



Juulia Savela

# Tekoäly ennakoivassa kunnossapidossa

Metropolia Ammattikorkeakoulu

Insinööri (AMK)

Sähkö- ja automaatiotekniikka

Insinöörityö

13.5.2024

# Tiivistelmä

Tekijä: Juulia Savela  
Otsikko: Tekoäly ennakoivassa kunnossapidossa  
Sivumäärä: 32 sivua  
Aika: 13.5.2024

Tutkinto: Insinööri (AMK)  
Tutkinto-ohjelma: Sähkö- ja automaatiotekniikka  
Ammatillinen pääaine: Automaatiotekniikka  
Ohjaajat: Lehtori Kristian Junno

---

Tämän insinööriyön tavoitteena oli luoda kirjallisuuskatsaus ajankohtaisimmista tutkimuksista tekoälyn hyödyntämisestä ennakoivan kunnossapidon toteutuksissa. Työn loppululoksena oli tarkoitus muodostaa lukijalle kattava tietopaketti ennakoivan kunnossapidon ja tekoälyn suhteesta, trendeistä ja haasteista.

Tiedonhankinta työn aikana suoritettiin valikoimalla uusimpia tutkimuksia aiheesta luotettavilta tieteellisten julkaisujen alustoilta. Aihetta tutkittiin sekä kunnossapidon että tekoälyn näkökulmasta ja tietoa kerättiin myös tunnettujen teknologia-alan yritysten verkkolähteistä.

Työ antaa katsauksen ennakoivaan kunnossapitoon ja sen merkitykseen sekä käy läpi uusimpia julkaisuja tekoälyn hyödyntämisestä ja haasteista. Katsauksessa käymme läpi kunnossapidon ja koneoppimisen menetelmiä ja kartoitamme tutkimuksista käytetyimpiä malleja. Työn lopputulos tarjoaa tietoa uusimmasta kirjallisuudesta kunnossapidon ja tekoälyn yhdistämisestä antaen lukijalle näkemyksen koneoppimisesta ennakoivassa kunnossapidossa, suosituimmista koneoppimisen malleista, implementoinnin haasteista ja tulevaisuuden suunnasta.

Avainsanat: tekoäly, koneoppiminen, ennakoiva kunnossapito

---

Tämän opinnäytetyön alkuperä on tarkastettu Turnitin Originality Check -ohjelmalla.

## Abstract

Author: Juulia Savela  
Title: Artificial Intelligence in Predictive Maintenance  
Number of Pages: 32 pages  
Date: 13 May 2024

Degree: Bachelor of Engineering  
Degree Programme: Electrical and Automation Engineering  
Professional Major: Automation Engineering  
Supervisors: Kristian Junno, Senior Lecturer

---

The aim of this thesis study was to construct a literature review of the latest research on the utilization of artificial intelligence in predictive maintenance. The intended result was to provide the reader with a comprehensive review of the role of artificial intelligence in predictive maintenance, its trends, and challenges.

During this project, information was gathered by selecting recent studies from trusted scientific publication platforms. The subject of the thesis study was examined from both maintenance and artificial intelligence perspectives, and information was also collected from well-known technology companies' online sources.

This thesis presents a review into predictive maintenance and its significance, while analyzing recent publications on the utilization and challenges of artificial intelligence in its implementations.

The result of this study is a comprehensive review on the latest research of combining maintenance and artificial intelligence, providing the reader insight into machine learning in predictive maintenance, popular machine learning models, challenges in implementation and future directions.

Keywords: Artificial intelligence, Machine Learning, Predictive Maintenance

# Sisällys

## Lyhenteet

1	Johdanto	1
2	Kunnossapito	2
2.1	Mitä on kunnossapito ja miksi sitä tarvitaan	2
2.2	Kunnossapidon historiaa	3
2.3	Teollisuus 4.0 ja ennakoiva kunnossapito	5
2.4	Tulevaisuus ja teollisuus 5.0	8
3	Tiedonhakuprosessi	8
4	Tekoälyn soveltaminen ennakoivassa huollossa	9
4.1	Tekoälyn määritelmä lyhyesti	9
4.2	Keskeisimmät koneoppimisen menetelmät	10
4.2.1	Ohjattu oppiminen	12
4.2.2	Puoliohjattu oppiminen	13
4.2.3	Ohjaamaton oppiminen	13
4.2.4	Vahvistettu oppiminen (Reinforcement learning)	13
4.2.5	Syväoppiminen ja neuroverkot	14
5	Koneoppimisen algoritmit ennakoivassa kunnossapidossa	14
5.1	Koneoppimisen hyödyntäminen vertailua	14
5.1.1	Ensimmäinen katsaus: Mallit ajoneuvoteollisuudessa	15
5.1.2	Toinen katsaus: Kohti kestäväää älykästä teollisuutta	18
5.1.3	Kolmas katsaus: Raideteollisuus ja ennakoiva kunnossapito	20
5.2	Yhteistulokset	23
5.3	Haasteet tekoälyn soveltamisessa	25
5.4	Tulevaisuus	26
6	Yhteenveto	28
	Lähteet	30

## Lyhenteet

- AI: *Artificial Intelligence*, tekoäly. Koneen kyvykkyys oppia ja olla älykäs.
- ANN: *Artificial Neural Network*, keinotekoinen neuroverkko. Tekoälyn osa-alue.
- CNN: *Convolutional Neural Network*, konvoluutioneuroverkko. Neuroverkkomalli, jota käytetään paljon kuvantunnistukseen.
- DL: *Deep Learning*, syväoppiminen. Tekoälyn osa-alue.
- ELM: *Extreme Machine Learning*, neuroverkkomalli.
- IoT: *Internet of Things*, esineiden internet. Kaikkien esineiden yhdistämistä verkkoon.
- k-NN: *k-Nearest Neighbor*, suosittu koneoppimisen malli, jota käytetään klassifikaatioon ja regressioon.
- LSTM: *Long Short Term Memory*, Neuroverkkoarkkitehtuuri, joka on takaisinkytketyn verkon variantti.
- ML: *Machine Learning*, koneoppiminen. Tekoälyn osa-alue.
- MLP: *Multilayer Perceptron*, Monikerroksinen perseptroniverkko. Keinotekoinen neuroverkkoarkkitehtuuri.
- PdM: *Predictive Maintenance*, ennakoiva kunnossapito. Ennakointiin perustuva kunnossapidon muoto.
- RUL: *Remaining Useful Life*, jäljellä oleva käyttöikä. Kunnossapidon menetelmä.

- RL: *Reinforced Learning*, vahvistettu oppiminen, koneoppimisen malli.
- RNN: *Recurrent Neural Network*, takaisinkytketty neuroverkko, neuroverkkoarkkitehtuuri.
- SVM: *Support Vector Machines*, tukivektorikoneet. Suosittu koneoppimisen malli.
- SVR: *Support Vector Regression*, tukivektoregressio. Tukivektorikoneen regressiovariantti.

# 1 Johdanto

Tämän insinööriyön tarkoituksena on kartoittaa uusinta kirjallisuutta tekoälyn käytöstä ennakoivan kunnossapidon toteutuksissa. Tavoitteena on saada mahdollisimman ajankohtainen katsaus tämänhetkiseen kirjallisuuteen aiheesta. Tutkittavat aineistot on kerätty viimeisen neljän vuoden sisään tulleista julkaisuista (2020–2024).

Teollisuudenaloilla tekoälyn hyödyntäminen on kasvanut merkittävästi viime vuosina [1]. Tekoälystä on kehittynyt tärkeimpiä työkaluja myös ennakoivassa kunnossapidossa. Neljännen teollisen vallankumouksen, teollisuus 4.0 tuoman kehityksen myötä tekoälyä kyetään soveltamaan laajasti ennakoivan kunnossapidon toteutuksissa. Ennakoivalla kunnossapidolla voidaan tarkkoja yksityiskoh-  
tia myöten parantaa koko tuotannon tehokkuutta ja kestävyyttä, vähentää kustannuksia, taukoja tuotannossa ja käyttöhäiriöitä. [2; 3.]

Ennakoivalla kunnossapidolla on valtava vaikutus teollisuudenalojen tuottoon, kestävyyteen ja toimivuuteen. Mitä paremmin kunnossapitoa kyetään ennakoimaan sitä tehokkaampi ja luotettavampi tuotto saavutetaan. Kunnossapidon sujuva toimivuus parantaa myös merkityksellisesti turvallisuutta sekä kestävyyttä. Tekoälyn kehittyessä ennakoivan kunnossapidon tarkkuus ja hyöty kasvaa entisestään. [2;3.]

Kunnossapidon muutos kolmannesta teollisesta vallankumouksesta neljänteen on ollut alaa mullistava, sillä se toi mukanaan esimerkiksi digitaaliset ratkaisut ja IoT-pilvijärjestelmät, jotka mahdollistavat massadatan keräämisen ja analysoinnin. Teollisuus 4.0:n myötä kunnossapito muuttui ennakoivaksi ja tekoälyä on alettu hyödyntämään aktiivisesti. [2.]

Tässä insinööriyössä käymme läpi kunnossapidon historiaa ja muutoksia kohti ennakoivaa kunnossapitoa, tekoälyä ja koneoppimista sekä nykyisiä tekoälyn hyödyntämisen menetelmiä ennakoivassa kunnossapidossa. Katsauksessa kartoitetaan ja vertaillaan koneoppimisen menetelmien käyttöä teollisuudenaloilla

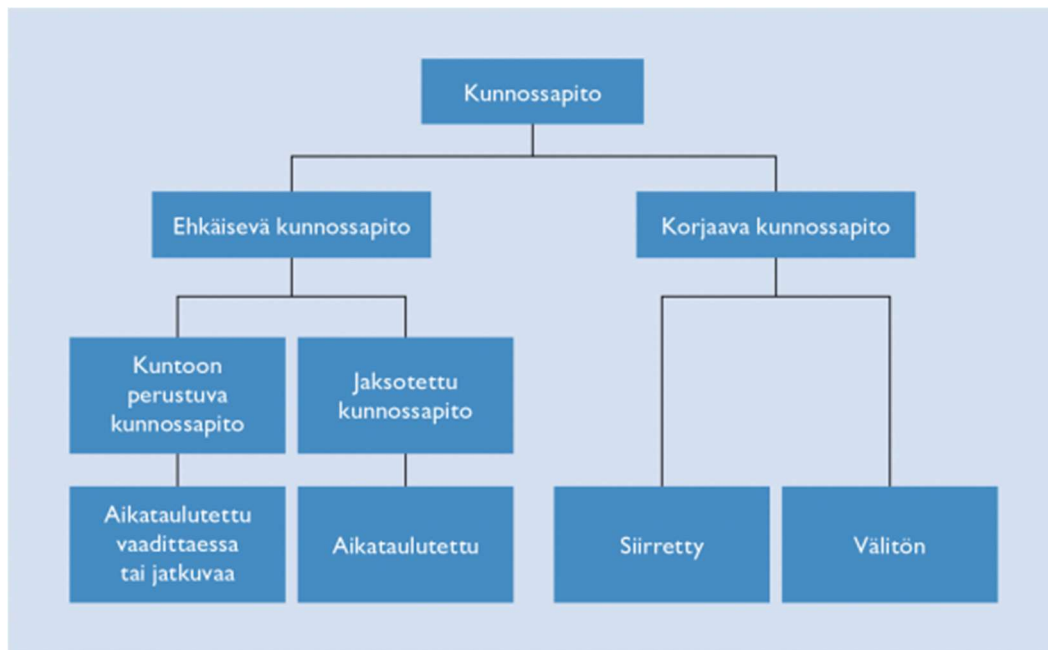
sekä pohditaan haasteita ennakoivan kunnossapidon toteutuksissa. Työn pyrkimyksenä on kerätä lukijalle ajankohtaisinta tietoa ennakoivan kunnossapidon toteutuksista ja haasteista.

## **2 Kunnossapito**

### **2.1 Mitä on kunnossapito ja miksi sitä tarvitaan**

Kunnossapidolla tarkoitetaan koneen tai laitteiston kunnon, luotettavuuden ja toimivuuden ylläpitoa erilaisilla tekniikoilla, toimenpiteillä ja menetelmillä. Kunnossapidolla huolehditaan koneiden ja laitteistojen toimintakyvystä, kunnosta ja elinkaaren pidentämisestä. [4.]

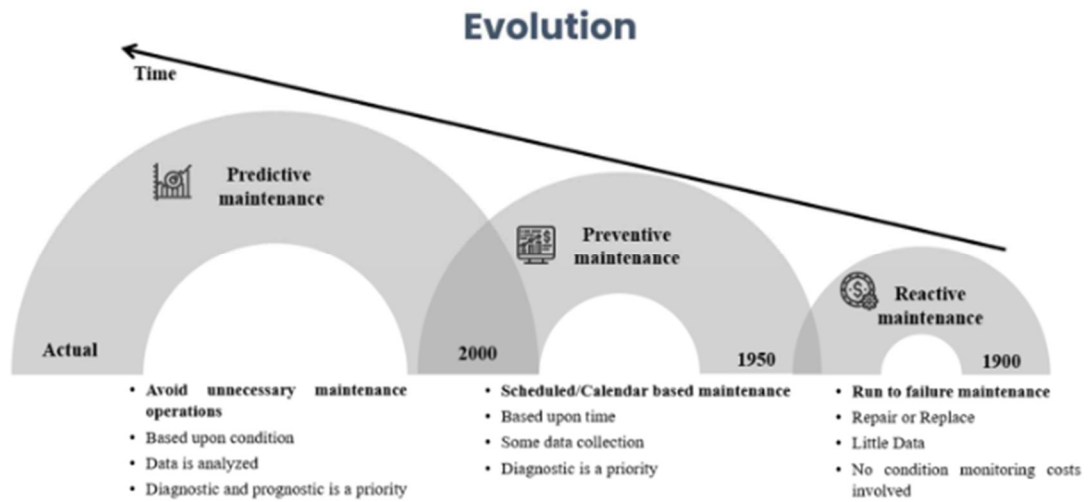
Kunnossapitoa voidaan toteuttaa useilla eri tavoilla. Ennen ennakointikykyä kunnossapito jakautui ehkäisevään ja korjaavaan kunnossapitoon ja niiden eri toimintamuotoihin. Kuvassa 1 on esitelty kunnossapidon toimintamuotoja. [4.] Nykyisin kolmantena muotona on myös ennakoiva kunnossapito, joka yleistyi neljännen teollisen vallankumouksen tuomien uusien teknologioiden myötä. Kunnossapidolla pyritään ehkäisemään ja ennakoimaan vikoja ja huoltotarpeita. Sillä on keskeinen rooli teollisuudessa ja se edistää merkittävästi tuottavuutta, kestävyyttä, turvallisuutta ja tehokkuutta. [2; 4.]



Kuva 1. Kunnossapitoyhdistys Promaintin visualisointi kunnossapidon tyypeistä [4].

## 2.2 Kunnossapidon historiaa

Ennen kolmatta teollista vallankumousta kunnossapito oli reaktiivista, ja huolto- toimenpiteet tapahtuivat usein vasta selkeiden ongelmien ilmetessä tai aikatau- lutettuina huoltoina ja tarkastuksina. Teollisuuden kehittyessä kunnossapidon tehokkuus on ollut nousujohteista ja kehittynyt tehokkaammaksi. Kuvassa 2 on visualisoitu kunnossapidon evoluution nousujohteisuutta. Kolmas teollinen val- lankumous teollisuus 3.0 toi mukanaan teollisuudenaloille ohjelmoitavia logii- koita, automaation, prosessiautomoisoinnin ja informaatioteknologian. Uusien teknologioiden hyödyntäminen mahdollisti kunnossapidossa automatisoitujen antureiden käyttämisen kunnossapidon toteuttamisessa. Tiedonkeruu oli kuiten- kin vielä manuaalista ja riippuvaista alkeellisista analyysitekniikoista. Anturien näyttämien tietojen avulla kyettiin ennakoimaan valvomalla kunnossapidon tar- peita, mutta ennakointi tapahtui manuaalisesti ihmistyövoimalla. Teollisuus 3.0:n aikainen kunnossapito oli pääasiallisesti manuaalisen ihmistyövoiman ta- kia vain ennaltaehkäisevää. [2; 3; 5.]



Kuva 2. Kunnossapidon evoluutio visualisoituna [5].

Ennakoinnin kyvykkyys oli 3.0:n aikana vielä rajoitettua ja perustui usein yksinkertaiseen sääntöpohjaiseen lähestymiseen tai tilastotietokone-analyysiin. [2] Kunnossapito oli pääosin reaktiivista ja kunnossapitotoimenpiteitä suoritettiin usein vasta, kun ongelmia huomattiin. Taulukossa 1 on luokiteltu teollisuus 3.0:n ja 4.0:n välisiä eroavaisuuksia.

Taulukko 1. Teollisten vallankumousten tuomia muutoksia kunnossapitoon [2].

	Teollisuus 3.0	Teollisuus 4.0
Kunnossapitokäytäntö	Ennaltaehkäisevä kunnossapito	Ennakoiva kunnossapito
Teknologinen innovaatio	Automaatio, tietokoneet	Digitaaliset ratkaisut, IoT, pilviratkaisut

Teknologia	Anturien moniointi	Datan käsittely ja ennakoiva analytiikka
Laitteiston kokonaistehokkuus	70-90%	>90%

Taulukosta ilmenee selkeästi muutos kokonaistehokkuudessa. Teollisuus 3.0 aikainen 70–90 % kunnossapidon kokonaistehokkuus on noussut ennakoivan kunnossapidon myötä minimissään 90 % tasolle.

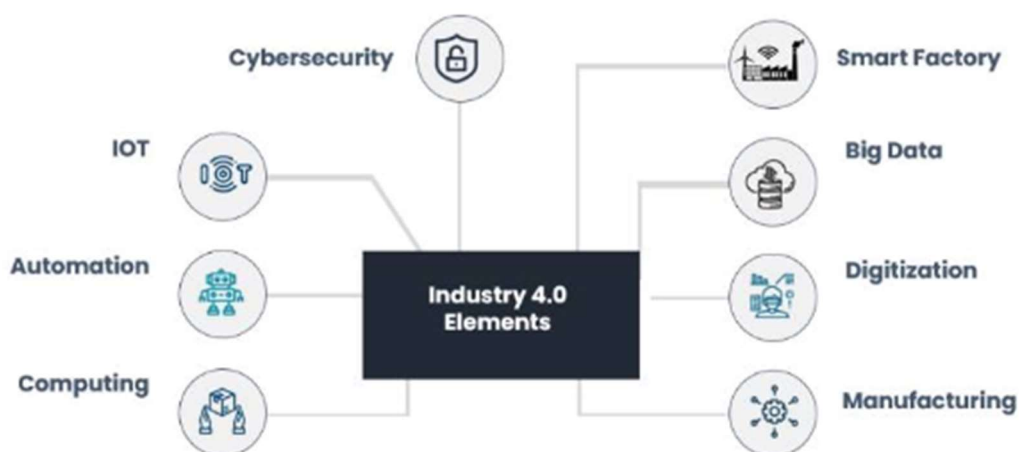
### 2.3 Teollisuus 4.0 ja ennakoiva kunnossapito

Neljäs teollinen vallankumous on vaikuttanut huomattavasti kunnossapitoon teollisuusalalla. Se toi mukanaan uutta teknologiaa, joiden avulla voitiin siirtyä ennakoivaan kunnossapitoon. Ennakoiva kunnossapito, PdM (Predictive Maintenance) nosti merkittävästi myös laitteiston kokonaistehokkuutta. [2.] Uusista teknologioista merkittävimpiä etenkin ennakoivan kunnossapidon näkökulmasta ovat:

- IoT (Internet of Things, esineiden internet), järjestelmä, jossa laitteet voivat kommunikoida langattomasti verkossa keräten ja siirtäen dataa.
- Pilvipalvelut (Cloud Computing) eli internetin välityksellä toimiva tietojenkäsittely, jonka avulla palveluita voi tehdä langattomasti verkon kautta.
- Reunalaskenta (Edge Computing) mahdollistaa datan prosessoinnin sen lähteen lähellä. Reunalaskenta mahdollistaa sen, että dataa ei tarvitse käsitellä keskitetyssä paikassa.
- Digitaalisen kaksonen, (Digital Twin) joka on virtuaalinen versio fyysisestä kohteesta. Sen avulla voidaan simuloida kohteen toimintaa.

- Tekoäly ja koneoppiminen, eli koneen kyvykkyyden oppia, päätellä, suunnitella.
- Massadata (Big Data) eli valtavien datamäärien käsittely, kerääminen ja siirto.

Uudet teknologiat mahdollistavat tiedonkeruun ja seurannan reaaliaikaisesti, mikä mahdollistaa tarkan jatkuvan tiedon kunnosta sekä sen analysoinnin suurien datamäärien perusteella. Kuvassa 3 on visualisoitu teollisuus 4.0:n mukana tuomia teknologisia muutoksia. [2; 6.]



Kuva 3. Teollisuus 4.0:n vaikuttavat elementit teollisuudessa [5].

Koneoppimisen hyödyntämisen myötä kyky ennakoida laajan tietomäärän perusteella mahdollistaa huomattavan ennakointikyvyn ja muutosten huomaamisen laitteiden toiminnassa. Koneoppimisen algoritmit kykenevät annetun datan perusteella huomaamaan muutoksia tai kaavoja laitteiston toiminnassa. Viat kyetään ennaltaehkäisemään ja ennakoimaan, huollon tarve ja ajoitukset voidaan optimoida sekä seisokit kyetään minimoimaan tai parhaimmillaan estämään kokonaan. Muutos verrattuna teollisuus 3.0:n aikaiseen ennaltaehkäisemään kunnossapitoon on merkittävä. Aikaisemmat kokonaistehokkuudet ovat olleet huomattavasti pienempiä ja alttiita inhimillisille virheille. Älykkään

ennakoinnin myötä kokonaisuustehokkuudet ovat nousseet merkittävästi, ollessa vähintään 90 %:n tasolla. [2; 5; 6.]

Ennakoiva kunnossapito kykenee vähentämään tehokkaasti kustannuksia ja lisäämään laitteiston elinkaarta ja kestävyyttä. Ennakoivan kunnossapidon implementointi on sijoituksena suuri, mutta tuo mukanaan merkittäviä kustannussäästöjä. [2; 5.] Tutkimuksista on selvinnyt useita eri hyötyjä, joita ennakoivan kunnossapidon ja tekoälyn implementointi voi tuoda mukanaan:

- kyvykkyys päätellä huoltotoimenpiteille sopiva aikaväli
- parantaa tuotantoa ja huoltoprosessia
- ylläpitää korkeaa laatutasoa.
- vikojen ja huoltotoimenpiteiden kustannuksien minimointi
- kyky implentoida niin sanottu "zero-failure strategy" eli nolla vikatilaa strategia, pyrkimys siihen, ettei vikatiloja tai häiriöitä tule ollenkaan
- ennakoiva analyysi
- koneiden välinen kommunikointi ja interaktio
- kunnossapitoon liittyvän tiedon generointi ja ennustaminen
- reaaliajassa tapahtuvan ja historiallisen datan kerääminen suurissa määrissä
- kilpailukyvyyn parantaminen
- pidentää laitteiston ikää
- parantaa turvallisuutta ihmisille ja laitteistolle

- tehokkaampaa resurssien käyttöä
- luotettavampi toimivuus.

Teollisuus 4.0 tuo useita parannuksia kunnossapidon toimintaan ja optimointiin. Ennakoiva kunnossapito tuo huoltoon merkittäviä helpotuksia ja parannuksia. [7; 8.]

## 2.4 Tulevaisuus ja teollisuus 5.0

Teollisuuden kehittymisen ja tekoälyn runsaan hyödyntämisen myötä tulevaisuuden teollisuuden vallankumous teollisuus 5.0 keskittyy ihmisen ja ympäristön hyvinvointiin tähtäävään teknologiaan. Teollisuus 5.0 tulevaisuuden näkymän on kuvattu olevan keskittynyt ihmisen ympärille, luomaan hyvinvointia ja vahvempaa yhteistyötä tekoälyn ja ihmisen välille, Euroopan unionin määritelmän mukaan perustuen ihmisläheiseen, kestävään ja luontoystävälliseen teollisuuteen. [9; 10.]

## 3 Tiedonhakuprosessi

Tämä insinööriyö on toteutettu kuvailevana kirjallisuuskatsauksena, sillä se soveltuu hyvin tilanteeseen, jossa tarkastelemme rajatun aikavälin tutkimuksia saadaksemme parhaimman käsityksen tilanteesta ennakoivan kunnossapidon ja tekoälyn yhdistämisestä teollisuuden alalla. Uusimpia julkaisuja aiheesta käsitellessä keskeisimmiksi tutkimuskysymyksiksi nousi neljä eri kysymystä:

1. Miten tekoäly vaikuttaa ennakoivaan kunnossapitoon?
2. Mitkä ovat yleisimpiä tekoälyn sovelluskeinoja teollisuudenalalla?
3. Mitkä ovat suurimmat ongelmat tekoälyn hyödyntämisessä ennakoivassa kunnossapidossa?

#### 4. Mihin suuntaan ennakoiva kunnossapito on kehittymässä tulevaisuudessa?

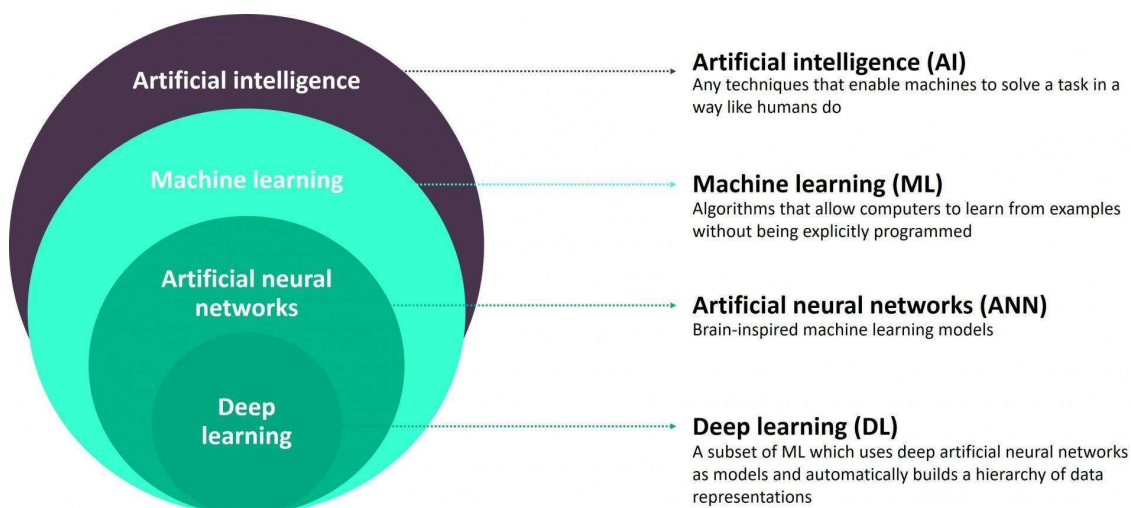
Kirjallisuuskatsauksen lähteiksi valittiin uusimpia alan julkaisuja aiheesta viimeisen neljän vuoden ajalta 2020–2024. Katsauksen tiedonhaku keskitettiin mahdollisimman uusiin julkaisuihin, jotta saadaan mahdollisimman ajankohtainen kuva tekoälyn ja koneoppimisen hyödyntämisestä ennakoivassa kunnossapidossa. Tutkimuslähteiden hakuun käytettiin tunnettuja luotettavia tietokantoja, joista haettiin julkaisuja pääasiallisesti englannin kielellä, sillä katsauksen tarkoituksena on huomioida tilanne tekoälyn hyödyntämisessä kansainvälisellä tasolla.

## 4 Tekoälyn soveltaminen ennakoivassa huollossa

### 4.1 Tekoälyn määritelmä lyhyesti

Tekoäly, AI (Artificial Intelligence) tarkoittaa koneen kyvykkyyttä olla ihmisen kaltaisesti älykäs. Tämä sisältää esimerkiksi taitoja kuten oppimisen, luomisen, päättelykyvyn ja suunnittelun. [11.] EU:n virallisen määritelmän mukaan AI:lla viitataan systeemeihin, jotka näyttävät älyllistä käyttäytymistä analysoimalla ympäristöään ja tekemällä päätöksiä tai ratkaisuja saavuttaakseen ennalta asetetun tavoitteen. AI toimii kattoterminä kaikille tekoälyä hyödyntäville sovelluksille ja ohjelmille. [12; 13.]

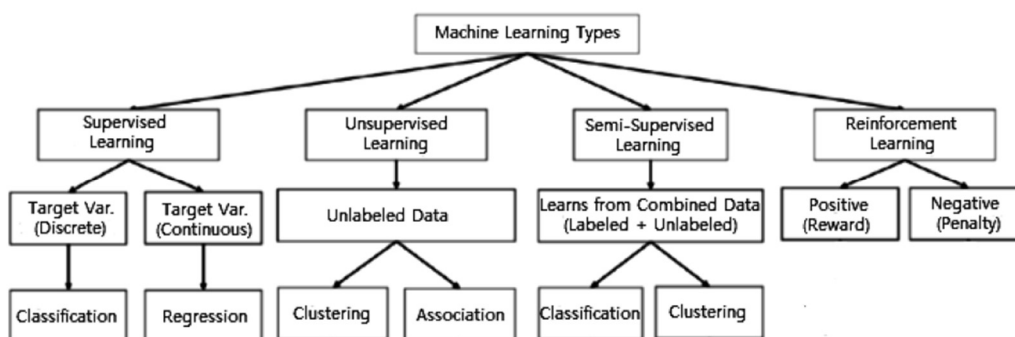
AI:lla on useita erilaisia osa-alueita, jotka on visualisoitu kuvassa 5. Koneoppiminen, ML (Machine Learning) on yksi tekoälyn osajoukoista, joka keskittyy imitoimaan ihmisenkaltaista oppimista, kehitystä, päätösten tekoa, ja ennakointia datan pohjalta. Koneoppimisen omia osa-alueita ovat esimerkiksi syväoppiminen DL (Deep Learning), joka on erikoistunut ihmisten aivojen kaltaiseen rakenteeseen ja toimimiseen ja hyödyntää koneoppimisen toista osa-aluetta, keinotekoisia neuroverkkoja (ANN, Artificial Neural Network). Keinotekoiset neuroverkot on mallinnettu ihmisten aivojen neuronien toimintojen perusteella. Syväoppiminen hyödyntää neuroverkkoja sisältämällä monia neuroverkkokerroksia ja suuria datamääriä. [13.] Kuvassa 4 on visualisoitu tekoälyn kategoriat kerroksittain.



Kuva 4. Visualisointi tekoälyn eri kerroksista [14].

## 4.2 Keskeisimmät koneoppimisen menetelmät

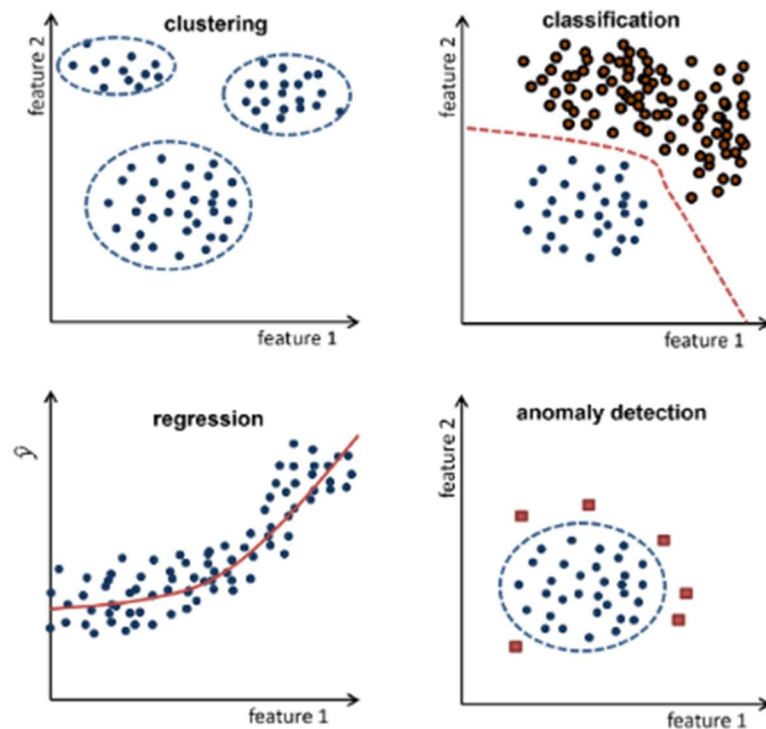
Viime vuosina eri tekoälyn soveltamiseen on käytetty useita eri malleja ja eri mallien hybridejä. Mallit käyttävät useita eri koneoppimisen malleja, keinotekoisia neuroverkkoja ja syväoppimista sekä niiden erilaisia yhdistelmiä. [15.] Keskeisten menetelmien tarkasteluun käytämme menetelmiä vertailevaa kirjallisuutta, joka on julkaistu viimeisen neljän vuoden sisään. Koneoppimisen menetelmiä voidaan jakaa neljään eri ryhmään, ohjattuun oppimiseen, puoliohjattuun oppimiseen, ohjaamattomaan oppimiseen ja vahvistettuun oppimiseen. Koneoppimisen alakategorioita on visualisoitu kuvassa 5. [16.]



Kuva 5. Visualisointi AI:n ja ML:n eri kategorioinneista [16].

Jokaista koneoppimisen mallia on jaettu vielä alakategorioina omiin tehtäviinsä. Ennakoivan kunnossapidon näkökulmasta merkittävimpiä metodeja hyödyntää koneoppimista ovat regressio, klusterointi, klassifikaatio ja poikkeavuuksien tunnistaminen (Anomaly Detection). [15.] Ne ovat kaikki koneoppimisen mallien tehtävätyyppejä. Tavat on visualisoitu kuvassa 6.

- Anomaly Detection, eli poikkeavuuksien tunnistaminen, pyrkii tunnistamaan datasta normaalista toiminnasta poikkeavia ilmentymiä.
- Classification, eli klassifikaatio on tekniikka, joka kategorisoi datapisteitä sille määriteltyihin luokkiin.
- Clustering, eli klusterointi on metodi, jolla ryhmitellään dataa.
- Regressio on metodi, joka pyrkii lähtödatan perusteella oppimaan ennustamaan jatkuvia lähtöjä uusille tuloille. [15.]



Kuva 6. Keskeisimmät koneoppimisen tehtävät ennakoivan kunnossapidon näkökulmasta [15].

#### 4.2.1 Ohjattu oppiminen

Ohjatulla oppimisella (Supervised Learning) tarkoitetaan koneen opettamista esimerkkien avulla. Ohjatussa oppimisessa käytetään opettamiseen tietoaineistoa, jonka avulla määritellään tavoitteena olevat tulot ja lähdöt. Oppimista kytetään ohjaamaan, koska tavoiteltu tulos on tiedossa ja algoritmi kykenee oppimaan virheistä. Ohjatun oppimisen alla on useita erilaisia alakategorioita, kuten edellisessä kappaleessa mainittu klassifikaatio. [17.] Ohjatun oppimisen alle kuuluu useita malleja, joita käytetään paljon ennakoivassa kunnossapidossa. Yleisiä ohjatun oppimisen malleja ovat:

- Support Vector Machines (SVM), eli tukivektorikone, on suosittu ohjatun oppimisen malli, joka sopii hyvin sekä klassifikaatioon että regressioon. SVM:ssä kahden näytejoukon väliin sovitetaan yhdensuuntainen mutta mahdollisimman suuri väli. [17.]
- Decision Trees, on hyvin tunnettu ohjatun oppimisen algoritmi, joka sopii sekä klassifikaation ja regression tehtäviin. Päättöpuut koostuvat kysymyksistä tai ehdoista ja niiden vastauksista, jotka muodostavat hierarkisesti puun muodon, josta algoritmin nimi tulee. [16.]
- K-Nearest Neighbor (k-NN) on parametritön algoritmi, joka luokittelee datapisteitä niiden läheisyyden ja yhteyksien perusteella muihin saatavilla oleviin tietoihin. KNN:ää pidetään helppokäyttöisenä ja alhaisen laskenta-ajan vuoksi se on suosittu algoritmi datatieteen parissa. k-NN:ää käytetään paljon esimerkiksi kuvantunnistuksessa. [16; 17.]
- Random Forest, jossa sana "metsä" viittaa joukkoon riippumattomia päätöspuita, joita yhdistetään vähentämään varianssia ja luomaan tarkempia ennustuksia. Random forestia pidetään joustavana algoritmina ja käytetään luokitteluun ja regressioon. [17.]

- Linear regressio, eli lineaarinen regressio, jolla ennustetaan yhden muuttujan arvoa toisen muuttujan perusteella. [21.]

#### 4.2.2 Puoliohjattu oppiminen

Puoliohjattu oppiminen (Semi-Supervised Learning) on tyyliltään samankaltaista kuin ohjattu oppiminen, mutta siinä yhdistetään sekä ohjattua että ohjaamatonta oppimista. Puoliohjatussa oppimisessa käytetään sekä luokiteltua että luokittelematonta dataa tekoälyn opetukseen. Tunnettuja puolioppimisen algoritmeja on esimerkiksi S3VM, joka on osittain ohjattu versio tukivektorikoneista. [16;20.]

#### 4.2.3 Ohjaamaton oppiminen

Ohjaamaton oppiminen on koneoppimisen algoritmeja, jotka analysoivat ja lajittelevat luokittelemattomia datasettejä. Ohjaamaton oppiminen pyrkii analysoimalla ja lajittelemalla löytämään dataseteistä ryhmiä, kaavoja tai malleja ilman ihmisen ohjausta. [16; 18.] Ohjaamattoman oppimisen malleista yleisimpiä ovat esimerkiksi:

- Clustering eli klusterointi on yksi yleisimmin käytetyistä ohjaamattoman oppimisen algoritmeista. Klusterointia käytetään dataa analysoimalla löytämään kaavoja ja ryhmiä, mitä ei ole huomattu. Cluster-analyysiä voidaan toteuttaa useilla eri metodeilla, kuten fuzzy k-means, k-means, hierarkisilla cluster-analyyseilla. [16; 18.]

#### 4.2.4 Vahvistettu oppiminen (Reinforcement Learning)

Vahvistettu oppiminen RL (Reinforcement Learning) on koneoppimisen malli, joka matkii ihmisten oppimista yrittämisen ja virheiden kautta. Sen tarkoituksena on opettaa ohjelmaa tekemään päätöksiä mahdollisimman optimaalisilla tuloksilla vahvistamalla tavoitteisiin vieviä tuloksia ja sivuuttamalla tulokset, jotka eivät vie haluttuun suuntaan. Vahvistavan oppimisen algoritmit käyttävät dataa prosessoidessa niin sanottua rangaistuksen ja palkitsemisen kaavaa. Näin ne

voivat oppia jokaisen tapahtuman tuloksista ja kykenevät löytämään itse parhaita reittejä sopivien tulosten saamiseen. [16; 22.]

#### 4.2.5 Syväoppiminen ja neuroverkot

Syväoppiminen on koneoppimisen osa-alue, joka hyödyntää oppimista keinotekoisien neuroverkkojen kautta. Syväoppimisessa hyödynnetään useita kerroksia neuroverkkoja, joilla voi olla eri tehtäviä. Kerrokset muodostuvat lähtökerroksesta, piilokerroksista ja tuloskerroksesta. Lähtökerroksen ja tuloskerroksen välillä voi olla satoja piilokerroksia, joilla on erilaisia analysointitehtäviä. Syväoppiminen ja neuroverkot sopivat erityisen hyvin oppimaan etenkin suurien data määrien pohjalta. [16; 23.] Paljon käytettyjä malleja ovat esimerkiksi:

- CNN (Convolutional Neural Network) on yksi tunnetuimmista syväoppimisen arkkitehtuureista. Sitä käytetään etenkin kuvantunnistukseen. [23.]
- RNN (Recurrent Neural Network) on syväoppimisen malli, joka tunnistaa sekvenssejä ja kaavoja, esimerkiksi tekstin ja puheentunnistusta. [23.]
- AE (Autoencoder) on ohjaamatonta oppimista käyttävä neuroverkkoarkkitehtuuri. [15.]

## 5 Koneoppimisen algoritmit ennakoivassa kunnossapidossa

### 5.1 Koneoppimisen hyödyntäminen vertailua

Ennakoivassa kunnossapidossa hyödynnetään monia erilaisia koneoppimisen malleja, syväoppimista, keinotekoisia neuroverkkoja ja eri mallien yhdistelmiä. Olemme valinneet aineistosta kolme eri katsausta, joissa on koottu useita eri tutkimuksia tarkoituksena kartoittaa tekoälyn käyttöä tarkemmin. [15.] Kolmessa katsauksessa tutkitaan koneoppimisen ja syväoppimisen malleja eri


teollisuudenaloilla ennakoivan kunnossapidon toteutuksissa. Tässä luvussa perehdymme seuraavien katsausten tuloksiin:

1. Predictive maintenance enabled by machine learning: use cases and challenges in the automotive industry, 2021. Katsaus koneoppimisen hyödyntämiseen ennakoivassa kunnossapidossa ajoneuvoteollisuudessa. [15.]
2. Machine learning in predictive maintenance towards sustainable smart manufacturing in industry 4.0, 2020. Laaja katsaus koneoppimisen käytöstä eri teollisuudenaloilla. [25.]
3. A survey on data-driven predictive maintenance for the railway industry, 2021. Katsaus ennakoivan kunnossapidon toteutuksiin raideteollisuuden näkökulmasta. [26.]

### 5.1.1 Ensimmäinen katsaus: Mallit ajoneuvoteollisuudessa


Ensimmäinen tarkastelemamme tutkimus on katsaus ennakoivan kunnossapidon toteutuksiin ajoneuvoteollisuudessa hyödyntäen koneoppimista. Katsaus perehtyy yhteensä 62 tutkimukseen kartoittaen koneoppimisen hyödyntämisen eri malleja ja metodeja. Tutkimus käy läpi hyödynnetyt koneoppimisen lajitteluperiaatteet ja koneoppimisen mallit. [15.] Selventääksemme tutkimuksen tuloksia loimme palkkikaavioita visualisoimaan alkuperäisen taulukon tuloksia, jossa käydään läpi eri tutkimuksissa käytetyt koneoppimisen mallit

Katsauksessa ennakoivan kunnossapito on jaettu kolmeen ryhmään, kuntoon perustuva ennakoivaan kunnossapitoon (Condition-Based Predictive Maintenance), tilastoihin perustuvaan ennakoivaan kunnossapitoon (Statistical Predictive Maintenance) ja jäljellä olevan hyödyllisen käyttöiän ennakkointiin (Remaining Useful Life, RUL). Näistä ryhmistä eniten katsauksessa on kuntoon perustuvaa kunnossapitoa, joita on 44 kaikista 62:sta tapauksesta. Kuvassa 7 on palkkikaavio tutkimuksessa olevista kunnossapidon tehtävistä.



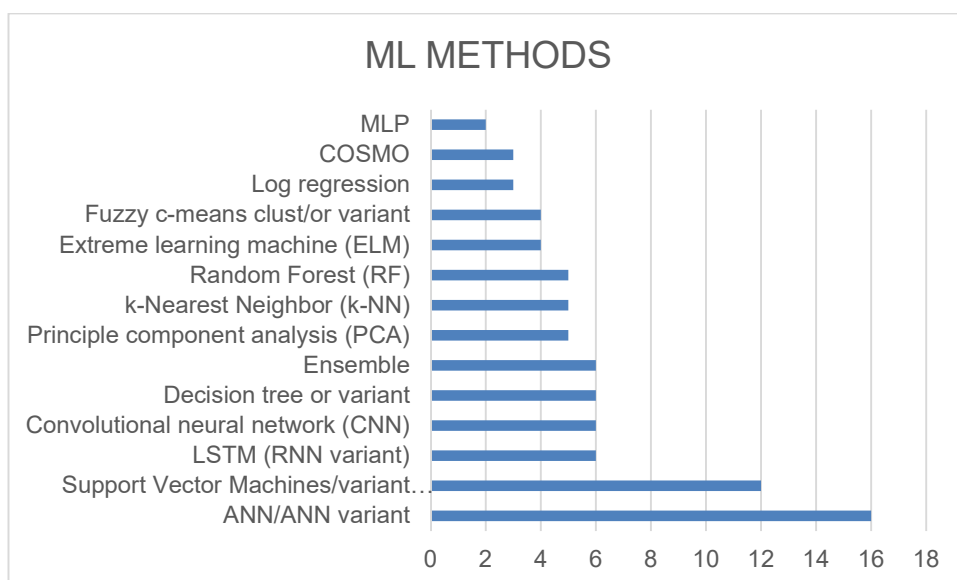
Kuva 7. Ennakoivan kunnossapidon tehtävien jakautuminen katsauksen tietojen pohjalta visualisoituna [15].

Koneoppimisen tehtävät on jaettu kategorioihin tarpeiden mukaan. Näistä tarpeista ennakoivassa kunnossapidossa huomioidaan tärkeimpinä klassifikaatio (classification), poikkeavuuksien tunnistaminen (anomaly detection), regressio (regression), ennustaminen (forecast) ja klusterointi (clustering). Suurin tarve katsauksen perusteella on klassifikaatiolle ja toiseksi suurimpana tarpeena poikkeamien havaitseminen. Kuvassa 8 on visualisoitu palkkitaulukon avulla koneoppimisen tehtävien jakautuminen. Katsauksen tutkimien lähteiden perusteella vähiten tarvetta ennakoivassa kunnossapidossa ajoneuvoteollisuudessa oli klusteroinnille, joita oli kaikista tapauksista vain viisi kappaletta. [15.]



Kuva 8. Visualisointi koneoppimisen tehtävistä ajoneuvoteollisuuden ennakoivan kunnossapidon toteutuksissa [15].

Toinen tutkimuksessa tarkasteltu asia oli koneoppimisen mallit. Mallit jaoteltiin karkeasti kategorioihin laskemalla samaan kategoriaan myös variantit kyseisestä mallista. Visualisointiin tehdyssä palkkidiagrammissa huomioitiin vain mallit, joita oli käytetty vähintään kahdessa tutkimuksessa. Yksittäiset koneoppimisen mallit jätimme huomioimatta, sillä tämän työn tarkoituksena on kartoittaa, mitkä malleista olivat eniten käytössä. Tutkimuksessa selkein eniten käytetty malli on keinotekoiset neuroverkot ja niiden eri variantit. Kuudestakymmenestä kahdesta tapauksesta kuusitoista hyödynsi keinotekoisia neuroverkkoja (Artificial Neural Network, ANN). Tämän lisäksi huomattavan monissa tapauksissa käytettiin jonkinlaista neuroverkko arkkitehtuuria, kuten LSTM (Long Short Term Memory), CNN (Convolutional Network), ELM (Extreme Machine Learning) ja MLP (Multilayer Perceptron). Toiseksi suosituimpana mallina on erilaiset variantit SVM:stä eli tukivektorikoneesta (Support Vector Machine), niitä oli hyödynnetty kahdessatoista tapauksessa. [15.] Kuvassa 9 palkkitaulukko koneoppimismallien jakaumasta, jossa ANN erottuu selkeästi suurimpana.




Kuva 9. Visualisointiin tehty kuva eniten käytetyistä koneoppimisen malleista ajoneuvoteollisuudessa [15].

Tutkimustuloksista on selkeää, että keinotekoiset neuroverkot ja neuroverkko-arkkitehtuurit koneoppimisessa ovat selkeästi suurimmassa suosiossa. Tutkimuksessa huomioidaan, että suosion kasvuun vaikuttaa neuroverkkojen käytön yleistymisen koneoppimisen malleissa. Tapauksissa huomataan myös, että neuroverkot on pidetty pieninä, eikä kerroksia ole käytetty monia. Tämän vuoksi voidaan todeta, ettei tapauksia voida suoraan kategorisoida syväoppimisen puolelle. Käytetyissä tapauksissa on siis pääasiallisesti yhdistetty koneoppimista ja neuroverkkoja, mutta syvään oppimiseen ei ole päästy, sillä kerroksia on vähän. Tämä voi johtua datan puutteesta, sillä syväoppimiseen tarvii suuria määriä dataa. [15.]

### 5.1.2 Toinen katsaus: Kohti kestäväää älykästä teollisuutta


Seuraava katsaus perehtyy tarkastelemaan koneoppimisen malleja laajasti teollisuuden eri aloilta. 2020 tehdyssä katsauksessa on tutkittu koneoppimisen mallien soveltamista ennakoivassa kunnossapidossa 126 julkaisun pohjalta. Katsauksessa valitut tutkimukset ovat useilta eri teollisuudenaloilta. [25.]

Tässä katsauksessa koneoppimisen tehtävät on jaettu kolmeen luokkaan: klassifikaatioon, regressioon ja klusterointiin. Kuvassa 10 on visualisoitu ryhmien jakautuminen palkkidiagrammissa. Suurin osa koneoppimisen tapauksista on klassifikaatiota, joita on kaikista tapauksista 47 tapaus. Toiseksi suurimpana on regressio seitsemällätoista tapauksella, ja kahdeksan tapauksista on luokiteltu klusteroinniksi. Jakauma koneoppimistehtävien välillä vastaa aikaisemman tutkimuksen tuloksia, kun klassifikaatio on merkittävästi muita kategorioita suurempi. [25.]



Kuva 10. Visualisointi ryhmien koosta tutkimuksen taulukkotiedon pohjalta [25].

Tutkimuksen pohjalta koneoppimisen malleja luokiteltiin 55 erilaiseen malliin, joista kartoitimme palkkidiagrammiin eniten käytetyt mallit. Valikoimme eniten käytetyt mallit mukailen edellisen tutkimuksen periaatteita. Mukaan lukeutuivat mallit, joita oli käytetty vähintään kolmessa tapauksessa. Kuvassa 11 palkkidiagrammi tutkimuksen kartoittamista käytetyimmistä koneoppimisen malleista.



Kuva 11. Palkkidiagrammi aineiston taulukon käytetyimmistä koneoppimisen malleista [25].

Tässä aineistossa eniten käytetyksi koneoppimisen malliksi nousi random forest -algoritmi. Edellisen katsauksen tavoin SVM-algoritmit ovat toiseksi yleisimpänä mallina, ja keinotekoinen neuroverkko on tässäkin aineistossa yksi merkittävimmistä algoritmeista ja on kolmanneksi suurimpana mallina. Selkeyttääksemme dataa yhdistimme edellisen tutkimuksen tavoin keinotekoiset neuroverkot (ANN) ja neuroverkot (NN) saman kategorian alle. Neuroverkkoarkkitehtuurit ovat tässä aineistossa edellisen tavoin yleisesti käytössä. [25.]

Katsauksessa huomioidaan ilmiö, jonka mukaan ennustavassa kunnossapidossa käytetään random forest -mallia hyvin laajalaisesti erilaisien laitteiden kunnossapidon tarkkailuun. [25]


### 5.1.3 Kolmas katsaus: Raideteollisuus ja ennakoiva kunnossapito

Kolmas katsaus perehtyy koneoppimisen ja syväoppimisen hyödyntämiseen raideteollisuuden ennakoivan kunnossapidon näkökulmasta. 2021 kootussa

kirjallisuuskatsauksessa on käsitelty spesifisti datalähtöistä ennakoivaa kunnossapitoa, jonka tutkimus määrittää olevan dataa, jolla ei ole ennakkoon tiedossa tiettyä mallia. [26.] Katsauksessa lajiteltiin koneoppimisen ja syväoppimisen malleja 45 eri tutkimuksesta.

Katsauksessa tutkimukset on jaettu kahteen ryhmään: yleiset ennakoivan kunnossapidon koneoppimisen mallit ja raideteollisuudessa käytetyt mallit. Molemmissa kategorioissa koneoppimisen mallit jaetaan kolmeen kategoriaan: klassifikaatioon, regressioon ja poikkeavuuksien tunnistamiseen. Tämän lisäksi on merkitty malleille ryhmät tavoitteiden mukaan kahteen kunnossapidon kategoriaan: pidentää jäljellä olevaa käyttöikää (RUL, remaining useful life) ja ennustaa vikoja (FP, failure prediction). [26.]


Tulosten visualisoimiseksi luodussa palkkitaulukossa voimme havaita klassifikaation olevan molemmissa tapauksissa suurin kategoria. Huomattavaa on kuitenkin, että raideteollisuudessa poikkeavuuksien tunnistus (anomaly detection) on lähes yhtä merkittävänä kategoriana kuin regressio. On mahdollista, että tässä on teollisuuskohtaisten tarpeiden vuoksi suurempi esiintyvyys. Kuvassa 12 on esitetty raideteollisuudessa käytetyt koneoppimisen tehtäväkategoriat ja yleisesti teollisuudenaloilla kunnossapidossa käytetyt kategoriat vierekkäin.



Kuva 12. Palkkitaulukko tutkimuksen taulukkotiedon pohjalta [26].

Katsauksessa huomioitua eniten käytetty koneoppimisen mallit jatkavat aiemmissä katsauksissa huomattuja trendejä. Raideteollisuuden ennakoivassa kunnossapidossa suurimmat hyödynnetyt koneoppimisen mallit ovat tukivektorikoneet (SVM) ja random forest -mallit. Yleisessä ennakoivan kunnossapidon vertailuaineistossa on eniten käytettyinä malleina AE ja RNN.

Kuten kahdessa aikaisemmassa tutkimuksessa on huomattu, syväoppimisen mallit ovat ylliedustettuna etenkin yleisessä ennakoivan kunnossapidon katsauksessa. Kuvassa 13 mallit on visualisoitu palkkidiagrammeihin.




Kuva 13. Visualisointi katsauksen tarkastelemista koneoppimisen malleista [26].

## 5.2 Yhteistulokset

Tarkastelemme seuraavaksi kolmen katsauksen yhteistuloksia. Katsauksien tuloksissa on huomioitava, että jokainen katsaus lajittelee koneoppimisen malleja hieman eri tavoin. Osa on eritellyt eri koneoppimisen mallien variantteja, kun taas osassa varianteja on laskettu päämallin alle. Tämän vuoksi katsauksien tuloksia visualisoidessa osa varianteista on laskettu päämallin kanssa samaan kategoriaan, jotta tulokset olisivat selvempiä. Tästä esimerkiksi SVR (Support Vector Regression), joka on regressiovariantti SVM:stä, on laskettu visualisointikuvissa samaan kategoriaan SVM:n kanssa. Monissa tutkimuksissa on myös yhdistelty eri koneoppimismalleja, mutta selventääksemme tuloksia eniten käytetyistä malleista, on tuloksissa huomioitu mallit yksittäisinä, eikä hybridiyhdistelminä muiden mallien kanssa.

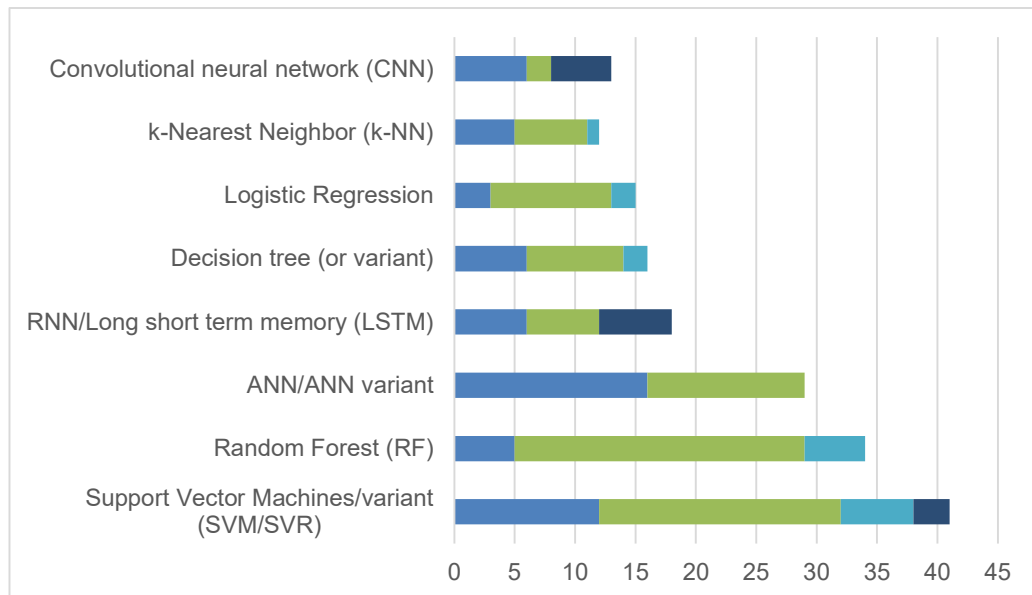
Yleisin koneoppimisen luokittelutehtävä oli klassifikaatio. Muita koneoppimisen luokittelukategorioita oli huomattavasti vähemmän ja näiden katsausten perusteella voi päätellä tutkimuksien suurimman keskittymiskohteen olevan koneoppimisen klassifikointikyvyssä. Kuvassa 14 on palkkidiagrammi luokittelutehtävien yhteistuloksista.



Kuva 14. Yhdistetty kolmen katsauksen tietojen pohjalta yhteistulokset luokittelutehtävistä [15; 25; 26].

Kaikissa katsauksissa yhdeksi suurimmista koneoppimisen malleista nousi tukivektorikoneet tai jokin niiden variaatio. Tämä voi viitata niiden olevan erityisen suosittuja ennakoivan kunnossapidon toteutuksissa ja tutkimuksissa. Perinteisistä koneoppimisen malleista tukivektorikoneiden lisäksi huomattavan paljon käytettyjä olivat myös Random Forest, decision tree ja logistic regression. Kyseiset koneoppimisen mallit ovat kuitenkin yleisesti hyvin suosittuja, joten on vaikea arvioida, johtuuko yleinen käyttö vain suosiosta tai helppoudesta. Kaikissa katsauksissa huomioitiin eri neuroverkkojen ja syväoppimisen mallien suosio. ANN oli neuroverkoista suosituin, ja syväoppimisen malleista RNN ja CNN variaatioineen olivat suosituimmat. Vaikka syväoppimisen mallit havaittiin katsauksissa suosituiksi, huomioitiin kuitenkin, että niissä ei toteutunut mallien syvyys, vaan kerroksia oli usein vähän. [15.]

Tulosten visualisointiin tehtyyn palkkitaulukkoon valikoitui vain suosituimmat mallit, joita oli käytetty vähintään kymmenessä tapauksessa. Kuvassa 15 palkki-diagrammi kolmen katsauksen suosituimpien koneoppimisen mallien yhteistuloksista.



Kuva 15. Kuvassa yhdistetty kolmen katsauksen pohjalta suosituimmat koneoppimisen mallit. [15; 25; 26]

### 5.3 Haasteet tekoälyn soveltamisessa

Koneoppimisen avulla toteutetulla ennakoivalla kunnossapidossa on valtavasti potentiaalia teollisuus 4.0:n ja älykkään tuotannon myötä, mutta katsauksista ja useista tutkimuksista selviää useita haasteita. Keskeisimmiksi haasteiksi uusimmista julkaisuista nousivat seuraavat asiat:

- Julkisesti saatavilla olevan oikean datan puute. Oikea laitteista saatu data on usein yksityisten yritysten hallussa, salattua tietoa tai maksumuurien takana [15].
- Järjestelmäintegraation puuttuminen ja sen aiheuttamat ongelmat datan keräämiseen [8].
- Reaaliaikainen monitorointi. Suurien datamäärien prosessoiminen laitteista reaaliajassa [27].
- Luokitellun datan vähäinen saatavuus [15; 24; 28].
- Epätasapaino saatavan datan sisällössä. On helppo kerätä paljon dataa, jossa vikatilanteita ei ole. Vikatilanteet ovat paljon harvinaisempia ja niistä on vaikea saada oikeaa dataa. Tämä johtaa siihen, että on enemmän dataa laitteen normaalitoiminnasta, mutta ei vioista. [28.]
- Tiettyyn kohteeseen sopivan opetusdatan saaminen. Tarpeisiin sopivan datan saaminen on vaikeaa ja sen itse kerääminen on pitkäkestoinen prosessi, sillä monia vikatilanteita tulee vasta laitteen elinkaaren lopussa. [8; 15; 27; 28.]
- Opetusdatan laatu. Ulkopuoliset tekijät, kuten inhimilliset virheet, ongelmat kerätä dataa ja ympäristö voivat vääristää opetusdataa. Vääristynyt tai virheellinen opetusdata voi johtaa vääriin ennustuksiin. [28.]
- Opetettu data on staattista ja malli ei kykene oppimaan uutta [31].

Onnistunut koneoppimisen hyödyntäminen on täysin riippuvaista opettamiseen käytettyjen datasettien laadusta ja osuvuudesta. Suurin osa katsauksissa olevista tutkimuksista käytti luokiteltua dataa mallien opettamiseen, sillä suurin osa katsauksissa olevista malleista hyödynsi joko ohjattua oppimista tai osittain ohjattua oppimista. Molemmat näistä tarvitsevat luokiteltua dataa opettamiseen ja tämän datan puuttuminen luo uusien tutkimusten tekemiseen haastavan pullonkaula tilanteen. [15.]

Suureksi ongelmaksi monissa julkaisuissa nostettiin sopivan opetusdatan saaminen. Laadukasta ja yhteensopivaa dataa on vaikea saada tai tuottaa. Soveltavat kohteet ennakoivalle kunnossapidolle ovat usein uniikkeja ja monimutkaisia kokonaisuuksia. Kohteissa laitteiden toimivuuteen vaikuttavat koneen itsensä lisäksi ympäristö, muut laitteet ja käyttäjät. Kun soveltamisen kohde on monimutkainen kokonaisuus, on sopivan koneoppimisen mallin valitseminen vaikeaa. Mallin valitsemisessa ilman varmuutta sen sopivuudesta on omat riskinsä ajan hukkaamiseen ja kustannuksien kasvamiseen. [8; 15; 27; 28.]

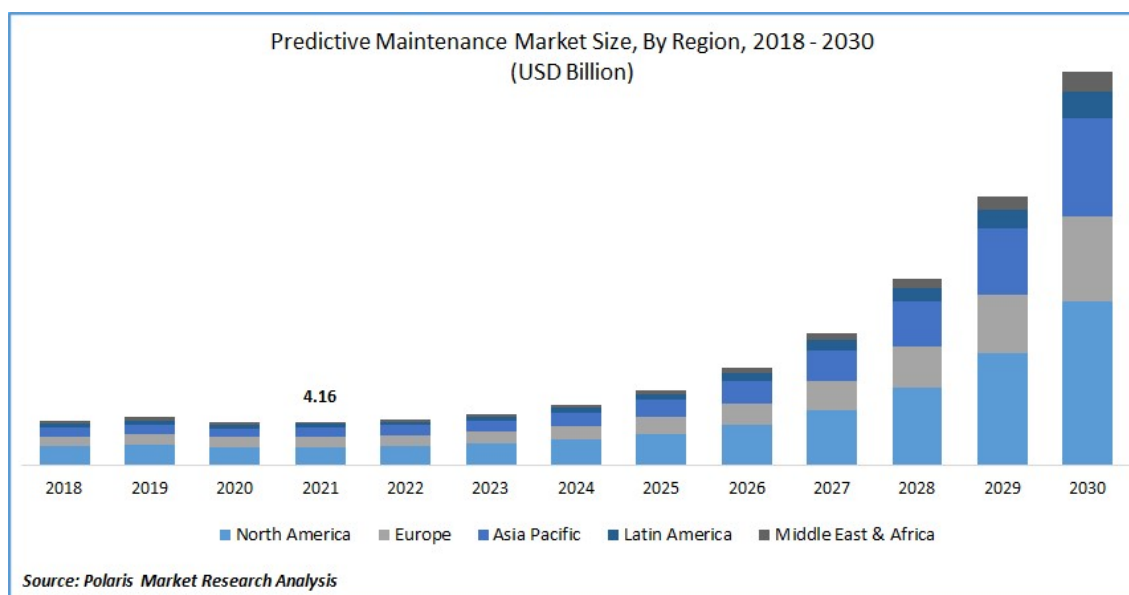
Uusimmissa tutkimuksissa nostettiin myös haasteeksi opettettujen mallien staattisuus ja se ettei mallit toistaiseksi kykene jatkuvaan oppimiseen. Mallit on opetettu tietyn datan pohjalta, spesifeihin skenaarioihin, joita datassa näkyy. Todellisuudessa laitteiden toimimiseen vaikuttaa niin monet asiat, että voi tulla uudenlaisia muutoksia, joita mallille ei ole opetettu. Tämä johtaa tilanteisiin, jossa malli tekee vääriä päätöksiä tai ei toimi optimaalisesti. [31.]

## 5.4 Tulevaisuus

Ennakoivan kunnossapidon ja tekoälyn hyödyntämisellä on haasteista huolimatta suurta potentiaalia. Staattisuuden haasteisiin on toivottu ratkaisua esimerkiksi siirtyvästä oppimisesta (Transfer Learning, TL) tai jatkuvasta oppimisestä (Continual Learning, CL). Siirrettyssä oppimisessä malli kykenee siirtämään jo opetettua asiaa yhdestä tehtävästä toiseen, ja näin hyödyntämään jo opittua asioita muista tehtävistä. Jatkuva oppiminen taas pyrkii siihen, että mallit

kykenisivät oppimaan uudesta datasta ilman, että unohtaisivat jo opetettuja asioita. [31.]

Ennakoiva kunnossapito on vielä kasvuvaiheessa. PwC:n 2017 julkaistun kyselyn mukaan vain 11 % käyttää big dataan pohjautuvaa ja koneoppimista hyödyntävää ennakoivaa kunnossapitoa [29]. Monilla teollisuudenaloilla ei ole vielä siirrytty hyödyntämään teollisuus 4.0:n tuomia uusia teknologioita. PwC:n kyselyn mukaan 66 % vastaajista ei ollut vielä päässyt edes reaaliajassa tapahtuvaan kunnonvalvontaan, vaan kunnossapito on edelleen instrumenttien ja laitteiden visuaalista tarkkailua. [29.] Alalla on vielä valtavasti potentiaalia kasvaa ja kehittyä. Kuvassa 16 visualisoitu markkinojen kasvu vuodesta 2018 vuoteen 2030. [30.]



Kuva 16. Arvioitu ennakoidun kunnossapidon markkinakoko 2018–2030 [30].

Ennakoivan kunnossapidon markkinoiden on ennustettu kasvavan seuraavan kuuden vuoden aikana merkittävästi. Vuoteen 2030 mennessä alan markkinoiden koon on ennustettu vähintään kolminkertaistuvan. [30.]

## 6 Yhteenveto

Tämän insinööriyön tarkoituksena oli tarkastella tekoälyn suhdetta ja erilaisia sovelluskeinoja ennakoivan kunnossapidon näkökulmasta. Työn tavoite oli havaita trendejä ja haasteita tekoälyn soveltamisessa. Työtä tehdessä havaittiin, että aihe on tällä hetkellä hyvin suosittu ja tutkimuksia on hyvin paljon.

Selkeää konsensusta siitä, mikä on paras malli mihinkin tarkoitukseen, on vaikeaa tehdä, sillä käyttötarkoitukset ovat uniikkeja, tarpeet ovat tapauskohtaisia ja soveltamistapoja ja malleja on erittäin paljon.

Tässä työssä saimme kartoitettua useita eniten sovellettuja tekoälyn malleja ennakoivan kunnossapidon toteutuksissa. Näistä kartoitetuista malleista näkyy selkeä trendi syväoppimiseen ja neuroverkkoihin, mutta myös edelleen perinteisiin suosittuihin koneoppimisen malleihin kuten tukivektorikoneisiin ja random forest -malleihin. Näiden kaikkien mallien soveltamisessa havaittiin kuitenkin monia haasteita, jotka vaikeuttavat mallien tutkimista ja eri tarkoituksiin sopivien mallien kartoittamista. Opettamiseen tarkoitettun datan saaminen sekä yksityiskäyttöön, että tutkimuskäyttöön on vaikeaa ja kallista. Ilmaista opetusdataa on vähän saatavilla ja sen käyttökohteet rajallisia.

Työssä kartoitettiin laajasti myös ennakoivan kunnossapidon suurimpia ongelmia. Näistä merkittävimmiksi nousi laadukkaan opetusdatan lisäksi mallien staattisuus. Mallit toimivat täysin opetetun datan perusteella, mikä tarkoittaa sitä, etteivät ne kykene reagoimaan oikein, jos tapahtuu jotain, mitä ei ole tapahtunut ennen. Todellisuudessa eri teollisuudenaloilla laitteiden toimintaan vaikuttaa useita eri asioita, ympäristöllisiä, käyttäjäkohtaisia ja muita arvaamattomia virheitä. Joidenkin ongelmatilanteiden ilmenemiseen voi mennä vuosia, joten voi olla lähes mahdotonta saada kaikkea opetusdataan.

Tulevaisuudessa on mahdollista, että nykyiset ongelmat koneoppimisen rajallisuudelle ennakoivassa kunnossapidossa selviää uusimmilla tutkituilla tekniikoilla. Tässä työssä huomioitu jatkuva oppiminen näyttää potentiaaliselta keinolta korjaamaan ongelmia koneoppimisen mallien ongelmakohdissa.

Työn tuloksena syntyi katsaus ennakoivan kunnossapidon tämänhetkiseen tilanteeseen koneoppimista soveltaen.

## Lähteet

- 1 Benjamin Stratton. 2022. Verkkoaineisto. BlueTree. <<https://bluetree.digital/ai-industry-growth-metrics/>>. Luettu:15.2.2024.
- 2 What is predictive maintenance? Verkkoaineisto. SAP. <<https://www.sap.com/products/scm/apm/what-is-predictive-maintenance.html>>. Luettu:15.2.2024.
- 3 What is predictive maintenance?. Verkkoaineisto. IBM <<https://www.ibm.com/topics/predictive-maintenance>>. Luettu 15.2.2024.
- 4 Kunnonvalvonta ja kunnossapito uudet SFS-käsikirjat kunnossapitoon. 2013. Verkkoaineisto. Promaint. <<https://promaintlehti.fi/Kunnonvalvonta-ja-kayttovarmuus/Kunnonvalvonta-ja-kunnossapito-uudet-SFS-kasikirjat-kunnossapitoon>>. Luettu 17.2.2022.
- 5 Achouch, Mounia; Dimitrova, Mariya; Ziane, Khaled; Sattarpanah Karganroudi, Sasan; Dhouib, Rizck; Ibrahim, Hussein & Adda, Mehdi. (2022). On Predictive Maintenance in Industry 4.0: Overview, Models, and Challenges. Applied Sciences, 12(16), <<https://doi.org/10.3390/app12168081>>. Luettu 10.2.2024.
- 6 What is industry 4.0? Verkkoaineisto. IBM. <<https://www.ibm.com/topics/industry-4-0>>. Luettu 10.3.2024.
- 7 James Chan. 2024. Verkkoaineisto. Limble CMMS. <<https://limblecmms.com/blog/benefits-of-predictive-maintenance/>>. Luettu 20.3.2024.
- 8 Sivanuja, Thirumal & Sandanayake, Y.G. 2022. Industry 4.0 predictive maintenance of facilities: A study on applicability, benefits and challenges. <[https://www.researchgate.net/publication/365607434\\_Industry\\_40\\_enabled\\_predictive\\_maintenance\\_of\\_facilities\\_A\\_study\\_on\\_applicability\\_benefits\\_and\\_challenges](https://www.researchgate.net/publication/365607434_Industry_40_enabled_predictive_maintenance_of_facilities_A_study_on_applicability_benefits_and_challenges)>. Luettu 25.3.2024.
- 9 Jeroen Kraaijenbrink. 2022. What is industry 5.0 and how it will radically change your business strategy? Verkkoaineisto. Forbes. <<https://www.forbes.com/sites/jeroenkraaijenbrink/2022/05/24/what-is-industry-50-and-how-it-will-radically-change-your-business-strategy/>>. Luettu 22.3.2024.
- 10 Industry 5.0: Towards more sustainable, resilient and human centric industry. 2021. Verkkoaineisto. European Commission. <[https://research-and-innovation.ec.europa.eu/news/all-research-and-innovation-news/industry-50-towards-more-sustainable-resilient-and-human-centric-industry-2021-01-07\\_en](https://research-and-innovation.ec.europa.eu/news/all-research-and-innovation-news/industry-50-towards-more-sustainable-resilient-and-human-centric-industry-2021-01-07_en)>. Luettu 22.3.2024.

- 11 Mitä tekoäly on ja mihin sitä käytetään? 2020. Verkkoaineisto. Euroopan parlamentti. <<https://www.europarl.europa.eu/topics/fi/article/20200827STO85804/mita-tekoaly-on-ja-mihin-sita-kaytetaan>>. Luettu 24.3.2024.
- 12 A definition of Artificial Intelligence: main capabilities and scientific disciplines. 2018. Euroopan komissio < <https://digital-strategy.ec.europa.eu/fi/node/2226>>. Luettu 22.3.2024.
- 13 Mitä koneoppiminen on? Verkkoaineisto. SAP. <<https://www.sap.com/finland/products/artificial-intelligence/what-is-machine-learning.html>>. Luettu 22.3.2024.
- 14 Ghods, Kimia; Azizi, Arash; Jafari, Aryan & Ghods, Kian. 2023. Application of Artificial Intelligence in Clinical Dentistry, a Comprehensive Review of Literature. J Dent Shiraz Univ Med Sci, 24(4). <<https://doi.org/10.30476/dentjods.2023.96835.1969>>. Luettu 1.4.2024.
- 15 Theissler, Andreas; Pérez-Velázquez, Judith; Kettelgerdes, Marcel & Elger, Gordon. 2021. Predictive maintenance enabled by machine learning: use cases and challenges in the automotive industry. Reliability Engineering & System Safety, 215. <<https://doi.org/10.1016/j.ress.2021.107864>>. Luettu 10.2.2024.
- 16 Sarker, Iqbal H. 2021. Machine Learning: Algorithms, Real-World Applications and Research Directions. SN Computer Science, 2(3). <<https://doi.org/10.1007/s42979-021-00592-x>>. Luettu 20.4.2024.
- 17 What is supervised learning? Verkkoaineisto. IBM. <<https://www.ibm.com/topics/supervised-learning>>. Luettu 10.3.2024.
- 18 What is unsupervised learning? Verkkoaineisto. IBM <<https://www.ibm.com/topics/unsupervised-learning>>. Luettu 10.3.2024.
- 19 What is machine learning? Verkkoaineisto. SAP. <<https://www.sap.com/finland/products/artificial-intelligence/what-is-machine-learning.html>>. Luettu 12.3.2024.
- 20 What is semi-supervised learning? Verkkoaineisto. IBM <<https://www.ibm.com/topics/semi-supervised-learning>>. Luettu 10.3.2024.
- 21 What is linear regression? Verkkoaineisto. IBM <<https://www.ibm.com/topics/linear-regression>>. Luettu 10.3.2024.

- 22 What is reinforcement learning? Verkkoaineisto. AWS Amazon. <<https://aws.amazon.com/what-is/reinforcement-learning/>>. Luettu 13.4.2024.
- 23 What is deep learning? Verkkoaineisto. IBM. <<https://www.ibm.com/topics/deep-learning>>. Luettu 13.4.2024.
- 24 Nunes, P; Santos, J & Rocha, E. 2023. Challenges in predictive maintenance – A review. CIRP vol 40. <<https://doi.org/10.1016/j.cirpj.2022.11.004>>. Luettu 20.3.2024.
- 25 Çınar, Zeki Murat; Nuhu, Abubakar Abdussalam; Zeeshan, Qasim; Korhan, Orhan; Asmael, Mohammed & Safaei, Babak. 2020. Machine Learning in Predictive Maintenance towards Sustainable Smart Manufacturing in Industry 4.0. Sustainability. 12(19) <<https://doi.org/10.3390/su12198211>>. Luettu 7.4.2024.
- 26 Davari N, Veloso B, Costa GdA, Pereira PM, Ribeiro RP, Gama J. 2021. A Survey on Data-Driven Predictive Maintenance for the Railway Industry. *Sensors*. 21(17) <<https://doi.org/10.3390/s21175739>>. Luettu 3.4.2024.
- 27 Davari, Narjes; Veloso, Bruno; Costa, Gustavo de Assis; Pereira, Pedro Mota; Ribeiro, Rita P., & Gama, João. 2022. Challenges and Cases of Artificial Intelligence Applied to Assist Predictive Maintenance in the Industry, Respectively in the Mining Sector. *Sensors*, 21(17). <<https://doi.org/10.3390/s21175739>>. Luettu 15.4.2024.
- 28 Xia, Liqiao; Zheng, Pai; Li, Xinyu; Gao, Robert. X., & Wang, Lihui. 2022. Toward Cognitive Predictive Maintenance: A Survey of Graph-based Approaches. *Journal of Manufacturing Systems*. 64. 107-120. <<https://doi.org/10.1016/j.jmsy.2022.06.002>>. Luettu 15.4.2024.
- 29 Predictive maintenance 4.0, Predict the unpredictable. 2017. Verkkoaineisto. PwC. <<https://www.pwc.be/en/documents/20171016-predictive-maintenance-4-0.pdf>>. Luettu 14.4.2024.
- 30 Predictive Maintenance Market Share, Size, Trends, Industry Analysis Report, By Component (Solutions, Services); By Deployment Model (Cloud, On-Premise); By Organization Size; By Industry Vertical; By Region; Segment Forecast, 2022 - 2030. 2022. Verkkoaineisto. Polaris. <<https://www.polarismarketresearch.com/industry-analysis/predictive-maintenance-market>>. Luettu 12.4.2024.
- 31 Hurtado, Julio; Salvati, Dario; Semola, Rudy; Bosio, Mattia, & Lomonaco, Vincenzo. 2023. Continual learning for predictive maintenance: Overview and challenges. *Intelligent Systems with Applications* vol. 19. <<https://doi.org/10.1016/j.iswa.2023.200251>>. Luettu 20.4.2024.