tehdä mahdolliseksi kaupungin asukkaiden mahdollisimman laaja informaation käyttö siihen tarkoitukseen, kun he sitä haluavat käyttää. Tavoitteena on koko kaupungin laajuinen sitoutuminen älykaupunkihankkeeseen. (Mustonen ym., 2014, 6.)

3.3 Esineiden internet (IoT) ja sen sovellusalueita

3.3.1 Yleistä esineiden internetistä

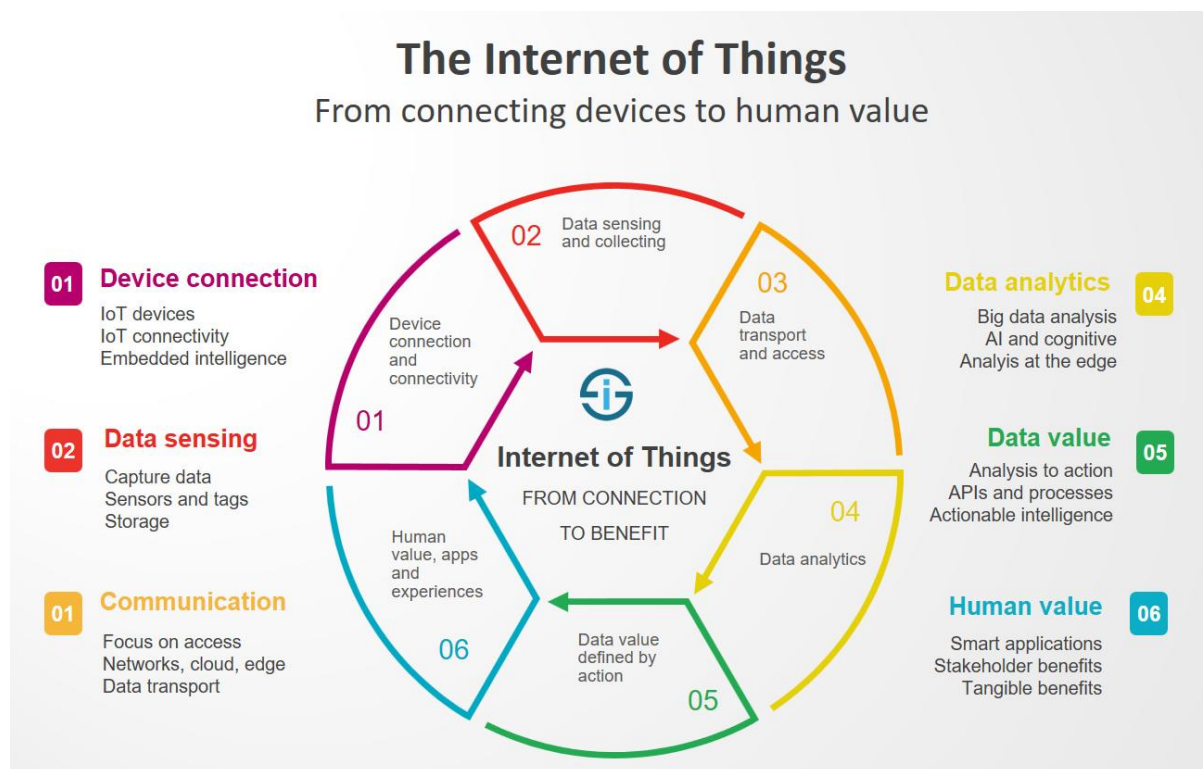
Esineiden internetillä (IoT) tarkoitetaan toistensa kanssa kommunikoivia asioita ja esineitä, jotka sijaitsevat ympärillämme (Atzori ym., 2010). Morganin (2014) mukaan esineiden internet on konsepti, joka periaatteessa yhdistää internetiin minkä tahansa laitteen, jossa on on/off-kytkin. Tämä sisältää kaiken matkapuhelimista, kahvinkeitinistä, pesukoneista, kuulokkeista, lampuista, päälle puettavista laitteista ja lähes kaikenlaisista sähkölaitteista, joita voi kuvitella. Liiketoiminnassa esineiden internet on nykypäivän kaupallinen ponnistus integroida suuri määrä teknisiä ja kaupallisia informaatiota tuottavia komponentteja uusien liiketoiminnallisten tilaisuuksien mahdollistamiseksi, perustuen laitteen ja järjestelmän älykkyyteen (Clarke, 2015). Gartner määrittelee IoT:n fyysisten objektien verkostoksi, jotka sisältävät objektien sisäisten tilojen väliseen tai ulkoiseen ympäristöön suuntautuvaan kommunikointiin tai interaktioon tarvittavaa teknologiaa (Gartner, 2017).

Esineiden internetin avulla voidaan toteuttaa muun muassa kotiautomaatiota, valmistaa päälle puettavaa teknologiaa, kuluttajapalveluita, ajoneuvojen elektroniikkaa ja sitä voidaan hyödyntää myös sairaalaympäristössä, avustetussa asumisessa ja kuntoilussa. Teollisuus ja valtiot ovat myös teknologiasta kiinnostuneita ja IoT-tekniikkaa on hyödynnetty lämmityksen ja infrastruktuurin monitoroinnissa, kuljetuksessa, maataloudessa, älykkäissä kaupungeissa, prosessiautomaatiossa, turvallisuusalalla ja niin edelleen. KUVIO:sta 11 ilmenee esineiden internetin toiminta, potentiaali ja sovellusalueet.



KUVIO 11. IoT-toiminta ja sovellusalueita (i-Scoop)

KUVIO:ssa 12. ilmenee kuuteen osaan jaettu IoT -toiminta laitteiden yhdistämisestä ihmisille lisäarvoa tuottaviin palveluihin. Osat ovat: 1. laitteiden yhdistäminen, 2. datan havainnointi (sensorit), 3. kommunikaatio (verkot, pilvet), 4. data-analytiikka (Big Data-analyysi, AI, kognitiivinen analyysi), 5. datan arviointi (analyysistä toimintaan), 6. lisäarvo ihmisille (älykkäät sovellukset ja osakkeenomistajien hyöty jne.).



KUVIO 12. IoT yhdistyy ihmisille lisäarvoa tuottaviin palveluihin (i-Scoop)

3.3.2 Esineiden internet ja sensorit älykkäissä rakennuksissa

Rakennusten infrastruktuurin alueella on meneillään suuria muutoksia kaupallisten rakennuksien ja yksityiskotien tullessa yhä älykkäämmiksi. Äly tässä kontekstissa viittaa automatisoituihin prosesseihin, jotka vähentävät operationaalisia kuluja, säästävät energiaa, optimoivat tilojen allokoitua, parantavat turvallisuutta ja asukkaiden viihtyvyyttä, sekä jossain tapauksissa tuottavat liiketoimintatietoa (Business Intelligence). Nykyiset sensorit, kuten liikkeen tunnistimet, eivät pysty tuottamaan riittävää informaatiota, vaan lisäksi on tarpeen käyttää muita tapoja valvontainformaation keräämiseksi. Kaupallisissa rakennuksissa IP-videokamerat yhdistettyinä videopohjaiseen analytiikkaan tarjoavat parhaimmat mahdollisuudet henkilöiden seuraamiseen, tosin videokameroilla on myös haittapuolensa: ne ovat kalliita, vaativat leveää kaistanleveyttä videokuvan siirtämiseen ja lisäksi ne helposti koetaan yksityisyyttä loukkaaviksi. (Roth, 2016.)

Älykkäiden sensorien ja tietoverkkoja hyödyntävien valaistusjärjestelmien myötävaikutuksesta IoT:sta ja Big Datasta on tullut toteuttamiskelpoisia kaupallisiin rakennuksiin. Big dataa keräämällä ja analysoimalla voidaan ymmärtää rakennuksien tilaa aiempaa paremmin, jolloin voidaan samanaikaisesti optimoida esimerkiksi energian kulutusta. Yhdysvaltalaisen USGBC-rakennusneuvoston (Green Building Council) arvioi, että 40 - 48 % muuhun kuin asuinkäyttöön rakennettavista rakennuksista oli vuonna 2015 vihreisiin arvoihin perustuvia. Vertailukohteena voidaan pitää vuoden 2005 tilannetta, jolloin vastaava arvo oli ainoastaan 2 %. Tulevaisuuden rakentamisessa IoT ja Big Data ovat yhä

enemmän läsnä ja ne tulevat vaikuttamaan rakennusten suunnitteluun ja rakentamiseen itsessään. (Costello, 2016.)

Valaistusjärjestelmien tarjotessa dataa valon tasoista ja energian käytöstä, älykäs valaistus on vasta alkua teknologian tarjoamista mahdollisuuksista älykkäisiin rakennuksiin. Älykkäät järjestelmät (KUVIO 13) pystyvät keräämään informaatiota, kuten lämpötilan, tilan käytön ja niin edelleen. Lisäksi ne kykenevät kommunikoimaan muiden rakennusjärjestelmien kanssa, kuten HVAC ja turvallisuuteen liittyvät järjestelmät. Älykkäät sensorit, jotka hyödyntävät oikeanlaista arkkitehtuuria seuraten lämpötilan, valojen tasojen, päivänvalon, liikkeen, lämmön ja energian kulutuksen suhteen, kykenevät erottamaan toisistaan ihmisen sekä ei-ihmisen lämmön ja liikkeen lähteet. (Costello, 2016.)



KUVIO 13. IoT ja rakennukseen asennettavia älykkäitä sensoreita (Costello, 2016)

Kehittyneiden valaistussensorien hyödyntäminen rakennusprojekteissa voi olla tarpeen otettaessa huomioon vihreiden rakennuksien sertifiointistandardit, kuten LEED (Leadership in Energy and Environment Design). Tämänkaltaiset sensorit tarjoavat useita erilaisia hyödyntämistapoja energiatehokkuuden hallintaan ja valojen käyttöön kiinteistöjen tiloissa. Sensoreiden tuottamasta datasta voidaan päätellä, kuinka tilan valaistus voidaan optimoida samanaikaisesti luonnollista valoa hyödyntäen. Liiketunnistimien dataa voidaan käyttää henkilöiden kulun valvontaan ja saada informaatiota siitä, milloin tila ei ole käytössä. Päivänvalon määrän tunnistamista varten kehitetyt sensorit kykenevät mittaamaan ulkoa tulevaa luonnollista valoa ja säätämään keinotekoisen valon määrää, jotta molempia valonlähteitä voidaan yhtäaikaisesti hyödyntää. Valoa voidaan IoT-teknologiaa käyttäen säätää sopivaksi esimerkiksi työntekijöiden tarpeen mukaan heidän työpisteissään. (Costello, 2016.)

Tilojen käytön tuottama data on arvokas IoT:n komponentti, varsinkin erityisesti kaupallisissa rakennuksissa, koska se voi auttaa tilojen ylläpitämisessä ja päivittämisessä tulevaisuuden tarpeita varten. Kehittyneet verkottuneen valaistusjärjestelmän sensorit pystyvät jäljittämään tiloissa tapahtuvaa liikettä, joka tarjoaa arvokasta tietoa siitä, kuinka tiloja käytetään tai ei käytetä. Mikäli jotain tiettyä aluetta ei käytetä sen alkuperäiseen tarkoitukseen (esimerkiksi jatkuvasti tyhjänä oleva kokoushuone), se voidaan allokoida paremmin ja käyttötarkoitus muuttuu. Menettelyä voidaan hyödyntää myös suuremmissa kampusalueissa ja rakennuksissa, jolloin laajennuksia voidaan suunnitella tilan käytön datan perusteella. Nykyään on mahdollista tunnistaa tilassa tapahtuva liike, jolloin voidaan muodostaa tietynlaisia liikkeestä johtuvia lämpökarttoja tai polkuja. Edellä mainittuja voidaan hyödyntää esimerkiksi valvontatarkoituksiin. (Costello, 2016.)

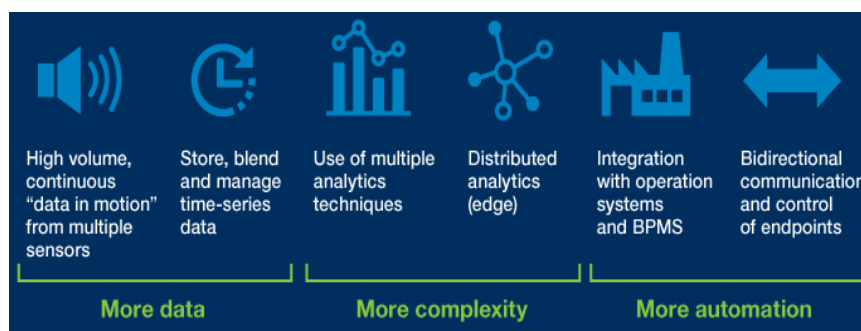
Kehittyneet järjestelmät ulottuvat perinteisten älyratkaisujen kuten valaistuksen kontrolloinnin ylitse ja ne tarjoavat mahdollisuuden integroida IoT:ta muihin rakennuksien järjestelmiin. Yhdistettäessä lämpötilan kontrollointi verkossa olevaan valaistusjärjestelmään, voidaan tuottaa informaatiota rakennuksen niin sanotuista ”kuumista” ja ”kylmistä” pisteistä HVAC:n optimoimiseksi. HVAC (Heating, Ventilation and Air Conditioning) tarkoituksena on huolehtia rakennuksen lämpöohjauksesta ja sisäilman laadusta. Lisäksi voidaan asentaa erilaisia liikesensoreita rakennuksen tiloihin, joiden avulla voidaan päätellä, milloin tiloja tulee lämmittää ja milloin ei. (Costello, 2016.)

IoT -teknologiaa voidaan hyödyntää myös tunkeilijoiden havaitsemiseen ja ihmisten paikantamiseen rakennuksen tiloissa katastrofitilanteissa. Liiketunnistimia voidaan käyttää myös esimerkiksi tilanteessa, jossa hämäräkytkin varoittaa asukkaita ennen valaistuksen sammumista, jolloin on vielä riittävästi aikaa poistua rakennuksesta tai ohittaa kontrollijärjestelmä. IoT -teknologiaa hyödyntävät valaistuskontrollit voivat myös valaista jalkakäytävän esimerkiksi jalankulkijan, asiakkaan tai työntekijän edestä lisäten näkyvyyttä ja turvallisuutta. (Costello, 2016.)

3.3.3 Esineiden internet analytiikassa

Esineiden internetin analytiikka on osittain samankaltaista kuin tavanomainen perinteinen analytiikka käyttäen useimmiten samoja algoritmeja ja työkaluja, kuin liiketoimintatiedon hallinta (BI eli Business Intelligence) ja edistyneen analytiikan teknologiat. Gartnerin arvioiden mukaan yli puolet tärkeimmistä uusista liiketoimintaprosesseista ja järjestelmistä tulee sisältämään jotain esineiden internetin elementtejä. Analytiikalla on tärkeä rooli myös esineiden internetissä, sillä se tukee päätöksenteon prosesseja. Analytiikkaa käytetään tyypillisesti raportointiin, diagnosointiin, ennustamiseen ja muihin edistyneen analytiikan toimintoihin. Esineiden internetin analytiikka pitää sisällään kaiken edellä mainitun ja lisäksi jatkuvasti useista tuhansista datalähteistä generoituvan streaming-datan ja mahdollisuuden suodattaa sekä analysoida sitä. (Petty, 2016.)

Esineiden internetin analytiikka tuottaa enemmän dataa (KUVIO 14) ja analytiikan syötteen ovat koneista, lääketieteellisistä laitteista, sensoreista ja muista fyysisistä kokonaisuuksista tulevia virtoja, joiden hallinta ja tallennus aiheuttavat haasteita, jotka usein vaativat soveltuvia prosessointialustoja ja tietokannan hallintajärjestelmiä. Monimutkaisuutta ja asennuksen, hallinnan ja ylläpidon haasteita aiheuttaa myös useiden erilaisten analyysitekniikoiden hyödyntäminen, joita on hajautettava datan analyysin tapahtuessa laitteissa, kontrollijärjestelmissä, palvelimissa ja älykkäissä reitittimissä. Esineiden internetin analytiikassa on aiempaa enemmän automaatiota ihmisten puuttuessa asioihin, vasta jonkin mennessä pieleen. Integrointi operationaalisten ja liiketoiminnallisten prosessien hallintajärjestelmien kanssa on oleellista ja IoT:n automatisoidessa liiketoiminnallisia prosesseja, kattava tietoturvan ja identiteetin hallinta vähentää elintärkeitä operaatioita kontrolloivien automaattisten ratkaisujen riskejä. (Petthey, 2016.)



KUVIO 14. IoT-analytiikan ominaispiirteitä (Petthey, 2016)

Esineiden internetin analytiikka on tärkeä työkalu valmistajille. Se tarjoaakin mahdollisuuksia säästää kustannuksissa, lisätä liikevaihtoa paremman tuotemyynnin seurauksena ja parantaa sisäisiä prosesseja. Lisäksi valmistajilla on mahdollisuus lisätä liikevaihtoa myymällä dataa tai neuvontapalveluita, jotka hyödyttävät osakkeen omistajien ekosysteemiä. (Harward Business Review, 2016.) Eniten lisäarvoa esineiden internetin analytiikasta saadaan, kun saapuva data voidaan ottaa käyttöön ilman ihmisen väliintuloa ja luoda dataan pohjautuvia ennusteita sekä ennustaa tulevaisuutta. Verkkoa hyödyntävät etäluettavat sensorit ja laitteistot sekä kerätty ja pilvipalveluihin koneoppimisen algoritmeja hyödyntäen tallennettu ja prosessoitu data mahdollistaa personoidumman ja laajemman IoT-teknologian hyödyntämisen. (Park, 2016.)

3.3.4 Esineiden internet ja päälle puettavat laitteet

Päälle puettavaa teknologiaa on usein kutsuttu yhdeksi suurimmista Internet of Things (IoT)-sovelluksista. Laittevalmistajat, kuten Fitbit ja muut samankaltaiset yritykset mahdollistavat henkilökohtaisen terveyden ja aktiviteetin sekä kuntoilun seurannan, mikä oli aiemmin mahdotonta. Älykellot tuovat älypuhelin tekniikkaa suoraan käyttäjän ranteeseen. Terveydenhuollon teollisuus on yksi suurimmista toimijoista, joka kiihdyttää päälle puettavien laitteiden markkinoita, sillä kuluttajien sekä ammattilaisten teknologiset trendit rohkaisevat siihen suuntaan. (Meola, 2016.)

Kuntoilun seurantasovellukset ovat johtava kuluttajasegmentti päälle puettaville laitteille, koska useimmat kuluttajat käyttävät päälle puettavia laitteita tallentamaan harjoittelunsa ja terveystilastoja sekä edistymistä. Nykyään myös sairaalat, lääketieteen alan yritykset sekä farmaseuttiset yritykset ja vakuutusyhtiöt ovat aloittaneet käyttämään näitä laitteita. Kriteerinä laajaan lääketieteellisten päälle puettavien laitteiden adoptioon on kuitenkin tarkkuus, jonka valmistajien tulee varmistaa, jotta käyttäjät voivat saada tarkkoja edistymisraportteja tilastaan. Tarkkuuden edelle menevät kuitenkin yksityisyysvaatimukset, sillä terveysdata on varsin arkaluontoista, eivätkä käyttäjät ole valmiita jakamaan sitä kaikkien tarkasteltavaksi. (Meola, 2016.) KUVIO:sta 15. ilmenee päälle puettavan teknologian sovellusalueita.



KUVIO 15. Päälle puettava teknologia ja sen sovellusalueita (Ericsson, 2017)

Nykyään useimmat päälle puettavat laitteet ovat fokuoitu kuntoilua varten, joten monet älyvaatteet tarjoavat hyötyjä, kuten mittarit ja yksityiskohtaisen analyysin suoritetuista harjoitteista. Tutkimuksien mukaan 40 % älypuhelinien käyttäjistä on kiinnostunut päälle puettavasta teknologiasta, kuten paita, johon on sisällytetty sensoreita, jotka voivat mitata tuhansia mittauksia kehosta. Tämän lisäksi sovellus voi suositella vaatteita internetissä, jotka sopivat täydellisesti kehon muotoon. Älylasit ovat myös yksi mielenkiintoinen sovellusalue, jota voidaan hyödyntää niin lääketieteessä kuin arkielämässäkin. Älyhousut taas voivat generoida virtaa muille päälle puettaville laitteille, jolloin niiden käyttö helpottuu, sillä lataamista ei tarvitse muistaa tehdä käytön jälkeen. Kiinnostusta on ollut myös lämpökoruja kohtaan, jotka voivat lähettää kuumia tai kylmiä pulsseja käyttäjän iholle parantaakseen yleistä lämpötilan kokemisen mukavuutta. (Ericsson, 2017.)

Päälle puettava teknologia ei ole vain pelkästään hyödyllistä ja ongelmatonta, vaan sen käyttöön liittyy myös riskejä. Tulevaisuudessa laitteet ovat yhä alttiimpia viruksille, hakkeroinnille tai tietomurroille, jolloin mahdollisesti arkaluonteinen data on vaarassa joutua väärin käsiin tai julkisesti jaettavaksi. Tällä hetkellä luottamus ei ole kuitenkaan vielä huonolla tasolla laitteiden vasta kehittyessä. Käyttäjät ovat enemminkin halukkaita jakamaan dataa myös kolmannen osapuolen palveluntarjoajille, mikäli saavat siitä jonkinlaista hyötyä. Yli 60 % käyttäjistä tuntee, että he voivat kontrolloida kenelle dataa on jaettu ja tuntevat siten olevansa turvassa. Eniten käyttäjät haluavat jakaa dataa laitevalmistajien, lääkäreiden, vakuutusyhtiöiden, internetissä toimivien yritysten ja kuntosalien kanssa. Vähiten dataa haluttiin jakaa työnantajille. (Ericsson, 2017.)

3.3.5 Teollinen esineiden internet (IIoT) ja älykäs valmistaminen

Teollinen esineiden internet (Industrial Internet of Things, IIoT) käsittää IoT-laitteiden monipuolisen käytön massatuotannossa, tuotannon suunnittelussa ja valvonnassa. IoT-laitteita on mahdollista käyttää työstettävien materiaalien ja valmistettujen tuotteiden paikannukseen, resurssien allokonttiin sekä pitämään kirjaa tuotannossa käytettävien koneiden ja työvälineiden kunnosta, sillä ne varmistavat suoran ja selkeän kommunikointikeinon (Sharp, Ak & Hedberg, 2018, 8). Toisin sanoen järjestelmän on mahdollista suorittaa koko tuotantoprosessi tilauksen asettamisesta valmiin tilauserän pakkaamiseen asti kokonaisvaltaisesti ilman ihmisen puuttumista järjestelmän toimintaan samalla minimoiden mahdolliset tuotantoprosessin katkeamiset antureiden kirjon ja ennakoivan analytiikan avulla. Nykyisellään ne pyrkivät täyttämään luotettavuuden, käytettävyyden, ylläpidon ja turvallisuuden standardeja sekä käytänteitä, kuten muutkin CP – järjestelmät (Abate ym., 2018, 1).

Teollisessa IoT:ssa raaka-materiaalia, raaka-ainetta, tuotteen osaa, valmistuvaa tuotetta, valmista tuotetta ja sen pakkaamista voidaan seurata ja ohjata automaattisesti koko tuotantoprosessin ajan aina kuljetukseen asiakkaalle asti. Kertynyt informaatio on mahdollista liittää tuotteesta tehtävään digitaaliseen kaksoseen tai digitaaliseen sertifikaattiin. Tällainen tarkkaan suunniteltu järjestelmä mahdollistaa tuotteen koko valmistusprosessin aikaisen tiedonkeruun, jolloin se lisää tuotteen läpinäkyvyyttä ja luo puitteet tuotteen koko elinkaaren aikaiselle seuraamiselle (Sharp ym., 2018, 2).

Tekoälyn hyödyntämistä valmistuksessa syntyvien datamäärien tulkitsemisessa, esittämisessä ja tuotannon suunnittelussa voidaan ymmärtää älykkäänä valmistamisena ("smart manufacturing") (Qi, Tao, Zuo & Zhao, 2018, 1). Järjestelmien tuottaman suuren datan määrä mahdollistaa tekoälyn käyttämisen IIoT:ssa ja sitä on esimerkiksi käytetty tukena päätöksenteossa. Nykyisiin trendeihin ja kiinnostuksen kohteisiin kuuluu tekoälyn hyödyntäminen tuotteiden ja valmistuksen elinkaarenhoidossa, päätöksenteossa ja tietämyksen hallinnassa. Tulevaisuudessa tekoälyn ja koneoppimisen hyödyntäminen tuotteen eri elinkaaren ja prosessien vaiheissa sekä koko yrityksen tasolla voi tarjota uusia

näkökulmia, tutkimuskohteita sekä ratkaisuja tutkimusaineiston rikastuessa entistä erilaisemmalla datalla (Sharp ym., 2018, 9).

IIoT-järjestelmien suunnittelussa on käytetty ISA-95- ja 5C-arkkitehtuureja. Yksinkertaisuudessaan ISA-95-standardi sisältää viisi tasoa, joista pohjimmaisimmalla määritellään käytettävät fyysiset prosessit (taso 0). Tasolla yksi määritellään mittarointiin ja fyysisiin prosesseihin liittyvät toiminnot sensoreiden ja toimijoiden avulla. Seuraavalla tasolla kuvataan fyysisten prosessien valvontaan ja automaattisen kontrollointiin liittyvät toimet. Kolmannella tasolla optimoidaan tuotannon prosesseja ja aikataulutetaan niitä yksityiskohtaisesti. Viimeisellä tasolla (taso 4) eli abstrakteimmalla tasolla suunnitellaan valmistusaikataulut, materiaalin käyttö, tavaraluettelointi, tuotteiden valmistuminen ja lähettäminen asiakkaalle.

5C-arkkitehtuurimallissa alimman tason muodostaa yhteys ("connection") eri laitteiden ja laitteiden osien välillä. Näiden ominaisuuksia voi mitata sensoreilla ja selvittää esimerkiksi koneen terän lämpötilan verrattuna vallitsevaan ympäristön lämpötilaan. Seuraavalla tasolla (muunnos, "conversion") useista lähteistä kerätty data on mahdollista muuntaa informaatioksi. Kyber-tasolla ("cyber") koko valmistuslaitteverkoston data ja informaatio kerätään yhteen ja tästä datasta erotellaan ja jatkojalostetaan tilastollista tietoa, jota on mahdollista käyttää koneiden vertailuun ja arvottamiseen. Seuraavalla ajattelua ("cognition") vaativalla tasolla informaatio pyritään esittämään käyttäjille selkeästi ja relevantisti, jotta tuotantoon vaikuttavia päätöksiä olisi mahdollista tehdä. Viimeisellä mukautukset ("configuration") -tasolla järjestelmä muokkaa ja mukauttaa fyysisten koneiden ja laitteidensa toimintaa. (Jiang, 2018, 2 - 3.) Jiang ehdottaa lisää ominaisuuksia 5C-arkkitehtuurille. Hänen mielestään yhteistyö ("coalition"), asiakas ("customer") ja sisältö ("content") kuuluvat 5C-arkkitehtuurin lisäominaisuuksiksi. Yhteistyö tarkoittaa, että arvo- ja tuotantoketjut olisi yhdistettävä eri tuottajien välillä ja tuotannot aikataulutettava yhdessä. Asiakkaan vaikutus olisi se, miten asiakkaan toiveet olisi otettava huomioon ja olisiko asiakkaalla mahdollisuus vaikuttaa erikoistuotteiden valmistukseen. Sisällöllä tarkoitetaan tuotteista ja valmistuksesta saatavan datan kokonaisvaltaiseen keräämiseen ja tuotteen elinkaaren läpinäkyvään taltiointiin. (Jiang, 2018, 4 - 5.)

Teollisessa IoT:ssa on mahdollista vaikuttaa myös erikoistuotteiden valmistukseen. Käytännössä tämä tarkoittaa sitä, että paikallisen IIoT-laite-järjestelmän avulla tuotantolaitos reagoi pieneen tilaukseen mukautettua erikoistuotetta automaattisesti ajastamalla tuotantoerien valmistuksen vapaiden tai vapautuvien fyysisten laitteiden avulla samalla varmistaen tuotannossa tarvittavien raaka-aineiden ja kuljetusten ajoittamisen. Kaikkien tuotannossa käytettyjen koneiden käytön optimoiminen mahdollistaa massatuotannon ja mukautettujen erikoistuotteiden tuotannon (Jiang, 2018).

4. Älykkäiden rakennuksien ennakoiva kunnossapito

Nykyajan rakennukset ovat muuttuneet paljon entisajoista, mutta niiden perustarkoitus on yhä sama – suojella ihmistä luonnonvoimilta. Rakennusten laadun parantuessa on niistä huolehtiminen noussut entistä aiheellisemmaksi. Rakennusten ajastettu kunnonvalvonta on kuitenkin tehotonta. Eräs keino huolehtia ja huoltaa rakennuksia on sijoittaa sensoreita tai sensori-toimija-pareja valvomaan rakennuksessa vaikuttavia suureita kuten valaistusta, luonnonvaloa, suhteellista kosteutta, ilmastointia, vettä ja energiankulutusta sekä varoittamaan mahdollisesta tulipalosta tai kaasuvuodosta. (Kumar, Singh, Kumar, Singh, Mahanta & Mukhopadhyay, 2018, 4847.)

Rakennusten kunnontarkastelua ja kunnan muutoksiin mukautumista sensoreiden avulla tunnetaan nimellä rakennusterveystarkastelu (Structural Health Monitoring, SHM), jossa sensoridatasta voidaan analysoida rakenteen ominaisuuksia ja päätellä milloin mahdollinen piilevä vikailmaantuu, millainen vian tyyppi on ja minne vika paikallistuu (Legatiuk & Smarsly, 2018, 1). SHM liittyy täten hyvin vahvasti älytaloihin, -rakennuksiin, -infrastruktuuriin ja –kaupunkeihin sekä näiden järjestelmien suunnitteluun (Legatiuk & Smarsly, 2018, 1), rakentamiseen (de Souza, da Costa & Bauer, 2018), testaukseen (Hester, Brownjohn, Bocian, Xu & Quattrone, 2018, 776 - 798; Azuara, Barrera & Ruiz, 2018), käyttöön (Choi, Yeum, Dyke, Jahanshahi, Pena & Park, 2018), ennalta ehkäisevään suojeluun (Choi ym., 2018; de Souza ym., 2018; Fromme, 2018) ja purkuun (Helmy, Elfouly & Salem, 2012, 279 - 295). Ennen vian ilmaantumista jäljellä olevan käyttöiän (Remaining Usefull Life-time, RUL) (Javed, Gouriveau, Zerhouni & Nectoux, 2015, 1) laskeminen SHM datan pohjalta kuuluu puolestaan ennakoivaan kunnonvalvontaan (Prognostic Health Monitoring, PHM)(Sbarufatti, Cadini, Locatelli & Giglio, 2018, 1.)

Ennakoiva kunnossapito (Predictive Maintenance eli PdM) on kunnossapitoa, jossa suoraan monitoroidaan esimerkiksi normaalisti toimivan laitteen tilaa, jonka avulla voidaan vähentämään virheiden todennäköisyyttä. Ennakoiva kunnossapito koettaa pitää kustannukset matalalla vähentämällä kunnossapidollisten tehtävien toistuvuutta sekä suunnittelemattomia rikkoontumisia ja eliminoimalla tarpeettoman ennalta ehkäisevien kunnossapidollisten tehtävien tarpeen. PdM:n avulla organisaatiot kykenevät jatkuvasti monitoroimaan ja testaamaan erilaisia tilanteita, kuten esimerkiksi voitelun tilaa tai mahdollista korroosiota. Testaamisessa käytettäviä menetelmiä ovat muun muassa infrapunatestaus, akustinen- ja vibraatioanalyysi, sekä äänen ja öljyn tasojen analyysit. Tietokoneohjatut kunnossapidon hallintajärjestelmät (Computerized Maintenance Management Systems eli CMMS) voivat myös helpottaa tilannetietoisuuden saavuttamista. (Eemaint, 2017.)

Usein tutkimukset ja datan kerääminen korjaustarpeiden kartoittamiseksi aloitetaan vasta silloin kuin ongelma tai korjaustarve on jo tullut esille. Avainkysymyksiä voivat olla millaista informaatiota tarvitaan ennakoitavuuden parantamiseksi. Esimerkiksi miten olisi mahdollista saavuttaa tilanne, jossa rakennuksen putkistoja voitaisiin jatkuvasti monitoroida ja hyödyntää kerättyä dataa kalliiden vesivahinkojen estämiseksi. Keräämällä tämänkaltaista dataa ja hyödyntämällä sitä voidaan toteuttaa todelliseen tilaan perustuvia ennusteita myös muista korjaustarpeista. Datan määrällä on myös vaikutusta eli mitä pidempään ja mitä enemmän dataa kerätään, sen tarkempia ennusteita voidaan tehdä. (Vepsäläinen, 2016.)

Ongelmana kuitenkin on se, että vaikka data on olemassa, se on hajallaan ja sen kerääminen on vaikeaa. Ennusteita parantaakseen aiemmin kerättyyn dataan voidaan lisätä jo olemassa olevien teknologisten ratkaisujen tuottamaa dataa, joilla voidaan mitata esimerkiksi putkien tilaa, lämpötilaeroja, kosteutta tai muita tilanteita. Tällä tavoin voidaan päästä melko lähelle reaaliaikaista monitorointia, välttää vahinkoja ja pitkällä aikavälillä esimerkiksi homeen tai muiden ongelmien muodostuminen. Tämänkaltaisia ominaisuuksia on tarpeen toteuttaa myös älykkäisiin rakennuksiin ja tulevaisuudessa ne tulevat olemaan osa uutta arkkitehtuuria. (Vepsäläinen, 2016.)

4.1 Ennakoivan kunnossapidon hyötyjä ja haittoja

Ennakoivan kunnossapidon prosessia on pystytty menestyksekkäästi hyödyntämään johtuen sen kyvystä rekisteröidä pieniä muutoksia, jotka mahdollistavat suurien esimerkiksi putkistossa piilevien ongelmien löytymisen. Järjestelmien seisokkiajat voidaan pitää minimaalisina, koska kiinteistöstä vastaavan isännöitsijän ei yksin tarvitse reagoida ongelmiin, vaan ennakoivien kunnossapidon järjestelmien kautta hänellä on kattavampi ymmärrys siitä, mitä rakennuksessa tapahtuu, jolloin ongelmiin voidaan puuttua. Tämä antaa kiinteistöistä vastaaville isännöitsijöille informaatiota alueista, joihin tulee kiinnittää huomiota tulevaisuudessa. (Senseware.)

Ennakoivaa kunnossapitoa hyödyntämällä kiinteistöstä vastaavat henkilöt voivat suunnitella korjaustoimenpiteitä jo etukäteen, jolloin he voivat hyödyntää mahdollisimman matalia työvoima- ja materiaalikustannuksia. Kuluja vähentää myös henkilöresurssien optimaalinen hyödyntäminen, jolloin urakoitsijat, ylläpitohenkilöstö ja muut työntekijät voivat toimia aikataulun mukaisesti. Koska korjauksia tehdään vain tarpeen mukaan, kiinteistöistä vastaavat henkilöt voivat keskittyä optimoimaan rakennusten toimintoja, eikä heidän tarvitse juosta kriisistä toiseen etsien tasapainoa kiinteistöön liittyvien tarpeiden ja ongelmatilanteista johtuvien esimerkiksi tuottavuusongelmien välillä. (Senseware.)

Ajan myötä kiinteistöstä vastaava henkilö saa riittävän määrän dataa, jotta korjaustarve voidaan ennustaa. Järjestelmä paranee lisättäessä sensoreita laitteisiin ja samalla laajenee myös infrastruktuuri uusien datapisteiden kautta. Kiinteistöistä vastaavien henkilöiden epäillessä ongelmia jollain tietyllä alueella, he voivat verrata kyseistä dataa historiallisiin

trendeihin, etsiä pieniä varoitusmerkkejä tai saada kuvauksen koko järjestelmästä. Integraatio rakennusautomaatiojärjestelmien ja muiden ratkaisujen kanssa antaa mahdollisuuden kiinteistöistä vastaaville henkilöille saada yhä enemmän hyötyä datasta. Generoidut raportit tarjoavat merkittävää dataa muun muassa parantuneesta ylläpitosuunnitelmasta, kiinteistöistä vastaavien henkilöiden toimintojen parantamisesta ja lisäksi suosituksia tulevaisuuden kasvulle. (Senseware.)

Kriittiset järjestelmät hyötyvät varsin paljon ennakoivasta kunnossapidosta, sillä tähän infrastruktuurin osaan voi kohdistua vain vähän häiriötilanteita. Tällaisia järjestelmiä ovat esimerkiksi lääketieteelliset laitokset ja pankkioperaatiot. Ennakoiva kunnossapito tarjoaa enemmän ennakoitavuutta kuin muut vaihtoehdot säilyttäen silti kustannustehokkaan lähestymistavan. Ennalta ehkäisevä kunnossapito on hyvä vaihtoehto silloin kuin kiinteistöistä vastaavalla henkilöllä ei ole täydellistä pääsyä rakennusten järjestelmiin. IoT-sensorit tarjoavat mahdollisuuden reaaliaikaiseen datavirtaan ja sitä voidaan hyödyntää raportoimaan useita erilaisia tilanteita aina tärinästä CO₂-tasoihin saakka. (Senseware.)

KUVIO 16. havainnollistaa erilaisten kunnossapidon lähestymistapojen hyviä ja huonoja puolia. Reaktiivinen lähestymistapa tarvitsee vain minimaalisen määrän työvoimaa ja sillä on matalimmat aloituskustannukset. Reaktiivinen lähestymistapa on kuitenkin lähestymistavoista kaikkein tehottomin ja aiheuttaa eniten kustannuksia. Preventiivinen eli ennalta ehkäisevä lähestymistapa on reaktiivista tehokkaampi ja se mahdollistaa 12 - 18 % säästöjä reaktiiviseen lähestymistapaan verrattuna. Preventiivinen lähestymistapa kuitenkin aiheuttaa tarpeetonta ylläpitoa ja siitä puuttuu priorisointi.

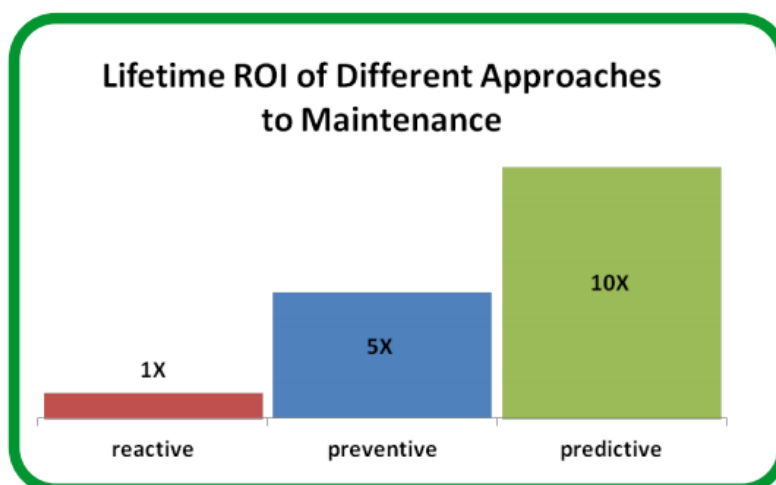
Prediktiivinen eli ennakoiva lähestymistapa on kustannustehokas mahdollistaen 8 - 12 % säästöt preventiiviseen lähestymistapaan verrattuna. Kyseinen lähestymistapa myös tarjoaa paremman turvallisuuden, tuottavuuden, tehokkuuden, priorisoinnin ja vähiten vikatilanteita. Haittana tosin on lähestymistavoista korkeimmat alkuinvestoinnit henkilöstöön, koulutukseen, diagnostiikkaan ja niin edelleen. Kustannuksista johtuen säästöt eivät ole heti nähtävissä. Prediktiivinen lähestymistapa yhdistettynä analytiikkaan on lähestymistavoista kaikkein kustannustehokkain. Se tarjoaa parhaimman priorisoinnin, virtaviivaisen toiminnan ja mitattavissa olevan ROI:n. Tämä lähestymistapa kuitenkin vaatii erikoisosaamista, jotta siitä voidaan saada parhaat hyödyt.

Maintenance approach	Pros	Cons
Reactive	<ul style="list-style-type: none"> • minimal staff • lowest initial investment 	<ul style="list-style-type: none"> • least efficient & cost-effective • increased cost of unplanned downtime, labor, repair • inefficient use of staff
Preventive	<ul style="list-style-type: none"> • more efficient & cost-effective: 12–18% savings over reactive • less equipment failure/ more uptime 	<ul style="list-style-type: none"> • lack of prioritization • unnecessary maintenance
Predictive	<ul style="list-style-type: none"> • highly efficient & cost-effective: 8–12% savings over preventive • least equipment failure/ most uptime • improved safety, comfort, productivity, efficiency compliance • greater prioritization 	<ul style="list-style-type: none"> • highest initial investment (staff, training, diagnostics) • savings potential not immediately seen by management
Predictive + analytics	<ul style="list-style-type: none"> • most efficient & cost-effective • greatest prioritization • streamlined operations • quantifiable ROI to show management 	<ul style="list-style-type: none"> • requires robust BMS • special expertise

KUVIO 16. Erilaisten kunnossapidon ohjelmien hyötyjä ja haittoja (Hemmerdinger, 2016)

4.2 Ennakoivan kunnossapidon kustannukset ja säästöt


Oikealla tavalla toteutettuna ennakoivan kunnossapidon sijoitetun pääoman tuotto prosentti (ROI eli Return On Investment) voi olla jopa 10-kertainen reaktiivisiin kunnossapidon ohjelmiin verrattuna (KUVIO 17). Ennalta ehkäisevillä (preventive) ohjelmilla ROI voi olla viisinkertainen. Säästöistä huolimatta Yhdysvaltalaisen energiaosaston (US Depart of Energy) vuoden 2010 tutkimuksista selvisi, että reaktiiviset kunnossapidon ohjelmat ovat yhä rakennuksissa eniten edustettuina ja niitä on käytössä peräti 55 % tapauksista. Ennalta ehkäiseviä (preventive)-ohjelmia on 31 % rakennuksista ja ennakoivia kunnossapidon ohjelmia vain 12 % rakennuksista.



KUVIO 17. Sijoitetun pääoman tuotto % kunnossapidon ohjelmissä (Hemmerdinger, 2016)

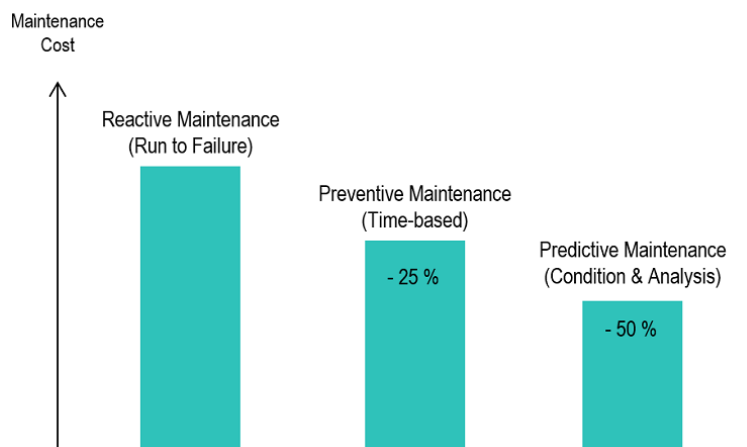
Reaktiivisen kunnossapidon ohjelmassa korjaavia toimenpiteitä suoritetaan vasta, kun laitteet alkavat toimia väärällä tavalla tai ne hajoavat. Menettely aiheuttaa korkeita korjaus- ja ylläpitokustannuksia ennalta ehkäisevien kustannuksien ollessa pieniä. Reaktiivista kunnossapidon ohjelmaa voidaankin hyvällä syyllä kutsua korjaamiseksi. Reaktiivinen kunnossapito aiheuttaa maksimaalisia kustannuksia (KUVIO 18) sekä palveluiden ja toiminnan keskeytyksiä korjaustoimien aikana. Kolmasosassa tapauksista rakennusten omistajat hyödyntävät ennakoivaa kunnossapidon lähestymistapaa, joka tarkoittaa säännöllisten ja ennalta sovittujen huoltotarkastusten ja korjauksien suorittamista, olivat ne tarpeen tai eivät. Menettely tarjoaa reaktiivista tapaa parempia tuloksia, mutta ei kuitenkaan ole optimaalinen. Optimaalisin kolmesta edellä mainitusta kunnossapidon ohjelmasta on ennakoivan kunnossapidon ohjelma, jossa kokonaiskulut sekä korjauksiin ja ennaltaehkäisyyn liittyvät kulut ovat pienimmät.

Tehokkaampi tapa kustannusten pienentämiseksi ja parhaan mahdollisen käytettävyyden saavuttamiseksi palvelusuunnitelman tekemiseksi on hyödyntää sekä ennalta ehkäiseviä että ennakoivia kunnossapidon ohjelmia perustuen laitteistojen todelliseen tilaan ennalta määritellyn aikataulun sijasta. Ohjelmassa ennakoivaa kunnossapitoa voidaan käyttää korjauksien ja ylläpidon priorisointiin, jolloin tärkeimmät järjestelmät voidaan korjata ensin, jotta mahdollisimman suuri sijoitetun pääoman tuotto (ROI) voidaan varmistaa. Yhdistämällä ennakoivaa kunnossapitoa ja analytiikkaa, on mahdollista tehdä jopa 20 % vuosittaisia säästöjä huollon ja energiakulujen alueilla sekä samanaikaisesti parantaa rakennuksien elinaikaa useilla vuosilla.



KUVIO 18. Kustannukset vikaantumisen funktiona kunnossapidossa (Foxworth, 2017)

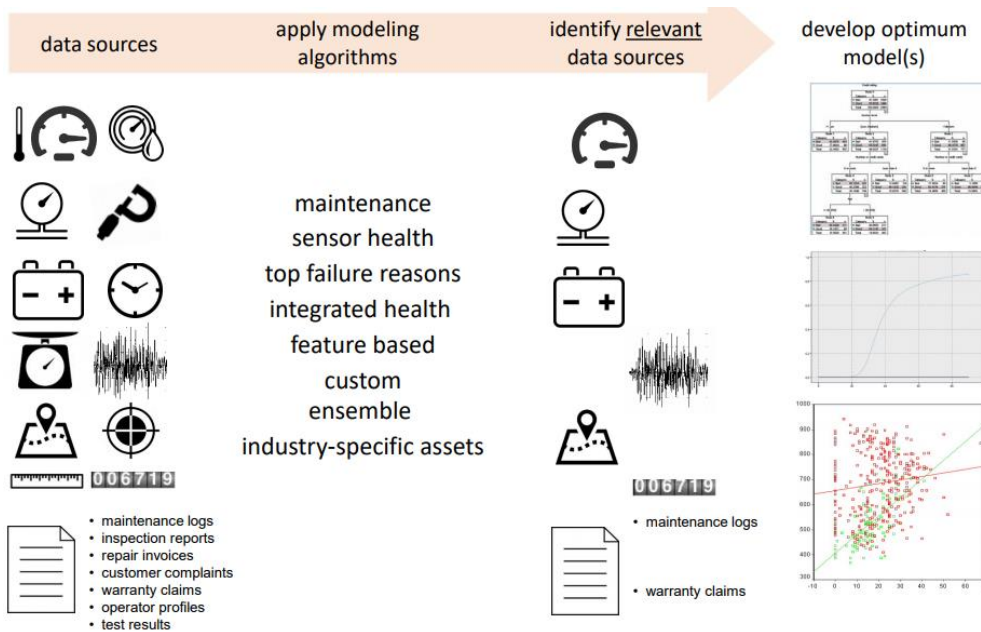
Tutkimuksien mukaan ylläpitokustannukset muun muassa teollisuuden aloilla, kuten paperi-, teräs- tai energiateollisuudessa, voivat huomattavasti vähentyä ennakoivaa kunnossapitoa hyödyntämällä. Reaktiivinen kunnossapito aiheuttaa suurimmat kustannukset (KUVIO 19) ja ennalta ehkäisevää kunnossapidon ohjelmaa hyödyntäen voidaan säästää 25 % ylläpidon kuluissa. Parhaan tuloksen antaa ennakoiva analytiikkaa hyödyntävä kunnossapito, jossa säästöä voi tulla peräti 50 %.



KUVIO 19. Kunnossapidon ylläpitokustannuksia teollisuuden aloilla (Sigma IT Consulting)

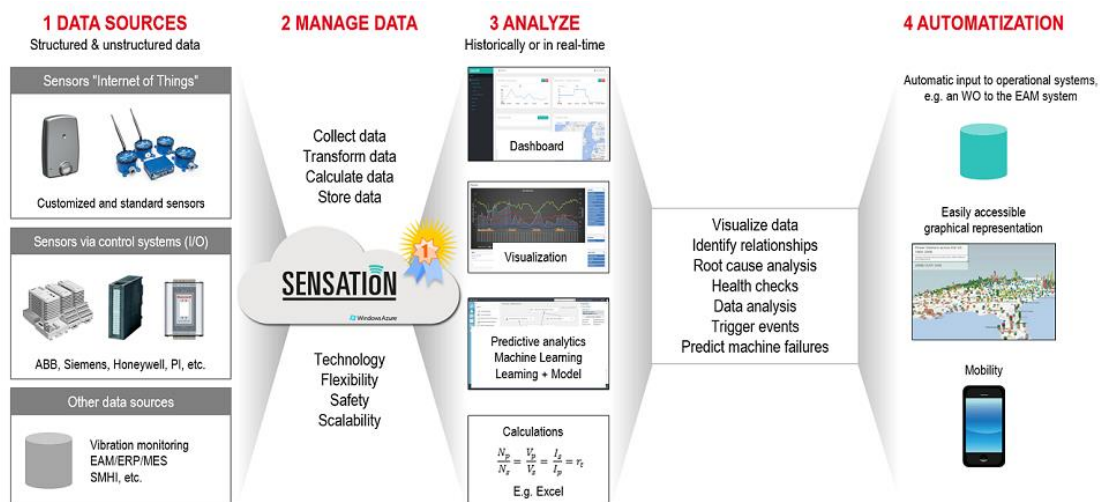
4.3 Ennakoivan kunnossapidon prosessi

Tässä luvussa esitellään ennakoivan kunnossapidon prosessia (esimerkkinä KUVIO 20). KUVIO:ssa 20 on esiteltyä datalähteet, jotka voivat tuottaa dataa, kuten ylläpitolokit, tarkastusraportit, korjauslaskut, asiakasvalitukset, takuuvaatimukset, operaattoriprofiilit ja testitulokset. Dataan voidaan soveltaa mallinnusalgoritmeja ja mallien avulla voidaan tunnistaa relevantit datalähteet. Lopputuloksena on optimoitu malli, johon pohjautuen voidaan ennakoitua kunnossapidon prosessia toteuttaa.



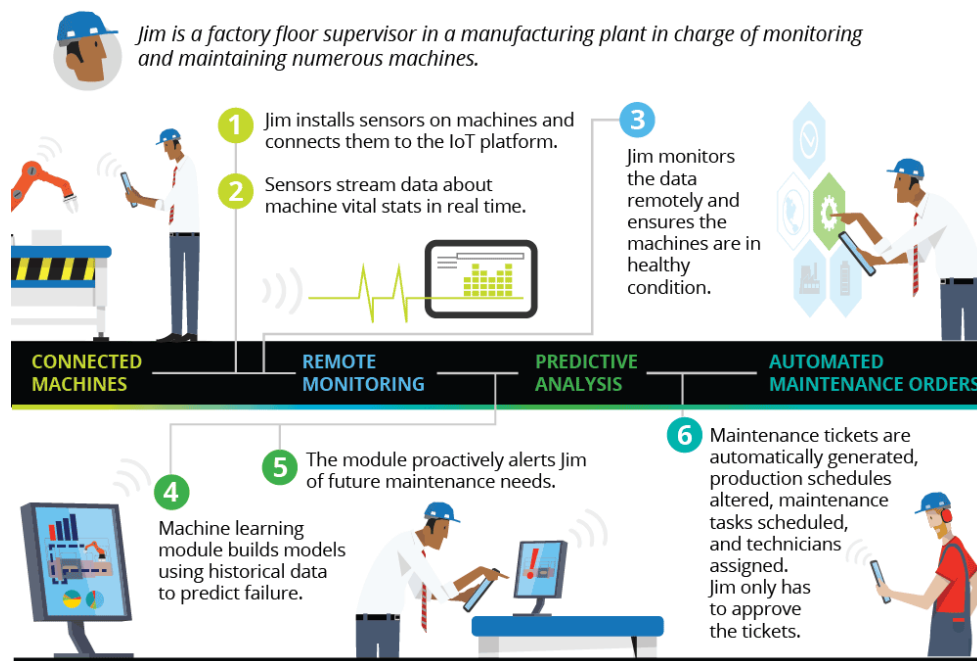
KUVIO 20. Ennakoivan kunnossapidon prosessi (Durham, 2017)

KUVIO:ssa 21. on esimerkki (Sigma IT Consulting) datan hyödyntämisestä ennakoivan kunnossapidon osana. Ensimmäisessä osassa ovat datalähteet, joihin kuuluu esineiden Internet (IoT) sensorit, kontrollijärjestelmien sensorit (I/O) ja muut data lähteet. toisessa vaiheessa data kerätään, muunnetaan, tehdään tarvittavat laskutoimitukset ja lopulta data varastoidaan. Kolmas vaihe on analysointivaihe, jossa data voidaan esittää kojelautanäkymissä (dashboards) historiallisena datana tai reaaliajassa. Tässä vaiheessa data visualisoidaan ja vaiheen osana muodostetaan koneoppimisen malli ja hyödynnetään prediktivistä analytiikkaa. Neljäs vaihe on automatisointi, jossa data syötetään käyttäjärjestelmille ja jonka päällä siitä voidaan visualisoida graafinen esitys. Dataa voidaan hyödyntää myös mobiilisovellusten käyttöliittymien kautta.



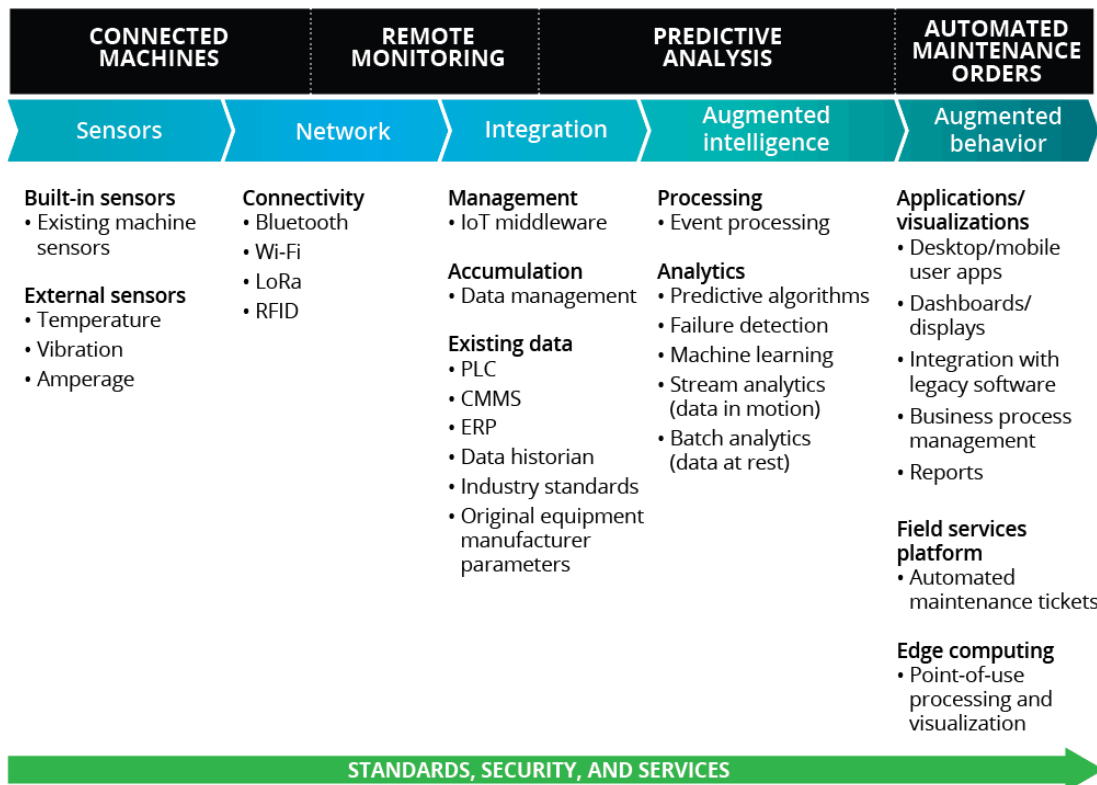
KUVIO 21. Datn hyödyntäminen ennakoivassa kunnossapidossa (Sigma IT Consulting)

KUVIO:ssa 22. on esimerkki ennustavan analytiikan prosessista teollisuuden kontekstissa. Esimerkissä Jim on tuotantolaitoksen tehtaan tarkastaja, joka on vastuussa useiden koneiden monitoroinnista ja ylläpidosta. Jim:n tehtävänä on asentaa sensoreita koneisiin ja yhdistää ne IoT-alustaan. Asennettavat sensorit mittaavat koneiden tuottamaa dataa reaaliajassa luoden tilannekuvan. Jim monitoroi dataa etänä ja varmistaa, että koneet ovat toimintakypyisiä. Koneoppimisen moduuli rakentaa malleja hyödyntäen historiallista dataa virhetilanteiden ennakkoinnissa ja lähettää proaktiivisesti Jimille hälytyksiä tulevaisuuden ylläpitotarpeista. Järjestelmä generoi ylläpitoticketit automaattisesti, muuttaa tuotannon aikatauluja, ajoittaa tehtäviä ja jakaa työtehtäviä.



KUVIO 22. Esimerkki ennakoivan kunnossapidon prosessista teollisuudessa (Coleman ym., 2017)

KUVIO:ssa 23. esitellään PdM:ää ohjaavia teknologioita. Sensorit-kategoriassa on esitelty sensoreita, kuten lämpötila, värinä ja virta. Etämonitorointiin liittyy myös langattomat protokollat ja teknologiat, kuten Bluetooth, Wi-Fi, LoRa ja RFID. Etämonitoroinnin ja prediktiivisen analyysin välissä on integraatiokerros, johon kuuluu hallinta ja datan hallinta sekä järjestelmät, kuten ERP, CMMS, PLC jne. Prediktiivisen analytiikan osana laajennetun älykkyyden kerros, johon kuuluu tapahtuman käsittely, ja analytiikka, johon sisältyvät prediktiiviset algoritmit, virhetilanteiden tunnistus, koneoppiminen, liikkuvan datan analytiikka ja eräanalytiikka. Automaattisten huoltotilauksien alla on laajennetun käyttäytymisen kerros, johon sisältyy sovellukset/visualisointi, kentällä hyödynnettävät alustat/visualisointi ja sovellukset.

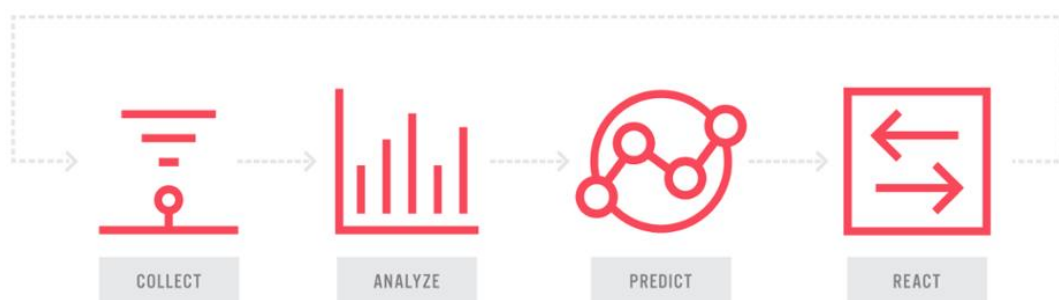


KUVIO 23. PdM:ää ohjaavat teknologiat (Coleman ym., 2017)

4.4 Esimerkkejä ennakoivan kunnossapidon ratkaisuista

4.4.1 Acme Industrial

Acme Industrialin tarkoituksena on parantaa sisäisiä prosesseja ja monitoroida laitoksiensa kuntoa. Järjestelmän tarkoituksena on generoida hälytys, jos luvassa on ongelmia. Lisäksi järjestelmä kykenee määrittelemään laitoksiensa kunnan PdM:ää hyödyntäen, sillä PdM:llä on tarvittava informaatio laitoksen tiloissa sijaitsevien laitteiden tilasta. KUVIO:sta 24. havainnollistuvat avainkomponentit, jotka Acmen tulee toteuttaa luodakseen toimivan PdM:n. Avainkomponentit ovat kerääminen (collect), analysointi (analyze), ennakointi (predict) ja reagointi (react). (Foxworth, 2017.)



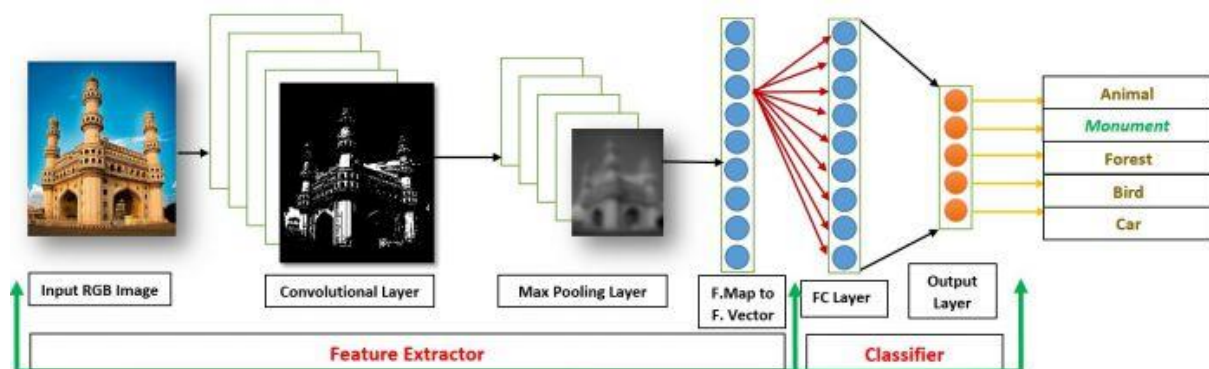
KUVIO 24. Acmen neljä avainkomponenttia PdM:n toteutukseen (Foxworth, 2017)

Ensimmäinen avainkomponentti on kerääminen. Acme:lla on tuotantolaitoksissaan tuhansia koneita ja ongelmia tunnistessaan Acme joutuu hyödyntämään vibraatioanalyysiä. Vibraatioanalyysi on tehokas useimmissa pyörivissä laitteissa, joita useimmat laitoksien koneista sisältävät. Vibraation laskemiseksi asennetaan kiihtyvyyssantureita jokaiseen koneeseen, jotka sitten lähettävät vibraatiodataa pilvipalveluun. (Foxworth, 2017.)

Analysointivaiheessa Acmen tehtävänä on määrittellä parametrit, joiden avulla voidaan päätellä, milloin koneet toimivat ja milloin eivät. Koneoppimisen avulla ei kuitenkaan voida automaattisesti ennustaa ongelmia tai anomalia datasta, vaan tilannetta voidaan lähestyä kysymyksen tai ongelman näkökulmasta. Voidaan esimerkiksi kysyä: ”onko mahdollista tunnistaa koneen tai laitteen todennäköinen vikaantumisen lähitulevaisuudessa?”. Kysymyksen asettaminen on kuitenkin luokittelijaongelma yrityksen ollessa kiinnostunut enemmän diskreeteistä vastauksista aineistossa, kuten vastauksen etsimisestä kysymykseen: ”onko koneen tai laitteen toiminta normaalia?” tai ”onko koneen tai laitteen vikaantumisen todennäköistä?”. (Foxworth, 2017.)

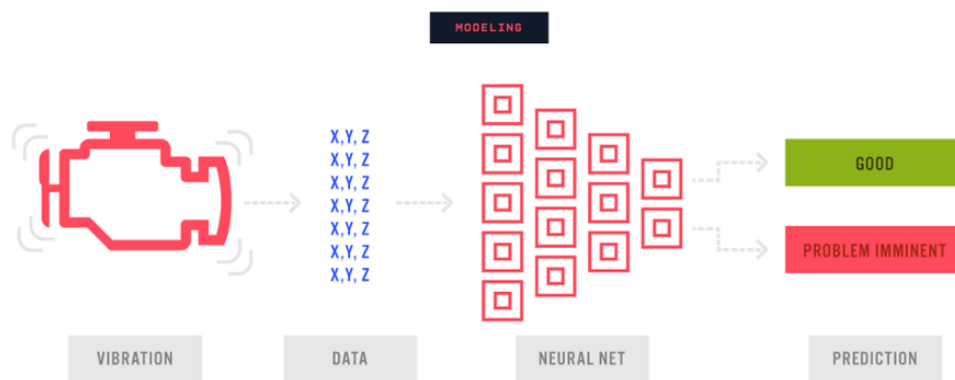
Vikaantumisen määrittämisessä on tärkeää kerätä riittävästi esimerkein kuvattua dataa, jonka perusteella on mahdollista oppia, milloin laite tai kone toimii normaalisti ja milloin se on vikaantumassa. Toimiva strategia on kerätä dataa kaikilta koneilta tai laitteilta, jotka toimivat normaalitilanteissa. Koneen tai laitteen vikaantuessa dataa voidaan ottaa talteen tietyn ajanjakson aikana ennen vikaantumista. Tästä kyseisestä datasta syntyy aineisto, jota voidaan käyttää vikaantumisen ennustamiseen. (Foxworth, 2017.)

Kuvan luokittelussa voidaan hyödyntää konvoluutioneuroverkkoja (CNN). Tyypillisen kuvan luokittelijamallin havaitessa kuvan (KUVIO 25), siitä muodostuu pitkä lista numeroita. Numerot voidaan sitten hajottaa osajoukoiksi, jotka kuvaavat kuvapikselin R (red), G (green) ja B (blue) arvoja. Seuraavaksi malli tunnistaa, mikä tai mitkä kuvapikselit kuvassa määrittävät, löytyykö kuvasta haluttu vastaus kysymykseen vai ei. (Foxworth, 2017.)



KUVIO 25. Konvoluutioneuroverkon hyödyntäminen kuvan luokittelussa (Sigh, 2017)

Koneen tai laitteen vikaantumisen tunnistaminen korreloi suoraan kuvan luokittelijaongelman kanssa. Acmen keräämästä vibraatiostatista jokainen kiihtyvyyssanturi tuottaa X, Y, Z-arvoja, jotka ovat samankaltaisia kuin R, G, B. Hyödyntämällä konvoluutioneuroverkkoja (KUVIO 26) voidaan samalla tapaa tunnistaa, mitkä vibraatioparametrit määrittävät laitteissa tai koneissa esille tulevia ongelmia tai todennäköistä vikaantumista. Tämä tosin vaatii lisäksi vielä opettamisen, joka voidaan toteuttaa pilvipalvelussa. Menettelyn jälkeen ja tätä metodia hyödyntämällä voidaan suurella todennäköisyydellä löytää kerätystä aineistosta todennäköisesti vikaantuvat koneet tai laitteet, jolloin yritys voi toteuttaa korjaavia huoltotoimenpiteitä ja lopulta laskea koko laitoksessa tai kiinteistössä olevien laitteiden tai koneiden niin sanotun ”terveydentilan”. (Foxworth, 2017.)



KUVIO 26. Neuroverkon hyödyntäminen ongelmien ennakoinnissa (Foxworth, 2017)

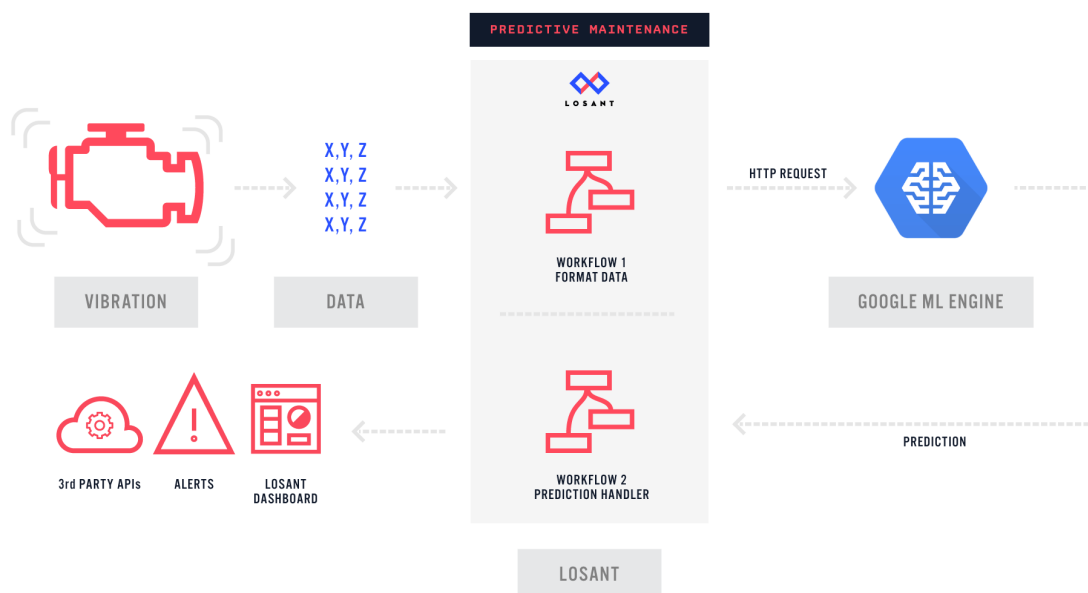
Ennakoivan kunnossapidon toteutus vaatii automatisoitua prosessia datan keräämisestä päätöksen tekoon. Ennakointijärjestelmän toimiessa, on tarpeen käyttää reaktiomootoria päätöksentekoa ja tiedonantoilmoituksia varten. Koneen tai laitteen lähettäessä vibraationäytteen mallille, malli voi päätellä, toimivatko ne normaalisti vai onko vikaantuminen todennäköistä. Normaalitytilanteissa toimenpiteitä ei tarvita, mutta vikaantumistilanteissa, luodaan ilmoitus tarvittaville sidosryhmille. (Foxworth, 2017.)

Acmen ratkaisuna ongelmaan on hyödyntää Googlen Cloud Machine Learning (Google Cloud ML) pilvipalveluun toteutettua Googlen koneoppimista ja Losant IoT-alustaa. Google ML-moottori (KUVIO 27) tukee opetusta ja TensorFlow-mallien asentamista pilvipalveluun. TensorFlow-neuroverkkojen opettamisen jälkeen se opetetaan tunnistamaan koneiden tai laitteiden vikaantumista. Opettamisen jälkeen voidaan malli asentaa ja sitä voidaan hyödyntää vikaantumisen ennakoinnissa. (Foxworth, 2017.)



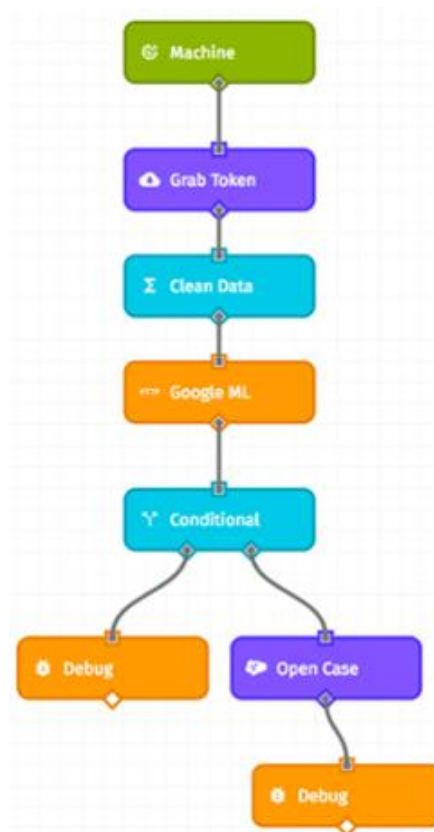
KUVIO 27. TensorFlow-neuroverkon opettaminen ja ennakoiva malli (Foxworth, 2017)

Tietokoneeseen liitetty laitteisto lähettää vibraationäytteen (KUVIO 28) Losantille säännöllisin väliajoin ja Acmen sovellus Losantissa sisältää työnkulun (workflow), joka ottaa näytteen vastaan muokaten dataa ja lähettää HTTP-kutsun Google ML-moottorille suoraan API-rajanpinnan kautta. Google ML-moottorin datan käsittelyn jälkeen saadaan ennuste ja voidaan toteuttaa sen perusteella jatkotoimenpiteet. (Foxworth, 2017.)



KUVIO 28. Vibraationäytteen lähettäminen korjaustarpeen ennakointi (Foxworth, 2017)

KUVIO:sta 29. havainnollistuu kaaviona ennakoinnin ketju ja lopulta positiivisen tuloksen esille nostama Salesforce-ilmoitus, jonka perusteella jatkotoimenpiteisiin voidaan ryhtyä. (Foxworth, 2017.)

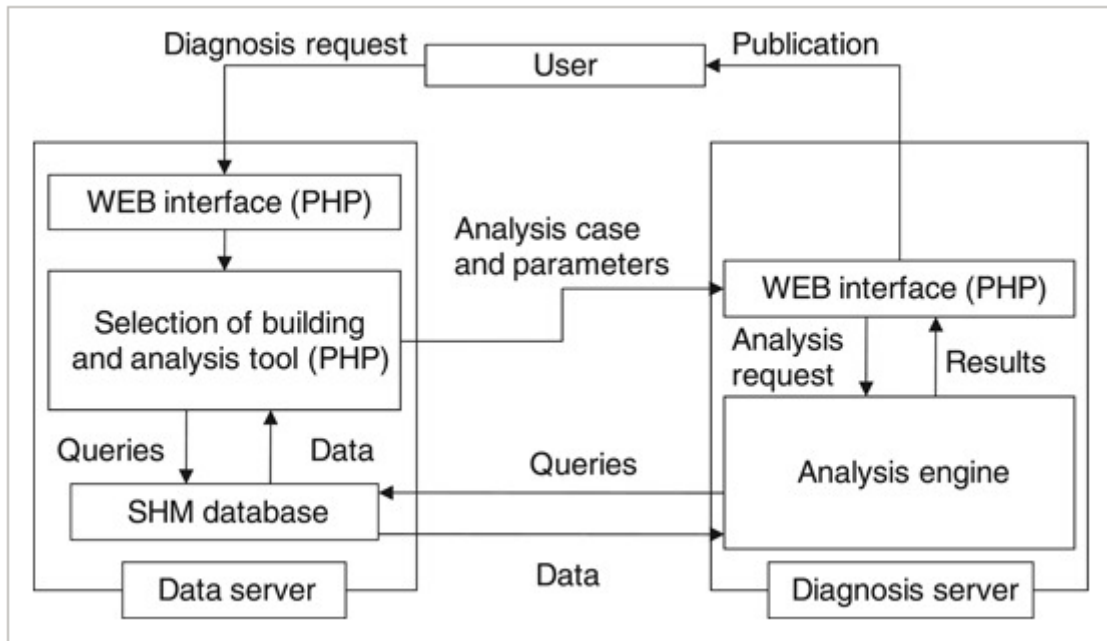


KUVIO 29. Salesforce-tiketin aukeaminen korjaustarpeen ilmaannuttua (Foxworth, 2017)

4.4.2 SHM-platform ja älykäs sensori


Mita-laboratorioissa Keion yliopistossa on tutkittu jo pitkään kehitysalustaa, joka pyrkii yhtenäistämään eri SHM -tekniikoissa käytettyjä datamalleja tarjoamalla kerätyn datan standardissa formaatissa muovautuvalla datamallilla. Järjestelmässä on kolme osaa:

1. Älykkäät sensorit, jotka keräävät dataa varastoon automaattisesti ja joiden parametreja voi muokata internetin välityksellä. Sensorit välittävät datan annetulle serverille, joka siirtää sensorin kokoonpanolistauksen ja mittaustulokset automaattisesti tietovarantoon XML-muodossa. Mittaukset tapahtuvat säännöllisin väliajoin, mutta manuaalinen mittaus on myös mahdollinen.
2. Tietovarasto.
3. Diagnosointivälineet, joita voi käyttää internetin välityksellä. Diagnosoinnissa käytetään ARX mallia, josta tehtiin automaattinen.



KUVIO 30. Kaaviokuva SHM-alustan käytöstä (Mita ym., 2010, 795)

Kehitysalustan toiminta on esitetty KUVIO:ssa 30. ja se toimii seuraavasti: Käyttäjä valitsee haluamansa asetukset (kuten mikä mittaus) ja lähettää diagnosointipyyntönsä käyttöliittymän kautta internetissä. Data serveri suorittaa datan etsinnän ja tallennuksen. Diagnosointiserveri kysyy mittausarvot tietokannasta ja suorittaa automaattisesti mittausten analysoinnin. Käyttäjä saa näkymästä näkyviin diagnosointiserverin piirtämät kuvaajat. Kehitysalustalla voi olla useampia käyttäjiä samanaikaisesti ja sen välityksellä sensoreita voi opastaa suorittamaan mittauksia automaattisesti tietyin väliajoin, pakottaa mittaus alkamaan välittömästi, lisätä mittausdataa tietokantaan ja suorittaa datan analysointia. (Mita ym., 2010, 795.) KUVIO:ssa 31. on esitelty pilvenpiirtäjien värähtelymittauksissa käytettyjä älysensoreita.

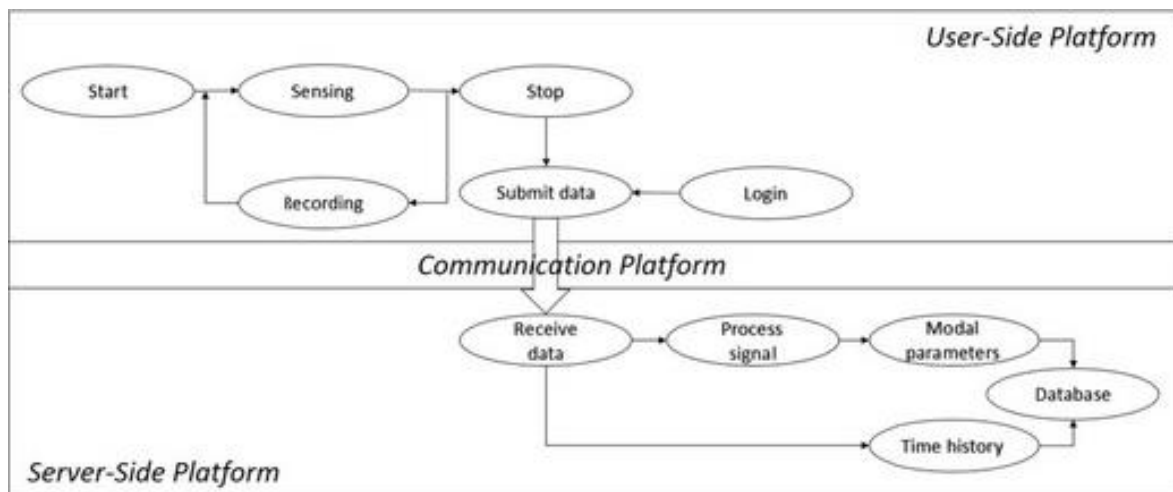


KUVIO 31. Pilvenpiirtäjien värähtelymittauksissa käytettyjä älysensoreita (Mita ym., 2010, 795)

4.4.3 SHM-datan keräys vapaaehtoisten avulla

Yhdysvaltain Columbian yliopistossa on tutkittu SHM:ää hyödyntämällä vapaaehtoisia kansalaisia. Kansalaiset, joilla on ollut iPhone-merkkinen puhelin, ovat voineet ladata yliopiston kehittämän mittausohjelman ja lähettää sen avulla ottamansa värähtelymittaukset erityisesti tähän tarkoitukseen tehdyille serverille. Näistä mittauksista tutkijat ovat voineet selvittää rakennusten värähtelymoodeja. (Ozer ym., 2015, 14591.)

Tutkijat testasivat vapaaehtoisten avulla millaisia värähtelyjä 11 metriä pitkältä sillalta voi saada heidän iPhone-merkkisten puhelimiensa avulla. Tutkimus suoritettiin siten, että vapaaehtoinen latoi puhelimelleen ohjelman Citizen Sensors for SHM ja käynnisti sen ollessaan jossakin kohdassa tutkittavaa siltaa. Mittaus alkoi, kun käyttäjä kosketti start-painiketta. Ohjelma suoritti vibraatio-mittausta, kunnes käyttäjä painoi samaa painiketta uudelleen. Käyttäjä pystyi sitten yksinkertaisen käyttöliittymän avulla kirjautumaan internet-palveluun ja lataamaan sinne valitsemansa datan. Mittaustulokset pystyttiin lataamaan internetsivulle myös käyttäjän itse valitsemallaan tavalla ja valitsemanaan aikana. Serveri otti vastaan käyttäjien mittaustulokset ja talletti ne SQL-tietokantaan. Lisäksi serveri muokkasi ja etsi aikajanalta taajuuksien huiput ja tallensi nekin tietokantaan. Keräysalustan toimintamalli on esitetty KUVIO:ssa 32. Lopulta tutkijat vertasivat käyttäjiltä saatuja tuloksia sillalle tasaisin välein asennettujen kuuden värähtelysensorin mittaamaan dataan. (Ozer ym., 2015, 14591.)



KUVIO 32. Keräysalustan toimintamalli (Ozer ym., 2015, 14591)

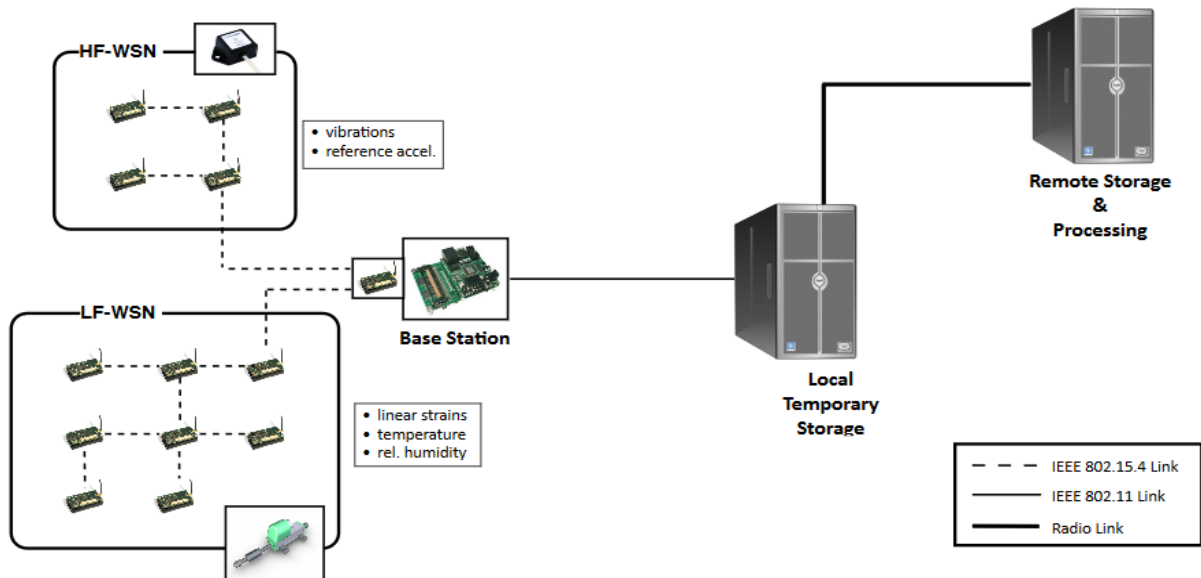
Uusimmilla puhelimilla suoritettujen mittausten tulokset olivat hyvinkin tarkkoja, mutta vanhempien puhelinten tulokset sisälsivät herkästi liikaa melua. Tutkijat uskovat, että SHM:ssä voidaan hyödyntää useilta vapaaehtoisilta saatua dataa, vaikka mittaustuloksiin liittyikin hieman epävarmuutta. Seuraavaksi ohjelmasta olisi tarkoitus tehdä muille puhelinmerkeille soveltuva ohjelma, jotta mahdollisia vapaaehtoisia saataisiin lisää. Yhtenä keräämisen haasteena on saada lisää mittaajia ja pitää ihmiset kiinnostuneina

joukkomittauksista. Eräs ratkaisu voisi olla ohjelman muokkaaminen pelillisemmäksi. (Ozer ym., 2015, 14591.)

4.4.4 Historiallisen rakennuksen SHM


Anastasin, Lo Ren ja Ortolanin projektin tarkoituksena oli luoda ohjelma vastaamaan rakenneinsinöörien (Structural Engineering eli SE) tarpeita. Ohjelmalla oli tarkoitus tarkastella ennestään tuntemattoman rakennelman käyttäytymistä. Koska restaurointitöissä käytetyt tekniikat ja materiaalit voivat johtaa siihen, että rakennelma käyttäytyy eri tavoin kuin alkuperäinen rakennelma, täytyy kunnostettua rakennelmaa monitoroida sensorein. Rakennelman "tuntemattomuus" poistetaan luomalla malli sensoridatan pohjalta, mikä voi suuresti helpottaa vastaavien kunnossapitäjien tehtävää. Käyttäjä voi lisäksi jokseenkin säädellä mallin parametreja haluamallaan tavalla tarkastellakseen rakennelman käyttäytymistä eri tilanteissa. (Anastasi ym., 2009.)

Projektissa on kehitetty langaton sensoriverkkojärjestelmä (Wireless Sensor Networks eli WSN), jonka etuihin kuuluu reaaliaikaisuus, tunkeilemattomuus, halpa hinta, muokattavissa oleva datan keräys- ja analysointijärjestelmä. Käytössä olevia sensoreita on kahdenlaisia: HF-WSN ja LF-WSN. Toiset ovat korkean taajuuden sensoreita ja toiset vastaavasti matalan taajuuden sensoreita. HF-WSN-tyypin sensoreilla on lisävirtalähteet asennettuna yhteyteensä, sillä vibraation lähes jatkuva mittaaminen kuluttaa paljon energiaa. LF-WSN-tyypin sensorit mittaavat esimerkiksi lämpötilaa ja suhteellista kosteutta. KUVIO:sta 33. voidaan huomata, että sensorit välittävät datan langattomasti väliyksikölle, joka alustavasti käsittelee dataa, kuten datan pakkaus pienemmäksi, ja lopuksi lähettää sen lokaalille palvelimelle. Lokaali-palvelin toimii välivarastona, mikäli se ei saa luotettavasti radioyhteyttä toimivalle pidemmän säilytyksen palvelimelle. Tämä pidemmän säilytyksen palvelin on tietokanta, jossa varsinainen datan säilytys, käsittely ja visualisointi tapahtuvat. Käyttäjät voivat sitten tarkastella internetissä toimivan GUI:n välityksellä esimerkiksi kuinka sensoreita on sijoiteltu tarkasteltavaan kohteeseen, mikä on sensoreiden mittaustaajuus, mitä aiemmin on tutkittu, miten rakennus käyttäytyy kullakin hetkellä, onko tullut hälytyksiä, millaisia hälytyksiä on tullut tai millaisia hälytyksiä ohjelma voi jonkin tilanteen sattuessa lähettää tai tutkia kerättyä dataa analysointityövälinein ja tallentaa saadut tulokset tietokantaan. (Anastasi ym., 2009.)



KUVIO 33. Järjestelmän toimintamalli (Anastasi ym., 2009)

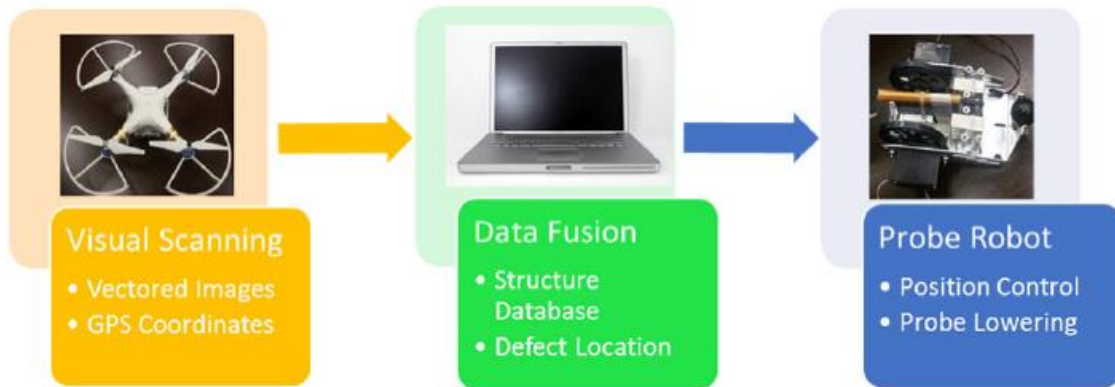
Ohjelman prototyyppiä testattiin Italian Palermossa sijaitsevassa kirkossa nimeltä St. Theresa, joka oli kärsinyt vahinkoja pienessä maanjäristyksessä vuonna 2002. Mittausasettelua esittää KUVIO 34. HF-WSN-tyypin sensoreita oli viritetty yksi kappale kirkon kupoliin ja toinen vastaava sensori oli viritetty ullakolle vakaimpaan kohtaan. Tarkoitus oli mitata rakennuksen kokemaa värähtelyä, joka voisi johtua luonnonoloista tai voimakkaasta liikenteestä. Ajatus oli, että jos kupolin vibraatiosensori kokee asetetun rajan ylittävää värähtelyä aiheuttaa se hälytyksen mihin ullakolla sijaitseva sensori reagoisi. Ullakon sensori toimisi näin referenssinä, kun molempien sensorien dataa lopulta tutkittaisiin. Ullakolla tiedettiin olevan myös muutama heikko kohta, joten näihin kohtiin viritettiin LF-WSN-sensorit, joiden oli tarkoitus mitata rasitetta sekä lämpötilaa ja suhteellista kosteutta. LF-WSN-sensorit keräsivät kymmenen mittausta 15 minuutin väliajoin ja lähettivät keskiarvostetun tuloksen paikalliselle serverille. (Anastasi ym., 2009.)




KUVIO 34. St. Theresan SHM-järjestelmä (Anastasi ym., 2009)

4.4.5 Drone ja robotteja SHM:ssä

Qatarissa tutkijat ovat kehittäneet robottia, joka hyödyntäisi kuvananalysointialgoritmeja. Tarkasteltavan kohteen mittaus on tarkoitus suorittaa niin, että robotti toimii yhdessä dronen, eli miehittämättömän ilma-aluksen, ja serverin kanssa. KUVIO 35. esittelee tätä mittauksen pääkomponenttien toimintajärjestystä. Drone nousee tavoitekorkeuteensa pitäen samalla nousupisteensä ja kohtisuoran etäisyytensä rakennukseen samana. Se suorittaa kaksi skannausta mitattavasta kohteesta. Kuvista nivotaan kaksi pintakuvaa (stitched surface images), jotka laitetaan samaan linjaan. Koska kuvat ovat sidoksissa dronen nousupisteen koordinaatteihin ja ne ovat samassa asennossa, niille voidaan suorittaa vektorilaskentaa joka paljastaa mahdolliset poikkeamat. Dronen ottamien kuvien avulla robotti voi laskea sondinsa, eli pienen robottinsa, talon katolta seinämää pitkin ja tarvittaessa korjata omaa tai sondin paikkaa. Kaikki data kuvista sekä lasketuista koordinaateista välittyy langattomasti serverille. Talon katolla oleva älykäs vinssirobotti ottaa vastaan lasketut koordinaatit ja liikkuu tarvittaessa kohti mitattavaa kohtaa. Tämä robotti on esitetty KUVIO:ssa 36. Robotti osaa automaattisesti kiertää mahdolliset esteet, jotka se havaitsee ultraäänianturin avulla. GPS:n lisäksi robotissa on kompassi, joka helpottaa sen suunnistusta kohteeseen. Robotti on varustettu vinssinosturilla. Varsinainen mittaus tapahtuu sondin avulla. Tämä robotti mittaa MFL-tekniikan (Magnetic Flux Leakage) avulla mahdollisia poikkeamia metallisessa rakennuksessa noin oman kokoisensa pinnan alueelta. Robottiin on asennettu vahvat magneetit, jotka yhdessä robotin liikkeen kanssa muodostavat jännitteen johtavan materiaalin pintaan. Mikäli materiaalissa on poikkeamia, on jännitekin poikkeava. Robotin Hall-sensorit havaitsevat tällaiset poikkeamat. (Qidwai ym., 2017, 299.)



KUVIO 35. Data siirtyy dronelta serverin kautta robotille (Qidwai ym., 2017, 299)



KUVIO 36. Vinssirobotti, joka osaa automaattisesti kiertää esteitä (Qidwai ym., 2017, 299)

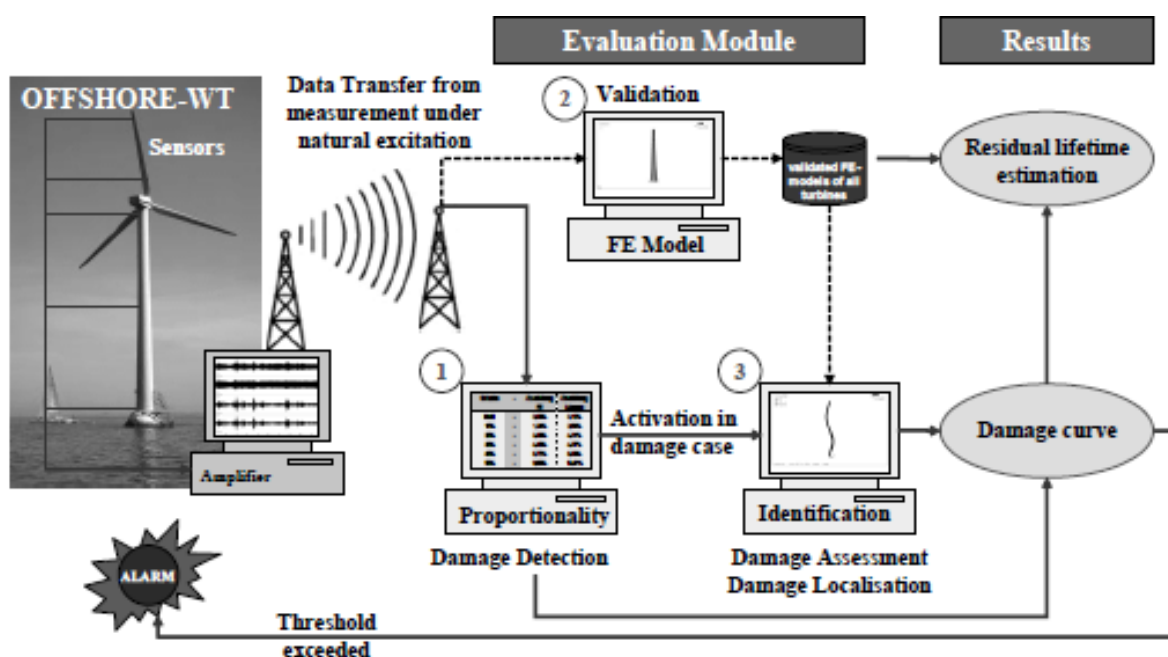
Koska robotti on riippuvainen GPS:stä, sitä ei voi käyttää sisätiloissa. Ulkona korkeat rakennukset voivat haitata robotin liikkumista osittain peittämällä robotin yhteydensatelliitteihin. Tutkimuksen robotti tarvitsee neljän satelliitin yhteyden voidakseen liikkua luotettavasti (satelliittien avulla lasketaan keskiarvoistetut koordinaatit). Koordinaattien keskiarvoistaminen vähentää heijastavien pintojen takia syntyvää useiden reittien häiriötä (multi-path interference), mikä johtaa epätarkkuuteen robotin reitissä. KUVIO:ssa 37. on karttakuvaan esitetty robotin liikkeentestauksesta saadut tulokset. Sinisellä värillä esitetty reitti on robotin kulkema reitti keskiarvoistetuista koordinaateista. Ero on paikoin huomattava verrattuna punaisella värillä merkittyyn reittiin, missä koordinaatteja ei ollut keskiarvoistettu. (Qidwai ym., 2017, 299.)



KUVIO 37. Keskiarvoistamisen vaikutus reitissä (Qidwai ym., 2017, 299)

4.4.6 Tuuliturbiinien SHM

Tuulivoimaturbiinien huoltotaukojen vähentäminen ja huoltotaukojen pituuden lyhentäminen ovat osa keinoja, joilla tavoitella maksimaalista tuottoa. Oikeaoppisesti harjoitetulla SHM:llä on mahdollista pitää tuulivoimalaitoksen käyttöaste mahdollisimman korkeana koko voimalaitoksen kaavaillon elinkaaren aikana. Siksi sinne kannattaa sijoittaa automaattinen rakenteen kunnossapito- ja valvontajärjestelmä. (Rolfes, ym., 2007, 1.)



KUVIO 38. Tuulivoimalaitoksen SHM-järjestelmän rakennekuva (Rolfes, ym., 2007, 1)

Leibnizin yliopiston tutkijat ovat suunnitelleet integroitua SHM-järjestelmää, jota voisi käyttää merelle rakennettavissa tuulivoimalaitoksissa. KUVIO:ssa 38. on esitelty tutkijoiden käyttämän kunnonvalvontajärjestelmän toimintakaaviota, jonka varsinaista toimintaa kokeiltiin kuitenkin maalla sijainneisiin kahteen tuuliturbiiniin. Varsinaisessa järjestelmässä on kaksi rasiusmittaria, kahdeksan kiihtyvyyksmittaria ja viisi langatonta sensoria. Langattomat sensorit alkukäsittelevät mittareiden dataa ennen kuin lähettävät sen varsinaiseen analysointijärjestelmään. Järjestelmän toiminta on jaettu kolmeen laskentaosaan, joita kutsutaan moduuleiksi. Ensimmäinen moduuli selvittää maksimi rasiuksen ja maksimi nopeuden sekä laskee näiden perusteelta, onko rakennelman jäykkyydessä havaittavia muutoksia. Moduuli kaksi laskee ominaistaajuudet ja parametriseoi rakennemallin. Sitä käytetään tulosten oikeellisuuden arviointiin FE-mallin (Finite Element, FE) perusteelta. Moduuli kolme laskee muiden moduuleiden pohjalta rakennelman kokeneen vaurion suuruuden ja päättelee FE-mallin avulla poikkeaman paikan suhteessa rakennelmaan. Rakennuksen tilanteesta päivittyvä arvio jäljellä olevasta tuuliturbiinin käyttöiästä. Mikäli jokin ennalta-asetettu kynnyksiarvo ylittyy, on suositeltavaa lähettää korjaustiimi paikalle. (Rolfes, ym., 2007, 1.)

4.4.7 Ultraääniämittaava drone

Dronejen yleistyminen on innostanut tutkijat kehittämään lennokkia, joka voisi suorittaa ultraääni- tai pyörrevirtausmittauksia öljynjalostamoissa. Dronella on tarkoitus kiinnittää sensori rakennuksen kylkeen, joka suorittaa varsinaisen mittauksen. Tällainen on uusinta uutta perinteisten kunnossapitomittauksien saralla, sillä muissa droneilla tehtävissä tutkimuksissa on keskitytty vain kohteen visuaaliseen tarkasteluun. Tällä mittauskeinolla on mahdollista saada tietoa rakenteen kunnosta eri tavalla vahingoittamatta rakennetta. Lennokkien käyttäminen öljynjalostamoilla nopeuttaa tarkastustoimenpiteitä ja tekee niistä turvallisempia, kun korkeiden paikkojen tarkastusta varten ei tarvitse kasata telineitä taikka kiinnittää kiipeilyköysiä tarkastuksen manuaalista tekijää varten. (Mattar ym., 2018, 1.)

KUVIO:ssa 39. on esitelty dronen rakenne. Dronen runko on Y:n mallinen ja siinä on kolme propellia, joista yhtä on mahdollista käänellä. Sensorit se kiinnittää rakennuksen seinään varrella työntyessään kohti seinää. Varressa on varren ja sensorin välillä jousitus, jotta sensoria ei työnnettäisi liian suurella voimalla seinään. Sähkömagneetit avittavat sensorin asettelussa tasaisesti seinää vasten ja ne voi kytkeä päälle tai pois päältä. Ultraäänisensori lähettää aaltoja 2,25 MHz:n taajuudella, joiden heijastumasta voidaan laskea öljynjalostamon seinän paksuus sensorin pinta-alalta 0.1 mm:n tarkkuudella. Data välitetään suoraan tietokoneelle, josta sitä voi seurata reaaliajassa. (Mattar ym., 2018, 1.)

Tutkijat testasivat mittausjärjestelmän toimintaa suorittamalla kymmenen lentomittausta raakaöljytankille yhdellä akulla. Drone aloitti lennon maasta nousten suoraan ylöspäin. Mittauskorkeuden saavutettuaan ja ollessaan riittävän lähellä seinää dronen lennättäjä käynnisti sähkömagneetit. Osuessaan seinään sensori alkoi automaattisesti tekemään ultraäänimittauksia. Mittaustulokset saatuaan dronen lennättäjä sammutti sähkömagneetit, jolloin sensori ja drone irtosivat seinästä. Jokainen lento vei noin 20 sekuntia ja jokainen mittaus onnistui tuulennopeuden ollessa hieman alle 10m/s. (Mattar ym., 2018, 1.)



KUVIO 39. Lennokilla on suojat propelliensa ympärillä (Mattar ym., 2018, 1)

4.4.8 SHM-visualisointikeinoja 3D:ssä

Erilaisia 2D- ja 3D-visualisointitekniikoita on käytössä SHM:ssä. 2D-tekniikoiden on todettu säästävän aikaa, rahaa ja olevan tietorakenteellisesti helpompia kuin 3D-tekniikoiden. Koska dataa käyttävien ihmisten taustoissa on eroavaisuuksia, joiden takia kunnossapitojärjestelmän toiminnassa voi esiintyä puutteita, informaatio voi jäädä ymmärtämättä tai järjestelmä voi jäädä kokonaan käyttämättä. Tutkijoiden mielestä tästä syystä 3D-tekniikoihin pitäisi panostaa. Lisäksi uusien sensortekniikoiden myötä informaation kuvantaminen voi muuttua entistä hankalammaksi perinteisin 2D-keinoin. (Napolitano ym., 2018, 1.)

Erilaisia SHM:ssä käytettäviä 3D-tekniikoita ovat esimerkiksi fotogrammetria (engl. photogrammetry), laserskannaus (engl. laser scanning) ja rakenteen informaatiomallinnus (Building Information Modeling, BIM). Fotogrammetriassa ja laserskannauksessa luodaan skaalautuvia kolmiulotteisia pisteparvia, jotka kuvaavat rakenteita. Toisessa pisteparvien luonti tapahtuu 2D-kuvista, joita on oltava paljon 3D-mallin tarkkuuden takaamiseksi ja toisessa laserilla mitataan rakennuksen jokaisen pisteen etäisyyksiä laseriin. BIM puolestaan mahdollistaa rakennuksen osien datan samanaikaisen tarkastelun. (Napolitano ym., 2018, 1.)

Tutkijat kehittivät ohjelman, jolla voitiin tarkastella Streicker Bridge-sillan SHM-dataa interaktiivisesti. Sillasta otettiin 27 pallomaista panoraamakuvaa sillan eri kohdista RICOH THETA S-kameralla, joka muodosti kuvista automaattisesti panoraamakuvia. Kuvista poistettiin kameran jalusta Photoshop-kuvankäsittelyohjelmalla, jotta se ei häiritsisi mallin lopullisten käyttäjien käyttäjäkokemuksia. Panoraamakuvista tehtiin virtuaalikierron (Virtual Tour, VT), jossa käyttäjä pystyi liikkumaan mallissa hiirenpainalluksilla eri kohtiin siltaa ja sillan alle. Liikkumiseen mallissa oli kehitetty myös vaihtoehtoisiksi tavoiksi Google Maps-kartta sekä pudotusvalikko, josta pystyi valitsemaan minkä tahansa siltaan sijoitetun sensorin. Sensorit olivat merkittävänä kuviin ja niiden tilaa kuvasi värikoodisto. Sensorin yllä pysytellessään hiirellä käyttäjä pystyi näkemään mistä sensorista oli kysymys ja sensorin klikkaaminen toi esiin sensorin aikasarjatiedoston tietokannasta. KUVIO:ssa 40. on havainnollistettu tätä. Ohjelmalla sai tietokannasta myös halutessaan muita tietoja, kuten rakenteen tekniset tiedot, sensorien asettelun ja tekniset kuvat, SHM-järjestelmän metadatan, käsittelemättömän mittausdatan ja erilaisia graafeja. Koska ohjelma hyödynsi informaatiomallinnusta (Information Modeling, IM), on kyse VT- ja IM -tekniikoiden yhdistelmästä eli VT/IM-tekniikasta. (Napolitano ym., 2018, 1.)



KUVIO 40. Käyttäjän saama näkymä VT/IM-ohjelmasta (Napolitano ym., 2018, 1)

Tutkijat testasivat VT/IM-ohjelmaansa Princeton-yliopiston SHM-kurssin käyneiden opiskelijoiden avulla, jotka ymmärsivät SHM:n termistön ja käsitteet, mutta heillä ei ollut käytännön kokemusta. Opiskelijat vastasivat lyhyeen kyselytutkimukseen ohjelman kokeilun jälkeen ja kyselytutkimuksen tulokset olivat hyvinkin positiivisia. Useimpien mielestä ohjelmasta oli hyötyä tarkasteltaessa siltaa ja pyrittäessä ymmärtämään sen ominaisuuksia. Ainoana selvänä ongelmana oli koettu klikkaamalla siirtyminen sillan päältä sillan alle ja sen parannusehdotuksena oli kyseisen liikutteluikonin muuttaminen erinäköiseksi kuin muut liikutteluikonit. Tutkijat listasivat tekniikan muiksi hyödyiksi sen suhteellisen nopean valmistustekniikan verrattuna muihin 3D-mallinnustekniikoihin. Tämän mallin kuvien ottamiseen kului tekijältään tunti, mutta CAD-mallin tekemiseen kului jopa 12 tuntia. (Napolitano ym., 2018, 1.)

4.4.9 Pikainen visuaalinen tarkastus ortokuvista

Yhdysvalloissa tornadojen ja hurrikaanien jälkeen talojen ulkosivut ja ulkosivuille kiinnitettyjen ilmastointilaitteiden ulko-osien kunto ja kiinnitys on tarkistettava lisävahinkojen varalta ennen kuin rakennus voidaan ottaa uudelleen käyttöön. Tämän hetkisten säännösten mukaan tarkastajan on käytävä paikan päällä ja visuaalisesti tarkistettava jokaisen rakennuksen ulkosivut ja kirjattava havaitut vahingot rakennuksesta tehtyyn malliin, mikä on usein liian aikaa vievää hätätilanteen jälkeen. Koska säännökset eivät määrittele yhtenäistä standardia, jonka perusteella visuaalisen tarkastelun voi tehdä, kehittivät Purdue University – yliopiston mekaanisen rakentamisen sekä maa- ja vesirakentamisen yksiköiden tutkijat metodin, jolla dronella otetaan ortokuvia (orthophoto) julkisivusta (Choi, Yeum, Dyke, Jahanshahi, Pena & Park, 2018). Choi & ym. (2018) ovat julkaisseet artikkelinsa Creative Commons CC_BY_NC licence -lisenssillä (<https://creativecommons.org/licenses/by-nc/4.0/>).

Ortokuva tarkoittaa rakennuksen pinnasta luotua kuvaa, joka on luotu monista kuvista ja jonka dimensiot vastaavat todellisen rakennuksen muotoja. Ortokuva luodaan ottamalla lennokilla kuvia läheltä rakennuksen ulkopintaa. Kuvia otetaan tiheään tahtiin lennokin lentäessä ennalta määrättyä tasaista reittiä pitkin ja näistä lennokin ottamista kuvista muodostetaan rakennemalli liikkeestä- algoritmeilla (SfM, Structure-from-Motion). SfM-algoritmin jälkeen kuvia vielä yhdistellään ja tasoitellaan mistä muodostuu varsinainen korkealaatuinen ortokuva (Choi & ym., 2018).

Tutkijat testasivat prosessinsa toimintaa ottamalla 137 metriä pitkistä ja 16 metriä korkeasta testirakennuksesta droneen (3DR Solo Quadcopter) kiinnitetyllä kevyellä kameralla (Canon PowerShot SX280 HS) kuvia. Drone ohjattiin lentämään neljästi testirakennuksen ulkoseinämän viertä ja ottamaan kuvia joka lennolla hieman eri kuvakulmasta, jotta kuvia voisi lopulta tarkastella riittävän yksityiskohtaisesti ja että kuvat varmasti menisivät toistensa päälle. Mittauksessa käytetty kameran kuvausnopeus oli 1 kuva/s ja dronen nopeus oli alhainen, jolloin kuvien päällekkäisyys oli yli suositellun 75 %:ia. Otetut 1520 kuvaa käsiteltiin ensin VisualSfM ohjelmalla, mikä laski tarvittavat projektiomatriisit

rinnakkaislaskentakirjastonsa avulla. Projektimatriiseista ja kuvista rakennuksen tason tunnistaminen ja raskas ortokuvan muodostaminen tapahtui MATLAB-ohjelmalla (Choi & ym., 2018).

Ohjelman käyttäjällä on mahdollisuus nähdä todellisuutta hyvin vastaava kuva rakennuksesta. Kehitetyllä tekniikalla on myös mahdollista tarkastella kuvien mielenkiintoisia kohtia klikkaamalla kyseistä kohtaa ortokuvasta. Ortokuvan muodostaminen on laskennallisesti vaativampi tehtävä kuin rakennuksen tunnistus kuvista ja projektimatriisien muodostus osin siksi, että kuvasta tulee hyvin iso. Ongelmia tekniikkaan lisää mahdolliset kameran ja rakennuksen väliin jäävät esteet, kuten puut ja pensaat, joita tutkijat eivät pystyneet täysin karsimaan mittauksen aikana. Näköesteiden aiheuttaman häiriön takia tutkijat suosittelivat useampi ohilentoja eri etäisyyksiltä rakennuksesta. Tutkimus havaittiin, että kyseisen alueen varsinaisen mittauksen suorittaminen vaati vain noin 20 minuuttia, ja ortokuvasta pystyi havaitsemaan rikkoutuneet, haljenneet ja puuttuvat ikkunat (Choi & ym., 2018).

4.4.10 Lastausten ja halkeamien paikantaminen betonirakenteesta

BAM:n (Bundesanstalt für Materialforschung und –prüfung) tutkijat selvittivät käytännön kokeessa 24.4 metriä pitkän vahvistetun betonipalkin halkeamien paikantamista koda-aaltohäiriömittauksella (Coda Wave Interferometry, CWI). Seismologiassa harjoitettavassa CWI tekniikassa käytetään aaltoja, joiden taajuus on yli 50 kHz:iä. Tämä mahdollistaa rakenteen tarkemman tarkastelun, sillä tällöin aaltojen aallonpituus on lyhyempi kuin itse rakenteen (esimerkiksi tyypillisen värähtelymittauksen taajuutta 20 kHz vastaava aallonpituus on 5E-5 metriä, kun CWI-mittauksessa käytettävän taajuuden vastaava aallonpituus on 2E-5 metriä). Lähetetyt aallot hajoavat rakenteessa törmätessään epäyhdenmukaisuuksiin ja lopulta katoavat kokonaan. Tekniikassa aaltoja pyritään vertaamaan kahdessa eri tilassa. Ensimmäisenä palaavaa aaltoa verrataan myöhemmin palaavaan aaltoon. Näitä eroja pyritään tulkitsemaan joko aallon venymänä tai puristumana ajan suhteen jonkin kertoimen α mukaisesti. Koska signaalin loppuosa on tyypillisesti melua, se hylätään valitsemalla tarkasteltava aikaikkuna hieman aaltoa lyhyemmäksi. Kerroin α etsitään iteratiivisesti minimaalisella resoluutiolla. Paras α on sellainen, jonka avulla verrattavat signaalit korreloivat parhaiten. Arvoa käytetään suhteellisen nopeuden muutoksen esittämiseen. CWI-tekniikka on herkkä pienille rakenteen muutoksille. Sitä on esimerkiksi käytetty lämpötilan aiheuttamien nopeusmuutosten ja hiekkakiven vesikylläisyyden seurantaan. (Wang & Niederleithinger, 2018.) Wang ja Niederleithinger (2018) ovat julkaisseet artikkelinsa Creative Commons CC_BY_NC licence -lisenssillä (<https://creativecommons.org/licenses/by-nc/4.0/>).

Tutkimuksia varten betonipalkki oli esikiinnitetty korkoon päistään ja se oli tuettu keskeltä pienemmällä palkilla keskeltä. Se oli jaettu viiteen osaan (A:sta E:hen) ja siihen oli asennettu yhteensä 14 ultraäänianturia (ACS SO807). Anturit oli upotettu sisään palkkiin kiinni ulkopuolisten pinnallisten häiriöiden, kuten lämpötilan pois sulkemiseksi. Kahdella tonnoin painoisella kappaleella betonipalkkiin tehtiin keinotekoisia vikoja liikuttamalla kappaleet

ensin palkin reunoilta keskelle ilman keskitukea ja sitten kappaleet siirrettiin takaisin palkin toiseen päähän ja keskituki laitettiin takaisin paikalleen. (Wang & ym., 2018.)

Dynaamisessa testissä pieni (36.6 kg) tärytin heilutti palkkia 15 minuutin ajan vaihdellen satunnaisesti taajuuttaan välillä [0 Hz, 100 Hz]. Tärytin oli sijoitettu 4.2 metrin päähän betonipalkin vasemmasta laidasta. Koska laite on pieni, sen tuottaman värinä on vähäistä. Testauksen datasta laskettu korrelaatiokerroin vaihteli välillä [0.9929, 1] ja aalloille laskettunopeuden muutos vaihteli välillä [-0.012%, 0.021%], mikä kieli CWI-tekniikan tarkkuudesta. (Wang & ym., 2018.)

Staattisessa testissä kahta tonnin painoista kappaletta siirrettiin betonipalkin oikeasta laidasta vasempaan laitaan diskreetteinä siirtoina. Kappaleita siirrettiin noin kaksi metriä eteenpäin 500 sekunnin välein, kunnes toinen pää saavutettiin. Ultraäänisensorit keräsivät dataa koko tunnin pituisen mittauksen ajan. Suuret kappaleet aiheuttivat paljon suuremman nopeuden muutoksen kuin dynaamisessa testissä käytetty täristin aiheutti. Täten α -arvon etsimiseen ei tarvittu yhtä tiuhaa iteratiivista etsimistä. Signaalin aikaikkunaksi oli valittu [0, 3 ms]. Mittauksessa paljastui, että seitsemännen lastauksen kohdalla eli noin seitsemännen ja kahdeksannen metrin kohdalla osat D ja E olivat saavuttaneet suurimman vertikaalisen siirtymänsä 37 mm. Lisäksi tällä paikoin oli havaittavissa suuria muutoksia suhteellisessa nopeudessa, joka kasvoi poikkeuksellisesti yhdestä prosentista viiteen mikä indikoi suurempien rakojen syntymistä. (Wang & ym., 2018.)

CWI-tekniikkaa voi käyttää oikeissa rakenteissa sekä staattisiin että dynaamisiin testeihin. Tekniikka on tarkka ja havaitsee pienetkin muutokset helposti. Dynaamista testiä käytetään kappaleen poikkeamien ilmaantumisen selvittämiseen. Staattinen testi soveltuu parhaiten poikkeamien paikallistamiseen. (Wang & ym., 2018.)

4.5 Esimerkkejä tekoälyä hyödyntävistä ennakoivan kunnossapidon ratkaisuista

4.5.1 Urheiluhallien SHM

Venäjällä Moskovan alueella on tutkimuksen alla ollut automatisoitu järjestelmä, jonka tarkoituksena on pyrkiä tarkastelemaan rakennuksen nykyistä tilaa ja ennustamaan sensoridatan pohjalta, kuinka rakennuksen kunnolle käy ajan myötä. Tämä älykäs järjestelmä kerää ja tarkastelee 80:n eri urheilurakennuksen sensorien mittauksia Moskovan, Khimkin ja Zelenogradin alueella. (Kozharinov, 2017.)

Tutkijoiden saamien kokemusten perusteelta järjestelmää on myöhemmin tarkoitus kehittää. Toinen mahdollisuus on luoda täysin uusi järjestelmä niin, että sillä pystyisi tarkastelemaan sekä teollisuushallien että muunkinlaisessa käytössä olevien rakennusten kuntoa ja valvomaan yleistä turvallisuutta. Ratkaistavana on ensin kuitenkin "time series"-tarkastelun

matemaattisen pohjan lisääminen, uusiinratkaisuihin kykenevien neuroverkkojen kouluttaminen, ja yhteistyörakennusten ja -kiinteistöjen löytäminen. Ohjelmallisesta näkökulmasta on järjestelmästä tehtävä oikea ohjelma, nopeuttaa algoritmeja, mahdollistaa käytettävyyttä myös muillakin tietokannanhallintajärjestelmillä, sekä suunnitella yhteiset käytännöt ja dokumentaatio. Lisäksi ohjelman käyttöliittymää ja käyttöystävällisyyttä on tarkoitus parantaa. (Kozharinov, 2017.)

4.5.2 Koneoppivien mallien testausta kiinteistöalalla

Uppsalan yliopistossa Ruotsissa on kirjoitettu julkaisu siitä, kuinka Fabege nimiselle asuntoalan yritykselle on kartoitettu koneoppivia malleja, joilla ennustaa asiakkailta saatavien virheraporttien laatua ja ilmaantumista. (Schnackenburg & Leife, 2017, 1.)


Virheilmoitukset kerättiin oleellisilta osilta SQL-kyselyin tietokannoista ja tallennettiin CSV-tiedostoon. Samoin tehtiin säätiladatalle, joka sisälsi mittausparametreja kuten lämpötila, kosteus, tuulen suunta ja sademäärä. Kiinteistöissä käytettävien antureiden data löytyi sopivassa muodossa Kabona nimisestä kiinteistönmittausdatatietokannasta. Kaksi koneoppimismallia koulutettiin. Toinen koneoppimismalli koulutettiin luokittelemaan virheitä saatujen virheilmoitusten ja säätiöjen perusteella. Toinen koulutettiin lisäksi lähes vuoden sisäilmastodatalla. (Schnackenburg & Leife, 2017, 1.)

Kouluttamisessa malliksi valittiin decision jungles eli päätösviidakot, sillä se on suhteellisen uusi koneoppimisen tekniikka (Schnackenburg & Leife, 2017, 1.) Päätösviidakko muodostuu solmuista, joiden väleillä voi olla useampia suunnattuja reittejä. Päätösviidakko alkaa juurisolmusta, josta lähtee kaksi reittiä. Reitit johtavat seuraaviin solmuihin, joita kutsutaan sisäsolmuiksi. Sisäsolmut voivat ottaa vastaan yhdestä useampaa reittiä, mutta vain kaksi reittiä lähtee ulos jokaisesta solmusta. Riippuen päätösviidakon koosta voivat reitit jatkaa seuraavan tason sisäsolmuihin tai lehtisolmuihin. Lehtisolmut voivat ottaa vastaan useita reittejä, aina vähintään yhden. Lehtisolmu on päättelyketjun päätepiste, mistä ongelmalle saadaan jokin ratkaisu. Päätösviidakot eivät muodosta silmukkaa eli mistään sisäsolmusta ei voi muodostua reittiä takaisin kohti aiemman tason solmua. (Shotton, Sharp & Kohli, 2013, 1.) Tässä mielessä ne muistuttavatkin Bayers-verkkoja ja muita suunnattuja epäsyklisiä graafeja (directed acyclic graphs = DAG's). Decision jungles – malli vaatii vähemmän muistia tietokoneelta kuin päätöspuut. (Schnackenburg & Leife, 2017, 1; Shotton, Sharp & Kohli, 2013, 1.) 78 prosentin tarkkuudella eri virheiden ilmaantumista pystyttiin ennustamaan oikein pääkäyttöisen mallin avulla (ensimmäisenä mainittu malli). (Schnackenburg & Leife, 2017, 1.)

4.5.3 Betonihalkeamien tunnistaminen kuvasta neuroverkon avulla

Sensoreiden asennus rakennuksiin on vaativaa ja sensoridatan tulosten laskeminen ja tulkitseminen voi olla joskus hyvinkin haasteellista, sillä esimerkiksi poikkeavat sääolot, epätasaisesti puhaltava tuuli ja vaihtuvat kuormat rakennelmilla kuten silloilla voivat vaikuttaa rakennelman käyttäytymiseen. Chanartikkelissa onkin päätetty aiempien

tutkimusten perusteelta tutkia betonin halkeamia kuvista, jolloin muiden tutkimusten kaltaisilta ongelmilta vältytään, sillä kuvia tutkittiin konvoluutioneuroverkolla (Convolutional Neural Network, CNN). Koska konvoluutioneuroverkko täytyy kouluttaa, sen kouluttamisessa käytetään sekä positiivisia että negatiivisia malleja. Toisin sanoen neuroverkolle on annettava useita kuvia sekä haluttua ominaisuutta sisältävistä kuvista, että kuvista, joissa haluttua ominaisuutta ei ole tai haluttu ominaisuus on jollain tavalla hankalammin havaittavissa. (Cha, ym., 2017.)




KUVIO 41. Kokonaisvaltainen arkkitehtuuri betoniseinän tilasta (Cha, ym., 2017)

Tutkijoiden käyttämän konvoluutioneuroverkon rakenne koostui useasta kerroksesta. Neuroverkon saadessa kuvan matriisimuodossa se suodatti kuvan pikseleitä alkuperäisestä $256 \times 256 \times 3$ pikselimäärästä $1 \times 1 \times 96$ kokoiseksi. Tämä on esitetty KUVIO:ssa 41., missä alkuperäinen kuva toimii neuroverkon lähteenä ja pienenee kunnes päästään kohtaan L5-BN.

Lähdematriisia käydään läpi pienemmällä matriisilla eli maskilla, joka etenee pitkin lähdematriisia ennalta valituin askelin. Joka askeleella tämän maskin sisällä oleville arvoille lasketaan "pistetulo", jota ei pidä sekoittaa lineaarialgebralliseen pistetuloon, varsinaisen filtterimatriisin kanssa. Filtterimatriisi on alustettu satunnaisluvuilla kerran jokaisen suodatuskerroksen alussa. Pistetulosta saadut arvot lasketaan yhteen sekä summaan lisätään kaikille luvuille käytettävä bias -arvo. Summa sijoitetaan lopuksi seuraavalle tasolle päätyvälle matriisille. Konvoluutioneuroverkkoa koulutettaessa filtterimatriisin arvot sekä bias -arvot tulevat muuttumaan, sillä niiden laskennassa käytetään stokastista laskevan gradientin-algoritmia (stochastic gradient descent, SGD). Suodatuskerrosten lisäksi neuroverkkoon oli sijoitettu keräyskerroksia (Pooling Layers), joilla lähdematriisia pystyi pienentämään entisestään. Tällaisten kerrosten toimintaperiaate oli hyvin samanlainen kuin konvoluutiokerroksilla, mutta pistetulon laskemista ei tapahtunut vaan maskin sisään jääneiden lukujen joukosta valittiin suurin. (Cha, ym., 2017.)

KUVIO:sta 41. huomataan, että seuraavaksi datan matka jatkuu ReLu-kerrokselle (Rectified Linear Unit), joka toimii nopeana aktivaatiokerroksena, missä negatiivisista luvuista tehdään nollia. ReLu-kerroksen lisäksi on käytetty poistokerroksia (Dropout Layer, DL) ja satsin normalisointikerroksia (Batch Normalization, BN), sillä näillä tekniikoilla neuroverkon opettamista on mahdollista parantaa. DL-kerroksia käytetään kierrettäessä ylityöntämistä (overfitting), missä äkillisellä tiedon poistamisella jostakin neuroverkon silmusta voidaan pakottaa neuroverkko oppimaan uudelleen tai uudella tavalla jokin ominaisuus. BN:ssä satsin arvot nimensä mukaisesti normalisoidaan, mikä nopeuttaa NN:n oppimisprosessia. KUVIO:ssa 41. BN-kerroksia on muutama, kuten esimerkiksi L5-kerroksen yhteydessä. ReLu-kerroksen jälkeen L7 kerroksella epälineaarista arvoista lasketaan pistetulo ja Softmax-kerroksella datan perusteelta tehdään varsinainen luokittelu. Mikäli alkuperäisessä kuvassa oli halkeama, on halkeaman todennäköisyys suurempi kuin muiden vaihtoehtojen. (Cha, ym., 2017.)



KUVIO 42. Kuvat käytiin läpi liukuva ikkuna-tekniikalla (Cha, ym., 2017)

Tutkijat rakensivat käyttämänsä tietokannan ottamalla 277 4928*3264 resoluutioisia kuvia NN:n opettamista varten sekä 55 kappaletta 5888*3584 resoluutioisia kuvia NN:n testausta varten. Kuvat käytiin käsin läpi ja merkittiin, oliko kuvassa halkeamaa vai ei. Näistä 277:stä kuvasta tehtiin 40000 kuvaa sisältävä koulutustietokanta ottamalla jokaisesta kuvasta 256*256 resoluutioisia kuvia. Tietokannasta kuvat jaettiin satunnaisesti 32000:n opetuskuvaan ja 8000:n validointikuvaan. Treenauksen jälkeen NN:n tarkkuus oli huimat 98,22 prosentti koulutusdatalle ja 97,95 prosenttia validointidatalle. Testaamista varten 55 kuvaa oli otettu toisesta rakennuksesta, mutta tästäkin huolimatta NN:n tarkkuus oli 97 prosenttia. Osaltaan tuloksia selittää se, että testattavien kuvien reunat käytiin läpi liukuva ikkuna-tekniikalla (Sliding Window, SW), jossa reunat käytiin kahdesti läpi. SW-tekniikasta on esitetty toimintaperiaate KUVIO:ssa 42., missä mahdollisen halkeaman osuminen reunalle tarkistetaan. Tutkijat vertasivat tuloksiaan vielä toisiin tutkimuksiin, joissa oli käytetty muita

tekniikoita, mutta NN-tekniikan havaittiin olevan tarkin. NN:n etuihin kuuluu se, ettei kuvan valoisuudella, etäisyydellä kohteeseen taikka kuvan rakeisuudella ollut vaikutusta tuloksiin. (Cha, ym., 2017.)

4.5.4 Neuroverkot ja vähentävä klusterointi HVAC-järjestelmässä

Lämmön-, ilmankierron- ja ilmastoinninsäätely (heating, ventilation and air condition, HVAC) on tärkeää rakennuksen energiankulutuksen kannalta. Erilaisten vikojen ilmaantuminen rakennuksessa sekä harhat käytetyissä sensoreissa lisäävät energiankulutusta, vähentävät rakennuksen käyttöikä ja alentavat ihmisten viihtyvyyttä. Yleisiä vikoja ovat esimerkiksi jäähdytysvesiletkun asennon lukkiutuminen tai sensoriharhat. Vianmääritysratkaisut voidaan jakaa kolmeen luokkaan: malli- (esim. fyysinen malli tai simuloitu malli), sääntö- (esim. joukko erikoissääntöjä, jotka perustuvat kokemukseen laitteiston käyttäytymisestä) ja datapohjaiset ratkaisut (esimerkiksi PCA-analyysi). Tutkijat esittelivät vian havainnointi- ja diagnosointistrategian käyttäen yhdistettyjä neuroverkkoja ja vähentävää klusterointianalyysejä. Neuroverkkoja käytettiin havaitsemaan rakennuksen ilmastointijärjestelmän viat tuloilman lämpötilassa. Tämä oli datapohjainen ratkaisu. (Du, ym., 2013.)

Tyypillisessä HVAC -järjestelmässä tuloilma, joka koostuu ulkoilmasta ja kierrätetystä ilmasta, luovuttaa lämpöenergiaa letkuissa kiertävälle kylmälle vedelle samalle laskien ilman lämpötilaa. Vesi lämpenee kohdatessaan lämpimän ilman kanssa, joten sen kierron on puolestaan jatkuttava veden viilennysyksikölle. Usein ilman ja veden kohtaamista voidaan säädellä. Ilma puhalletaan seuraavaksi ulos laitteesta käyttökohteeseensa, kuten pieneen toimistohuoneeseen. Huoneilman viilentäminen jatkuu imemällä huoneesta vanhaa lämmintä ilmaa, josta puolet päätyy viilennettäväksi ja loput rakennuksesta pihalle. (Du, ym., 2013.)

Tutkijat pyrkivät selvittämään tuloilmasäätelyn vikoja mittaamalla paluueden lämpötilasensorin harhan, tuloilman lämpötilasensorin harhan, tuloilman lämpötilasensorin ajalehtivan harhan ja tuloilman lämpötilasensorin täydellisen hajoamisen sekä vesiventtiilin tukkiutumisen. (Du, ym., 2013.)

Pääneuroverkko sai syötteenään tuloilman lämpötilan asetusarvon, tuloveden lämpötilan, lähtevän veden lämpötilan, kylmän veden syöttösuhteen ja viilennysvesiletkun asennon. Näiden perusteelta pääneuroverkko ennusti ilman lämpötilan. KUVIO:ssa 43. on esitetty tulokset, jotka saatiin, kun pääneuroverkolle syötettiin simuloitua dataa. Dataan oli sisällytetty erilaisia virhettä tuottavia ominaisuuksia, joista pääneuroverkon oli tarkoitus tunnistaa esimerkiksi tuloilman lämpötilasensorin ajalehtiva harha. KUVIO:sta 44. on puolestaan esitetty aponeuroverkon tulokset, kun sitä testattiin vastaavalla datalla. Aponeuroverkko sai syötteenkseen tuloilman lämpötilan ja -säädön, tuloveden lämpötilan, kylmän veden syöttösuhteen ja viilennysvesiletkun asennon. Aponeuroverkko pyrki

ennustamaan lähtevän veden lämpötilaa, sillä PCA-tarkastelulla lähtevän veden lämpötilan oli havaittu olevan tuloilman lämpötilan kanssa tärkeimmät komponentit ilman lämpötilan säätelyssä. (Du, ym., 2013.)

Fault cases	False alarm ratio	Missing alarm ratio	Detection time
Fixed bias of T_{wr} sensor	0.8%	0%	1 min
Positive fixed bias of T_{sup} sensor	0.6%	10.2%	1 min
Negative fixed bias of T_{sup} sensor	4.2%	50.8%	3 min
Drifting bias of T_{sup} sensor	9.2%	19.4%	54 min
Complete failure of T_{sup} sensor	5.8%	43.1%	60 min
Chilled water valve stuck	2.7%	13.9%	1 min

KUVIO 43. Pääneuroverkon tulokset (Du, ym., 2013)

Fault cases	False alarm ratio	Missing alarm ratio	Detection time
Fixed bias of T_{wr} sensor	5.8%	0%	1 min
Positive fixed bias of T_{sup} sensor	1.9%	4.2%	4 min
Negative fixed bias of T_{sup} sensor	8.3%	0%	1 min
Drifting bias of T_{sup} sensor	9.2%	6.9%	25 min
Complete failure of T_{sup} sensor	7.2%	3.3%	8 min
Chilled water valve stuck	3.9%	18.9%	6 min

KUVIO 44. Apuneuroverkon tulokset simuloidulla datalla ja virheillä (Du, ym., 2013)


Neuroverkoja testattiin lopulta yhdessä simuloidun datan ja virheiden varalta. Paljastui, että neuroverkkojen yhdistäminen vähensi huomattavasti väärin hälytysten määrä sekä puuttuvien hälytysten määrää. havainnointiaika myös pieneni. Tämä on esitetty KUVIO:ssa 45. (Du, ym., 2013.)

Fault cases	False alarm ratio	Missing alarm ratio	Detection time
Fixed bias of T_{wr} sensor	1.7%	0%	1 min
Positive fixed bias of T_{sup} sensor	0.6%	2.5%	1 min
Negative fixed bias of T_{sup} sensor	3.3%	0%	1 min
Drifting bias of T_{sup} sensor	7.5%	8.3%	29 min
Complete failure of T_{sup} sensor	5.5%	4.2%	9 min
Chilled water valve stuck	1.1%	6.5%	1 min

KUVIO 45. Yhdistettyjen neuroverkkojen tulokset (Du, ym., 2013)

4.5.5 Hajautetun vaurion havainnointijärjestelmä


Abdeljaberin tutkimuksessa ehdotetaan värähtelyyn perustuvaa epäparametrissa algoritmia käytettäväksi adaptiivisten 1D konvoluutioneuroverkkojen kanssa SHM:ää varten. Oikein muuttuvilla CNN:llä on mahdollista luokitella kiihtyvyyssantureidenmittaukset ilman tarvetta esi- ja jälkikäsitteilylle. Tutkimukset suoritettiin empiirisesti Qatarin yliopiston (Qatar University, QU) pääkatsomosimulaattorilla (Grandstand simulator). KUVIO:ssa 46. on esitelty pääkatsomosimulaattoria, joka kaikessa yksinkertaisuudessaan on metallikehikko suunniteltu kannattelemaan 30 henkilöä. Pääkatsomon liitoskohtiin oli asennettu 30 kiihtyvyyssanturia sekä tärisytin, jota ohjattiin kahdella 16-kanavaisella tiedonkeruujärjestelmällä. Jokaiselle värähtelyanturille oli opetettu oma 1D konvoluutioneuroverkko. Koska jokaiselle liitoskohdalle oli koulutettu oma konvoluutioneuroverkkonsa, käsittelivät ne vain liitoskohtansa dataa. Yleisesti koko järjestelmä oli siis hajautettu. (Abdeljaber, ym., 2017.)



KUVIO 46. Havaintokuva keskeneräisestä pääkatsomosta (Abdeljaber, ym., 2017)


Neuroverkkojen rakenne oli suunniteltu niin, että niissä oli vain kaksi konvoluutio/keräyskerrosta piilokerroksilla ja kaksi piilotettua täysin yhdistettyä kerrosta ('hidden fully connected layers'). Ensimmäisen kerroksen koko oli 64 solmua ja viimeisen puolestaan 10 solmua. Kouluttamisen pysäytysehtoina toimivat joko 100 iteraatiota tai luokitteluvirheen tarkkuuden saavuttaessa yhden prosentin virhemarginaalin. (Abdeljaber, ym., 2017.)

Varsinaisessa mittauksessa yhtä tai useampaa kehikon pulttia löysättiin, jolloin voitiin simuloida vähäistä vahinkoa taikka kulumaa pääkatsomossa. Ensimmäiseksi tarkkailtiin vain yhtä teräskehikon palkkia, jossa oli viisi liitoskohtaa. KUVIO:ssa 47. on esitetty, kuinka yhdelle palkille laskettu vaurion todennäköisyys sijoittui vaurioitumattomassa tapauksessa (vasen) ja vaurioituneessa tapauksessa (oikea). (Abdeljaber, ym., 2017.)



KUVIO 47. Vaurioiden todennäköisyydet yhden palkin mittauksessa (Abdeljaber, ym., 2017)

Toisessa mittauksessa tarkkailtiin koko pääkatsomon käyttäytymistä. Kouluttamista varten mittauksia oli tehty 31 kappaletta ja validoinnissa neuroverkkoja testattiin 24:llä eri tapauksella, joista yksi oli vaurioton tapaus, osa oli yhden vaurion tapauksia ja osa useamman vaurion. Keskivirhe luokittelulle havaittiin olevan 0.54 prosenttia. Ongelmia näytti aiheutuvan, mikäli kahta vierekkäistä liitoskohtaa oli löystytetty tai jos liitoskohtia oli löystytetty palkin symmetria-akselilla. Kuitenkin saadut tulokset olivat vähintäänkin tyydyttäviä. KUVIO:ssa 48. on esitetty tapaus, jossa kahta vierekkäistä liitoskohtaa oli löystytetty. Neuroverkko ilmaisee korkeampaa vauriotodennäköisyyttä (punainen) myös löysäämättömälle liitokselle. (Abdeljaber, ym., 2017.)



KUVIO 48. Kahden vaurion todennäköisyys (Abdeljaber, ym., 2017)

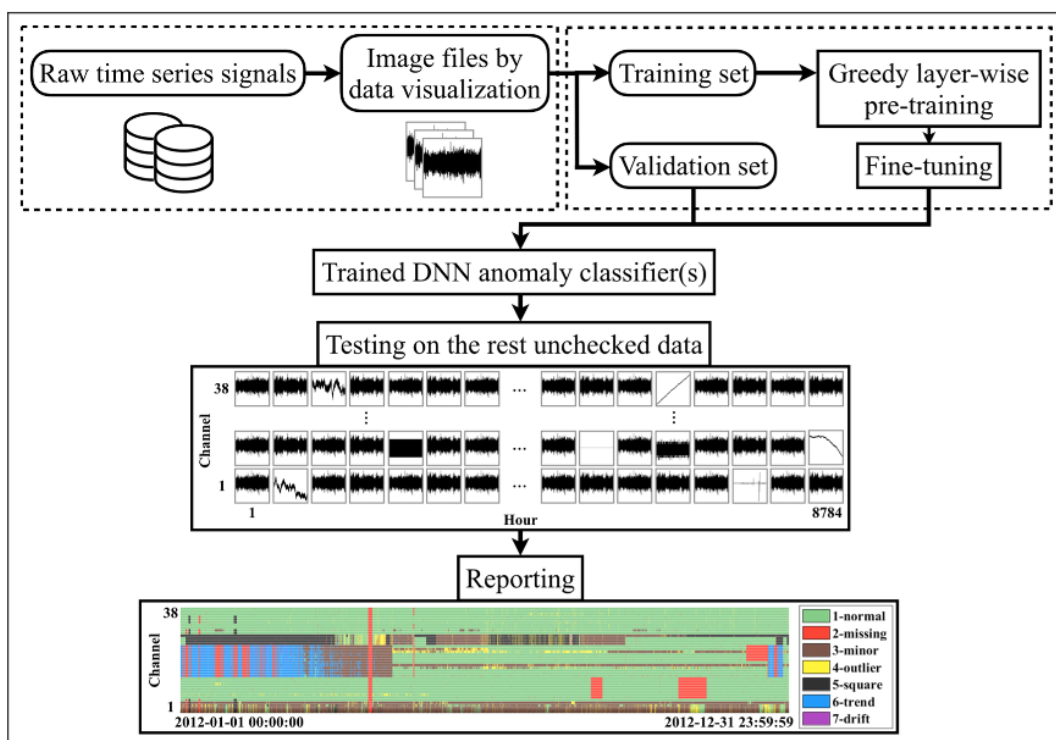
Tutkijoiden on tarkoitus seuraavaksi kerätä oikeista rakennelmista vauriotonta dataa ja simuloida vauriodataa, sillä vauriodataa on oikeista rakennelmista tyypillisesti hankala saada. Lisäksi tutkijoita kiinnostaa selvittää miten ehdotettu hajautettu CNN toimii isompien vaurioiden kanssa. (Abdeljaber, ym., 2017.)

4.5.6 Datapoikkeamien havainnointi neuroverkoilla

Älykkäiden rakennusten kunnossapidossa syntyy valtava määrä dataa, jonka on ennustettu Kiinassa jatkavan kasvuaan, kun yksittäisten talojen kunnossapitojärjestelmissä siirrytään talojoukkojen kunnossapitojärjestelmiin ja sitä kautta tulevaisuudessa kokonaisten kaupunkien yhteiseen kunnossapitojärjestelmään. Tällainen datamäärän kasvu tarkoittaa, että on kehitettävä Big Dataan perustuvia SHM-järjestelmiä, jotka selviäisivät myös häiriötapauksista tehokkaasti. Häiriöitä aiheutuu sensoreista ja huonolaatuisesta datan välityksestä. (Bao, ym., 2018.)

Tutkijat suunnittelivat järjestelmän, jossa data ensin muunnetaan kuvaajiksi ja sitten kuvaajat syötetään syvälle neuroverkolle (Deep Neural Network, DNN). KUVIO:ssa 49. havainnollistetaan suunnitellun järjestelmän koulutusta, testausta ja koko datan käsittelyä sekä sen raportointia.

Visualisoinnissa aikasarjadata jaetaan tunnin mittaisiin paloihin ja näistä paloista tehdään 100x100 harmaasävykuvia (grayscale images). Harmaasävykuvista muodostetaan aikajärjestyksessä oleva vektori, joka syötetään DNN:lle. DNN koulutetaan osalla tästä datasta ja tässä vaiheessa kuvat oli merkittävä asiantuntijan avulla manuaalisesti sisältyvän mikä mihinkin häiriöluokkaan. Koska tutkijoilla oli käytettävissään kokonaisen vuoden mittausdata sillasta, riitti se, että valittiin noin 3 % datapaloista. Puolet tästä määrästä käytettiin DNN:n koulutukseen ja puolet sen toiminnan validointiin. (Bao, ym., 2018.)




KUVIO 49. Sillan datan matka luokitelluksi (Bao, ym., 2018)

Varsinaisen verkon rakenne oli jouduttu osin muodostamaan piilokerroksilla esiopetetuina autoenkoodereina (autoencoder). Autoenkooderit muodostuivat kolmikerroksisista neuroverkkokerroksista, joiden sisään- ja ulostulot olivat saman suuruiset. Näitä käytettiin, jotta häviävän gradientin ongelmasta päästiin. (Bao, ym., 2018.)

Tutkijat ehdottivat verkon rakenteelle myös kolmea eri aliverkkomuodostelmaa: rinnan, yhdessä tai ryhmässä. Rinnakkain asetellut aliverkot suoriutuvat tyypillisesti hyvin paikallisella tasolla, mutta ne eivät kommunikoi sensoreiden välillä. Yhdistetty aliverkkoratkaisu saa tiedon kaikilta sensoreilta, mutta tämä ei välttämättä luokittele tarpeeksi hyvin. Ryhmitellyssä ratkaisussa, mikäli sensoreista ja sensoriverkoista tiedetään jotain tarkemmin kuten sensorikohtaiset sijainnit, ne voidaan ryhmitellä omiksi joukoikseen ja kouluttaa näille joukoille omat neuroverkkonsa. (Bao, ym., 2018.)

Sillan sensoreiden häiriöt oli jaettu kuuteen luokkaan: missing eli puuttuva, minor eli vähäinen eli arvot jotka olivat aivan liian pieniä suhteessa muihin arvoihin, outlier eli arvot, jotka poikkesivat suuruudellaan huomattavasti muiden arvojen joukosta, square eli neliömuoto, jolloin mittausarvot vaihtelevat epänormaalisti koko mittausalueella, trend eli trendi, jolloin mittaustuloksissa voidaan havaita tasaista mittaustulosten poikkeamista normaalista ja sille voisi laskea nollasta poikkeavan kulmakertoimen ja drift eli ajalehtiminen, joka muistuttaa trendiä, mutta ei ole tasaisesti poikkeava. Näistä luokista on osaa havainnollistettu KUVIO:ssa 50. (Bao, ym., 2018.)



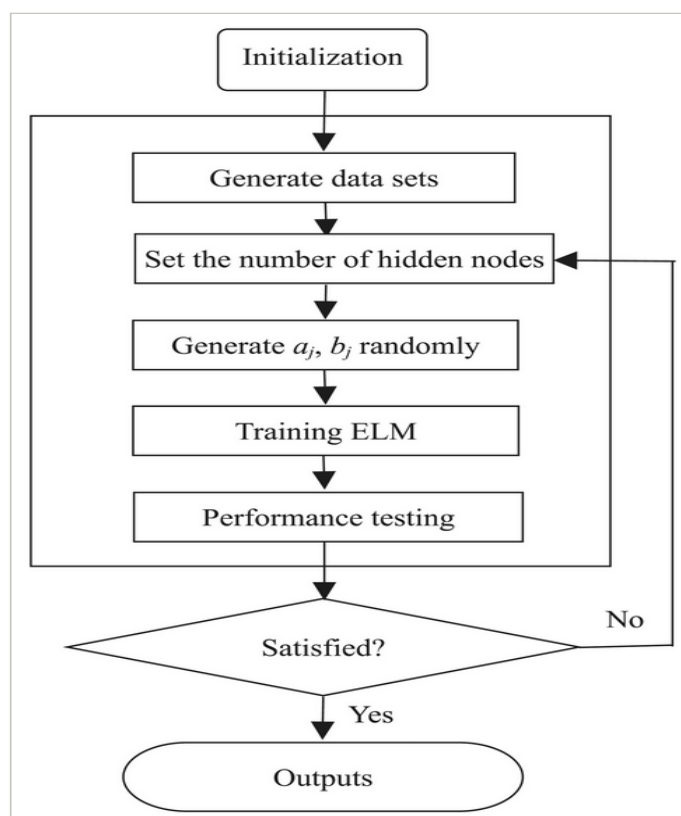
KUVIO 50. Neliömuodon, trendin ja ajalehtivan häiriön havainnollistus (Bao, Y., ym., 2018)

Tutkijoiden siltatutkimuksessa DNN rakentui 10000x1 kokoisesta sisääntulokerroksesta ja piilokerroksia oli kolme, joista ensimmäisellä oli 100 nodea, seuraavalla 75 ja kolmannella 50. Viimeisellä kerroksella eli ulostulokerroksella oli seitsemän nodea, jotka kuvasivat eri häiriötilanteita sekä normaalia toimintaa. Koulutustarkkuudeksi saatiin 90,7% ja validointitarkkuudeksi 85,8%. Kaikelle datalle tehdyssä luokittelussa aikaa kului 6 tuntia, mikä on ajankäytöllisesti hyvä tulos verrattuna käsin tehtävään tarkastukseen. Tutkijat saivat näin selville, että 30,08 % kaikesta datasta sisälsi jonkinlaista häiriötä. Tämän lisäksi he suorittivat manuaalisen tarkistuksen ja päätyivät siinä tulokseen, että 34,09 % kaikesta datasta sisältää häiriötä, joten automaattisen tarkistuksen tarkkuudeksi saatiin lopulta 87 %. (Bao, ym., 2018.)

4.5.7 Padon muodonmuutosten ennustuskeinojen vertailu

Padot ovat tärkeitä nyky-yhteiskunnissa ja niiden merkityksen vuoksi niitä on ehdottomasti syytä tarkkailla, jotta onnettomuuksilta ja taloudellisilta menetyksiltä vältyttäisiin. Patojen fyysisten ja kemiallisten ominaisuuksien tarkkailu voidaan jakaa staattisiin ja dynaamisiin keinoihin. Staattisilla keinoilla mitataan esimerkiksi padon veden korkeutta, jännitystä rakenteessa, halkeamien kokoa ja sijaintia sekä ympäristön lämpötiloja. Dynaamisten ominaisuuksien mittauksiin kuuluu esimerkiksi patojen värähtelymittaukset tuulen tai aaltojen vaikutuksesta. Kangin tutkimuksessa tutkijat keskittyivät pääosin tutkimaan staattisiin mittauksiin saatua dataa ja miten äärimmäisoppimiskone (Extreme Learning Machine, ELM) oppii sitä tulkitsemaan padon horisontaalista siirtymää. (Kang, ym., 2017.)


ELM on yhden piilokerroksen sisältävä neuroverkko, jonka painot ja piilokerroksen noodien määrät valitaan satunnaisesti. Sille syötettävän datan on oltava normalisoitu. Mikäli piilokerroksen ulostulon painoista laskettu pienimmän etäisyyden pienin neliöratkaisu on alle halutun tarkkuuden, verkon muodostus lopetetaan ja sille suoritetaan varsinainen tarkkuustesti validointidatalla. Jos neliösumma ei alittanut haluttua tarkkuutta, on piilokerroksen noodien määrä valittava uudelleen tai haluttua tarkkuutta kasvatettava. KUVIO:ssa 51. havainnollistetaan tätä. (Kang, ym., 2017.)



KUVIO 51. ELM:n perusteet (Kang, ym., 2017)

Fengman dam-pato sijaitsee Kiinassa. Se on 91 metriä korkea, 1080 metriä pitkä ja kokonaisvesikapasiteetti kattaa 1146 miljoonaa kuutiota. Pato on jaettu 60 osaan, joista tutkijat tutkivat vain keskimmäisimmän osan dataa. Keskimmäisen osan data oli valittu, koska siinä oli havaittu eniten vastetta laskennassa käytetyille kaavoille ja data oli riittävän jatkuvaa ollakseen käyttökelpoista. Vaakasuuntaiseen siirtymään vaikuttaa eniten erot padon eri puolilla olevan vedenpinnan korkeuksissa, lämpötila sekä ikääntyminen. Täten itsenäiset muuttujat mittauksissa voi luetella seuraavasti: $X = [H, H_2, H_3, T_1, T_{1-7}, T_{8-15}, T_{16-30}, T_{31-60}, \theta, \ln(\theta + 1)]$, missä H ilmentää korkeuseroa, H_2 sen neliötä ja H_3 korkeuseron kuutiota, T kuvastaa mittauspäivän keskilämpötilaa, T_p-q puolestaan kuvaa päivien p ja q välistä lämpötilojen keskiarvoa, ja θ on padon ikä, mikä on laskettu mittauspäivän ja mittausten alkamispäivän erotuksena jaettuna sadalla. Datasetti käsitti yhdeksän vuoden datan, joka oli jaettu 150 ryhmään. Datan käsittelyn jälkeen ryhmiä oli jäljellä 141 kappaletta, joista ensimmäiset 117 käytettiin eri tekoälytekniikoiden kouluttamiseen ja loput testaukseen. (Kang, ym., 2017.)

BP-neuroverkon painot ja esiasetukset oltiin alustettu Nguyen-Widrown alustusfunktiolla ja verkon rakenne oli Levenberg-Marquart. Tavoitetarkkuudeksi eli pienimmän neliösumman virheeksi oli asetettu 10^{-3} . Piilokerroksen aktivointifunktiona käytettiin hyperbelistä tangentti sigmoidfunktiota ja ulostulokerroksella lineaarista siirtofunktiota (linear transfer function). ELM-mallissa piilokerroksen noodien määrät oli löydettävä manuaalisesti, mikä on havainnollistettu KUVIO:ssa 52. Tässä kuviossa (vasen) BP löytää hyväksyttävän tuloksen jo 15-noden kohdalla, kun taas (oikea) ELM-malli löytää etsityn minimin vasta 22-noden kohdalla. Molempia malleja koulutettiin ja testattiin viidesti, sillä satunnainen aloituspiste voi vaikuttaa mallien minimin löytämiseen. (Kang ym., 2017.)



KUVIO 52. ELM:n paras tarkkuus saavutettiin 22-noden kohdalla (Kang, ym., 2017)

ELM:n ja BP:n lisäksi multiple linear regression (MLR)- ja stepwise regression (SR)-mallit koulutettiin. KUVIO:n 53. on koottu kaikkien menetelmien parhaat tulokset. Tähän kuvioon on laskettu eri menetelmillä virhearvot. MAE tarkoittaa keskimääräistä keskivirhettä (Mean Average Error), MSE tarkoittaa keskimääräistä neliöön korotettua virhettä (Mean Squared Error), S tarkoittaa suurinta absoluuttista virhettä ja R on korrelaatiokerroin, joka kuvaa simuloitujen ja todellisten arvojen riippuvuutta. (Kang, ym., 2017.)

Model	MAE		MSE		S		R		Time (s)
	Training	Testing	Training	Testing	Training	Testing	Training	Testing	
BP	0.4270	0.8491	0.3505	1.1311	2.2703	2.3678	0.9824	0.9466	5.3309
ELM	0.3978	0.7020	0.2653	0.8929	1.6336	2.2076	0.9840	0.9564	2.9265
MLR	0.8355	1.0673	0.9947	1.7170	2.0376	2.8455	0.9388	0.9190	2.1619
SR	0.9097	1.0959	1.1750	1.6609	2.5263	2.3165	0.9361	0.9099	2.7656


KUVIO 53. MLR oli nopein kouluttaa (Kang, ym., 2017)

Niistä voi huomata, että parhaimmat tulokset tarkkuuden puolesta on saatu ELM:llä BP:n ollessa hyvin likeinen kakkonen. Pohdittavaksi jääkin olisiko BP:llä päästy parempiin tuloksiin, mikäli myös sen noodien määrää olisi kasvatettu yli 20:n, sillä KUVIO:n 76. perusteella näin ei ole tehty. Kuitenkin ELM:n kouluttaminen on ollut selkeästi nopeampaa kuin BP:n. (Kang, ym., 2017.)

4.5.8 Sijaismalli reaaliaikaista SHM diagnosointi- ja ennustusjärjestelmää varten

Milanon ammattikorkeakoulun mekaanisen suunnittelun tutkijat ovat kehittäneet tekniikkaa, jolla rakennuksen koristepaneelinrasitusta voi ennustaa Bayesian – todennäköisyyslaskennalla. Tyypillisesti tällainen jatkuva mallin päivitys suoritetaan rakennuksesta tehdyn FE-mallin avulla numeerisesti. Todennäköisyydet lasketaan jokaisen suureen signaalille jokaiselle otannalle, mikä todellisten rakennusten tapauksessa on erittäin vaativa toimenpide. Tehdäkseen laskennasta reaaliaikaisen tutkijat loivat ANN-sijaismalleja. Sijaismallit koulutettiin analyttisillä simulaatioilla ennustamaan rasiitusta koordinaattien ja vaurion koon perusteella. Peräkkäinen merkitys Monte-Carlo –otannalla (Monte-Carlo Sampling, MCS), joka toimi suodattimena (PF, "Particle Filter"), puolestaan arvioitiin raon kokoa ja sen keskipisteen koordinaatteja. Lisäksi suodatinta käytettiin arvioimaan Parisin lain ("Paris's law") mukaisia rasiitusarvoja sekä RUL, jotka toimivat tutkijoiden käyttämässä kappaleen väsymisestä johtuvan raon kasvun mallissa ("Fatigue Crack Growth model") kahtena parametria. (Sbarufatti, Cadini, Locatelli & Giglio, 2018.) Sbarufatti & ym. (2018) julkaisivat artikkelinsa Creative Commons CC_BY_NC licence -lisenssillä (<https://creativecommons.org/licenses/by-nc/4.0>).

Tutkijat testasivat sijaismalleja simuloitulla äärettömän suurella alumiinilevyllä, jossa oli siniaallon mukaisesti vaikuttava paikallaan pysyvä paino. Alumiinilevyssä oli 20 virtuaalista rasiusta mittaavaa sensoria. Sensorit mittasivat rasiusta, joka oli simuloitu MCS-algoritmilla ja johon oli lisätty häiriötä. MCS-algoritmi oli alustettu alumiinin A12024-T3 historiadataalla. Tutkijat kouluttivat sensoridataa 20 sijaismallia eli neuroverkkoa, joiden input-kerroksella oli kolme nodea, piilokerroksella 100 nodea ja output-kerroksella yksi node. Neuroverkkojen kouluttamiseen käytettiin 70 prosenttia kaikesta datasta lopun allokoituessa validointia varten. Mallit pyrittiin pitämään mahdollisimman yleiskelpoisina hyödyntämällä ristiin validointia ('cross validation') ja aikaista pysäytystä ('early stopping criteria'). (Sbarufatti & ym., 2018, 1.)



KUVIO 54. Rasiuksen todelliset ja ennustetut arvot (Sbarufatti & ym., 2018, 1)

KUVIO:ssa 54. on esitetty kolmen eri sijaismallin ennusteet rasiukselle todellisten rasiusten kanssa halkeaman pituuden funktiona. Sensoreille neljä ja yhdeksän ennusteet ovat onnistuneet hyvin verrattuina todelliseen rasiukseen. Sensori kahdeksan on antanut hieman suurempia tuloksia rasiukselle raon pituuden välille [17 mm, 37 mm]. Tulokset ovat kuitenkin olleet pääsääntöisesti lupaavia. (Sbarufatti & ym., 2018, 1.)

4.5.9 Energian kulutuksen arviointi tekoälyllä

Intian pohjois-alueille kuuden kuukauden kesä on tyypillinen ja huhtikuusta alkavana aikana ihmiset käyttävätkin rakennuksien viilennykseen energianlähteenä sähköä ja öljyperäisiä tuotteita. Fossiiliperäisten energianlähteiden käyttöä tulisi vähentää, sillä niistä syntyy huomattavia hiilidioksidipäästöjä. Tutkijat Shoolin ja Dr. Y. S. Parmar University of Horticulture & Forestry yliopistoista pyrkivät ennustamaan kerrostalon (pituus 45m, leveys 15m ja korkeus 18m) energian tarvetta sitä viilennettäessä ja vertailivat käytettyjen

energianlähteiden hintaa ja hiilidioksidipäästöjä. (Kumar, Aggarwal, Sharma & Pathania, 2013,7 - 12.)

He käyttivät laskuissaan ikkunoiden, seinien ja katon U-arvoja, koko vuoden lämpötilan keskiarvoa, ulkotilan lämmönsiirtovakiota, sisäilman tavoiteltua lämpötilaa, tilan absorptio keskiarvoa, ikkunoiden läpäisyastetta, ilman tiheyttä ja ilman lämpö määrää sekä neuroverkkoa, jonka piilokerroksessa oli kymmenen nodea. Neuroverkolla he pyrkivät laskemaan johtumishäviötä, lämmöntuottoa, ilmanvaihdon häviöitä, sisäistä lämmöntuottoa ja lämpökuormitusta. Ennusteiden ja todellisten arvojen välille lasketut korrelaatiot paljastivat, että mallissa oli puutteita, sillä ilmanvaihdon todelliset ja ennustetut arvot eivät korreloineet ollenkaan. Muiden suureiden regressioanalyysin tulokset olivat huonoimmillaankin yli 0.7. Kumar & ym. (2013) saivat lopulliseksi tulokseksi kerrostalon viilennykseen käytettävän energian määräksi 870 MW. Mikäli se tuotetaan sähköllä, siitä syntyy 3,5t hiilidioksidia (47709,16\$). Vastaavasti dieselillä syntyvä määrä on 236,2 t hiilidioksidia (57250,9\$). (Kumar & ym., 2013, 7 - 12.) Tutkijoiden kirjoittama artikkeli oli valitettavasti vähäsanainen koskien neuroverkkoa, sen rakennetta, miten käytettyä dataa oli käsitelty ja miten se oli jaettu koulutus, testi ja validointidataan.

5. Lehto Asunnot Oy:n IoT-datan analyysi

Tässä luvussa keskitytään Lehto Asunnot Oy:ltä saadun IoT-sensoridatan analysointiin sekä tekoäly- ja teknologiakartoitukseen. Luvussa myös pohditaan analysoituun dataan nojaten ja Lehto Asunto Oy:n yhteistyöyrityksen Riotsin rajapintoihin peilaten, minkälainen Lehto Asunnot Oy:n tekoälyä hyödyntävä itseohjautuva lämmitysjärjestelmä (asiantuntijajärjestelmä) voisi olla sekä minkälaisia teknologisia vaatimuksia ja puutteita sen toteuttaminen voisi vaatia.

Luvussa 5.1 keskitytään Lehto Asunto Oy:n toimittaman datan analysointiin. Analysoinnissa analysoidaan rakennuksien kerroksien ja tornien lämpötilojen, connect lämmitysmuuttujien meno- ja paluueden lämpötilamittauksia ja paineilma Maman lämpötilojen käyttäytymistä aikavälillä 24.9.2019 - 24.1.2019 sekä rakennuksen 1. lämpötilaa suhteessa ulkoilman lämpötilaan aikavälillä 16.11.2018 - 24.1.2019. Luvussa käsitellään myös poikkeuksia aikaväliltä 21.9.2018 - 25.1.2019 ja aikaeroja aikaväliltä muun muassa 15.12.2018 - 7.1.2019 ja 23.10.2018 - 28.10.2019.

Lisäksi luvussa 5.1 analysoidaan myös rakennuksen 2. asuntojen

- lämpötilan keskiarvoja (kaikki asunnot)
- lämpötilamuutosta
- lämpötilamuutosta suhteessa ulkolämpötilan muutokseen tunnin aikana
- yhteisen lämpötilan keskiarvon muutosta

suhteessa ulkoilman lämpötilaan aikavälillä 1.11.2018 - 29.1.2019.

luvussa 5.1 analysoidaan myös rakennuksen 2. connect


- lämmitys 1. meno –muuttujan muutoksia
- lämmitys 2. meno –muuttujan lämpötila-arvoja
- lämmitys 1. paluu –muuttujan arvoja
- lämmitys 2. paluu –muuttujan muutoksia

suhteessa ulkoilman lämpötilan muutokseen aikavälillä 1.11.2018 - 29.1.2019.

Luvussa toteutetaan teknologiakartoitus, jossa esitellään Lehto Asunnot Oy:n kumppaniyritys Riots Global Oy:n pilvipalvelu- ja IoT-ratkaisuja, yleistietoa julkisen pilvipalvelun omaksumisasteesta, tekoälyä hyödyntävä IoT-esimerkkitoteutus Googlen pilvipalveluteknologialla, informaatiota julkisten pilvipalveluiden (Google) hinnoittelusta ja pohdintaa asiantuntijajärjestelmän toteuttamisesta.

5.1 Analyysi


5.1.1 Kerrokset



KUVIO 55. Rakennuksen 1. kerroksen 1. lämpötilat 1.8.2018 - 28.1.2019

KUVIO:ssa 55. on esitetty rakennuksen 1. kerroksen 1. lämpötilojen käyttäytyminen mittausvälillä 1.8.2018 – 28.1.2019. Data on esitetty koko ajalta 75 tunnin välein. Aikajaksoista on nähtävissä, että asunnoista ei ole ollut saatavilla dataa aikavälillä 7.9 - 2.11.2018. Tähän voi olla vaikuttanut esimerkiksi sähkökatko tai muu järjestelmähäiriö.


Lämpimimmän ja viileimmän asunnon lämpötilojen erotus on ollut noin 2 - 3 °C -astetta 7.9 asti, jonka jälkeen lämpötilakäyristä ei ole saatu informaatiota lähes kahteen kuukauteen. Vastaava käyttäytyminen on kuitenkin jatkunut 12.11 jälkeen, kun sensorit ovat jälleen toimineet. 21.11 jälkeen kerroksen asuntojen lämpötilat ovat olleet kasvussa lämpimimmän ja viileimmän asunnon lämpötilojen lämpötilaeron kasvaessa vaihtelevaan 2 - 4 °C -asteeseen. Koko mittausjakson ajan asuntojen lämpötila on ollut oleellisesti yli tavoitelämpötilarajan ylärajan 22 °C -astetta. Kun ulkolämpötila on laskenut nollan °C -asteen alapuolelle, asuntojen lämpötilat ovat vaihdelleet välillä 22 - 26 °C -astetta. Suurilla lämpötilan pudotuksilla ei ole ollut huomattavaa vaikutusta asuntojen lämpötilakäyttäytymiseen 21.11 jälkeen.



KUVIO 56. Rakennuksen 1. kerroksen 2. lämpötilat 1.8.2018 - 28.1.2019


KUVIO:ssa 56. on esitetty rakennuksen 1. kerroksen 2. lämpötilojen käyttäytyminen mittausvälillä 1.8.2018 - 28.1.2019. Data on esitetty koko ajalta 75 tunnin välein. Asunnossa 13. on ollut viileintä koko mittausjakson ajan, mutta lämpötila on pysynyt lähellä 22 °C-astetta koko 29.8 jälkeisen ajan. Aikavälillä 1.8. - 7.9 molempien asuntojen lämpötilat ovat olleet laskussa. Asuntojen 13. ja 17. välinen lämpötilaerotus on vaihdellut välillä 1,5 - 2 °C-astetta.

2.11.2018 alkaen asunnon 17. sensorimittaukset eivät ole enää onnistuneet. Kyseisen asunnon mittausarvot ovat toistuneet. Ongelman lienee aiheuttanut sensorivaurio tai tietokantaongelma. Sensorivaurion tapauksessa, on mahdollista, että sensorissa on tallennustilaa, mikä on tarkoitus korvata uudella mittausdatalla ennen lähettämistä palvelimelle. Jos anturipuoli on vaurioitunut, ei vanhaa dataa pysty korvaamaan uusilla mittaus tuloksilla ja palvelimelle tallennettavaksi lähetettävä data vastaa vanhaa dataa. Jos kyseessä on tietokantaongelma, tällöin tietokannan osoite on serverin puolella todennäköisesti vaihtunut ja uusi tietokannan osoite ei ole päivittynyt laitepuolelle. Vaihtoehtona myös on, että datan lukemiseen tarkoitettu osoite on jäänyt päivittämättä muutosten jälkeen.




KUVIO 57. Rakennuksen 1. kerroksen 3. asuntojen lämpötilat 1.8.2018 - 28.1.2019

KUVIO:ssa 57. on esitetty rakennuksen 1. kerroksen 3. lämpötilojen käyttäytyminen mittausvälillä 1.8.2018 – 28.1.2019. Data on esitetty koko ajalta 75 tunnin välein. Aikajaksoista on nähtävissä, että asunnoista ei ole ollut saatavilla dataa aikavälillä 2.9 - 12.11.2018. Lisäksi asunnon 27. lämpötilamittausdataa ei ole ollut saatavilla 18.11 saakka. Tähän voi olla vaikuttanut esimerkiksi sähkökatko tai muu järjestelmähäiriö. Asunnon 23. lämpötila-arvot ovat 22.8 jälkeen, jolloin ulkolämpötilan arvot ovat laskeneet alle 18 °C-asteen, pysytelleet lämpötila välillä 20 - 22,5 °C-astetta lukuun ottamatta 7.9 tapahtunutta lämpötilan piikkiä. Kyseinen piikki on muodostunut ulkolämpötilan kasvun ja aloitetun rakennuksen lämmityksen yhteisvaikutuksena. Asunnon 27. lämpötilakäyrässä on ollut havaittavissa useita lämpötilapiikkejä, mutta muuten sen käytös on muistuttanut asunnon 23. lämpötilakäyrän käytöstä. Kyseiset piikit ovat olleet kovin suurehkoja poikkeamia asunnon lämpötilakäyrän arvoissa, jotka todennäköisesti ovat johtuneet asunnon lämmitysratkaisuista. Lämmitysratkaisua on epäiltävä, sillä piikit ovat sattuneet samoihin ajanjaksoihin ulkoilman lämpötilan pudotuksen kanssa. Toinen mahdollisuus on, että asunnon lämpötilasensori on osin hajonnut eikä pysty suorittamaan mittauksia tasaisesti.




KUVIO 58. Rakennuksen 2. kerroksen 1. lämpötilat 24.9.2018 - 24.1.2019

KUVIO:ssa 58. on esitetty rakennuksen 2. ensimmäisen kerroksen lämpötilojen käyttäytyminen koko mittausväiltä 24.9.2018 - 24.1.2019. Asunnon 1. lämpötila on ollut 18.11.2018 asti alhaisin, jolloin asunnon 4. lämpötila on pudonnut noin yhden celsiusasteen alhaisemmaksi. Tällöin ulkoilman keskilämpötila (vaalean sininen) on pudonnut huomattavasti, mikä on vaikuttanut jokaiseen kerroksen asuntoon, mutta asunnon 4. lämpötila on muuttunut voimakkaimmin. 14.12 - 23.12 asunnon 4. lämpötiläkäyrässä on ollut nähtävissä samankaltaista käyttäytymistä, kun ulkolämpötila on laskenut noin 10 °C -astetta muutaman päivän aikana. Se on myös mahdollista, että asunnon lämmitys on ollut säädettyä alhaisemmaksi kuin muiden kerrosten asuntojen lämpötila. Asunnon 5. lämpötila on ollut likimain 26 °C -astetta 21.11 - 25.11.




KUVIO 59. Rakennuksen 2. kerroksen 2. lämpötilat 24.9.2018 - 24.1.2019

KUVIO:ssa 59. on esitetty rakennuksen 2. kerroksen 2. lämpötilojen käyttäytyminen mittausvälillä 24.9.2018 - 24.1.2019. Asunnon 7. lämpötila on ollut pääsääntöisesti alhaisin, kun asunnon 11. lämpötila on puolestaan ollut korkein. Ulkoilman keskilämpötilan äkilliset pudotukset eivät ole vaikuttaneet voimakkaasti asuntojen lämpötiloihin. Aikaväleillä 18.11 - 3.12 ja 14.12 - 23.12 asunnon 10. lämpötila on ollut asunnoista matalin. Koska asuntojen 4. ja 10. lämpötilakäyrissä on kyseisinä hetkinä näkynyt samankaltaista käytöstä, on selvää, että asuntojen lämmitysten välillä on voimakas yhteys, joka on 18.11 alkaen vaikuttanut lämpötilakäyrien muuttuneeseen käytökseen. Se on myös mahdollista, että asunnon 4. lämmitys on ollut säädettyä alhaisemmaksi kuin muiden kerrosten asuntojen lämpötila tai asunnon lämmityksessä on ollut muita ongelmia. Kerroksen asunnoissa on ollut viileintä aikavälillä 30.10 - 6.11. Huolestuttava merkki on, että asuntojen lämpötilan kasvu samoihin lukemiin on kestänyt noin kahdeksan päivää, sillä ulkolämpötila on pudonnut noin 10 °C - astetta aikavälillä 22.10 - 28.10.



KUVIO 60. Rakennuksen 2. kerroksen 3. lämpötilat 24.9.2018 - 24.1.2019


KUVIO:ssa 60. on esitetty rakennuksen 2. kerroksen 3. lämpötilojen käyttäytyminen mittausvälillä 24.9.2018 – 24.1.2019. Asuntojen lämpötilakäyristä on nähtävissä, että asuntojen lämpötilat ovat pysytelleet lähellä toisiaan 10.11 asti, jonka jälkeen lämpötilakäyrät ovat hajaantuneet erilleen toisistaan noin 2 °C -asteen verran. Se on mahdollista, että lämmitysveden lämpötila ei ole ollut enää riittävä koko rakennuksen asuntojen tasapuoliseen lämmitykseen, kun ulkoilman lämpötila on laskenut pienemmäksi tai yhtä suureksi kuin 5 °C -astetta.



KUVIO 61. Rakennuksen 2. kerroksen 4. lämpötilat 24.9.2018 - 24.1.2019

KUVIO:ssa 61. on esitetty rakennuksen 2. kerroksen 4. lämpötilojen käyttäytyminen mittausvälillä 24.9.2018 - 24.1.2019. Asuntojen lämpötilakäyristä on nähtävissä, että asuntojen 19. ja 20. mittausjaksot ovat olleet liki muuttumattomat aikavälillä 8.10 - 22.10.2018. Asuntojen lämpötilat ovat pysytelleet lähellä toisiaan 23.12 asti, jonka jälkeen lämpötilakäyrät ovat hajaantuneet erilleen toisistaan noin 1,5 °C-asteen verran. Sekin on mahdollista, että lämmitysveden lämpötila ei ole ollut enää riittävä koko rakennuksen asuntojen tasapuoliseen lämmitykseen, kun ulkoilman lämpötila on laskenut pienemmäksi tai yhtä suureksi kuin 5 °C -astetta. Tärkeää on myös huomioida, että lämpötilat ovat silti 10.11 alkaen pysyneet lähes täydellisesti tavoitevälillä 20 - 22 °C-astetta. Asunnon 20. lämpötilakäyrässä on 23.12 ollut nähtävissä poikkeus, jolloin sen lämpötila on laskenut noin 0,5 °C -astetta voimakkaammin muihin lämpötilakäyriin verrattuna. Siinä on myös ollut mahdollista, että kyse on ollut käyttäjän toimista. Kerroksen asunnoissa on ollut viimeimmillään noin 16 °C astetta aikavälillä 30.10 - 6.11.2018.


5.1.2 Tornit



KUVIO 62. Rakennuksen 1. tornin 2. lämpötilat 24.9.2018 - 24.1.2019

KUVIO:ssa 62. on esitetty rakennuksen 1. tornin 2. lämpötilojen käyttäytyminen mittausvälillä 24.9.2018 - 24.1.2019. Mittaukset ovat esitettyinä 75 tunnin välein. Asuntojen lämpötilakäyristä on nähtävissä, että asuntojen 3., 13. ja 23. mittausjaksot eivät ole muuttuneet aikavälillä 2.11 - 12.11.2018. Lisäksi on huomautettava, että rakennuksen datasta myös puuttui kaikki data aikaväliltä 7.9 - 2.11.


Asuntojen lämpötilat ovat olleet hyvin samankaltaisia ja lämpimimmän asunnon eli asunnon 3. ja viileimmän asunnon eli asunnon 23. välinen lämpötilojen erotus on ollut koko seurattavissa olleen ajan noin 2 °C -astetta. 2.11 - 15.11 tapahtunut ulkolämpötilan lasku 21 °C -asteesta noin 5 °C -asteeseen on laskenut myös kaikkien tornin asuntojen lämpötilaa 12.11 - 30.11 välisenä aikana noin 2 °C -asteella. Tämän jälkeen asuntojen lämpötilat ovat viimein katkaisseet asuntojen sisäilman lämpötilan pudotuksen. Asuntojen 13. ja 23. lämmitys on 27.11 - 4.12 ollut voimakkaampaa kuin asunnon 3., mikä on johtunut siitä, että asunnon lämpötila on lähtenyt kasvuun jo 24.11.



KUVIO 63. Rakennuksen 1. tornin 6. lämpötilat 24.9.2018 - 24.1.2019


KUVIO:ssa 63. on esitetty rakennuksen 1. tornin 2. lämpötilojen käyttäytyminen mittaussvälillä 24.9.2018 - 24.1.2019. Mittaukset ovat esitettyinä 75 tunnin välein. Asuntojen lämpötilakäyristä on nähtävissä, että asunnon 7. mittausarvot eivät ole muuttuneet aikavälillä 2.11 - 12.11.2018. Asunnon 27. mittausarvot eivät ole puolestaan vaihtuneet aikavälillä 2.11 - 18.11. Lisäksi on huomautettava, että rakennuksen datasta puuttuu kaikki data aikaväliltä 7.9 - 2.11, mikä on johtunut siitä, ettei kyseistä dataa ole onnistuttu keräämään. Asunnon 17. lämpötilakäyrästä on nähtävissä, että 7.9 jälkeen asunnon lämpötilanmittaukset eivät ole tuottaneet uusia tuloksia vaan vanhaa dataa on päätynyt datasettiin.

Aikavälillä 1.8 - 7.9 asuntojen lämpötilat ovat olleet hyvin samankaltaisia ja lämpimimmän asunnon ja viileimmän asunnon lämpötilojen välinen erotus on ollut noin 2 °C -astetta. Asunnon 27. lämpötilakäyrässä on 22.8 ollut nähtävissä muista poikkeava huippu. Vastaavia huippuja on lisäksi ollut nähtävissä 21.11 jälkeen. Mikäli kyseessä ei ole sensorivirhe, lämmitysjärjestelmän ylireagointi tai jotakin asukkaan toimista johtuvaa käytöstä, on mahdollista, että asunnon 27. eristeiden luokitusta olisi harkittava uudelleen, sillä ulkolämpötilan laskettua 5 °C -asteesta noin -10 °C asteeseen on asunnon 27. lämpötila laskenut (21,5 °C -asteesta 20 °C -asteeseen) nopeammin kuin asunnon 7. lämpötila (23 °C -asteesta 22 °C -asteeseen).




KUVIO 64. Rakennuksen 2. tornin 1. lämpötilat 24.9.2018 - 24.1.2019

KUVIO:ssa 64. on esitetty rakennuksen 2. tornin 1. lämpötilojen käyttäytyminen mittausväliä 24.9.2018 - 24.1.2019. Asuntojen lämpötilakäyristä on nähtävissä, että asunnon 19. mittaukset ovat olleet liki muuttumattomat aikavälillä 8.10 - 22.10.2018, kun puolestaan muiden asuntojen mittausarvot ovat muuttuneet. Asuntojen lämpötilat ovat pysytelleet lähellä toisiaan 28.10 asti, jonka jälkeen asunnon 19. lämpötilakäyrä on jäänyt alhaisemmaksi kuin muiden tornin lämpötilojen keskiarvot. Se on myös mahdollista, että lämmitysveden lämpötila ei ole ollut enää riittävä koko rakennuksen asuntojen tasapuoliseen lämmitykseen, kun ulkoilman lämpötila on laskenut pienemmäksi tai yhtä suureksi kuin 10 °C -astetta. Toinen vaihtoehto voisi olla se, että asunnon 19. lämpötila-anturi on vaurioitunut, kun se ei ole ollut suorittanut mittauksia. 10.11 alkaen asuntojen 1., 7. ja 13. lämpötilat ovat ylittäneet noin 2 °C -asteella tavoitelämpötilan ylärajan 22 °C -astetta, kun asunnon 19. lämpötila on pysytellyt välillä 20 - 22 °C -astetta.




KUVIO 65. Rakennuksen 2. tornin 2. lämpötilat 24.9.2018 – 24.1.2019

KUVIO:ssa 65. on esitetty rakennuksen 2. tornin 2. lämpötilojen käyttäytyminen mittausvälillä 24.9.2018 - 24.1.2019. Asunnon 20. mittaukset ovat olleet liki muuttumattomat aikavälillä 8.10 - 22.10.2018, kun puolestaan muiden asuntojen mittausarvot ovat muuttuneet. Asuntojen 2. ja 8. lämpötilat ovat olleet lähes identtiset koko mittausjakson ajan kunnes 3.12 asunnon 8. lämpötila on koko loppu mittausjakson ajaksi jäänyt noin 0,5 °C -astetta pienemmäksi kuin asunnon 2. lämpötila-arvot. Asunnon 14. lämpötila-arvot ovat lähes koko mittausjakson olleet noin 1,5 °C -astetta alhaisemmat kuin asunnon 2. lämpötila-arvot. 28.10 alkaen asunnon 20. lämpötilojen keskiarvot ovat olleet tornin alhaisimmat johtuen siitä, että asunto sijaitsee ylimmässä kerroksessa. Aikavälillä 28.10 – 6.11 asuntojen lämpötilat ovat olleet myös matalimmillaan vaihdellen noin 16 °C -asteesta 19 °C -asteeseen. Ulkolämpötilan keskilämpötilan yli -10 °C -asteen pudotus läheisinä päivinä näyttäisi aiheuttaneen pudotuksen myös tornin asuntojen 14. ja 20. arvoihin 23.12.2018.




KUVIO 66. Rakennuksen 2. tornin 3. lämpötilat 24.9.2018 - 24.1.2019

KUVIO:ssa 66. on esitetty rakennuksen 2. tornin 3. lämpötilojen käyttäytyminen mittausvälillä 24.9.2018 - 24.1.2019. Asuntojen lämpötilakäyristä on nähtävissä, että osa asunnon 3. mittauksista puuttuu aikaväliltä 28.9 - 8.10, mikä voi olla johtunut esimerkiksi ongelmista eri datasettien yhdistämisessä. Tämä ei kuitenkaan ole ollut tarkastelun kannalta ongelma, sillä kaikista tornin asunnoista on ollut mittausarvoja 8.10 alkaen. Asuntojen lämpötilat ovat pysytelleet lähellä toisiaan 10.11 asti, jolloin asuntojen lämpötilakäyrien lämpimimmän ja viileimmän välinen erotus on kasvanut noin 2 °C -asteen erotuksesta suurimmillaan noin 4 °C -asteen erotukseksi. Koko mittausjakson aikana viileintä on ollut asunnossa 21., jolloin sen lämpötila on ollut noin 16 °C -astetta, mikä on johtunut asunnon matalasta lämpötilasta ja ulkolämpötilan äkillisestä pudotuksesta aikavälillä 22.10 - 28.10. Asunnossa 3. on ollut lämpimintä koko mittausjakson ajan ollen noin 25 °C -astetta aikavälillä 18.11 - 3.12.




KUVIO 67. Rakennuksen 2. tornin 4. lämpötilat 24.9.2018 – 24.1.2019

KUVIO:ssa 67. on esitetty rakennuksen 2. tornin 4. lämpötilojen käyttäytyminen mittausväliä 24.9.2018 - 24.1.2019. Asuntojen lämpötilakäyristä on nähtävissä, että asuntojen mittausarvojen välillä on ollut paljon hajontaa. Mittausarvojen väliset erot suurimman ja pienimmän päivittäisen lämpötila-arvon välillä ovat vaihdelleet noin 1 °C -asteesta 4 °C -asteeseen. Asuntojen 4., 10. ja 16. lämpötilat ovat laskeneet voimakkaasti aikavälillä 14.11 - 25.11, mikä on johtunut ulkolämpötilan äkillisestä noin -10 °C -asteen laskusta 18.11 - 20.11. Poikkeavaa on se, että asunnossa 22. ei ole kyseistä lämpötilan laskua näkynyt. Se on myös mahdollista, että tämä on johtunut asukkaan toimista tai siitä, että asunnon lämpötila on ollut kasvussa ennen ulkolämpötilan voimakasta ja äkillistä laskua. Koko mittausjakson aikana viileintä on ollut asunnossa 22. noin 16 °C -astetta. Asunnossa 4. on pääsääntöisesti ollut lämpimintä koko mittausjakson ajan ollen melkein 25 °C -astetta aikavälillä 3.1 - 7.1. Asunnossa 16. on ollut lämpimintä 18.11 noin 25 °C -asteella. Asuntojen 4. ja 10. lämpötilakäyrissä on ollut nähtävissä voimakasta kasvua 21.12.2018 - 3.1.2019 aikana, mikä on johtunut asuntojen aiemmin laskeneesta lämpötilan trendistä sekä ulkolämpötilan laskusta alle -10 °C -asteeseen 23.12.2018.



KUVIO 68. Rakennuksen 2. tornin 5. lämpötilat 24.9.2018 - 24.1.2019


KUVIO:ssa 68. on esitetty rakennuksen 2. tornin 5. lämpötilojen käyttäytyminen mittaustuloksilla 24.9.2018 - 24.1.2019. Asuntojen dataa puuttuu aikaväliltä 4.10 - 8.10.2018. Asunnon 23. lämpötila on ollut pääsääntöisesti alhaisin, kun asuntojen 5. ja 11. lämpötilat ovat puolestaan pääsääntöisesti olleet lämpimimmät. Ulkoilman keskilämpötilan äkilliset pudotukset eivät ole vaikuttaneet voimakkaasti asuntojen lämpötiloihin. Aikavälillä 18.11 - 3.12 asuntojen lämpötila-arvot ovat muodostaneet samankaltaisen pykälän lämpötilakäyriinsä, mikä lienee johtunut lämmitysjärjestelmän ratkaisusta asuntojen lämmittämiseksi. Datan perusteella kyseessä ei ole kohta, jolloin anturit eivät olisi keränneet mittaustuloksia vaan mittauservoja on kertynyt hyvin tasaisista lämmitysarvoista. Asuntojen 5., 11. ja 17. lämpötilat ovat pysytelleet lähellä toisiaan, kunnes 10.11 asunnon 17. lämpötila ei ole enää noussut samalle tasolle asuntojen 5. ja 11. lämpötilojen kanssa. Ero on suurimmillaan ollut noin 0,7 °C-astetta. 10.11.2018 alkaen myös asunnon 23. lämpötila on jäänyt entisestään noin 2 °C-astetta matalammaksi kuin asuntojen 5. ja 11. lämpötilat. Asunnon 11. lämpötila on poikennut 24.1.2019 käyrän ja asunnon 5. lämpötilakäyrän käytöksestä laskien noin 1 °C-asteen. Todennäköisesti tähän on ollut syynä ero käytettävissä olleen datan muuttujakohtaisissa määrittämissä. Siksi sitä ei voida välttämättä voi lukea poikkeavuudeksi.



KUVIO 69. Rakennuksen 2. tornin 6. lämpötilat 24.9.2018 - 24.1.2019


KUVIO:ssa 69. on esitetty rakennuksen 2. tornin 6. lämpötilojen käyttäytyminen mittausväillä 24.9.2018 - 24.1.2019. Asunnon 6. lämpötila on ollut pääsääntöisesti korkein käyden korkeimmillaan noin 25 °C-asteessa. Asunnon 24. lämpötilan keskiarvot ovat puolestaan olleet matalimmat. Aikavälillä 28.10 - 1.11 asuntojen lämpötilat ovat olleet matalimmillaan asunnon 24. lämpötilan käydessä jopa 16 °C-asteessa. Lämpimimmän ja viileimmän asunnon lämpötilaerotus on 24.9 - 28.10 ollut noin 2 °C-astetta, 28.10 - 14.11 ollut noin 4,5 °C-astetta, 14.11 - 21.12 noin 4 °C-astetta ja 21.12.2018 - 24.1.2019 noin 2 °C-astetta. Eron muodostuminen johtunee siitä, että asunnon 24. lämmittäminen on ollut hidasta, joten sen eristeluokan parantaminen saattaisi parantaa asukastyytyvyyttä. 3.1 - 7.1 asunnon 24. datassa käyrä on ollut lähes vaakasuora, mutta datan perusteella kyseessä on kohta, jolloin mittausarvoja on kertynyt hyvin tasaisista lämmitysarvoista.

5.1.3 Connectit




Kuvio 70. Connect Lämmitys muuttujien lämpötila-arvot 14.12.2018 - 29.1.2019

KUVIO:ssa 70. on esitetty Connect Lämmitys –muuttujien meno- ja paluuveden lämpötilamittaukset aikaväliltä 14.12.2018 - 29.1.2019. Connect Lämmitys 1. Meno –muuttujan mittausarvot ovat olleet suurimmat koko mittausvälillä vaihdellen 40 °C-asteesta noin 60 °C-asteeseen. Connect Lämmitys 2. Meno –muuttujan lämpötila-arvot ovat olleet toiseksi korkeimmat vaihdellen välillä 29 - 34 °C-astetta. Connect Lämmitys 1. Paluu –muuttujan ja Connect Lämmitys 2. Paluu –muuttujan lämpötilakäyrät ovat olleet lähes samat vaihdellen välillä 27,5 – 30,5 °C-astetta. Kuvaajassa on lisäksi esitetty ulkoilman lämpötila, joka on vaihdellut välillä 5 - 26 °C-astetta. Kuvaajasta voidaan helposti huomata, että lukuun ottamatta aikavälin 14.12 - 19.12 dataa lämmitysveden meno ja paluuarvojen käyrät ovat peilikuvia ulkolämpötilan käyrälle.




KUVIO 71. Connect Lämmitys 1 –muuttujien lämpötila-arvot 14.12.2018 - 29.1.2019

KUVIO:ssa 71. on esitetty Connect Lämmitys 1. -muuttujien meno- ja paluuveden lämpötilamittaukset aikaväliltä 14.12.2018 - 29.1.2019. Connect Lämmitys 1. Meno –muuttujan mittausarvot ovat olleet suurimmat koko mittausvälillä vaihdellen 40 °C-asteesta noin 60 °C-asteeseen. Erityisesti aikavälillä 14.12.2018 - 18.12.2018 menoveden lämpötila on ollut liki 60 °C-astetta. Siinä on mahdollista, että kyseessä on sensorivirhe, mutta Connect Lämmitys 1. Paluu –muuttujan lämpötila-arvot kyseisellä aikavälillä ovat olleet huipun muodon kannalta kovin samanlaiset kuin menoveden lämpötilan. Siten todennäköisesti on, että menoveden lämpötila on ylittänyt mittausanturin mittausvälin. Päivinä 24.12, 2.1, 3.1 ja 21.1 samaisessa käyrässä on nähtävissä teräviä pohjia, jotka mahdollisesti vastaavat mittausvirheitä datassa, sillä vastaavia pohjia ei ole helposti havaittavissa Connect Lämmitys 1. Paluu –muuttujan lämpötilakäyrässä. Paluuveden lämpötila on pysytellyt koko mittausjakson aikana välillä 29 - 31 °C-astetta.




KUVIO 72. Connect Lämmitys 2 –muuttujien lämpötila-arvot 14.12.2018 - 29.1.2019

KUVIO:ssa 72. on esitetty Connect Lämmitys 2. –muuttujien meno- ja paluuveden lämpötilamittaukset aikaväliltä 14.12.2018 – 29.1.2019. Connect Lämmitys 2. Meno –muuttujan mittausarvot ovat olleet suurimmat koko mittausvälillä vaihdellen 29 °C-asteesta noin 34 °C-asteeseen. Connect Lämmitys 2. Paluu –muuttujan lämpötila-arvot ovat vaihdelleet välillä 28 - 30 °C-astetta. Connect Lämmitys 2. Paluu –muuttujan lämpötila-arvojen käyrän muodon perusteella, rakennuksen lämmittämiseen ei vaikuta muu kuin lämmitysveden lämpötila ja KUVIO:n 67. perusteella ulkolämpötilan käytös. Mittausjakson huippujen ja pohjien muodot sekä sijoittumiset vastaavat toisiaan lähes täysin eikä tällä aikavälillä ole nähtävissä selkeitä poikkeamia. Havaittavissa kuitenkin on, että Connect Lämmitys 2. Paluu –muuttujan arvot tulevat Connect Lämmitys 2. Meno –muuttujan arvoihin nähden jäljessä.



KUVIO 73. Connect Lämmitys –muuttujien lämpötila-arvot 14.12.2018 - 29.1.2019


KUVIO:ssa 73. on esitetty Connect Lämmitys –muuttujien lämpötila-arvot aikaväliltä 14.12.2018 - 29.1.2019 ilman Connect Lämmitys 1. Meno –muuttujaa ja ulkoilman lämpötilan arvoja. Connect Lämmitys 1. Paluu –muuttujan (sininen) ja Connect Lämmitys 2. Paluu –muuttujan (vihreä) arvojen välinen samankaltaisuus on ollut hyvin suurta pois lukien aikavälin 14.12 - 18.12 mittausarvot, jolloin Connect Lämmitys 1. Paluu –muuttujan arvot ovat olleet noin 1 °C-asteen suuremmat kuin Connect Lämmitys 2. Paluu –muuttujan arvot. Muina mittausjakson hetkinä näiden välinen erotus on ollut noin 0,2 °C-astetta. Poikkeuksellisesti 18.12.2018 - 20.12.2018 ja 7.1.2019 - 9.1.2019 Connect Lämmitys 1. Paluu –muuttujan arvot ovat olleet matalammat kuin Connect Lämmitys 2. Paluu –muuttujan mittausarvot, mikä lienee johtunut siitä, että ulkolämpötilan keskiarvot ovat laskeneet 2 - 3 päivässä noin 10 °C-astetta.



KUVIO 74. Connect Lämmitys –muuttujien korrelaatiomatriisi

KUVIO:ssa 74. on esitetty Connect Lämmitys –muuttujien korrelaatiomatriisi välille 0 - 1 skaalatulle datalle heatmap-esityksenä aikaväliltä 21.9 - 25.9.2018. Korrelaatio kuvastaa sitä kuinka samanlaisia kaksi toisiinsa verrattavaa muuttujaa ovat. Mikäli muuttujien välillä on samankaltaisuutta, korrelaatioarvo on lähellä arvoa 1 tai -1, mikäli muuttujien arvojen välillä tapahtuu peilautumista. Korrelaatioarvo on nolla, jos muuttujien välillä ei ole ollenkaan samankaltaisuuksia. Connect Lämmitys 1. Meno –muuttujan ja Connect Lämmitys 2. Paluu –muuttujan välinen korrelaatio on jäänyt matalimmaksi arvolla -0.87, joten näiden muuttujien arvojen käytös ovat toistensa peilikuvia. kaikkien Connect Lämmitys –muuttujien korrelaatio on erinomainen. Erityisesti Connect Lämmitys 1. Paluu on lähes samankaltainen kuin Connect Lämmitys 2 Meno tai Connect Lämmitys 2. Paluu.


5.1.4 Mama



KUVIO 75. Paineilma Mama –muuttujien lämpötila-arvot 7.10.2018 - 29.1.2019


Seuraavissa kuvaajissa ovat esitettyinä Paineilma Mama kolmen tunnin s –muuttuja (sininen) ja Paineilma Mama ulkolämpötila –muuttuja (oranssi) yhdessä sääpalvelusta saadun ulkoilman lämpötila –datan (vihreä) kanssa. Tarkasteluvälillä 7.10.2018 - 28.10.2018 ulkoilman lämpötila on vaihdellut välillä -7 - 15 °C-astetta, kun sekä Paineilma Mama ulkolämpötila –muuttuja että Paineilma Mama kolmen tunnin s –muuttuja eli ennuste seuraavalle kolmelle tunnille ovat vaihdelleet välillä -7 - 10 °C-astetta. Aikaväliltä 28.10.2018 - 16.11.2018 Paineilma Mama- muuttujien mittauksia ei ole.

Aikajaksolta 5.12.2018 - 18.12.2018 on nähtävissä, kuinka Paineilma Mama kolmen tunnin s –muuttuja (KUVIO 75), joka kuvaa seuraavan kolmen tunnin ennustettua sään arvoa, on pääsääntöisesti huomattavasti alhaisempi muita muuttujia samalla aikavälillä. Aikavälillä 27.12.2018 - 29.1.2019 tämä kolmen tunnin sään ennuste on kuvastanut paremmin Paineilma Mama ulkolämpötila –muuttujan ja ulkoilman lämpötilan käytöstä. Tosin tämän aikavälin alussa on ollut nähtävissä suuria ennustevirheitä verrattuna todelliseen arvoon. Se on todennäköistä, että kolmen tunnin lämpötilan ennuste on laadittu perustuen kylmempien ulkolämpötilojen käyttäytymiseen, mikä selittäisi sen, miksi ennustetun ja todellisen arvon välinen ero on ollut aikavälillä 6.12.2018 - 14.12.2018 suuri.



Kuvio 76. Paineilma Mama –muuttujien lämpötila-arvot 7.10.2018 - 29.1.2019


Tässä kuvaajassa (KUVIO 76) on esitetty Paineilma Mama kolmen tunnin s –muuttuja (sininen) ja Paineilma Mama ulkolämpötila –muuttuja (oranssi) yhdessä aikaväliltä 7.10.2018 - 29.1.2019. Se on huomioitava, että kolmen tunnin sään ennuste (Paineilma Mama kolmen tunnin s -muuttuja) on ilmeisesti laskettu hieman kylmemmillä ulkolämpötilan arvoilla, sillä ennusteet ovat 2.12.2018 - 18.12.2018 jääneet alhaisemmiksi kuin todelliset lämpötila-arvot. Ulkolämpötilan käyrässä on myös 11.10.2018 - 28.10.2018 nähtävissä kaksi poikkeamaa, jolloin mittari ei ole mitannut mitään.



KUVIO 77. Paineilma Mama –muuttujien korrelaatiomatriisi


KUVIO:ssa 77. on esitetty Paineilma Mama –muuttujien sekä ulkoilman lämpötilan korrelaatiokerroin matriisi skaalatulle datalle. Paineilma Mama kolmen tunnin s –muuttuja ja Ilman lämpötila (degC) –muuttuja ovat käyttäytyneet enemmän toistensa kaltaisesti kuin Paineilma Mama ulkolämpötila -muuttujan, joka on kuvannut rakennuksen 2. todellista välitöntä ulkoilman lämpötilaa. Tästä voidaan päätellä, että Paineilma Mama kolmen tunnin s –muuttujan ja Ilman lämpötila (degC) –muuttujien välillä on jokin yhteys. se on mahdollista, että kolmen tunnin sää lasketaankin sääpalvelun arvoista. Kaikkien lämpötilamuuttujien välinen korrelaatio on ollut erittäin voimakasta ja täten samankaltaista.

5.1.5 Poikkeuksia




KUVIO 78. Rakennus 2. koottuja poikkeamia

KUVIO:ssa 78. on esitetty rakennuksen 2. koottuja lämpötilan poikkeamia asuntojen 2., 7. ja 10. avulla. Ensimmäinen poikkeuma on ollut datan alussa jolloin asunnon 7. datasetti on sisältänyt selkeästi muusta datasta poikkeavan arvon nolla °C-astetta. Välillä 21.9 – 25.9 asunnon 10. lämpötila on ollut muiden asuntojen lämpötilaa noin 2 °C-asteella alhaisempi. Välillä 4.10 - 7.10 asunnon 2. lämpötilassa on nähtävissä kaksi kappaletta lämpötilan pohjia, jotka ovat selkeitä poikkeamia ympäröivistä lämpötila-arvoista.



KUVIO 79. Rakennus 2

5.1.6 Aikaero



KUVIO 80. Asuntojen lämpötilan keskiarvon ja ulkolämpötilan käytös (15.12.2018 - 7.1.2019)

KUVIO:ssa 80. on esitetty rakennuksen 2. asuntojen yhteisen lämpötilan keskiarvon käyttäytyminen aikavälillä 15.12.2018 - 7.1.2019. Kuvio esittää rakennuksen 2. asuntojen yhteisen lämpötilan keskiarvon käyttäytymistä suhteessa ulkoilman lämpötilan käyttäytymiseen aikavälillä 15.12.2018 - 7.1.2019, josta on poistettu kaikki yli 25 peräkkäistä tuntia muuttumattomina olleet mittaustulokset, karsittu pois ylimääräiset datapisteet sekä laskettu tunnin ja edeltävän tunnin erotus. Tämä vastaa seuraavan kuvion 100 esittämän taulukon ryhmän kaksi dataa ja on tässä esitetty vain vertailun vuoksi. Kuvion (KUVIO 80) perusteella näyttäisi siltä, että data sisältää hetkiä, jolloin asuntojen lämpötilan keskiarvon käytös (sininen) on jäljessä ulkoilman lämpötilan käytöstä (oranssi).

	aloitus	lopetus	iteraatio	korrelaatio	etaisyys	absoluuttinen_etaisyys	aloitus_pvm	lopetus_pvm
0	0	40	8	-0.320246	-22	NaN	2018-10-23	2018-10-28
1	40	80	0	0.648549	-10	10.0	2018-10-23	2018-10-28
2	80	120	2	0.622666	-8	8.0	2018-10-23	2018-10-28
3	120	160	9	-0.543435	-1	1.0	2018-10-23	2018-10-28
0	0	40	14	-0.319768	-16	NaN	2018-12-15	2019-01-07
1	40	80	16	-0.334010	-14	NaN	2018-12-15	2019-01-07
2	80	120	13	-0.451571	-17	NaN	2018-12-15	2019-01-07
3	120	160	15	-0.219990	-15	NaN	2018-12-15	2019-01-07
4	160	200	16	-0.442753	-14	NaN	2018-12-15	2019-01-07
5	200	240	8	0.596301	-2	2.0	2018-12-15	2019-01-07
6	240	280	12	-0.332074	-18	NaN	2018-12-15	2019-01-07
7	280	320	15	-0.413949	-15	NaN	2018-12-15	2019-01-07
8	320	360	8	0.588303	-2	2.0	2018-12-15	2019-01-07
9	360	400	20	-0.596414	10	10.0	2018-12-15	2019-01-07
10	400	440	6	0.513580	-4	4.0	2018-12-15	2019-01-07
11	440	480	17	-0.428162	-13	NaN	2018-12-15	2019-01-07
12	480	520	15	-0.535085	5	5.0	2018-12-15	2019-01-07
13	520	560	8	0.514137	-2	2.0	2018-12-15	2019-01-07
0	0	40	18	-0.501282	8	8.0	2019-01-12	2019-01-21
1	40	80	10	-0.809521	0	0.0	2019-01-12	2019-01-21
2	80	120	14	-0.397427	-16	NaN	2019-01-12	2019-01-21
3	120	160	16	-0.543220	6	6.0	2019-01-12	2019-01-21
4	160	200	6	-0.408375	-24	NaN	2019-01-12	2019-01-21


KUVIO 81. Asuntojen lämpötilan keskiarvon tunnittainen etäisyys ulkoilman lämpötilaan nähden

KUVIO:ssa 81. on esitetty rakennuksen 2. asuntojen yhteisen lämpötilan keskiarvon käyttäytyminen taulukkona. Taulukko on muodostettu datasta, josta on poistettu kaikki yli 25 peräkkäistä tuntia muuttumattomina olleet mittauksilukut. Datasta oli lisäksi karsittu kaikki ylimääräiset datapisteet, laskettu tunnin ja edeltävän tunnin erotus ja näistä muodostuneista dataryhmistä kolme pisintä jatkuvaa ryhmää oli valittu tarkastelua varten. Ryhmä yksi muodostui datasetin päivämäärien 23.10.2018 - 28.10.2018 mittauksista, ryhmä kaksi muodostui datasetin päivämäärien 15.12.2018 - 7.1.2019 mittauksista ja ryhmä kolme muodostui datasetin päivämäärien 12.1.2019 - 21.1.2019 mittauksista. Näiden ryhmien välille [0 – 1] skaalatulle datalle tehtiin aloitus ja lopetus sarakkeiden mukainen väliarvoinen korrelaatiotarkastelu, missä lähin korrelaation etäisyys välin puolivälin pisteeseen, mikäli korrelaatioarvon absoluuttinen raja 0,50 ylittyi, valikoitui todelliseksi erotukseksi asuntojen keskiarvon ja ulkolämpötilan välillä. Jos mikään laskettu korrelaatioarvo ei ylittänyt absoluuttista rajaa, todelliseksi etäisyydeksi valittiin suurimman absoluuttisen korrelaation etäisyys välin puolimatkan pisteestä. Kuviossa (KUVIO 96) lämpötilojen erotus on taulukoitu etäisyys –sarakeeseen, missä negatiivinen arvo kuvastaa sitä, että asuntojen lämpötilan keskiarvon käyttö on saapunut jäljessä ulkoilman lämpötilan käyttöön. Absoluuttinen_ etäisyys –sarakeessa on vastaava etäisyys ilmoitettuna absoluuttisena arvona. Mikäli sen arvo on Nan, kuvastaa se sitä, että yli 0,5 olevia korrelaatioarvoja ei ole löydetty tällä välillä vaan paras mahdollinen tulos on valittu etäisyydeksi.

Taulukosta on nähtävissä, että aikavälillä 23.10.2018 - 28.10.2018 asuntojen lämpötilojen yhteinen keskiarvo on aluksi ollut noin 22 tuntia jäljessä ulkoilman lämpötilan käytöstä. Keskiarvon ja ulkoilman lämpötilan käytösten välinen ero on kuitenkin kaventunut noin 8 tuntiin asuntojen keskiarvon ollessa ulkoilman lämpötilaa jäljessä.

Ryhmän kaksi aikana asuntojen lämpötilan keskiarvon muutokset ovat ensimmäisten 360 tunnin aikana olleet ulkolämpötilan muutoksia jäljessä keskiarvoisesti noin 12,5 tuntia mediaaniarvon ollessa -14 tuntia. Aikavälillä 30.12.2018 - 7.1.2019 eli ryhmän sisäisellä välillä 360 - 560 tuntia asuntojen lämpötilan keskiarvon käyttö on suurimmillaan ollut noin 10 tuntia edellä ulkoilman lämpötilan käytöstä. Tällä ryhmän sisäisellä tuntivälillä asuntojen lämpötilan keskiarvon käyttö on ollut keskimäärin 4 tuntia jäljessä ulkoilman lämpötilan muutosta.

Ryhmässä kolme asuntojen lämpötilan keskiarvon käyttö on ollut ensimmäisen 40 tunnin aikana noin 8 tuntia edellä ulkoilman lämpötilan käytöstä ja seuraavan 40 tunnin aikana muuttujien välillä ei ole ollut aikaeroa. Tämän jälkeen asuntojen lämpötilojen keskiarvon käyttö on tullut ulkoilman lämpötilan käytöstä jäljessä noin 11 tuntia.



KUVIO 82. Asuntojen lämpötilan keskiarvon ja Mama kolmen tunnin s -muuttujan käytös (23.10.2018 - 28.10.2018)

KUVIO:ssa 82. on esitetty rakennuksen 2. asuntojen yhteisen lämpötilan keskiarvon käyttäytyminen aikavälillä 23.10.2018 - 28.10.2019. Kuvio (KUVIO 98) esittää rakennuksen 2. asuntojen yhteisen lämpötilan keskiarvon käyttäytymistä suhteessa ulkoilman seuraavan kolmen tunnin lämpötilan ennusteiden käyttäytymiseen datalla, josta on poistettu kaikki yli 25 peräkkäistä tuntia muuttumattomina olleet mittaustulokset, karsittu pois ylimääräiset datapisteet sekä laskettu tunnin ja edeltävän tunnin erotus. Tämä vastaa seuraavan kuvion (KUVIO:ssa 83) esittämän taulukon ryhmän kaksi dataa ja on tässä esitetty vain vertailun vuoksi. Kuvion perusteella näyttäisi siltä, että asuntojen lämpötilan keskiarvon käytös (sininen) on selkeästi jäljessä ulkoilman lämpötilan ennusteiden käytöstä (oranssi). Tarkastelu on kuitenkin helpommin tulkittavissa seuraavan kuvion perusteella.

	aloitus	lopetus	iteraatio	korrelaatio	etaisyys	absoluuttinen_etaisyys	aloitus_pvm	lopetus_pvm
0	0	40	20	-0.431253	-10	NaN	2018-10-23	2018-10-28
1	40	80	10	-0.481531	-20	NaN	2018-10-23	2018-10-28
2	80	120	1	-0.343957	-29	NaN	2018-10-23	2018-10-28
3	120	160	20	0.590287	10	10.0	2018-10-23	2018-10-28
4	160	200	12	-0.468664	-18	NaN	2018-10-23	2018-10-28
5	200	240	4	0.524465	-6	6.0	2018-10-23	2018-10-28
6	240	280	1	0.500564	-9	9.0	2018-10-23	2018-10-28
7	280	320	12	-0.361641	-18	NaN	2018-10-23	2018-10-28
8	320	360	11	-0.336528	-19	NaN	2018-10-23	2018-10-28
9	360	400	4	0.615638	-6	6.0	2018-10-23	2018-10-28
10	400	440	20	-0.191868	-10	NaN	2018-10-23	2018-10-28
11	440	480	8	-0.326184	-22	NaN	2018-10-23	2018-10-28
12	480	520	15	-0.373660	-15	NaN	2018-10-23	2018-10-28
13	520	560	19	-0.559434	9	9.0	2018-10-23	2018-10-28
0	0	40	19	0.541015	9	9.0	2019-01-16	2019-01-21
1	40	80	7	-0.345275	-23	NaN	2019-01-16	2019-01-21
2	80	120	0	-0.396935	-30	NaN	2019-01-16	2019-01-21
3	120	160	7	-0.556929	-3	3.0	2019-01-16	2019-01-21

KUVIO 83. Asuntojen lämpötilan keskiarvon tunnittainen etäisyys Mama kolmen tunnin s - muuttuun nähden

KUVIO:ssa 83. on esitetty rakennuksen 2. asuntojen yhteisen lämpötilan keskiarvon käyttäytyminen taulukkona. Taulukko on muodostettu datasta, josta on poistettu kaikki yli 25 peräkkäistä tuntia muuttumattomina olleet mittaustulokset. Datasta oli lisäksi karsittu kaikki ylimääräiset datapisteet, laskettu tunnin ja edeltävän tunnin erotus ja näistä muodostuneista dataryhmistä kaksi pisintä jatkuvaa ryhmää oli valittu tarkastelua varten. Ryhmä yksi muodostui datasetin päivämäärien 23.10.2018 - 28.10.2018 mittauksista ja ryhmä kaksi muodostui datasetin 16.1.2019 - 21.1.2019 mittauksista. Näiden ryhmien välille [0 – 1] skaalatulle datalle tehtiin aloitus ja lopetus sarakkeiden mukainen väliarvoinen korrelaatiotarkastelu, missä lähin korrelaation etäisyys välin puolivälin pisteeseen, mikäli korrelaatioarvon absoluuttinen raja 0,50 ylittyi, valikoitui todelliseksi erotukseksi asuntojen keskiarvon ja ennustetun kolmen tunnin sään arvojen välillä. Jos mikään laskettu korrelaatioarvo ei ylittänyt absoluuttista rajaa, todelliseksi etäisyydeksi valittiin suurimman absoluuttisen korrelaation etäisyys välin puolimatkan pisteestä. Kuviossa lämpötilojen erotus on taulukoitu etäisyys –sarakeeseen, missä negatiivinen arvo kuvastaa sitä, että asuntojen lämpötilan keskiarvon käytös on saapunut jäljessä suhteessa Mama kolmen tunnin s - muuttujan lämpötilan käytökseen. Absoluuttinen_etaisyys –sarakeessa on vastaava etäisyys


ilmoitettuna absoluuttisena arvona. Mikäli sen arvo on Nan, kuvastaa se sitä, että yli 0,5 olevia korrelaatioarvoja ei ole löydetty tällä välillä vaan paras mahdollinen tulos on valittu etäisyydeksi.

Taulukosta on nähtävissä, että aikavälin 23.10.2018 - 28.10.2018 sisäisellä välillä 0 - 120 tuntia, asuntojen lämpötilojen yhteinen keskiarvo on ollut koko ajan jäljessä ennustettua kolmen tunnin sään lämpötilan käytöstä ja ero on kasvanut -10 tunnista -29 tuntiin tällä välillä. Tärkeää on huomioida, että kyseiset absoluuttiset korrelaatioarvot ovat olleet alhaisempia kuin 0,5, joten etäisyyksien luotettavuus on kyseenalainen. Välillä 120 - 160 asuntojen lämpötilan keskiarvon käytös ja ennustetun lämpötilan käytöksen välinen ero on kuitenkin ollut käänteinen, jolloin asuntojen lämpötilan keskiarvon käytös on ollut 10 tuntia ennustetta edellä. Ryhmän sisäisellä välillä 160 - 520 asuntojen lämpötilan keskiarvon käytös on ollut keskimäärin 13,7 tuntia jäljessä ulkoilman lämpötilan kolmen tunnin sään ennusteiden käytöstä. Viimeisellä välillä 520 - 560 asuntojen lämpötilan keskiarvo on kuitenkin ollut 9 tuntia sään ennusteita edellä.

Aikavälillä 16.1.2019 - 21.1.2019 ryhmän kaksi datalle laskettu asuntojen lämpötilan keskiarvon muutoksen etäisyys ennustettuun ulkoilman lämpötilakäyttöön on aluksi eronnut 9 tunnilla asuntojen lämpötilan keskiarvon käytöksen ollessa 9 tuntia ennusteita edellä. Tämän jälkeen sisäisellä tuntivälillä 40 - 120 asuntojen lämpötilan keskiarvon käytöksen etäisyys on jäänyt keskimääräisesti noin 26 tuntia jälkeen ulkoilman lämpötilaennusteista. Viimeisellä aikavälillä 120 - 160 erotus on kuitenkin kaventunut huomattavasti jääden -3 tuntiin.

5.2 Tekoäly –ja teknologiakartoitus

5.2.1 Lämpötilat suhteessa ulkoilman lämpötilaan




KUVIO 84. Rakennuksen 1. lämpötila suhteessa ulkoilman lämpötilaan (16.11.2018 - 24.1.2019)

KUVIO:ssa 84. on esitetty rakennuksen 1. asuntojen lämpötilan keskiarvot suhteessa ulkoilman lämpötilaan aikavälillä 16.11.2018 - 24.1.2019. Kuvio on muodostettu tämän aikavälin datalla, sillä asunnon 2. poikkeavaa käytöstä ei huolitettu vääristämään asuntojen todellista lämpötilakäytöstä. Lisäksi kohdat, joiden lämpötila-arvot eivät ole muuttuneet yli 25 tuntiin, on poistettu datasetistä. Keskiarvo on laskettu ilman asuntoa 17., sillä asunnon 17. data oli selkeästi pääsääntöisesti virheellistä.

Kuvio esittää täten asuntojen lämpötilojen yhteisen keskiarvon jakaumaa ulkoilman lämpötilavälillä -28 - 3 °C-astetta. Suurinta lämpötilahajauma on kyseisellä mittausvälillä ollut silloin, kun ulkoilman ilmanlämpötila on ollut välillä -15 - -10 °C-astetta, jolloin asuntojen keskiarvot ovat vaihdelleet välillä 22.8 - 23,95 °C-astetta. Toiseksi suurinta hajauma on ollut lämpötilavälillä -21 - 17 °C-astetta, jolloin se vaihteli välillä 22,8 - 23,4 °C-astetta. Asuinnoissa on ollut viileintä silloin, kun ulkolämpötila on ollut noin -7 °C-astetta. Tällöin asuntojen lämpötilahajauma on ollut välillä 22,7 - 23,3 °C-astetta.

Lämpötilan keskiarvojen hajauma ulkoilman lämpötila jakaumana on tyypillinen tälle mittausjaksolle. Tutkittavaksi jää olisiko seuraavan vuoden lämpötilamittausten jakauma samanlainen tämän kertaiseen lämpötilahajaumaan.




KUVIO 85. Rakennuksen 1. asuntojen lämpötilan muutos suhteessa ulkolämpötilaan (16.11.2018 - 24.1.2019)

KUVIO:ssa 85. on esitetty rakennuksen 1. asuntojen lämpötilan keskiarvojen muutoksen hajauma suhteessa ulkoilman lämpötilan arvoihin lämpötilavälillä -28 - 3 °C-astetta. Laskelmissa on käytetty aikaväliä 16.11.2018 - 24.1.2019, kun on selvitetty asuntojen keskiarvo ilman asunnon 17. dataa. Lisäksi datasettiä oli työstetty hieman loppupäästä, sillä asunnon 2. todennäköisesti asukkaan aiheuttamien mittauspoikkeamien arvojen ei haluttu vääristävän asuntojen todellista lämpötilakäytöstä. Saaduille aika-akselin keskiarvoille on sitten laskettu kyseisen tunnin ja edeltävän tunnin keskiarvojen erotukset. Tämä on analogista nopeuden laskemiseen.

Lämpötilan muutoksien lämpötilahajauma on ollut positiivisinta, kun ulkoilman ilmanlämpötila on ollut välillä -12 - 11 °C-astetta. Tällöin tunninaikaiset lämpötilan muutokset ovat vaihdelleet välillä -0.1 – 0.45 °C-astetta. Negatiivisinta asuntojen lämpötilamuutos on ollut silloin, kun ulkoilman lämpötila on ollut noin -14 °C-astetta. Asuntojen lämpötilan yhteisen keskiarvon muutos on tuolloin vaihdellut välillä -0.4 - 0 °C-astetta tunnissa. Asuntojen lämpötilan yhteisen keskiarvon muutos on vaihdellut välillä -0.25 - 0.2 °C-astetta tunnissa, kun ulkoilman lämpötila on ollut välillä -10 - 3 °C-astetta.


Kuviosta selviää siis asuntojen yhteisen lämpötilakeskiarvon yhden tunnin aikaisten lämpötilamuutosten hajauma ulkolämpötilan lämpötilavälillä -28 – 3 C-astetta. Jakauma on yksilöllistä tämän rakennuksen lämpötilakäyttäjymiselle tällä kyseisellä aikavälillä. Lisätutkimukselle on tarvetta, sillä tällainenkin data voi olla merkittävää. Erityisesti mikäli lämpötilan muutosnopeuksia ulkoilman lämpötilan jakaumina halutaan verrata usealta vuodelta. Usealta vuodelta kerätty data mahdollistaisi yksilöidyn vertaamisen rakennushistoriaan ja asuntojen käyttäytymisen ennustamiseen sekä arvioimiseen.



KUVIO 86. Rakennuksen 1. lämpötilan muutos suhteessa ulkoilman lämpötilan muutokseen (16.11.2018 - 24.1.2019)


KUVIO:ssa 86. on esitetty rakennuksen 1. asuntojen lämpötilan keskiarvojen muutoksen hajauma suhteessa ulkoilman lämpötilan muutokseen yhden tunnin aikana. Ulkoilman lämpötilan muutosväli on ollut -10 - 5 °C-astetta/tunti. Laskelmissa on käytetty aikaväliä 16.11.2018 - 24.1.2019, kun on selvitetty asuntojen keskiarvo ilman asunnon 17. dataa. Lisäksi datasettiä oli tyypistetty hieman loppupäästä, sillä asunnon 2. lämpötiladatan suurta mittauspoikkeamaa pyrittiin välttämään, sillä se olisi vääristänyt asuntojen todellista lämpötilakäytöstä liikaa. Saaduille aika-akselin keskiarvoille on sitten laskettu kyseisen tunnin ja edeltävän tunnin keskiarvojen erotukset, mikä on esitetty suhteessa ulkoilman lämpötilan muutoksiin.

Lämpötilan muutoksien suhde ulkolämpötilan muutoksiin on yksilöllistä tälle rakennukselle, mutta tämän esitysmuodon hyöty on siinä, että se ei ole sidottu suoraan aikaan eikä ulkolämpötilaan. Näin ollen sitä voisi käyttää vertailtaessa rakennuksen asuntojen lämpötilakäyttäytymistä eri vuodenaikoina sekä vertailtaessa muiden samankaltaisten ja samalla alueella sijaitsevien rakennusten väliseen vertailuun. Asuntojen lämpötilamuutos on ollut positiivisimmillaan likimain 0,3 °C-astetta tunnissa samanaikaisesti, kun ulkoilman ilmanlämpötilan muutos on ollut noin -1,5 °C-astetta tunnissa. Kuvaajan värityksestä on kuitenkin pääteltävissä, että kyseinen muutos on ollut poikkeus. Toiseksi suurin lämpötilan muutos arvo on ollut noin 0,24 °C-astetta tunnissa, kun ulkoilman lämpötilan muutos on ollut joko -1,9 C-astetta tai 3,8 °C-astetta.




KUVIO 87. Rakennuksen 1. lämpötilan muutos suhteessa ulkoilman lämpötilan muutokseen (16.11.2018 - 24.1.2019)

KUVIO:ssa 87. on esitetty rakennuksen 1. lämpötilan muutos suhteessa ulkoilman lämpötilan muutokseen aikaväliltä 16.11.2018 - 24.1.2019 ulkoilman muutosnopeuden väliltä -3 °C-astetta/tunti välille 3 °C-astetta/tunti. Tässä tarkennetussa kuvaajassa on mahdollista huomata kuinka asunnon lämpötilan muutokset sijoittuvat suurimmalta osaltaan ulkolämpötilan muutosvälille -1,7 °C-astetta/tunti – 1,6 °C-astetta/tunti. Ulkoilman muutoksen ollessa noin -0,2 °C-astetta tunnissa asuntojen yhteisen keskimääräisen lämpötilan muutos vaihtelee välillä -0,5 °C-astetta/tunti arvoon 0,23 °C-astetta/tunti.




KUVIO 88. Lämpötilan keskiarvot suhteessa ulkoilman lämpötilaan 1.11.2018 - 29.1.2019

KUVIO:ssa 88. on esitetty kaikkien rakennuksen 2. asuntojen lämpötilojen keskiarvot suhteessa ulkoilman lämpötilaan. Kuvio on muodostettu datalla, josta on poistettu kaikki yli 25 tuntia muuttumattomana pysyneet asuntojen arvot. Asuntojen lämpötilat ovat vaihdelleet noin 18 °C-asteesta 23,5 °C-asteeseen, kun ulkoilman lämpötila on ollut suurempaa kuin 0 °C-astetta. Ulkoilman lämpötilan välillä -2 °C-asteesta 2 °C-asteeseen asuntojen keskiarvo on pysytellyt välillä 23 - 23,5 °C-astetta. Kun ulkolämpötilan arvot ovat olleet välillä -14 °C-astetta – -16 °C-astetta, asuntojen keskiarvot ovat vaihdelleet 22,4 °C-asteesta 23,2 °C-asteeseen. Toisin sanoen ulkolämpötilavälillä -16 °C-asteesta 1 °C-asteeseen asuntojen keskilämpötilan kulmakerroin on kasvava. Lämpötilavälillä -18 – -15 °C-astetta asuntojen keskilämpötila on ollut vakaasti noin 22,5 °C-astetta.



KUVIO 89. Rakennuksen 2. asuntojen lämpötilamuutos suhteessa ulkoilman lämpötilaan


KUVIO:ssa 89. on esitetty rakennuksen 2. asuntojen keskiarvoista laskettu tunnitainen muutos suhteessa ulkoilman lämpötilaan. Lämpötilamuutos on laskettu asuntojen yhteiselle keskiarvolle peräkkäisten tuntien avulla aikajakson 1.11.2018 - 29.1.2019 datalla, josta on poistettu kaikki yli 25 tuntia muuttumattomana pysyneet asuntojen arvot. Kuvio ilmentää siis sitä, kuinka mittausjakson aikana asuntojen lämpötilojen yhteisen keskiarvon muutos on hajautunut ulkoilman lämpötilavälille. Ulkoilman lämpötilan ollessa välillä $-16 - -14$ °C-astetta asuntojen lämpötilan keskiarvon muutokset ovat vaihdelleet välillä $-0.07 - 0.25$ °C-astetta tunnissa, mutta käyrän värityksen perusteella vaihtelu on pääsääntöisesti pysynyt välillä $-0,05 - 0.19$ °C-astetta tunnissa. Ilman lämpötilan ollessa välillä $-26 - -23$ °C-astetta asuntojen lämpötilan keskiarvon muutokset ovat olleet negatiivisimmillaan ja vaihdelleet välillä $-0.1 - 0.01$ °C-astetta tunnissa. Näin kylmiä päiviä tiedetään kuitenkin olleen vain vähän. Ulkoilman lämpötilan ollessa välillä $-2 - 9$ °C-astetta asuntojen lämpötilan keskiarvon muutokset ovat pysyneet kapeimmalla välillään $-0.05 - 0.1$ °C-astetta tunnissa. Tämä kohta on siinä mielessä mielenkiintoinen, sillä tarkasteltaessa esimerkiksi KUVIO:sta 58. voidaan huomata, kuinka osa tästä ulkolämpötilavälistä vastaa hetkeä, jolloin rakennuksen 2. kerroksen 1. lämpötilat ovat olleet voimakkaassa nousussa.



KUVIO 90. Asuntojen lämpötilamuutos suhteessa ulkolämpötilan muutokseen tunnin aikana


KUVIO:ssa 90. on esitetty rakennuksen 2. asunnoille lasketun yhteisen keskiarvon muutoksen suhde ulkoilman lämpötilan muutokseen. Muutoksen yksikkö on ilmoitettu muodossa °C-aste/tunti, sillä muutoksen merkitystä on haluttu painottaa. Muutokset on laskettu datalla, josta on poistettu asuntojen mittauspisteet, jotka eivät ole aikadatan perusteella muuttuneet yli 25 tuntiin. Aikavälin 1.11.2018 - 29.1.2019 mittausdatassa on ollut hetki, jolloin ulkoilman lämpötila on peräkkäisten tuntien aikana muuttunut hieman yli -8 °C-astetta. Tällöin asuntojen lämpötilan yhteisen keskiarvon muutos peräkkäisinä tunteina on vaihdellut välillä $-0.35 - -0.2$ °C-astetta, mikä tarkoittaa, että asuntojen lämmitys ei ole pysynyt täysin ulkoilman lämpötilan muutoksen perässä. Asuntojen yhteisen keskiarvon lämpötilan muutos on tällöin

ollut suurimmillaan noin 0.15 °C-astetta negatiivisempi kuin ilman lämpötilan muutoksen vaihdella välillä -2 - 2 °C-astetta/tunti.




KUVIO 91. Rakennuksen 2. asuntojen yhteisen lämpötilan keskiarvon muutos suhteessa ulkolämpötilan muutokseen rajattuna kapeammalle välille (1.11.2018 - 29.1.2019)

KUVIO:ssa 91. on esitetty rakennuksen 2. asunnoille lasketun yhteisen keskiarvon muutoksen suhde ulkoilman lämpötilan muutokseen aikavälin 1.11.2018 - 29.1.2019 datalla. Datasta on poistettu asuntojen mittauspisteet, jotka eivät ole aikadatan perusteella muuttuneet yli 25 tuntiin. Ulkoilman lämpötilan muutoksen ollessa välillä -1,4 - 0.1 °C-astetta/tunti asuntojen lämpötilan keskiarvon muutos on vaihdellut välillä -0,1 - 0.5 °C-astetta/tunti. Ulkoilman muutosvälillä 0.1 - 1,2 °C-astetta/tunti asuntojen lämpötilan muutos vaihtelee välillä -0.05 - 0.1 °C-astetta/tunti. Poikkeuksena on ulkolämpötilan muutos välillä 0,6 - 0,7 °C-astetta/tunti jolloin asuntojen yhteisen lämpötilan keskiarvon muutos on ollut noin 0,2 C-astetta. Pääsääntöisesti koko ulkolämpötilan muutoksen välillä -2 - 2 °-astetta/tunti asuntojen yhteisen lämpötilan keskiarvon muutos on vaihdellut välillä -0,1 - 0,1 °C-astetta.




KUVIO 92. Rakennuksen 2. Connect Lämmitys 1. Meno –muuttujan muutos suhteessa ulkolämpötilaan 1.11.2018 - 29.1.2019

KUVIO:ssa 92. on esitetty rakennuksen 2. Connect Lämmitys 1. Meno -muuttujan arvot suhteessa ulkoilman lämpötilaan aikavälillä 1.11.2018 - 29.1.2019. Ulkolämpötilan ollessa suurempaa tai yhtä suurta kuin 3 °C-astetta menoveden lämpötila on vaihdellut välillä 52,5 - 59 °C-astetta. Lämpötila välillä -7,5 - 3 °C-astetta Connect Lämmitys 1. Meno –muuttujan lämpötila on vaihdellut eniten koko mittausjakson aikana. Sen lämpötilamittaukset ovat vaihdelleet välillä 42 - 59 °C-astetta. Vaihtelu lienee johtunut siitä, että rakennuksen lämmitysjärjestelmä on pyrkinyt lämmittämään asuntoja vaihtelevalla tehokkuudella tällä ulkolämpötilan välillä. Toisin sanoen ulkolämpötilan arvot ovat vaihdelleet usein tällä välillä eikä lämmitysjärjestelmän ole kannattanut lämmittää rakennusta sen jo lämmitettyä riittävästi. Ulkolämpötilan välillä -28 - -12 °C-astetta menoveden lämpötilassa on ollut nähtävissä useita lämpötilan pudotuksia arvojen käydessä jopa noin 41 °C-asteessa. Se on mahdollista, että rakennuksen lämmitysjärjestelmä on pyrkinyt tällöin lämmittämään rakennusta tehokkaammin, jotta minkään asunnon lämpötila ei pääsisi laskemaan liian alhaiseksi poikkeuksellisen kylmän sään vuoksi.




KUVIO 93. Rakennuksen 2. Connect Lämmitys 1. Meno –muuttujan muutos suhteessa ulkolämpötilaan 1.11.2018 - 29.1.2019

KUVIO:ssa 93. on esitetty rakennuksen 2. Connect Lämmitys 1. Meno -muuttujan muutokset peräkkäisinä tunteina suhteessa ulkoilman lämpötilan muutokseen aikavälillä 1.11.2018 - 29.1.2019. Ulkoilman lämpötilavälillä -2 - 7 °C-astetta Connect Lämmitys 1. Meno –muuttujan muutos on ollut kapeimillaan vaihdellen noin välillä -1 - 0.5 °C-astetta/tunti. Ilman lämpötilan ollessa välillä -6 - -2 °C-astetta menoveden muutokset ovat pysytelleet hieman leveämmällä muutosvälillä -2 - 2 °C-astetta/tunti. Tässä on myös havaittavissa, että ulkolämpötilan muuttuessa negatiivisemmaksi myös muuttujan muutosten arvot muuttuvat negatiivisemmiksi. Mahdollista on, että tällä lämpötilavälillä rakennuksen lämmitysjärjestelmä pyrkii reagoimaan lämmityksen tarpeeseen. Ulkolämpötilan välillä -20 - -12 °C-astetta lämmitysveden lämpötilan muutos on vaihdellut välillä -3 - 5 C-astetta/tunti. Tällä välillä on myös useita positiivisia lämpötilapiikkejä, mikä voisi tarkoittaa, että kuumempaa vettä on syötetty lämmitysjärjestelmään kuin edeltävänä tuntina on ollut käytettävissä. Ulkoilman lämpötilavälillä -28 - -20 °C-astetta 2. Connect Lämmitys 1. Meno –muuttujan muutokset ovat vaihdelleet välillä -10 - 3 °C-astetta/tunti. Suureen negatiiviseen piikkiin voi olla syynä sekä ulkolämpötilan poikkeuksellinen viileys sekä lämmitysveden lämpötilan alhaisempi lämpötila kuin edeltävänä tuntina on ollut mitattavissa.




KUVIO 94. Rakennuksen 2. Connect Lämmitys 1. Paluu –muuttujan muutos suhteessa ulkolämpötilaan 1.11.2018 - 29.1.2019

KUVIO:ssa 94. on esitetty rakennuksen 2. Connect Lämmitys 1. Paluu -muuttujan arvot suhteessa ulkoilman lämpötilaan aikavälillä 1.11.2018 - 29.1.2019. Ulkolämpötilan ollessa välillä 3 - 10 °C-astetta paluuveden lämpötila on vaihdellut välillä 29 - 30,3 °C-astetta. Lämpötilavälillä -4 - 3 °C-astetta Connect Lämmitys 1. Paluu –muuttujan lämpötila on vaihdellut laajimmin välillä 28 - 30,3 °C-astetta. Koko mittausdatasta on kuitenkin nähtävissä trendi välillä -18 – 2 °C-astetta, jolloin Connect Lämmitys 1. Paluu –muuttujan lämpötila-arvot kasvavat, kun ulkolämpötila laskee. Tämän muuttujan käytös muistuttaa vahvasti Connect Lämmitys 1. Meno –muuttujan käytöstä, mikä ei kummastuta, sillä molemmat muuttujat mittaavat saman lämmitysjärjestelmän kiertävän veden lämpötiloja.




KUVIO 95. Rakennuksen 2. Connect Lämmitys 1. Paluu –muuttujan muutos suhteessa ulkolämpötilaan 1.11.2018 - 29.1.2019

KUVIO:ssa 95. on esitetty rakennuksen 2. Connect Lämmitys 1. Paluu –muuttujan muutokset suhteessa ulkoilman lämpötilaan aikavälillä 1.11.2018 - 29.1.2019. Ulkolämpötilan ollessa välillä -3 - 4 °C-astetta ovat Connect Lämmitys 1. Paluu -muuttujan muutosarvot vaihdelleet välillä -0.2 - 0.1 °C-astetta/tunti. Ulkolämpötilan viilentyessä Connect Lämmitys 1. Paluu -muuttujan muutosarvot hajaantuvat enemmän. Esimerkiksi välillä -13 - -4 °C-astetta paluuveden muutoksen arvot ovat kasvaneella välillä -0,17 - 0,2 °C-astetta/tunti.




KUVIO 96. Rakennuksen 2. Connect Lämmitys 2. Meno –muuttujan lämpötila-arvot suhteessa ulkolämpötilaan 1.11.2018 - 29.1.2019

KUVIO:ssa 96. on esitetty rakennuksen 2. Connect Lämmitys 2. Meno –muuttujan lämpötila-arvot suhteessa ulkoilman ilmanlämpötilaan aikaväliltä 1.11.2018 - 29.1.2019. Connect Lämmitys 2. Meno –muuttujan lämpötila-arvot ovat vaihdelleet välillä 29,3 - 31,2 °C-astetta, kun ulkolämpötilan lämpötila-arvot ovat vaihdelleet välillä 1 - 10 °C-astetta. Kuljettaessa ulkolämpötilan arvosta 1 °C-aste lämpötilaan - 12 °C-astetta kasvavat menoveden lämpötilan arvot tasaisesti. Välillä -16 - -12 °C-astetta muuttujan lämpötila-arvojen kasvu on pysähtynyt välille 32,4 - 33,5 °C-astetta. Ulkoilman lämpötilavälillä -28 - -18 °C-astetta Connect Lämmitys 2. Meno –muuttujan arvoissa on nähtävissä lämpötilan pudotuksia, joiden erotus oletettavaan tarkoitettuun lämpötilaan on eronnut noin 1,5 - 2 °C-asteella.




KUVIO 97. Rakennuksen 2. Connect Lämmitys 2. Meno –muuttujan muutos suhteessa ulkolämpötilaan 1.11.2018 - 29.1.2019

KUVIO:ssa 97. on esitetty rakennuksen 2. Connect Lämmitys 2. Meno –muuttujan lämpötila- arvojen muutos suhteessa ulkoilman ilmanlämpötilaan aikaväliltä 1.11.2018 - 29.1.2019. Connect Lämmitys 2. Meno –muuttujan muutosarvot ovat vaihdelleet välillä -0,5 - 0,4 °C- astetta/tunti, kun ulkolämpötilan lämpötila-arvot ovat vaihdelleet välillä 3 - 10 °C-astetta. Ulkoilman lämpötilavälillä -12 - 1 °C-astetta muuttujan muutosarvot ovat pääsääntöisesti vaihdelleet välillä -0,3 - 0,3 °C-astetta/tunti. Ulkoilman lämpötilan ollessa alle 20 °C-astetta Connect Lämmitys 2. Meno –muuttujan muutokset kasvavat radikaalisti ja vaihtelevat välillä -1 - 1,3 °C-astetta/tunti.



KUVIO 98. Rakennuksen 2. Connect Lämmitys 2. Paluu –muuttujan lämpötila suhteessa ulkolämpötilaan 1.11.2018 - 29.1.2019

KUVIO:ssa 98. on esitetty rakennuksen 2. Connect Lämmitys 1. Paluu –muuttujan lämpötila-arvot suhteessa ulkoilman ilmanlämpötilaan aikaväliltä 1.11.2018 - 29.1.2019. Connect Lämmitys 1. Paluu –muuttujan lämpötila-arvot ovat vaihdelleet välillä 27,5 - 28,7 °C-astetta, kun ulkolämpötilan lämpötila-arvot ovat vaihdelleet välillä 1 - 10 °C-astetta. Välillä -12 - 1 °C-astetta muuttujan arvot ovat vaihdelleet välillä 27,5 - 30 °C-astetta, mutta lämpötilan varianssi suhteessa ulkoilman lämpötilaan on ollut kapeinta tällä ajalla. Välillä -16 - -12 °C-astetta muuttujan lämpötila-arvojen kasvu on pysähtynyt välille 29,3 - 29,7 °C-astetta.



KUVIO 99. Rakennuksen 2. Connect Lämmitys 2. Paluu –muuttujan muutos suhteessa ulkolämpötilan muutokseen 1.11.2018 - 29.1.2019

KUVIO:ssa 99. on esitetty rakennuksen 2. Connect Lämmitys 2. Paluu –muuttujan lämpötila-arvojen peräkkäisten tuntien välinen muutos suhteessa ulkoilman ilmanlämpötilaan aikaväliltä 1.11.2018 - 29.1.2019. Kun ulkoilman lämpötila on ollut välillä -28 - -15, Connect Lämmitys 1. Paluu –muuttujan lämpötilan muutosarvot ovat vaihdelleet välillä -0,35 - 0,5 °C-astetta/tunti. Välillä -15 - -12 °C-astetta muuttujan muutosarvot ovat vaihdelleet välillä -0,2 - 0,15 °C-astetta/tunti ja ulkolämpötilavälillä -12 – 1 °C-astetta Connect Lämmitys 2. Paluu –muuttujan muutosarvot ovat vaihdelleet kaventuneella välillä -0,15 - 0,1 °C-astetta/tunti. Välillä 1 – 10 °C-astetta muuttujan lämpötila-arvojen muutos on pääsääntöisesti vaihdellut välillä -0,1 – 0,1 °C-astetta/tunti.

5.2.2 Riots-ratkaisut ja pilvipalveluteknologia

Riots-ratkaisut (Rios huoneistohallinta, KUVIO 100) tarjoavat asuntojen olosuhteiden etäseurannan-, vesi- ja sähkömittareiden etäluennan, palopeltien asuntotiedon ja IV-koneen toiminnan etävalvonnan sekä hälytystiedot vesivuodoista ja lämpötilapoikkeamista. Lisäksi teknologia mahdollistaa kylpyhuoneen sähköisen lattialämmityksen ohjaamisen. Riots-infra muodostuu kiinteistöön asennettavista Riots-laitteista, jotka lähettävät paikallisen verkon kautta dataa toisilleen ja edelleen pilvipalveluun. Tiedonsiirrossa käytetään langatonta ja kaapeloitua yhteyttä kiinteistön sisällä. Riots-infran rakentaminen kiinteistöön mahdollistaa


Riots-laitteiden käytön kiinteistössä sekä Riots-laitteiden tuottaman datan hyödyntämisen pilvipalvelun lisäksi myös kiinteistön automaatiojärjestelmässä.



KUVIO 100. Riots huoneistohallintaratkaisu huoneistotasolla

Riots-infra (Kuvio 101) toteutetaan tyypillisesti hyödyntäen jotain seuraavista vaihtoehdoista:

- Moniväylä (kerrostaloon): usea CAN-väylä, väylä vaaka- ja pystysuunnassa
- Yksittäisväylä (kerrostaloon/luhtitaloon): yksi CAN-väylä pohjakerrokseen, langaton tiedonsiirto pystysuunnassa
- Tähtitopologia (kerrostaloon): pohjakerrokseen tähtitopologia (LAN), langaton tiedonsiirto pystysuunnassa
- Tähtitopologia (rivitaloon): tähtitopologia (LAN) rakennusten sisällä
- Linjaväylä (rivitaloon): yhtenäinen CAN-väylä rakennusten läpi, tai oma CAN-väylä jokaiseen rakennukseen
- Linjaväylä (luhtitaloon): yksittäinen CAN-väylä rakennuksen läpi



KUVIO 101. Riots-infran toimintaperiaate

Riots-huoneistohallinta koostuu seuraavista laitteista:

- Riots Mama
 - älykäs keskusyksikkö, joka toimii kiinteistöön asennettujen Riots-laitteiden ja Riots Cloud –pilvipalvelun rajapintana
 - LAN-liityntä yleiskaapelointijärjestelmän kautta
- Riots Connect
 - keskusyksikkö, joka yhdistää Riots-järjestelmän laitteet toisiinsa ja kiinteistön automaatiojärjestelmiin
 - Modbus-väyläliityntä kiinteistön valvonta-alakeskuksen (VAK) ja M-Bus-väyläliityntä vesimittareille
 - CAN-väyläliityntä Riots väyläreitittimeen
- Riots väyläreititin (CAN router)
 - reititin langattomaan tiedonsiirtoon
- Riots Apartment Easy
 - asuntokohtainen keskusyksikkö, johon yhdistetään yhden huoneiston Riots-laitteet
- Riots Wire –huoneanturi
 - huoneistokohtainen anturi, joka mittaa huonelämpötilaa ja ilmakeuhetta

- Riots vuotoanturi
 - kosteusanturi, joka toimii asunnon vesivuotovahtina
- M-Bus vesimittarit
 - kylmävesimittari
 - lämminvesimittari

Riots pilvipalvelu on käyttäjälle näkyvä osa Riots-järjestelmää. Pilvipalvelun avulla voidaan hallinnoida kohteita sekä rakennuksia ja nähdä jo asennettujen laitteiden tuottaman datan laitekohtaisesti tai ryhmiteltynä. Palvelun avulla voidaan myös tarkastella historianäkymässä valittujen laitteiden mittauksia aikajanalla. Riots Oy:n tarjoamiin palvelupaketteihin sisältyy Riots Cloud-pilvipalvelu rajattomalle käyttäjämäärälle, rajattomat historiatiedot sekä laitteiden mittaustietojen esitys hallintapaneelissa. Palvelu sisältää myös rajapintojen hyödyntämismahdollisuuden, jolloin on mahdollista hyödyntää kulutustietoja ja mittausdataa myös muiden valmistajien automaatiojärjestelmissä tai palvelualustoissa. Rajapintojen hyödyntämismahdollisuus ei kuitenkaan sisälly palvelun ilmaisversioon.

Rajapinnat ovat:


- Kohde (target): Kohde on reaali maailmassa sijaitseva sijaintitieto (osoite) sisältäen yhden tai useamman rakennuksen.
- Rakennus (building): Rakennuksella tarkoitetaan fyysistä rakennusta, joka sijaitsee kohteessa. Kohteessa voi olla yksi tai useampi rakennus ja yksi rakennus voi sisältää yhden tai useamman tilan.
- Tila (space): Tila on erillinen tila rakennuksessa – tyyppillisesti erillinen asunto. Rakennuksessa voi olla yksi tai useampi tila ja tila voi sisältää yhden tai useamman arvon (esim. huoneen lämpötila).
- Arvot (values): Arvot voivat olla tulo/lähtöarvoja, joita Riots:n laitteet tuottavat ja monitoroivat.

Riots-pilvipalvelun rajapinnat sisältävät myös arvojen asettamiseen soveltuvan post-funktion, jonka avulla voidaan ohjata sähköistä kylpyhuoneen lattialämmitystä haluttuun lämpötilaan. Teknisesti sähköistä kylpyhuoneen lattialämmitystä ohjataan puolijohdereleellisen sähkömittarin liitäntärasian kautta, jolloin liitäntärasiaan yhdistetään myös lattian lämpötila-anturi. Lattialämmityksen arvot asetetaan pilvipalvelussa ja lattialämmitys toimii paikallisesti.

5.2.3 Yrityksen julkisen pilvipalvelun omaksumisaste

Tekoälyä voidaan toteuttaa monin tavoin, joista yksi vaihtoehto on julkisten pilvipalveluteknologioiden ja niihin ohjelmoitujen koneoppimisen palveluiden hyödyntäminen. Suurimmat pilvipalvelutoimittajat ovat Amazon (AWS) 68 %, Microsoft (Azure) 58 %, Google Cloud 19 %, IBM Cloud 15 % jne. markkinaosuuksillaan (KUVIO 102).

Googlen pilvipalvelut ovat kehittyneet voimakkaasti etenkin Suomen alueella viime aikoina, sillä Google investoi Haminan palvelinkeskukseen syyskuussa 2011, jolloin suuren toimijan pilvipalvelut laajenivat Suomen rajojen sisäpuolelle pienentäen samalla viivettä (latenssi). Pilvipalvelujen toimittajista Amazon on selkeästi vanhin 12 vuoden kokemuksellaan, Azure on toiminut seitsemän vuoden ajan ja Google kuusi vuotta. (Jain, 2018.)



KUVIO 102. Yritysten julkisen pilvipalvelun omaksumisaste prosentteina

Jokaisella pilvipalvelutoimittajalla on omat vahvuutensa ja heikkoutensa, jotka tekevät niistä hyviä tai huonoja valintoja projekteihin. Amazonin suurin vahvuus on sen hallitseva markkina-asema, joka sillä on ollut jo yli 10 vuoden ajan. Amazonilla on valtava ja yhä kasvava määrä palveluita sekä kattavin verkosto maailmanlaajuisia palvelinkeskuksia. Gartnerin mukaan Amazonin AWS on kehittynein, yrityskäyttöön tarkoitettu palveluntuottaja, jolla on parhaimmat mahdollisuudet hallita suurta määrää käyttäjiä ja resursseja. Amazonin suurimpia heikkouksia on kustannusrakenne ja vaikka AWS säännöllisesti laskee hintoja, on kustannusrakenne silti vaikea ymmärtää ja kustannukset vaikea hallita silloin, kun käytetään suuria määriä palveluita. Heikkouksistaan huolimatta Amazonilla on silti suurin markkinaosuus ja laajat valikoimat toimivia palveluita. (Harvey, 2019.)

Microsoft tuli myöhään markkinoille, mutta se kykeni hyödyntämään aiempia menestyneitä palveluitaan, kuten Windows Server, Office, SQL Server, Sharepoint, Dynamics Active Directory, .Net jne. ja muuntamaan ne pilvipalveluympäristöön sopiviksi. Suuri syy Microsoft Azuren menestykseen on, että niin monet yritykset ovat ottaneet käyttöön Windows-käyttäjärjestelmän ja Microsoftin ohjelmistoja. Azuren ollessa tiukasti integroitu muihin sovelluksiin, huomaavat Microsoftin ohjelmistoja usein käyttävät yritykset myös Azuren käytön mielekkääksi. Lisäksi Microsoftin vanhat asiakkaat saavat merkittäviä alennuksia palvelusopimuksista. Gartnerin mukaan palvelukokemus tuntuu kuitenkin vähemmän

yrittäjäkäyttöön soveltuvalta, kuin asiakkaat ovat odottaneet, vaikka Microsoftilla on pitkä historia yrittäjäkäyttöön toimitettujen ohjelmistojen valmistajana. (Harvey, 2019.)

Googlen pilvipalveluissa on nopeat vasteajat ja Googella on vahva osaaminen konttitekniologioista, sillä Google on kehittänyt konttitekniologian (Kubernetes-ohjelmisto), jota Amazonin ja Microsoft tarjoavat nyt pilvipalveluissaan. Google erikoistuu raskasta laskentaa tarjoaviin tuotteisiin, kuten Big Data-, analytiikka- ja koneoppimisen palvelut. Lisäksi se tarjoaa huomattavia skaalaus ja load balancing (kuormituksen tasapainotus) palveluita. Varjopuolena on, että Google on toistaiseksi mukana huomattavasti pienemmällä markkinaosuudella kuin Amazon ja Microsoft, sillä Googlen pilvipalvelu (GCP) ei tarjoa ainakaan vielä yhtä monia erilaisia palveluita ja ominaisuuksia, kuten AWS- ja Azure-pilvipalvelut. Sillä ei myöskään ole yhtä monia globaaleja palvelinkeskuksia, kuin Amazonilla tai Microsoftilla, vaikka se on laajentumassa nopeasti. Gartnerin mukaan asiakkaat tyypillisesti valitsevat Googlen GCP-pilvipalvelun sekundaarisesti tarjoajaksi strategisen palvelutarjoajan sijaan. Asiakkaat valitsevat Googlen pilvipalvelun kuitenkin yhä useammin myös strategisena vaihtoehtona Amazonin pilvipalvelulle, mikäli yrityksen liiketoiminta kilpailee Amazonin kanssa, asiakkaat ovat enemmän avoimeen lähdekoodiin keskittyneitä tai he ovat vähemmän Microsoft Azuren kannalla. (Harvey, 2019.)

5.2.4 Tekoälyä hyödyntävä IoT-esimerkkitoeutus Googlen pilvipalvelulla

Google tarjoaa ratkaisun IoT-sensoreiden lähettämän datan keräämiseen, prosessointiin, analysointiin ja visualisointiin. Ratkaisu on esitetty KUVIO:ssa 103, jossa vasemmalla ovat sensorit, jotka lähettävät dataa Cloud IoT Edge laskenta-alustalle, joka toimii Googlen IoT-pilvipalveluratkaisun ja sensoreiden välillä. Cloud IoT Edge-alusta integroituu Googlen pilvipalvelussa olevan Cloud IoT Coren kanssa ja sen toimintoja ovat muun muassa datan kerääminen, yhdistäminen (aggretointi), prosessointi ja suodatus. Edellä mainitut vaiheet ovat tarpeen tehdä ennen kuin data siirretään eteenpäin Googlen pilvipalveluun. (Janakiram, 2018.)

Data siirtyy Cloud IoT Edge-alustalta Googlen Pilvipalvelussa olevalle Cloud IoT Core-palvelulle, joka mahdollistaa sensoridatan tietoturvallisen siirtämisen ja hallinnan sensoreilta pilvipalveluun. Cloud IoT Coren kautta data siirtyy Cloud pub/sub toimii viestintäpalveluna ja sen avulla dataa voidaan lähettää esimerkiksi sovelluksien välillä viestien muodossa. Cloud pub/sub yhdistyy Cloud Dataflow-palveluun, jota, jota käytetään apuvälineenä hakemaan dataa tietokannasta ja tallentamaan dataa tietokantaan.

Data voidaan tallentaa Cloud Bigtable NoSQL-tietokantaan tai BigQuery tietovarastoon, johon voidaan lähettää kyselyitä tavanomaisella SQL-kielillä. BigQuery käsittelee tietokantaa suurena massana ja hyvin nopeasti. Se on myös huomattavasti nopeampi käymään läpi suuria määriä dataa kuin BigTable. Googlen mukaan BigQuery kykenee käsittelemään Teratavuittain dataa sekunneissa ja Petatavun verran minuuteissa. BigQuery on skaalautuva ja serverless-

palvelu, joka useimmiten tarkoittaa käytön perusteella maksettua palvelinkapasiteettia pilvipalvelussa. (Zhou, 2017.)

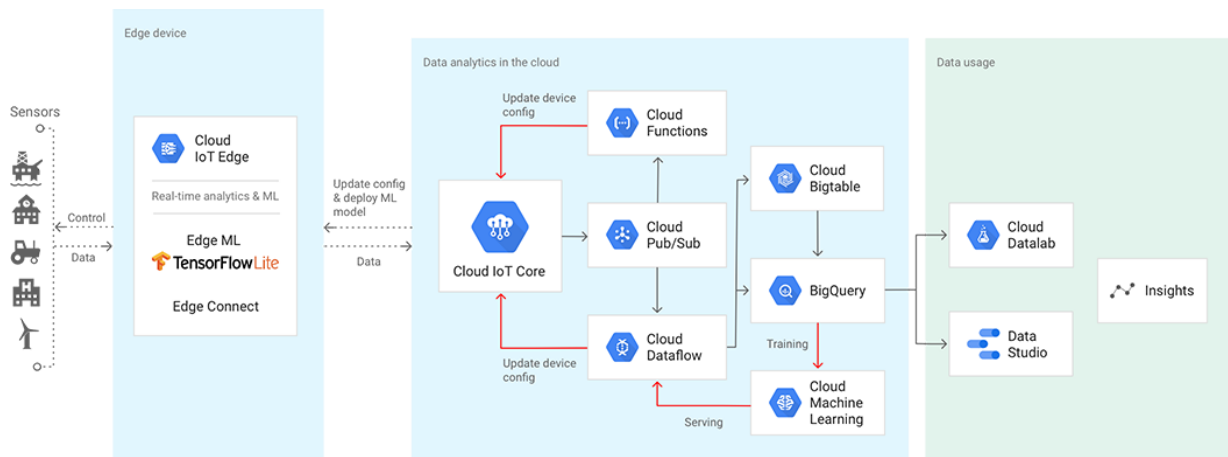
Serverless-teknologian avulla voidaan toteuttaa esineiden internet (IoT) –hankkeita, jolloin laitteiden hyödyntäminen usein onnistuu pelkällä konfiguroinnilla. Tällöin IoT-laitteiden ja muun järjestelmän välillä kulkevat viestit voidaan saada nopeasti hyödynnettyä ja välitettyä. Serverless-teknologian hyödyntäminen on mielekästä myös tekoälyratkaisuja toteutettaessa, sillä perinteisiä palvelininfrastruktuureja hyödyntäen tekoälyratkaisujen toteutukset voivat olla hyvin kalliita tai jopa mahdottomia toteuttaa. Useilla pilvipalvelualustoilla on valmiit ohjelmistorajapinnat (API) useiden erilaisten tekoälypalveluiden hyödyntämiseen, kuten esimerkiksi kuvantunnistus. Serverless-teknologia hyödyttää myös älykotiratkaisujen kehittämistä ja suuri osa tarjolla olevista plug-n-play älykotiratkaisuista käyttävät Serverless-palveluita. (Rantala, 2018.) Serverless-teknologian hyödyntäminen ilman asiantuntijatason käyttötaitoja hyödyttää käyttäjiä, joilla ei ole kokemusta palvelinratkaisuista sekä käyttäjiä, joilla on jo laajempi osaaminen.

Google Cloud Machine Learning (ML) Engine on palvelu, joka tarjoaa datatieteilijöille ja ohjelmistokehittäjille mahdollisuuden kehittää ja tuoda koneoppimisen malleja tuotantoon. Cloud ML Engine tarjoaa koulutus ja ennustavan analytiikan palveluita, joita voidaan käyttää yhdessä tai erikseen. Cloud ML engine-palvelua on käytetty ongelmien ratkaisemiseen pilvien tunnistamiseen satelliittikuvista, ruoan turvallisuuden varmistamiseen tai moninkertaisesti nopeutettuun asiakassähköposteihin vastaamiseen. (Cloud Machine Learning Engine.)

Cloud ML engine mahdollistaa koneoppimisen mallien muodostamisen useista eri koneoppimisen viitekehysistä (frameworks), kuten scikit-learn, XGBoost, Keras ja Tensorflow. Tensorflow on johtavia syväoppimisen viitekehysiksiä, jota hyödynnetään muun muassa Googlen eri tuotteissa, kuten Google Photos ja Google Cloud Speech. Cloud ML mahdollistaa automaattisen mallien arkkitehtuurisuunnittelun ja arvioinnin sekä skaalauksen. Opetettuja koneoppimisen malleja voidaan hyödyntää ennustavan analytiikan ratkaisujen kautta, kuten online prediction ja batch prediction. Online prediction täysin hallinoitu reaaliaikainen ennustavan analytiikan palvelu, joka kykenee automaattisesti skaalautumaan ja johon on sisäänrakennettu tietoturvaominaisuuksia. Batch prediction toimii rajapintana asynkronisille sovelluksille. Opetetut mallit voidaan sijoittaa Cloud ML engine-palveluun, jolloin niille voidaan hallita ja niille voidaan lähettää ennustuksiin liittyviä kutsuja. (Cloud Machine Learning Engine.)

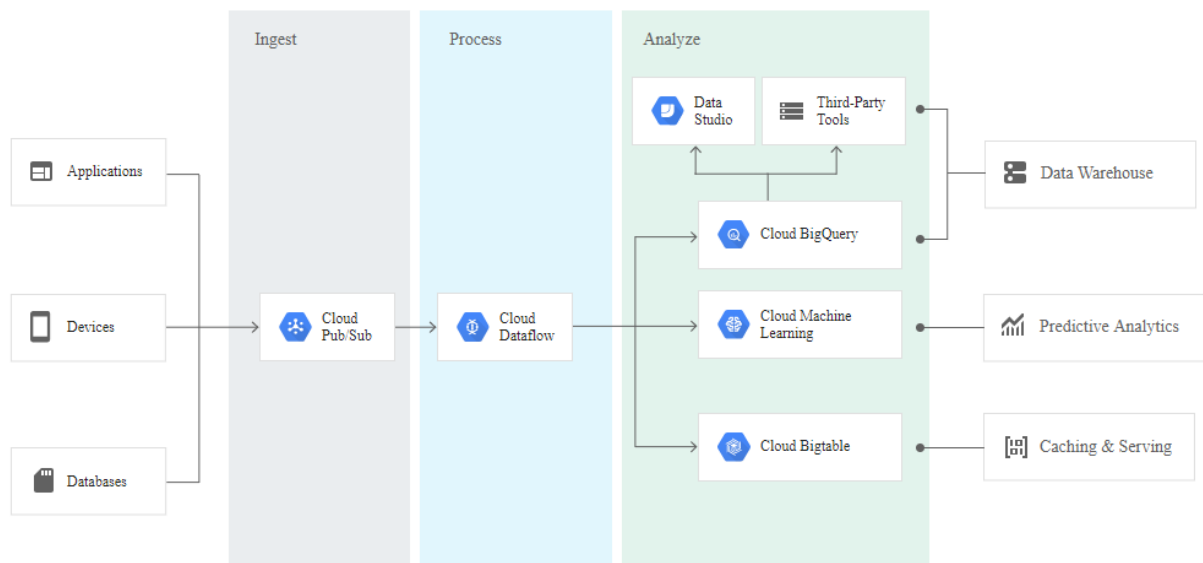
Koneoppimisen malleja voidaan luoda ja ajaa myös BigQuery ML-palvelun yhteydessä käyttäen tavanomaisia SQL-kyselyitä. BigQuery nopeuttaa ohjelmistokehitystä eliminoimalla datan siirtämisen tarpeen. BigQuery ML tukee seuraavan tyyppisiä malleja: lineaarinen regressio (numeeriset arvot), binäärinen logistinen regressio (luokkien ennustaminen) ja moniluokkainen (esimerkiksi matala, keskimääräinen tai korkea arvo) logistinen regressio luokittelua varten. Etuna BigQuery ML:n hyödyntämisessä on, että koneoppimisen

toteutuksiin ei tarvita ohjelmointikielten, kuten Python tai Java osaamista, vaan mallit voidaan opettaa ja niitä voidaan käsitellä BigQuery-tietokannassa SQL-kieltä käyttäen. (BigQuery, 2019.)



KUVIO 103. Googlen pilvipalveluarkkitehtuuri IoT-toteutuksessa (Cloud IoT Core)

KUVIO:ssa 104. on esitetty datan lähetys sovelluksista, laitteista tai tietokannoista Cloud Pub/Sub- ja Cloud DataFlow-palveluiden kautta Cloud BigQuery tietovarastoon ja Cloud Bigtable tietokantaan (välimuisti) ja Cloud Machine Learning-palvelulle koneoppimisen mallin muodostusta varten, jota hyödynnetään predikttiiviseen analytiikkaan. Cloud BigQuery, Data Studio (analytiikkapalvelu) ja muut kolmannen osapuolen työkalut muodostavat yhdessä tietovarastoinnin kokonaisuuden.



KUVIO 104. Datun lähetys Pub/Sub ja DataFlow kautta analysoitavaksi (Cloud Pub/Sub)

5.2.5 Julkisten pilvipalveluiden hinnoittelu

Amazonin AWS:n hinnoittelu on osittain vaikeaselkoinen ja vaikka käytössä on laskuri, liian monta kokonaishintaan vaikuttavaa muuttujaa on otettava huomioon, joka tekee tarkkojen arvojen tekemisestä haastavaa. Gartnerin mukaan ”rakeinen” hinnoittelurakenne on monimutkainen, jolloin kolmannen osapuolen toteuttamat kulunhallintatyökalut ovat hyvin suositeltavia.

Microsoft Azure ei tarjoa hinnoittelun suhteen yhtään helpotusta, koska siihen liittyy Microsoftin monimutkaisia ohjelmistolisenssivaihtoehtoja ja tilanteista riippuvia alennuksia. Microsoftin Azuren hinnoittelurakenne voi olla vaikea ymmärtää ilman ulkopuolista apua ja/tai merkittävää kokemusta.

Googlen käyttää GCP-pilvipalvelunsa hinnoittelua erottelevana tekijänä. Googlen tarkoituksena on tarjota ”asiakasystävällisiä” hintoja, jotka ovat halvempia kuin kilpakumppaneiden tarjoamat listahinnat. Gartnerin mukaan Google käyttää huomattavia alennuksia ja poikkeuksellisen joustavia sopimuksia, joiden avulla se yrittää hankkia projekteja asiakkailta, jotka ovat jo käyttäneet merkittäviä summia rahaa pilvipalveluiden hankkimiseen kilpakumppaneilta.

Tärkeää on, että yritykset, jotka valitsevat pilvipalveluiden tuottajat pääasiassa hintoihin perustuen, analysoisivat jokaisen projektin tapauskohtaisesti, jotta paras mahdollinen sopimus voidaan solmia. Lisäksi koska pilvipalveluiden tuottajat pudottavat hintojaan säännöllisesti, on tarpeen tehdä laskelmia säännöllisin välein. Kustannukset voivat kuitenkin olla hyvin vaikeita ennustaa ja kulut määräytyvät pitkälti käytön mukaan. Mytton (2017) mukaan hinnoittelumalli tarjoaa joustavuutta, mutta korostaa myös päivittäistä palvelujen käytön monitorointia ja poikkeamien havaitsemista palvelujen käytössä. Kuukausibudjetit voi olla helppo ylittää, mikäli kustannuksien kehittymistä ei seurata säännöllisin väliajoin esimerkiksi raportein, visualisointien, budjettien tai hälytysten avulla.

Pilvipalvelujen tuottajat, kuten Amazon ja Google tarjoavat periaatteessa huomattavan matalia hintoja esimerkiksi datan varastointiin, mutta lähinnä silloin, kun dataa ei hyödynnetä liian usein. Serverless-palvelut, joiden tapauksessa maksetaan vain siitä, mitä käytetään (esim. API-kutsut, tietokantapalvelut, tiedostojen ja kuvien säilyttäminen jne.) tarjoavat hinnoittelun lisäksi myös nopean tavan aloittaa palvelujen kehitys, sillä niissä ei ole palvelimien konfigurointia ja ylläpitoa. Lisäksi ennakointi helpottuu skaalautuvuuden ansiosta. Ongelmana kuitenkin on esimerkiksi virhe ohjelmointiodissa, joka voi aiheuttaa silmukan pilvipalveluihin lähetettäviin pyyntöihin aiheuttaen kustannusten huomattavan nousun. Tämän kaltaisen tilanteen voi aiheuttaa myös esimerkiksi haittaohjelmana toteutettu ohjelmistorobotti (botti), joka on päässyt yrityksen järjestelmään. (Mytton, 2017.)

Esimerkkinä potentiaalisesta ongelmatapauksesta on Amazonin NoSQL-tietokanta, DynamoDB, jossa maksetaan tauluun kirjoittamisesta ja lukemisesta. DynamoDB-tietokantaa käytettäessä ongelmana on ollut automaattinen skaalautuminen, jolloin luku- ja kirjoituskapasiteetin skaalaamista on joutunut omatoimisesti miettimään. Tällöin perinteinen relaatiotietokanta on voinut olla parempi ratkaisu, joka on toimiva ratkaisu diskreettiä dataa, kuten lämpötilat, ilmanpaineet, ilmankosteudet jne. tallennettaessa. Relaatiotietokanta, kuten Amazonin Postgres tai Googlen tarjoama BigQuery ovat hyviä edellä mainitun kaltaisen rivi- ja sarakemuotoisen datan analysointiin sekä lisäksi NoSQL-tietokantoja helpompia hallita. Tarjolla on myös ilmaisia avoimen lähdekoodin relaatiotietokantoja. NoSQL-muotoinen (esimerkiksi MongoDB) tietokanta soveltuu paremmin rakenteettoman datan, kuten sosiaalisen median, tekstipohjaisen tai geograafisen datan analysointiin, jossa hyödynnetään luonnollisen kielen prosessointia tai kuvankäsittelyä.

Esimerkiksi Googlen veloittaa BigQuery-palvelun aktiivisen varastoinnin käytöstä \$0.020 per GT (joista ensimmäiset 10 GB/kk on ilmaista). Pitkäkestoinen varastointi maksaa \$0.010

Esimerkkihintoja Googlen palveluista:

Gt kohden ja tietokantaan lisätyt rivit maksavat \$0.010 200 Mt:ä kohden. Tietokantaan lähetetyt kyselyt maksavat \$5.00 per Tt. Google tarjoaa myös kuukausihinnoiteltua flat-rate-palvelua, joka kustantaa \$40,000 per kk. Googlen Data Studio-visualisointi ja analytiikkapalvelut hyödyntävät BigQuery-tietokantaa, jolloin käyttökustannukset määräytyvät BigQuery-hinnoittelun perusteella.

Googlen Cloud IoT Core on ilmainen 250 Mt/kk saakka. 250 Mt/kk maksaa \$0.0045, 250 Mt – 5 Tt/kk \$0.0020 ja yli 5 Tt/kk 0.00045 per Mt. Cloud Pub/Sub on ensimmäiseen 10 Gt/kk saakka ilmainen, seuraavat 50 tebitavua \$60, seuraavat 100 tebitavua 50\$ ja 150 tebitavun jälkeen 40\$. Cloud Dataflow Streaming (IoT) maksaa \$0.069 vCPU (per tunti), \$0.003557 per Gt per tunti (muisti), \$0.000054 per Gt per tunti (varastointi) ja \$0.018 per Gt (prosessoitu data). Hinta-arvion laskemiseen olisi tarpeen tietää IoT-sensoreista lähetettävän datan koko, varastoinnin pituus, tietokantaan lähetetyt kyselyt ja muutokset, visualisoinnin ja analytiikkapalveluiden hyödyntäminen ym.

5.2.6 Asiantutijajärjestelmän edellytykset

Lehto Asunto Oy –data-analyysi paljasti, että asunnoista kerätään osa-aikaisesti ja vaihtelevasti dataa erilaisista muuttujista. Muuttujina tämän tutkimuksen aikana ovat toimineet asuntojen lämpötila, asuntojen suhteellinen ilmankosteus, asuntojen hiilidioksidiarvot, rakennuksen ulkopuolisen ilman lämpötila ja ulkoilmalle laskettu kolmen tunnin sään lämpötilan ennuste sekä neljä eri lämmitysveden mittausarvoa. Data on kuukausittain lähetetty analysoitavaksi Excelin .xls –formaattissa, joka on sisältänyt halutun muuttujan mittausdatan ja päivämäärän lisäksi datan otsikon jokaisella välilehdellä. Riippuen

rakennuksesta otsikoiden nimet ovat vaihdelleet ja sisältäneet kirjoitusvirheitä. Dataa on joskus puuttunut ja toisinaan data on sisältänyt monistuneita arvoja.

Tällaiselle datalle suunniteltavan yleispätevän asiantuntijajärjestelmän, jossa käytetään tekoälyä rakennusten lämmityksen ohjaukseen, rakentaminen on haasteellista. Asiantuntijajärjestelmän rakentamista voi kuitenkin helpottaa suunnittelemalla se moduuliseksi. Moduulisella järjestelmällä tarkoitetaan, että sen toiminnallisuus muodostuu pienemmistä osakokonaisuuksista. Suuria datasettejä, joissa käsitellään useita muuttujia kerralla, vaivaa niin kutsuttu dimensionaalisuuden kirous, mikä tarkoittaa, että oleellinen tieto ei välity kaikkien muuttujien joukosta joko diskreetissä ajassa tai ei koskaan. Pienempi osakokonaisuus voi täten johtaa hallittavissa olevaan toimivaan ratkaisuun.

Moduulisuutta suosien tekoälyn tekeminen alkuun yhdelle rakennukselle ja kaikille sen asunnoille olisi suotavaa. Neuroverkkojen kouluttaminen yhden asunnon tai rakennuksen olosuhteiden luokitteluun ja muuttujien arvojen ennustamiseen on vielä kohtuullisen yksinkertaista. Ohjausjärjestelmän kouluttaminen on puolestaan hankalaa. Sama pätee useiden rakennusten tapauksessa. Tekoälyn olisi hyvä sisältää luokitteleva osa, simuloiva osa, ennustava osa, ohjaava osa ja nämä kaikki yhdistävä rakenne yhdistettynä versionhallintaan.

Rakennuksen asuntojen lämmitystä ohjaavan järjestelmän eräs tärkeimmistä edellytyksistä on luokittelevan tekoälyn suunnittelu, kouluttaminen ja tulosten esiin tuonti. Suosittelemme, että luokitteleva tekoäly rakennetaan omaan moduuliinsa niin, että se muodostuisi kahdesta alaosasta. Nämä alaosat voisivat olla datan lähteen tunnistin ja datan poikkeamien luokittelija.

Datan lähteen tunnistimen tehtävä olisi varmistaa automaattisesti, että datan muuttujat kuuluvat rakennuksesta kerättäviin suureisiin ja suuret vastaisivat tarkoitettuja muuttujia. Tällä tarkoitetaan, että tekoäly tarkistaisi tietokannasta haettavat datasetit ja päättelisi kuvastavatko haettavat muuttujat ja saadut muuttujat tyypillisesti samasta rakennuksesta saatavia tietoja, jolloin todennäköisyys sille, että tietokantaan väärin kirjatun rakennuksen tiedot päätyisivät huomaamatta tarkoitettun rakennuksen datajoukkoon, pienenis. Tällaisen tunnistimen rakentaminen vaatisi esimerkiksi sen, että .xls –muotoisen datasetin otsikkotiedoille tehtäisiin luonnollisen kielen prosessoinnilla sanamatriisit ja näitä verrattaisiin edeltävien datasettien sanamatriiseihin mm. klusteroimalla. Tämän jälkeen olisi lisäksi varmistettava, että itse muuttuja vastaisi otsikon nimikettä eli esimerkiksi Connect Lämmitys 1. Meno –muuttujan arvot vastaisivat muuttujan tyypillisiä arvoja.

Datan poikkeamien luokittelija saisi datasetin sen jälkeen käsiteltäväkseen, kun datan lähteen tunnistava moduulin osa olisi hyväksynyt datasetin. Datan poikkeamien luokittelijan tehtävä olisi muuttujien poikkeamien tunnistaminen ja lopulta paikantaminen yhden rakennuksen datasetistä tai rakennuksen asuntojen dataseteistä. Taustalla voisi käyttää muun muassa syväneuroverkkoa, joka on koulutettu riittävällä datalla tunnistamaan eri poikkeustyyppisiä

esimerkiksi lämpötila-, ilmankosteus- ja hiilidioksididatan joukosta. Poikkeamista olisi hyvä luokitella monistuneet arvot, toimimattomat sensorit, kasvaneet arvovälit ja täysin ympäröivistä arvoista eroavat poikkeamat. Lisäksi olisi hyvä luokitella hetket, jolloin suureiden arvot ovat kasvaneet tai laskeneet huomattavasti verrattuna tyyppillisiin aikaikkunan arvoihin, mutta eivät ole poikenneet ympäröivästä datasta lyhyellä aikavälillä.

Luokittelijoiden rakentaminen on haasteellista, mikäli pyritään lähes täydelliseen tulokseen. Yleensä riittää, että luokittelu onnistuu noin 80 prosentin varmuudella. Luokittelijoiden rakentamisen edellytyksenä tekoälyä varten on määrällisesti riittävän laadukkaan koulutusdatan ja validointidatan kerääminen. Onneksi osaa datasta voi tapauksesta riippuen simuloida ja mallintaa. Suosittelemme simulointijärjestelmän käyttöönottoa tekoälyratkaisun ohessa. Valmiin simulointiohjelman avulla voisi olla mahdollista mallintaa rakennusten fyysistä käytöstä ja täydentää luokitteludatasetin määrää ja laatua.

Simulointi liittyy oleellisesti muuttujien arvojen ennustamiseen. Todelliseen dataan ja fyysisten ominaisuuksien simulaatiodataan perustuvat tekoälymallit voisivat toimia eksperttijärjestelmän ennusteiden generoinnissa. Neuroverkot soveltuvat näidenkin taustalle. Käyttämällä eräänä osakokonaisuutena eri aikaikkunoihin perustuvia laskentamalleja voi neuroverkkoja käyttää laskemaan rakennuksen asunnoille ennusteita useammankin tunnin ajalle. Näiden ennusteiden tarkkuus on joissain tapauksissa parannettavissa neuroverkkojen kokoa kasvattamalla ja yhdistämällä eri mallien tuloksia esimerkiksi ensemble-neuroverkon avulla, joka kokoa muiden neuroverkkojen tai mallien ennusteet ja tuottaa näiden pohjalta lopullisen ennustearvon.

Toisena vaihtoehtona voisi olla ennusteiden luominen tekoälyä hyödyksi käyttäen, kun ennustetaankin muuttujien välisiä suhteita. Esimerkiksi erotusdatan muodostaminen alkuperäisestä datasetistä ja sen käyttäminen neuroverkon koulutukseen voisi parantaa ensemble-neuroverkon ennusteiden oikeellisuutta.

Seuraavaksi päästään itseohjautuvan lämmitysjärjestelmän pohdintaan. Lehto Asunto Oy:n data-analyysissä käytetyn datan perusteella ei vielä voi ohjausta suorittaa. Riitsin ohjelmointirajapinnasta oli nähtävissä, että asuntojen lämmityksen ohjaamiseen tarjoutuu yksinkertainen ohjauskeino, joka vaatii ainoastaan asunnon tietojen lisäksi tavoitelämpötilan ja keston ennustamisen. Nyt tieto tavoitelämpötilasta, lämmityskeston pituudesta ja säädön alkamisesta puuttuu Lehto Asunto Oy:n datasetistä. Tämän kiertämistä varten näitä arvoja olisi simuloitava yhdessä rakennuksen, asuntojen ja sään muuttujien avulla yhdistäen todellisiin muutoksiin kerätyissä dataseiteissä ja muutoksien ajoittumisissa. Geneettisen koodauksen avulla voisi olla mahdollista löytää paras rajoitetussa ajassa laskettavissa oleva ratkaisu, joka käyttäisi syötteinään optimaalisimpia muuttujia. Geneettinen koodaus tarkoittaa alkutilanteesta muuttuvia algoritmeja, jotka voivat eri tavoin yhdistellä toistensa ominaisuuksia ja säädellä ominaisuuksiensa vaikutuksia jokaisen sukupolven jälkeen oleellisesti kehittyen vastaamaan tiettyjä ehtoja. Esimerkiksi neuroverkko voi oppia

minimoimaan monitavoiteongelmia, kuten todellisen ja ennustetun lämpötilan välisiä eroja samalla pyrkien vähentämään sähkö- ja lämpöenergian käyttöä. Tämänkaltaisen koodauksen etuihin lukeutuu se, että näin tehtynä tekoäly voi toimia paremmin kuin ihmisen tekemänä. Geneettisen koodauksen ongelma on kuitenkin sen laskennallinen vaativuus koulutusvaiheessa.

Asiantuntijajärjestelmän olisi hyvä myös säilyttää tekemiensä päätösten tiedot sekä kaikkien osakokonaisuuksissaan käytettyjen neuroverkkojen tiedot, kuten muun muassa laskentaan osallistuneet algoritmit, rakennuksen laskentakerran simuloitujen ennusteet, todellisten ja simuloitujen arvojen väliset erot sekä monestiko laskentaa on suoritettu virheellisesti tai ilman virheitä. Tällaisen informaation säilyttäminen, esittäminen ja hallinnointi on lisäksi hyvä mahdollistaa käyttäjälle tai vastuuhenkilölle. Tekoälyjärjestelmät eivät ole useinkaan täydellisiä ja niiden toimintaan voi vaikuttaa myös käyttäjä. Tästä syystä tekoälyä käyttävän asiantuntijajärjestelmän olisi hyvä graafisen esitysmuodon lisäksi hyödyntää versionhallintaa. Esimerkiksi jonkin moduulin metatietojen virhekertymän ylitettyä jonkin tietyn ennalta määritellyn rajan, tekoäly voisi tallentaa kyseisen moduulinsa versionhallintaan ja kouluttaa moduulin uudelleen. Mikäli koulutus ei tuota parempaa tulosta, voisi edeltävän version moduulista palauttaa versionhallinnasta uudelleen käyttöön.

6. Suomen Yliopistokiinteistöjen datan analyysi

Tässä luvussa paneudutaan Suomen Yliopistokiinteistöjen (SYK) Kampusareenasta mitatun sensoridatan analysointiin ja visualisointiin. Luvussa esitellään Kampusareena ja VIRPA C- ja D -hankkeet, joiden aikana Kampusareena ja sen tarjoama data on ollut tutkimuksen kohteena. Jyväskylän yliopisto sai alkukesästä 2018 Polku Innovation Virpa C –hankkeen yhteydessä kehittämän ”SYKin avoimen IoT-alustan” ja Siemensin kanssa tehtyjen sopimusten ansiosta rajoitetun datasetin Kampusareenan Tapahtuma-areena- ja Giga-huoneista. Tässä luvussa esitellään SYK:n IoT-alusta ja sensoriverkko, mittaustiedot sekä datan visualisointi. Luvussa keskitytään myös sääinformaation tarkasteluun, sisäilman suureiden ennustamiseen ja annetaan vaihtoehtoisia tekoälyä hyödyntäviä ehdotuksia hiilidioksidipitoisuuden ennustamiseksi. Luvun lopussa ovat tulokset ja päätelmät.

6.1 Kampusareena-kiinteistön esittely

Kampusareena (Kuvio 105) on Tampereen teknillisen yliopiston kampuksen keskellä sijaitseva, tutkimuksen ja teknologian keskipiste, joka toimii kohtauspaikkana eri alojen yrityksille sekä Tampereen teknillisen yliopiston tutkijoille, opettajille ja alumneille. Monialaiset kohtaamiset synnyttävät uudenlaisia ideoita, joilla voi olla potentiaalia kehittyä suuriksi yhteistyössä toteutettaviksi tutkimus- ja kehityshankkeiksi, innovaatioiksi, uusiksi työpaikoiksi ja menestyväksi liiketoiminnaksi. Kampusareena tarjoaa laajan valikoiman palveluita ja monenlaisiin tarpeisiin soveltuvia muuntuvia tiloja. Tilat mahdollistavat erilaisten tapahtumien järjestämisen, tutkimustarkoitukset sekä lyhyt- ja pitkäkestoisen työskentelyyn. Lisäksi Kampusareena tarjoaa oppimisympäristön, jossa ovat tarjolla keskeiset opiskeluun liittyvät palvelut. (Kemiläinen, 2015) Fyysisesti Tampereen kampusareena sijoittuu Tietotalon ja Konetalon väliin. Kampusareenan sijoittumisen kampukselle voi nähdä kuvioista 106.



KUVIO 105. Havaintokuva Tampereen Kampusareenasta (Kemiläinen, 2015)



KUVIO 106. Tampereen kampusareenan fyysinen sijainti (SYK)

6.2 VIRPA C- ja D-projektien esittely

Virtuaalinen palveluympäristö (VIRPA C) –yrityshankkeessa on mukana 15 yritystä ja viisi tutkimusryhmää kolmesta tutkimusorganisaatiosta kehittämässä yhteistyössä uusia kiinteistöpalveluita. Hankkeessa yhdistyvät osaaminen kiinteistöjen suunnittelusta, rakentamisesta, johtamisesta, energiahallinnasta, ICT:stä ja palveluliiketoiminnasta. Kiinteistöpalveluiden kehittäminen hyödyntää dataa, jonka avulla voidaan luoda uudenlaisia tapoja tehostaa kiinteistöjen toimintaa. Hankkeen tavoitteena on kehittää kiinteistöjen käyttäjäkokemusta, elinkaarenhallintaa sekä uusia liiketoimintamalleja. Hanke päättyy vuoden 2018 aikana ja sen budjetin suuruusluokka on yli 4 miljoonaa euroa. (Mirasys, 2017.)

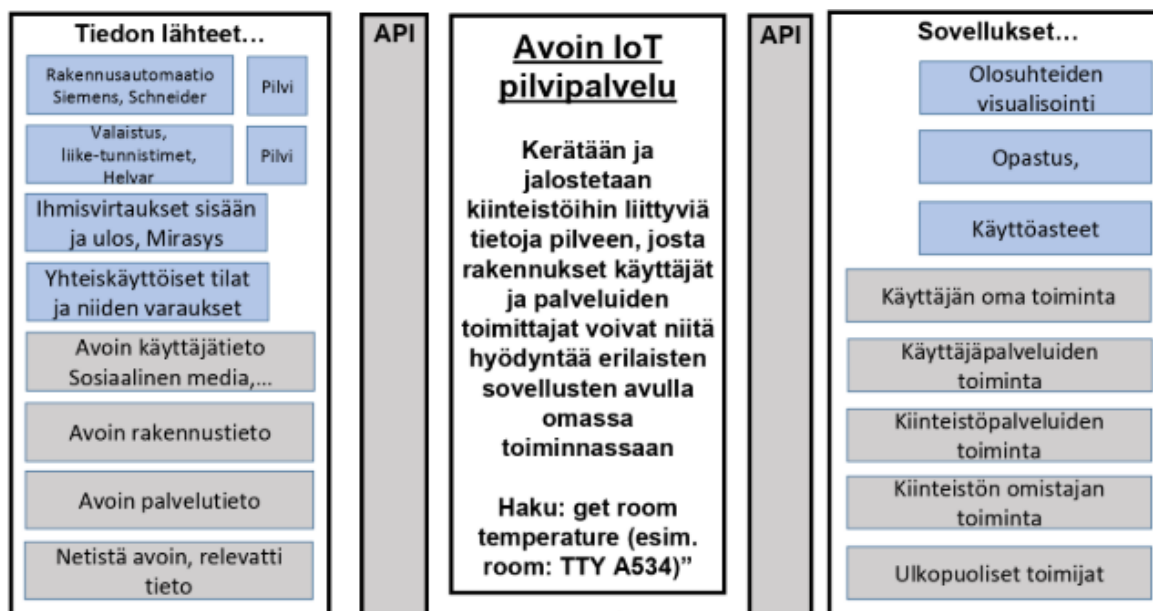
VIRPA C –hankkeessa tutkimuslaitokset tukevat yrityksiä kehittämis- ja innovaatiotoiminnassa suodattaen ajankohtaista ja uusinta tutkimustietoa hankkeen osapuolten käyttöön, suorittamalla trendikartoituksia sekä jäsentämällä ja havainnollistamalla uusien palveluiden liiketoiminnallisia mahdollisuuksia, ekosysteemin toimintamalleja ja vaihtoehtoisia skenaarioita palveluiden kehittämisen tueksi. Pilottiympäristöt sijaitsevat Oulun yliopiston kampuksella Linnanmaalla ja Tampereen teknillisen yliopiston kampuksella Hervannassa. Hankkeessa koetetaan synnyttää uusia kansainvälisille markkinoille tähtääviä palveluita yhteistyössä tietotekniikkapalveluita tuottavien ja energiatoimialan yritysten kanssa. Hankkeessa kehitetään uudenlaisia sovelluksia, jotka kykenevät hyödyntämään virtuaalitekniologiaa, kuten 3D-mallinnus ja virtuaalinen sekä lisätty todellisuus. Sovelluksien kehitystyö tapahtuu kiinteistön käytön aikana. Uudenlaisten sovellusten tarkoituksena on lisätä toiminnan resursointia ja lisätä tehokkuutta sekä parantaa kiinteistöjen elinkaaren hallintaa, käyttäjien tyytyväisyyttä ja kiinteistöjen houkuttelevuutta. (Mirasys, 2017.)

VIRPA-D-projekti on yliopistojen ja yrityselämän yhteisprojektina toteuttava virtuaalinen palvelinympäristö, jossa kokeillen kehitetään uusia palveluja, joiden toteuttamiseen palveluiden käyttäjät voivat vaikuttaa. VIRPA-D-projektin on ennakoitu tuottavan 740 miljoonaa euroa liikevaihtoa, 342 miljoonaa euroa uutta vientiä ja 1569 uutta työpaikkaa. Projekti kuuluu Business Finlandin Fiiliksestä fyrkkaa –ohjelmaan, jossa rahoitetaan korkeatasoista tutkimusta muun muassa uudesta teknologiasta, tunteista ja digitaalisesta asiakaskokemuksesta. (Tieto, 2018) VIRPA-projektissa on useita erilaisia mielenkiintoisia osapuolia ja se on mahdollistanut uusien ratkaisujen pilotoinnin yhdessä muiden organisaatioiden kanssa (Granlund, 2018).

VIRPA-D-projektin tavoitteena on kehittää toimitilojen käyttäjille jopa maailmanluokan kriteerit täyttäviä palveluita, joiden avulla käyttäjät voivat edistää työn tuottavuutta, hyvinvointia ja arjessa pärjäämistä. Projektiin kuuluvat yliopistot ja yritykset yhdessä muodostavat ekosysteemin, jossa voidaan kehittää uudenlaisia kiinteistö- ja toimitilasektorille skaalautuvia käyttäjäpalveluita. Projektissa hyödynnetään eri osapuolten välistä tiivistä yhteistyötä ja kokeilemalla oppimista. Tutkimuksen kohteina ovat käyttäjäpalveluiden tulevaisuuden tarpeet, käyttäjäkokemuksen muotoilu, liiketoimintamallit, datan kerääminen ja analytiikka. (SYK, 2018.)


6.3 SYKin IoT-alusta ja sensoriverkko

Suomen yliopistokiinteistöillä (SYK) on VIRPA-projektien kautta toteutettu IoT -alusta (Kuvio 107), ja sensoriverkko, jossa on useita erilaisia tietolähteitä, kuten rakennusautomaatio, valaistus, liiketunnistimet, ihmisvirtaukset, yhteiskäyttöiset tilat sekä avoin käyttäjä-, rakennus- ja palvelutieto ynnä muu relevantti informaatio. Tiedon lähteisiin päästään käsiksi API (Application Programming Interface) -rajapinnan kautta, jolloin voidaan esimerkiksi kysyä huoneen lämpötilaa, ilmanpainetta tai ilman kosteutta. Alustalle voidaan toteuttaa erilaisia sovelluksia, kuten olosuhteiden visualisointi, opastus, käyttöasteet sekä käyttäjän-, kiinteistön-, kiinteistön omistajan ja ulkopuolisen toimijan palvelut.



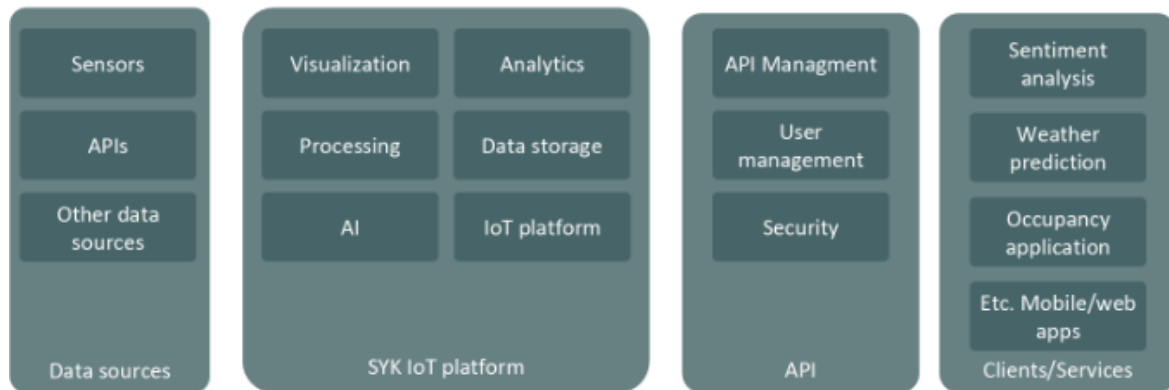
KUVIO 107. SYKin IoT -alusta (Virpa C ja D) (SYK)

SYK:n sensoriverkossa sensorit yhdistetään Linux-pohjaiseen yhden piirilevyn Raspberry PI3-tietokoneeseen (Kuvio 108), joka liitetään sähkö- ja tietoverkkoon. Raspberryyn liitettyjen antureiden data varastoidaan SYK:n luottamukselliseen pilvipalveluun. Datan varastoinnin jälkeen pilvipalvelusta voidaan saada anonymisoitua tietoa tutkimus- ja opetuskäyttöön sekä SYKin IoT -pilvipalvelun kautta palvelukäyttöön. Raspberryyn liitettäviä dataa keräviä antureita ovat muun muassa lämpötila, ilman kosteus, hiilidioksidipäästö, ilmanpaine, liiketunnistus, Maan magneettikenttää mittaava anturi, ovien kytkimet, painesensorit, maaperän kosteusanturit, kiihtyvyyssanturit/gyroskoopit, GPS, mikrofoni, valaistus ja niin edelleen.



KUVIO 108. Raspberry PI3 ja anturit (SYK)

SYKin IoT -alustan arkkitehtuuri ilmenevät kuviossa 109, jossa vasemmalla ovat datalähteet (sensorit, rajapinnat ja muut datalähteet) ja seuraavana SYK:n IoT -alusta (visualisaatio, prosessointi, tekoäly, analytiikka, tietovarasto, IoT-alusta). SYKin IoT -alustaa seuraa API-rajapinta, jossa on API:n- ja käyttäjien hallinta sekä tietoturvasuorituskomponentit. Viimeisenä Kuviossa 53 ilmenevät palvelut, kuten sään ennustaminen, tilojen käytön seuranta, mobiili/WEB-sovellukset jne.



KUVIO 109. SYKin IoT -alustan arkkitehtuuri (SYK)

6.4 Mittausdata-aineiston esittely

Tampereen kampusareenan sensoriverkon data on tallennettu JSON-muodossa (JavaScript Object Notation), joka on yksinkertainen avoimen standardin tiedostomuoto tiedonvälitykseen. Rajapinnassa on kuvattu muun muassa huone, jossa sensorit sijaitsevat, ohjelmisto- ja laitteistokohtaiset ID:t, koordinaatit, aika ja varsinainen sensoridata, kuten lämpötila Celsiusasteina, ilman kosteus prosentteina, ilman paine millibaareina ja melu desibeleinä. Lisäksi Kampusareenan sensoriverkon JSON-tiedostomuotoon on tallennettu liiketunnistustietoja.

KUVIO:ssa 110. on otos Kampusareenan sensoriverkon datan mitattavista suureista ja datan alkuperäisestä JSON -tiedostomuodosta, jollaisessa muodossa data oli aluksi ilman esiprosessointia. Kuviossa ilmenee sensorin mittaaman suureen nimi, yksikkö, arvo, ID ja aikaleima. Aikaleima on tallennettu JSON -tiedostomuotoon millisekunneina.

	icon	term	unit	value	timestamp
0	tachometer	Pressure	mBar	1011.3	1517420331000
1	tint	Humidity	%	22.0	1517420331000
2	thermometer-full	Temperature	°C	22.3	1517420331000
0	volume-off	Noise	dB	46.0	1517566802000
1	tachometer	Pressure	mBar	1006.7	1517566802000
2	tint	Humidity	%	21.0	1517566802000
3	thermometer-half	Temperature	°C	20.2	1517566802000
0	volume-off	Noise	dB	38.0	1517567404000
1	tachometer	Pressure	mBar	1006.9	1517567404000
2	tint	Humidity	%	21.0	1517567404000
3	thermometer-half	Temperature	°C	20.7	1517567404000

KUVIO 110. Kampusareenan sensoriverkon data ennen esiprosessointia

KUVIO:ssa 111 Kampusareenan data on esiteltyä esikäsittelyn jälkeen. Esikäsittelyssä aikaleima on konvertoitu luettavaan muotoon ja mitatut suureet on järjestetty uudelleen seuraavaan järjestykseen: ilmankosteus (%), liiketunnistus (on/ei), melu (dB), ilmanpaine (mBar) ja lämpötila (°C). Kuviossa 79 NaN tarkoittaa, ettei mittausta ole voitu toteuttaa.

timestamp	term	Humidity	Motion	Noise	Pressure	Temperature
2018-01-31 17:38:51.000		22.0	NaN	NaN	1011.3	22.3
2018-02-02 10:20:02.000		21.0	NaN	46.0	1006.7	20.2
2018-02-02 10:30:04.000		21.0	NaN	38.0	1006.9	20.7
2018-02-02 10:40:06.000		21.0	NaN	40.0	1007.0	21.3
2018-02-02 10:55:09.000		21.0	NaN	38.0	1007.0	21.7
2018-02-02 11:05:09.000		21.0	NaN	38.0	1007.1	21.9
2018-02-02 11:15:11.000		21.0	NaN	44.0	1007.0	21.9
2018-02-02 11:25:13.000		21.0	NaN	40.0	1007.1	22.0

KUVIO 111. Kampusareenan sensoriverkon data esikäsiteltyä

KUVIO:ssa 112 esittää mittauksien lukumäärää ja siinä on vasemmalta oikealle tarkasteltuna päiväys ja mittauksien lukumäärät (ilman kosteus, melu, ilmanpaine ja lämpötila). Liiketunnistusta ei ole otettu mukaan, sillä liiketunnistustaukukset eivät tältä osin saaneet arvoja. Kuviossa ilmenee, että mittauksissa on ollut taukoa 2018-03-07 – 2018-03-11 välisenä aikana, jolloin sensorit eivät ole olleet käytössä ja mitanneet haluttuja suureita.

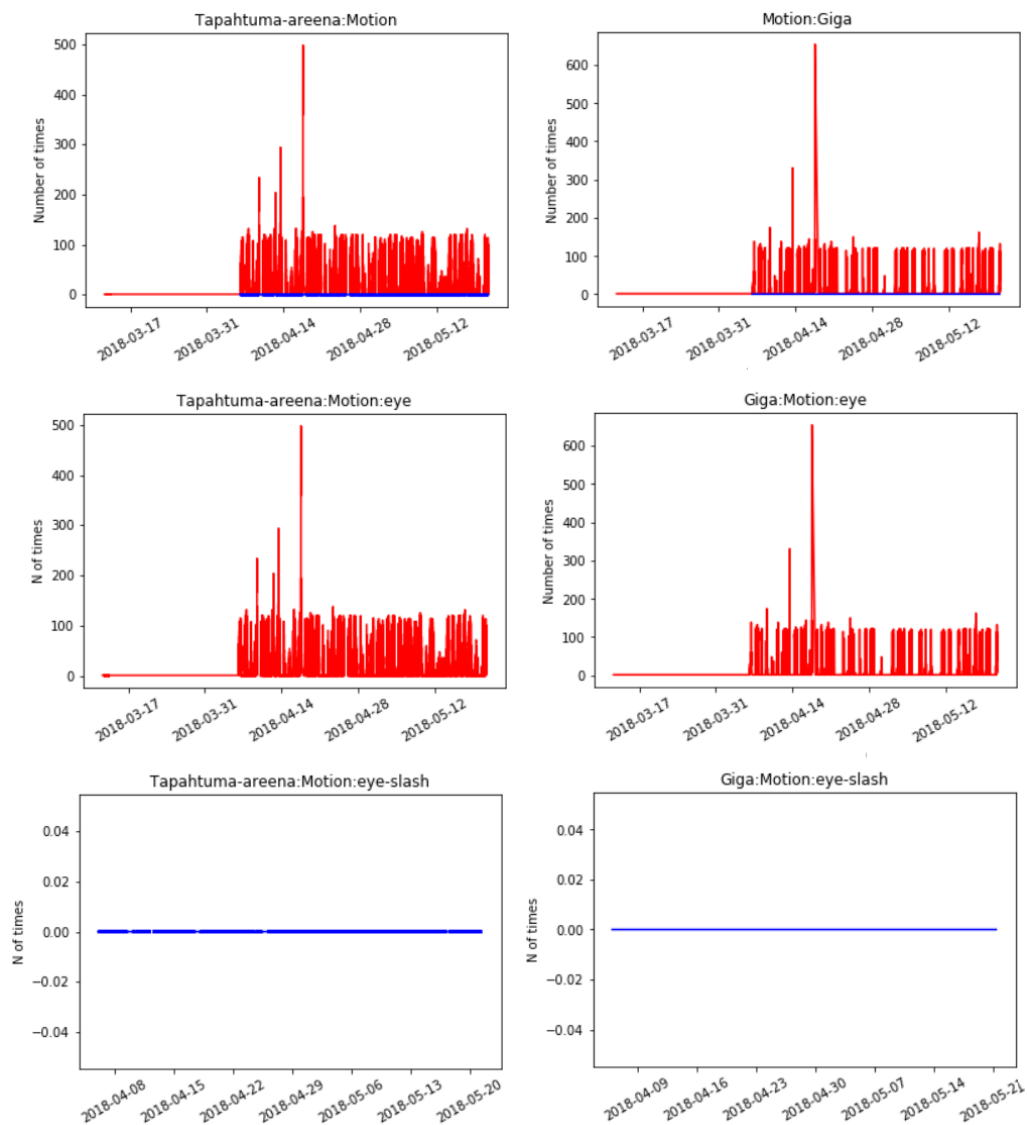
2018-03-03	4	4	4	4
2018-03-04	22	22	22	22
2018-03-05	111	111	111	111
2018-03-06	53	53	53	53
2018-03-07	0	0	0	0
2018-03-08	0	0	0	0
2018-03-09	0	0	0	0
2018-03-10	0	0	0	0
2018-03-11	0	0	0	0
2018-03-12	44	44	44	44
2018-03-13	32	32	32	32

KUVIO 112. Kampusareenan sensoriverkon datan lukumääriä

6.5 SYK:n datan analysointi ja visualisointi


6.5.1 Datan visualisointi

Kampusareenan datan mittausväli oli aikavälillä 31.1.2018 – 21.5.2018. Kampusareenan data on visualisoitu kuvioissa 81 – 86. Datan käsittelyssä ja visualisoinnissa on käytetty python-ohjelmointikieltä ja sen kirjastoja. KUVIO 113. kuvaa Kampusareenan (tapahtuma-areenan, huone 515.) sekä huoneen 534. liiketunnistuksien määrää. KUVIO:ssa huoneen 515. kokonaisliiketunnistus on esitetty vasemmassa yläkulmassa ja huoneen 534. puolestaan oikeassa yläkulmassa. Liiketunnistusdata on myös jaettu komponentteihin 'eye' (keskellä) ja 'eye-slash' (alla). Liiketunnistuksessa voidaan havaita piikki mittausjakson keskivaiheilla sekä kampusareenan huoneessa 515. että huoneessa 534., joka saattaa viitata areenalla pidettyyn tapahtumaan. Muut mittausjakson päivät ilmentävät melko tasaista liikkeen määrää. 'eye-slash'-komponentilla ei ole ollut mittaustuloksia kummassakaan huoneessa. Huoneen 534. käsittely päättyy tähän, sillä huoneesta ei ole mitattu muita suureita.




KUVIO 113. Huoneista 515. ja 534. tehdyt liiketunnistuksen sensorimittaukset

KUVIO 114. havainnollistaa tapahtuma-areenan ilmankosteuden prosentuaalista määrää esitettyinä viivakaavion avulla, josta on helppo lukea ilmankosteuden arvoja. Ilmankosteus nousi yli 25 kosteusprosenttiin mittausjakson alkuvaiheella, jota ennen se oli ollut tasaisessa laskussa. Kuvioista on myös havaittavissa mittauksissa olleet tauot. Tauot kielivät siitä, että joko sensorit on laitettu jostain syystä pois päältä, niiden toiminnassa on vikaa tai tiedonvälitysprosessi sensoreilta tietokantaan ei toimi.




KUVIO 114. Tapahtuma-areenan tehdyt ilmankosteuden sensorimittaukset

KUVIO:ssa 115. on puolestaan esitetty ilmanpaineen vaihtelu mittausajanjakson aikana. Kuviossa ilmanpaine on alussa ollut esitettävissä sinikäyränä. Paineen käytös on ollut tasaista, mutta mittauskäytänteissä on alkanut tapahtua muutoksia tai sensoreihin on alkanut ilmestyä vikaa, sillä päivittäisten mittausten määrät ovat vaihdelleet paljon tarkastelujakson loppua kohden. Lisäksi tässäkin tapauksessa sensorit ovat ilmeisesti olleet poissa päältä jostakin syystä.



KUVIO 115. Huoneen 515 paineen mittaukset ovat alussa selkeästi jatkuvia.

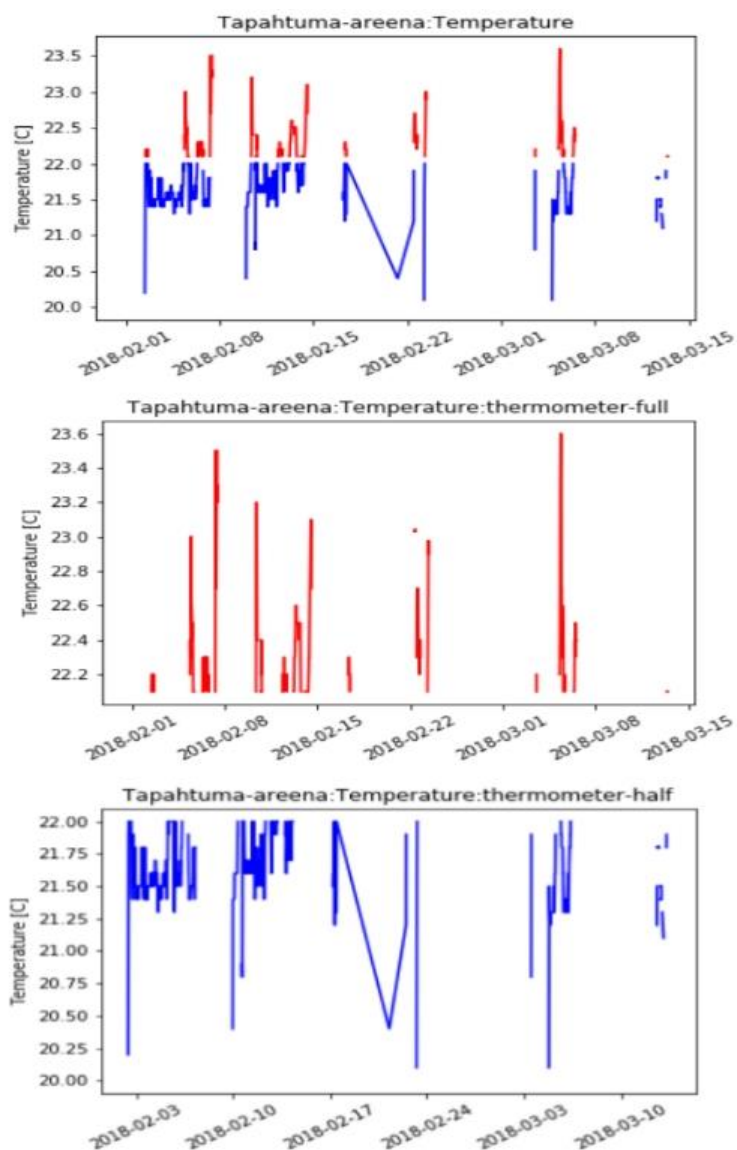
KUVIO 116. esittää kosteuden ja paineen mittausdatat scatter plot -kuvaajina. Selkeimpiä taukoja voi laskea olevan kuvioissa kuusi kappaletta



KUVIO 116. Tapahtuma-areenan epäjatkuvuuskohdat

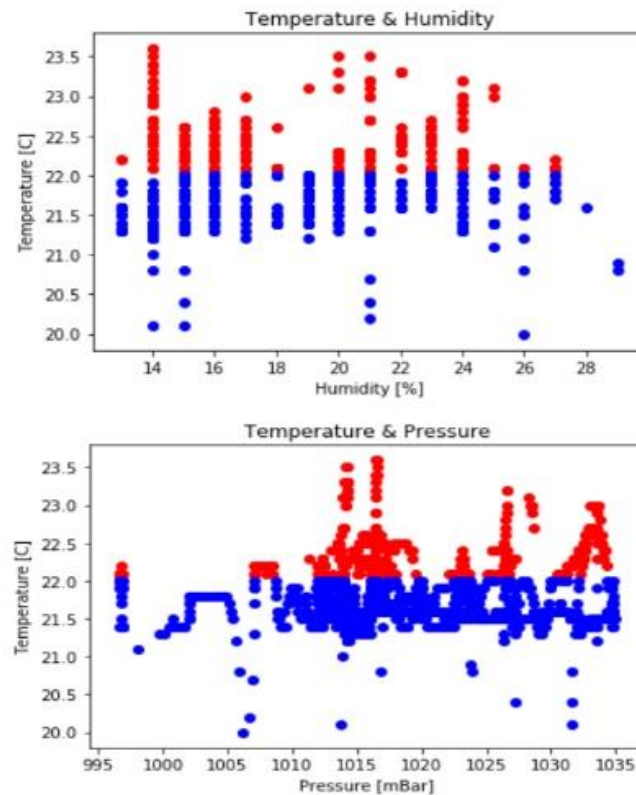
KUVIO:oon 117. on kerätty huoneen 515. lämpötilakuvaajat. Punaiset arvot kuvaavat lämpötiloja, jotka ovat suurempia tai yhtä suuria kuin 22.1 C-astetta ja siniset kuvaavat tätä alempia arvoja. Kuvion vasemmassa laidassa on lämpötila näytetty ensin kokonaisuudessaan ja sen alle on eroteltu korkeiden arvojen käyrä ja matalien arvojen käyrät, jotta niitä voisi tarvittaessa tarkastella helpommin. Mittausten alussa ensimmäisellä kirjatulla ajanjaksolla 2018-02-01 - 2018-02-07 lämpötilan voi havaita pysyvän melko tasaisesti 21,40 C:n ja 21,80 C:n välillä. Tätä voi pitää lämmityksen kannalta otollisena, koska Suomessa rakennusten sisälämpötila pyritään pitämään 21 - 22 C-asteen välillä. Toisella ajanjaksolla 2018-02-09 – 2018-02-15 sisälämpötila näyttäisi kasvavan melko tasaisesti verrattuna ensimmäisen ajanjakson mittauksiin. On mahdollista, että kasvu indikoi harhaa sensoreissa, mutta se voi myös kertoa lämmityslaitteen asetusten muutoksista. Kolmannen ajanjakson 2018-02-16 –

2018-02-23 keskellä tapahtuu suuri pudotus ilman lämpötilassa, jossa alun 22 C:sta lämpötila putoaa 20,5 C-asteeseen useamman päivän ajan. Arvojen välille piirretty negatiivisen gradientin suuntainen suora viiva ja sitä seuraava positiivisen gradientin saanut suora indikoivat, että ajanjakson aikana on otettu liian vähän mittauksia. Neljännellä ajanjaksolla 2018-03-02 – 2018-03-07 lämpötila on vaihdellut koko arvovälillä. Itse ajanjakson välillä olevaa taukoa (2018-03-03 - 2018-03-04) voisi puolestaan pitää hyväksyttävänä virheenä sensoridatassa, joka olisi seurausta varsinaisessa mittarissa tai muussa matkalla sensorilta tietokantaan olevassa laitteesta tapahtuneesta virheestä. Viimeisen ajanjakson 2018-03-12 - 2018-03-13 mittauksista ei voi sanoa mitään, koska mittauspisteitä on liian vähän.




KUVIO 117. Lämpötilan kuvaajat

KUVIO:n 118. yläosassa on esitetty lämpötila ilmastokosteuden avulla. Ilmastokosteus on vaakakselilla prosentteina ilmoitettuna ja lämpötila pystyakselilla Celsiusina. Kuviosta katsomalla lämpötilan keskiarvo on ollut noin 22 Celsiusastetta. Lämpötila on saavuttanut huippunsa 23,7 Celsiusastetta, kun kosteus on ollut 14 %: a. Kosteus on vaihdellut välillä 12 % - 30 %: a. Kuvion alaosassa on esitelty lämpötila ja ilmapaine. Ilmapaine on vaihdellut välillä 996 mBar – 1035 mBar: a. Toisin kuin lämpötilan ja kosteuden kanssa, on huomattavissa, ettei paineella ole ollut vaikutusta lämpötilaan.




KUVIO 118. Kosteus ja paine lämpötilamuuttujalla ilmoitettuna

KUVIO:ssa 119 on viimeisenä kuvattu lämpötila ja liiketunnistusdata aikasarjana. Alussa lämpötilamittauksia on tehty, mutta liiketunnistuspitoa ei ole tehty. Maaliskuun 12. päivän paikkeilla tapahtui muutos mitattavissa suureissa ja liiketunnistuspitoa mittaaminen alkoi. Tästä eteenpäin vain liiketunnistuspitoa on tehty Kampusareenan Tapahtuma-areenalla.




KUVIO 119. Liiketunnistuksen mittaus alkoi 12. päivä maaliskuuta

KUVIO:ssa 120. on esitetty tulokset principal component - analyysistä (PCA-analyysi). Muuttujina datasetistä oli valittuna ilmankosteus, lämpötila ja ilmanpaine. Melu ja liiketunnistukset oli karsittu pois, sillä ne eivät kuvasta huoneen fyysisiä ominaisuuksia. PCA-analyysia käytetään dimensioiden vähentämiseen. PCA-analyysissä datalle lasketaan kovarianssimatriisi, jonka alkio kertoo siitä kuinka paljon mikäkin komponentti riippuu toisistaan. Jos riippuvuutta on, arvo on lähellä ykköstä. Jos taas riippuvuutta ei ole, arvo on lähellä nollaa. Suuret eli komponentit järjestetään suuruusjärjestykseen. Kuviossa suurin komponentti on x-akselilla ja toiseksi suurin on y-akselilla. Kuvioista voidaan huomata, ettei datassa ole varsinaista yhteneväisyyttä eli komponentit eivät riipu selkeästi toisistaan eivätkä ne ole täysin riippumattomiakaan. Kuvion 85 oikeassa laidassa on esitetty komponenttien vaikutusten suuruudet, jotka on saatu laskemalla kovarianssimatriisista matriisin ominaisarvot. Ominaisarvot on muunnettu prosentteiksi jakamalla yksittäiset ominaisarvot kaikkien ominaisarvojen summalla. Komponentit on esitetty vihreinä palkkeina kuviossa 85. Ensimmäinen komponentti on ilmanpaine, mikä on selkeästi ollut tärkein komponentti. Se on vaikuttanut tulosten vaihteluväliin eniten, jopa lähes 50 %:lla. Toisena komponenttina on lämpötila, jonka arvo on noin 30 %:ia. Viimeisenä on kosteus noin 17 %:lla. Kuviossa oleva musta viiva kuvaa komponenttien kumulatiivista summaa.




KUVIO 120. PCA-malli ja kumulatiivinen summa

KUVIO:n 121. muodostuksessa on käytetty itsestään järjestyvää karttaa (Self Organizing Map, SOM) klusteroimaan eli ryhmittelemään datapisteitä ja esittämään useampi dimensioinen data tasossa värien avulla. Pythonin Somoclu -kirjaston funktioita käytettiin kuvien piirtoon. Vasemmassa kuviossa on lisäksi näytetty parhaimmat osumat pienten pisteiden avulla. Perusvärit olivat punainen ja sininen ja ne kuvasivat datapisteiden luokittelua lämpimiksi ja viileiksi arvoiksi. Koska molemmissa kuvioissa värit eivät ole puhtaita, kyseisellä jaolla lämpimiin ja viileisiin arvoihin ei ole ollut merkitystä. Kuvioissa piirtynyt kirkas jana, on merkki siitä, että datasetin klustereiden välillä on jokin suurempi etäisyys data-avaruudessa. Tämän perusteella klustereita olisi kaksi.



KUVIO 121. Dan mittauksiin perustuva SOM-mallin muodostaminen


KUVIO:ssa 122. on esitetty datapisteet ryhmiteltyinä kolmeen klusteriin k-means -klusteroinnilla. Tässäkin dataa oli klusteroitu vain fysikaalisten suureiden perusteelta. Vasemmassa kuviossa on esitetty klusterit punaisen, vihreän ja sinisen avulla, mutta aikaisemmista merkinnöistä poiketen nämä kuvaavat vain eri klustereita, eivätkä lämpötilojen perusteelta tehtyä luokittelua. Oikeassa kuviossa on otos datapisteistä ja niiden tarkemmista arvoista. 3D-kuvion akselit vastaavat oikean kuvion attribuutteja pc1, pc2 ja pc3. Kuvion perusteelta on vaikea sanoa kuuluisiko klustereita olla kaksi vai kolme, sillä varsinaisia selkeitä ryhmittymiä ei näy. K-means -klusteroinnin ongelma on se, että algoritmi klusteroi juuri niin monta ryhmittymää kuin on haluttu klusteroituvan.



	cluster	pc1	pc2	pc3
0	2	-0.531797	2.980496	2.362143
1	2	-0.511045	2.745674	1.213572
2	2	0.310308	1.971358	0.442965
3	2	0.633304	1.605282	-0.251177
4	2	0.858961	1.370765	-0.539798


KUVIO 122. Datan mittauksiin perustuva klusterimallin muodostaminen

Datasta tehtiin lisäksi dendrogrammi, jonka puurakenteen avulla on mahdollista selvittää montako klusteria datassa kuuluisi olla. KUVIO:ssa 123 on esitetty tällainen dendrogrammi skaalatulle datalle. Dendrogrammin vaakasuorat viivat kuvaavat yhdistettyjä klustereita ja pystysuorat viivat kuvaavat klustereiden välistä etäisyyttä. Esimerkiksi kirkkaan keltaisella värjätty klusterijoukko on kaukana klusterijoukosta, johon se on yhdistetty. Tämä klusteri käsittää lähes kaiken datan omissa aliklustereissaan. Koska dendrogrammin loppupään klustereita on paljon ja ne ovat melko tasaisesti korkeuksissaan väheneviä, on oleellinen informaatio datan ryhmittymisestä puurakenteen juuren lähellä. Toisaalta muutama yksittäinen 'outlier' on havaittavissa loppupään klusterijoukoissa.



KUVIO 123. Dendrogrammi skaalatulle datalle


Dendrogrammin juuri on esitelty selkeämmin KUVIO:ssa 124. Tässä kuviossa on karsittu esitettävien klustereiden määrää esittämällä vain oleellimmat klusterit. Aliklusterit ovat järjestettyinä klustereiden määrän mukaisesti kasvavaan järjestykseen. Esimerkiksi vasemmanpuoleisimman yksittäisen datapisteen indeksin arvo on 1234, kun taas sen viereisestä klusterijoukosta on vain esitetty klusterijoukon koko eli aliklustereiden määrä. Aikaisemmin mainittu kirkkaan keltainen klusterijoukko on nyt klusteri, jonka koko on 76 klusteria. Tasojen välisistä korkeuseroista voi päätellä, että todennäköisimmin klustereita on kaksi tai kolme, kun pienimpien yksittäisten datapisteiden ja klustereiden ajatellaan olevan merkityksettömiä. Toisin sanoen alipuut (vasemmalta oikealle) 1-4 muodostavat oman klusterijoukkonsa kuin myös alipuut 5 - 12. Tämän voisi kuitenkin jakaa alipuihinsa 5-6 ja 7-12, sillä alipuiden ero toisiinsa on suuri.



KUVIO 124. Dendrogrammin juuri ja alipuiden koot


6.5.2 Sääinformaation tarkastelu

KUVIO:ssa 125. on esitetty Härmälän sääasemadata aikaväliltä 2.1.2018-31.3.2018. Data on skaalattuna välille [-1,1]. Kuviossa ilmanpaine on sinisenä käyränä ja se näyttää käyttäytyvän käänteisesti ilman lämpötilan (punainen) ja kastepistelämpötilan (violetti) kanssa, sillä paineessa esiintyy piikki, kun lämpötila ja kastepistelämpötila ovat pohjalla. Paineen suurin piikki mittausvälillä on saavutettu helmikuun viimeisenä päivänä. Suhteellinen kosteus (oranssi) on ollut tasaisen korkea ja suppea mittausjakson alussa, mutta mittausjakson loppupuolella sen vaihteluväli on kasvanut. Sateen intensiteetti on esitetty kuviossa vihreinä piikkeinä. Lämpötila ja kastepistelämpötila näyttäisivät laskevan hieman välittömästi pitkäkestoisimpien sateen intensiteetti-piikkien jälkeen. Molemmissa suureissa on tapahtunut selkeää hajontaa ajanjaksolla 19.2.2018-6.3.2018. Ilman lämpötila on pysytellyt pääsääntöisesti kastepistelämpötilan alapuolella, mutta hajonnan kasvaessa tämä käyttäytyminen on loppunut ja suureet ovat olleet lähes samat.




KUVIO 125. Härmälän normalisoitu säädata

KUVIO:ssa 126. on esitetty Tapahtuma-areenan kosteus ja lämpötila yhdessä Härmälän normalisoidun säädatan kanssa. Huoneen kosteus on esitetty violetilla värillä ja huoneen lämpötila ruskealla värillä. Viivojen porrasmaisuus selittyy sillä, että sekä sää- että huoneen 515-data on jouduttu muokkaamaan diskreetiksi. Muutos on tehty niin, että mittauspisteistä on laskettu jokaista tuntia vastaavan tunnin keskiarvo. Kuvioista voidaan nähdä, että Tapahtuma-areenan kosteus on seurannut ulkoilman lämpötilan vaihteluja hieman jäljessä. Huoneen lämpötila vaihtelee paljon ja voi olla, että sen arvoihin vaikuttavat sekä ulkoilman lämpötila, että rakennuksen ulkopuolinen suhteellinen kosteus. Lisäksi ilmanpaineen piikit näyttäisivät sijoittuvan samoille paikoille kuin huoneen lämpötilan.




KUVIO 126. Tapahtuma-areenan kosteus ja lämpötila yhdessä säädatan kanssa

Ilmankosteuden ja huoneen 515. kosteuden vuorokauden aikainen vaihtelu on esitetty KUVIO:ssa 127. Data eriteltiin niin, että kello 8 - 20 väliset mittaustulokset kuuluivat päiväsaikaan ja kello 21 - 7 kuuluivat yöaikaan. Ilmankosteus on koko mittausjakson ollut suurempi kuin huoneen 515. sisäilmanpaine. Ilmankosteuden päiväratio on esitetty kuviossa sinisellä ja sitä vastaava yön arvo on esitetty oranssina. Sisäilmankosteus on pääsääntöisesti pysynyt yön kosteutta suurempana. Ulkoilmankosteuskäyttäytyminen on puolestaan ollut käänteinen.




KUVIO 127. Kosteuden vuorokausikäyttäytyminen

KUVIO:ssa 128. on esitetty paineen vuorokausivaihtelu. Ulkopuolisen paineen vaihtelu on kuvattu sinisellä viivalla (päivällä) ja oranssilla viivalla (yö). Huoneen sisäilmanpaineen vaihtelu on kuvattu vihreällä ja punaisella (yö) värillä. Ulkoilmanpaine on ollut pääsääntöisesti jatkuvaa ja vuorokausivaihtelu ei ole ollut huomattavaa. Sisäilmanpaineessakaan ei ole ollut suuria vuorokausivaihteluja. Sisäilmanpaine on myös ollut selkeästi suurempi kuin ulkoilmanpaine indikoiden Tapahtuma-areenan ilmastoinnin toimivan tarkoituksenmukaisesti ja pääsääntöisesti ylipaineistettuna.




KUVIO 128. Paineen käyttäytyminen päivin ja öin

KUVIO:ssa 129 on esitetty lämpötilojen vuorokausikäyttäytyminen. Sinisellä viivalla on kuvattu ulkoilman lämpötila päivällä ja oranssilla viivalla yöaikainen lämpötila. Vastaavasti sinisillä ja oransseilla pisteillä on esitetty sisäilman lämpötila päivä- ja yöaikaan. Tässä kuviosta on huomattavissa, että lämpötila on pääsääntöisesti ollut päivällä korkeampi kuin yöllä.



KUVIO 129. Lämpötilakäyttäytyminen päivin ja öin

PCA-analysoinnintulosta on esitelty KUVIO:ssa 130. PCA-tarkastelua varten data luokiteltiin kolmeen osaan jakamalla se sisäilmanlämpötilan perusteella. Mikäli lämpötila oli pienempi kuin 22.0 Celsius-astetta luokiteltiin arvot viilleiksi ja arvot, jotka olivat suuremmat kuin 22.1 astetta olivat lämpimiä arvoja. Arvot, jotka jäivät välille 22.0-22.1 Celsius-astetta merkittiin normaaleiksi arvoiksi. Koska dataa oli käsitelty niin, että jokaiselle tunnille oli laskettu jokaista suuretta vastaavat tuntien keskiarvot, joten oli mahdollista, että nyt arvojen joukoissa oli lukuja, jotka mahtuivat vastaavalle välille. Viileät arvot ovat tässä kuviossa esitettyinä sinisillä, normaalit vihreillä ja lämpimät punaisilla pisteillä. Datan käsittelyssä käytettiin Python-ohjelmointikieltä ja sen sklearn -kirjastoja. Principal Component 1 on yhdistetyn kovarianssi- ja ominaisarvo-taulukon perusteella sisäilman kosteus ja Principal Component 2 on sisäilman paine. Kuvion perusteella suureilla ei ole varsinaista yhteyttä toisiinsa eikä keinotekoisiiin lämpötilamuuttujiin.



KUVIO 130. PCA-analysointi yhdistetylle huone- ja säädatalle

KUVIO:ssa 131. on esitetty yhdistetty kovarianssi- ja ominaisarvo-taulukko. Suureet on esitetty sekä pystyyn että vaakaan. Hka tarkoittaa Tapahtuma-areenan sisäilman kosteutta, Pka tarkoittaa vastaavasti painetta ja Tka sisäilman lämpötilaa. Säädata on melko yksiselitteisesti nimetty. Viimeinen sarake tarkoittaa ominaisarvoja. Tämä taulukko on muodostettu sklearn-kirjaston PCA-luokan avulla parametrin `n_components` ollessa yhdeksän. Taulukosta voidaan nähdä, että suurin ominaisarvo on sisäilman kosteudella, jolloin sen muutokset vaikuttavat eniten suhteessa muihin muuttujiin. Sisäilman paine on toiseksi suurin muuttuja ja sisäilman lämpötila on kolmanneksi suurin. Kovarianssimatriisin pohjalta voi sanoa, että huoneen kosteuteen vaikuttaa pilvien määrä, ulkoilman suhteellinen kosteus, ulkoilman lämpötila ja ulkoilman kastepistelämpötila, joista kastepistelämpötila on selkeästi vaikuttavin huoneen kosteuteen. Sisäilman paineeseen vaikuttaa huoneen

kosteuden lisäksi käänteisesti pilvien määrä, ulkoilman paine ja lumen syvyys. Sisäilman paineella ja ulkoilman paineella on selvä riippuvuus toisistaan, vaikka molemmat ovat itsenäisiä suureita. Taulukkoa tarkasteltaessa voi huomata, että sisäilman lämpötilaan ei muilla suureilla ole vaikutusta eli sisäilman lämpötila on riippumaton muista suureista.

	Hka	Pka	Tka	Pilvien määrä (1/8)	Ilmanpaine (msl) (hPa)	Suhteellinen kosteus (%)	Sateen intensiteetti (mm/h)	Lumensyvyys (cm)	Ilman lämpötila (degC)	Kastepistelämpötila (degC)	omarvot
Hka	1.003448	-0.414833	0.207858	0.536364	-0.445566	0.538224	0.403075	0.357910	0.868247	0.908528	4.894387
Pka	-0.414833	1.003448	0.064830	-0.543975	1.002436	-0.272583	-0.390833	-0.569888	-0.425179	-0.448755	1.561409
Tka	0.207858	0.064830	1.003448	-0.032383	0.047695	-0.290578	-0.078090	0.066727	0.282706	0.197443	1.327011
Pilvien määrä (1/8)	0.536364	-0.543975	-0.032383	1.003448	-0.561693	0.393669	0.155130	0.144992	0.626087	0.660916	0.937464
Ilmanpaine (msl) (hPa)	-0.445566	1.002436	0.047695	-0.561693	1.003448	-0.280084	-0.392472	-0.579000	-0.463195	-0.485128	0.504690
Suhteellinen kosteus (%)	0.538224	-0.272583	-0.290578	0.393669	-0.280084	1.003448	0.267793	0.046764	0.295260	0.488800	0.468453
Sateen intensiteetti (mm/h)	0.403075	-0.390833	-0.078090	0.155130	-0.392472	0.267793	1.003448	0.423335	0.313293	0.342096	0.244247
Lumensyvyys (cm)	0.357910	-0.569888	0.066727	0.144992	-0.579000	0.046764	0.423335	1.003448	0.410476	0.385589	0.096550
Ilman lämpötila (degC)	0.868247	-0.425179	0.282706	0.626087	-0.463195	0.295260	0.313293	0.410476	1.003448	0.981155	0.000183
Kastepistelämpötila (degC)	0.908528	-0.448755	0.197443	0.660916	-0.485128	0.488800	0.342096	0.385589	0.981155	1.003448	0.000089

KUVIO 131. Tapahtuma-areenan kovarianssi ja ominaisarvo-taulukko

6.5.3 Sisäilman suureiden ennustaminen

Edellä esitellyn kovarianssi- ja ominaisarvo-taulukon avulla pyrittiin seuraavaksi ennustamaan huoneen 515. sisäilman suureiden käyttäytymistä lineaarisella regressiomallilla.

Taulukosta valittiin pilvien määrä, suhteellinen kosteus, ilman lämpötila ja kastepistelämpötila suureiksi, joita käytettiin huoneen ilmankosteuden ennustamiseen. Nämä suureet valikoituivat, sillä niiden kovarianssitaulukon mukaiset absoluuttiset arvot ovat suuremmat kuin 0.50 Hka -sarakeessa. Samalla periaatteella sisäilman paineen ennustamisessa käytettiin suureita pilvien määrä, ilmanpaine ja lumensyvyys. Sisäilman lämpötilan ennustamiseen puolestaan käytettiin kaikkia suureita.

Data jaettiin satunnaisesti koulutus- ja testi-dataan Sklearn -kirjaston `train_test_split`-funktion avulla, `random_state` arvon ollessa 42, josta testi-datan suuruus oli kymmenen prosenttia kaikesta datasta. Jokaista kolmea suuretta ennustettiin LinearRegression -mallia käyttäen. Kuviossa 132 on esitetty esimerkkinä kosteudelle ennustettuja arvoja ja todellisia arvoja ja näiden erotukset. On huomioitava, että tarkkuus on mitattu vain yhdellä desimaalilla. Indeksissä 4 on tapaus, jossa ennustus on onnistunut kohdalleen ja heti seuraavassa indeksissä voi huomata, että ennustetun ja todellisen arvon välinen etäisyys on 1,3 yksikköä.

	abs_ero		erotus	pred	y_test
0	0.7	[0.6999999999999993]	15.7	[15.0]	
1	0.6	[0.5999999999999979]	16.4	[15.8]	
2	0.1	[-0.0999999999999964]	13.9	[14.0]	
3	0.3	[-0.3000000000000007]	19.7	[20.0]	
4	0.0		[0.0]	19.0	[19.0]
5	1.3	[1.3000000000000007]	20.3	[19.0]	

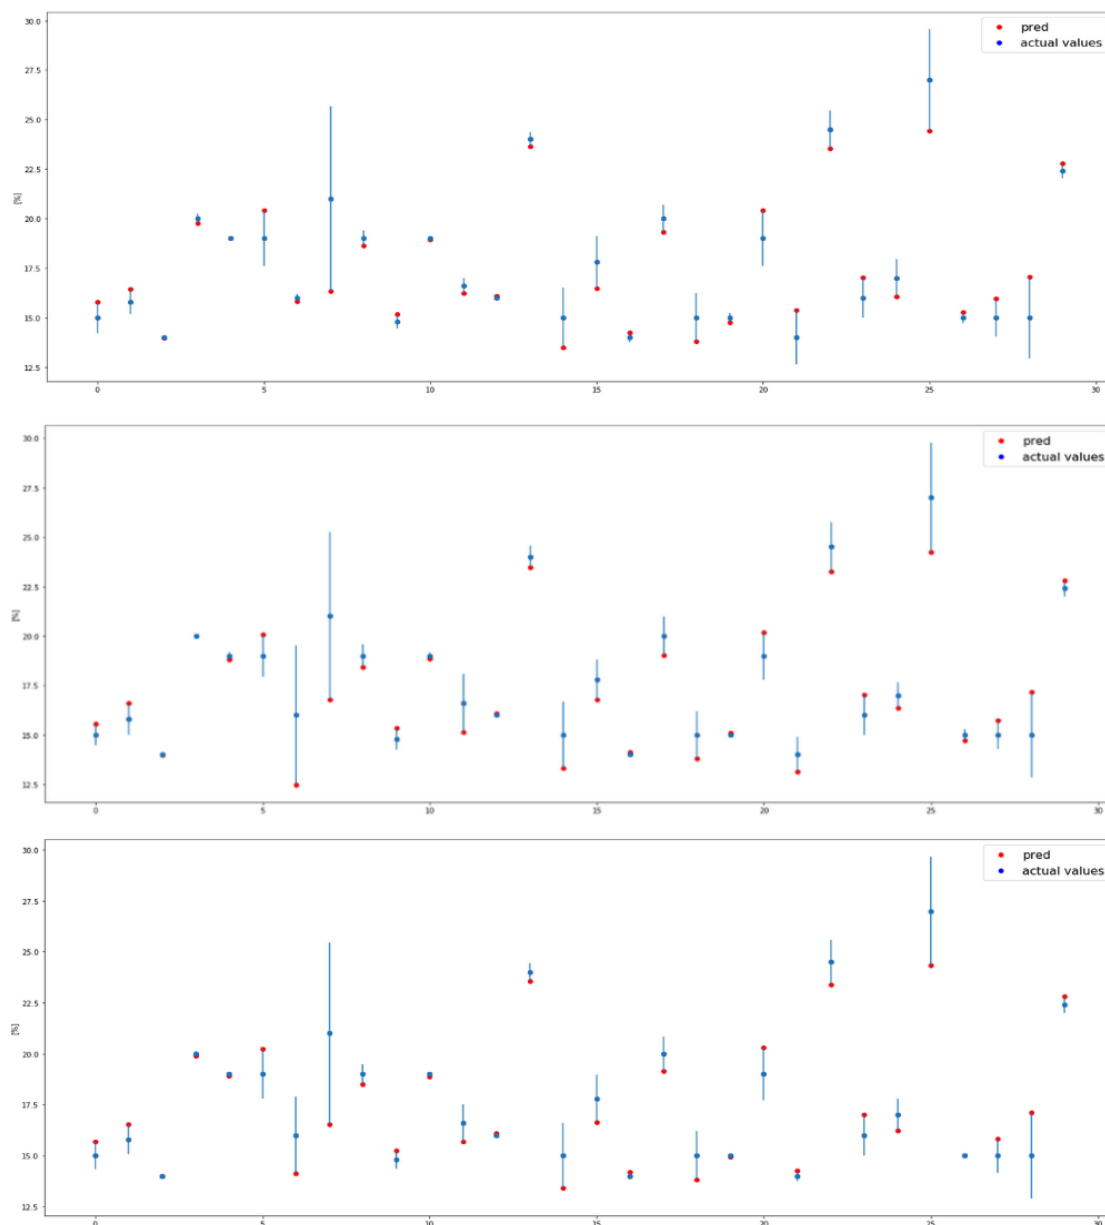
KUVIO 132. Pred-sarakkeessa on mallilla ennustettu arvo

KUVIO:ssa 133. on esitetty laskennat siitä, montako prosenttia ennustetuista mittaustuloksista on mennyt oikein suhteessa etäisyyteen todellisesta arvosta. Kuviossa on eritelty tulokset, jotka on saatu laskettaessa huoneen kosteutta (a), painetta (b) ja lämpötilaa (c). Ensimmäinen sarake on tulosten indeksi. Jokainen delta-sarake kuvaa plus/miinus -etäisyyttä oikeasta arvosta. Oikein-sarake kuvaa tälle etäisyyden välille mahtuvien tulosten prosentuaalista osuutta kaikkien testiarvojen lukumäärästä kyseisen suureen kohdalta. Kosteuden ennuste ei saavuta mittaustuloksilla koskaan 100 %: ia, joten mittaustulokset on ollut sille liian kapea. Sisäilman paine saavuttaa 100 %: n, kun ennusteväli on $\pm 1,6$ yksikköä. Sisäilman lämpötila saavuttaa 100 %: ia, kun ennusteväli on $\pm 1,2$ yksikköä. 80 %: ia voidaan usein pitää hyvänä tuloksena; tällöin ennusteväli olisi kosteudelle $\pm 1,4$ yksikköä, paineelle $\pm 1,0$ yksikköä ja lämpötilalle $\pm 0,4$ yksikköä. Lämpötilan ennusteväli on pienin, mikä todennäköisesti johtuu siitä, että huoneen lämpötila pysytteli koko mittaustulosten ajan paljon pienemmällä arvovälillä kuin sisäilman paine ja kosteus.

a	delta	oikein [%]	b	delta	oikein [%]	c	delta	oikein [%]
0	0.0	6.666667	0	0.0	3.333333	0	0.0	3.333333
1	0.1	10.000000	1	0.1	10.000000	1	0.1	26.666667
2	0.2	23.333333	2	0.2	16.666667	2	0.2	53.333333
3	0.3	26.666667	3	0.3	26.666667	3	0.3	66.666667
4	0.4	43.333333	4	0.4	36.666667	4	0.4	80.000000
5	0.5	46.666667	5	0.5	53.333333	5	0.5	86.666667
6	0.6	50.000000	6	0.6	56.666667	6	0.6	93.333333
7	0.7	56.666667	7	0.7	66.666667	7	0.7	96.666667
8	0.8	56.666667	8	0.8	73.333333	8	0.8	96.666667
9	0.9	56.666667	9	0.9	76.666667	9	0.9	96.666667
10	1.0	70.000000	10	1.0	83.333333	10	1.0	96.666667
11	1.1	70.000000	11	1.1	86.666667	11	1.1	96.666667
12	1.2	70.000000	12	1.2	96.666667	12	1.2	100.000000
13	1.3	70.000000	13	1.3	96.666667	13	1.3	100.000000
14	1.4	83.333333	14	1.4	96.666667	14	1.4	100.000000
15	1.5	90.000000	15	1.5	96.666667	15	1.5	100.000000
16	1.6	90.000000	16	1.6	100.000000	16	1.6	100.000000

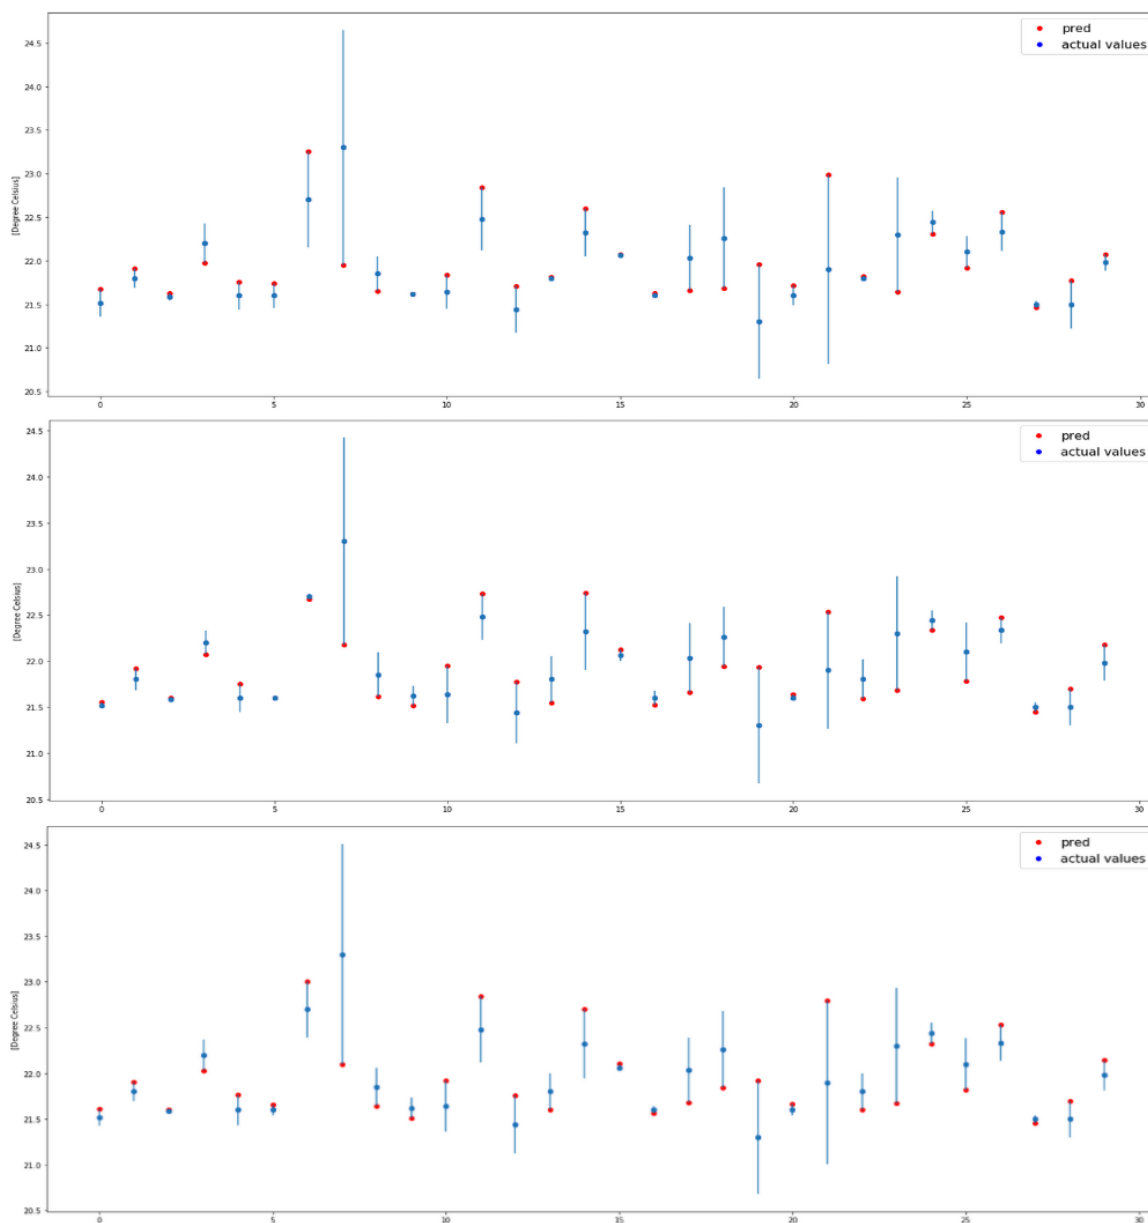
KUVIO 133. Kosteuden (a), paineen (b) ja lämpötilan (c) ennusteiden epätarkkuus

KUVIO:ssa 134. ovat esitettyinä kolmen eri mallin tulokset kuvaajina. Mallit esittävät sisäilman kosteuden todellisia arvoja ja näille ennustettuja arvoja, kun mallit on koulutettu ja testattu satunnaisella datalla. Mallien kouluttamiseen ja testaamiseen oli käytetty kaikki liennyt data. Todelliset arvot ovat esitettyinä sinisillä pisteillä ja ennustetut punaisina pisteinä. Pisteiden välinen pystysuora viiva kuvaa ennustetun ja todellisen arvon etäisyyttä eli virhemarginaalia kyseille tapaukselle. Kosteuden arvot on esitetty pystyakselilla ja vaaka-akselilla on mittauksen indeksi. Kosteuden yksikkö on prosentti, kun taas vaaka-akselilla ei ole yksikköä. Kuviossa ylimpänä on LinearRegression -mallin tulos, keskimmäisenä BayesianRidge -mallilla saatu tulos ja alimpana Ridge -lsqr-mallin tulos. Malleja, joita testattiin ennustamisessa käyttämiseen, oli useita, mutta nämä tuottivat parhaimmat ennusteet, kun mallit valittiin kaikista parhaimman delta-etäisyyden perusteella, joka oli 1.3 yksikköä. Toisin sanoen delta valikoitui sillä, että se oli kaikkien mallien kaikista delta-etäisyyksistä, jotka vastasivat oikein-sarakkeen 80 prosentin arvoa, pienin. Lineaarille regressio-mallille tämä tarkoitti, että 22 mittauksista meni oikein 30:stä ja joista kahdeksan meni täysin tai lähes täysin oikein. Täysin tai lähes täysin osuus on laskettu kuvaajasta, kun sininen ja punainen piste ovat edes osittain päällekkäin. BayesianRidge- mallilla 24 mittauksista meni oikein ja täysin tai lähes täysin oikein menneiden lukumäärä on kuvan perusteella seitsemän. BayesianRidge -mallilla oli näistä malleista eniten outlieria, mutta niistä huolimatta malli antoi hyviä tuloksia. Ridge -lsqr-malli oli paras kahdeksalla täysin tai lähes täysin oikein menneellä mittauksella. Kokonaisuudessaan oikein meni 25 mittauksista 30:stä mittauksesta. Erityisesti kuvaajien indeksien piste kuusi on mielenkiintoinen, sillä ensimmäinen malli on saanut sen lähes täysin oikein, mutta BayesianRidge- ja Ridge-lsqr-malleissa se on outlier, joskin hieman eri kokoinen.



KUVIO 134. LinearRegression (ylin), BayesianRidge ja Ridge-lsqr (alin) mallien tulokset kosteuden ennustuksessa


KUVIO:ssa 135. on puolestaan esitetty Tapahtuma-areenan sisälämpötilan ennusteet ja vastaavat oikeat arvot kuvaajissa. Kuvaajissa pystyakselilla on esitetty lämpötilan arvo (yksikkönä Celsius) ja vaaka-akselilla on mittauksen indeksi, joka on yksikötön. Ennusteet ovat punaisina pisteinä ja todelliset arvot sinisinä pisteinä. Esitetyt mallit ovat BayesianRidge, LinearRegression ja Ridge-cholesky, sillä ne osoittautuivat tarkimmiksi, kun delta-etäisyyden arvo oli 0,4 ja se oli valittu samaan tapaan kuin edellä kosteuden mittauksissa. Kuviossa ylimpänä on BayesianRidge -malli, jonka ennustuksista 24 meni oikein 30 mittauksesta. Oikein tai lähes oikein menneitä arvoja oli seitsemän ja ne laskettiin kuvaajasta. LinearRegression- ja Ridge-cholesky-mallit saivat molemmat 25 ennustusta oikein 30:stä mittauksesta. Kuvaajista katsottuna oikein tai lähes oikein meni molemmilla malleilla sama määrä eli kuusi ennustusta.



KUVIO 135. BayesianRidge (ylin), LinearRegression ja Ridge-cholesky (alin). Sisätilan lämpötilan ennustaminen


KUVIO:ssa 136. on esitetty sisätilan paineen ennustetut ja todelliset arvot kolmella eri mallilla. Ennustetut arvot on esitetty punaisina pisteinä ja todelliset arvot sinisinä pisteinä. Paineen yksikkö on hPa. Vaaka-akseli on yksikötön, sillä se kuvaa vain ennustuksen järjestysnumeroa. Sisätilan paineen tapauksessa delta-etäisyydeksi valikoitui edeltävällä päättelyllä 0,4 yksikköä, mikä on hyvin pieni etäisyys suhteessa paineen arvojen suuruuksiin. Kuviossa ylimpänä on LinearRegression -mallilla saadut ennusteet ja vastaavat todelliset arvot. 80 prosentin oikeellisuuden rajan saavutti 22 ennustusta kaikista 30:stä. Lasso-mallin kuvaaja on keskellä kuviota. Sillä saavutettiin 24 oikein mennyttä ennustetta 30:stä ennusteesta. Alimpana kuviossa on KernelRidge -malli, jonka ennusteiden laskennassa käytettiin lineaarista kerneliä. Myös tämä malli tuotti 24 oikein mennyttä ennustetta kaikista testikerroista. Paineen tapauksessa ei ole mielekästä laskea täysin tai lähes täysin menneiden ennusteiden

lukumääriä, sillä paineen arvot suhteessa delta-arvoon ovat noin 2490:1. Jokainen valittu malli antoi hyvän ennusteen paineen arvolle.



KUVIO 136. LinearRegression (ylin), Lasso, KernelRidge-linear (alin). Paineen ennusteet

KUVIO:ssa 137. on esitetty kolmen eri mallien tulokset, kun kouluttamisessa ja testaamisessa on käytetty dataa vain aikaväliltä [2018-02-02 10:00:00, 2018-02-07 10:00:00], jolloin Tapahtuma-areena-huoneen data oli yhtenäisintä. Kahta erilaista koulutusmenetelmää käytettiin; satunnaisesti valittua ja aikasarjadataa.




KUVIO 137. LinearRegressor (ylin), RANSACRegressor, SVR-rbf (alin)

KUVIO:ssa 137. on esitetty satunnaisesti valitulla datalla koulutetut ja testatut kolme parhaimmaksi valikoitunutta mallia. Mallit esittävät sisätilan kosteuden ennusteita ja todellisia arvoja. Ennusteet on esitetty punaisina pisteinä ja todelliset arvot sinisinä pisteinä. Pisteiden välinen sininen pystysuora viiva kuvaa todellisen ja ennustetun arvon virheväliä. Pystyakselilla on ilmaistu kosteuden arvo prosentteina. Vaaka-akseli on eri arvoilla tehtyjen ennusteiden indeksi. Kuviossa ylimmäisenä on LinearRegression-mallin tulosten kuvaaja, keskimmäisenä RANSACRegressor-mallin tulosten kuvaaja ja alimmaisena SVR-rbf-mallin tulosten kuvaaja. Mallit valikoituivat parhaimmiksi kosteuden kuvaajiksi käytettäessä 80 %: in luottamusväliä, jolloin delta-etäisyys oli 0,7 yksikköä. LinearRegression-mallilla kuusi ennustetta 12:sta mahtui virhevälille $\pm 0,7$ yksikköä oikeasta arvosta. RANSACRegressor mallilla meni oikein seitsemän testiä 12:sta. Tällä mallilla oli eniten outliereita. SVR-rbf-mallilla

oikein meni puolestaan kymmenen ennustetta 12:sta. Kaikille malleille oli yhteistä, että indeksissä viisi ennustus oli mennyt selkeästi väärin, mikä johtunee siitä, että vastaavaa tai vielä suurempaa arvoa ei ole ollut koulutusdatassa.


KUVIO:ssa 138. on esitetty sisäilman lämpötilaennusteet kolmella eri mallilla. Ennusteet ovat punaisina pisteinä ja todelliset arvot sinisinä pisteinä. Lämpötilan yksikkönä on Celsius. Vaaka-akseli kuvaa ennusteen indeksistä. Mallit ovat KernelRidge -malli lineaarisella kernelillä (kuviossa yllä), SVR-sigmoid (keskellä) ja SVR-rbf (alin). Delta-etäisyys oli 0,3 yksikköä. KernelRidge -linear-malli sai kahdeksan ennustetta oikein 12:sta, kun SVR -sigmoid ennusti yhdeksän tapausta oikein 12:sta. Tarkin malli oli SVR-rbf -malli, joka sai 10 ennustusta oikein 12:sta ennustuksesta. Vaikka SVR -sigmoid sai hyvät tulokset ennustamisesta näin pienellä testillä, se on selkeästi rajoittunut välille 21,5 - 22,0 Celsiusia.



KUVIO 138. KernelRidge-linear (yllin), SVR-sigmoid, SVR-rbf. Sisätilan lämpötilaennusteet


6.5.4 SYK:n dataa hyödyntäviä tekoälyratkaisuja CO₂-pitoisuuden arviointiin

Suomen yliopistokiinteistön Kampusareenan datan liiketunnistussensorin mittaama liiketunnistusdata jaettiin viiden minuutin aikajaksoihin (KUVIO 139) aikavälille 0 - 60 min. Mittausdatasta on nähtävissä, että aikaväleillä 10 - 15 min, 25 - 30 min, 40 - 45 min ja 55 - 60 min Kampusareenan Tapahtuma-areenan tiloissa on ollut havaittavissa keskimääräistä enemmän liikettä ja keskimäärin tiloihin on tullut tai niistä on lähtenyt 8 - 9 ihmistä. Muina ajankohtina liike on ollut huomattavasti vähäisempää ja keskimäärin tiloista on lähtenyt tai niihin on tullut yksi ihminen.




KUVIO 139. Liiketunnistuksen keskimäärä 5 minuutin aikajaksojen funktiona

KUVIO:ssa 140. havainnollistetaan liiketunnistusdatan erotuksia aikavälillä 0 - 60s. Tämä kuvio havainnollistaa erotuksen sekunneissa edeltävään arvoon ja suurimmat huiput kävijämäärissä sijoittuvat aikavälin alkupäähän ja keskivaiheille. Ensimmäisten noin viiden sekunnin aikana huoneeseen kulkee tai huoneesta lähtee suurin osa ihmisistä eli ihmiset kulkevat ryhmässä. Seuraava huippu on 30 sekunnin molemmiin puolin, jolloin lähes yhtä suuri joukko ihmisiä kulkee huoneistoon tai sieltä pois. Aikavälin loppupäässä n. 60 sekunnin kohdalla kulkevien ihmisten määrä on jo huomattavasti pienempi, jolloin on nähtävillä pientä kohoumaa. Ihmisten kulkiessa sisään tai ulos huoneistosta oven avaamisen yhteydessä huoneistoon sisään virtaa ilmaa, joka riippuu oven aukioloajan pituudesta. Ilman virtauksella on vaikutusta huoneiston hiilidioksidipitoisuusarvoihin.



KUVIO 140. Liiketunnistusdatan erotukset sekunneissa edeltävään arvoon aikavälillä 0 - 60 s

KUVIO:ssa 141. havainnollistetaan liiketunnistusdatan erotuksia aikavälillä 0 - 50 000s (13h 53 min 20 sek.). Mittausjakson alkupäässä on havaittavissa piikki, jonka vaikutus kestää noin 1700 sekunnin (28 min) ajan. Piikin eli noin 28 minuutin ajanjakson aikana ihmiset kulkevat Kampusareenan Tapahtuma-areenaan tai lähtevät sieltä. Mittausjaksolla ei ole muita yhtä merkittäviä nousuja, tosin 45 000 - 50 000 sekunnin välillä on havaittavissa pienimuotoista kohoumaa. 10 000 - 40 000 sekunnin välillä on hiljainen ajankohta, jolloin ei ole juuri havaittavissa liikettä. Ajanjakson voisi päätellä mahdollisesti olevan yöaikaa tai olevan muulla tavoin hiljainen ajankohta.



KUVIO 141. Liiketunnistusdatan erotukset sekunneissa edeltävään arvoon koko aikaväliltä

Hiilidioksidipitoisuuden arviointia varten voisi mahdollisesti soveltaa yhtä seuraavista neljästä vaihtoehdosta:

Vaihtoehto 1

Näistä voisi kehittää mallin, jonka perusteella ennakoida kävijämääriä, mutta joka olisi todennäköisesti kuitenkin huono hiilidioksidin laskentaa varten. Sellainen malli tarvitsisi parametreikseen esim. päivän numeron (1-7), kellon ajan (tunnit ja minuutit omanaan) ja luennon/muun toimen tarkoitetun alkamisajan (tunnit ja minuutit ominaan) sekä toimen tarkoitetun keston minuutteina. Näillä ja arvioiduilla kävijämäärillä voisi mahdollisesti ennustaa kävijöiden määrää ja siten hiilidioksidin kasvua.

Ongelma on siinä, että tämä ennustaminen riippuu voimakkaasti ehdotetusta mallista, jossa on tehty useita oletuksia. Oletukset painottuvat voimakkaasti käyttäjämäärä/tunti distribuution muuttumattomuuteen. Ei ole olemassa takeita siitä, etteikö käyttäjämäärät muuttuisi päivittäin ja vieläpä vuosien varrella usein.

Vaihtoehto 2

Muodostetaan malli käyttäen edeltävän tunnin käyttäjämääriä ja edeltävien kahden minuutin liiketunnistusdataa sekä näissä olevia aikavälillisiä erotuksia. Tällöin voitaisiin arvioida, montako ihmistä on huoneessa ja miten he ovat viimeisen kahden minuutin aikana saapuneet huoneeseen.

Ongelma on, että ei tiedetä ovatko käyttäjät poistuneet huoneesta tunnin päästä, mikä hankaloittaa hiilidioksidin määrän arviointia. Poistuminen huoneesta tarkoittaa, että mallissa on jälleen oletettava näin tapahtuvan. Datan perusteella tämä ei tällä hetkellä ole pääteltävissä.

Vaihtoehto 3

Muodostetaan malli käyttäen vaihtoehtoa 2. lisäksi käyttäjämäärät informaation lisäksi käyttäjien kulkudistribuutio rajatulta aikaväliltä eli data ikkunoidaan. Lisäksi on annettava (minuutteina tai jonain muuna yksikkönä) kesto aloitukseen. Esim. 60 minuutin aikaikkuna, jolle data annetaan minuuteittain siten, että minuutti sisältää uusien käyttäjien määrän kyseisen minuutin aikana. Verkko koulutettaisiin arvioimaan seuraavan aika-askeleen (tai esim. viiden seuraavan aika-askeleen) päähän hiilidioksidin määrän kasvua huoneessa.

Ongelma syntyy jälleen siitä, että alun hiilidioksidilukemia ei tiedetä, käyttäjien kulku huoneeseen tapahtuu minuutin aikajaksoissa ja käyttäjien poistumaa huoneesta ei tiedetä. Lisäksi kahden minuutin sekunnittainen käyttäjädistribuutio lisäisi neuroverkon syöteparametreja 120 kappaleella, mikä on paljon.

Tieto siitä kauanko aloituksesta on kulunut suhteessa nykyhetkeen voi helpottaa hiilidioksidikäyttäytymisen arviointia. Lisäksi aloitushetkestä alkaen laskettu käyttäjämäärä tarvitaan. Todennäköisesti on koulutettava useampi malli niin, että esimerkiksi ensimmäinen malli olettaisi suurimman osan käyttäjistä poistuvan huoneesta 30 min päästä, toinen malli olettaisi poistumisen tapahtuvan tunnin päästä, jne.

Yksinkertaisinta voisi olla, että oletetaan käyttäjiä saapuvan huoneeseen vain ensimmäisten 15 min ajan (ennen aloitusta huone on tyhjä) ja kouluttaa neuroverkko/t ennustamaan hiilidioksidimääriä seuraaville minuuteille, kuten minuuteille 16,17,18 jne. 30 minuuttiin asti tarkoitetun jakson alulta.

Vaihtoehto 4

Aikaikkunaratkaisu on mahdollista kiertää käyttämällä LSTM-neuroverkkoa, jolloin malli saisi syötteekseen vain käyttäjien lukumäärän ja käytön keston eli nykyisen ajanhetken erotuksen alkamisaikaan esim. sekunneissa, sekä arvioidun hiilidioksidimäärän. Mallia voisi käyttää näin ennustamaan hiilidioksidipitoisuusarvoja.

Malli olisi edelleen paranneltavissa esimerkiksi sisällyttämällä parametreihin viimeisten kahden minuutin käyttäjädistribuutio, jolloin malli 'näki' miten käyttäjiä on saapunut paikalle, mikä voisi tarkentaa hiilidioksidiarvojen ennusteita. Tämä informaatio pitäisi syöttää neuroverkolle esimerkiksi 10 sekunnin väleinä, mikä tarkoittaisi yhteensä viisi lisäparametria (kohtuullista) neuroverkolle. Tällöin yhteensä parametreja tarvittaisiin lkm + kesto + ennuste + huoneen kuutiolavuus + viimeisen kuluneen 10 sekunnin aikana kulkevien ihmisten määrä = 5 kappaletta, mikä on täysin kohtuullinen parametrimäärä. Vaihtoehtoa 4 testatessa käytettiin 12 yksikön aikaikkunaa ja pyrittiin ennustamaan hiilidioksidiarvoja minuutin ja kahden minuutin päähän.


Vaihtoehdon 4 testaaminen lienee järkevintä nykyisen tietämyksen perusteella.

6.5.5 Käytöksen simulointi ja LSTM-neuroverkko

Vaihtoehtoa neljä testattiin luomalla simuloitua dataa, jossa oli muuttujina ihmisten lukumäärä, mittaushetken ajallinen erotus mittaushetken alusta, edeltävä arvio hiilidioksidin määrästä huoneessa, huoneen kuutiolavuus sekä viimeisten 10 sekunnin aikana kulkeneiden ihmisten lukumäärä. Dataa simuloitiin 30 min ajalle sata kertaa käyttäen satunnaista virhettä ihmisten tulohetkestä huoneeseen, hengityksestä johtuvan hiilidioksidin arvojen kasvuun ja huoneen tilavuuden vaihteluun, jotta datassa olisi häiriötekijöitä, sillä häiriötekijöiden kohtuullinen lisääminen yleensä parantaa neuroverkkojen yleistymistä.


KUVIO:ssa 142. on havainnollistettu simuloitujen hiilidioksidin käyttäytymistä käyttäjien lukumäärän suhteen. X-akselilla on esitetty simuloitujen huoneen käyttäjien lukumäärä ja y-akselilla on esitetty hiilidioksidin arvot grammoina. Kuvion kuusi käyrää esittävät hiilidioksidin käytöstä eri ajan hetkinä, joista alin on hiilidioksidin kasvun käytös ensimmäisen viiden minuutin aikana mittauksen alusta. Tämä

käyrä on kaikkien simulaatioiden perusteella vaihdellut välillä 0 - 40 grammaa. Toiseksi alin käyrä tarkoittaa mittauksen ajallista välillä 5 - 10 minuuttia, jolloin hiilidioksidikäyrän arvot ovat vaihdelleet välillä 30 - 120 grammaa. Kolmas käyrä on ajanväliltä 10 – 15 minuuttia, jolloin hiilidioksidiarvot ovat vaihdelleet välillä 160, käyttäjiä ollessa huoneessa noin 19 henkeä, ja 250, käyttäjiä ollessa noin 60 henkeä. Neljäs käyrä kuvaa aikaväliä 15 - 20 minuuttia, jolloin hiilidioksidiarvot ovat kasvaneet noin 180 grammasta noin 350 grammaan. Viides käyrä on ollut aikaväliltä 20 - 25 minuuttia ja kuudes käyrä on ollut aikaväliltä 25 - 30 minuuttia. Näiden käytökset ovat muistuttaneet toisiaan sekä neljännen käyrä käyrän käytöstä. Näiden välinen ero on suhteessa huoneen käyttäjien lukumäärään nähden kasvanut noin 100 grammasta noin 200 grammaan.



KUVIO 142. Simuloidun datan CO₂ –kasvu ajan ja henkilömäärän kasvaessa

KUVIO:ssa 143. on esitetty kaikkien simulaatiokertojen käyttäjien jakauma. Jakauma esittää kuinka ihmiset ovat saapuneet simuloituun huoneeseen 30 minuutin aikana. Jakauma on tehty Python -ohjelmointikielellä käyttämällä seaborn -kirjastoa. Pysty-akselilla on esitetty käyttäjien määrä ja vaaka-akselilla puolen tunnin aikainen jakauma. Kuvioista on nähtävissä, että simulaatio ei ole onnistunut kuvaamaan täydellisesti kuvion 139 käytöstä. Käyttäjämäärät ovat olleet suuremmat ja käyttäjiä on tullut useammin simuloituun huoneeseen kuin kuviossa 139 on esitetty.



KUVIO 143. Kaiken simuloitun datan jakauma ensimmäiseltä 30 minuutilta


Käyttäen Keras –ohjelmointirajapintaa ja sen taustalla TensorFlow –ohjelmointikirjastoa luotiin LSTM –neuroverkko käyttäen aiemmin mainittuja simuloituja arvoja syötteenä. Data oli jaettu koulutus- ja testidataan satunnaisesti puoliksi kaikista simulaatiokerroista. Data oli muokattu niin, että neuroverkon sisääntulokerrokselle syötettiin kahden minuutin ajalta 10 sekunnin välein aiemmin mainittujen muuttujien mukaiset parametrit. Piilokerroksen kerroksien rakenne oli seuraava: ensimmäisellä eli LSTM –kerroksella oli 20 neuronua, kahdella seuraavalla Dense –kerroksella oli molemmissa 10 neuronua ja seuraavilla kahdella Dense –kerroksella oli 7 neuronua. Ulostulokerroksella oli kaksi neuronua, sillä LSTM –neuroverkko koulutettiin ennustamaan samanaikaisesti sekä yhden että kahden minuutin päähän mittaushetkestä tulevaisuuteen hiilidioksidiarvoja. Piilo- ja ulostulokerroksen rakenne on kuvattu KUVIO:ssa 144.

Layer (type)	Output Shape	Param #
lstm_71 (LSTM)	(None, 20)	2080
dense_263 (Dense)	(None, 10)	210
dense_264 (Dense)	(None, 10)	110
dense_265 (Dense)	(None, 7)	77
dense_266 (Dense)	(None, 7)	56
dense_267 (Dense)	(None, 2)	16

KUVIO 144. LSTM –neuroverkon piilokerrokset

LSTM –neuroverkkoja koulutettiin 31 kappaletta. Näiden keskiarvoinen virhe oli noin 263 grammaa ja pienin virhe oli noin 0,6 grammaa. KUVIO:ssa 145. on esitetty parhaimman koulutetun LSTM –neuroverkon tulokset testausdatalla, jossa testausotokset alkoivat satunnaisesti simulaatiokertojen eri vaiheissa. Tässä yhden minuutin ennuste on esitetty

punaisella, kahden minuutin ennuste on esitetty vihreällä ja todelliset arvot ovat esitettyinä sinisellä sekä keltaisella. Yhden minuutin ennusteen ja simuloitun todellisen arvon välillä on virhe ollut suurempaa kuin kahden minuutin ennusteiden ja simuloitujen todellisten arvojen välillä. Ensimmäisen minuutin ennusteiden pienin arvo on ollut 510 grammaa ja suurin noin 555 grammaa. Todellisella datalla nämä puolestaan ovat olleet noin 508 grammaa ja 556 grammaa. Toisen minuutin ennusteiden pienin arvo on ollut 510 grammaa ja suurin noin 579 grammaa. Todellisella datalla nämä puolestaan ovat olleet noin 532 grammaa ja 578 grammaa.



KUVIO 145. Parhaimman NN-verkon ennusteet

6.5.6 Tulokset ja päätelmät

Kampusareenan huoneiden 515. (Tapahtuma-areena) ja 534. (Giga) mittaukset ovat kärsineet toistuvista katkoksista, mutta ollessaan päällä mittaukset ovat pääsääntöisesti olleet jatkuvia. Huoneesta 515 oli suoritettu mittauksia, jotka keskittyivät huoneen fyysisten ominaisuuksien tarkasteluun, kun huoneesta 534 oli mitattu vain kävijämääriä. Näistä selvisi, että huoneen keskiarvoinen lämpötila on koko mittausjakson ajan 1.2.2018 – 15.3.2018 ollut noin 22 C° ja minimiarvon sekä maksimiarvon välinen ero on ollut likimain 3,5 C°. Huoneen ilmankosteus on vaihdellut välillä 30 - 15 prosenttiyksikköä ja ilmankosteus on ollut öisin matalampi kuin päivisin. Sisäilmanpaine on ollut ulkoilmanpainetta suurempi. Molemmista huoneista oli

mitattu ihmisvirtauma aikalavälillä 12.3. - 21.5.2018. Huonetta 515. oli käytetty useammin kuin huonetta 534, mutta 18.2. huoneessa 534 on käynyt enemmän käyttäjiä kuin huoneessa 515.

Huoneen 515. suureiden datasta oli tehty data-analyysi, jossa huoneen arvoja oli pyritty klusteroimaan ja löytämään voimakkaimpia tekijöitä. Valitettavasti klusterointi ei tuottanut riittävän laadukasta tulosta, joka kuvaisi huoneen käytöstä selkeästi. Pääkomponenttianalyysi paljasti, että asunnon suureista vaikuttavin tekijä olisivat paine ja lämpötila. Huoneen dataa verrattiin myös Härmälän säädataan, mikä puolestaan osoitti, että huoneessa vallitsee ylipaine ja huoneen lämpötila on käyttäytynyt järkevästi suhteessa ulkoilman lämpötilan muutoksiin. Huoneen kosteus on ollut koko mittausjakson ajan hieman liian alhainen, jotta se olisi tuntunut miellyttävältä kaikkien huoneen käyttäjien osalta. Matalalla ilmankosteudella voi olla negatiivisia terveysvaikutuksia.

Huoneen 515. käytöstä tutkittiin ja pyrittiin ennustamaan ulkoilman suureiden avulla, mikä osoittautui mahdolliseksi erilaisin regressiomenetelmin. Lineaarilla regressiomenetelmällä kosteuden ennuste oli yli 80 prosenttisesti oikein, kun virheraja oli korkeimmillaan 1,4 %. Paineen arvot olivat 83 prosenttisesti oikein, kun virheraja oli 1 Pa, ja lämpötilan arvot olivat 80 prosenttisesti oikein, kun virheraja oli 0.4 C°. Eryteisesti paineen ennusteet ovat onnistuneet lähes kaikilla menetelmillä, mutta tämä on johtunut paineen arvojen skaalasta.

Hiilidioksidiarvojen puuttuessa luotiin simulointimalli, jonka innoittamana ideoitiin neljä eri neuroverkkomallia. Simuloidun datan perusteella koulutettiin LSTM-neuroverkko, jonka pohjaksi oli valittu vaihtoehto neljä. Neuroverkko sisälsi yhden LSTM-kerroksen, neljä piilokerrosta sekä ulostulokerroksen. Neuroverkko otti syötteen käyttäjien lukumäärän, ajallisen keston mittauksen alusta, huoneen tilavuuden, edeltävän arvion hiilidioksidin kertyneeksi määräksi ja edeltävän 10 sekunnin käyttäjämäärän. Käyttäen edeltävän kahden minuutin dataa verkolla ennustettiin seuraavan minuutin ja seuraavan kahden minuutin hiilidioksidiarvoja. Verkkoja koulutettiin yli 30 kappaletta ja näiden keskiarvoinen virhe jäi noin 260 grammaan, mutta parhaan neuroverkon virhe jäi 0,6 grammaan. LSTM-neuroverkon tulokset kertovat siitä, että mallia voisi vielä parantaa kasvattamalla sekä mallin piilokerrosten ja kerrosten neuronien lukumääriä. Lisäksi dataan olisi hyvä lisätä melua, jotta potentiaaliselta ylikouluttumiselta välttyttäisiin. Mallin tuloksia ei ole mahdollista verrata asuntojen todellisiin hiilidioksidiarvoihin, sillä näitä ei ollut mitattu huoneista 515. ja 534.

Valitettavasti mittausasetelmat eivät ole olleet riittävän kattavat, jotta datasta olisi ollut mahdollista saada mielekkäitä tuloksia. Datan hyödynnettävyys on kärsinyt rakennuksen kunnan analysoinnin näkökulmasta, sillä data ei tällaisenaan pysty vastaamaan mielenkiintoisiin kysymyksiin kuten hiilidioksidirajojen ylittymisiin huoneen käyttäjien määrän kasvun toimesta. Toisaalta fyysisten suureiden tarkastelu ei paljastanut suuria puutoksia huoneen 515 toiminnassa, joten huone ainakin näiden osalta on ollut kunnossa. Koska huoneesta 534 ei ollut vastaavia mittauksia, ei sen kunnosta voi sanoa mitään.

Parannusehdotuksena suosittelemme hiilidioksidiantureiden asentamista huoneisiin mahdollisuuksien mukaan ja jonkinlaisen käyttäjätyytyväisyyskyselyn luomista, mikäli hiilidioksidirajojen käytös huoneissa kiinnostaa. Lisätutkimusta vaatisi myös hiilidioksidin käytöksen mallintaminen, sillä hiilidioksidin syntymiseen voi vaikuttaa useat tekijät ihmisten hengityksen lisäksi.

7 Yhteenveto

Tämä raportti keskittyi tarkastelemaan tekoälyn hyödyntämistä rakennusten ennakoivassa kunnossapidossa. Raportti toteutettiin osana KIRA-digi –hanketta, jonka osana Jyväskylän yliopistolla oli kokeiluhanke: ”Tekoälypohjaiset ennustemenetelmät älykkäiden rakennusten ennakoivassa kunnossapidossa”. Kokeiluhankkeen tavoitteena oli selvittää datan pohjalta, voiko tekoälyllä paikallistaa tarkasti ja luotettavasti mahdollisten poikkeamien esiintymistä kiinteistöissä ja rakennuksissa, voiko datan pohjalta tekoälytekniikoilla luoda nopean, tarkan ja yleispätevän generisen mallin, jonka perusteella huoltaa kohteita, ja lisäksi miettiä useamman mallin alustaa.

Raportti jakaantui kuuteen lukuun, joista ensimmäinen oli KIRA-digi –hankkeeseen ja Jyväskylän yliopiston pilottihankkeeseen johdatteleva luku, toinen tekoälyn kehityskulkua ja menetelmiä tarkasteleva luku ja kolmas älykkäitä rakennuksia ja kaupunkeja sekä niihin liittyvää teknologiaa esittelevä luku. Neljännessä luvussa käsiteltiin älykkäiden rakennuksien ennakoivaa kunnossapitoa, niiden hyötyjä ja haittoja, kunnossapidon kustannuksia ja säästöjä, kunnossapidon prosessia ja esimerkkejä ennakoivan kunnossapidon ratkaisuksista. Viides luku keskittyi Lehto Asunnot Oy:n kiinteistöistä kerätyn IoT -datan analysointiin ja tuloksiin sekä Lehto Asunnot Oy:lle tehdystä tekoäly- ja teknologiakartoituksesta. Kuudennessa luvussa paneudutaan Suomen yliopistokiinteistöjen Kampusareenan datan analysointiin, visualisointiin, sääinformaation tarkasteluun, tekoälyä hyödyntävien ratkaisujen esittelemiseen CO₂-pitoisuuden mittaamista varten, käytöksen simulointiin ja neuroverkkoihin. Seitsemäs eli viimeinen luku toimii yhteenveto ja pohdintalukuna.

Rakennusten kunnonvalvonnasta ja monitoroinnista on tullut nykypäivänä yhä tärkeämpää. Korjausrakentamisen kustannusten noustessa tehokkaiden menetelmien kehittäminen ja soveltaminen ovat aiempaa oleellisempia toimenpiteitä. Rakenneterveystarkastelussa paneudutaan rakennuksen rakenteisiin ilmaantuneiden vikojen identifiointiin ja luokitteluun, jossa voidaan hyödyntää tilanteeseen soveltuvia sensoreita eli antureita. Erilaisia konstruktioita, kuten rakennuksia siltoja, patoja, tuuliturbiineita on tarpeen suojella erilaisia tekijöitä, kuten rakenteiden heikkenemistä, liiallista kuormitusta, ympäristöä ja lämpötilan muutoksia vastaan. Sensoreista kerätyn datan analysointi ja tekoälypohjaiset ratkaisut, kuten koulutetut neuroverkot, voivat parantaa muun muassa edellä mainittujen tekijöiden ennakoitavuutta, jolloin asioihin voidaan puuttua ajoissa. Ennakoitavuus voi tuoda myös kustannussäästöjä ja parantaa turvallisuutta.

Rakennusterveystarkastelu (SHM) ja ennakoiva kunnonvalvonta (PHM) eivät yksinään kuitenkaan riitä. Tarpeellista on kehittää yhtenäinen standardi tai vähintään joitakin laajimmin käytettyjä tuoteperheitä tukeva yhteneväinen käytäntö tai rajapinta. Tämän pohjalta voi kehittää kontekstittietoisien rakennekunnossapitojärjestelmän, joka kykenee itsenäiseen sensoridatan keräämiseen, valvontaan ja diagnosointiin. Järjestelmän ennakoivan

kunnonvalvonnan osajärjestelmä suorittaa varsinaisen ennustamisen ja jäljellä olevan hyödyllisen käyttöajan (RUL) laskennan.

Esineiden internetin (IoT) sensorijärjestelmät tuottavat valtavasti raakaa ja käsittelemätöntä dataa. Tämä tarkoittaa, että rakenneterveystarkastelujärjestelmien toiminnan takaamiseksi ja laajamittaisen käyttöönoton turvaamiseksi, dataa on tallennettava paikallisesti ja globaalisti. Paikallisesti sensoreilta tuleva data olisi kyettävä yksinkertaisuudessaan pakkaamaan jo sensoritasolla. Sensoreilta kerättävä data voidaan lähettää yksityisen tai julkisen pilvipalvelun tietovarastoon, jossa se voi toimia esimerkiksi koneoppimismallien raaka-aineena mahdollistaen rakenteisiin ilmaantuneiden vikojen ja poikkeamien tunnistamisen.

Yksityisen pilvipalvelun etuna on datan sijainnin täysi kontrollointi ja tietoturva, mikäli se on toteutettu oikein. Toisinaan vaatimukset organisaation sisältä tai sen ulkopuolelta edellyttävät oman konesalikapasiteetin käyttöä ja joissain tapauksissa palvelu voidaan toteuttaa palveluntuottajakumppanin konesalista tarjottujen resurssien puitteissa. Datan sijaitseminen Suomessa oli vielä muutamia vuosia aiemmin jopa vaatimus useissa organisaatioissa. Yksityisen pilvipalvelun käyttö voi tulla myös halvemmaksi, etenkin jos ohjelmointilogiikassa on virhe ja tietovarastoihin kohdistuu suuri määrä kutsuja. Tietokantaoperaatioiden, esimerkiksi kutsut tietovarastoihin, voivat aiheuttaa suuria kustannuksia julkisten pilvipalveluiden kyseessä ollessa. Tällöin on tärkeää monitoroida pilvipalvelujen käyttöä riittävän usein. Vaikka yksityisten pilvipalveluiden hyödyntäminen aiheuttaa laitteistokustannuksia, voivat ne joissain tapauksissa olla myös julkisten pilvipalveluiden tietovarastoinnin kustannuksia pienemmät, mikäli datan määrä on riittävän suuri.

Julkisen pilvipalvelun etuina voidaan pitää kustannusten säästöä, mikäli palvelu on mitoitettu oikein. Organisaatioiden ei tarvitse ostaa, asentaa, hallita ja ylläpitää palvelimia tai muuta laitteistoa, kuten se olisi tarpeen yksityisen pilvipalvelun tapauksessa. Organisaatiot voivat kehittää omia sovelluksiaan, mutta niiden toimintalogiikka sijaitsee julkisen pilven (kuten Google, Amazon tai Microsoft) resursseissa. Julkiset pilvipalvelut myös tarjoavat resursseja huomattavalle käyttäjämäärälle samanaikaisesti, jolloin julkisten pilvipalveluiden käytöstä tulee kustannustehokasta käyttäjille. Julkisten pilvipalveluiden tapauksessa organisaatiot (kuten yksityiset käyttäjät) maksavat vain resursseista, joita he todella käyttävät.

Julkiset pilvipalvelut nostavat kuitenkin tietoturva-asiat uuteen valoon ja potentiaaliset haavoittuvuudet tai hyökkäykset, jotka voivat hyödyntää virtuaalikone- (hypervisor) tai muita käyttäjien istuntoja ja mahdollistaa pääsyn mahdollisesti kriittiseen dataan. Toistaiseksi vakavilta hyökkäyksiltä on vältytty, mutta tietoturvallisuus on silti syytä ottaa huomioon teknologiaa valittaessa. Organisaatiot itse ovat kuitenkin viime kädessä vastuussa omien sovelluksiensa tietoturvasta, jolloin ne joutuvat panostamaan myös tietoturvatestaukseensa riittävin resurssein.

Yksityisen ja julkisen pilvipalvelun yhdistelmä, hybridipilviratkaisu, voisi olla varteen otettava ratkaisu teknologista ratkaisua harkittaessa. Hybridipilvi soveltuu myös tilanteisiin, joissa tietojärjestelmien vaatimustaso tietoturvan osalta on korkea. Hybridimallin avulla organisaatio saa maksimoitua julkisen pilvipalvelun tuomat hyödyt, mutta voi silti olla turvallisin mielin tietoturvakysymysten suhteen. Tärkein hybridipilven tarjoama hyöty on kuitenkin ketteryys, jolloin organisaatio voi hyödyntää julkisen pilven skaalautuvuutta dynaamisesti, mikäli on tarpeen hyödyntää suurempaa laskentakapasiteettia tai palvelua, jota pilvipalveluun on toteutettu. Tämän kaltaisia palveluita voivat olla esimerkiksi puheen-, kuvantunnistus tai luonnollisen kielen prosessointiin liittyvät palvelut. Organisaatio voi jättää kriittisempään dataan kohdistuvat laskentatehtävät yksityiseen pilveen tai omiin palvelimiinsa ja laskentavaatimusten noustessa toteuttaa osa laskennasta julkisessa pilvipalvelussa. Hybridipilviratkaisu tarjoaa pelkkää julkista tai yksityistä pilvipalveluratkaisua enemmän joustavuutta tulevaisuuden muuttuviin tarpeisiin, jolloin tarpeiden muuttuessa on mahdollista sovittaa datan hallinta sopivasti julkisen, yksityisen ja yrityksen omien teknologisten resurssien välillä.

Tekoälyä hyödyntävä ratkaisu, jossa tekoälyä käytetään esimerkiksi itseohjautuvan lämmitysjärjestelmän toteuttamiseen, voidaan periaatteessa teknisesti toteuttaa yksityiseen tai julkiseen pilvipalveluun, hybridipilvimallin avulla tai organisaation omia resursseja (palvelimet ja tietovarastot) hyödyntäen. Tämä tosin vaatisi sen, että myös data on tarkoitukseen soveltuvaa. Julkisessa pilvipalvelussa, kuten esimerkiksi Googlen pilvessä, on toteutettuna valmiina koneoppimisen malleja, kuten: lineaarinen regressio (numeeriset arvot), binäärinen logistinen regressio (luokkien ennustaminen) ja moniluokkainen (esimerkiksi matala, keskimääräinen tai korkea arvo) logistinen regressio luokittelua varten. Etuna valmiiden mallien hyödyntämisessä on, että koneoppimisen toteutuksiin ei tarvita ohjelmointikielten, kuten Python tai Java osaamista, vaan mallit voidaan opettaa ja niitä voidaan käsitellä perinteistä relaatiotietokannoista tuttua SQL-kieltä käyttäen. Googlen pilvipalvelu tukee koneoppimisen mallien muodostamista myös useista eri koneoppimisen viitekehysistä, kuten scikit-learn, XGBoost, Keras ja Tensorflow. Tensorflow on johtavia syväoppimisen viitekehysiksiä, jota hyödynnetään muun muassa Googlen eri tuotteissa, kuten Google Photos ja Google Cloud Speech. Googlen pilvipalvelu mahdollistaa automaattisen mallien arkkitehtuurisuunnittelun ja arvioinnin sekä skaalauksen.

Lehto Asunto Oy:n –data-analyysi paljasti, että asunnoista kerätään osa-aikaisesti ja vaihtelevasti dataa erilaisista muuttujista. Muuttujina tämän tutkimuksen aikana ovat toimineet asuntojen lämpötila, asuntojen suhteellinen ilmankosteus, asuntojen hiilidioksidiarvot, rakennuksen ulkopuolisen ilman lämpötila ja ulkoilmalle laskettu kolmen tunnin sään lämpötilan ennuste sekä neljä eri lämmitysveden mittausarvoa. Riippuen rakennuksesta otsikoiden nimet ovat vaihdelleet ja sisältäneet kirjoitusvirheitä. Dataa on joskus puuttunut ja toisinaan data on sisältänyt monistuneita arvoja.

Tekoälyn hyödyntäminen rakennuksen lämmityksen ohjausjärjestelmän toteuttamisessa on kuitenkin käytännössä haastavaa. Ohjausjärjestelmän rakentamista voisi tosin helpottaa suunnittelemalla se moduuliseksi, jossa toiminnallisuus muodostuu pienemmistä osakokonaisuuksista, sillä suurten datasettien ollessa kyseessä oleellinen informaatio ei välttämättä välity kaikkien muuttujien joukosta joko diskreetissä ajassa tai ei välttämättä koskaan. Moduulisuutta suosivan tekoälyn kehittäminen aluksi yhdelle rakennukselle ja kaikille rakennuksessa oleville asunnoille olisi toivottavaa. Neuroverkkojen kouluttaminen yhden asunnon ja rakennuksen luokittelussa ja muuttujien arvojen ennustuksessa on suhteellisen yksinkertaista. Ohjausjärjestelmän koulutus tosin on haastavaa ja sama pätee useiden rakennusten tapauksessa. Tekoälyratkaisun olisi hyvä sisältää luokitteleva, simuloiva, ennustava ja ohjaava osa ja edellä mainittu rakenne yhdistettynä versionhallintaan. Eräs tärkeimmistä edellytyksistä ohjaavan järjestelmän toiminnan kannalta on luokittelevan tekoälyn suunnittelu, kouluttaminen ja tulosten esittäminen.

Lehto Asunto Oy:n datan analysoinnin aikana selvisi, että saatua dataa hyödyntäen ei voida itseohjautuvan lämmitysjärjestelmän ohjausta vielä toteuttaa. Riotsin toteuttamasta ohjelmointirajapinnasta oli nähtävissä, että siihen oli toteutettu yksinkertainen ohjauskeino, jossa vaatimuksena oli vain asunnon tietojen lisäksi tavoitelämpötilan ja keston ennustuksen. Ainakin tällä hetkellä informaatio tavoitelämpötilasta, lämmityskeston pituudesta ja säädön alkamisesta puuttuu Lehto Asunto Oy:n datasetistä. Edellä mainittuja arvoja tulisi simuloida yhdessä rakennuksen, asuntojen ja sään muuttujien avulla yhdistäen todellisiin muutoksiin kerätyissä dataseiteissä ja muutoksien ajoittumissa. Laskennallisesti vaativaa geneettistä koodausta hyödyntäen voisi olla mahdollista löytää paras rajoitetussa ajassa laskettavissa oleva ratkaisu, joka käyttäisi syötteinään optimaalisimpia muuttujia. Esimerkiksi neuroverkko voi oppia minimoimaan monitavoiteongelmia, kuten todellisen ja ennustetun lämpötilan välisiä eroja samalla pyrkien vähentämään sähkö- ja lämpöenergian käyttöä. Tämänkaltaisen koodauksen etuihin lukeutuu se, että näin tehtynä tekoäly voi toimia paremmin kuin ihmisen tekemänä.

Suomen yliopistokiinteistön data-analyysiosuudessa analysoitiin Tampereen Kampusareenasta saatua dataa. Kampusareena ja sen tarjoama data on ollut VIRPA C- ja D – hankkeiden tutkimuksen kohteena. Jyväskylän yliopisto sai kesällä 2018 rajoitetun datasetin Kampusareenan Tapahtuma-areena ja Giga-huoneista Polku Innovation Virpa C –hankkeen yhteydessä kehittämän SYKin avoimen IoT-alustan ja Siemensin kanssa tehtyjen sopimusten ansiosta. Muuttujina tutkimuksessa olivat lämpötila Celsiusasteina, ilman kosteus prosentteina, ilman paine millibaareina ja melu desibeleinä. Kampusareenan sensoriverkon tietokantaan on lisäksi tallennettu liiketunnistetietoja.

SYK:in datan analyysissä ilmeni, että Tapahtuma-areena- (huone 515.) ja Giga-huoneiden (huone 534.) mittauksissa on ollut toistuvia katkoksia. Mittausanturien ollessa päällä ja toiminnassa, mittaukset ovat pääsääntöisesti olleet jatkuvia. Mittausdatan perusteella huonetta 515. oli käytetty enemmän kuin huonetta 534. Huoneesta 534. oli tosin mitattu vain

kävijämääriä ja huoneesta 534. myös huoneen fyysisiä ominaisuuksia. Ilmankosteus 515 ilmankosteus on ollut öisin päivittäistä kosteutta matalampi ja sisäilman paine ulkoilman painetta korkeampi. Huoneen kosteus on ollut mittausjakson ajan liian matalalla, jotta se olisi ollut kaikille käyttäjille miellyttävällä tasolla. Matalalla ilmankosteudella voi olla negatiivinen vaikutus terveydentilaan. Keskimääräinen lämpötila on ollut noin 22 °C ja lämpötilan minimi ja maksimiarvon erotus on ollut noin 3,5 °C.

Huoneesta 515. kerätylle mittausdatalle toteutettiin data-analyysi, jossa huoneiden arvoja pyrittiin klusteroimaan ja löytämään voimakkaimpia tekijöitä. Klusterointi ei kuitenkaan tuottanut riittäviä tuloksia, joiden perusteella huoneen käytöstä olisi voinut selkeästi kuvata. Pääkomponenttianalyysin mukaan asunnon suureista vaikuttavimmat tekijät olivat ilmanpaine ja lämpötila. Huoneen 515. käytöstä koetettiin ennustaa ulkoilman suureiden avulla, jossa erilaisten regressiomenetelmien hyödyntäminen oli tuloksellista. Lineaarisen regressiomenetelmän avulla ilmankosteuden ennuste oli yli 80 % oikein virherajan ollessa 1,4 %, paineen arvot olivat 83 % oikein virherajana 1 Pa ja lämpötila-arvot olivat 80 % oikein virherajana 0,4 °C.

Hiilidioksidiarvojen puuttuessa muodostettiin simulointimalli, jonka pohjalta ideoitiin neljä eri neuroverkkomallia. Simuloidun datan avulla koulutettiin LSTM-neuroverkko, jossa oli syöteinä käyttäjien lukumäärä, ajallinen kesto mittauksen alusta, huoneen tilavuus ja edeltävä arvio hiilidioksidin kertyneeksi määräksi sekä edeltävän 10 sekunnin käyttäjämäärän. Verkkoja koulutettiin 30 kpl ja keskiarvoiseksi virheeksi tuli 260 g, parhaan virheen ollessa 0,6 g. LSTM-neuroverkon mallia voisi parantaa kasvattamalla mallin piilokerrosten ja kerrosten neuronien lukumäärään sekä lisäämällä dataan melua, jotta ylikouluttautumiselta voitaisiin välttyä. Simulaatiomallin tuloksia ei voitu kuitenkaan verrata huoneiden 515 ja 534 tuloksiin, sillä niistä ei hiilidioksidipitoisuuksia oltu mitattu.

Datan pohjalta ei lisäksi vastata kysymyksiin, kuten hiilidioksidipitoisuusrajojen ylittymisiin huoneen käyttäjien määrän kasvaessa tai vähentyessä. Mittausdatan perusteella voidaan päätellä, että huone 515. olisi kunnossa, suuria poikkeamia ei löytynyt. Mittaustulosten puuttumisen johdosta huoneen 534. suhteen ei ole mahdollista ottaa kantaa huoneen kuntotilanteeseen. Hiilidioksidiantureiden asentaminen Kampusareenan huoneisiin ja käyttäjätyytyväisyyskyselyn hyödyntäminen nykyistä mittausasetelmaa täydentämään toisi informaatiota hiilidioksidirajoista ja ilmanlaadullisista asioista. Hiilidioksidipitoisuuden ei tulisi sisäilmassa ylittää 1500 ppm rajaa terveysuojalain mukaisesti. Korkeat CO₂-pitoisuudet aiheuttavat tunkkaisuuden tunnetta, väsymystä, päänsärkyä ja työtehon alenemista. Hiilidioksidimittaukset toisivat siten mukaan myös terveydellisen näkökulman, joka tulisi ottaa huomioon asianmukaisella tavalla. Lisätutkimusta vaatisi myös hiilidioksidin käytöksen mallintaminen, koska hiilidioksidi voi muodostua usein eri tavoin ihmisten hengityksen lisäksi.

Lähteet

Abate, A., Budde, C., E., Cauchi, N., Hoque, K., A. & Stoelinga, M. 2018. Assessment of Maintenance Policies for Smart Buildings Application of Formal Methods to Fault Maintenance Trees. *Proceedings of the European Conference of the PHM Society*, 4(1), 1 - 16.

Abdeljaber, O., Avci, O., Kiranyaz, S., Gabbouj, M. & Inman, D. 2017. Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks. *Journal of Sound and Vibration*, 388, 154 - 170.

Ahmed, E., Yaqoob, I., Gani, A., Imran, M., Guizani, M. 2016. Internet-of-things-based smart environments: state of the art, taxonomy, and open research challenges. *IEEE Wireless Communications*, 23(5), 10 - 16.

Anastasi, G., Lo Re, G. & Ortolani, M. 2009. WSNs for Structural Health Monitoring of Historical Buildings. *Human System Interactions, 2nd Conference*, 574 - 579.

Atzori, L., Iera, A. & Morabito, G. 2010. The Internet of Things: A survey. *Computer networks*, 54(15), 2786 - 2805.

Bao, Y., Tang, Z., Li, H. & Zhang, Y. 2018. Computer vision and deep learning-based data anomaly detection method for structural health monitoring. *Structural Health Monitoring*, 1 - 21.

Bell, J. 2014. Machine Learning: Hands-On for Developers and Technical Professionals. 1. painos. Indiana: John Wiley and Son's inc.

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*, 64 - 67.

Cha, Y.-J., Choi, W. & Büyüköztürk, O. 2017. Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks. *Computer-Aided Civil and Infrastructure Engineering*, 32(5), 361 - 378.

Chamoso, P., Gonzales-Briones, A., Rodriguez, S. & Corchado, J., M. 2018. Tendencies of Technologies and Platforms in Smart Cities: A State-of-the-Art Review. *Wireless Communications and Mobile Computing*, 1 - 17.

Coleman, C., Damodaran, S., Chandramouli, M. & Deuel, E. 2017. Making Maintenance Smarter: Predictive Maintenance and the Digital Supply Network. Deloitte University Press.

Choi, Y., Yeum, C., M., Dyke, S., J., Jahanshahi, M., Pena, F. & Park, G., W. 2018. Machine-Aided Rapid Visual Evaluation of Building Façades. *9th European Workshop on Structural Health Monitoring*, 1 - 9.

Durham, R. 2017. IoT Predictive Maintenance: Building Predictive Vibration Analysis Models. IBM Watson IoT. Diaesitys. *IEEE International Conference on Prognostics and Health Management*.

Goodfellow, I., Bengio, Y. & Courville, A. 2016. Deep Learning. England: MIT Press.

Helmy, H., M., Elfouly, A., K. & Salem, H., M. 2012. Numerical Simulation of Demolition of Perna Seca Hospital Using the Applied Element Method. *Structures Congress*, 1, 279 - 295.

Hemmerdinger, R. 2016. Predictive Maintenance Strategy for Building Operations: A Better Approach. Schneider Electric Whitepaper.

Hester, D., Brownjohn, J., Bocian, M., Xu, Y. & Quattrone, A. 2018. Using inertial measurement units originally developed for biomechanics for modal testing of civil engineering structures. *Mechanical Systems and Signal Processing*, 104, 776 - 798.

Javed, K., Gouriveau, R., Zerhouni, N. & Nectoux, P. 2015. Enabling Health Monitoring Approach Based on Vibration Data for Accurate Prognostics. *IEEE transactions on industrial electronics*, 62(1), 647 - 656.

Jiang., J-R. 2018. An Improved cyber-physical systems architecture for Industry 4.0 smart factories. *Advances in Mechanical Engineering*, 10(6), 1-5.

Kang, F., Liu, J., Li, J. & Li, S. 2017. Concrete dam deformation prediction model for health monitoring based on extreme learning machine. *Structural Control Health Monitoring*. John Wiley & Sons, Ltd.

Kozharinov A.S. 2017. Первоочередные направления и задачи развития интеллектуальной системы прогнозирования состояний зданий и сооружений (Priority directions and tasks of the development of an intelligent system for forecasting the conditions of buildings and structures). Новая наука: От идеи к результату. National Research Technological University "MISIS", 153 - 157.

Kumar, R., Aggarwal, RK, Sharma, J., D. & Pathania S. 2013. Predicting Energy Requirement for Cooling the Building Using Artificial Neural Network. *Journal of Environmental Engineering and Technology*, 2(1), 113 - 121.

Kumar, A., Singh, A., Kumar, A., Singh, M., K., Mahanta, P. & Mukhopadhyay, S., C. 2018. Sensing Technologies for Monitoring Intelligent Buildings: A Review. *IEEE Sensors Journal*, 18(12), 4847 - 4860.

Legatiuk, D. & Smarsly, K. 2018. An abstract approach towards modeling intelligent structural systems. *9th European Workshop on Structural Health Monitoring*, 1 - 11.

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, 553 - 558. Berlin: Springer, Heidelberg.

Mattar, R. A., Kalai, R. 2018. Development of a Wall-Sticking Drone for Non-Destructive Ultrasonic and Corrosion Testing. *Drones*, 2(1), 1 - 11.

Mita, A., Sato, H. & Kameda, H. 2010. Platform for structural health monitoring of buildings utilizing smart sensors and advanced diagnosis tools. *Structural control and health monitoring*, 17, 795 - 807.

Mohanty, S., P., Choppali, U. & Kougianos, E. 2016. Everything you wanted to know about smart cities: The Internet of things is the backbone. *IEEE Consumer Electronics Magazine*, 5 (3), 60 - 70.

Mustonen, V., Koponen, J. & Spilling, K. 2014. Älykäs kaupunki – Smart City – Katsaus Fiksuihin Palveluihin ja Mahdollisuuksiin. Liikenne- ja viestintäministeriön julkaisu 12/2014.

Napolitano, R., Blyth, A. & Glisic, B. 2018. Virtual Environments for Visualizing Structural Health Monitoring Sensor Networks, Data, and Metadata. *Sensors*. 18(1), 1 - 14.

Ozer, E., Feng, M., Q. & Feng, D. 2015. Citizen Sensors for SHM: Towards a Crowdsourcing Platform. *Sensors*. 15(6), 14591 - 14614.

Parviainen, E., Riihimäki, J. Lendasse, A. 2010. Interpreting Extreme Learning Machine as an Approximation to an Infinite Neural Network. *International Conference on Knowledge Discovery and Information Retrieval*, 1 - 8.

Petru, M., Novák, O., Herák, D. & Simanjuntak, S. 2015. Finite Element method model of the mechanical behavior of *Jatropha curcas* L. seed under compression loading. *Agronomy Research* 13(4), 939 - 947.

Putra, C., A., Rahmat, A., Hardirianto, S & Purnomo, H., M. 2015. Character Recognition of Vehicle License Plate Using Extreme Learning Machine. *The 3rd Bali International Seminar on Science and Technology (BISSTECH)*, B5.8-1 - B5.8-4.

Schnackenburg, E. C., & Leife, K. 2017. Maskininlärning i fastighetsbranschen: Prediktion av felanmälningar gällande inomhusklimat baserat på sensordata. *Digitala Vetenskapliga Arkivet*. Sweden: Uppsala University.

Shotton, J., Sharp, T., & Kohli, P. 2013. Decision Jungles: Compact and Rich Models for Classification.

Qidwai, U., Ijaz, A. & Akbar, A. 2017. Robotic probe positioning system for structural health monitoring. Control System. *Computing and Engineering (ICCSCE), 2017 7th IEEE International Conference*, 299 - 304.

Qi, Q., Taaa, F., Zuoa, Y., Zhao, D. 2018. *Digital Twin Service towards Smart Manufacturing. 51st CIRP Conference on Manufacturing Systems*, 237 - 242.

Pedregosa, F., Varoquaux, G., Gramfort, A. Michel, V. Thirion, B. & Grisel, O. 2011. Scikit-Learn: Machine Learning in Python. *Journal of Machine Learning Research (12)*, 2825 - 2830.

Rolfes, R., Zerbst, S., Haake, G., Reetz, J. & Lynch, J. 2007. Integral SHM-System for Offshore Wind Turbines Using Smart Wireless Sensors. *Proceedings of the 6th International Workshop on Structural Health Monitoring*, 1 - 8.

Sbarufatti, C., Locatelli, A. & Giglio, M. 2018. Surrogate modelling for observation likelihood calculation in a particle filter framework for automated diagnosis and prognosis. *9th European Workshop on Structural Health Monitoring*. 1 - 12.

Sharp, M., Ak, R. & Hedberg Jr., T. 2018. A survey of the advancing use and development of machine learning in smart manufacturing. *Elsevier in Journal of Manufacturing Systems on*, 1 -31.

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. *FPGA '17 Proceedings of the 2017 ACM/SIGDA International Symposium on Field-Programmable Gate Arrays*, 15 - 24.

Wang, X. & Niederleithinger, E. 2018. Coda Wave Interferometry used to detect loads and cracks in a concrete structure under field conditions. *9th European Workshop on Structural Health Monitoring*, 1 - 8.

Zhang, J., Xiao, W., Zhang, S. & Huang, S. 2017. Device-Free Localization via an Extreme Learning Machine with Parameterized Geometrical Feature Extraction. *Hazards in Motion: Development of Mobile Geofences for Use in Logging Safety. Sensors 17(4)*, 1 - 15.

Internet-lähteet

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

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

BigQuery. 2019. Introduction to BigQuery ML. BigQueryn internetsivusto. Saatavilla: 21.3.2019 <https://cloud.google.com/bigquery/docs/bigqueryml-intro>

Brownlee, J. 2016. What is Deep Learning? Machine Learning Masteryn internetsivusto. Saatavilla: 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? Geoawesomenessin internetsivusto. Saatavilla: 31.5.2017 <http://geoawesomeness.com/whats-difference-artificial-intelligence-machine-learning-deep-learning>

Chandradevan, R. 2017. AutoEncoders are Essential in Deep Neural Nets. Towards Data Sciencen internetsivusto. Saatavilla: 15.3.2019 <https://towardsdatascience.com/autoencoders-are-essential-in-deep-neural-nets-f0365b2d1d7c>

Clarke, P. 2015. The Internet of Things for Defence. The Wind River Inc:n internetsivusto. Saatavilla: 12.6.2017 <https://www.wired.com/insights/2015/03/internet-things-smart-machines-collide>

Cloud IoT Core. A Fully Managed Service to Easily and Securely Connect, Manage, and Ingest Data from Globally Dispersed Devices. Google cloudin internetsivusto. Saatavilla: 21.3.2019 <https://cloud.google.com/iot-core>

Cloud Machine Learning Engine. Build Superior Models and Deploye Them into Production. Google cloudin internetsivusto. Saatavilla: 21.3.2019 <https://cloud.google.com/ml-engine>

Cloud Pub/Sub. Ingest Event Streams from Anywhere, at Any Scale, for Simple, Reliable, Real-Time Stream Analytics. Google cloudin internetsivusto. Saatavilla: 21.3.2019 <https://cloud.google.com/pubsub>

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

Costello, J. 2015. Unlocking the IoT in Commercial Buildings with Smart Sensor Technology. Construction Executiven internetsivusto. Saatavilla: 30.10.2017

<http://enewsletters.constructionexec.com/techtrends/2015/09/unlocking-the-iot-in-commercial-buildings-with-smart-sensor-technology>

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

Eemaint. 2017. What is Predictive Maintenance (PdM)? Accelix Communityn internetsivusto. Saatavilla: 10.11.2017 <https://www.emaint.com/what-is-predictive-maintenance>

Ericsson. 2017. Future technologies for intelligent society. Ericssonin internetsivusto. Saatavilla: 28.7.2017 <https://www.ericsson.com/networked-society/trends-and-insights/consumerlab/consumer-insights/reports/wearable-technology-and-the-internet-of-things#wearablefuture>

Foxworth, T. 2017. Using IoT and Machine Learning for Industrial Predictive Maintenance. Losant IoT:n internetsivusto. Saatavilla: 9.11.2017 <https://www.losant.com/blog/using-iot-and-machine-learning-for-industrial-predictive-maintenance>

Gartner. 2017. Internet of Things. Gartner Inc:in internetsivusto. Saatavilla: 12.6.2017 <http://www.gartner.com/it-glossary/internet-of-things>

Granlund. 2018. Kiinteistöala parempien käyttäjäkokemusten jäljillä. Granlundin internetsivusto. Saatavilla: 2.5.2018 <http://www.granlund.fi/ajankohtaista/kiinteistoala-parempien-kayttajakokemusten-jaljilla>

Harvard Business Review. 2016. Manufacturer's Most Important Tool. Harvard Businessin internetsivusto. Saatavilla: 1.8.2017 <https://hbr.org/sponsored/2016/12/why-iot-analytics-are-a-manufacturers-most-important-tool>

Sigma IT Consulting. Predictive Maintenance. Sigma IT Consultingin internetsivusto. Saatavilla: 9.11.2017 <http://iot.sigma.se/en/our-solutions/2790-2>

Hubens, N. 2018. Deep Inside: Autoencoders. Towards Data Sciencen internetsivusto. Saatavilla: 15.3.2019 <https://towardsdatascience.com/deep-inside-autoencoders-7e41f319999f>

I-Scoop. Internet of Things: The Complete IoT Guide - Benefits, Risks, Examples, Trends. I-Scoopin internetsivusto. Saatavilla: 12.6.2017 <https://www.i-scoop.eu/internet-of-things-guide>

Janakiram, M. 2018. Google Forays into Edge Computing with Cloud IoT Edge and TPU. Forbesin internetsivusto. Saatavilla: 21.3.2019

<https://www.forbes.com/sites/janakirammsv/2018/07/30/google-forays-into-edge-computing-through-cloud-iot-edge-and-tpu/#4b6d459c6005>

Kamoun, N. 2016. Smart Cities, Innovative Applications. IoT Levier de Croissance Enocomique SESAME Workshop. Dia-esitys. Saatavilla: 9.11.2017

<https://www.slideshare.net/loTTunisia/farouk-kamoun-smart-cities-innovative-applications-iot-tunisia-2016>

Kannan, P. 2017. Artificial Intelligence – Applications in Healthcare. Asian Hospital & Healthcare Managementin internetsivusto. Saatavilla: 30.5.2017

<https://www.asianhnm.com/technology-equipment/artificial-intelligence>

Kemiläinen, M. 2015. Kampusareena - Uutta Virtaa Monilaisista Kohtaamisista. Tampereen korkeakouluyhteisön internetsivusto. Saatavilla: 30.4.2018

<http://www.tut.fi/fi/kampusareena/index.htm>

Lorica, B. 2015. How Intelligent Data Platforms Are Powering Smart Cities. Smart Cities and Smart Nations Run on Data. O'Reilly Media Inc:n internetsivusto. Saatavilla: 10.3.2019

<https://www.oreilly.com/ideas/how-intelligent-data-platforms-are-powering-smart-cities>

Meola, A. 2016. Wearable Technology and IOT Wearable Devices. Business insiderin internetsivusto. Saatavilla: 28.7.2017

<http://www.businessinsider.com/wearable-technology-iot-devices-2016-8?r=US&IR=T&IR=T>

Mirasys. 2017. Virpa C –kehityshankkeessa Tieto Integroituu Uusiksi Palveluiksi. Mirasys Ltd:n internetsivusto. Saatavilla: 30.4.2018

<https://mirasys.com/fi/virpa-c-kehityshankkeessa-tieto-integroituu-uusiksi-palveluiksi>

Morgan, J. 2014. A Simple Explanation of “The Internet of Things”. Forbesin internetsivusto.

Saatavilla: 12.6.2017 <https://www.forbes.com/sites/jacobmorgan/2014/05/13/simple-explanation-internet-things-that-anyone-can-understand/#73eb78a41d09>

Park, C. 2016. The Internet of Things: AV/IT Benefits for the University. Tech Decisions. IT

Infrastruktuurin internetsivusto. Saatavilla: 1.8.2017 <https://techdecisions.co/it-infrastructure/internet-things-avit-benefits-university>

Parloff, R. 2016. Why Deep Learning is suddenly Changing Your Life. Saatavilla: Fortunein internetsivusto. 16.5.2017

<http://fortune.com/ai-artificial-intelligence-deep-machine-learning>

Pettey, C. 2016. Transform Your Business With IoT Analytics. Gartner Inc:n internetsivusto. Saatavilla: 1.8.2017 <http://www.gartner.com/smarterwithgartner/transform-your-business-with-iot-analytics>

Ramachandran, B. 2019. BarcelonaSmartCity:TheHeavenonEarth
BarcelonaSmartCity:TheHeavenonEarth (InternetofThings:TechnologicalGod). ZTE communications:n internetsivusto. Saatavilla: 1.8.2017
https://www.researchgate.net/profile/Somayya_Madagam3/publication/292906873_Barcelona_Smart_City_The_Heaven_on_Earth_Internet_of_Things_Technological_God/links/56b1d9f008ae5ec4ed4a8815/Barcelona-Smart-City-The-Heaven-on-Earth-Internet-of-Things-Technological-God.pdf

Roth, I. 2016. Smart Sensors at the Forefront of Building Intelligence. Smart Buildings Magazine internetsivusto. Saatavilla: 30.10.2017
<http://www.smartbuildingsmagazine.com/features/smart-sensors-at-the-forefront-of-building-intelligence>

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

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

Senseware. The Role of Predictive Maintenance. Senseware, Inc:n internetsivusto. Saatavilla: 10.11.2017 <https://www.senseware.co/2017/05/08/role-predictive-maintenance>

Sigh, V. 2017. Convolutional Neural Networks for Image Classification. Bootstrapin internetsivusto. Saatavilla: 17.3.2019
<https://www.compleategate.com/2017022864/blog/deep-machine-learning-images-lexnet-alexnet-cnn/all-pages>

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

SYK. Perinteisestä Kiinteistöliiketoiminnasta alusta- ja palvelubisnekseen. Suomen Yliopistokiinteistöt Oy:n internetsivusto. Saatavilla: 9.5.2018 <http://www.sykoy.fi>

SYK. 2018. Suomen Yliopistokiinteistöt Oy Panostaa Kampusten Älykkyyteen ja Käyttäjien Hyvinvointiin. Suomen Yliopistokiinteistöt Oy:n internetsivusto. Saatavilla: 2.5.2018
<https://sykoy.fi/suomen-yliopistokiinteistot-oy-panostaa-kampusten-alykkyyteen-ja-kayttajien-hyvinvointiin>

Rantala, J. 2018. 6 + 1 tilannetta, jossa Serverless Pesee Perinteisen Palvelininfrastruktuuriin. Siilin internetsivusto. Saatavilla: 21.3.2019 <https://www.siili.com/fi/tarinat/6-1-tilannetta-jossa-serverless-pesee-perinteisen-palvelininfrastruktuuriin>

Tjoa, S. Introduction to Deep Learning. Dia-esitys. Saatavilla: 16.5.2017
https://ccrma.stanford.edu/workshops/mir2013/CCRMA_MIR2013_DBN.pdf

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

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

Vepsäläinen, T. 2016. Repair Construction is Predicted Using Data – of Which There's Plenty, But More Is Needed. Deleten internetsivusto. Saatavilla: 10.11.2017
<https://www.delete.fi/en/2017/02/07/repair-construction-is-predicted-using-data-of-which-theres-plenty-but-more-is-needed>

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

Zhou, W. 2017. My Big Data World. Google Cloud SQL vs Cloud DataStore vs BigTable vs BigQuery vs Spanner. My Big Data Worldin internetsivusto. Saatavilla: 21.3.2019
<https://weidongzhou.wordpress.com/2017/06/10/google-cloud-sql-vs-cloud-datastore-vs-bigtable-vs-bigquery-vs-spanner>

Informaatioteknologian tiedekunnan julkaisuja
No. 79/2019

ISBN 978-951-39-7730-6 (verkkoj.)
ISSN 2323-5004