

Paavo Hintsa

**KONEOPPIMISEN HYÖDYNTÄMINEN  
TEOLLISUUDEN KONEIDEN HUOLTOTARPEEN  
ENNUSTAMISESSA**

Kandidaattitutkielma  
Informaatioteknologian ja viestinnän tiedekunta  
Tammikuu 2024

# TIIVISTELMÄ

Paavo Hintsa: Koneoppimisen hyödyntäminen teollisuuden koneiden huoltotarpeen ennustamisessa

Kandidaatintutkielma

Tampereen yliopisto

Tietojenkäsittelytieteiden tutkinto-ohjelma

Tammikuu 2024

Tässä kandidaatintutkielmassa selvitetään, miten teollisuudessa toteutetaan huoltoja, mitä on data-analyysi ja koneoppiminen ja miten niitä voidaan hyödyntää teollisuuden koneiden huoltotarpeen ennustamiseen. Tutkimuskysymyksenä on selvittää, mitä koneoppimismallien hyödyntäminen teollisuuden laitteiden huoltotarpeen ennustamiseen vaatii.

Teollisuuden huoltomenetelmiä käsiteltäessä kiinnitetään huomiota erityisesti eri tapojen ennustustarkkuuteen, niistä aiheutuviin kustannuksiin ja siihen kuinka paljon ennen mahdollista koneen hajoamista pystytään käsiteltävällä huoltomenetelmällä reagoimaan. Käsiteltävät huoltomenetelmät ovat reagoiva kunnossapito (reactive maintenance), ehkäisevä huolto (preventive maintenance), sovellettu huolto (condition-based maintenance), ennakoiva kunnossapito (predictive maintenance) ja ohjaava kunnossapito (prescriptive maintenance).

Data-analyysiä esiteltäessä keskitytään data-analyysin peruseräisiin, vaiheisiin ja yleisiin ongelmiin. Koneoppimista käsiteltäessä esitellään, miten data-analyysiä voidaan jatkaa koneoppimisella, mitä koneoppiminen käytännössä on ja millaisia ovat koneoppimisen neljä yleistä päälinjaa. Koneoppimisen esittelyä jatketaan kertomalla tapaustutkimusten avulla, miten koneoppimista käytännössä hyödynnetään. Lopuksi vertaillaan tapaustutkimuksia keskenään ja pohditaan, miten löydettyjä koneoppimisen hyödyntämistapoja voidaan oikeasti käyttää teollisuuden koneiden huoltotarpeen ennustamiseen.

Koneoppimisen hyödyntäminen teollisuuden koneiden huoltotarpeen ennustamiseen vaatii laadukasta dataa, koneeseen liittyvää kontekstintuntemusta, data-analyysin suorittamista ja koneoppimismallin hyödyntämistä. Toimivaa koneoppimismallia voidaan tehostaa parantamalla minkä tahansa edellä mainitun vaiheen toimintaa.

Avainsanat: koneoppiminen, kunnossapito, data-analyysi, ennakoiva kunnossapito, ohjaava kunnossapito

Tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck -ohjelmalla.

# SISÄLLYSLUETTELO

1.	Johdanto	1
2.	Teollisuuden huoltomenetelmiä	3
2.1	Data-analyysin kunnossapito	3
2.2	Dataohjattu kunnossapito	4
3.	Koneoppiminen teollisuudessa	6
3.1	Data-analyysi	6
3.2	Koneoppiminen	7
4.	Tapaustutkimuksia koneoppimisen käytöstä huoltotarpeen ennustamisessa	9
4.1	Logipohjainen koneoppimismalli	9
4.2	Syvä- ja vahvistusoppimisen yhdistäminen ohjaavaan kunnossapitoon	10
4.3	A2-LSTM pohjainen ratkaisu ennakoivaan kunnossapitoon	12
4.4	Tapaustutkimusten vertailu	13
4.5	Päätelmät	15
5.	Yhteenveto	16
	Lähteet	17

# 1. JOHDANTO

Tässä kandidaatintutkielmassa tutkitaan data-analyysiä ja koneoppimista teollisuuden laitteiden huoltotarpeen ennustamisen apuna. Koneoppimisen ja data-analyysin hyödyntämistä teollisuudessa tutkitaan nykyisin yleisesti runsaasti, mutta suomen kielellä melko vähän. Tässä tutkielmassa selvitän, mitä koneoppimisen hyödyntäminen teollisuuden laitteiden huoltotarpeen ennustamiseen vaatii ja että mitä hyötyjä koneoppimisen avulla on saavutettavissa.

R. Patil ym. (2023) esittelevät tutkimuksessaan, miten datan avulla voidaan erinäisten koneoppimismallien avulla tehdä ennustuksia koneen hajoamisesta tulevaisuudessa. Tutkimus on näkökulmaltaan eri koneoppimismallien tarkkuutta vertaileva.

Sipos ym. (2014) esittelevät tutkimuksessaan, miten teollisuuden koneita ajavien ohjelmistojen lokien avulla voi suorittaa ennakoivaa kunnossapitoa.

Jiang ym. (2022) esittelevät, miten teollisuuden koneista kerätyn sähkötiedon perusteella voi suorittaa ennakoivaa kunnossapitoa. Tutkimus on näkökulmaltaan eri koneoppimismallien tarkkuuksia vertaileva.

Goby, Brandt ja Neumann (2023) esittelevät tutkimuksessaan, miten yhdistelemällä syväoppimista ja vahvistusoppimista voidaan suorittaa ohjaavaa kunnossapitoa. Tutkimuksessa keskityttiin vertailemaan kustannuksia esitellyn koneoppimismallipohjaisen huoltostrategian ja data-analyysiä hyödyntämättömien huoltostrategioiden välillä.

Koneoppimisen teollista hyödyntämistä pidetään usein kalliina ja monimutkaisena kokonaisuutena toteuttaa. Etsiessäni erilaisia tapoja toteuttaa teollisuuden koneiden huoltoa löydän myös kustannustehokkaita ja yksinkertaisia tapoja pitää koneet kunnossa.

Tutkielmassani pyrin vastaamaan asettamaani tutkimuskysymykseen: Mitä koneoppimismallien hyödyntäminen teollisuuden laitteiden huoltotarpeen ennustamiseen vaatii? Tuloksena huomasin, että riippumatta valitusta koneoppimismallia hyödyntävästä huoltostrategiasta, tarvittavat toimenpiteet ovat samankaltaiset. Joka tapauksessa tarvitsee kerätä dataa, tuntea datan konteksti, analysoida dataa ja hyödyntää koneoppimismallia.

Tutkielmassani esittelen aluksi teollisuuden erilaisia huoltotapoja, jotta saan selvennettyä mitkä ovat vaihtoehtoisia ratkaisuja koneoppimismalleille pohjautuville ratkaisuille. Tämän jälkeen esittelen data-analyysin, jota teollisuudessa nykyisellään tehdään paljon. Jatkan

data-analyysistä esittelemällä, miten sitä voidaan laajentaa koneoppimismalleihin pohjautuvaan ennustavaan data-analyysiin. Tämän jälkeen esittelen muutaman yleisen koneoppimismallin. Aivan lopuksi tutkin ja vertailen, miten koneoppimismallit ovat todellisuudessa hyödynnettävissä kunnonvalvonnassa muutaman tapaustutkimuksen avulla.

Suoritin tiedonhaun Andor -verkkokirjastoon tehdyillä hauilla. Käytin osiokohtaisia hakusanoja ja pyrin löytämään kuhunkin esittelyosioon lähteeksi ainakin yhden kirjan ja kaikkiin osioihin ainakin yhden tällä vuosikymmenellä tehdyn artikkelin. Hakusanoina käytin esimerkiksi "industrial prescriptive maintenance", "industrial predictive maintenance" ja "industry 4.0". Rajasin hakutuloksista valitsemalla käsittelyyn vain Andor -verkkokirjaston relevanttiusjärjestyksessä ensimmäiset kymmenen ja niistä seuloin sopivimman oloiset tarkastelemalla otsikoita, tekijöitä ja julkaisualustoja. Mikäli artikkeli vaikutti vielä tämänkin jälkeen hyvältä, luin sen tiivistelmän ja yhteenvedon, joiden perusteella päätin joko hyödyntää tai olla hyödyntämättä artikkelia. Mikäli huomasin jonkin tutkimani artikkelin sisältävän runsaasti hyödyllisiä viittauksia samaan artikkeliin, tarkastin myös sen läpi, ja näin löysin muutaman hyödyllisen lähteen.

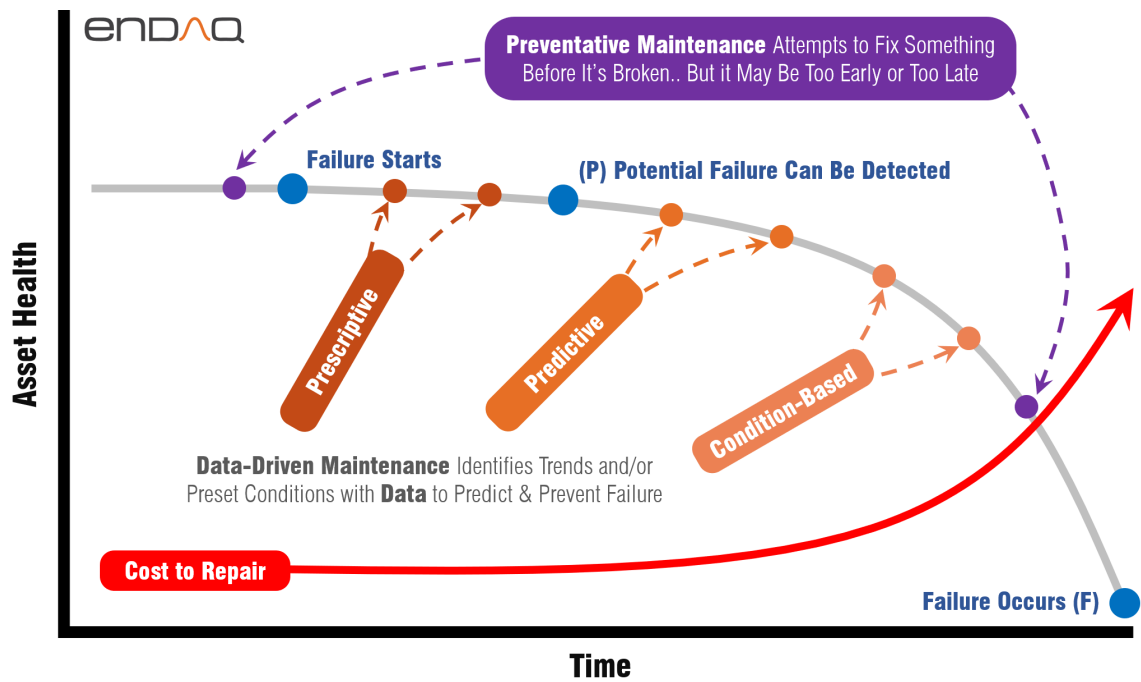
## 2. TEOLLISUUDEN HUOLTOMENETELMIÄ

Teollisuuden laitteet vaativat jatkuvaa huoltoa toimiakseen. Tässä osiossa esittelen teollisuuden huoltomenetelmiä kaavion [1](#) avulla.

### 2.1 Data-analyysin kunnossapito

Yleisiä data-analyysiä hyödyntämättömiä huoltostrategioita ovat esimerkiksi reagoiva kunnossapito (reactive maintenance) ja ehkäisevä huolto (preventive maintenance). R.Patilin ym. (2023) mukaan reagoivassa kunnossapidossa odotetaan jonkin osan hajoavan ja se vaihdetaan hajoamisen jälkeen. Ehkäisevässä huollossa tehdään huoltoja, tarkastuksia tai osien vaihtoja ennalta määritellyn aikataulun mukaisesti. Käytännössä useimmiten käytetään näiden kahden tavan jonkinlaista yhdistelmää riippuen huollettavasta laitteesta ja siitä, mikä on halvin tapa pitää laite kunnossa. Reagoivan kunnossapidon suurimmat kustannukset tulevat laitteen seisonta-ajasta, usein vieläpä yllättävällä hetkellä, ja ehkäisevän huollon kustannukset tulevat turhaan tehdyistä kunnossapitotöistä. Ehkäisevä huolto ei kuitenkaan aina onnistu odotetusti. Koneiden osat voivat hajota odotettua aiemmin, sillä koneet toimivat eri tavoin eri olosuhteissa ja vaihdetut osat voivat olla huonolaatuisia. Tällöin joudutaan edelleen korjaamaan hajonnutta konetta ennakoivista toimenpiteistä huolimatta. Toisaalta ennakoivassa huollossa huolto voi tapahtua myös tarvittua aikaisemmin, jolloin koneen ehjää käyttöikää eli RULia (remaining useful life) jää turhaan hyödyntämättä.

Reagoiva kunnossapito ja ehkäisevä huolto eivät tarvitse tietoa koneen hetkellisestä kunnosta koneen toimiessa normaalin oloisesti. Jos koneen ajantasaista kuntoa haluttaisiin mitata perinteisin menetelmin, voitaisiin visuaalisesti tutkia osia ja mitata niiden fyysisiä kulumista (Abubakr ym. 2021). Näin ei useinkaan tehdä, koska kuluvat osat ovat usein myös liikkuvia osia, hankalasti tarkasteltavina syvällä koneen sisällä tai peitettyinä valmistettavalla tuotteella. Niiden tutkimista voidaan täten ollen harjoittaa vain koneen ollessa pysähtyneenä eli esimerkiksi aikasidonnaisten huoltojen aikana. Koneen pysäyttäminen on kuitenkin lähes poikkeuksetta kallista.



Kuva 1. Kaavio eri huoltomenetelmien vaikutusalueista (Hanly 2020)

## 2.2 Dataohjattu kunnossapito

Teollisuuden laitteiden huoltotarvetta voidaan ennustaa erilaisilla tarkkuuksilla data-analyysin avulla. Dataohjattu kunnossapito jaetaan kaavion 1 mukaan sovellettuun huoltoon (condition-based maintenance), ennakoivaan kunnossapitoon (predictive maintenance) ja ohjataan kunnossapitoon (preventive maintenance) ennustuksen tarkkuuden ja ajoituksen ennen hajoamista mukaan.

**Sovellettu huolto** on näistä epätarkin ennustusmenetelmä, se kykenee ennustamaan koneen hajoamisen vasta lähellä itse hajoamista, mutta toisaalta se on yleisesti implementointikustannuksiltaan halvin eli vähiten ohjelmistotyötä vaativa tapa. Sovelletussa huollossa annetaan koneen osien kuntoa valvovien sensoreiden mittamille arvoille asiantuntija-arvioon perustuvat hälytysrajat, joiden ylittymisen jälkeen kone korjataan (R. Patil ym. 2023). Hälytyskynnykset aiheuttavat sovelletussa huollossa myös ongelmia. Jos hälytyskynnys asetetaan liian tiukaksi, vääriä hälytyksiä voi tulla myös mitattavien arvojen normaalista vaihtelusta. Toisaalta jos hälytyskynnys on liian salliva, kone saattaa ehtiä hajota odotettua laajemmin ennen hälytystä.

**Ennakoiva kunnossapito** eroaa sovelletusta huollosta siten, että se pyrkii löytämään datasta kehityssuuntia ja ennustamaan niiden avulla, milloin kone tulisi tarvitsemaan huoltoa (Goby, Brandt ja Neumann 2023). Ennustettu hajoamisaika minimoi seisontajan, mutta menetelmän käyttöönotto vaatii huomattavia investointeja datan keräämiseen, käsittelyyn ja analysointiin (R. Patil ym. 2023). Idealistisesti ennakoivan kunnossapidon toimiessa ei tule lainkaan seisakkia ennalta määrittämättömänä aikana

ja huoltomenot ovat mahdollisimman pienet, sillä osat vaihdetaan juuri ennen, kuin niiden heikentyneestä kunnosta alkaisi olla haittaa. Näin ollen osia ei tarvitse tarkastaa ja vaihtaa niin usein, joten säästetään myös työtunteja. Ennakoivan kunnossapidon toimiessa täydellisesti säästytäisiin myös koneen hajoamisista johtuvilta onnettomuuksilta. Ennakoivan kunnossapidon eräs keskeisistä vahvuuksista onkin huomioiminen, että kone saattaa toimia esimerkiksi olosuhteiden vuoksi eri tavalla kuin sen tyyppisten koneiden pitäisi toimia. Esimerkiksi mittaustulosten suuruusluokka voi vaihdella suurestikin ulkoisten olosuhteiden vuoksi, jolloin samat hälytysrajat kaikille samanlaisille koneille eivät tuottaisi riittävän tarkkoja arvioita tilanteen hälyttävyydestä. Toinen ennakoivan kunnossapidon keskeisistä vahvuuksista on, että konetta tutkitaan sen ollessa käynnissä.

**Ohjaava kunnossapito** eroaa Gobyn, Brandtin ja Neumannin (2023) mukaan ennakoivasta siten, että siinä missä ennakoiva kunnossapito tyytyy kertomaan, että jotain on hajoamassa, ohjaava kunnossapito pyrkii kertomaan mitä koneen toiminnassa pitää muuttaa, jotta mitään ei hajoa. Ohjaavaa kunnossapitoa toteutetaan pääosin kahdella eri tavalla: joko reagoidaan ennustettuihin arvoihin erinäisin optimisointikeinoin tai lasketaan paras mahdollinen toimintaratkaisu datasta simulaation avulla. Käytännössä kuitenkin ohjaavassa kunnossapidossa pyritään löytämään ongelmia aiheuttavat juurisyyt jo ennen kuin ne alkavat aiheuttaa ongelmia. Data-analytiikan kannalta ohjaava kunnossapito eroaa ennakoivasta lähinnä monimutkaisemmalla koneoppimisen hyödyntämisellä. Kerätty data on usein jopa samaa, kuin millä toteutettaisiin ennakoivaa kunnossapitoa. Toimiessaan ohjaava kunnossapito minimoisi koneiden huoltokustannukset. Ennakoivaan kunnossapitoon verrattuna suurempi koneoppimisen tarve ja sitä myötä suuremmat käyttöönottokustannukset kuitenkin hidastavat menetelmän laajempaa hyödyntämistä.



### 3. KONEOPPIMINEN TEOLLISUUDESSA

Jotta teollisuuden laitteiden kunnonvalvontaa voidaan toteuttaa koneoppimista hyödyntäen, tarvitaan data-analytiikkaa. Tässä osiossa esittelen data-analyysiä yleisesti ja koneoppimisen neljä päälinjaa.

#### 3.1 Data-analyysi

Jatkuvasti kasvava määrä dataa hankitaan, säilötään ja prosessoidaan. Datan avulla automatisoidaan ja hallitaan teollista tuotantoa, jakelua, logistiikkaa ja tuotantoketjuprosesseja. Runklerin (2012) mukaan data-analyysin tärkeimpänä tehtävänä teollisuudessa on prosessien optimisointi ja yhtiön kilpailukyvyn parantaminen. Juuri data-analyysi onkin ollut yksi neljännen teollisen vallankumouksen keskiössä olevista teknologioista (Ajayi, Bagula ja Maluleke 2022).

Data-analyysi koostuu yleisesti neljästä vaiheesta: valmistelusta (preparation), esikäsitteilystä (preprocessing), analyysistä (analysis) ja jälkikäsitteilystä (postprocessing).

**Valmistelu:** Runklerin (2012) mukaan Tarkemmin valmistelukin jaetaan neljään osaan. Data-analyysin valmistelu aloitetaan suunnittelulla (planning). Hyvin hoidetun suunnittelun jälkeen data-analyysin tekijä tietää, mitä analysoitava data käytännössä tarkoittaa ja mitä analysoitavasta datasta olisi saatava irti. Valmistelua jatketaan datan keräämisellä (data collection) ja datan valinnalla (data selection) (Runkler 2012). Datan laatu aiheuttaa usein ongelmia, jotka on helpointa torjua juuri tässä vaiheessa.

Yleisiä datan laatuun liittyviä ongelmia ovat esimerkiksi datan lähettäjän ja vastaanottajan eriävät standardit metadatan ja merkinnän suhteen (Hunziker ym. 2017), dataputken (datapipeline) ongelmat eli se, kun dataa ei jostain syystä odotetusti tulekaan, ja duplikaatit datassa (Lindström ym. 2023). Datan ongelmia tunnistetaan yleisesti datan laadun tarkastuksella (Data Quality Assessment DQA) eli käytännössä katsotaan joko automaattisesti tai manuaalisesti, onko datassa heikon dataalaadun tunnusmerkkejä. Löydetyt ongelmat ratkotaan ennen kuin data-analyysiä jatketaan valmistelua pidemmälle. Valmistelun viimeinen vaihe on uusien arvojen laskeminen saadusta datasta (feature generation). Käytännössä tämä tarkoittaa usein sitä, että tarvittaessa lasketaan uudeksi sarakkeeksi numeerisesta datasta tunnuslukuja, kuten vaikkapa

tietyn ajan keskiarvoa.

**Esikäsitteily:** Data sisältää käytännössä lähes aina virheitä ja häiriöitä, sitä täytyy skaalata tai sitä on ainakin kerätty keskenään erilaisista lähteistä (Runkler 2012). Näitä ongelmia ratkaistaan esikäsitteilyllä. Esikäsitteily aloitetaan datan siivoamisella (cleaning) ja rajaamisella (filtering). Näitä oikeastaan saatetaan aloittaa jo DQA:n yhteydessä, jos esimerkiksi poistetaan datajoukosta duplikaatteja. Dataa voidaan siivota ja rajata esimerkiksi algoritmien avulla tai hakemalla poikkeamia tiettyjen tunnusmerkkien perusteella. Lisäksi esikäsitteilyssä voidaan standardisoida (standardization) ja muuntaa (transformation) dataa (Runkler 2012). Käytännössä dataa siis voidaan esimerkiksi normittaa analyysin tarkentamiseksi.

**Analyysi ja jälkikäsitteily:** Itse analyysivaiheen toimenpiteet riippuvat hyvin paljon siitä, minkälaista dataa tutkitaan. Analyysivaiheessa dataa voidaan visualisoida (visualization) ja siitä voidaan lisäksi etsiä trendejä korrelaatioista (correlation), luokittelemalla (classification), lineaarisen regression avulla tai ryvästämällä (clustering) (Runkler 2012). Se, mitä datalle tarkemmin ottaen analyysivaiheessa tehdään, riippuu aina data-analyysin tavoitteista. Runklerin (2012) mukaan datan perusteella voidaan pyrkiä myös ennustamaan datan tulevia arvoja (forecasting). Analyysin jälkeen jälkikäsitteilyssä datasta tehdään tulkintoja (interpretation), tuloksia arvioidaan (evaluation) ja ne dokumentoidaan.

Suurin osa teollisuudessa tehtävästä data-analyysistä ei tähtää koneoppimiseen. Nykyisin useissa tapauksissa riittää, että dataa ylipäänsä tulee, vaikka sitä tulisivin viiveellä. Useimmiten historiallisen datan visualisointeja seurataan pitkältä aikaväliltä ja niiden perusteella tehdään asiantuntija-arvioita laitteiden tilasta. Pelkän historiallisen datan ihmisen toimesta tapahtuva tulkitseminen vaatii asiantuntemusta ja usein tulkittavia datan visualisointeja on paljon.

## 3.2 Koneoppiminen

On arvioitu, että datan kokonaismäärä on yli 300 kertaistunut vuosien 2005 ja 2020 välillä (Vermeulen 2020). Datamäärän kasvu sekä mahdollistaa aiempaa tarkemman analysoinnin suoraan datan perusteella että vaatii analysoinnin aiempaa laajempaa automatisointia. Koneoppiminen edesauttaa näistä molempia. Ajayin, Bagulan ja Maluleken (2022) mukaan koneoppiminen on tekoälyn alayksikkö, joka opettelee datan avulla luokittelemaan tai tekemään ennustuksia automaattisesti. Koneoppiminen jaetaan neljään päälinjaan: ohjattuun oppimiseen (supervised learning), ohjaamattomaan oppimiseen (unsupervised learning), vahvistusoppimiseen (reinforcement learning) ja syväoppimiseen (deep learning).

**Ohjattu oppiminen** vaatii Kämäräisen (2023) mukaan harjoitusdatan, josta tunne-

taan syöte ja tuloste. Harjoitusdatan avulla ohjatulle oppimiselle osoitetaan, että mitä tulosteita kullakin syötteellä tulisi saada. Ohjattu oppiminen luo tämän perusteella funktion, jonka avulla se yhdistää syötteet tulosteisiin. Funktion tarkkuutta tutkitaan testidatan avulla siten, että annetaan koneoppimismallille pelkät syötteet ja verrataan sen valitsemia tulosteita todellisiin tulosteisiin.

**Ohjaamattomassa oppimisessä** ei anneta koneoppimismallille tulosteita, kuten ohjatussa oppimisessä. Sen sijaan pelkät syötteet riittävät. Ohjaamaton oppiminen luo syötteistä uusia kuvauksia. Tätä hyödynnetään usein esimerkiksi ryvästämiseen. Ohjaamattoman oppimisen suurin etu on, että se voi hakea tietoa täysin automaattisesti. (Kämäräinen 2023)

**Vahvistusoppimisessä** ei ole käytössä syötteitä, eikä tulosteita. Sen sijaan vahvistusoppimisessä on agentti, jota ohjataan palkkioilla ja rangaistuksilla löytämään parhaat toimintatavat. Agentti tarvitsee syötteekseen ympäristön tilan, jonka perusteella se valitsee pitkällä aikavälillä palkkioiden perusteella suurimman tuoton antavan toimintatavan. (Kämäräinen 2023)

**Syväoppiminen** on yleisnimi neuroverkkopohjaisille lähestymistavoille koneoppimiseen. Neuroverkot koostuvat päättelimestä (perceptron), jotka matkivat toiminnaltaan yksittäisiä aivosoluja. Päättelimiä yhdistellään rinnakkain ja peräkkäin neuroverkoiksi. Syväoppiminen on nykyään tutkituin koneoppimistapa ja sitä pystyy hyödyntämään äärimmäisen laajalti. (Kämäräinen 2023)


## 4. TAPAUSTUTKIMUKSIA KONEOPPIMISEN KÄYTÖSTÄ HUOLTOTARPEEN ENNUSTAMISESSA

Tässä osiossa esittelen ja vertailen kolmea eri tapaustutkimusta koneoppimisen hyödyntämisestä teollisuuden koneiden huoltotarpeen ennustamisessa.

### 4.1 Logipohjainen koneoppimismalli

Sipos ym. (2014) esittelevät tutkimuksessaan, miten sovellettua huoltoa voi toteuttaa laitteen ohjelmiston lokin avulla. Normaalisti lokeja käytetään lähinnä ohjelmistovirheiden korjaamiseen, joten niiden hyödyntäminen kunnonvalvonnassa vaatii runsaasti datan esikäsittelyä. Lokeista saadun datan monipuolisuus on samaan aikaan vahvuus ja heikkous analyysin kannalta. Vahvuutena tietoa on paljon saatavilla, mutta heikkoutena se ei ole standardisoitua ja lisäksi luonnollista kieltä käytettäessä samoilla sanoilla saataan tarkoittaa eri asioita. Pienetkin väärin ymmärretyt merkityserot voivat muuttaa tulosta huomattavasti. Yksittäisen lokimerkinnän merkityksen pienentämiseksi tässä tapauksessa hyödynnetään moni-ilmentymä oppimista (multi-instance learning), jossa data jaetaan joukkioihin (bag) ja joukkioille annetaan negatiivinen arvo, jos kaikki sen sisältämät ilmentymät ovat negatiivisia. Mikäli yksikin ilmentymä on positiivinen, on koko joukkio positiivinen. Tässä tutkimuksessa positiivisena pidettiin viitettä koneen tulevaan vikaan. Tutkimuksessa dataa eriteltiin lokimerkinnöistä muun muassa parsimalla luonnollista kieltä, poimimalla numeerisia arvoja ja etsimällä tapahtumaketjuja. Tutkimuksessa vertailtiin myös miten eri määrien ominaisuuksia poimiminen vaikuttaa lopputulokseen.

Tutkimuksessa tavoitteena oli luokitella joukkioita oikein. Datajoukkioita luokiteltiin tukivektorikoneen (Support Vector Machine SVM) avulla. SVM:lle annettiin harjoitteluvaiheen aikana datajoukkioita ja tieto joukkion positiivisuudesta. Sen perusteella SVM loi rajat, joiden avulla ennustettiin, millä ominaisuuksilla yksittäinen joukkio oli positiivinen ja millä negatiivinen. (Sipos ym. 2014)

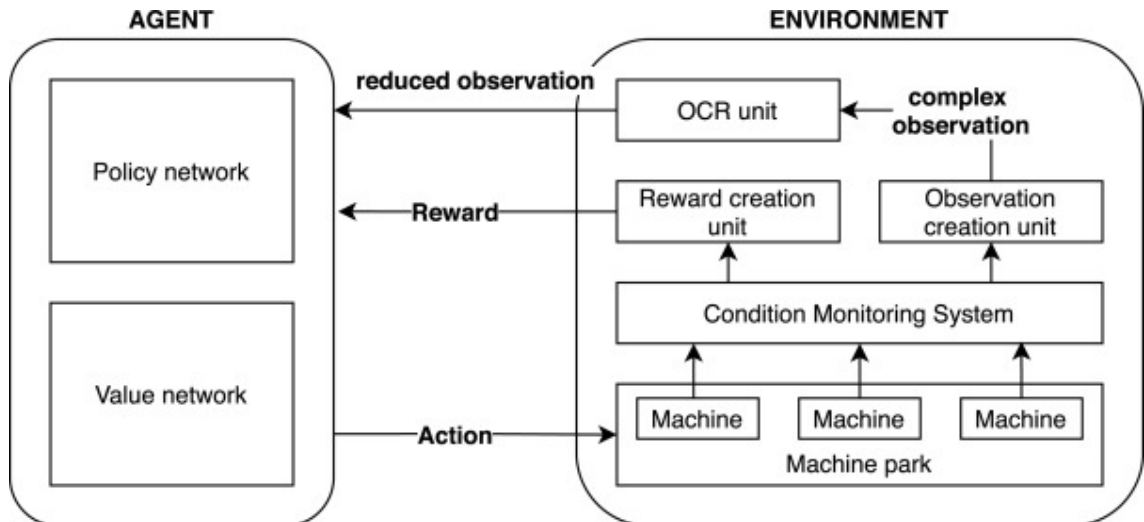


**Kuva 2.** Kaavio Sipos ym. (2014) tuloksista

Kuten kuvasta [2] on tulkittavissa, vika on ennustettavissa tutkimuksessa esitellyllä tavalla sitä tarkemmin, mitä lähempänä vikaantumista ollaan. Toisaalta tutkimuksessa huomattiin, että ennustettu todennäköisyys vikaantumiselle ei muuttunut aina päivien välillä sulavasti tai samaan suuntaan, mikä laski huomattavasti mallin luotettavuutta. Tutkimuksessa huomattiin myös tarkkuuden kasvavan sitä suuremmaksi, mitä enemmän tutkittavia ominaisuuksia datassa on. (Sipos ym. (2014))

## 4.2 Syvä- ja vahvistusoppimisen yhdistäminen ohjaavaan kunnossapitoon

Goby, Brandt ja Neumann (2023) esittelevät artikkelissaan, miten yhdistelemällä syväoppimista ja neuroverkkoja voidaan tehdä hyvinkin tarkkaa ja kustannustehokasta teollisuuden laitteiden ohjaavaa kunnossapitoa. Artikkelissa esitelty syväoppimisen ja neuroverkkojen yhdistelmä DRL (Deep Reinforcement Learning) toimii tässä tapauksessa siten, että neuroverkkojen avulla luodaan kullekin koneelle vaihtoehdot mitä huoltotoimenpiteitä niille voitaisiin tehdä kussakin aikaikkunassa ja toimenpiteille lasketaan palkkiot, joiden avulla vahvistusoppiminen voi määrittää mikä yhdistelmä toimenpiteitä on kannattavinta suorittaa. Palkkioiden määrittäminen on yleisestikin yksi tärkeimmistä vahvistusoppimi-



**Kuva 3.** Kaaviokuva datamallista DRL hyödyntämiseksi teollisuuden laitteiden ohjaavaan kunnossapitoon (Goby, Brandt ja Neumann [2023](#))

sen haasteista. Tässä tapauksessa palkkioiden määrittäminen perustuu olettamukselle, että huollettaessa konetta työntekijä pystyy määrittämään koneen todellisen jäljellä olevan turvallisen käyttöajan RULin (remaining useful life) ja arvioimaan tehdyn huoltopäätöksen oikeellisuutta. Lisäksi koko huollon tavoite on tehdä tasan niin vähän huoltoa, kuin tarvitaan jotta koneet toimivat. Tämän saavuttamiseksi palkkiot annetaan siten, että jos kaikki tutkittavat koneet toimivat, ja mitään niistä ei huolleta, palkkio on 1. Palkkio pienenee rangaistuksen verran, mikäli jokin koneista ei toimi ja sitä ei huolleta tai jos kone huolletaan, vaikka RULia on jäljellä vielä merkittävästi.

DRL onnistuu ratkaisemaan kummankin koneoppimistavan yksin käytettynä usein tapahtuvia perinteisiä ongelmia. Esimerkiksi vahvistusoppimisessa kaikkia havaintoja pidetään täysinä tosina ja teollisessa tosimaailman ympäristössä tulee huomattavan paljon vääriä havaintoja. Myöskään kaikkia mahdollisia vikatilanteita ei voi määrittää etukäteen. Neuroverkkojen avulla pystytään pienentämään yksittäisen väärän havainnon merkitystä ja tutkimaan yllättäviäkin tilanteita arvioimalla useita vaihtoehtoisia tapahtumaketjuja. Kun vahvistusoppiminen valitsee yhden yksittäisen valinnan sijasta parhaan valintaketjuista, sen tekemät valinnat ovat pitkänäköisempiä ja tarkempia. Lisäksi neuroverkot kykenevät löytämään piilotettuja rakenteita tutkittavasta datasta. (Goby, Brandt ja Neumann [2023](#))

Goby, Brandt ja Neumann ([2023](#)) esittelevät, miten DRL implementoidaan käytännössä kaavion [3](#) mukaan. Koneista kerätään sensoreilla dataa, jota Condition Monitoring System CMS esikäsittelee. Esikäsitellyn datan avulla lasketaan kyseisen aikaikkunan palkkio vahvistusoppimista varten ja sitä käsitellään edelleen Observation creation unitissa, jossa se muunnetaan Observation Confidence Ranking (OCR) -yksikön vaatimaan muotoon. OCR-yksikössä lasketaan todennäköisyys hajoamiselle seuraavassa aikaikkunassa historiadatalla opetetun deep feed-forward networkin avulla ja laskettujen todennäköisyyksien avulla laitetaan koneiden huoltotarpeet kriittisyysjärjestykseen. OCR-yksikkö

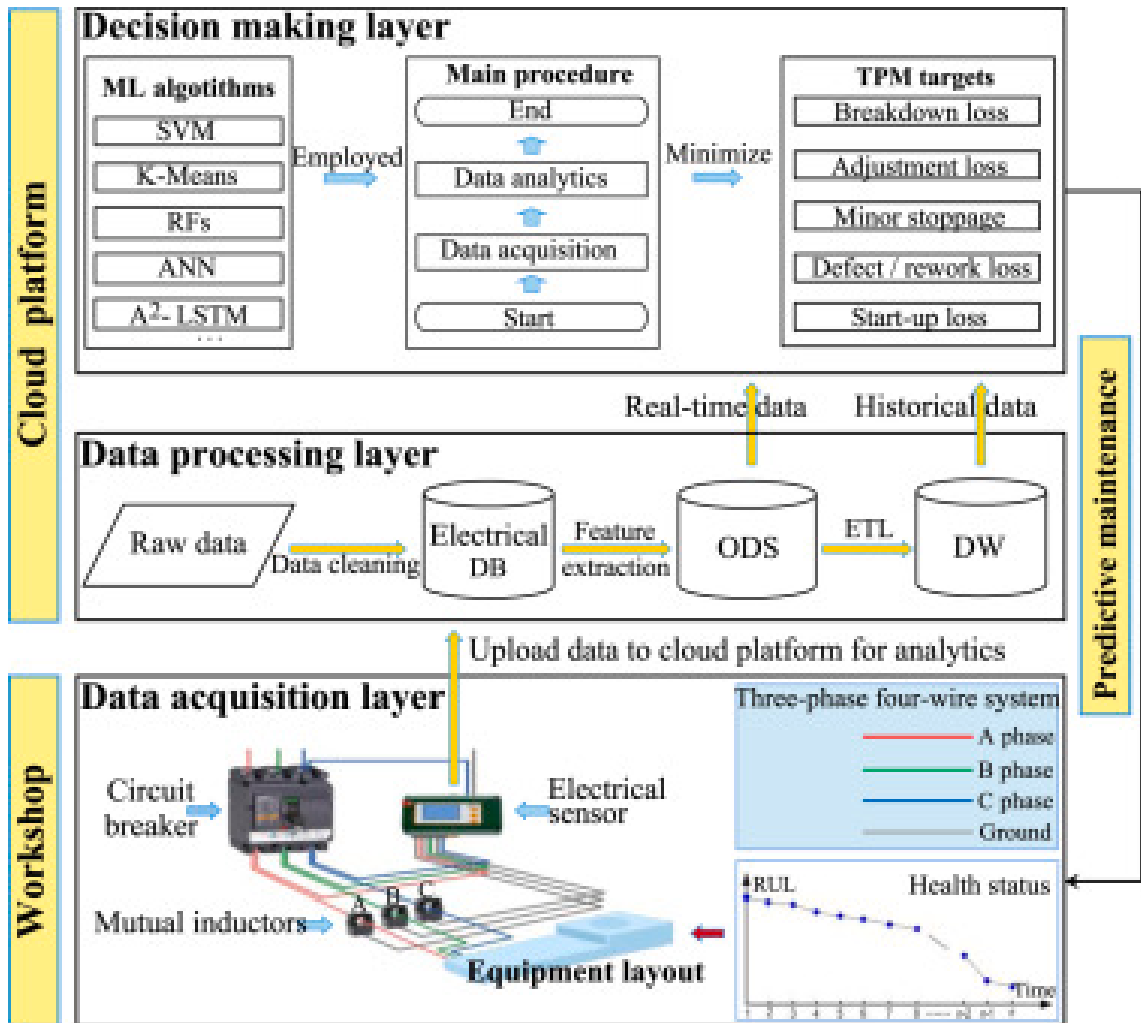
lähettää agentille laskemansa tiedot, joiden avulla agentti määrittää mitkä kaikki laitteet tarvitsevat huoltoa. Lopulta agentti valitsee huoltojärjestyksestä niin monta ensimmäistä huoltoa kaipaavaa laitetta huollettavaksi, kuinka monelle riittää huoltajia. Kun koneet huolletaan, huoltaja määrittää kuinka paljon koneella olisi ollut RULia jäljellä ja antaa sitten palautteen koneoppimisjärjestelmälle, jolloin koneoppimisjärjestelmän päätöksenteko tarkentuu entisestään.

### 4.3 A2-LSTM pohjainen ratkaisu ennakoivaan kunnossapitoon

Jiang ym. (2022) esittelevät tutkimuksessaan tavan toteuttavaa ennustavaa huoltoa keräämällä koneessa kulkevasta sähköstä tietoa ja muodostamalla A2-LSTM avulla ennustuksia koneen RULista. A2-LSTM (attribute attentioned long short-term memory) eli ominaisuudet huomioiva pitkäkestoinen lyhytkestomuisti on syväoppimiseen pohjautuva koneoppimismalli. A2 eli attribute attention tarkoittaa tässä tapauksessa sitä, että ennen LSTM ennustusta lasketaan, mitkä ovat datan tärkeimpiä ominaisuuksia. LSTM muodostaa niiden avulla ennustuksia mihin suuntaan ominaisuudet ovat menossa ja tulevien ominaisuuksien avulla ennustetaan RUL. RULin ennustamisella pyritään vähentämään koneiden hajoamista, säätöjen tarvetta, koneen tekemiä virheitä, seisakkia ja tarvittavia koneen käynnistyskertoja. Yleisesti LSTM on sarjojen seuraavien jäsenten ennustamiseen käytetty koneoppimismalli, joka käyttää ennustamisessa apunaan tiettyä määrää edeltäviä jäseniä ja edellisten ajokertojen tuloksia. Koska LSTM käyttää edellisen ajokerran tulosta seuraavan ajokerran lähtötietona, se kuuluu takaisinkytkettäviin neuroverkkoihin.

Jiangin ym. (2022) tutkimuksessa esitetty datamalli toimii kuvan 4 mukaisesti. Koneesta kerätään sähkötietoa kolmesta eri vaiheesta ja saatu tieto ladataan pilveen analytiikan hyödynnettäväksi. Pilvessä data esikäsitellään ja sen jälkeen reaaliaikainen data siirretään operatiivisen datan säiliöön (ODS) ja historiallinen data tietovarastoon (DW). Sen jälkeen valitulla koneoppimismallilla pyritään ennustamaan RUL, jotta saavutetaan tutkimuksessa asetetut huoltomenetelmän tavoitteet.

Jiang ym. (2022) esittelevät, että jos datamallissa hyödynnetään koneoppimismallina A2-LSTM pohjaista ennustusmallia, on ennustusmallilla neljä kerrosta. Ensimmäisellä kerroksella poistetaan manuaalisesti datasta joko tarpeettomia tai sähkötekniikan tuntemuksen avulla laskettavia piirteitä. Tämä parantaa koneoppimismallin suorituskykyä. Toisella kerroksella pyritään arvioimaan teollisuuslaitteiston terveystilaa yhdistämällä virta, jännite, teho, tehokertoimet ja taajuus yhdeksi attribuutiksi. Kolmannella kerroksella toteutetaan A2 eli annetaan eri ominaisuuksille omat painoarvonsa LSTM analyysin hyväksi syväoppimisen avulla. Neljännellä ja viimeisellä tasolla LSTM ennustaa tulevia ominaisuuksia, joiden avulla syväoppimismalli fully connected layers eli FC ennustaa RULin. Tutkimuksessa huomattiin esitellyn mallin olevan usein tehokkaampi ja heikoimmillaankin yhtä tehokas, kuin muut yleisesti tunnetut koneoppimismallit.



**Kuva 4.** Kaaviokuva datamallista A<sup>2</sup>-LSTM hyödyntämiseksi teollisuuden laitteiden ennustavaan kunnossapitoon (Jiang ym. 2022)

#### 4.4 Tapaustutkimusten vertailu

Tutkimissani case studyissa oli keskenään hyvin erilaiset datan keruutavat. Siposin ym. (2014) ja Gobyin, Brandtin ja Neumannin (2023) tutkimuksia yhdistää, että niissä analysoidaan joka tapauksessa kerättävää dataa, kun taas Jiang ym. (2022) lisäävät laitteisiinsa sensoreita keräämään dataa juurikin data-analytiikan ja koneoppimisen mahdollistajaksi. Gobyin, Brandtin ja Neumannin (2023) datan keruumenetelmät olivat nykyteollisuudelle tavanomaisimpia, sillä hyvin useissa yrityksissä tehdään jo ennestään jonkinlaista data-analytiikkaa kunnonvalvonnan hyväksi. Kuitenkin ennakoivan ja ehkäisevän valvonnan teorioissa suunnitellaan pääsääntöisesti ennustaminen tehtäväksi laajan suoraan koneista sensoreilla kerättävän data-aineiston pohjalta. Sipos ym. (2014) edustaa toista ääripäätä, sillä he eivät kerää dataa lainkaan suoraan laitteelta sensorien avulla, vaan konetta ajavan ohjelmiston lokista. Ratkaisu osoittaa, että koneoppiminen ei aina vaadi mittavia investointeja sensoreihin ollakseen hyödyntämiskelpoista. Jiangin ym. (2022) suorittama tutkimus asettuu datan keruutavaltaan kahden aiemman väliin. Siinä hyödynnetään sen-



soreita, mutta niitä asennetaan vain vähän. Mielestäni datan keruumenetelmistä paras on Goby, Brandtin ja Neumannin (2023) esittelemä, sillä sen avulla saadaan kattavin ja tarkin aineisto data-analytiikkaa varten. Toisaalta on hyvä tiedostaa, kuten kaksi muuta tutkimusta osoittaa, heikommallakin aineistolla pärjää.

Datan keruumenetelmillä on suuret vaikutukset data-analyysin suorittamiseen. Jiangin ym. (2022) datamallin avulla päästään helpoimmalla datan esikäsittelyllä, sillä dataa on näistä tutkimuksista vähiten ja se on muodoltaan tasalaatuisinta. Toisaalta analyysivaiheessa se vaatii eniten viitekehyksen tuntemusta, jotta niin vähästä ja tiukasti tapaukseen liittyvästä tiedosta saadaan tehtyä luotettavia päätelmiä. Siposin ym. (2014) tutkimuksessa vaaditaan eniten esikäsittelyä, sillä aineisto on suurin ja standardoimattomin. Toisaalta sen käsittely ei vaadi juurikaan tarkempaa viitekehyksen tuntemusta, sillä data on äärimmäisen moninaista ja sitä käsitellään antamatta yksittäisille havainnoille suurta painoarvoa. Goby, Brandt ja Neumann (2023) tutkimuksessa datan esikäsittely on lähes yhtä helppoa kuin Jiangilla ym. (2022), sillä dataa on paljon, mutta se on kerätty jo valmiiksi huoltotarpeen seurannan hyödyksi.

Koneoppimisen suhteen ainoastaan Sipos ym. (2014) hyödyntävät pelkästään yhtä koneoppimismallia. Jiangin ym. (2022) saamien tulosten perusteella hyödyntämällä samanaikaisesti useampia koneoppimismalleja saa usein tarkempia ja vähintään yhtä tarkkoja ennustuksia kuin käyttämällä yksittäistä koneoppimismallia. Goby, Brandt ja Neumann (2023) vertailevat esitettyä koneoppimismallien yhdistelmää vain koneoppimista hyödyntämättömiin huoltotapoihin, jotka se päihittää selvästi sekä ennustustarkkuudessa, että kustannustehokkuudessa. Sipos ym. (2014) ja Jiang ym. (2022) käsittelevät kustannuksia vain ohimennen. Sipos ym. (2014) mainitsevat ainoastaan esitellyn koneoppimismallin tuovan säästöjä koneiden huoltokustannuksiin ja Jiang ym. (2022) käsittelevät kustannuksia kunnolla pelkästään huoltotapojen esittelyn yhteydessä. Kummassakaan tutkimuksessa ei oteta tarkemmin kantaa itse analyysin kustannuksiin, tutkita tuleeko analyysi halvemmaksi kuin saavutetut säästöt huoltokustannuksissa tai verrata esitellyn koneoppimistavan kustannuksia muihin huoltotapoihin ja koneoppimismenetelmiin. Kuitenkin kaikissa kolmessa tutkimuksessa tullaan samaan lopputulokseen, että koneoppimismalliin pohjautuva huoltotapa on tehokas ja järkevä ratkaisu toteuttaa teollisuuden koneiden huoltoa.

## 4.5 Päätelmät

Vaikka kaikissa kolmessa tutkimuksessa datan keruutavat, analyysimenetelmät ja koneoppimismallit olivat erilaisia, niiden käytännön toteutuksen kannalta olennaiset vaatimukset olivat yllättävän samanlaiset. Jokaisessa tutkimuksessa korostui tarve hankkia laadukasta dataa, omaksua kontekstintuntemusta, suorittaa data-analyysiä sekä hyödyntää tehokasta koneoppimismallia. Menetelmien moninaisuus osoittaa, että näitä perusvaatimuksia voidaan soveltaa menestyksekkäästi erilaisiin laitteisiin ja ympäristöihin. Toisaalta yleiset vaatimukset tiedostamalla koneoppimismallien saavuttamia tuloksia pystyy entisestään parantamaan. Kontekstintuntemuksen hyödyntäminen oli kaikissa tapaustutkimuksissa tähän tehokas tapa. Silti myös laajaa datajoukkoa tarvitaan, jotta koneoppimismalli pystyy hahmottamaan datasta mahdollisia ihmiselle näkymättömiä riippuvuuksia.

Kun teollisuuden huoltostrategiassa hyödynnetään koneoppimista, itse datamallille ei ole juurikaan väliä onko kyseessä ennakoiva vai ohjaava huolto. Data-analyysissä muuttuu tällöin useimmiten ainoastaan käytettävä koneoppimismalli, sillä ohjaavaa huoltoa tehdessä täytyy oikeastaan vain pystyä ennustamaan hieman pidemmälle monipuolisemmin ja luotettavammin kuin ennakoivassa huollossa.

## 5. YHTEENVETO

Koneoppimista on mahdollista hyödyntää teollisuuden koneen huoltotarpeen ennustamiseen. Se vaatii toimiakseen luotettavasti huomattavan panostuksen data-analytiikkaan ja -arkkitehtuuriin. Nykyisin teollisuudessa kertyy kuitenkin joka tapauksessa paljon dataa ja koneoppimismalli pystytään useissa tapauksissa istuttamaan jopa lähes suoraan muutenkin yrityksessä tehtävän data-analytiikan päälle. Mikäli dataa tarvitsee kerätä, datan keräämisen voi toteuttaa luovuuden rajoissa luotettavasti monin erilaisin tavoin ja se voi tapahtua muutenkin kuin kalliisti ja monimutkaisesti. Teollisuuden laitteen huoltotarpeen ennustamiseen pyrkivän data-analyysin vaiheet ovat hyvin samanlaiset riippumatta datan keruutavasta ja valitusta huoltostrategiasta, vaikka vaiheet pystytään toteuttamaan erilaisin tavoin. Kaikki huoltostrategiat eivät kuitenkaan nojaa data-analyysin hyödyntämiseen ja kullakin huoltostrategialla on omat vahvuutensa.

## LÄHTEET

- Abubakr, Mohamed et al. (2021). "Sensors selection for tool failure detection during machining processes: A simple accurate classification model". In: *CIRP journal of manufacturing science and technology* 32, pp. 108–119. URL: <https://doi.org/10.1016/j.cirpj.2020.12.002>.
- Ajayi, Olasupo, Antoine Bagula, and Hloniphani Maluleke (2022). *The Fourth Industrial Revolution: A Technological Wave of Change*. IntechOpen. URL: <https://doi.org/10.5772/intechopen.106209>.
- Goby, Niklas, Tobias Brandt, and Dirk Neumann (2023). "Deep reinforcement learning with combinatorial actions spaces: An application to prescriptive maintenance." In: *Computers Industrial Engineering* 179. URL: <https://doi.org/10.1016/j.cie.2023.109165>.
- Hanly, Steve (2020). *Differences Between Condition-Based, Predictive, and Prescriptive Maintenance*. *Types of maintenance*. URL: <https://blog.endaq.com/differences-between-condition-based-predictive-and-prescriptive-maintenance> (visited on 11/23/2023).
- Hunziker, S. et al. (2017). "Identifying, attributing, and overcoming common data quality issues of manned station observations". In: *International journal of climatology* 37.11, pp. 4131–4145. URL: <https://doi.org/10.1002/joc.5037>.
- Jiang, Yuchen et al. (2022). "A2-LSTM for predictive maintenance of industrial equipment based on machine learning". In: *Computers Industrial Engineering* 172. URL: <https://doi.org/10.1016/j.cie.2022.108560>.
- Kämäräinen, Joni (2023). *Koneoppimisen perusteet*. Helsinki: Otatieto.
- Lindström, Veronica et al. (2023). "Data quality issues in production planning and control – Linkages to smart PPC". In: *Computers in industry* 147, p. 103871. URL: <https://doi.org/10.1016/j.compind.2023.103871>.
- R. Patil, Chaitali et al. (2023). "Machine Learning-Based Predictive Maintenance of Industrial Machines". In: *International journal of computer trends and technology* 71.3, pp. 50–56. URL: <https://doi.org/10.14445/22312803/IJCTT-V71I3P108>.
- Runkler, Thomas A. (2012). *Data Analytics: Models and Algorithms for Intelligent Data Analysis*. Wiesbaden: Springer Nature, pp. 1–21. URL: <https://doi.org/10.1007/978-3-8348-2589-6>.
- Sipos, Ruben ym. (2014). "Log-based predictive maintenance". Teoksessa: ACM, s. 1867–1876. URL: <https://doi.org/10.1145/2623330.2623340>.

Vermeulen, Andreas François (2020). *Industrial Machine Learning Using Artificial Intelligence as a Transformational Disruptor*. Berkeley, CA : Apress : Imprint: Apress. URL: [https://doi.org/10.1007/978-1-4842-5316-8\\_8](https://doi.org/10.1007/978-1-4842-5316-8_8).