

Leevi Suominen

DATAN HYÖDYNTÄMINEN TEOLLISUUDEN KONEJÄRJESTELMIEN VIKAANTUMISEN ENNUSTAMISESSA

Kandidaatintyö
Tekniikan ja luonnontieteiden tiedekunta
Tarkastaja: Väitöskirjatutkija Teemu Mäkiäho
Tammikuu 2022

TIIVISTELMÄ

Leevi Suominen: Datan hyödyntäminen teollisuuden konejärjestelmien vikaantumisen ennustamisessa

Kandidaatintyö

Tampereen yliopisto

Konetekniikan tutkinto-ohjelma

Tammikuu 2022

Tässä opinnäytetyössä käsitellään menetelmiä datan hyödyntämiseen teollisuuden konejärjestelmien vikaantumisen ennustamisessa. Nykyaikaisten tuotantojärjestelmien kasvava monimutkaisuus ja integraatio, sekä trendit, kuten resurssitehokkuuden, vastuullisuuden, turvallisuuden ja ympäristöasioiden korostuminen, edellyttävät tuotantolaitoksen resurssien tehokasta käyttöä. Keskeinen keino resurssien tehokkaaseen käyttöön on hyödyntää tuotantolaitoksesta saatavaa dataa päätöksenteossa. Datan avulla voidaan ennustaa konejärjestelmien vikaantumista, joka johtaa tehokkaampaan kunnossapitoon ja suunnittelemattomien tuotantoseisakkien väheneemiseen. Datasta saatavaa ymmärrystä voidaan hyödyntää myös turvallisuuden ja tuotantoprosessien kehittämisessä.

Työn tavoitteena oli esittää, kuinka dataa voidaan hyödyntää teollisuuden konejärjestelmien vikaantumisen ennustamiseen. Tutkimusmenetelmänä käytettiin kirjallisuuskatsausta ja tapaus-tutkimusta. Kirjallisuuskatsauksessa esitellään erilaisia datan hyödyntämisen menetelmiä ja niiden etuja ja rajoituksia. Myös kunnossapidon ja hyödynnettävän datan teoriaa esitellään taustoit-tamaan aiheita. Tapaustutkimuksessa käsitellään Yaran Uudenkaupungin tuotantolaitoksen kun-nossapitoa ja datan hyödyntämiseen liittyviä asioita. Tapaustutkimuksen aineisto hankittiin haas-tattelulla.

Kirjallisuuskatsauksen pohjalta selvisi, että datan hyödyntämisen menetelmät voidaan jakaa neljään pääryhmään: tietopohjaisiin, fysiikkapohjaisiin, datapohjaisiin ja yhdistettyihin menetel-miin. Jokaisen ryhmän menetelmiin liittyy tiettyjä etuja ja rajoitteita. Tapaustutkimuksen pohjalta voidaan todeta, että kohdeyrityksessä on kiinnostusta datan hyödyntämisen kehittämiseen ja siinä nähdään potentiaalisia hyötyjä sekä kunnossapidon että tuotantoprosessien kannalta. Da-tan hyödyntämisen kehittämisen esteinä on sekä teknologiaan että organisaatioon ja henkilös-töön liittyviä haasteita, joita tulisi ratkoa ennen kuin kehittyneitä datatyökaluja voidaan ottaa laa-jempaan käyttöön.

Avainsanat: Ennustava kunnossapito, älykäs kunnossapito, vikaantumisen ennustaminen, prognostiikka, datan hyödyntäminen

Tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck –ohjelmalla.

ABSTRACT

Leevi Suominen: Utilizing data in predicting manufacturing equipment failure
Bachelor's thesis
Tampere University
Mechanical engineering
January 2022

This thesis is about the methods of utilizing data to predict the failure of manufacturing equipment. The increasing complexity and level of integration in modern production systems, along with trends like responsibility, safety, and environmental issues, create increasing requirements for effective utilization of resources. Key solution for effective resource utilization is using data in decision making. Data gathered from a production plant can be used to predict the failure of manufacturing equipment, which leads to more effective maintenance and less unplanned production downtime. Knowledge gained from the data can also be used to improve safety and develop manufacturing processes.

The goal of this thesis is to present how data can be used to predict the failure of manufacturing equipment. Research methods used are literature review and case study. In the literature review different methods for data utilization are presented, together with the associated advantages and limitations. The theory of industrial maintenance and data are also discussed for background information. In the case study maintenance and data utilization in Yara's Uusikaupunki manufacturing plant are discussed. Material for the case study was obtained by an interview.

According to the literature review, data utilization methods can be divided into four main categories: knowledge-based, physics-based, data-based, and combined methods. There are certain advantages and limitations in each category. The main conclusion from the case study is that the case company is interested in developing data utilization, and potential benefits are seen both in maintenance and developing production processes. There are technological, organizational, and people-related problems that need to be solved before advanced data tools can be widely implemented.

Keywords: Predictive maintenance, e-maintenance, failure prediction, prognostics, data utilization

The originality of this thesis has been checked using the Turnitin OriginalityCheck service.

SISÄLLYSLUETTELO

1. JOHDANTO	1
2. TEOLLISUUDEN KUNNOSSAPITO	2
2.1 Ennustava kunnossapito	3
2.1.1 Tavoitteet	3
2.1.2 Prosessi	4
2.2 Älykäs kunnossapito ja teollisuus 4.0	5
3. DATAN LÄHTEET, KERÄÄMINEN JA ESIKÄSITTELY	7
3.1 DIKW-hierarkia	7
3.2 Kunnonvalvontamenetelmät	8
3.2.1 Värähtelymittaukset	8
3.2.2 Tribologiset menetelmät	9
3.2.3 Muut kunnonvalvontamenetelmät	9
3.3 Muut datan lähteet	10
3.4 Datan kerääminen ja esikäsittely	11
3.4.1 Teollisuuden tietojärjestelmät ja teollinen internet	11
3.4.2 Datan esikäsittely ja yhdistäminen	11
4. DATAN HYÖDYNTÄMINEN VIKAANTUMISEN ENNUSTAMISESSA	13
4.1 Prognostiikka	13
4.2 Tietopohjaiset menetelmät	14
4.3 Fysiikkapohjaiset menetelmät	15
4.4 Datapohjaiset menetelmät	16
4.4.1 Koneoppiminen	16
4.4.2 Tilastolliset mallit	17
4.4.3 Luokittelu- ja regressiomallit	17
4.4.4 Mahdollisuudet ja haasteet	18
4.5 Yhdistetyt menetelmät	19
5. TAPAUSTUTKIMUS	20
5.1 Yrityksen ja haastateltavan esittely	20
5.2 Tuotantolaitoksen kunnossapito	20
5.3 Datan hyödyntämisen nykytilanne ja mahdollisuudet	21
6. JOHTOPÄÄTÖKSET	24
LÄHTEET	26

1. JOHDANTO

Teollisuuden tuotantojärjestelmien kasvava monimutkaisuus ja integraatio aiheuttavat kasvavia vaatimuksia myös tuotantolaitosten kunnossapidossa (Järviö & Lehtiö 2012, s. 21–23; Elattar et al. 2016). Tuotantojärjestelmien kehitys on johtanut tilanteeseen, jossa tuotantoseisakkien aiheuttamien puutekustannuksien merkitys on jopa suurempi kuin kunnossapitokustannusten (Järviö & Lehtiö 2012, s. 21–23). Myös trendit, kuten resurssien kestävä käyttö, vastuullisuus, digitalisaatio sekä turvallisuus- ja ympäristöasioiden korostuminen edellyttävät tuotantolaitoksia käyttämään resursseja entistä tehokkaammin. Keskeinen osa tehokasta resurssien käyttöä on dataan perustuva päätöksenteko. (Järviö & Lehtiö 2012, s. 25–26; Kortelainen et al. 2021) Kunnossapidon resurssien tehokkaampaan käyttöön voidaan pyrkiä ennustamalla tuotantolaitoksen konejärjestelmien vikaantumista datan pohjalta. Vikaantumisen ennustaminen auttaa yrityksiä tekemään tehokkaampaa kunnossapitoa ja vähentämään suunnittelemattomia tuotantoseisakkeja. Datasta saatavaa ymmärrystä voidaan hyödyntää myös turvallisuuden parantamisessa ja tuotantoprosessien kehittämisessä. (Elattar et al. 2016; Bousdekis et al. 2020)

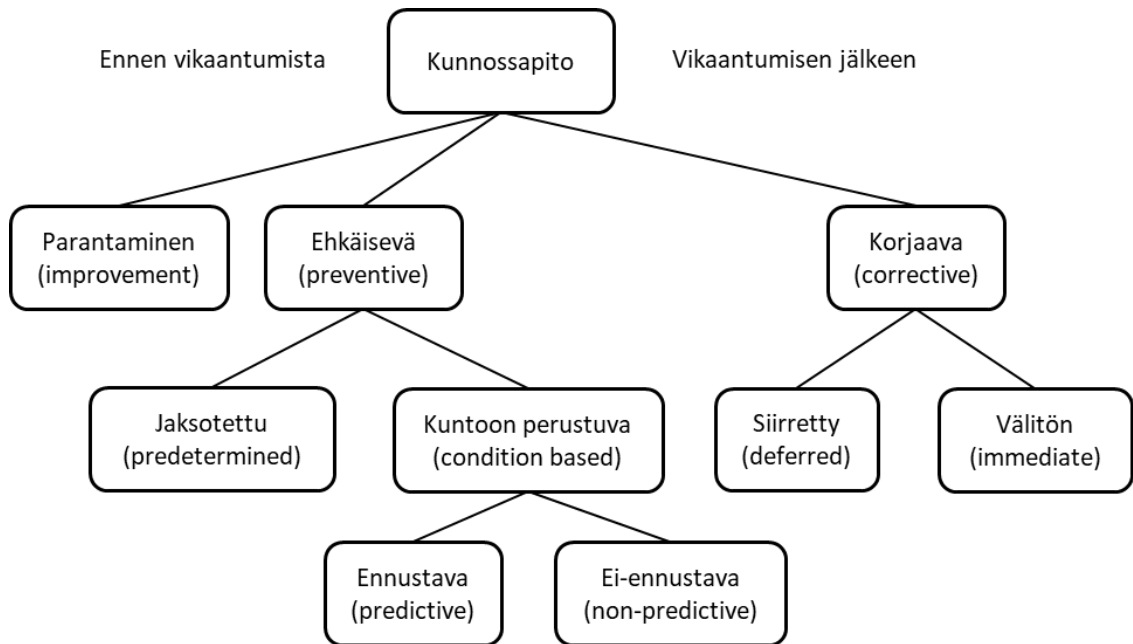
Tämän työn tavoitteena on esitellä erilaisia menetelmiä datan hyödyntämiseen teollisuuden konejärjestelmien vikaantumisen ennustamisessa. Työssä pyritään vastamaan seuraavaan tutkimuskysymykseen: kuinka dataa voidaan hyödyntää teollisuuden konejärjestelmien vikaantumisen ennustamisessa? Työssä käytetyt tutkimusmenetelmät ovat kirjallisuuskatsaus ja tapaustutkimus. Tapaustutkimusta varten haastateltiin teollisuusyrityksen kunnossapidon henkilöä datan hyödyntämisestä kunnossapidossa. Tapaustutkimuksen tarkoituksena on selvittää kunnossapidon ja datan hyödyntämisen nykytilannetta kohdeyrityksessä, sekä kohdeyrityksen suhtautumista ja ajatuksia näistä aiheista.

Työn luvussa 2 kerrotaan teollisuuden kunnossapidosta, ja liitetään työn aihe osaksi laajempaa teollisuus 4.0:n käsitettä. Luvussa 3 esitellään DIKW-hierarkia, ja käydään läpi erilaiset datan lähteet teollisessa tuotantolaitoksessa. Luvussa 3 kerrotaan myös datan keräämiseen ja esikäsittelyyn liittyvistä teknologioista. Luvussa 4 käsitellään erilaisia datan hyödyntämisen menetelmiä ja niihin liittyviä etuja ja rajoituksia. Luvussa 5 esitellään tapaustutkimuksen tuloksia. Luvussa 6 käydään läpi tärkeimpiä havaintoja, ja pohditaan aihetta sekä työn teoriaosuuden että tapaustutkimuksen pohjalta.

2. TEOLLISUUDEN KUNNOSSAPITO

Teollisuuden kunnossapitoa voidaan kuvata teollisuusyrityksen tuotanto-omaisuuden hoitamiseksi (Järviö & Lehtiö 2012, s. 13–20). Standardi SFS-EN 13306:2017 (2017, s. 5) taas määrittelee kunnossapidon seuraavasti: ”kaikki kohteen elinjakson aikaiset tekniset, hallinnolliset ja liikkeenjohdolliset toimenpiteet, joiden tarkoituksena on ylläpitää tai palauttaa kohteen toimintakyky sellaiseksi, että kohde pystyy suorittamaan vaaditun toiminnon.” Standardissa huomautetaan, että kunnossapidon tekniset toimenpiteet tarkoittavat korjaamisen ja kunnostamisen lisäksi kohteen tilan havainnointia ja analysointia. (SFS-EN 13306:2017 2017, s. 5) Kunnossapidon määritelmiä on lukuisia, mutta teollisuusympäristössä se tarkoittaa yksinkertaistetusti koneiden ja konejärjestelmien toimintakyvyn ylläpitämistä ja kehittämistä.

Kunnossapitoa voidaan johtaa ja suorittaa eri tavoin, ja eri tapoja hahmotetaan usein kunnossapitolajien avulla. Käytetyt termit ja yksityiskohdat vaihtelevat, mutta karkea jako voidaan tehdä ehkäisevään ja korjaavaan kunnossapitoon. Ehkäisevää kunnossapitoa suoritetaan ennen vikaantumista vikaantumisen estämiseksi, ja korjaavaa kunnossapitoa suoritetaan vikaantumisen jälkeen toimintakyvyn palauttamiseksi. Ammattikirjallisuudessa ehkäisevää kunnossapitoa kutsutaan usein proaktiiviseksi, ja korjaavaa kunnossapitoa reagoivaksi (Järviö & Lehtiö 2012, s. 46–47). Kuvassa 1 esitetään standardin SFS-EN 13306:2017 mukaiset kunnossapitolajit.



Kuva 1. Standardin SFS-EN 13306:2017 mukaiset kunnossapitolajit (mukaillen lähteestä SFS-EN 13306:2017 2017, s. 22).

2.1 Ennustava kunnossapito

Ennustava kunnossapito (predictive maintenance) tarkoittaa prognoosien eli ennusteiden tuottamista datan perusteella ja ennusteiden hyödyntämistä kunnossapidossa. (Pecht & Kang 2018, s. 589; Bousdekis et al. 2020) Standardi SFS-EN 13306:2017 (2017, s. 14) määrittelee ennustavan kunnossapidon seuraavasti: ”kuntoon perustuvaa kunnossapitoa, jota toteutetaan perustuen ennusteisiin, joita saadaan toistuvista analyysistä ja tunnetuista tunnusmerkeistä sekä tarkastelemalla kohteen huononemista kuvaavia olennaisia arvoja.” Ennustava kunnossapito on osa kuntoon perustuvaa kunnossapitoa (condition based maintenance), joka taas kuuluu ehkäisevään kunnossapitoon (preventive maintenance). (SFS-EN 13306:2017 2017, s. 14)

2.1.1 Tavoitteet

Ennustavan kunnossapidon tuottamaa tietoa voidaan hyödyntää useissa yrityksen prosesseissa. Käytännönläheinen käyttökohde on kunnossapidon suunnittelu ja aikataulutus, mutta tietoa voidaan hyödyntää myös tuotantolaitoksen luotettavuuden ja kunnossapidon kehittämisessä. Ennustavan kunnossapidon tuottama tieto ja ymmärrys ovat myös arvokkaita tuotantolaitoksen tuotannon ja prosessien valvonnassa, optimoinnissa ja kehittämisessä. (Mobley 2002, s. 61–70)

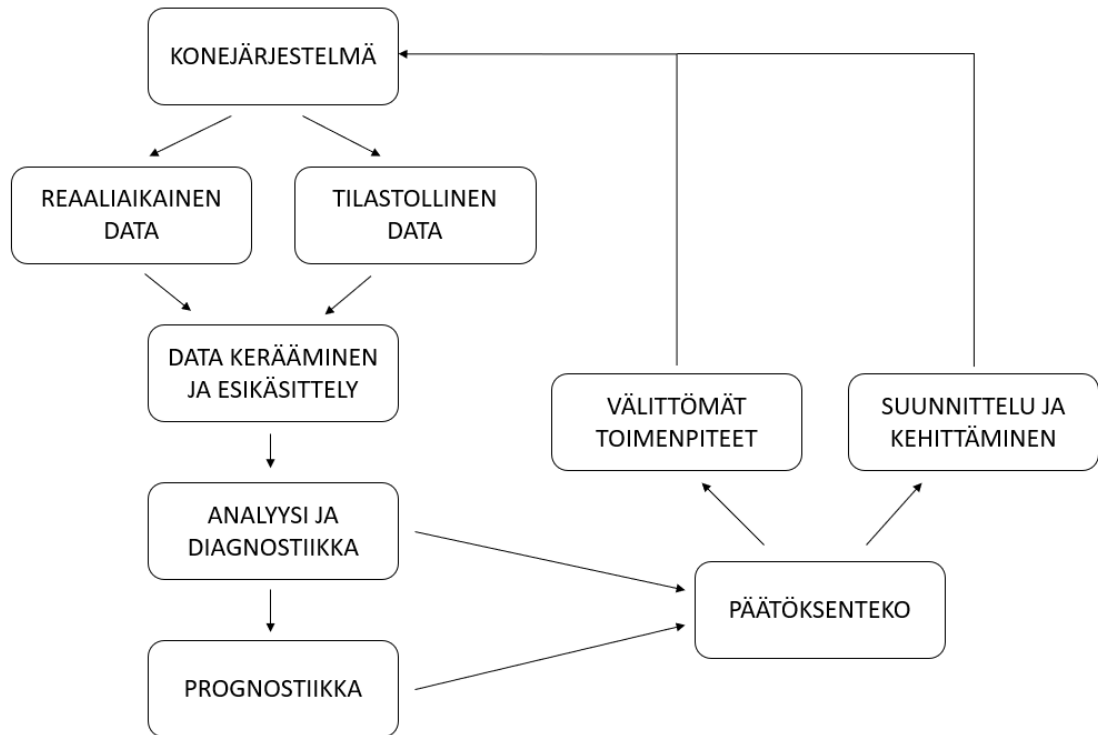
Ennustavan kunnossapidon tavoitteet ja mittarit ovat pitkälti samat kuin kunnossapidossa yleisestikin eli tuotannon korkea kokonaistehokkuus ja hyvä käyttövarmuus. Tuotannon kokonaistehokkuus muodostuu kolmesta tekijästä: käytettävyydestä, toiminta-

asteesta ja laatukertoimesta (Järviö & Lehtiö 2012, s. 59). Käytettävyys on yksi kunnossapidon tärkeimpiä tunnuslukuja, jolla tarkoitetaan tarkasteltavan kohteen, esimerkiksi koneenosan tai tuotantolinjan, kykyä suorittaa siltä vaadittu toiminto. Toiminta-aste kuvaa tuotannon tehokkuutta (tuotantomäärät), ja laatukertoimella huomioidaan hylättävän tuotannon määrä. (Järviö & Lehtiö 2012, s. 59) Schimdtin ja Wangin (2018) mukaan ennustavan kunnossapidon tuomia yksittäisiä hyötyjä voivat olla esimerkiksi parempi turvallisuus, parempi käyttövarmuus, parempi kunnossapidon tehokkuus, matalammat elinkaarikustannukset, pienempi tarve tarkastuksille ja pienempi riski korjaamisesta aiheutuviin vikoihin.

Ennustavan kunnossapidon lisäksi ehkäisevään kunnossapitoon kuuluu jaksotettu kunnossapito. Jaksotetulla kunnossapidolla (myös ennaltaehkäisevä tai aikaperusteinen kunnossapito) tarkoitetaan ajan tai käyttömäärän perusteella suoritettavaa ehkäisevää kunnossapitoa. (SFS-EN 13306:2017 2017, s. 14) Tuotantolaitoksessa tämä tarkoittaa esimerkiksi säännöllistä voitelua, säätöä ja kuluvien osien uusimista (Järviö & Lehtiö 2012, s. 49–50). Jaksotetun kunnossapidon haaste on optimaalisten huoltovälien määrittäminen. Koneiden vikaantumisen ajallinen hajonta voi olla hyvin suurta, jolloin optimaalista huoltoväliä ei ole mahdollista määrittää. Yhdysvaltojen puolustusministeriön datan perusteella vain 11 % vikaantumisista on estettävissä jaksotetulla kunnossapidolla. Jaksotetun kunnossapidon rajoitusten vuoksi sen rinnalle tarvitaan ennustavaa ja kuntoon perustuvaa kunnossapitoa. (Hashemian 2011)

2.1.2 Prosessi

Ennustavan kunnossapidon prosessista erotetaan usein kolme osaa: datan kerääminen, datan käsittely ja kunnossapidon päätöksenteko (Jardine et al. 2006; Heng et al. 2009). Tässä työssä datan keräämistä käsitellään luvussa 3 ja datan käsittelyä luvussa 4. Ton et al. (2020) laajentaa Jardinen et al. mallia viiteen vaiheeseen: datan kerääminen, datan käsittely ja diagnostiikka, prognostiikka, kunnossapidon päätöksenteko ja optimointi sekä tiedon yhdistäminen omaisuudenhallinnan strategiseen suunnitelmaan. Kahden viimeisen vaiheen pohjalta tehdään toimenpiteitä, jotka vaikuttavat datan keräämisen kohteena oleviin järjestelmiin. Näin ollen ennustavan kunnossapidon prosessi on takaisinkytketty ja jatkuvaa kehittämistä tukeva malli. (Ton et al. 2020) Ennustavan kunnossapidon prosessi on kuvattu kuvassa 2.



Kuva 2. Ennustavan kunnossapidon prosessi.

Ton et al. (2020) korostaa myös organisatoristen ja henkilöstöön liittyvien asioiden merkitystä ennustavassa kunnossapidossa. Ne vaikuttavat ennustavan kunnossapidon prosessin jokaisessa vaiheessa, mutta erityisesti päätöksentekovaiheessa tärkeää on järjestelmien käyttäjäkeskeinen suunnittelu. Ton et al. (2020) mukaan ihmisten luottamus ja valmius datan hyödyntämiseen ovat keskeisimpiä haasteita dataan perustuvien kunnossapitojärjestelmien käyttämisessä.

2.2 Älykäs kunnossapito ja teollisuus 4.0

Älykkäällä kunnossapidolla (e-maintenance) viitataan kunnossapitoon, jossa hyödynnetään digitaalisia teknologioita, ja jossa kunnossapito on integroitu yrityksen muihin digitaalisiin prosesseihin. Laajemmassa mielessä käsitteellä voidaan tarkoittaa myös siirtymistä perinteisistä kunnossapitomenetelmistä ja -strategioista uusiin. (Muller et al. 2008) Älykkäällä kunnossapidolla tavoitellaan kilpailukykyä luotettavuuden ja käytettävyyden avulla (Starr et al. 2010, s. 5). Siirtymistä älykkääseen kunnossapitoon ajavat osaltaan kestävä kehitys ja elinkaariajattelun voimistuminen (Starr et al. 2010, s. 23–25). Keskeistä älykkäessä kunnossapidossa on reaaliaikaisen datan hyödyntäminen kunnossapidossa. Älykkästä kunnossapidosta saadaan hyötyjä kunnossapidon strategisella tasolla kunnossapidon suunnittelussa, järjestelmissä ja työkaluissa sekä operatiivisella tasolla lattiataason kunnossapitotehtävissä. (Muller et al. 2008)

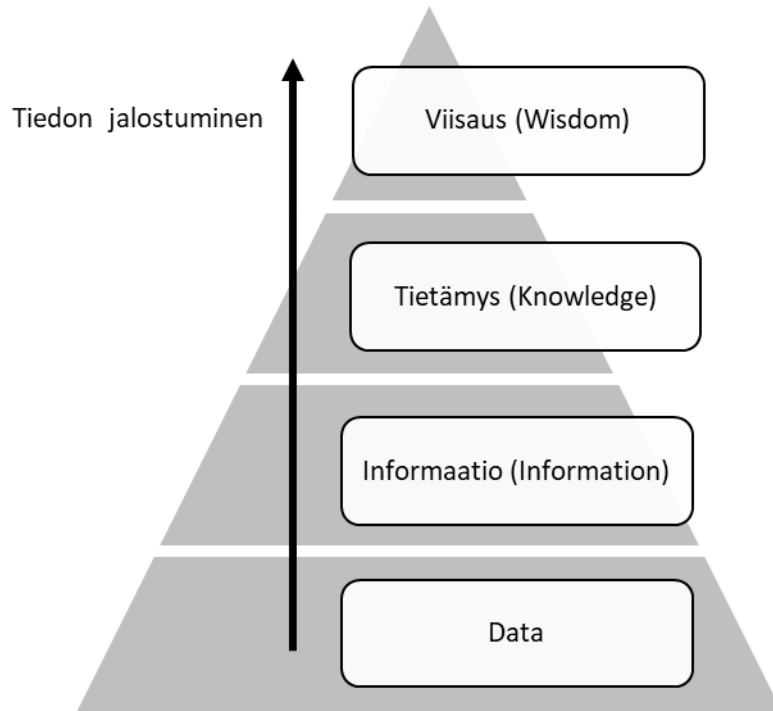
Älykäs kunnossapito ja ennustava kunnossapito ovat yksi teollisuus 4.0:n keskeisistä sovelluksista (Bousdekis et al. 2020). Teollisuus 4.0 tai neljäs teollinen vallankumous tarkoittaa valmistavan teollisuuden muutosta, jota ajaa pääasiassa informaatioteknologian kehitys. Siihen liittyviä tärkeitä konsepteja ovat älykkäät tehtaot, kyberfyysiset järjestelmät, itseohjautuvat ja hajautetut organisaatiot, muutokset toimitusketjujen hallinnassa ja tuotekehityksessä, ihmiskeskeisyys ja vastuullisuus. (Lasi et al. 2014) Teollisuus 4.0:n teknologiat jaetaan usein yhdeksään osa-alueeseen, jotka ovat teollinen internet, big data ja data-analytiikka, järjestelmäintegraatio, simulaatio, pilvipalvelut, lisätty todellisuus, autonomiset robotit, lisäävä valmistus sekä kyberturvallisuus ja kyberfyysiset järjestelmät (Vaidya et al. 2018). Näistä useat ovat keskeisiä myös älykkään kunnossapidon ja ennustavan kunnossapidon kannalta.

3. DATAN LÄHTEET, KERÄÄMINEN JA ESIKÄSITTELY

Ennustavan kunnossapidon perustana on riittävä määrä luotettavaa ja relevanttia dataa. Tässä työssä tarkastellaan dataa, jota voidaan käyttää hyväksi ennustavassa kunnossapidossa. Tämä käsittää kaiken värähtelymittauksista laitteen korjaushistoriaan. Luvussa 3.1 esitellään tiedon eri tasoja kuvaava DIKW-hierarkia. Luvussa 3.2 käsitellään tavanomaisimpia kunnonvalvontamenetelmiä, ja luvussa 3.3 muita datan lähteitä. Luvussa 3.4 käsitellään datan keräämiseen ja esikäsittelyyn liittyviä menetelmiä ja teknologioita.

3.1 DIKW-hierarkia

Tässä työssä käytetään paljon tietoon liittyvää käsitteistöä. Jotta käsitteet olisivat yksiselitteisiä ja johdonmukaisia, hyödynnetään työssä data–informaatio–tietämys–viisaushierarkia eli DIKW-hierarkiaa (Data-Information-Knowledge-Wisdom). DIKW-hierarkiassa tiedon matalinta tasoa kutsutaan dataksi. Datalla tarkoitetaan tässä työssä mittauksista saatavaa tyypillisesti numeerista aineistoa. Dataa voi toisaalta olla myös ei-numeerinen aineisto. Datasta saadaan informaatiota käsittelemällä sitä ihmiselle ymmärrettävään muotoon. Tämän työn aihepiirissä informaatiota ovat esimerkiksi datasta lasketut keskiarvot ja trendikuvaajat. Informaatiosta siirrytään tietämyksen tasolle, kun informaatiota tulkitaan ja tehdään siitä päätelmiä, esimerkiksi todetaan komponentin vikaantumisen. Viisaus on DIKW-hierarkian korkein taso. Viisauden muodostamiseksi hyödynnetään laajasti eri tietolähteitä, kuten aiempia kokemuksia ja heuristiikkaa. Tämän työn aihepiirissä viisautason tietoa on esimerkiksi kunnossapito-ohjelman kehittäminen kokonaisuutta tarkastelemalla. (Martinsuo & Kärri 2017, s.19–20) DIKW-hierarkia on esitetty kuvassa 3.



Kuva 3. DIKW-hierarkia (mukaihen lähteestä Martinsuo & Kärri 2017, s. 19–20).

3.2 Kunnonvalvontamenetelmät

Kunnonvalvonta on tärkeä osa nykyaikaista kunnossapitoa, ja kunnonvalvontamittaukset ovat tärkeä datan lähde ennustavassa kunnossapidossa. SFS-EN 13306:2017 (2017, s. 16) määrittelee kunnonvalvonnan seuraavasti: ”määrätyin välein manuaalisesti tai automaattisesti tehtävä toimenpide, jolla mitataan kohteen fyysisen tilan ominaisuuksia tai arvoja.” Seuraavissa alaluvuissa esitellään yleisimpiä kunnonvalvontamenetelmiä.

3.2.1 Värähtelymittaukset

Liikkuvat koneet tuottavat käydessään mekaanista värähtelyä. Värähtely tarkoittaa jaksollista liikettä tasapainoaseman ympärillä. Liikkuvat koneet synnyttävät värähtelyä myös normaalissa kunnossa ja normaalilla käytöllä, mutta poikkeavat tilanteet voidaan usein havaita värähtelyn muutoksista. Mekaaniset viat, kuten puutteellinen voitelu, laakerien kuluminen, epätasapaino, huonot liitokset ja linjausongelmat, näkyvät tyypillisesti värähtelyn kasvuna. Värähtelymittaukset ovat usein tärkein kunnonvalvontamenetelmä ennustavan kunnossapidon kannalta. (Mikkonen et al. 2009, s. 223–225; Mobley 2014, luku 3.2).

Värähtelymittauksissa käytetään kolmen tyyppisiä antureita: etäisyysanturit (erityisesti liukulaakereille), nopeusanturit ja kiihtyvyydentanturit (Mikkonen et al. 2009, s. 234–241; Mobley 2014, luku 3.2). Pyörivistä laitteista värähtelyä mitataan tyypillisesti laakerien lä-

heisyydestä, esimerkiksi laakeripesän pinnasta (Mobley 2002 s. 121). Värähtelymittauksia voidaan kiinteisiin antureihin perustuvan jatkuvan mittauksen lisäksi suorittaa jaksottaisesti kannettavilla mittalaitteilla (Mikkonen et al. 2009, s. 259–262; Mobley 2014, luku 3.2). Pyörivien laitteiden värähtelymittausdataa käsitellään usein taajuustasossa, ja taajuuksia tutkitaan suhteessa laitteen pyörimisnopeuteen. (Mobley 2002 s. 119–120; Mikkonen et al. 2009, s. 285–286).

3.2.2 Tribologiset menetelmät

Värähtelymittausten ohella toinen merkittävä kunnonvalvontamenetelmien ryhmä ovat tribologiset menetelmät, joissa mitataan voiteluun liittyviä parametreja. Tribologisilla menetelmillä voidaan saada tietoa sekä voiteluaineen kunnosta että voidellun järjestelmän kunnosta. (Mikkonen et al. 2009, s. 428; Mobley 2014, luku 3.4) Voiteluaineen analyysi kertoo alkavasta viasta aikaisemmin kuin useimmat muut kunnonvalvontamenetelmät (Kortelainen et al. 2021, s. 140). Teollisuudessa tyypillisiä tribologisten menetelmien käyttökohteita ovat esimerkiksi vaihteen tai laakerin voitelu. Kunnonvalvonnan lisäksi tribologisista menetelmistä saatavan tiedon avulla voidaan kehittää laitoksen voiteluhuoltoa, esimerkiksi valita parempia voiteluaineita ja optimoida vaihtovälejä. (Mobley 2002, s. 202–203)

Voiteluaineesta voidaan mitata ainakin seuraavia parametreja: viskositeetti, epäpuhtaudet, partikkelien määrä ja hapettumisesta kertovat parametrit kuten TAN (Total Acid Number). Spektrografisilla menetelmillä voidaan tutkia voiteluaineen sisältämiä aineita, ja kulumapartikkeleita tutkimalla voidaan saada tietoa koneen kunnosta. (Mobley 2002 s. 203–207; Mikkonen et al. 2009, s. 249–437) Voiteluaineen analyysia voidaan tehdä joko jatkuvina mittauksina tai öljynäytteisiin perustuvina jaksottaisina testeinä (Mobley 2014, luku 3.4).

3.2.3 Muut kunnonvalvontamenetelmät

Värähtelymittausten ja tribologisten menetelmien lisäksi on lukuisia muita kunnonvalvontamenetelmiä. Muita menetelmiä ovat ainakin lämpötilaan perustuvat menetelmät, akustiset menetelmät, sähkösuureisiin perustuvat menetelmät ja aistihavaintoihin perustuvat menetelmät.

Koneenosan poikkeava lämpötila voi kertoa vikaantumisesta tai epänormaalista ja haitallisesta käynnistä (Mobley 2002, s. 179–180; Pascual 2015, s. 98–99) Lämpökameralla voidaan tarkastaa suuriakin kokonaisuuksia melko nopeasti, ja lämpökamerat sopivat sekä mekaanisten että sähköisten koneiden kunnonvalvontaan (Kortelainen et al. 2021, s. 140). Lämpökuvaus on yksi tyypillisimmistä manuaalisesti suoritettavista kunnonvalvontamenetelmistä, mutta sitä on datan luonteen (lämpökamerakuvat) vuoksi vaikea

hyödyntää laskennallisissa menetelmissä. Lämpötilaa voidaan mitata myös antureilla jatkuvana kunnonvalvontana, jolloin dataa voidaan hyödyntää myös laskennallisissa menetelmissä. (Moblely 2014, luku 3.3)

Akustisessa emissiossa mitataan materiaalin rakenteen synnyttämää korkeataajuisia elastista värähtelyä. Värähtely syntyy kuormituksessa olevan rakenteen poikkeamista, kuten särön kasvusta tai muodonmuutoksesta, tai esimerkiksi kavitaatiosta tai kitkasta. (SFS-EN 13554:2011 2011, s. 4–5; Pascual 2015, s. 123–127)

Sähkömoottoreista voidaan mitata ja analysoida virtasignaalia. Mittauksia voidaan tehdä joko kannettavilla mittalaitteilla tai kiinteillä mittausjärjestelmillä. (Mikkonen et al. 2009, s. 386)

Tärkeä osa kunnonvalvontaa ovat myös ihmisaistein suoritettavat havainnot. Aisteista käytössä ovat ainakin kuulo-, näkö-, haju- ja tuntoaisti. Ihmisaistein voidaan havaita monipuolisesti koneen kunnosta kertovia indikaattoreita, joskin tämä tyypillisesti edellyttää ammattitaitoa ja kokemusta. Aistihavaintojen tukena voidaan käyttää myös laitteita, kuten stroboskooppia. (Mikkonen et al. 2009, s. 418–423)

3.3 Muut datan lähteet

Kunnonvalvontadatan lisäksi konejärjestelmien vikaantumisen ennustamiseen voidaan hyödyntää myös muuta dataa. Tässä työssä käsiteltävä data voidaan jakaa kahteen tyyppiin: reaaliaikaiseen prosessidataan ja tilastolliseen dataan. Prosessidatalla tarkoitetaan kaikkea järjestelmän senhetkisestä toiminnasta ja kunnosta kertovaa dataa, kuten kunnonvalvontadataa tai mittaus- ja ohjausdataa. Tilastollisella datalla taas tarkoitetaan järjestelmän historiasta kertovaa dataa, kuten vika- ja huoltohistoriaa. On hyvä huomata, että tilastollista dataa tarkastellaan usein populaatiotasolla, esimerkiksi tietyn konetyypin kaikkia koneita, kun taas prosessidata on aina järjestelmäkohtaista. (Kortelainen et al. 2021, s. 158–159)

Prosessidataa saadaan kunnonvalvonnan lisäksi esimerkiksi ohjaus- ja automaatiojärjestelmistä. Prosessidata voi kuvata tuotantoprosessin tai ympäristön tilaa, esimerkiksi lämpötilojen tai ilmankosteusarvojen muodossa. Prosessidata voi myös kertoa järjestelmän käytöstä ja kuormituksessa, esimerkiksi ohjausdatana. (Ahonen & Reunanen 2009)

Tärkeä datatyyppi on tieto vikaantumisista ja tehdyistä kunnossapitotoimenpiteistä. Tätä voidaan kutsua myös tapahtumadatakksi. Tapahtumadata sisältää esimerkiksi tietoja vikaantumisten ajankohdista ja tyypeistä, sekä tehtyjen kunnossapitotoimenpiteiden ajan-

kohdista ja tyypeistä. Myös staattista perustietoa järjestelmästä, kuten mallityyppi, asennustiedot ja keskeiset komponentit, voidaan hyödyntää. (Ahonen & Reunanen 2009; Microsoft 2021)

3.4 Datan kerääminen ja esikäsittely

Dataa syntyy monista lähteistä ja sitä kerätään tyypillisesti useisiin tietojärjestelmiin tai tietokantoihin. Datan hyödyntämisessä tärkeää on datan esikäsittely, ja eri lähteistä tulevan datan yhdistäminen.

3.4.1 Teollisuuden tietojärjestelmät ja teollinen internet

Teollisuudessa käytetään useita tietojärjestelmiä, joihin tässä luvussa käsiteltäviä dataa tallennetaan. Näitä ovat esimerkiksi toiminnanohjausjärjestelmä (Enterprise Resource Planning, ERP), suunnittelujärjestelmät (esimerkiksi Product Data Management, PDM) sekä automaatio- ja prosessinohjausjärjestelmät. Kunnossapitoon liittyviä tietojärjestelmiä ovat esimerkiksi kunnossapidon tietojärjestelmä (Computerized Maintenance Management System, CMMS), tuotanto-omaisuuden hallintajärjestelmä (Enterprise Asset Management, EAM) tai toiminnanohjausjärjestelmän kunnossapitomoduli. Tyypillisesti myös kunnonvalvontadataa tallennetaan eri tietojärjestelmiin. Tärkeää on, että eri järjestelmät pystyvät vaihtamaan tietoa keskenään, ja niiden dataa voidaan yhdistellä analyysiä varten. (Kortelainen et al. 2021, s. 129–130)

Teollinen internet on yksi teollisuus 4.0:an liitetyistä konsepteista, jolla tarkoitetaan teollisuuden fyysisten laitteiden yhdistämistä internettiin ja edelleen erilaisiin älykkäisiin sovelluksiin. Teollisella internetillä on keskeinen rooli tuotantolaitoksesta tulevan datan keräämisessä, siirtämisessä, prosessoinnissa ja tallentamisessa. (Boyes et al. 2018) Bradicichin (2018) esittelemän IoT-mallin (Internet of Things, esineiden internet) mukaisesti kerätty data siirretään ja tallennetaan internetin avulla palvelimelle, tyypillisesti pilvipalvelimelle. Mallissa olennaista on reunalaskenta (edge computing) eli toimenpiteiden, esimerkiksi datan esikäsittelyn, suorittaminen paikallisen tiedonsiirron ja internetin rajapinnassa. Tällä saavutetaan muun muassa pienempi viive ja palvelimelle tallennettavan datan pienempi koko. (Bradicichi 2018)

3.4.2 Datan esikäsittely ja yhdistäminen

Datan esikäsittelyn merkitystä korostetaan usein lauseella ”garbage in, garbage out” eli ”roskaa sisään, roskaa ulos.” Lause tarkoittaa, että dataa on tärkeä esikäsitellä ennen kuin se syötetään sitä hyödyntävään järjestelmään, esimerkiksi tekoälyalgoritmiin. Antu-

reilta ja muista mittauksista saatava data sisältää usein häiriötä, virheitä ja epätäydellisyyttä. Data voi olla myös väärässä muodossa käsittelyä varten. (Larose & Larose 2015, s. 20–21)

Edellä mainittujen ongelmien korjaamista kutsutaan datan siivoamiseksi. Puuttuvaa dataa voidaan esimerkiksi korvata viereisistä arvoista lasketulla arviolla. (Pecht & Kang 2018, s. 111–114) Poikkeavia havaintoja, eli muista havainnoista epänormaalin kaukana olevia havaintoja voidaan puhdistaa graafisilla tai numeerisilla menetelmillä. Ilman puhdistusta poikkeavat havainnot voivat helposti vääristää analyysin tulosta. Tyypillisesti eri datalähteiden mitta-asteikot ovat erilaiset, jolloin data täytyy normalisoida. Datan normalisointi tarkoittaa datan muokkaamista niin, että kaikki arvot ovat samalla asteikolla. Erilaisia normalisointimenetelmiä ovat esimerkiksi min–max-normalisointi ja Z-arvo-normalisointi. (Larose & Larose 2015, s. 22–27, 30–31, 38–39)

Teollista internettiä hyödyntävässä järjestelmässä datan esikäsittely tapahtuu usein reunalaskentana. Data siis esikäsitellään ennen kuin se tallennetaan palvelimelle. Tämä on tärkeää, sillä raaka data vaatisi huomattavasti enemmän tallennustilaa ja tiedonsiirtokapasiteettia kuin esikäsitelty data. Datasta voidaan siivoamisen ja normalisoinnin lisäksi laskea tunnuslukuja, kuten tehollis- tai huippuarvoja, ja tallentaa ainoastaan näitä palvelimelle. Tärkeää on myös optimoida datan säilyttämisaikaa. (Compare et al. 2020)

Datalähteitä on usein tarve yhdistää paremman tarkkuuden saavuttamiseksi datafuusion (data fusion) avulla. Dataa voidaan yhdistää datatasolla, piirretasolla tai päätöstasolla. Datatasolla yhdistetään esimerkiksi antureista saatavaa samantyyppistä raakadataa, kuten usean värähtelyanturin mittausdataa. Piirretasolla yhdistetään raakadatasta johdettuja piirteitä (features) (piirteistä enemmän luvussa 4.5). Edellisistä poiketen päätöstason yhdistämisessä yksittäisiä datan lähteitä yhdistetään vasta päätöksentekovaiheessa, hyödyntäen esimerkiksi lineaarisia regressiomalleja. (Wei et al. 2021) Tyypillisesti hyödynnettävä data on sekä kvantitatiivista (esimerkiksi kunnonvalvontadata) että kvalitatiivista (esimerkiksi asiantuntijan erityistietämys). Näitä datalähteitä voidaan yhdistää esimerkiksi niin, että datapohjaista analyysia tulkitaan tai muokataan asiantuntija-arvion perusteella. (Kortelainen et al. 2021, s.143–144)

4. DATAN HYÖDYNTÄMINEN VIKAANTUMISEN ENNUSTAMISESSA

Konejärjestelmän vikaantumisen ennustamiseen datan avulla voidaan käyttää erilaisia menetelmiä. Vikaantumisen ennustamisesta käytetään usein sanaa prognostiikka, jota käsitellään luvussa 4.1. Datat hyödyntämisen menetelmät eli prognoosimenetelmät voidaan jakaa karkeasti tietopohjaisiin, fysiikkapohjaisiin, datapohjaisiin ja näiden yhdistelmiin (Peng et al. 2010; Pecht & Kang 2018, s. 596–597; Zonta et al. 2020) Tietopohjaisia menetelmiä käsitellään luvussa 4.2, fysiikkapohjaisia luvussa 4.3, datapohjaisia luvussa 4.4 ja yhdistettyjä luvussa 4.5. Kuvassa 4 on esitetty yhteenveto menetelmistä ja niiden eduista ja rajoituksista.

	Toiminta	Edut	Rajoitukset
Tietopohjaiset	<ul style="list-style-type: none"> Perustuu erityistietämykseen järjestelmästä 	<ul style="list-style-type: none"> Yksinkertainen 	<ul style="list-style-type: none"> Edellyttää erityistietämystä Skaalautuu huonosti
Fysiikkapohjaiset	<ul style="list-style-type: none"> Perustuu matemaattisiin kuvauksiin järjestelmän fysikaalisista ominaisuuksista 	<ul style="list-style-type: none"> Potentiaalisesti tarkka Kuvaava ja läpinäkyvä 	<ul style="list-style-type: none"> Edellyttää erityistietämystä Skaalautuu huonosti Mallin kehittäminen haastavaa
Datapohjaiset	<ul style="list-style-type: none"> Perustuu järjestelmästä saatavaan dataan 	<ul style="list-style-type: none"> Ei vaadi tietoa fysikaalisista ominaisuuksista Skaalautuu hyvin 	<ul style="list-style-type: none"> Riippuvainen datan laadusta ja määrästä
Yhdistetyt	<ul style="list-style-type: none"> Yhdistää tieto-, fysiikka- ja datapohjaisia menetelmiä 	<ul style="list-style-type: none"> Puutteita datassa voidaan paikata erityistietämyksellä ja toisinpäin 	<ul style="list-style-type: none"> Yksittäisten menetelmien mukana tulevat rajoitukset

Kuva 4. Yhteenveto prognoosimenetelmistä.

4.1 Prognostiikka

Prognostiikalla tarkoitetaan ennusteen laatimista eli jonkin asian tulevan kehityksen arviointia. Kunnossapidon analyysissä erotetaan tyypillisesti diagnostiikka ja prognostiikka. Diagnostiikalla tarkoitetaan järjestelmän senhetkisen kunnan arviointia, tai vikaantumisen jälkeistä vikaantumistavan ja -syiden selvittämistä. Prognostiikassa pyritään ennustamaan järjestelmän kunnan kehittymistä. Prognostiikan tulos eli prognoosi ilmaistaan tyypillisesti tarkasteltavan kohteen jäljellä olevana käyttöikänä eli RUL-lukuna (remaining

useful life). (Lee et al. 2014) DIKW-hierarkian mukaisilla käsitteillä prognoosi on datasta ja informaatiosta jalostettua tietämystason tietoa. Prognostiikka on yksi ennustavan kunnossapidon haastavimmista osa-alueista, jonka kehitys on olennaista koko alan kehityksen kannalta (Elattar et al. 2016).

Jardine et al. (2006) käsittelevät prognostiikan tunnuslukuja. RUL-luvun sijaan tunnusluvuksi ehdotetaan todennäköisyyttä sille, että järjestelmä toimii vikaantumatta määrättyyn ajanhetkeen saakka, esimerkiksi seuraavan tarkastusintervallin yli. Tämä tunnusluku voisi olla RUL-lukua parempi käytännön kunnossapidon kannalta. (Jardine et al. 2006) Elattarin et al. (2016) mukaan ennusteen tulisi sisältää useita RUL-lukuja erilaisille vikaantumistyypeille ja tietoa niihin liittyvästä epävarmuudesta. Prognostiikassa on tärkeää tarkastella ennusteisiin liittyvää epävarmuutta, jotta ennusteet olisivat käyttökelpoisia ja merkityksellisiä (Elattar et al. 2016; Pecht & Kang 2018, s. 193–196).

4.2 Tietopohjaiset menetelmät

Tietopohjaiset prognoosimenetelmät perustuvat erityistietämykseen tarkasteltavasta järjestelmästä. Tämä asiantuntijatieto voidaan joko ohjelmoida tietokoneeseen tai hyödyntää sitä manuaalisessa analyysissä. Tyypillisesti kunnonvalvontajärjestelmiä myyvät yritykset tarjoavat myös ohjelmistoja, joilla dataa voidaan käsitellä ja visualisoida. Esimerkkejä käytettävistä työkaluista ovat trendien tutkiminen ja vertaileva analyysi (Moblely 2002, s. 161–165). Värähtelymittausdataa voidaan myös esittää taajuustasossa ja päätellä taajuusspektristä erilaisia vikamuotoja (Moblely 2002, s. 285–288). Näitä työkaluja hyödyntämällä asiantuntija havaitsee järjestelmän kunnosta kertovat merkit ja laatii ennusteen kunnon kehityksestä. Tällainen asiantuntija-analyysi perustuu vahvasti järjestelmäkohtaiseen tietämykseen ja kokemukseen. DIKW-hierarkian mukaisilla tiedon tasoilla datan käsittelyssä ja visualisoinnissa on kyse datan muuttamisesta informaatioksi. Tietopohjaisia menetelmiä voidaan myös käyttää osana useita menetelmiä yhdistäviä malleja (Zonta et al. 2020).

Asiantuntijajärjestelmät (expert systems) ovat yksi tekoälyn alalaji. Asiantuntijajärjestelmä toimii siihen ohjelmitujen sääntöjen mukaan, ja sitä voikin kuvailla järjestelmään tallennetuksi asiantuntijatiedoksi. Asiantuntijajärjestelmä voi toimia esimerkiksi JOS–NIIN-tyyppisten päättelysääntöjen mukaan. Asiantuntijajärjestelmän rakentaminen vaatii hyvää ymmärrystä tarkasteltavasta kohteesta. Se on myös staattinen järjestelmä, johon tarkasteltavan kohteen muutokset on päivitettävä manuaalisesti. (Peng 2010)

4.3 Fysiikkapohjaiset menetelmät

Fysiikkapohjaisissa menetelmissä hyödynnetään tarkkoja matemaattisia kuvauksia tarkasteltavan järjestelmän fysikaalisista ominaisuuksista. Fysiikkapohjaisia menetelmiä voidaan luonnehtia myös niin sanotuiksi white-box-menetelmiksi. Käsitteellä tarkoitetaan mallia, joka on läpinäkyvä, eli sen toiminta perustuu ihmiselle ymmärrettäviin sääntöihin, usein fysiikan lakeihin. (Pascual 2015, s. 7–8) Usein fysiikkapohjaisia menetelmiä käytetään osana yhdistettyä mallia (Zonta et al. 2020).

Fysiikkapohjaiset mallit voivat olla hyvin tehokkaita ja kuvaavia, sillä ne perustuvat täsmällisiin fysiikan lakeihin. Hyvällä mallilla voidaan myös päästä tarkkoihin tuloksiin. Fysiikkapohjaisten mallien keskeinen etu on, että ne eivät vaadi yhtä paljoa dataa kuin datapohjaiset menetelmät (Heng et al. 2009). Mallit ovat kuitenkin haastavia rakentaa ja laskennallisesti vaativia. Mallit vaativat järjestelmien fysikaalisten ominaisuuksien ja riippuvuuksien tuntemusta, jota ei ole aina saatavilla. (Elattar et al. 2016) Lisäksi todelliset järjestelmät ovat usein hyvin stokaistisia, eli satunnaisuudella on niissä suuri merkitys, jolloin niiden mallintaminen voi olla liian monimutkaista (Heng et al. 2009). Fysiikkapohjaiset mallit ovat laite- tai komponenttikohtaisia, joka rajoittaa niiden laajempaa käyttöön-ottoa. (Elattar et al. 2016)

Jotta järjestelmän kuntoa ja jäljellä olevaa käyttöikää voidaan arvioida fysikaalisilla perusteilla, laskentamallissa täytyy olla kuvauksia vaurioiden etenemisestä järjestelmän komponenteissa. Yksi tärkeimmistä tarkasteltavista komponenteista on vierintälaakeri. Vierintälaakerien vaurioitumista voidaan ennustaa esimerkiksi särön kasvua kuvaavalla Paris'n lailla. Fysiikkapohjaisissa malleissa käytettäviä vaurioiden syntymistä ja etenemistä kuvaavia yhtälöitä ja lakeja on lukuisia. (El-Thalji & Jantunen 2015)

Fysiikkapohjaisiin menetelmiin sisältyy myös digitaalisen kaksosen hyödyntäminen. Digitaalisella kaksosella tarkoitetaan fyysisen järjestelmän virtuaalista vastinetta (Grieves 2014). Aivaliotis et al. (2019) esittävät erään menetelmän digitaalisen kaksosen hyödyntämiseen ennustavassa kunnossapidossa. Menetelmän perusajatus on, että fyysisen järjestelmän kunnonvalvonnan lisäksi dataa tuotetaan digitaalisella kaksosella virtuaalisten antureiden ja simulaation avulla. Hyödyntämällä molempien lähteiden dataa sekä analyysityökaluja lasketaan RUL-luku. Olennaisena osana artikkelin menetelmään kuuluu myös digitaalisen kaksosen jatkuva säätäminen ja parantaminen fyysisestä järjestelmästä saatavan datan pohjalta. (Aivaliotis et al. 2019)

4.4 Datapohjaiset menetelmät

Datapohjaisten menetelmien toiminta perustuu täysin dataan, jolloin tarkasteltavan järjestelmän fysikaalisia ominaisuuksia ei ole tarpeen mallintaa (Heng et al. 2009). Datapohjaiset menetelmät hyödyntävät sekä tekoälytekniikoita että tilastollisia menetelmiä (Elattar et al. 2016). Datapohjaisten menetelmien kehitystä ovat tukeneet edistykset tietojenkäsittelyssä ja saatavilla olevan datamäärän kasvu (Susto et al. 2015; Yan et al. 2017). Datapohjaisia menetelmiä käytetäänkin fysiikkapohjaisia menetelmiä enemmän (Elattar et al. 2016). Datapohjaisia menetelmiä voidaan luokitella usealla tavalla. Tässä työssä jako on tehty käytetyn teknologian perusteella tilastollisiin ja koneoppimisen malleihin sekä mallin tyyppin mukaan regressio- ja luokittelumalleihin.

4.4.1 Koneoppiminen

Koneoppimisella tarkoitetaan tekoälytekniikoita, joissa tietokone opetetaan tunnistamaan datasta kuvioita ja ilmiöitä itsenäisesti. (Kortelainen et al. 2021, s. 172) Koneoppiminen on keskeinen menetelmä vikaantumisen ennustamisessa. Sitä voidaan hyödyntää datapohjaisissa menetelmissä sekä osana yhdistettyjä menetelmiä.

Koneoppimisalgoritmi tarkoittaa menetelmää, jolla koneoppimisjärjestelmä käsittelee dataa. Koneoppimisalgoritmit voidaan jakaa kolmeen ryhmään: ohjattuun oppimiseen (supervised learning), ohjaamattomaan oppimiseen (unsupervised learning) ja vahvistusoppimiseen (reinforcement learning). Ohjatuilla algoritmeilla mallin opettaminen tapahtuu ohjatusti, eli mallille annetaan lähtötiedot ja lopputulokset, jolloin malli pyrkii löytämään tavan päästä annetuista lähtötiedoista tunnettuihin lopputuloksiin. Näitä tietoja kutsutaan harjoitusdataksi, joka kunnossapidon sovelluksissa on vikaantumisdataa järjestelmästä. Jos vikaantumisdataa ei ole saatavilla, on käytettävä ohjaamattomia algoritmeja. Ohjaamattomat algoritmit pyrkivät tunnistamaan datasta kuvioita ja hahmoja ottamatta kantaa siihen, onko näillä löydöillä yhteyttä reaali maailman ilmiöihin, kuten järjestelmän vikaantumiseen. Vahvistusoppimisessa algoritmi taas tarkkailee jatkuvasti mallin ja ympäristön vuorovaikutusta, ja optimoi mallia sen pohjalta. Vahvistusoppimisessa siis toteutetaan oppimis- ja käyttövaihe samaan aikaan, kun taas ohjatussa oppimisessa mallia ensin opetetaan ja sitten käytetään. (Susto et al. 2015; Lee et al. 2018)

Ohjattujen ja ohjaamattomien algoritmien ero on tärkeä, sillä datapohjaisten menetelmien toimivuuden kannalta riittävä määrä oikeanlaista dataa on välttämätöntä. Jos tuotantolaitoksessa on esimerkiksi hyödynnetty laajasti ehkäisevää kunnossapitoa, ei vikaantumisdataa ole välttämättä saatavissa. Tällöin ei voida hyödyntää koneoppimisen ohjattuja menetelmiä, vaan on käytettävä ohjaamattomia menetelmiä. Yksi ohjaamattomien algoritmien sovelluksista on poikkeuksien havaitseminen (anomaly detection)

(Pascual 2015, s. 157). Siinä pyritään tunnistamaan datan tyypillisistä arvoista tai trendeistä poikkeavat havainnot. Nämä poikkeamat kertovat usein järjestelmän kunnosta ja käytöstä. (Pascual 2015, s. 149–151)

Yksi koneoppimisen alatyyppeistä on syväoppiminen, joka tarkoittaa neuroverkkoja hyödyntävää koneoppimista. Neuroverkot ovat ihmisaivojen toimintaa jäljitteleviä algoritmeja, jotka muodostuvat toisiinsa kytketyistä solmukohtista eli neuroneista. Neuroverkko muodostuu useista kerroksista, joista ensimmäiseen syötetään sisääntulodataa ja viimeisestä luetaan ulostulo. Näiden välissä voi olla ns. piilokerroksia, jotka käsittelevät dataa. Kuten muihinkin koneoppimisalgoritmeihin, neuroverkkoihin voi kuulua painokertoimia ja biasvakioita, jotka algoritmi ohjatussa oppimisessa pyrkii ratkaisemaan. (Lee et al. 2018)

4.4.2 Tilastolliset mallit

Tilastolliset mallit käyttävät tilastomatematiikkaa ja todennäköisyyslaskentaa ennusteen laatimiseen. Koska järjestelmien vikaantumiseen liittyy satunnaisuutta, ovat ennustavassa kunnossapidossa käytetyt tilastolliset mallit tyypillisesti stokastisia eli satunnaistekijöitä sisältäviä (Kortelainen et al. 2021, s. 163–164). Esimerkkejä tyypillisistä menetelmistä ovat autoregressio ja eksponentiaaliset liikkuvat keskiarvot (Heng et al. 2009).

Elattar et al. (2016) kutsuvat tilastollisia, historiadataa hyödyntäviä malleja luotettavuuspohjaisiksi menetelmiksi. Heidän esittämässään mallissa historiadatasta lasketaan MTBF-aika (Mean Time Between Failures) eli keskimääräinen vikaantumisten välinen aika, jota voidaan hyödyntää kunnossapidon aikatauluttamiseen ja suunnitteluun. MTBF-ajan laskemiseen käytetään tilastollisia työkaluja, kuten weibull-jakaumaa. Tällainen menetelmä sopii erityisesti vähemmän kriittisille konejärjestelmille, joista ei ehkä kerätä kunnonvalvontadataa. On myös hyödyllistä, jos kohde on massatuotettu, jolloin tilastollista dataa on paremmin saatavilla. (Elattar et al. 2016)

4.4.3 Luokittelu- ja regressiomallit

Datapohjaisia menetelmiä voidaan luokitella myös niiden ulostulojen tyyppien perusteella. Tässä luvussa esitellään jako luokittelu- ja regressiomalleihin.

Regressioanalyysissä tutkitaan kahden tai useamman muuttujan suhdetta. Analyysissä pyritään selittämään vastemuuttujan arvo yhden tai useamman selittävän muuttujan avulla. Ennustavassa kunnossapidossa vastemuuttuja on tyypillisesti RUL-luku, ja selittävät muuttujat esimerkiksi kunnonvalvontadataa tai järjestelmän käyttömääriä. Regressiomalleja on lukuisia erilaisia, joista yksinkertaisin on tavanomainen lineaarinen regressio, mutta myös edistyneempiä malleja, kuten polynomiregressiota tai k-NN-algoritmia

(k-Nearest Neighbours), voidaan käyttää. Regressiomalleissa voidaan käyttää koneoppimiselle ominaisia painokertoimia ja bias-vakiota. (Pecht & Kang 2018, s. 178–185) Regressiomallien lopputuloksena on todennäköisin RUL-luku ja ennusteeseen liittyvä epävarmuus.

Luokittelumallien ulostulo on datalle määritetty luokka. Esimerkki binaarisesta luokittelusta on järjestelmän luokittelu joko vialliseksi tai ehjäksi. Vaihtoehtoinen binaarinen luokittelu on luokittelu tarkastelujakson aikana todennäköisesti vikaantuvaksi tai todennäköisesti ei vikaantuvaksi. Moniluokkaisessa luokittelussa mahdollisia luokkia on enemmän kuin kaksi, esimerkiksi luokka jokaiselle vikamuodolle. Luokittelumallit laskevat todennäköisyyden, jolla tarkasteltava järjestelmä kuuluu kuhunkin luokkaan. Ulostulona annetaan todennäköisin luokka. Luokittelussa voidaan käyttää tilastollisia ja koneoppimisen malleja, sekä ohjattuina että ohjaamattomina. Ohjaamattomia menetelmiä kutsutaan usein rypästämiseksi tai klusteroinniksi (clustering), sillä niissä dataa ”rypästetään” yhteen luokkien muodostamiseksi ottamatta kantaa näiden luokkien yhteydestä reaali maailman ilmiöihin, kuten vikaantumiseen. (Pascual 2015, s. 334–336)

4.4.4 Mahdollisuudet ja haasteet

Suoraan järjestelmän vikaantumisesta kertovia parametrejä on usein hyvin vaikea mitata. Datapohjaisilla menetelmillä voidaan kuitenkin etsiä epäsuoria yhteyksiä vikaantumisen ja mitattavien parametrien välillä, erityisesti tiedonlouhinnan (data mining) työkalut sopivat tähän. (Elattar et al. 2016) Nämä epäsuorat yhteydet eivät aina ole kausaalisesti selkeitä, ja niiden löytäminen voi olla ihmiselle vaikeaa. (Yan et al. 2017)

Datapohjaisten menetelmien yksi etu on, että sen toteuttaminen ei vaadi järjestelmäkohtaista erityistietämystä. Tämä tarkoittaa myös sitä, että datapohjaista menetelmää on helppo soveltaa erilaisiin kohteisiin, eikä sitä ole tarvetta räätälöidä järjestelmäkoh-taiseksi. Datapohjaiset menetelmät voivat kuitenkin olla laskennallisesti raskaita, mutta tähän voidaan vaikuttaa paljon algoritmien suunnittelulla. (Elattar et al. 2016)

Yksi datapohjaisten menetelmien haaste on riittävän ja relevantin datan saatavuus. Datapohjaiset mallit toimivat parhaiten, jos niitä voidaan harjoittaa vikaantumisesta kertovalla datalla. Tällaista dataa voidaan hankkia ajamalla järjestelmiä vikaantumiseen saakka joko tuotantokäytössä tai testiympäristössä. Tuotantokäytössä tämä on harvoin toivottavaa, ja datan hankkiminen testiympäristössä on kallista ja aikaa vievää. (Elattar et al. 2016) Vikaantumisdataa voidaan hankkia myös fysiikkapohjaisia menetelmiä käyttäen (Aivaliotis et al. 2019). Muita datapohjaisiin menetelmiin liittyviä haasteita ovat ai-

nakin kunnossapitotoimenpiteiden, erityisesti epätäydellisen kunnossapidon, vaikutuksen huomioon ottaminen (Heng et al. 2009) sekä fleet-tason järjestelmien kehittäminen (Elattar et al. 2016).

4.5 Yhdistetyt menetelmät

Kaikissa kolmessa edellä mainituissa menetelmissä, tietopohjaisessa, fysiikkapohjaisessa ja datapohjaisessa on rajoituksia ja huonoja puolia. Käyttämällä yhdistettyjä menetelmiä voidaan päästä yksittäistä menetelmää parempaan lopputulokseen. Fysiikkapohjaisella mallinnuksella voidaan korvata puutteita datassa, ja toisaalta datapohjaisilla algoritmeilla voidaan paikata puutteellista ymmärrystä järjestelmän fysikaalisista ominaisuuksista. Yhdistetyllä menetelmällä ei kuitenkaan päästä eroon yksittäisiin menetelmiin liittyvistä rajoitteista, kuten tieto- ja fysiikkapohjaisten mallien järjestelmäkohtaisuudesta. (Elattar et al. 2016; Pecht & Kang 2018, s. 80–81) Yhdistettyjen mallien suosio onkin kasvanut jo jonkin aikaa (Peng 2010; Pecht & Kang 2018, s. 81).

Datapohjaisia menetelmiä voidaan hyödyntää yhdistetyn mallin useissa eri vaiheissa. Esimerkiksi Pecht ja Kang (2018, s. 23–24) kuvaavat mallin, jossa datapohjaisia algoritmeja, kuten PCA:ta (Principal Component Analysis) käytetään ensimmäiseksi tunnistamaan piirteitä (features) datasta. Piirteiden hakeminen datasta (feature engineering) on usein keskeinen osa prosessia. Sillä tarkoitetaan datan yksinkertaistamista mallien kannalta relevanteiksi piirteiksi (Pecht & Kang 2018, s. 116). Datapohjaisilla menetelmillä voidaan myös havaita poikkeamia datasta. Fysiikkapohjaisia vikaantumismalleja ja datapohjaisia menetelmiä, esimerkiksi Markovin piilomalli (hidden Markov model), käytetään yhdessä ennustamaan tarkastellun parametrin kehitystä. Historiadataa, standardeja ja tietoa järjestelmästä hyödynnetään vikamuodon tunnistamisessa. Pecht ja Kang ehdottavat myös, että käytettävät fysiikkapohjaiset vikaantumismallit valitaan vikaantumismallien tietokannasta datan perustella. Tällöin malli siis tunnistaa ja priorisoi todennäköisimpiä vikaantumismalleja kussakin tilanteessa. (Pecht & Kang 2018, s. 23–24)

Matyas et al. (2017) esittävät mallin, jossa työstökoneen RUL-luku lasketaan kunnonvalvontadatan, tuotantosuunnitelman, työstökoneen PLC-ohjausdatan ja laatudatan pohjalta. Mallissa hyödynnetään sekä datapohjaisia menetelmiä että fysiikkapohjaisia kulumismalleja. Laatudataa hyödynnetään etsimällä yhteyksiä laatuvariaatioiden ja vikaantumisten välillä. (Matyas et al. 2017)

5. TAPAUSTUTKIMUS

Tapaustutkimuksessa haastateltiin Yara Suomen Uudenkaupungin toimipisteen tarkastus- ja luotettavuuspäällikköä Mikko Kiviluomaa tehtaan kunnossapidosta erityisesti datan hyödyntämisen näkökulmasta. Haastattelu suoritettiin puolistrukturoidusti, ja aihe oli hieman työn aihetta laajempi.

5.1 Yrityksen ja haastateltavan esittely

Yara on maailmanlaajuinen lannoitteiden, teollisuuskemikaalien ja ympäristönsuojelutuotteiden toimittaja. Yaran pääkonttori sijaitsee Norjassa, mutta toimipaikkoja on yli 60 maassa. Suomessa Yaralla on kolme tuotantolaitosta Uudessakaupungissa, Siilinjärvellä ja Kokkolassa, jotka työllistävät yhteensä noin 900 henkilöä. (Yara 2021)

Tämän tutkimuksen kohteessa Uudenkaupungin tehtaalla valmistetaan pääasiassa lannoitteita ja typpihappoa. Typpihappoa sekä käytetään raaka-aineena lannoitetuotannossa että myydään suoraan teollisuuteen. Lannoitteen tuotantokapasiteetti on noin 1 300 000 tonnia vuodessa ja typpihapon noin 500 000 tonnia vuodessa. Lannoitteiden ja typpihapon lisäksi tuotetaan pienempiä määriä kemikaaleja teollisuuskäyttöön. Pääosa tuotetusta lannoitteesta menee vientiin. Typpihapon tuotannossa syntyy sivutuotteena energiaa, jota hyödynnetään sekä tehtaalla että kaupungin kaukolämpöverkossa. (Yara 2021)

Tapaustutkimusta varten haastateltu Mikko Kiviluoma toimii Uudenkaupungin tehtaan tarkastus- ja luotettavuuspäällikkönä. Hänen työtehtäviinsä kuuluvat tehtaan ehkäisevän kunnossapidon asiat eli ennakkohuolto ja kunnonvalvonta. Kiviluoma toimii myös esimiehenä tehtaan ennakkohuoltoasentajille, jotka vastaavat ennakkohuoltotöiden ja kunnonvalvontamittausten suorittamisesta.

5.2 Tuotantolaitoksen kunnossapito

Kunnossapito työllistää merkittävän osan tehtaan henkilöstöstä ja siihen kuuluu myös omaa korjaamotoimintaa. Oman henkilöstön lisäksi kunnossapitoa tekevät ulkopuoliset toimittajat. Tehtaan kunnossapito painottuu muutaman viikon välein pidettäviin huolto- ja puhdistusseisakkeihin sekä vuosittain pidettävään laajempaan seisakkiin. (Kiviluoma, haastattelu 15.11.2021)

Tehtaalla on käytössä laajat jaksotetun kunnossapidon ennakkohuolto-ohjelmat, joihin kuuluu esimerkiksi rasvauksia, öljynvaihtoja, puhdistuksia, tarkistuksia ja ennaltaehkäiseviä komponenttien vaihtoja. Lisäksi tehtaalla suoritetaan aistivaraisia tarkastuskierroksia, joissa tarkastetaan koneiden yleiskunto ja siisteys. Kierroksilla käytetään myös lämpökameraa. Tarkastuskierrosten ja normaalien käyttötoimenpiteiden aikana tehdyt havainnot ovat tärkeä osa tehtaan ehkäisevää kunnossapitoa. (Kiviluoma, haastattelu 15.11.2021)

Kunnonvalvontaa tehtaalla tehdään sekä jatkuvina mittauksina että jaksottaisina mittauksina. Tärkein kunnonvalvontamenetelmä ovat värähtelymittaukset. Jaksottaiset värähtelymittaukset ovat kolmen kuukauden välein suoritettavia mittauskierroksia kannettavaa mittalaitetta käyttäen. Jaksottaisten mittausten piirissä on pääasiassa suuria ja keskisuuria sähkömoottoreita ja niihin liitettyjä laitteita, kuten vaihteita ja pumppuja. (Kiviluoma, haastattelu 15.11.2021)

Jatkuvaa mittausta tehdään tehtaan suurimmille ja kriittisimmille laitteille, eli rummuille ja turbiinijunille. Rummuista mitataan moottorin, vaihteen ja kantopyörien värähtelyä. Turbiinijuniin kuuluvista laitteista, turbiineista, generaattoreista, vaihteista ja kompresso-reista mitataan värähtelyn lisäksi lämpötiloja ja roottorin aksiaalsiirtymää. Kokemuksen mukaan lämpötila on ”viimeinen varoitus” ja nousee vasta kun vikaantuminen on jo pitkällä. Aksiaalsiirtymän mittaaminen taas on todettu tärkeäksi, sillä sen kasvaminen liian suureksi aiheuttaa vakavia ja kalliita vahinkoja laitteisiin. Jatkuvia värähtelymittauksia on tarkoitus laajentaa seuraavaksi tehtaan puhaltimiin ja kuljettimiin. (Kiviluoma, haastattelu 15.11.2021)

Värähtelymittauksen lisäksi suuren öljytilavuuden laitteista, turbiinijunista, kompresso-reista ja vaihteista otetaan öljynäytteitä, jotka analysoidaan ulkopuolisessa laboratoriossa. Näytteenottoväli on laitteen kriittisyydestä riippuen 3–12 kuukautta. Tavoitteena on ottaa käyttöön myös jatkuvaa öljyn kunnonvalvontaa. Sähkömoottoreista mitataan virrankulutusta, ja tätä seuranta on tarkoitus laajentaa tulevaisuudessa. (Kiviluoma, haastattelu 15.11.2021)

5.3 Datan hyödyntämisen nykytilanne ja mahdollisuudet

Tehtaan kunnossapidon tietojärjestelmänä käytetään toiminnanohjausjärjestelmän kunnossapitomoduulia. Järjestelmästä löytyy tehtaan tuotanto-omaisuuden master data, kuten toimintopaikkahierarkia ja tiedot laitteista. Järjestelmään tallentuu myös vika- ja huoltohistoria. Historiadataa ei kuitenkaan hyödynnetä kunnonvalvonnassa, vaan tyypillisesti

sitä tutkitaan vasta, kun halutaan tarkemmin perehtyä jonkin laitteen tilanteeseen tai vikaantumiseen. Kunnonvalvontajärjestelmiä tehtaalla on käytössä kaksi, toinen värähtelymittauksille ja toinen turbiinijunien kunnonvalvontaan. Lisäksi jotain kunnonvalvontadataa, esimerkiksi yleistärinää, näytetään tuotannon automaatiojärjestelmässä. Tehtaan prosessidataa tallennetaan ja käsitellään automaatiojärjestelmässä. Kunnonvalvontajärjestelmät ja automaatiojärjestelmä eivät vaihda tietoa keskenään, ja prosessidataa ei hyödynnetä kunnonvalvonnassa. (Kiviluoma, haastattelu 15.11.2021)

Tiedonsiirto tehtaalla tapahtuu langallisilla yhteyksillä, ja dataa tallennetaan paikallisille palvelimille. Yksittäisillä laitteilla on lisäksi langaton yhteys laitetoimittajan pilvipalvelimeen. Tiedonsiirrosta puhuttaessa tärkeäksi aiheeksi nousi tietoturva ja kyberturvallisuus, erityisesti langattomissa, internettiin yhteydessä olevissa ratkaisuissa. Yksi huoli on, että internettiin yhteydessä olevaa laitetta pääsisi ohjamaan ulkopuolelta, tai kunnonvalvontajärjestelmään voitaisiin syöttää virheellistä tietoa, joka aiheuttaisi laitteen tai koko tuotantolinjan pysähtymisen. (Kiviluoma, haastattelu 15.11.2021)

Värähtelymittausdataa käsitellään kunnonvalvontatoimittajan tarjoamalla ohjelmistolla. Ohjelmistossa on työkaluja datan visualisointiin, hälytysrajojen asettamiseen ja taajuustason diagnostiikkaan. Taajuustason diagnostiikkaa varten ohjelmistoon voidaan syöttää tietoja laitteesta, kuten laakerien tyypit. Näiden tietojen avulla värähtelyn lähteitä voidaan paikantaa tiettyyn koneenosaan. Taajuustasosta voidaan myös tunnistaa eri vikatyyppeistä, esimerkiksi epätasapainosta tai hammaspyörän hammasrikosta kertovia merkkejä. (Kiviluoma, haastattelu 15.11.2021)

Kunnonvalvonnan kehittämisessä tehtaalla keskitytään jatkuvien värähtelymittausten lisäämiseen ja jatkuvan öljynkunnonvalvonnan käyttöönottoon. Tietojärjestelmien kannalta pyritään lisäämään nykyisen kunnossapidon tietojärjestelmän käyttöä ja hyödyntämistä. (Kiviluoma, haastattelu 15.11.2021)

Datan hyödyntämisessä nähdään mahdollisuuksia sekä kunnossapidon että tuotantoprosessien kannalta. Mahdollisuuksia nähdään erityisesti kunnonvalvontadatan ja prosessidatan yhdistämisessä, ja data-analytiikan laajemmassa hyödyntämisessä. Näin voitaisiin löytää syy-seuraus-suhteita datasta, ja päästä mahdollisesti kiinni tuotannon ja laitteiden ongelmien juurisyihin. (Kiviluoma, haastattelu 15.11.2021)

Merkittävimpinä esteinä datan hyödyntämiselle ovat osaamisen ja tietojärjestelmien integraation puute. Näitä ongelmia kuvaa hyvin se, että kunnossapidossa jo pitkään käytössä olleen toiminnanohjausjärjestelmän käyttöä on alettu kehittää vasta viime aikoina asiantuntevan henkilön palkkaamisen johdosta. Haasteita tuovat myös henkilöstön

asenteet ja suhtautuminen datapohjaiseen päätöksentekoon. Jo nykyisellään kunnonvalvontajärjestelmiin ei luoteta täysin, vaan esimerkiksi halutaan saada aistivarainen varmistus viasta ennen toimenpiteitä. Haasteellisena nähdään myös sellainen tilanne, jossa datan hyödyntämiseen liittyvä osaaminen ja tehtävät keskittyvät vain yhdelle tai muutamalle henkilölle. Ennustavan kunnossapidon käyttämiseen vaikuttavat myös yrityksen ylemmän tason tavoitteet, joihin ei tällä hetkellä kuulu ennustavan kunnossapidon käyttöönottoa, vaan keskittyminen on jatkuvien kunnonvalvontamittausten kehittämisessä. (Kiviluoma, haastattelu 15.11.2021)

Ennustavan kunnossapidon eri menetelmistä tehtaan näkökulmasta kiinnostavimpia ovat datapohjaiset menetelmät. Ennustavan kunnossapidon menetelmissä nähdään tärkeimpinä hyötyinä ennustettavuuden ja suunnitelmallisuuden paraneminen, sekä parempi ymmärrys laitteiden vikaantumisesta ja ilmiöiden välisistä vuorovaikutuksista. Olennainen etu on myös tietokoneen tehokkuus verrattuna asiantuntijan suorittamaan analyysiin. Haasteita ennustavassa kunnossapidossa ovat vaadittava osaaminen ja tietojärjestelmien integraatio. Lisäksi kysymyksiä herättää tarvittavan datan ja ennustavan kunnossapidon mallien saatavuus. Tärkeitä vaatimuksia ennustavalle järjestelmälle ovat hyvä integraatio nykyisiin järjestelmiin ja helppo laajentaminen uusiin laitteisiin. Helpolla laajentamisella tarkoitetaan, että uusien laitteiden lisääminen järjestelmään on ainakin osittain automaattista, eikä vaadi suurta määrää manuaalista työtä. (Kiviluoma, haastattelu 15.11.2021)

Kokonaisuudessaan voidaan todeta, että ongelmat datan hyödyntämisessä ovat pääosin teknologiaan ja henkilöstöön liittyviä, eivätkä liiketoimintaan ja taloudelliseen kannattavuuteen liittyviä. Datan hyödyntämisen tuomat hyödyt nähdään lupaavilta, mutta ennustavan järjestelmän käyttöönottoon vaaditaan teknologisesti kypsä ja helppokäyttöinen kokonaisratkaisu.

6. JOHTOPÄÄTÖKSET

Tässä työssä käsiteltiin datan hyödyntämistä konejärjestelmien vikaantumisen ennustamisessa sekä kirjallisuuden että tapaustutkimuksen pohjalta. Tapaustutkimuksen pohjalta voidaan todeta, että käytännössä datan hyödyntäminen on huomattavasti kirjallisuudessa esitettyjä malleja ja menetelmiä alkeellisempaa. Yritysten välillä on tietenkin huomattaviakin eroja johtuen erilaisista resursseista ja tavoitteista.

Tapaustutkimuksessa selvisi, että kohdeyrityksessä uskottiin datan hyödyntämisen tarjoavan selkeitä operatiivisia ja taloudellisia etuja. Siihen liittyvätkin ongelmat olivatkin pääosin teknologiaan, organisaatioon ja henkilöstöön liittyviä. Myös kirjallisuudessa korostetaan näitä haasteita (Bousdekis et al. 2020; Ton et al. 2020). Kirjallisuuden mukaan ennustavan kunnossapidon nykyiset ratkaisut ovat keskittyneet vain tiettyyn ennustavan kunnossapidon osaan. Alan keskeinen haaste onkin kokonaisvaltaisten ratkaisujen puute. (Ton et al. 2020; Kortelainen et al. 2021, s. 172) Tapaustutkimuksessa kävi ilmi, että myös kohdeyrityksessä edellytys ennustavan järjestelmän käyttöönotolle olisi kypsä ja helppokäyttöinen kokonaisratkaisu.

Teknologiaan liittyvistä esteistä tapaustutkimuksessa esille nousivat erityisesti järjestelmien integraation puute, ennustavien mallien saatavuus, kyberturvallisuus ja tarvittavan datan saatavuus. Tässä työssä ei juurikaan käsitelty tällaisia käytännön sovelluksiin liittyviä asioita. Kirjallisuudessa esitetyt ennustavat mallit olivat pääsääntöisesti joko puhtaasti teoreettisia, tai tiettyä tarkoitusta varten rakennettuja kokeellisia malleja. Näiden perusteella ei voida arvioida kaupallisten mallien ja järjestelmien saatavuutta tai ominaisuuksia. Henkilöstöön ja kulttuuriin liittyvistä asioista keskeisimpiä olivat henkilöstön osaamisen taso, sekä asenteet ja suhtautuminen datan hyödyntämiseen. Tapaustutkimuksessa kävi ilmi, että tuotantolaitoksessa ei ollut juurikaan osaamista datan hyödyntämiseen liittyvistä asioista.

Tapaustutkimuksessa selvisi, että kohdeyrityksen näkökulmasta lupaavin prognoosimenetelmäluokka on datapohjaiset menetelmät. Kirjallisuuskatsauksen perusteella myös alan tutkimus keskittyy näihin menetelmiin. Tätä selittävät ainakin osittain dataan ja tekoälyyn perustuvien sovellusten yleistyminen ja kasvava kiinnostus näitä aiheita kohtaan. Datapohjaisia menetelmiä tutkitaan ja kehitetään aktiivisesti, ja siksi niiden tulevaisuudennäkymät ovat erityisen kiinnostavat. Vaikka teknologia ei tällä hetkellä olekaan valmis laajaan kaupalliseen hyödyntämiseen, jatkuvan kehityksen myötä se saattaa saavuttaa vaadittavan käytännöllisyyden ja saatavuuden rajan lähitulevaisuudessa.

Tapaustutkimuksen pohjalta voidaan esittää, että datan hyödyntämisen kehittäminen kohdeyrityksessä edellyttää pohjan rakentamista edistyneempien järjestelmien käyttöönottoa varten. Tämä tarkoittaa ainakin olemassa olevien järjestelmien yhteensopivuuden parantamista, kirjauskäytäntöjen ja dokumentaation kehittämistä, osaamisen kehittämistä tai hankkimista sekä datapohjaisen päätöksenteon kulttuurin luomista.

Tälle työlle asetettu tavoite oli esitellä erilaisia menetelmiä datan hyödyntämiseen teollisuuden konejärjestelmien vikaantumisen ennustamisessa. Työlle laadittiin seuraava tutkimuskysymys: kuinka dataa voidaan hyödyntää teollisuuden konejärjestelmien vikaantumisen ennustamisessa? Tutkimuskysymykseen vastattiin esittelemällä erilaisia prognoosimenetelmätyyppejä sekä niihin liittyviä etuja ja rajoituksia. Toisaalta yksittäisiin menetelmiin ja teknisiin yksityiskohtiin ei menty kovin syvälle, vaan niitä käsiteltiin pintapuolisesti. Mielestäni työn tavoite kuitenkin saavutettiin, ja työssä onnistuttiin antamaan hyvä yleiskatsaus erilaisiin menetelmiin. Aihetta taustoitettiin esittelemällä kunnossapidon ja ennustamisessa hyödynnettävän datan teoriaa. Tapaustutkimuksen avulla aihetta käsiteltiin käytännön näkökulmasta. Tapaustutkimuksessa käsiteltiin kuitenkin vain yhtä tuotantolaitosta, joten sen tulokset eivät ole suoraan yleistettävissä.

Tässä työssä heräsi useita jatkotutkimusaiheita. Tapaustutkimuksessa nousi esille paljon käytännön sovelluksiin ja käyttöönottoon liittyviä kysymyksiä, joihin ei tässä työssä vastattu. Näitä olivat ainakin ennustavien mallien saatavuus, kyberturvallisuus, integrointi nykyisiin tietojärjestelmiin sekä henkilöstöön ja organisaatioon liittyvät asiat. Lisäksi työssä käsittelyä rajattiin vikaantumisen ennustamisen menetelmiin, eikä juurikaan tarkasteltu ennusteiden hyödyntämistä tai ennustavien mallien integrointia kunnossapitoon ja tuotantolaitoksen muihin prosesseihin. Mielenkiintoinen näkökulma on myös tietohallinnon rooli tuotantolaitoksen datan hyödyntämisessä.

LÄHTEET

- Ahonen, T & Reunanen, M. (2009). Elinkaaritiedon hyödyntäminen teollisen palveluliiketoiminnan kehittämisessä. VTT Working Papers, no. 136. VTT Technical Research Centre of Finland, Espoo. 72 s. Saatavissa (viitattu 3.1.2022): <https://cris.vtt.fi/en/publications/utilisation-of-lifetime-information-in-the-development-of-industr>
- Aivaliotis, P., Georgoulis, K. & Chryssolouris, G. (2019). The use of Digital Twin for predictive maintenance in manufacturing. *International Journal of Computer Integrated Manufacturing*. Vol.32(11), pp. 1067–1080.
- Bousdekis, A., Apostolou, D. & Mentzas, G. (2020). Predictive Maintenance in the 4th Industrial Revolution: Benefits, Business Opportunities, and Managerial Implications. *IEEE Engineering Management Review*. Vol.48(1), pp. 57–62.
- Boyes, H., Hallaq, B., Cunningham, J. & Watson, T. (2018). The industrial internet of things (IIoT): An analysis framework. *Computers in Industry*. Vol.101, pp. 1–12.
- Bradicich, T. (2018). The Intelligent Edge: What It Is, What It's Not, and Why It's Useful. Hewlett Packard Enterprise. Saatavissa (viitattu 4.11.2021): <https://www.hpe.com/us/en/insights/articles/the-intelligent-edge-what-it-is-what-its-not-and-why-its-useful-1711.html>
- Compare, M., Baraldi, P. & Zio, E. (2020). Challenges to IoT-Enabled Predictive Maintenance for Industry 4.0. *IEEE Internet of Things Journal*. Vol.7(5), pp. 4585–4597.
- Elattar, H. M., Elminir, H.M. & Riad, A.M. (2016). Prognostics: a literature review. *Complex & Intelligent Systems*. Vol.2(2), pp. 125–154.
- El-Thalji, I. & Jantunen, E. (2015). A summary of fault modelling and predictive health monitoring of rolling element bearings. *Mechanical Systems and Signal Processing*. Vol.60–61, pp. 252–272.
- Grieves, M (2014). Digital Twin. *Manufacturing Excellence through Virtual Factory Replication*.
- Hashemian, H. M. & Bean, W.C. (2011). State-of-the-Art Predictive Maintenance Techniques. *IEEE Transactions on Instrumentation and Measurement*. Vol.60(1), pp. 226–236.
- Heng, A., Zhang, S., Tan, A.C.C. & Mathew, J. (2009). Rotating machinery prognostics: State of the art, challenges and opportunities. *Mechanical Systems and Signal Processing*. Vol.23(3), pp. 724–739.
- Jardine, A.K.S., Lin, D. & Banjevic, D. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*. Vol.20(7), pp.1483–1510.
- Järviö, J. & Lehtiö, T. (2012). Kunnossapito: Tuotanto-omaisuuden hoitaminen. 5. uud. p. KP-Media, Helsinki. 288 s.

Kiviluoma, M., tarkastus- ja luotettavuuspäällikkö, Yara Uusikaupunki. Haastattelu 15.11.2021.

Kortelainen, H., Komonen, K., Laitinen, J., Valkokari, P. & Hanski, J. (2021). Tietämysteinen elinjakson hallinta. 1. painos. Kunnossapitoyhdistys Promaint ry, Helsinki. 240 s.

Larose, D. T. & Larose, C. D. (2015). Data mining and predictive analytics. Second edition. John Wiley & Sons, Hoboken, New Jersey. 794 s.

Lasi, H., Fetke, P., Kemper, H.-G., Feld, T. & Hoffmann, M. (2014). Industry 4.0. Business & Information Systems Engineering. Vol.6(4), pp. 239–242.

Lee, J., Wu, F., Zhao, W., Ghaffari, M., Liao, L. & Siegel, D. (2014). Prognostics and health management design for rotary machinery systems - Reviews, methodology and applications. Mechanical Systems and Signal Processing. Vol.42(1–2), pp. 314–334.

Lee, J.H., Shin, J. & Realf, M.J. (2018). Machine learning: Overview of the recent progresses and implications for the process systems engineering field. Computers & Chemical Engineering. Vol.114, pp. 111–121.

Martinsuo, M. & Kärrä, T. (toimittajat) (2017). Teollinen internet uudistaa palveluliiketoimintaa ja kunnossapitoa. Kunnossapitoyhdistys ProMaint. 238 s. Saatavissa (viitattu 30.10): <http://urn.fi/URN:NBN:fi:tty-201706061586>.

Matyas, K., Nemeth, T., Kovacs, K. & Glawar, R. (2017). A procedural approach for realizing prescriptive maintenance planning in manufacturing industries. CIRP Annals. Vol.66(1), pp. 461–464.

Microsoft (2021). Azure AI for predictive maintenance solutions. Verkkojulkaisu. Saatavissa (viitattu 1.12.2021): <https://docs.microsoft.com/en-us/azure/architecture/data-science-process/predictive-maintenance-playbook>

Mikkonen, H. (toim.), Miettinen, J., Leinonen, P., Jantunen, E., Kokko, V., Riutta, E., Sulo, P., Komonen, K., Lumme, V.E., Kautto, J., Heinonen, K., Lakka, S. & Mäkeläinen, R. (2009). Kuntoon perustuva kunnossapito: käsikirja. KP-Media, Helsinki. 606 s.

Mobley, R. K. (2002). An introduction to predictive maintenance. 2nd ed. Butterworth-Heinemann, Amsterdam. 438 p.

Mobley, R. K. (2014). Maintenance engineering handbook. 8th ed. McGraw-Hill, New York.

Muller, A., Crespo Marquez, A. & Jung, B. (2008). On the concept of e-maintenance: Review and current research. Reliability Engineering & System Safety. Vol.93(8), pp. 1165–1187.

Pascual, D. G. (2015). Artificial intelligence tools: decision support systems in condition monitoring and diagnosis. CRC Press, Boca Raton. 549 p.

Pecht, M. & Kang, M. (2018). Prognostics and health management of electronics: fundamentals, machine learning, and internet of things. Second edition. John Wiley & Sons, Hoboken, New Jersey. 808 p.

Peng, Y., Dong, M. & Zuo, M.J. (2010). Current status of machine prognostics in condition-based maintenance: a review. *International Journal of Advanced Manufacturing Technology*. Vol.50(1), pp. 297–313.

Schmidt, B. & Wang, L. (2018). Cloud-enhanced predictive maintenance. *International Journal of Advanced Manufacturing Technology*. Vol.99(1–4), pp. 5–13.

SFS-EN 13306:2017 (2017). Kunnossapito. Kunnossapidon terminologia. 3. painos. Suomen Standardisoimisliitto SFS ry, Helsinki. 68 s.

SFS-EN 13554:2011 (2011). Non-destructive testing. Acoustic emission testing. General principles. 2. painos. Suomen Standardisoimisliitto SFS ry, Helsinki. 16 p.

Starr, A., Al.Najjar, B., Holmberg, K., Jantunen, E., Bellew, J. & Albarbar, A. Maintenance Today and Future Trends. In Holmberg, K., Adgar, A., Arnaiz, A., Jantunen, E., Mascolo, J., Mekid, S. (editors) (2010). *E-maintenance*. 1st ed. Springer, London. 511 p.

Susto, G. A., Schirru, A., Pampuri, S., McLoone, S. & Beghi, Al. (2015). Machine Learning for Predictive Maintenance: A Multiple Classifier Approach. *IEEE Transactions on Industrial Informatics*. Vol.11(3), pp. 812–820.

Ton, B., Basten, R., Bolte, J., Braaksma, J., Di Bucchianico, A., Calseyde, van de, P., Grooteman, F., Heskes, T., Jansen, N., Wouter, T., Tinga, T. & Stoelinga, M. (2020). PrimaVera: Synergising Predictive Maintenance. *Applied Sciences*. Vol.10(23), pp. 1–19.

Vaidya, S., Ambad, P. & Bhosle, S. (2018). Industry 4.0 – A Glimpse. *Procedia Manufacturing*. Vol.20, pp. 233–238.

Wei, Y., Wu, D. & Terpanny, J. (2021). Decision-Level Data Fusion in Quality Control and Predictive Maintenance. *IEEE Transactions on Automation Science and Engineering*. Vol.18(1), pp. 184–194.

Yan, J., Meng, Y., Lu, L. & Li, L. (2017). Industrial Big Data in an Industry 4.0 Environment: Challenges, Schemes, and Applications for Predictive Maintenance. *IEEE Access*. Vol.5, pp. 23484–23491.

Yara (2021). Yaran suomenkieliset verkkosivut. Saatavissa (viitattu 22.11.2021): <https://www.yara.fi/>

Zonta, T., da Costa, C.A., da Rosa Righi, R., de Lima, M.J., da Trindade, E.S. & Li, G.P. (2020). Predictive maintenance in the Industry 4.0: A systematic literature review. *Computers & Industrial Engineering*. Vol.150, 106889.