

Ennustavan vikadiagnostiikan ja telemetrian kehitys ja sen hyödyntäminen

Jukka Pesonen

OPINNÄYTETYÖ
Syyskuu 2018

Tietojenkäsittely

TIIVISTELMÄ

Tampereen ammattikorkeakoulu
Tietojenkäsittely

PESONEN, JUKKA:

Ennustavan vikadiagnostiikan ja telemetrian kehitys ja sen hyödyntäminen

Opinnäytetyö 42 sivua
Syyskuu 2018

Opinnäytetyössä tutkittiin asiakasyritykselle koneoppimiseen perustuvaa ennustavan vikadiagnostiikan kehitystä. Rinnalla toteutettiin sekä reaaliaikaisen, että pilveen tallennetun telemetriatiedon parempaa analysointia. Lisäksi työn piti antaa yritykselle parannusehdotuksia nykyisten etäkunnonvalvontasovellusten parantamiseksi. Suurimman hyödyn saamiseksi ennustavaa vikadiagnostiikkaa sekä etäkunnonvalvontaa tutkittiin molempia samanaikaisesti.

Työssä keskityttiin koneoppimiseen liittyvien teknologioiden tarkasteluun sekä sen eri sidosryhmille tuomien hyötyjen tunnistamiseen. Lisäksi työssä mietittiin miten näitä saisi yhdistettyä nykyisiin sovelluksiin.

Case-tyyppisenä toteutetussa työssä, tutkittiin muutamien logistiikkakeskusten pilveen tallentamien telemetriatietojen analysointia ja miten näillä tiedoilla voitaisiin toteuttaa ennustavaa vikadiagnostiikkaa sekä löytää tapoja, joilla erottaa lastinkäsittelylaitteiden lähettämistä tiedoista poikkeamia. Koneoppimista testattiin avoimen lähdekoodin Scikit-learn kirjastolla. Työn tekeminen sisälsi paljon kokeilevaa ohjelmointia sekä luovaa määrittely- ja selvitystyötä telemetriatietojen analysoimiseksi ja parantamiseksi sekä koneoppimisen tuomien hyötyjen pohdintaan.

Koneoppimisesta saadut kokemukset ja tulokset näyttivät, että koneoppimisen algoritmeilla voidaan ennakoida muutoksia datassa sekä löytää poikkeavuuksia suurista datamassoista. Kehitystyötä tulee jatkaa, jotta ennustettavuutta saadaan parannettua ja integroitua nykyisiin sovelluksiin. Koneoppiminen tarjoaa teolliseen internetiin perustuvia liiketoimintamahdollisuuksia sovelluksien parantamisessa.

Telemetriatietojen analysoinnissa saadut tulokset olivat rohkaisevia ja niiden avulla olisi mahdollista saada paljon uusia tilastotietoja laitteiden suorituskyvystä. Kehitystyötä voitaisiin jatkaa saavutetuista lähtökohdista, vaikka toteutusta voisi miettiä jollain muulla ohjelmointikielellä kuin Pythonilla.

Asiasanat: ennustava vikadiagnostiikka, teollinen internet, koneoppiminen, etäkunnonvalvonta, esineiden internet

ABSTRACT

Tampereen ammattikorkeakoulu
Tampere University of Applied Sciences
Degree Programmer in Business Information Systems

PESONEN, JUKKA:
Developing Predictive Fault Diagnostics and Telemetry while Studying their Benefits

Business Bachelor's thesis 42 pages
September 2018

The purpose of the thesis was to study usefulness of machine learning based predictive fault diagnostic system for both real time and for data stored in a cloud. Also, this thesis was supposed to give improvement ideas for the current remote condition monitoring system. In order to reach the best possible outcome both predictive fault diagnostics and remote condition monitoring systems were studied and analyzed together.

The work focused on reviewing different machine learning technologies and identifying their benefits for different stakeholders. How to integrate these new technologies to the current applications was also studied.

Research was done as a case study where cloud base telemetry data from a few logistic parks was studied as how to implement machine learning and how to find critical outliers from this data. Predictability was tested using Scikit-learn Python libraries. The work included plenty of prototype programming and creative thinking on both analyzing the data and on when considering its benefits.

The experiences gained on machine learning showed that by using smart algorithms it is possible to predict values and to find outliers from big data. Further studies are required to improve algorithms and to integrate them to current applications. Machine learning does offer new service business opportunities as applications improve.

As a result of this work, the customer company has improved its knowledge of opportunities offered by machine learning tools and how to start to utilize them on current telemetry data on the cloud. Study has also aroused interest on development of how to use machine learning on debugging scenarios.

Key words: remote monitoring, predictive fault diagnostics, industrial internet, machine learning, internet of things

SISÄLLYS

1	JOHDANTO	7
1.1	Taustatietoa	7
1.1.1	Cargotec-konserni	8
1.1.2	Markkinatieto	9
1.1.3	Liikevaihto	9
1.2	Opinnäytetyön tavoite	10
1.3	Työmenetelmä	10
1.4	Rajaukset	10
1.5	Opinnäytetyön rakenne	11
2	Etäkunnonvalvonnan nykytila	12
2.1	Nykyinen käyttöliittymä.....	12
2.2	Alarm Tool.....	14
2.3	Telemetry ja vikadiagnostiikka	14
2.4	Nykyisen diagnostiikan haasteet	15
3	UUDET TEKNOLOGIAT	16
3.1	IoT ja teollinen internet.....	16
3.2	Koneoppiminen	18
3.3	Algoritmit	20
3.3.1	Ohjattu oppiminen	20
3.3.2	Ohjaamaton oppiminen	22
3.3.3	Puoli-ohjattu oppiminen	22
3.3.4	Vahvistusoppiminen	23
3.3.5	Päätöspuut	23
3.3.6	Bayes-verkko.....	25
4	ETÄKUNNONVALVONNAN JA TELEMETRIATIETOJEN PARANTAMINEN	27
4.1	Ehdotuksia uusista ominaisuuksista etäkunnonvalvontaan.....	27
4.1.1	Uusien tietojen lisääminen etäkunnonvalvontaan.....	27
4.1.2	Lastinkäsittelylaitteen tilastojen laskeminen	27
4.1.3	Lastinkäsittelylaitteiden etäohjauspyyntöjen havainnollistamisen parantaminen.....	31
4.2	Koneoppimisen hyödyntäminen vikadiagnostiikassa	35
4.2.1	Esitys koneoppimisen toiminnasta.....	35
4.2.2	Työvaiheet.....	36
5	LIIKETOIMINNAN KEHITYS JA HYÖDYT	38
5.1	IoT:n, teollisen internetin sekä koneoppimisen mahdollistamat uudet palvelut.....	38

5.1.1 Hyödyt sidosryhmille.....	38
5.1.2 Hyödyt tuotekehitykselle.....	39
6 POHDINTA	40
LÄHTEET.....	42

ERITYISSANASTO tai LYHENTEET JA TERMIT (valitse jompikumpi)

IoT	Internet of Things
ML	Machine learning
Big data	Valtavien ja jatkuvasti kasvavien tietomassojen kerääminen, säilyttäminen ja analysointi
CMS	Condition monitoring service, etäkunnonvalvonta järjestelmä
CAN	Controller Area Network

1 JOHDANTO

1.1 Taustatietoa

Teollisuuden kehittyminen voidaan jakaa neljään eri kehitysvaiheeseen. Ensimmäinen teollisuuden vallankumous syntyi koneistuksen, vesi- ja höyryvoiman kehittymisestä. Toinen teollisuuden vallankumous tuli massatuotannon, tuotantolinjojen ja sähkön tullessa yleisesti käyttöön. Kolmas vallankumous tuli ensimmäisten tietokoneiden ja tuotantolinjojen automatisoinnista.

Saksan liittovaltion (2014) luoma termi Teollisuus 4.0 kuvaa teollisuuden nykyistä vallankumousta, jossa internetin kehitys on tuonut reaali maailman sekä virtuaali maailman yhä lähemmäs toisiaan. Tehtaiden, laitteiden, sensorien ja järjestelmien yhdistäminen verkkoon ja toisiinsa tuovat uusia liiketoimintamahdollisuuksia ja palveluita markkinoille niin kuluttajille kuin yrityksille sekä tuo haasteita yhteiskunnalle työmarkkinoiden muuttuessa voimakkaasti. (The new High-Tech Strategy Innovations for Germany 2014, 16.)

Tämä integraatio tunnetaan paremmin, sen yleisemmällä termillä ”Esineiden internet” (eng. IoT - Internet of Things). Dave Evansin mukaan verkkolaittevalmistaja Cisco arvioi, että IoT syntyi vuosien 2008 ja 2009 välillä, jolloin internetiin liitettyjä laitteita oli ensi kertaa enemmän kuin ihmisiä maapallolla. Verkkolaittevalmistaja Ciscon vision mukaan verkkoon liitettyjä laitteita on 50 miljardia vuoteen 2020 mennessä. (Dave Evans 2011, 3.)

Koneoppimis- ja tekoälyratkaisut yleistyvät voimakkaasti kaikilla toimialoilla. Sekä julkisella sektorilla että raskaasta teollisuudesta aina mobiilisovelluksiin on herätty tähän vallankumoukseen, joka näkyy kasvavina investointeina alan ratkaisujen kehittämiseen.

Tässä opinnäytetyössä tutkitaan miten kohdeyrityksen etäkunnonvalvontaa voisi parantaa uusien teknologioiden avulla, sekä tehostaa pilvipalvelusta saatujen tietojen analysointia uusin tavoin sekä koneoppimisen menetelmin.

1.1.1 Cargotec-konserni

Cargotec-konserni on perustettu vuonna 2005 Kone Oyj:n jakautuessa kahdeksi erilliseksi pörssiyhtiöksi, Cargoteciksi ja uudeksi Koneeksi. Cargotecin historia voidaan kuitenkin katsoa alkaneeksi sata vuotta aiemmin, kun Kalmar – yksi Cargotecin kolmesta liiketoiminta-alueelta – aloitti toimintansa. Konsernin kaikki kolme liiketoiminta-alueita ovat MacGregor, Kalmar ja Hiab. (Cargotec 2018.)

Insinööriveljekset Robert ja Joseph MacGregor perustivat vuonna 1937 MacGregor & Companyn teräksisten lastiluukkujen myyntiä varten. Tästä alkoi MacGregorin tarina. MacGregor toimittaa globaalisti laivojen lastinkäsittelyratkaisuja, offshore-lastinkäsittelylaitteita ja näiden huoltopalveluita. Cargotec osti MacGregor International AB:n vuonna 2005. (Cargotec 2018.)

Cargotecin Kalmar-liiketoiminta alkoi kehittyä vuonna 1997, kun Partek Oyj osti Sisu Ab:n sekä ruotsalaisen Kalmar Industries AB:n. Näiden toiminta fuusioitiin yhteen ja näiden silloisen emoyhtiön Partek Oyj:n osakkeiden julkinen noteeraus lopetettiin. Kalmarin monet innovaatiot ovat nostaneet sen tänä päivänä edelläkävijäksi satama-automaatiossa, energiatehokkaassa kontinkäsittelyssä sekä kyvyssä integroida satamaterminaalin eri prosessit yhteen. (Cargotec 2018.)

Nykyään kuormankäsittelyalan tunnetuimpien tuotemerkin Hiabin, liiketoiminta alkoi muotoutua vuonna 1977 konsernin ostettua Multilift-ryhmän, mistä alkoi vuosikymmeniä kestänyt kehitystyö ja yrityskauppojen sarja, jonka päätteeksi vuonna 2004 Hiab-nimi otettiin käyttöön koko Cargotecin kuormankäsittelyliiketoiminnalle. Vuosikymmenien aikana Hiab on kasvanut johtavaksi ajoneuvojen kuormankäsittelylaitteiden, älykkäiden sekä digitaalisten palveluiden ja ratkaisujen toimittajaksi. (Cargotec 2018.)

Cargotec etenee ripein askelein digitalisaatiossa ja IoT:n sekä pilvipalveluiden tuomisessa liiketoiminnan ja erityisesti palveluliiketoiminnan osiksi. Tavoitteena onkin, että kaikki uudet laitteet ovat kytkeytyneet tietoverkkoihin vuoden 2018 loppuun mennessä. Tällaisten laitteiden avulla asiakkaille pystytään tarjoamaan

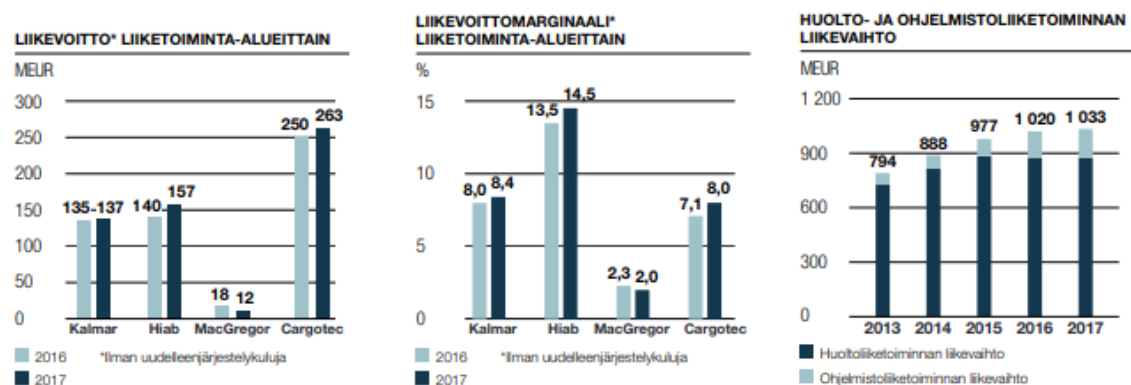
parempia palvelua ratkaisujen koko elinkaaren ajan niin etävalvonta- ja vianmäärityspalveluissa kuin toimintojen automatisoinnissa. (Cargotec 2018.)

1.1.2 Markkinatieto

Cargotec konserni on teknologiajohtaja vahvalla markkinaosuudella kaikilla kolmella liiketoiminta-alueellaan. Konsernin kaikki kolme brändiä ovat tunnettuja, elleivät jopa markkinajohtajia omilla alueillaan, ja niillä on hyvät mahdollisuudet pitkän aikavälin kasvuun. Lisäksi useat maailmaa muuttavat megatrendit tukevat digitalisoituvaa liiketoimintaa kuten, kaupungistuminen ja kasvava keskiluokka. (Cargotec 2018.)

1.1.3 Liikevaihto

Konsernin liikevaihto oli vuonna 2017 3280 miljoonaa euroa ja huolto- ja ohjelmistoliiketoiminnan osuus kokonaisliikevaihdosta oli 31 %. Kalmarin osuus kokonaisliikevaihdosta oli 49 % ja siitä huolto- ja ohjelmistoliiketoiminnan osuus oli 37 %. Hiabin osuus kokonaisliikevaihdosta oli 33 % ja siitä huoltoliiketoiminnan osuus oli 22 %. MacGregorin osuus oli 18 % ja huoltoliiketoiminnan osuus oli 33 %. Kuviosta 1 näkyy tarkemmin konsernin, ja erityisesti Kalmarin tavoite kasvattaa huolto- ja ohjelmistotuotannon liikevaihtoa. (Cargotec 2018.)



Kuvio 1. Yksityiskohtia liikevoitosta sekä huolto- ja ohjelmistotoiminnasta

1.2 Opinnäytetyön tavoite

Opinnäytetyön tavoitteena on tutkia millä tavoin koneoppimista voisi hyödyntää etäkunnonvalvonnassa sekä miten vikadiagnostiikkaa ja telemetriaa voisi kehittää niin perinteisin menetelmin kuin koneoppimisen keinoin. Työssä keskitytään koneoppimiseen perustuvaan ennakoivaan vikadiagnostiikan tutkimiseen sekä etäkunnonvalvonnan ja telemetrian analysoinnin parantamiseen sisäisille ja ulkoisille sidosryhmille. Sisäisellä sidosryhmällä tarkoitetaan tuotekehitystä ja ulkoisella sidosryhmällä asiakkaita eli lastinkäsittelylaitteen loppukäyttäjiä. Ennustavan vikadiagnostiikan avulla voidaan vaikuttaa huoltojen ajoitukseen sekä löytää toisiinsa sidoksissa olevia vikoja. Tämä parantaa asiakaspalvelua ja laitteen toimintavarmuutta. Etäkunnonvalvonnan parantamisella voisi löytää uusia ominaisuuksia palveluliiketoimintaan, esimerkiksi visualisomalla alueita, joilla koneilla on vaikeuksia toimia automaattisesti.

1.3 Työmenetelmä

Opinnäytetyö toteutetaan kehittämistutkimuksena. Tutkimismenetelmänä on pääasiassa tapaustutkimus (case study), koska tarkastelun kohteena ovat yrityksen toimittamat lastinkäsittelylaitteet toimivasta logistiikkakeskuksesta. Kanasen (2013) mukaan tapaustutkimus käyttää useita tiedonkeruumenetelmiä vastataksien tutkittavaan kysymykseen. Case-tutkimuksella pystytään ymmärtämään tutkittavan yrityksen toimintatapoja ja sen tiettyjä prosesseja, toimintoja ja tapahtumasarjoja. (Koskinen, Alasuutari & Peltonen 2005, 157.)

1.4 Rajaukset

Opinnäytetyössä tutkitaan automaattisten lastinkäsittelylaitteiden telemetriaa sekä etäkunnonvalvontaa. Analysoitavaksi otetaan useiden laitteiden dataa toimivasta logistiikkakeskuksesta ja pyritään löytämään yhdistäviä tekijöitä laitteen tilan ja tulevien vikojen suhteen sekä telemetriatietojen parempaa analysointia.

Etäkunnonvalvontaan mietitään uusia ominaisuuksia sekä palvelumahdollisuuksia Cargotec-konsernille sekä mahdollisia hyötyjä tuotekehitykselle. Etukäteen tunnistettuja tutkimuskohteita ovat tilanteet, joissa automaattinen nosturi pyytää operaattoria selvittämään ongelmatilanteen kauko-ohjausta käyttäen ja laitteiden suorituskyvyn mittaaminen.

1.5 Opinnäytetyön rakenne

Opinnäytetyön ensimmäisessä luvussa on esitelty yritys, tutkimusmenetelmä, tavoitteet ja rajaukset. Toisessa luvussa on esitelty tutkimuksen lähtökohta ja nykytila lyhyesti.

Kolmannessa luvussa esitellään koneoppimisen ja sen algoritmien perusteet. Luvussa esitellään myös työn kannalta oleellisemmat algoritmit ja ne käydään läpi yksityiskohtaisemmin.

Neljännessä luvussa pohditaan telemetriatietojen paremman analysoinnin tuomia hyötyjä yritykselle, sekä diagnostiikan parantamista koneoppimisen avulla. Luvussa esitellään telemetriatietojen analysoinnin tueksi luotuja kuvaajia sekä testataan algoritmien toimintaa olemassa olevalla tiedolla ja esitetään tapaustutkimuksen tulokset tämän tutkimuksen kannalta. Luvussa viisi mietitään IoT-tekniologioiden hyödyntämistä ja vaikutusta liiketoimintaan sekä kuvaillaan niiden tuomia hyötyjä. Kuudes luku sisältää johtopäätökset ja ehdotukset etäkunnonvalvonnan jatkotutkimusaiheista.

2 Etäkunnonvalvonnan nykytila

Yhteistyöyrityksen lastinkäsittelylaitteet ovat mahdollista yhdistää halutulla tavalla verkkoon ja pilveen sekä toisiinsa IoT-teknologiaa hyödyntäen. Datan välityksessä voidaan käyttää niin langattomia yhteyksiä kuin myös valokuituun perustuvia ratkaisuja joten halutessa on mahdollista liittää mikä tahansa yrityksen toimittama lastinkäsittelylaite etävalvonnan sekä pilvipalveluiden piiriin.

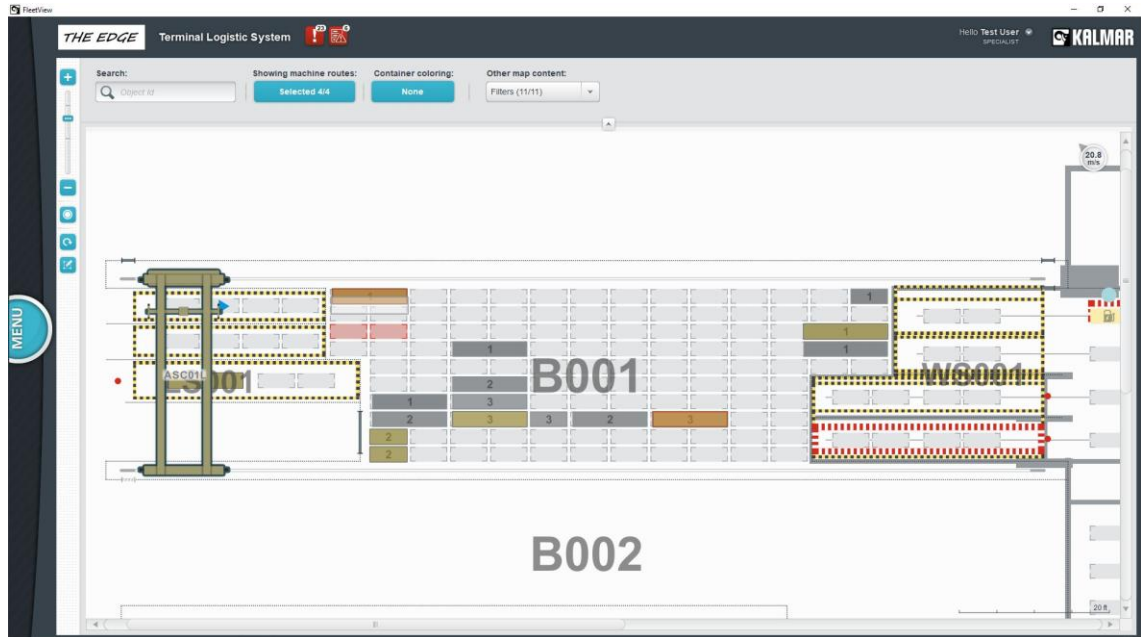
Nykyinen etävalvontajärjestelmä on monipuolinen ja siitä pystytään räätälöimään erilaisia versioita riippuen asiakkaan ostamasta huoltopalvelun tasosta sekä logistiikkakeskuksessa toimivista lastinkäsittelylaitteista. Helpposta räätälöinnistä onkin hyötyä, koska toimistossa työskentelevällä logistiikka-asiantuntijalla ja laitteiden huoltoinsinöörillä on hyvin erilaiset tarpeet etävalvontasovelluksen tarjoamille tiedoille. Siinä missä toinen tarvitsee mahdollisuuden antaa työkäskyjä ja nähdä kuormankäsittelylaitteen yleistilan, toinen tarvitsee yksityiskohtaisempia tietoja esimerkiksi öljypaineista ja muista mekaanisista tiedoista.

Etävalvontasovellus ei tällä hetkellä sisällä ennustavia elementtejä ja historiatietoja lastinkäsittelylaitteista se tarjoaa rajoitetusti. Kun käyttäjä haluaa tarkastella pilveen tallennettuja telemetriatietoja lastinkäsittelylaitteesta, hänen tarvitsee tietää tarkasteltava kellonaika. Käyttäjän pitää tietää melko tarkasti etukäteen mitä tietoja halutaan hakea, koska sovellus ei tarjoa normaalista poikkeavien tietojen tai virheiden hakua. Suuri osa pilveen tallennetusta tiedosta jääkin hyödyntämättä ja sitä on niin valtava määrä, että sitä ei ole käytännöllistä analysoida ihmisen toimesta ilman, että on tiedossa ajanhetki, josta tietoa halutaan. Tämän vuoksi koneoppimiseen perustuva automaattinen analysointi voisi tarjota arvokasta tietoa niin tuotekehittäjille kuin loppukäyttäjille.

2.1 Nykyinen käyttöliittymä

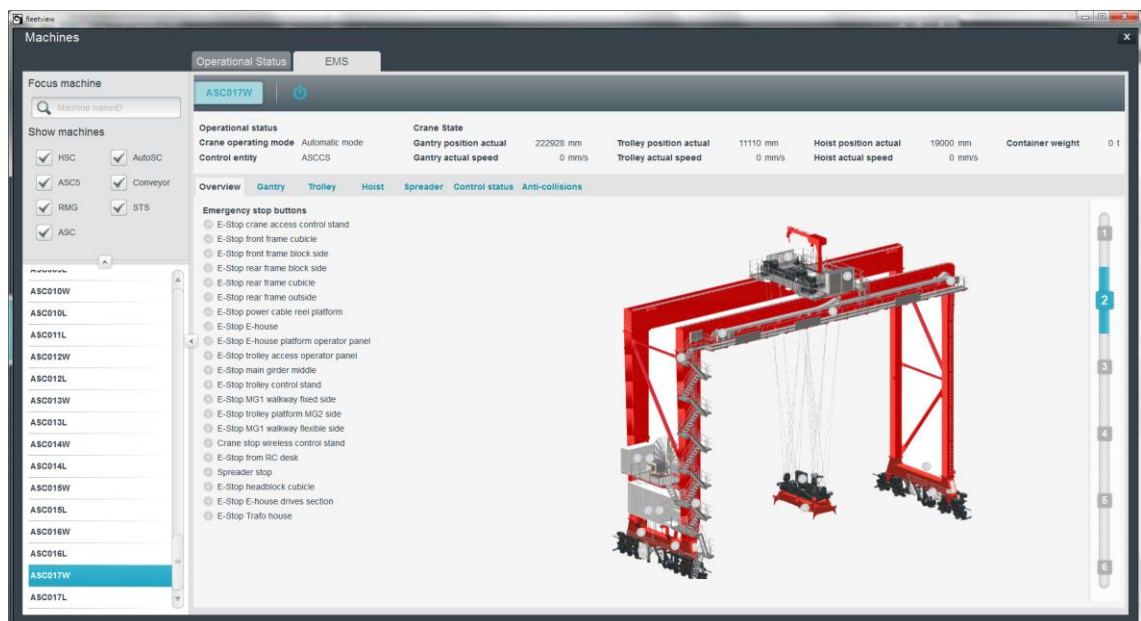
Yrityksellä on saatavilla räätälöitävissä oleva sovellus, joka integroi verkkoon liitetyt lastinkäsittelylaitteet ja järjestelmät. Sitä käytetään niin sanotusti ”fleet ma-

nagementtiin” eli suomeksi laivueen hallintaan. Tällä ohjelmalla logistiikkakeskuksen työntekijät voivat tarkkailla laitteiden sijaintia, kuljettavaa reittiä tai niiden tilaa sisältäen mahdollisesti aktiivisena olevat varoitukset ja virhetilanteet.



Kuva 1. Näkymä CMS-sovelluksen päänäkymästä

CMS sovelluksesta on tarjolla räätälöityissä olevia eri versioita, joiden ominaisuudet vaihtelevat. Sovellus on suunniteltu parantamaan asiakkaiden tuotannon tehokkuutta vähentämällä tarvetta mennä laitteen luo nähdäkseen telemetriatietoja ja mahdollisia aktiivisia vikatietoja. Sovelluksen avulla käyttäjät saavat reaaliaikaista tietoa lastinkäsittelylaitteesta miltä tahansa niiden kanssa samaan verkkoon kytketyltä tietokoneelta tai tabletilta.



Kuva 2. Näkymä laitteen tarkemmista tiedoista

Etävalvontaohjelmaan on mahdollista räätälöidä käyttäjille monia erilaisia toimintoja monitoroinnin tueksi. Käyttöliittymästä on mahdollista nähdä muun muassa erilaisten lastinkäsittelylaitteiden sijainti reaaliajassa sekä automaattisten laitteiden aiemmin suorittamia työtehtäviä, aktiivisena olevan työn reitti ja työhön liittyvä lasti sekä kaikenlaisia muita tietoja. Tietojen välitys pilveen ja sovellukseen tapahtuu riippuen koneen tyypistä joko yleensä langattoman verkon välityksellä tai valokuituyhteydellä, eikä tietojen lähetys vaadi käyttäjältä tai operaattorilta mitään toimia.

2.2 Alarm Tool

Nykyinen sovellus tallentaa lastinkäsittelylaitteiden liikkeet ja tilatiedot joko paikalliselle palvelimelle tai internetin kautta pilvipalvelimelle. Palvelimilta lastinkäsittelylaitteen tietoja voidaan hakea miltä tahansa valitulta ajanjaksolta tai muilla käytössä olevilla hakuehdoilla. Vikatilanteita jälkikäteen selvittäessä työkalusta on hyötyä, koska työkalulla on mahdollista hakea laitteen virhetilanteen telemetrian tiedot hyvin tarkasti. Näin huoltoinsinööri saa selvitettyä, mitä lastinkäsittelylaitte oli virheen sattuessa ollut tekemässä. Näin huoltoinsinööri saa tietoonsa esimerkiksi sylinterien asennot, aktiivisena olleet varoitukset tai aktiivisena olleet hälytykset. Etähallintajärjestelmän tarkkuus riittää tietojen hakuun jopa yhden sekunnin tarkkuudella.

2.3 Telemetry ja vikadiagnostiikka

Laitteiden telemetry ja vikadiagnostiikka perustuu analogisten sekä digitaalisten signaalien analysointiin PLC-yksikössä tai sulautetussa järjestelmässä. Diagnostiikalle on tietyt säännöt ja virhe sekä vikakoodit aktivoituvat etukäteen ohjelmoiduissa tilanteissa. Vikojen analysointi voi olla jossain tapauksissa monimutkaista ja tietoa tulkitaan monista eri parametreista ja sensoreista yhtä aikaa. Nämä tiedot yhdistämällä logiikassa saadaan näytettyä käyttäjälle yksi selväkielinen vikakoodi selityksineen.

Tietoa liikkuu edestakaisin lastinkäsittelylaitteessa eri väyliä pitkin kuten esimerkiksi CAN-väylää pitkin laitteen ohjausyksikölle sekä, logiikalle ja lopuksi laitteen ohjauspaneelille näytettäväksi sekä pilveen siirrettäväksi.

CAN-väylä on ajoneuvoteollisuuden käyttöön Boschin kehittämä sarjamuotoinen automaatioväylä pienien viestien nopeaan lähettämiseen. CAN-väylässä kaikki liikenne välitetään kaikille moduuleille ja vastaanottavat moduulit päättävät, reagoivatko viestiin. Näin esimerkiksi tieto kierrosluvusta tai lämpötilasta voidaan jakaa moneen eri paikkaan yhtä aikaa. (Steve Corrigan 2016, 2.) CAN-väylän tarkempi analysointi ei kuulu tämän opinnäytetyöhön alueeseen.

2.4 Nykyisen diagnostiikan haasteet

Nykyinen etäkunnonvalvontajärjestelmä kykenee näyttämään vain lastinkäsittelylaitteiden reaaliaikaista tilaa sekä yksinkertaisia tilastotietoja, kuten moottorin käyttötunteja.

Sovellus ei suorita ennakoivaa laskentaa, jolloin operaattorille ei tarjota tietoa esimerkiksi polttoaineen riittävydestä, vaan järjestelmä hälyttää vasta kun polttoaineen taso on laskenut riittävän alas.

Myöskään logistiikkakeskuksen suorituskyvystä järjestelmät eivät tarjoa tietoa, että miten nopeasti esimerkiksi keskimääräinen lastin siirto tehdään. Näitä tietoja saadakseen pitää käsitellä lokitiedostoja ja lokien perusteella laskea tietoja yhteen esimerkiksi Microsoft Excelin avulla. Tämä tapa on aikaa vievää ja vaivalloista sekä altis inhimillisille virheille. Tietoja on myös vaikea vertailla eri logistiikkakeskusten välillä, koska eri keskusten välillä voidaan laskea näitä tietoja eri tavalla, jos ollenkaan.

3 UUDET TEKNOLOGIAT

3.1 IoT ja teollinen internet

Asioiden tai esineiden internet muuttaa ympäristöä, jossa olemme hyvin nopeasti. Ottaen huomioon miten paljon Internet on jo vaikuttanut tai vaikuttanut moniin asioihin kuten koulutukseen, yhteydenpitoon, liiketoimintaan, tieteeseen, hallintoon ja siten ihmiskuntaan. Internet itsessään on yksi tärkeimmistä ja vahvimista ihmiskunnan keksinnöistä. (Cisco 2011.)

Maailma on seuraavan suuren digitaalisen murroksen ja innovoinnin kynnyksellä teollisen internetin kasvaessa. Se tuo muutoksia kaikkeen ympärillämme automaation siirtyessä tehtaista lähemmäs ihmistä kotiautomaation, älykkäiden laitteiden ja pilvipalveluiden muodossa. Näistä hyviä esimerkkejä ovat kotien älykkäät lämmitysratkaisut, jotka osaavat laskevat kodin lämpötilaa parilla asteella sen ollessa tyhjillään.

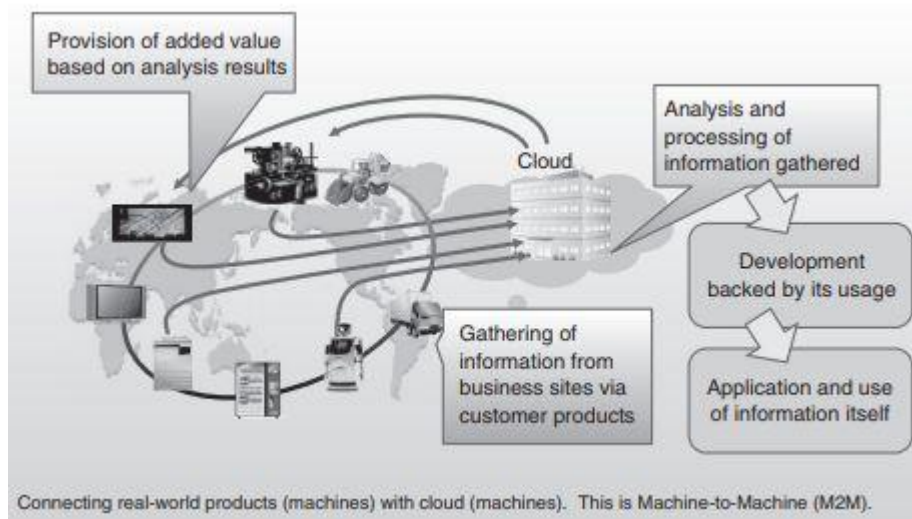
Asioiden internet voidaan jakaa kolmeen eri alueeseen: Esineiden internetiin, joka käsittää älykkäät esineet, jotka kommunikoivat internet-verkon avulla keskenään tai pilvessä olevien sovellusten kanssa. Toiseksi teolliseen internetiin, joka sisältää koneita ja laitteita, jotka tarkkailevat ja keräävät sensorien avulla tietoa olosuhteista, laitteen käytöstä ja sen tilasta liiketoiminnan tehostamiseksi. Kolmas osa-alue on tavaroiden internet, joilla ei välttämättä ole älykkyyttä, mutta niillä on oma identiteettinsä verkossa. Tällainen tavara voi olla esimerkiksi rahtikolli tai kirja. (Quva ja Elisa Oyj 2015, 4.)

Teollisen internetin nousu on seurausta kahdesta digitaalisesta vallankumouksesta. Teollisuuden vallankumouksesta, jossa valtava määrä erilaisia laitteita, laitoksia, koneita ja verkkoja yhdistettiin toisiinsa sekä Internetin vallankumouksesta, joka johti tietokoneiden yleistymiseen, prosessorien laskentatehon kasvuun, analytiikan nousuun, sensorien hintojen laskuun ja internetin räjähdysmäisestä kasvusta. (General Electric 2012.)

Yhdessä nämä tuovat yhteen kolme elementtiä, jotka ovat teollisen internetin ydin. 1. Älykkäät koneet, jotka ovat yhteydessä toisiinsa, toiminnanohjausjärjestelmiin, moniin sovelluksiin ja ulkopuolisiin toimijoihin. 2. Analytiikan, joka sisältää koneoppimista, muokkautuvia algoritmeja, automaatiota ja syvällistä osaamista fysiikan, sähkön, materiaalien ja muiden alojen asiantuntemuksesta. 3. Työssäkäyvät ihmiset, jotka ovat yhteydessä toisiinsa olivat he tehtaalla, toimistolla tai kentällä huoltamassa laitteita. He pystyvät auttamaan toisiaan, ja palvelemaan asiakkaita mistä ja milloin hyvänsä. (General Electric 2012.)

Yhdistämällä nämä kolme osa-aluetta saadaan syvempi digitaalisen maailman integraatio koneiden kanssa mahdolliseksi ja se tuo valtavan potentiaalin muokata teollisuutta ja tuottavuutta. Aiemmin laitteiden etäkunnonvalvontakin on ollut historiallisen datan analysointia vahingollisten tapahtumien jälkeen, mutta nyt on mahdollista rakentaa ennustavia järjestelmiä, jotka voivat reagoida asioihin ja tehdä päätöksiä ennakoivasti koneoppimista hyödyntämällä. (General Electric 2012.)

Tuotantoteollisuuden yritysten digitalisaation ja pilvipalveluiden kehitys voidaan jakaa viiteen eri kehitysvaiheeseen. Ensin vanhoja järjestelmiä päivitetään tai uusitaan, jolloin yleensä järjestelmiä integroidaan ja luodaan etävalvontasovelluksia pilvipalveluita hyödyntäen. Toisessa vaiheessa mahdollistetaan ennakoivaa huoltoa aiemman vaiheen pohjalta ja luodaan uusia huoltoliiketoimintamahdollisuuksia. Kolmannessa vaiheessa aletaan ymmärtämään M2M-järjestelmiä ja sen mahdollisuudet otetaan huomioon markkinoinnissa ja tuotekehityksessä. Neljännessä vaiheessa saadaan tuotettua hyödyllistä tukitietoa järjestelmistä itselle ja asiakkaille sekä järjestelmiä voidaan räätälöidä asiakkaiden toiveiden mukaan. Viidennessä vaiheessa kyetään tuottamaan hyödyllistä tietoa ja järjestelmiä useille sidosryhmille, vaikka avaamalla rajapintoja kumppaneille. Toisaalta kerätty ja analysoitu tieto tai sovellukset tuottavat itsessään huomattavaa lisäarvoa, jolla voidaan tehdä liiketoimintaa. (Tatsuzo Osawa 2011.)



Kuva 3. Seuraavan sukupolven M2M (Tatsuzo Osawa 2011.)

Nämä muutokset liiketoiminnassa ovat uhka yrityksille, jotka eivät pysy digitalisaation kehityksessä mukana. Ketterille yrityksille, jotka uskaltavat hyödyntää uutta teknologiaa tämä murros on mahdollisuus kehittää uusia asiakkaita kiinnostavia palveluita ja ratkaisuja sekä tuottavuutta parantavia työskentelytapoja ja kasvattaa liikevoittoa uusilta liiketoimintaratkaisuilta. (Suomi – Teollisen Internetin Piilaakso 2014, 7.)

IoT:n mahdollistamalla etädiagnostiikalla voidaan tarjota esimerkiksi lastinkäsittelylaitteista reaaliaikaista tietoa sekä tallentaa telemetriatiedot pilvipalveluun myöhempää hyödyntämistä varten. Lisäksi etädiagnostiikalla saavutetaan esimerkiksi seuraavia hyötyjä:

- vikatapausten nopea selvitys.
- ennalta ehkäisevää diagnostiikka.
- paikannustietoja.
- laitteen tietoja kuten polttoainetaloustietoa.
- asiantuntijalle mahdollisuus säätää laitteen asetuksia etänä menemättä paikan päälle.
- asiakkaalla on mahdollista saada tuotetukea nopeasti.

3.2 Koneoppiminen

Luvussa on tarkoituksena esitellä yleisellä tasolla koneoppimista. Mitä se on, mitä menetelmiä se pitää sisällään ja miten ne eroavat toisistaan sekä mitä koneoppimisella voidaan tehdä.

Vuonna 2006, Geoffrey Hinton et al. julkaisivat tutkimuksen, jossa he näyttivät kuinka opettaa syvä neuroverkko tunnistamaan käsinkirjoitettuja lukuja yli 98 % tarkkuudella. He nimesivät tämän tekniikan syväoppimiseksi (eng. Deep learning). Syvän neuroverkon opettaminen oli koettu mahdottomaksi tuohon aikaan useimpien tutkijoiden toimesta ja aktiivinen tutkimustyö oli lopetettu. Tämä uusi tutkimus sähköisti tutkijapiirit näyttämällä, että mahdottoman sijasta syvät neuroverkot kykenivät tuottamaan järjestyttävien tarkkoja tuloksia, joihin muilla sen aikaisilla koneoppimisen algoritmeilla ei ollut mahdollisuuksia. Tämä sysäsi liikkeelle laajan tutkimustyön koneoppimisen alalla ja näin syntyi monia koneoppimista hyödyntäviä yrityksiä ja innovaatiota. (Aurélien Géron 2017, xiii.)

Tällä hetkellä, vähän yli kymmenen vuotta myöhemmin koneoppiminen on vallannut sovelluskehityksen: sitä on hyödynnetty monien nykypäivän tuotteiden ytimessä. Sillä järjestellään verkkohakujen tuloksia, se toimii ennakoivan tekstinsyötön moottorina, sillä suositellaan käyttäjille elokuvia striimauspalveluissa ja koneoppiminen voitti hallitsevan mestarin suositussa Go-pelissä. (Géron 2017, xiii.)

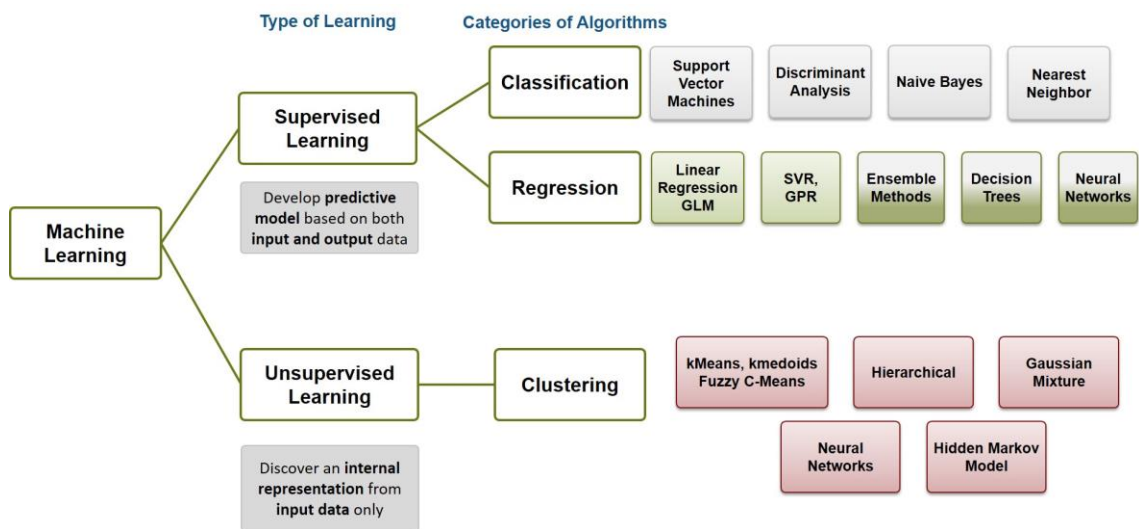
Koneoppiminen on yleistynyt osaksi nykypäivästä elämää, huomasimme sitä tai emme, mutta sen ymmärtäminen ainakin perustasolla on hyödyllistä kaikille teknologiasta kiinnostuneille. Koneoppimiseen liittyvän tutkimuksen ja kehityksen lopullisena tavoitteena voidaan nähdä todellisen tekoälyn luominen.

Koneoppiminen on tekoälyn osa-alue, jossa tehokkuuden parantaminen kokemuksen ja mukautumisen avulla on lähes kaikkien koneoppimisen toimintojen ydin. Siten koneoppimisen voisi yleisesti määritellä seuraavasti: koneoppiminen on systemaattista algoritmien ja systeemien kehittämistä, jotka parantavat osaamistaan ja suorituskykyään kokemuksen kautta. (Flach 2017, 3.)

3.3 Algoritmit

Opinnäytetyössä käytetään Googlen luomaa ja julkaisemaa ilmaista avoimeen lähdekoodiin perustuvaa Scikit learn -kirjastoa käyttäen Python-ohjelmointikieltä. Koneoppimisen sovelluksia ja algoritmeja voi kehittää monilla eri ohjelmointikielillä sekä kirjastoilla kuten esimerkiksi Amazon Machine Learning, Azure ML Studio, TensorFlow, Caffe, H2O, Mllib, mlpack, Shogun, Theano ja Pattern.


Seuraavassa kuvassa on koneoppimisen algoritmien eri tyyppiä. Tässä opinnäytetyössä esitellään tarkemmin ohjatuista tyypeistä päätöspuut (eng. Decision trees) ja Bayes-verkot (eng. Bayesian networks).



KUVA 4. Koneoppimisessa yleisimmin käytetyt ohjatut sekä ohjaamattomat algoritmit (lähde: Googlen kuvahaku.)

3.3.1 Ohjattu oppiminen

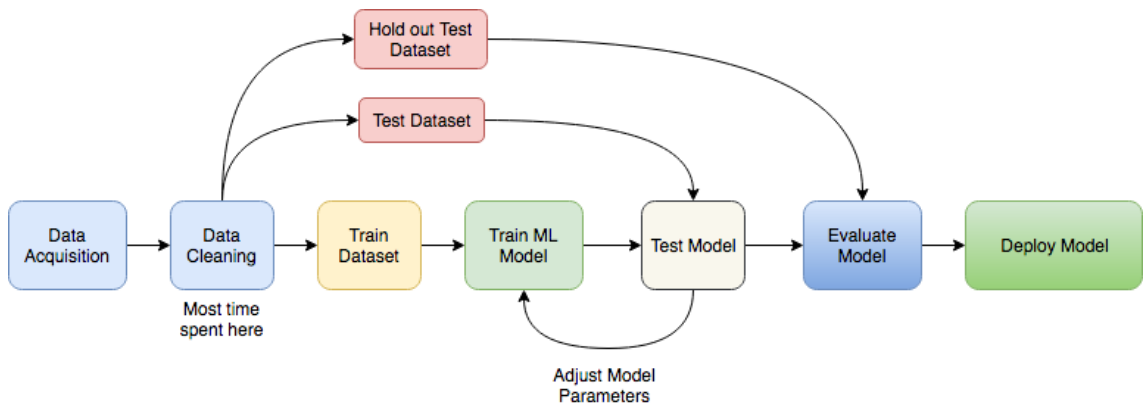
Ohjattu oppiminen tarkoittaa algoritmeja, joille syötetään oppimisdataa, joka sisältää syötteen sekä lopputuloksen (eng. labeled data). Näin oppimisdatalla muokataan algoritmin toimintaa haluttuun lopputulokseen. Roskapostisuodatin on tästä hyvä esimerkki. Siinä algoritmia opetetaan syöttämällä sille valmiiksi lajiteltuja sähköposteja, ja näiden perusteella algoritmin pitää oppia kategorioimaan sähköposteja itsenäisesti. (Géron 2017, 8.)



KUVA 5. Ohjattua oppimista halutulla lopputuloksella (Géron 2017, 8)

Yllä oleva luokittelu on yleisin tehtävä koneoppimisalgoritmeja opettaessa. Oppimisdatalla, joka sisältää syötteen ja tuloksen luodaan algoritmin luokittimia (eng. classifiers), joilla jokainen algoritmille syötettävä tieto voidaan yleistää yhteen luokittimeen. (Flach 2017, 52.)

Oppimisdatan käyttö ja luominen ovat myös koneoppimisen suurin haaste. Oppimisdatan luominen tyhjästä on usein liian työlästä, joten oppimisdata otetaan satunnaisotannalla oikeasta datasta. Tällöin oppimisdata voi sisältää mahdottomia arvoja (puutteellisia tai tyhjiä) tai arvot sisältävät satunnaisia poikkeamia, jolloin koneoppimisalgoritmi oppii huonosti tai väärin, jolloin se ei toimi kunnolla. Onkin tärkeää varmistaa oppimisdataa korjaamalla, että se sisältää riittävästi oleellista tietoa ja vähän epäoleellista. Géron 2017, 25.)




KUVA 6. Ohjatun oppimisen prosessin kulku (lähde: Googlen kuvahaku)

Työssä käsitellään tarkemmin vain ohjatun oppimisen (eng. supervised learning) menetelmiä, mutta on syytä mainita kolme muuta koneoppimisen pääluokkaa,

jotka ovat ohjaamaton oppiminen (eng. unsupervised learning), puoli-ohjattu oppiminen (eng. semisupervised learning) ja vahvistusoppiminen (eng. reinforcement learning). (Géron 2017, 8.)

3.3.2 Ohjaamaton oppiminen

Ohjaamattomassa oppimisessä oppimisdatassa ei ole annettu etukäteen haluttua lopputulosta, vaan algoritmin pitää etsiä datasta yhteneväisyyksiä. Roska-
postin esimerkissä algoritmi ryhmittelee sähköposteja ryhmiin laskemalla ja vertaamalla esimerkiksi niissä esiintyviä sanoja ja linkkien määriä sekä lähettäjän osoitetietoja. (Flach 2017, 14.)




KUVA 7. Etukäteen merkitsemätöntä oppimisdata ohjaamattomalle oppimiselle (Géron 2017, 10)

3.3.3 Puoli-ohjattu oppiminen

Puoli-ohjatussa koneoppimisessä algoritmi kykenee oppimaan osittain etukäteen merkityllä oppimisdatalla. Yleensä tällainen oppimisdata sisältää paljon merkitsemätöntä tietoa ja hieman merkittyä tietoa. Useimmat puoli-ohjatut koneoppimisen

algoritmit ovat yhdistelmä ohjaamattomia ja ohjattuja algoritmeja. (Géron 2017, 13.)

Useat valokuvien hosting-palvelut kuten esimerkiksi Google Photos ovat tästä hyviä esimerkkejä. Kun käyttäjä lataa palveluun kaikki perhevalokuvansa, palvelu kykenee tunnistamaan, että henkilö A on kuvissa 1, 5 ja 11 ja henkilö B on kuvissa 2, 5 ja 7. Näin ohjaamattoman oppimisen algoritmi oppii ryhmittelemällä ja enää algoritmi tarvitsee käyttäjän nimeämään henkilöitä yksittäisiin kuviin, jonka jälkeen se osaa nimetä henkilöt kaikissa valokuvissa. (Géron 2017, 13.)



KUVA 8. Puoli-ohjattua oppimista (Géron 2017, 13)

3.3.4 Vahvistusoppiminen

Vahvistusoppiminen on hyvin erilaista koneoppimista, koska tässä oppimistavassa algoritmi eli toimija kykenee havainnoimaan ympäristöä ja valitsemaan suoritettavan toiminnon. Toiminnon suorituksen jälkeen toimija saa tiedon oliko se tehnyt oikean vai väärän päätöksen. Näin algoritmi oppii ajan kanssa kokeilemalla ja löytämällä parhaita tuloksia ja siten se luo itselleen sääntöjä ja toimintatapoja eri tilanteisiin sekä muokkaa niitä jokaisen suoritettujen toiminnon jälkeen. (Géron 2017, 13.)

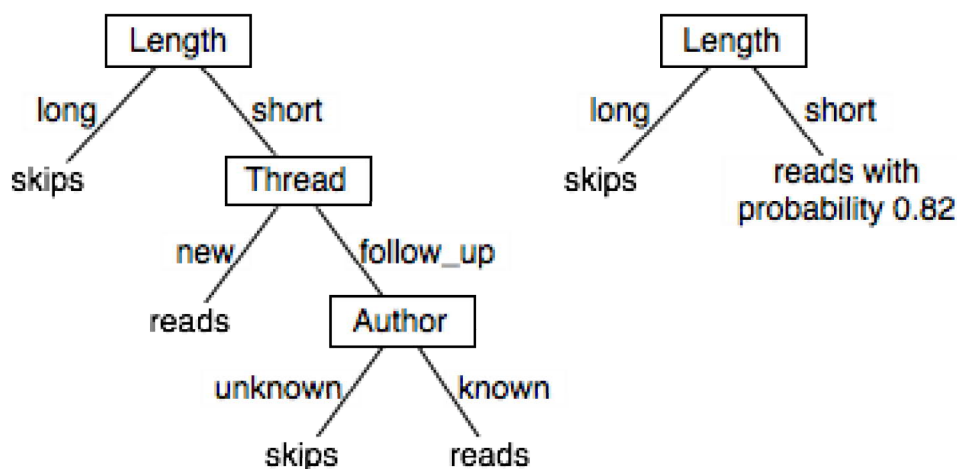
3.3.5 Päätöspuut

Päätöspuut (eng. tree models sisältäen puumallit: decision trees, classification tree ja regression tree) ovat niiden yksinkertaisuuden vuoksi koneoppimisen suosituimpia algoritmeja. Päätöspuut ovat hyvin kuvaavia ja helppoja ymmärtää sekä ovat luonnoltaan ”hajota-ja-hallitse” -tyyppisiä, jonka takia ne ovat tutkijoiden mieleen. (Flach 2017, 129.)

Päätöspuut ovat hyvin monikäyttöisiä koneoppimisen algoritmeja, jotka pystyvät suorittamaan tehtäviä niin luokittelemalla kuin regressioanalyysillä tai usean lopputuloksen menetelmillä (eng. multioutput tasks). Ne ovat hyvin tehokkaita algoritmeja, jotka kykenevät ratkomaan monimutkaisia datamassoja. (Géron 2017, 167.)

Päätöspuut ovat myös olennainen osa satunnaisen metsän (eng. random forests) algoritmeja, jotka ovat yksi tehokkaimmista nykypäivän koneoppimisen algoritmeista. (Géron 2017, 167.) Satunnaiset metsät eivät kuulu tämän opinnäytetyön piiriin.

Ne ovat nimensä mukaisesti binääripuu-rakenne, jossa jokaiseen solmuun sisältyy arvon testaus ja jokainen lehti on arvon luokittelu. Päätelyketju alkaa antamalla arvo juurisolmulle, jonka jälkeen se haarautuu eteenpäin, kunnes viimeinen päätössolmu saavutetaan, jossa on ennustettu tulos. (Flach 2017, 132). Algoritmi jakaa datan osiin ja luo jokaisesta vaihtoehdosta oman puurakenteen ja lopuksi yhdistää nämä kaikki vaihtoehdot yhdeksi puuksi.



KUVA 9. Esimerkki yksinkertaisesta päätöspuusta (lähde: Googlen kuvahaku)

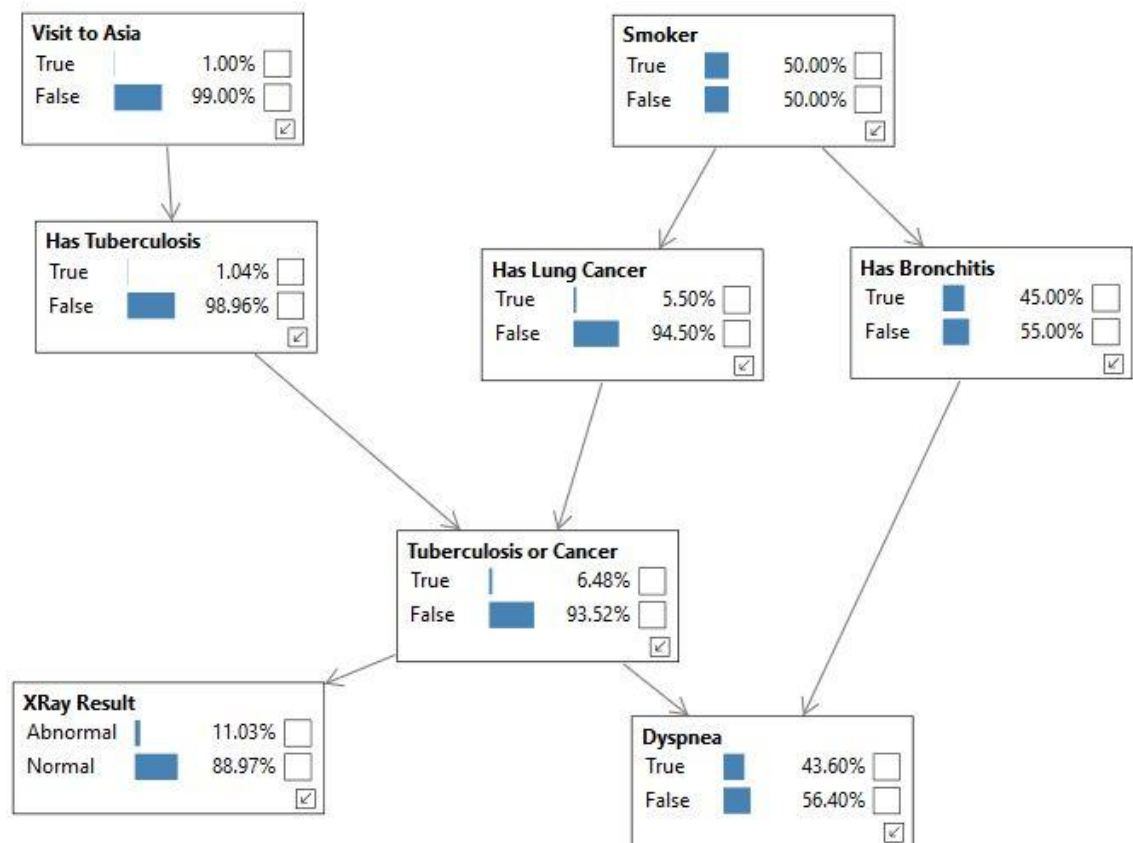
Koska algoritmi toimii tiukan binäärimallisesti, sen huono puoli on, että algoritmi pyrkii luomaan sääntöpuunsa liian tiukasti harjoitustiedon mukaiseksi. Jolloin se ei välttämättä toimi niin hyvin oikean datan kanssa ja päätyy tekemään vääriä tulkintoja ja johtopäätöksiä. Tämän takia algoritmin oppimista pyritään rajoittamaan erilaisin painotuksin, säännöin ja rajoituksin harjoitusdatan kanssa. Lisäksi algoritmin luonteen takia pienetkin muutokset harjoitustiedossa voivat muuttaa lopputulosta suuresti, koska parin solmun toisin suorittaminen muuttaa puun päättelyketjun. (Flach 2017, 156.)

3.3.6 Bayes-verkko

Bayes-verkko (eng. Bayes network, Bayes nets, tai Belief network) on todennäköisyysmalli, joka esittää muuttujia ja niiden välisiä riippuvuuksia ja käyttää todennäköisyyksiä ennakointiin sekä poikkeamien havaitsemiseen.

Bayes-verkko muodostuu solmuista ja niiden välisistä suunnatuista solmuista. Jokainen solmu voi sisältää yhden tai useamman parametrin. Parametri voi olla esimerkiksi sukupuoli tai ajan mittaan muuttuva, kuten ikä tai ajetut kilometrit.

Todennäköisyysmallin voi myös esittää graafisena kuvana sisältäen verkon solmut ja niiden väliset riippuvuudet sekä todennäköisyydet. Visualisointi on myös hyvä tapa ymmärtää mallin toimintaa.



KUVA 10. Esimerkki Asia Bayes-verkosta (Bayes Server 2018)

Bayes-verkkojen houkuttelevimpia ominaisuuksia ovat niiden todennäköisyyksiin pohjautuva rakenne, jonka ansiosta oppimista voidaan pitää jatkuvana prosessina, joka parantaa mallin toimintaa ajan myötä. (Flach 2017, 263.).

4 ETÄKUNNONVALVONNAN JA TELEMETRIATIETOJEN PARANTAMINEN

4.1 Ehdotuksia uusista ominaisuuksista etäkunnonvalvontaan

Seuraavissa kappaleissa esittelen tilastotietoja, joita oli mahdollista saada tämän hetkisillä tiedoilla sekä esitellä tietojen paremmalla käsittelyllä saavutettavia mahdollisuuksia, joita käyttää hyödyksi tuotekehityksessä sekä tuotteistaa loppukäyttäjille myytäväksi.

4.1.1 Uusien tietojen lisääminen etäkunnonvalvontaan

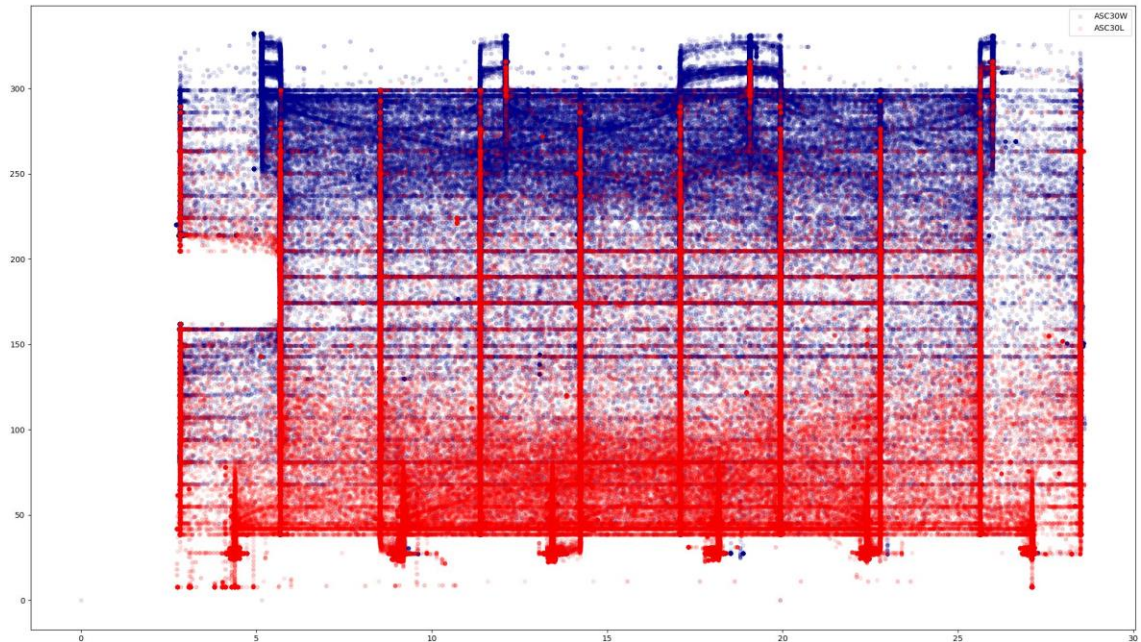
Nykyisen lastinkäsittelykeskuksen tietoja käsitellessä selvisi, että tilastojen laskennan saisi tarkemmaksi lisäämällä tietoihin kaksi toiminnanohjausjärjestelmän tietoa. Ensimmäisenä tietona työn uniikin tunnuksen, jonka logistiikkakeskuksen järjestelmä luo jokaista lastinkäsittelylaitteen työtä varten. Toisena tärkeänä tietona ehdottaisin lisättäväksi ohjausjärjestelmän tilan tunnusta, eli onko työ paikallisen ohjausjärjestelmän luoma vai keskuksen ohjausjärjestelmän luoma työ.

Suorituskykytilastojen kannalta on äärimmäisen tärkeää tietää työn alkuperä, koska paikallisen ohjausjärjestelmän luomia töitä käytetään esimerkiksi lastinkäsittelylaitteen huollossa ja testauksessa. Näin ollen testauksessa käytetyt työt laskevat järjestelmän kannalta oikeiden töiden keskiarvoa.


4.1.2 Lastinkäsittelylaitteen tilastojen laskeminen

Jo nykyisillä etävalvonnan tallentamilla telemetriatiedoilla on mahdollista laskea tilastotietoja hyvin kattavasti lastinkäsittelylaitteen toiminnasta sekä suorituskyvystä. Seuraavana muutamia esimerkkejä tallennettujen paikkatietojen yksinkertaisesta tulkinnasta ja niiden muuttamisesta visuaaliseen muotoon.

Seuraavana esiteltävät analyysit ja ruutukaappaukset ovat samasta lastinkäsittelykeskuksen alueesta kahden lastinkäsittelylaitteen tuottamista telemetriatiedoista.



Kuva 11. Lastinkäsittelylaitteiden kulkureittejä paikkatietojen perusteella



Kuva 12. Koordinaatit, joissa lastinkäsittelylaitteet ovat pyytäneet etäohjausta

Lastinkäsittelylaitteiden telemetriatiedoista on mahdollista laskea suorituskyyti-
lastoja melko tarkasti. Näiden tietojen näyttäminen reaaliajassa laitteen etähallin-
nassa olisi mahdollista ja tietojen tarkastaminen palvelimella päivittäin tai har-
vemmin suoritettavalla eräajolla.

Seuraavissa kappaleissa käydään läpi lastinkäsittelylaitteiden telemetriatietojen
pohjalta laskettuja tilastoja niin suorituskyvystä kuin töiden lukumääriä. Lastinkä-
sittelylaite suorittaa työt askeleissa ja laite lähettää jokaisesta askeleesta tiedon,
joiden pohjalta laskelmat ovat tehty.


Työ katsotaan alkaneeksi, kun laitteen tila vaihtuu toimettomasta aktiiviseksi ja
työ katsotaan päättyneeksi tilan vaihtuessa työn päättymiseen. Työ hylätään,
eikä lasketa onnistuneeksi automaattisesti suoritetuksi työksi, mikäli tilaksi tulee
etäohjauspyyntö tai virhe.

Seuraavassa taulukossa on kahden lastinkäsittelylaitteen telemetriatiedoista las-
kettuja tilastoja.

Töiden alue	Töiden lukumäärä	Etäohjaus- pyyntöjä	%
Lastausalue W	6341	52	0,83%
Moduuli	35258	574	1,65%
Lastausalue L	9068	994	12,31%
Yhteensä	50738	1623	3,30%

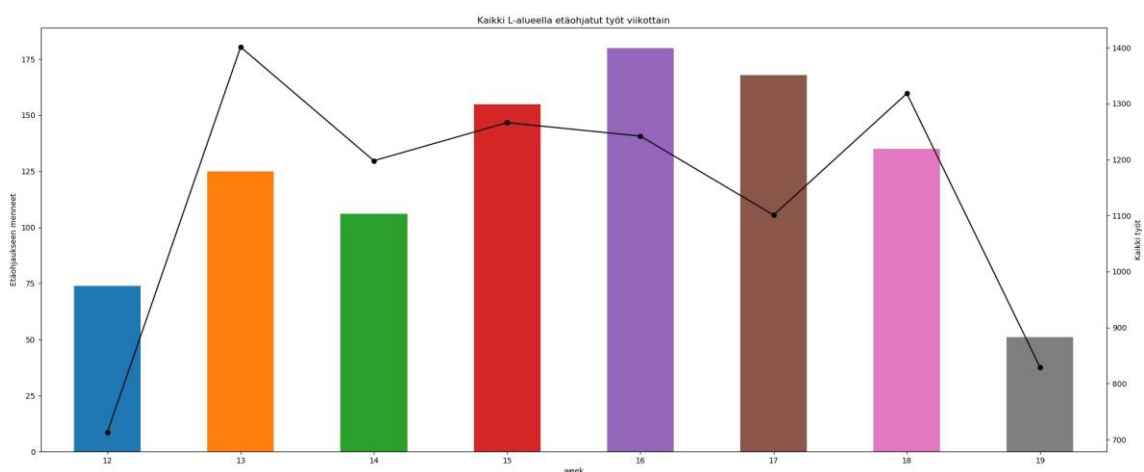
Taulukko 1. Lastinkäsittelyalueen työmäärät

Työmäärät yksinään antavat vain yleisestä tilastotietoa ja Taulukon 1 antamista
tiedoista tärkein on prosentuaalinen suhde etäohjauspyyntöjen ja töiden luku-
määrien välillä. Seuraavassa kuvaajassa on esitetty etäohjaukseen menneet työt
viikon jaksoissa verrattuna kaikkiin suoritettuihin töihin.

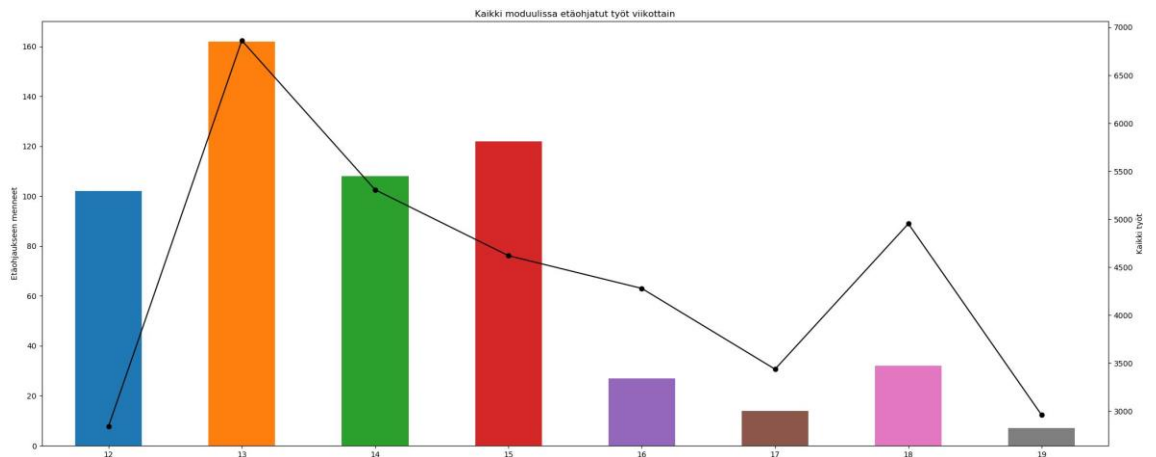


Kuva 13. Kaikki etäohjatut työt verrattuna kaikkiin suoritettuihin töihin


Seuraavissa kuvissa vertailun vuoksi etäohjatut työt lastinkäsittelyalueiden eri osissa. Kaavioista erottuu selvästi L-alueen haastavuus lastinkäsittelylaitteen automaattiselle toiminnalle.



KUVA 14. Kaikki L-alueen etäohjatut työt verrattuna kaikkiin alueella suoritettuihin töihin



KUVA 15. Kaikki A-alueen etäohjatut työt verrattuna kaikkiin alueella suoritettuihin töihin




KUVA 16. Kaikki W-alueen etäohjatut työt verrattuna kaikkiin alueella suoritettuihin töihin

4.1.3 Lastinkäsittelylaitteiden etäohjauspyyntöjen havainnollistamisen parantaminen

Yksi tärkeimmistä automaattisen lastinkäsittelylaitteen suorituskykyyn vaikuttavista tekijöistä on sen tekemien etäohjauspyyntöjen lukumäärä. Lastinkäsittelylaitte voi pyytää etäohjausta erilaisista syistä, joista osa voidaan eliminoida ennakkoivalla työllä niin mekaanisella huollolla kuin ohjelmiston parametreillä, sekä tutkimalla syitä etäohjauspyyntöihin. Tämä syy voi olla huonosti tehty ohjaukarta, sensorien kalibrointi tai laitteen mekaanisten osien kulumasta ja löystymisestä johtuvaa.

Etäohjauspyyntöjen tarkastelussa pitää ensimmäisenä selvittää paikkatiedoista ne kohdat, joissa lastinkäsittelylaite on pyytänyt etäohjausta. Kun tunnistetaan lastinsäilytysruutu, jossa laitteella on ongelmia suoriutua automaattisista siirto-tehtävistä, voidaan siirtyä tutkimaan ohjelmiston parametrejä ja itse ruudun sijaintia.



Kuva 17. Lastinkäsittelyalueen ruudut, joissa laitteet ovat pyytäneet eniten etäohjausapua

Taululukosta voidaan havaita, että pyyntöjä on tullut useasta lähekkäin sijaitsevasta kohdasta, jotka ovat alla eriteltynä kutsujen lukumäärän mukaisesti:


- A30.07.19ft40 18
- A30.08.17ft40 16
- A30.06.19ft40 14
- A30.07.17ft40 13
- A30.04.17ft40 12
- A30.05.19ft40 12
- A30.08.19ft40 10

Toisaalta, kun tarkastellaan lastinkäsittelyalueen eri ruutujen kokonaistyömääriä ja niissä tulleita etäohjauspyyntöjä, lista muuttuu oleellisesti:


Ruutu	Töitä yhteensä	Etäohjauspyyntöjä	Osuus
A30.06.11	40	7	17,5 %
A30.08.11	45	6	13,33 %
A30.03.26	45	5	11,11 %
A30.09.29ft40	98	7	7,14 %
A30.06.27ft40	72	5	6,94 %
A30.09.25ft40	61	4	6,56 %
A30.10.37ft40	113	7	6,19 %
A30.07.31ft40	66	4	6,06 %
A30.10.15ft40	93	5	5,38 %
A30.08.27ft40	104	5	4,81 %
A30.03.31ft40	105	5	4,76 %
A30.10.06ft40	126	6	4,76 %
A30.05.08ft40	87	4	4,6 %
A30.07.19ft40	444	18	4,05 %
A30.08.17ft40	396	16	4,04 %
A30.06.19ft40	392	14	3,57 %
A30.08.19ft40	357	10	2,8 %
A30.05.19ft40	442	12	2,71 %
A30.04.17ft40	450	12	2,67 %
A30.07.17ft40	506	13	2,57 %

Taulukko 2. Kontinkäsittelyalueen ruutujen etäohjauspyyntöjen osuuksia

Lastinkäsittelylaitteen suorituskykyyn vaikuttavat myös inhimilliset tekijät. Työn kiertoaikaan vaikuttaa aika, jonka laite joutuu odottamaan etäohjauksen yhdistymistä etävalvontaohjauskeskuksesta. Seuraavasta kuvaajasta voidaan nähdä, että suurimmassa osassa tapauksia lastinkäsittelylaite on odottanut etäohjausta alle 30 sekuntia. Yhteenlaskettuna 30 - 180 sekunnin odotusaikoja on lukumääräisesti lähes paljon, joka vaikuttaa jo merkittävästi lastinsiirron kokonaisaikaan.




Kuva 18. Lastinkäsittelylaitteen etäohjauksen odotukseen käytetty aika



Kuva 19. Lastinkäsittelylaitteen käyttämä aika etäohjauksessa

Keskimääräinen lastinsiirtotyön kesto-aika on 97 sekuntia (mediaani 85 sekuntia) ja mikäli lastinsiirtolaite joutuu keskeyttämään automaattisen ajon ja pyytämään etäohjausta, suorituskyky laskee työn osalta keskimäärin 156 sekuntia. Tämä ylimääräinen aika koostuu keskimäärin 87 sekunnista (mediaani 127 sekuntia), joka on etäohjauksen odottamiseen menevä aika ja etäohjauksessa käytetty aika, joka on keskimäärin 69 sekuntia ja mediaanin ollessa 49 sekuntia.



Kuva 20. Lastinkäsittelylaitteen yhden toimintaprosessin suoritusajkoja.

Telemetriatietojen visualisoinnilla voidaan myös auttaa huoltoinsinöörejä, löytämään mahdollisia ongelmapaikkoja esimerkiksi kuvan 20 mukaisilla kuvaajilla. Kuvassa on lastinkäsittelylaitteen yhden automaattisen toimintaprosessin suoritusajkoja. Tämän kuvaajan arvoja voidaan verrata kuvan 14 suorituskykykaavioon, jolloin voidaan tutkia vaikuttaako tämän vaiheen hidastumien etäohjauksipyyntöjen lukumäärän kasvuun.

Telemetriatiedoista on mahdollista luoda myös kuvaaja, joka sisältäisi käyttäjän valitsemien automaattisen prosessien vaiheiden suoritusajkoja. Näillä tiedoilla käyttäjä voisi verrata laitteen jatkuvaa suorituskykyä ja prosessin suoritusajkoja tai verrata kahden eri laitteen arvoja vastakkain. Kaaviossa voisi merkitä hyväksyttävät suoritusajat olla vihreillä pylväillä ja huonot arvot vastaavasti punaisella.

4.2 Koneoppimisen hyödyntäminen vikadiagnostiikassa

4.2.1 Esitys koneoppimisen toiminnasta

Tämän hetkinen vikadiagnostiikka ja telemetria ei mahdollista tai hyödynnä vikojen tai tilanteiden ennakoivaa havainnointia. Alla esitetään yleisellä tasolla millainen tämä toimintatapa voisi olla tulevaisuudessa, jossa etävalvonta hyödyntää ennakoivaa laskentaa.

- 1) Lastinkäsittelylaite lähettää jatkuvasti lähiverkon kautta tietojaan pilvipalveluun prosessoitavaksi.
- 2) Pilvipalvelun laskentateho antaa mahdollisuuden datan jatkuvaan analyysiin eri algoritmien avulla. Tietoja lähetetään eteenpäin käyttöliittymälle esimerkiksi laskehtaessa mahdollisia ennusteita työn suorituskyvystä tai onnistumisprosentista.
- 3) Mahdolliset vikakoodit tai ennusteet vikaantumisesta sen sijaan lähetään määritellylle huolto-organisaatiolle tarkistettavaksi.
- 4) Määritelty huolto-organisaatio tarkistavat dataa tarkemmin ja tekevät sen perusteella suosituksia tai päätöksiä. Huoltosopimuksen tason mukaan tämä voidaan tehdä ennakoivasti tai ottamalla yhteyttä asiakkaaseen.

4.2.2 Työvaiheet

Ensimmäinen työvaihe on koneoppimispalvelun valinta. Viime vuosina ilmestynyt käytännössä kaikilta suurilta toimijoilta kuten Amazon, Google, Microsoft ja IBM. Näistä kaikki ovat pyrkineet tekemään koneoppimisympäristöön mahdollisimman yksinkertaisia ja helppokäyttöisiä. Käyttäjän ei juurikaan tarvitse tuntea eri algoritmien, teorioiden tai ohjelmointikielien toimintoja perusteita pidemmälle.

Toinen työvaihe on palvelun tai työkalun valinnan jälkeen, on valita algoritmi tai algoritmit, joilla voidaan päästä haluttuun lopputulokseen. Alla olevassa taulukossa on esitelty algoritmien päätyyppejä, jotka soveltuvat lastinkäsittelylaitteiden kanssa käytettäväksi.

Taulukko 3. Soveltuvien algoritmimallien päätyypit

Malli	Tarkoitus	Käyttökohde
Ryhmittely	Etukäteen luokittelemattoman datan analysointi ja ryhmien tunnistaminen.	-Laitteen hälytysten ryhmittely ja niiden välisten yhteyksien tunnistaminen ja analysointi
Regressio	Arvojen ennustaminen	-Suorituskyvyn ja todennäköisyyksien ennustaminen. -Huoltojen ennakointi
Poikkeamien etsiminen	Löytää aineistosta normaalista poikkeavaa dataa.	-Laitteiden lokien seuranta -Sensoridatan seuranta ja mekaanisten osien kulumien tarkkailua

Kolmas ja tärkein vaihe on algoritmin koulutus sekä tarkasteltavan aineiston tarkistaminen. Algoritmit eivät pääse hyviin tuloksiin ilman, että niille syötettävä aineisto sisältää kaiken tarpeellisen tiedon ennusteiden laadintaan. Lisäksi useimmat algoritmit vaativat aineiston sisältävän vain numeerisia kenttiä, joten aineistoa voi joutua siivoamaan ja muuttamaan tekstikenttiä numeerisiksi.

Neljännessä vaiheessa algoritmia testataan koulutusvaiheen aineistolla ja tarvittaessa muokataan aineistoa ja algoritmin toimintaan vaikuttavia parametrejä. Kolmas ja neljäs vaihe ovat suurimman työmäärän tehtäviä, ja näitä kahta askelta voi joutua toistamaan monia kertoja.

Viidennessä vaiheessa koulutettu algoritmi viedään tuotantoon ja sen suorittamia ennusteita seurataan. On myös hyvä muistaa, että algoritmi oppii käsittelemästään datasta, ja sen toimintaa pitää aika ajoin tarkistaa. Vääristyneen aineiston syöttäminen esimerkiksi laitteen rikkoutuessa voi vääristää tuloksia vielä myöhemminkin

5 LIKETOIMINNAN KEHITYS JA HYÖDYT

5.1 IoT:n, teollisen internetin sekä koneoppimisen mahdollistamat uudet palvelut

Teollisen internetin ratkaisut antavat käyttäjille ja valmistajille tietoja laitteista reaaliajassa. Nämä tiedot voivat olla niin paikkatietoja, mitä ne tekevät ja paljonko laite sillä hetkellä kuluttaa polttoainetta tai sähköä, tai niinkin yksinkertaisia asioita kuin laitteissa olevat ohjelmistot ja niiden versiot tai tietoja muista laitteista sekä komponenteista.

Yksi tärkeimmistä teollisen internetin tarjoamista mahdollisuuksista on takuun hallinta. Jos myydyistä laitteista on tehty takuu- tai vahinkovaatimus, valmistaja voi analysoida, mitä tapahtui, ja arvioida vaatimuksen tuotteen käytöstä kertovien telemetriatietojen perusteella.

Palveluanalytiikan kehittäminen ja mekaanisten osien kulumien automaattista seuranta ja ennakoitua niin sensoreilla kuin automaattisilla ilmoituksilla, kun etukäteen määritellyt raja-arvot täyttyvät. Raja-arvot voivat olla esimerkiksi laitteen suorittaminen toimintojen määrä tai laitteen liikkuma matka.

Tilastojen laskennassa telemetriatiedoissa voitaisiin tulevaisuudessa myös ottaa kellonajat, sekä vallitsevat sääolosuhteet. Näin saataisiin tilastoihin uusia tietoja ja tarkennuksia, mikäli jonain ajanhetkenä sää vaikuttaisi lastinkäsittelylaitteiden suorituskykyyn.

5.1.1 Hyödyt sidosryhmille

Ulkoisille sidosryhmille teollinen internet tarjoaa mahdollisuuden teknisten palveluiden parantamisen tehokkaammiksi. Tämä voi olla olemassa olevien teknisten toimintojen parantaminen tai automatisointi, kuin järjestelmien ja toimintojen tehokkuuden lisääminen tai rutiinitarkastusten suorittamista.

Yleisin ja usein ensimmäinen teollisen internetin palvelu on asiakaspalvelupor-
taali. Tämä voi olla sovellus tai verkkosivu, joka tarjoaa työkalut luoda raportteja
laitteiden suorituskyvystä, ja antaa erilaisia tilastoja. Yhdistämällä nämä tiedot
koneoppimiseen voidaan tarjota ennakoivaa tietoa. Esimerkiksi automaattisille
lastinkäsittelylaitteelle annetun työn kestoaikaa tai ennustaa todennäköisyys,
jolla laite suorittaa työn itsenäisesti.

Lisäksi asiakkaille voidaan tarjota keinot itsepalveluun, esimerkiksi laitteen kun-
toon liittyvään tietoon ja tarjota mahdollisuus ennakoivaan ylläpitoon sekä huol-
toon sen sijaan, että tulevista huolloista pidetään kirjaa muissa järjestelmissä.
Pahimmassa tapauksessa huoltoja aikataulutetaan vasta laitteiden rikkoutuessa.

5.1.2 Hyödyt tuotekehitykselle

Teollisen internetin mahdollistamat telemetriatiedot antavat tuotekehitykselle
mahdollisuuden saada laitteiden tietoja reaaliajassa, jopa toisilta mantereilta.
Tuotekehitys pystyy myös hyödyntämään telemetriatietoja toimintojen suoritus-
kyvyn parantamiseen sekä virhetilanteiden selvittämiseen. Tällöin mahdollisissa
virhe- ja vikatilanteissa ei tarvitse lähettää asiantuntijaa paikan päälle selvittä-
mään vikaa moottoridatasta, vaan analyysi voidaan tehdä etänä.

Toinen esimerkki etäkunnonvalvonnan antamasta tuesta tuotekehitykselle on
tuotantoon otettujen lastinkäsittelylaitteiden suorituskyvyn ja käyttötilanteiden
seuraaminen. Kaikkia käyttötilanteita on mahdoton inhimillisesti tutkia, mutta uusi
tekniikka mahdollistaisi automaattisen vikatilanteiden seuraamisen.

6 POHDINTA

Yritykset, jotka toimialasta riippumatta lähtevät kehittämään toimintaansa uusien teknologioiden avulla tulevat olemaan vahvoilla toimialallaan tulevaisuudessa. IoT:n ja koneoppimisen tarjoamat näkymät ovat lupaavat ja kyseessä on lähes win-win tilanne. Uudet teknologiat hyödyttävät niin sisäisiä kuin ulkoisia sidosryhmiä. Telemetriaa hyödyntävän koneoppimisen ja ennakoivan vikadiagnostiikan avulla on mahdollista innovoida palveluliiketoimintaa, parantaa tuotekehitystä sekä tuoda asiakkaille uusia tuotteita.

Kalmar kerää jo valtaisan määrän telemetriatietoja, joko omille tai asiakkaidensa palvelimille. Vain keräämällä dataa lastinkäsittelylaitteilta ei vielä saada hyödyllistä tietoa tuotekehitykselle tai hyödynnettyä tätä dataa liiketoiminnassa. Data itsessään ei ole vielä itseisarvo vaan kerätty data on hyödyntämätöntä massaa. Tämän datan analysoinnin tulee olla mahdollisimman automaattista lukuisten lastinkäsittelylaitteiden tuottaman datan valtaisan määrän vuoksi, sillä yksittäinen ihminen ei pysty sitä hyödyntämään, kuin yksittäisen asian tarkastamiseen.

Jotta dataa voidaan hyödyntää mahdollisimman monipuolisesti, on data visualisoitava selkeästi ja visualisointiin vaikuttavien parametrien on oltava käyttäjän muokattavissa. Pitää pystyä valitsemaan yhtenevien lastinkäsittelylaitteiden tietoja rinnakkain vertailtavaksi, jotta voidaan nähdä mikä on normaalia käyttäytymistä. Tällä tavoin voidaan myös vertailla eri laiteyksilöiden suorituskykytietoja. Lisäksi tiedot pitää saada nopeasti pilvipalvelusta ja visualisointityökalun käytön sujuvaa ilman pidempiä lataustaukoja.

Etävalvonnasta ja vikadiagnostiikasta saadaan enemmän hyötyä yhdistämällä telemetriatietojen kerääminen koneoppimisella ennustavaan vikadiagnostiikkaan. Tämän integraation jälkeen järjestelmää voidaan sanoa nykypäivän etäkunnonvalvonnaksi. Tämän uuden toiminnallisuuden avulla voidaan myydä uusia palveluita asiakkaille sekä tehostaa vikaantumisten selvitystä.

Vaikka uuteen teknologiaan voidaan suhtautua toiveikkaasti, on silti hyvä muistaa kriittisyys. Tässä työssä on saatu parannettua telemetriatietojen käsittelyä ja analysointia sekä osoitettu, että on mahdollisuus ennakoivan vikadiagnostiikan kehittämiseen. Koneoppimisen tuominen mukaan telemetriatietoihin tulee vaati- maan enemmän työtä ja tarvittavan datan analysointia, jotta koneoppimisen al- goritmit saadaan opetettua tuottamaan hyödyllisiä tuloksia. Tulevaisuudessa ko- neoppimisen algoritmit kehittyvät samoin kuin tietokoneiden suorituskyky, tietojen tulkitsemiseen tarvitaan aina asiantuntijoita. Koneoppimisessa on pohjimmiltaan kyse tietokoneohjelmasta, jonka ovat tehneet ja opettaneet ihmiset.

Loppuun haluan sanoa, että koneoppiminen osoittautui mielenkiintoiseksi ai- heeksi, vaikka en koneoppimista päässyt hyödyntämään haluamassani laajuu- dessa. Telemetriatietojen käsittely osoittautui haastavaksi aloituskohdaksi datan valtavan määrän vuoksi. Vaati melko paljon työtä saada käsittelyn suoritus aika käytännölliselle tasolle. Kaikesta huolimatta yllätyksekseni pystyin myös löytä- mään paljon uusia mahdollisuuksia analyysien tekoon telemetriatiedoista, ja toi- vottavasti nämä herättävät mielenkiintoa yhteistyöyrityksessä.

LÄHTEET

Bayes Server learning center. Luettu 29.9.2018

<https://www.bayesserver.com/docs/introduction/bayesian-networks>

Tatsuzo Osawa 2011, Practice of M2M Connecting Real-World Things with Cloud Computing. Luettu 15.5.2018

<https://www.fujitsu.com/global/documents/about/resources/publications/fstj/archives/vol47-4/paper05.pdf>

The new High-Tech Strategy Innovations for Germany, 2014. Luettu 14.4.2018

https://www.bmbf.de/pub/HTS_Broschuere_eng.pdf

Dave Evans 2011. The Internet of things. Luettu 3.3.2018

https://www.cisco.com/c/dam/en_us/about/ac79/docs/innov/IoT_IBSG_0411FINAL.pdf

Peter C. Evans and Marco Annunziata 2012. Industrial Internet: Pushing the Boundaries of Minds and Machines. Luettu 1.4.2018

https://www.ge.com/docs/chapters/Industrial_Internet.pdf

Bill Schweber 2015. IoT ja teollisuus 4.0. Luettu 4.3.2018 <http://etn.fi/index.php/tekni-set-artikkelit/2800-iot-ja-teollisuus-4-0-suuria-mahdollisuuksia-ainutlaatuisia-haasteita>

Cargotec vuosikatsaus. Luettu 20.3.2018

https://www.cargotec.com/globalassets/files/investors/reports/2017/cargotec_vuosikat-saus_2017.pdf

Cargotec verkkosivut. Luettu 10.3.2018

<https://www.cargotec.com/fi>

Koskinen, I., Alasuutari, P. & Peltonen, T. 2005. Laadulliset menetelmät kauppatie-teissä. Tampere: Vastapaino

Kananen, J. 2013. Case-tutkimus opinnäytetyönä. Jyväskylä: Jyväskylän ammattikor-keakoulu

Quva & Elisa Oyj. 2015. Quvan ja Elisan yhteisjulkaisu: Yritysjohdon opas IoT:n ja teollisen internetin hyödyntämiseen. Luettu 23.4.2018. http://quva.fi/site/attachments/yritysjohdon_opas_IoT_ja_teollisen_internetin_hyodynta_miseen.pdf

Steve Corrigan 2016. Introduction to the Controller Area Network (CAN) Luettu 18.5.2018 <http://www.ti.com/lit/an/sloa101b/sloa101b.pdf>