

Juho Torppa

TEKOÄLYPOHJAINEN ENNAKOIVA KUNNOSSAPITO BIO- KAASUREAKTORISSA

Opinnäytetyö

Tekniikan ammattikorkeakoulututkinto

Robotiikan ja tekoälyn koulutus

2025



**Kaakkois-Suomen
ammattikorkeakoulu**

Tutkintonimike	Insinööri (AMK)
Tekijä	Juho Torppa
Työn nimi	Tekoälypohjainen ennakoiva kunnossapito biokaasureaktorissa
Toimeksiantaja	Arciplug Oy
Vuosi	2025
Sivut	59 sivua
Työn ohjaajat	Henry Lähteenmäki, Niko Etsola

TIIVISTELMÄ

Tämän opinnäytetyön tavoitteena on muodostaa yleiskatsaus siitä, mitä dataa biokaasureaktorin laitteistoista on tarpeen kerätä niiden tehokkaan kunnossapidollisen tilan seuraamiseksi, sekä kuinka kyseinen data on mahdollista kerätä. Työn taustalla oli toimeksiantajan, Arciplug Oy:n, tarve vähentää biokaasureaktoreiden käyttökatkoja ja optimoida huoltotoimintoja. Tuloksia on tarkoitus hyödyntää tekoälypohjaisen ennakoivan kunnossapitojärjestelmän kehitystyössä.

Opinnäytetyö toteutettiin kuvailevana kirjallisuuskatsauksena, jonka avulla koottiin aikaisempien tutkimusten tarjoamaa tietoa kohdelaitteiden mittaussparametreista ja kunnossapidon tarpeista. Aineisto koostui pääosin akateemisista julkaisuista ja teknisistä tutkimusartikkeleista, joita analysoitiin laadullisen sisällönanalyysin keinoin.

Tutkimuksessa tunnistettiin keskeiset mittaussparametrit, joita laiteluokkien kunnonvalvonnassa on hyödynnetty. Tutkimus osoittaa, että seurattavat muutujat voidaan jakaa sähköisiin, mekaanisiin ja prosessiperusteisiin suureisiin, joista virta, värinä ja lämpötila korostuivat merkittävimmin tekijöinä.

Opinnäytetyön tulokset tukivat työn tavoitteita ja perustuivat johdonmukaiseen kokonaiskuvaan, joka muodostui useiden tutkimusten pohjalta. Tulokset toimivat yleispäteväenä kunnonvalvonnan viitekehystenä, jota voidaan hyödyntää tekoälypohjaisen kunnossapidon jatkokehityksessä sekä ohjelmisto- että järjestelmätasolla. Työ luo perustan jatkotutkimuksille, joissa syvennytään laitekohtaiseen datankeruuseen ja tekoälyn soveltamiseen mitattavien suureiden analysoinnissa.

Asiasanat: tekoäly, koneoppiminen, kunnossapito, kunnonvalvonta

Degree title	Bachelor of Engineering
Author	Juho Torppa
Thesis title	AI-based predictive maintenance in biogas reactor
Commissioned by	Arciplug Oy
Time	2025
Pages	59 pages
Supervisors	Henry Lähteenmäki, Niko Etsola

ABSTRACT

The aim of this thesis was to provide a general overview of what data needs to be collected from biogas reactor equipment to effectively monitor its maintenance condition, and how this data can be obtained. The thesis was commissioned by Arciplug Oy, which seeks to reduce downtime and optimize maintenance operations in biogas reactors. The results of this study are intended to support the development of an AI-based predictive maintenance system.

The research was carried out as a descriptive literature review, compiling information from previous studies on measurement parameters and maintenance requirements of the target equipment. The material consisted mainly of academic publications and technical research articles, which were analyzed using qualitative content analysis.

The research identified key measurement parameters commonly used in equipment condition monitoring. The results indicate that the monitored variables can be categorized into electrical, mechanical, and process-related quantities, among which current, vibration, and temperature emerged as the most significant indicators.

The results of this thesis supported its objectives and were grounded in a coherent overall understanding formed through the synthesis of multiple studies. These findings provide a general framework for condition monitoring that can be applied in the further development of AI-based maintenance, both at the software and system levels. The thesis also establishes a foundation for future studies focusing on device-specific data acquisition and the application of artificial intelligence in the analysis of measurable variables.

Keywords: artificial intelligence, machine learning, maintenance, condition monitoring

SISÄLLYS

1	JOHDANTO.....	5
2	TEKOÄLY.....	6
2.1	Tekoälyn määritelmä.....	6
2.2	Koneoppiminen.....	9
2.3	Neuroverkot.....	15
3	ENNAKOIVA KUNNOSSAPITO.....	20
3.1	Ennakoivan kunnossapidon määritelmä.....	21
3.2	Keskeiset teknologiat.....	21
3.3	Tekoäly ja koneoppiminen ennakoivassa kunnossapidossa.....	22
4	OPINNÄYTETYÖN TOTEUTUS.....	23
5	TUTKIMUKSEN TULOKSET.....	28
5.1	Yleistä kaikille laitteille.....	29
5.2	Mittalaitteet.....	30
5.3	Sähkömoottorit.....	30
5.4	Kompressorit.....	34
5.5	Pumput.....	37
5.6	Venttiilit.....	40
5.7	Hydrauliikkajärjestelmä.....	45
5.8	Taajuusmuuttajat.....	48
5.9	Jatkokehitys.....	49
6	POHDINTA.....	50
6.1	Yhteenveto.....	50
6.2	Tekijän oppimiskokemukset.....	51
	LÄHTEET.....	53

1 JOHDANTO

Tutkimuksen aiheeksi valikoitui tekoölyn hyödyntäminen ennakoivassa kunnossapidossa. Tutkimuksen aihetta lähdettiin kehittämään tarpeesta selvittää mahdollisia ratkaisuja toimeksiantajan, Arciplug Oy biokaasureaktoreiden käyttökatojen minimoimiseen. Biokaasureaktoreiden prosessien ylös- ja alasajo ovat kokonaisuudessaan erittäin aikaa vieviä prosesseja, jotka tuovat mukanaan suuret kustannukset. Työssä käsiteltävän reaktorin tyypistä johtuen 100 % kaasuntuotannon saavuttaminen nollatasolta on kuukausia kestävä prosessi. Mikäli esimerkiksi vakavasta laiterikosta johtuen prosessi jouduttaiisiin ajamaan alas ja reaktori tyhjentämään korjausta sekä uudelleenkäynnistystä varten, tulisi koko prosessi viemään jopa kuukausia ja aiheuttamaan tappioita sadoista tuhansista jopa miljoonaan euroon. Lähtötietona biokaasureaktorin käyttökatojen kannalta vakavimmaksi tekijäksi nousivat kriittisten ja toisarvoisten huoltoon vaativien osien yllättävät laiterikot. Näiden osien huollollisen tilan tarve perustuu laitteiston valmistajan tarjoamaan tietoon, joka on puolestaan rajallista. Tekoöly- ja koneoppimismenetelmät tarjoavat mahdollisuuden käsitellä suuria datamääriä ja tunnistaa huollollisia tarpeita, joita perinteiset menetelmät eivät välttämättä tavoita.

Tutkimustulosten avulla pyritään saattamaan toimeksiantajalle pohjatietoa tekoölypohjaisen ennakoivan huollon kehitysohjelmaan. Tämä tulisi auttamaan ohjelmistokehityksen suunnan valinnassa ja ohjaisi toimeksiantajaa tekemään perustellumpia päätöksiä tekoölypohjaisen huollon järjestämisestä tulevaisuudessa.

Tutkimuksen rajaus ja tavoite

Tutkimus rajataan koskettamaan toimeksiantajan patentoiman tulppavirtaus tyyppisen biokaasureaktorin (engl. *plug flow reactor*, *PFR*) sisältämiä laitteita, jotka on kytketty reaktorin ohjausjärjestelmään.

Tutkimustyössä pyritään vastaamaan seuraaviin tutkimuskysymyksiin:

1. Mitkä ovat yksittäisen toimilaitteen huollollisen tarpeen ennustamiseen tarvittavat keskeiset datatyypit ja mittausparametrit?

2. Millä menetelmillä ja teknologioilla laitteista tarvittava data voidaan kerätä?

Tekoälyn hyödyntäminen

Tämän opinnäytetyön laatimisessa tekijä on hyödyntänyt tekoälytyökalua ChatGPT-5. Tätä ohjelmistoa on hyödynnetty vieraskielisten tekstien kääntämisessä ja tiedonhaussa. Tekijä on tarkistanut ja muokannut työkalun laatimaa sisältöä ja ottaa täyden vastuun teoksen sisällöstä.

2 TEKÖÄLY

Tässä luvussa käsitellään tekoälyn teoreettista viitekehystä. Luvun tavoitteena on luoda selkeä kokonaiskuva tekoälyn peruskäsitteistä, sen alajaoista sekä toiminnallisista periaatteista, jotka muodostavat perustan tekoälypohjaisille järjestelmille.

2.1 Tekoälyn määritelmä

Kansainväliseen käyttöön vakiintunut termi AI (engl. *Artificial Intelligence*) eli tekoäly on yhdysvaltalaisen tietojenkäsittelytieteilijän John McCarthyn aikaansaannos (Britannica Editors 2009). Tekoäly on käsitteenä laaja, ja sen määritelmä on muuttunut entisaikojen ”ajattelevan koneen” ajatuksesta tähän päivään asti. Tekoälyn yleistyminen ja nopea kehitys kuluneen vuosikymmenen aikana on johtanut sen määritelmän useaan eriotteiseen päivittämiseen niin juridisella kuin tieteellisellä tasolla.

Tekoälyn juridinen ja tieteellinen määritelmä on eroteltu tässä osiossa niiden tarkoitusperistä johtuvien seikkojen vuoksi. Juridisen määritelmän pyrkiessä kattavuuteen sekä käytännön sovellettavuuden, sääntelyn ja vastuunjaon tukemiseen ovat sitä vastoin tieteelliset lähestymistavat tekoälyn määrittelyssä usein tarkempia, kun tekoälyä tarkastellaan ilmiönä ja tieteenalana. Tieteellisissä määritelmissä korostuvat muun muassa järjestelmän toiminnalliset periaatteet, laskennalliset menetelmät ja loogiset rakenteet. Näiden seikkojen vuoksi on tieteellinen lähestymistapa tämän opinnäytetyön kannalta merkittävämpi tulosten ja tavoitteiden saavuttamiseksi, mutta juridiikan merkitystä ja

sen osuutta tekoälyn tutkimisessa ja kehittämisessä on tärkeä korostaa. (Sa-moili ym. 2021.)

Tekoälyn juridinen määritelmä

Juridiselta tasolta tätä opinnäytetyötä koskettava ja tekoälyn määrittelyn osalta merkittävimmäksi asetukseksi osoittautui Euroopan parlamentin ja neuvoston asetuksen 2024/1689 yleisten säännösten kolmas artikla, jonka mukaisesti tekoäly on määritelty seuraavalla tavalla: *Tässä asetuksessa tarkoitetaan ”tekoälyjärjestelmällä” konepohjaista järjestelmää, joka on suunniteltu toimimaan käyttöönoton jälkeen vaihtelevilla autonomian tasoilla ja jossa voi ilmetä mu-kautuvuutta käyttöönoton jälkeen ja joka päättelee vastaanottamastaan syöt-teestä eksplisiittisiä tai implisiittisiä tavoitteita varten, miten tuottaa tuotoksia, kuten ennusteita, sisältöä, suosituksia tai päätöksiä, jotka voivat vaikuttaa fyysisiin tai virtuaalisiin ympäristöihin.* Asetus on osa Euroopan unionin teko-älyasetusta (*EU Artificial Intelligence Act*), jonka avulla pyritään säätelemään riskipohjaisesti tekoälyn käyttöä kaikissa mahdollisissa sovelluskohteissa. Asetus on ensimmäinen kattava tekoälyn käytön säätelyä ohjaava lainsäädäntö, joka koskettaa jokaista organisaatiota ja yritystä EU:n alueella sekä EU:n ulkopuolella, mikäli näillä toimijoilla on vaikutusta eurooppalaisiin markki-noihin. Asetus koskettaa tekoälyjärjestelmien kehittämistä, käyttöä, sekä käyt-töönottoa, ja määrittelee nämä järjestelmät neljään riskiluokkaan: sietämätön, korkea, rajoitettu ja vähäinen/olematon. (Euroopan parlamentin ja neuvoston asetus (EU) 2024/1689.)

Tekoälyn tieteellinen määritelmä

Tekoälyn tieteellinen määritelmä pohjautuu eri tieteenalojen näkökulmiin ja kä-sittää laajan joukon ominaisuuksia, jotka liittyvät älykkään toiminnan ilmenemi-seen keinotekoisessa järjestelmässä. Yleisluontoisesti tekoäly voidaan määri-tellä tieteenalaksi, joka keskittyy normaalisti ihmisen älyllisiä kykyjä, kuten päättelyä, oppimista, suunnittelua, päätöksentekoa tai luovuutta vaativien teh-tävien suorittamiseen kykenevien järjestelmien kehittämiseen. Näitä tehtäviä voi luonnehtia monimutkaisiksi, muuttuvissa ja ennakoimattomissa olosuh-teissa tapahtuviksi toimiksi, joita järjestelmä suorittaa joko täysin itsenäisesti tai vähäisellä ihmisen ohjauksella. (AI vs. machine learning... 2023; Kelley

2024; Mohsen ym. 2023; Mitä on tekoäly... 2020; What is artificial intelligence (AI)? s.a.)

Tieteellisessä kontekstissa tekoäly määritellään usein joukoksi teknologisia ja laskennallisia ratkaisuja, joiden avulla keinotekoiset järjestelmät voivat havainnoida ja vaikuttaa ympäristöönsä, käsitellä ja analysoida tietoa, oppia kokemuksesta sekä tehdä päätöksiä annettujen tavoitteiden saavuttamiseksi. Tällaiset järjestelmät voidaan toteuttaa ohjelmistopohjaisesti (esim. puheentunnistus, hakualgoritmit, konenäkö) tai fyysisessä muodossa (esim. robotit, itseohjautuvat ajoneuvot, anturiverkot). Ne voivat myös yhdistää useita älykkäitä toimintoja, kuten havainnointia, suunnittelua, päätöksentekoa ja toimintaan ryhtymistä, muodostaen eräänlaisia älykkäitä agenteja. (AI vs. machine learning... 2023; Kelley 2024; Mohsen ym. 2023; Mitä on tekoäly... 2020; What is artificial intelligence (AI)? s.a.)


Tekoäly yhdistää useita tieteenaloja, kuten tietojenkäsittelytieteen, tilastotieteen, neuroverkkoihin pohjautuvan laskennan, ohjelmisto- ja laitteistotekniikan sekä kognitiotieteet. Koska tekoällyn sovelluskohteet vaihtelevat merkittävästi ja teknologian kehitys on nopeaa, ei tekoällylle ole olemassa yhtä ainoaa, ehdotonta määritelmää. Tekoäly ymmärretään kattoterminä joukolle menetelmiä, jotka pyrkivät jäljittelemään, mallintamaan tai täydentämään ihmismäistä älykkyyttä keinotekoisesti. (AI vs. machine learning... 2023; Kelley 2024; Mohsen ym. 2023; Mitä on tekoäly... 2020; What is artificial intelligence (AI)? s.a.)

Nykyteknologian tasolla tekoälyjärjestelmien sovellukset edustavat lähes poikkeuksetta kapeaa tekoälyä (engl. *Narrow AI*). Kapean tekoällyn järjestelmät perustuvat tilastollisiin ja matemaattisiin malleihin, jotka mahdollistavat datan analysoinnin, kaavojen tunnistamisen ja ennustavan päättelyn. Kapea tekoäly viittaa siis tekoällyn muotoon, joka on suunniteltu suorittamaan yksittäisiä rajoitettuja tehtäviä tai joukkoa tarkasti määriteltyjä tehtäviä. Tämä tekoällyn muoto ei pyri ihmisenmielen kaltaisen *yleisen älykkyyden* täydelliseen jäljittelemiseen, vaan sen kyvyt rajautuvat sille koulutettujen tehtävien suorittamiseen. (AI vs. machine learning... 2023; Boucher 2020; Kelley 2024; Mohsen ym. 2023; Mitä on tekoäly... 2020; Samoili ym. 2020; Stryker & Kavlakoglu 2024; What is artificial intelligence? 2025; What is artificial intelligence (AI)? s.a.)

2.2 Koneoppiminen

Koneoppiminen (engl. *Machine Learning, ML*) on tekoälyn osa-alue, joka keskittyy menetelmiin ja algoritmeihin, joiden avulla konepohjaiset järjestelmät voivat oppia suoraan tarkasteltavasta datasta ilman toimintojen erillistä ohjelmointia ja näin kehittämään toimintaansa kokempohjaisesti. Kaikkien koneoppimismallien pääpiirteisiin lukeutuu järjestelmien kyky optimoida sisäisiä parametrejaan havaitun tiedon perusteella. Tämä mahdollistaa näiden järjestelmien kyvyn analysoida suuria tietomääriä, tunnistaa niissä piileviä riippuvaisuuksia ja tekemään niiden pohjalta ennusteita ja päätöksiä. Koneoppiminen mahdollistaa tekoälylle ominaisen kyvyn oppia kokemuksesta. (AI vs. machine... 2023; Holdsworth & Scapicchio 2024; Machine learning... s.a.; Mohsen ym. 2023; Sharma ym. 2021; What Is Machine Learning... 2020; What is machine learning... s.a.)


Yksinkertaistettuna koneoppimisen prosessi toimii seuraavalla tavalla. Prosessi käynnistyy datan keruusta ja esikäsittelystä, jonka tavoitteena on varmistaa aineiston laatu ja analysoitavuus. Tämän jälkeen koneoppimismallin algoritmi koulutetaan valitun menetelmätyypin mukaan. Valvotut mallit oppivat vertaamalla tuloksia opetusdataan, kun taas valvomattomat mallit tunnistavat rakenteita ilman vastaavaa vertailutietoa. Mallin koulutuksellisen valmiuden saavuttaessa tyydyttävän tason, otetaan se käyttöön todellisessa sovelluskohhteessa, jossa se analysoi uutta dataa ja tuottaa päätelmiä. (Kuva 1.) (AI vs. machine... 2023; Holdsworth & Scapicchio 2024; Machine learning... s.a.; Mohsen ym. 2023; Sharma ym. 2021; What Is Machine Learning... 2020; What is machine learning... s.a.)



Kuva 1. Koneoppimisprosessi (What is machine learning... s.a.)

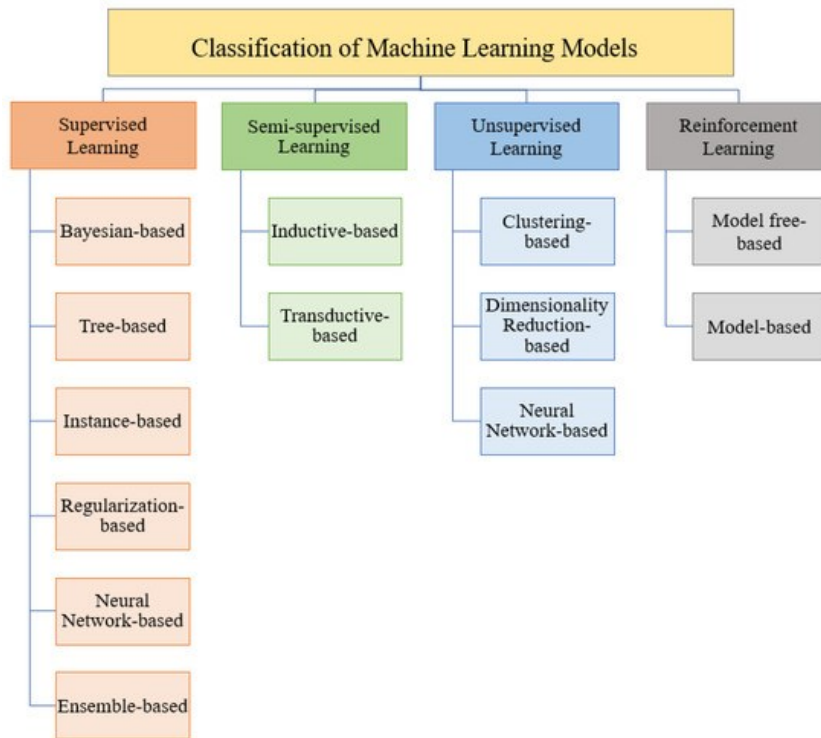
Koneoppimisen toimiessa tekoälyn tukipilarina, koostuu koneoppiminen edelleen neuroverkoista ja syväoppimisesta. Kuvassa 2 on esitetty tekoälyn, kone-

oppimisen, neuroverkkojen ja syväoppimisen välinen hiarkinen suhde. Tekoäly kuvataan laajana yläkäsitteenä, jonka sisällä koneoppiminen muodostaa dataan pohjautuvat oppimismenetelmät. Koneoppiminen puolestaan koostuu neuroverkoista sekä niiden erikoistuneesta syväoppimisen alajoukosta. (Bitton-Bailey ym. s.a.)



Kuva 2. Tekoälyn, koneoppimisen, neuroverkkojen ja syväoppimisen väliset suhteet (Bitton-Bailey ym. s.a.)

Koneoppiminen koostuu useista eri koneoppimismalleista, jotka on yleisesti hyväksytyyn mallin mukaisesti jaoteltu neljään eri pääluokkaan, **valvottuun**, **puolivalvottuun**, **valvomattomaan** ja **vahvistavaan oppimiseen**, jotka voidaan jakaa omiin alaluokkiinsa (Khoie & Kaabouch 2023).

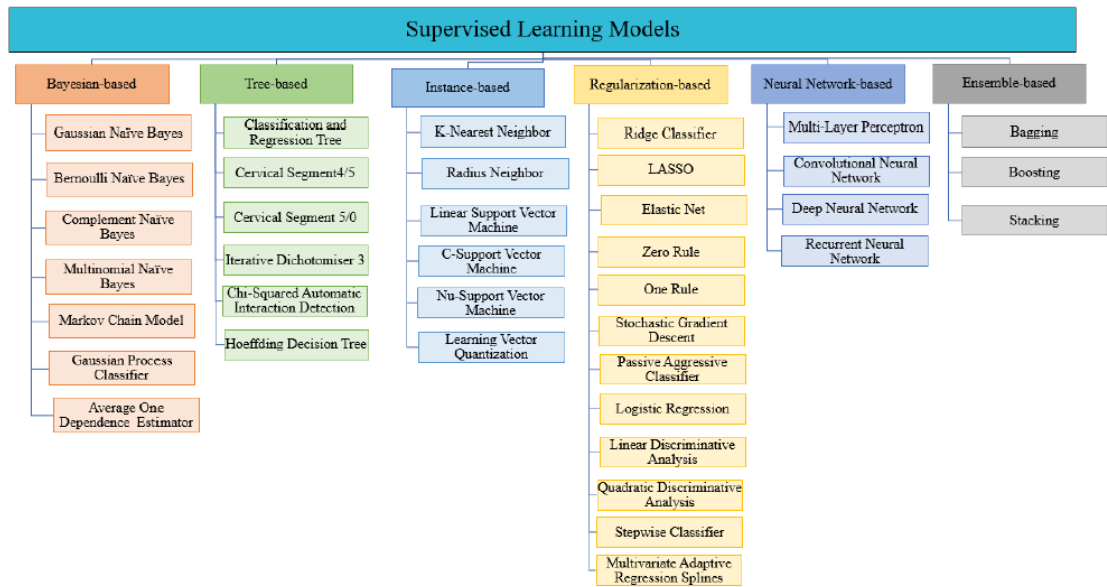


Kuva 3. Koneoppimismallien luokittelu (Khoei & Kaabouch 2023)

Kuvassa 3 havainnollistetaan mainittujen pääluokkien rakenteellisia eroja ja tarjotaan kokonaiskuva koneoppimisen menetelmällisestä kirjosta ilman menetelmätason syventymistä. Huomioitavaa on, että nämä luokittelut ovat suuntaa antavia ja kehittyvänä tieteenalana nämä luokitukset eivät koskaan tule olemaan täydellisiä.

Valvottu oppiminen

Valvottu oppiminen (engl. *Supervised Learning*) on koneoppimisen alaluokka, jonka pohjalta rakennettu algoritmi koulutetaan havaitsemaan syötteestä ennalta määritettyyn tuloon johtaneet riippuvaisuudet ja suhteet. Järjestelmän tehtävänä on havaita nämä siltä piilossa olevat muuttujat ja pyrkiä selvittämään esimerkki syötteen pohjalta valmiiksi mallinnettuun tuloon johtaneet tekijät. Valvottu oppiminen tuottaa parhaita tuloksia luokittelussa ja regressiossa, joissa mallin tehtävänä on tunnistaa syötteiden kategoriat tai arvioida niiden numeerisia suhteita. (Ali 2022; What is supervised learning? 2024; What is supervised learning? Machine... 2023; Yasar ym. 2024b.)

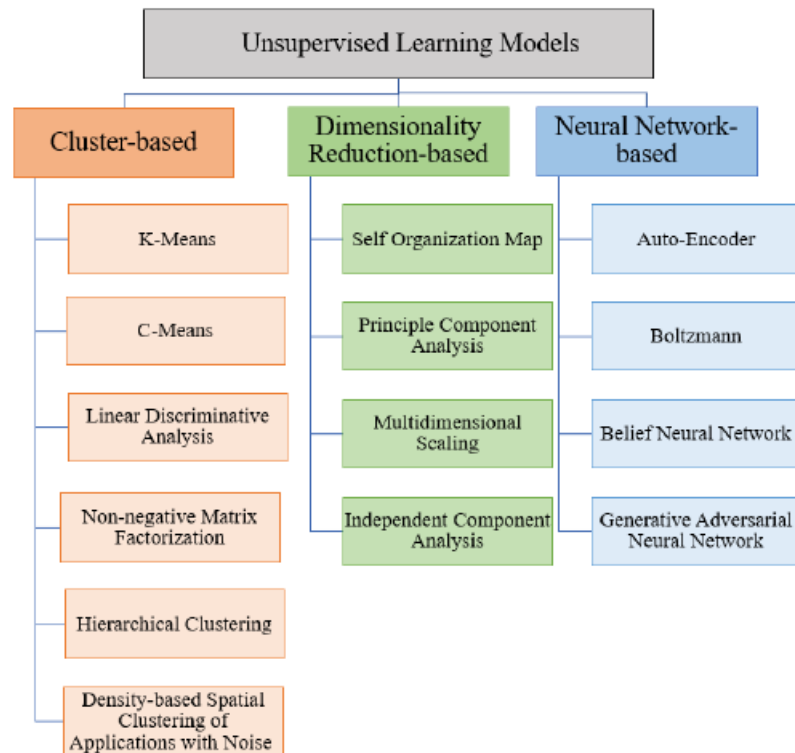


Kuva 4. Valvotun oppimisen mallien luokittelu (Khoei & Kaabouch 2023.)

Kuvassa 4 esitetään valvotun oppimisen pääluokat ja niiden keskeiset alaluokat. Mallit on jäsenetty kuuteen ryhmään, jotka havainnollistavat valvotun oppimisen menetelmällistä kirjoa ilman algoritmikohtaista syventymistä. Esitetyt ryhmät ovat Bayesiläiset (Bayesian-based) mallit, puupohjaiset (tree-based) menetelmät, instance-mallit, regularisointiin perustuvat menetelmät, neuroverkkopohjaiset mallit sekä ensemble-mallit. Kuvan tarkoituksena on antaa yleiskuva siitä, millaisia menetelmiä valvotun oppimisen kokonaisuus sisältää.

Valvomaton oppiminen

Valvomaton oppiminen (engl. *Unsupervised Learning*) on koneoppimisen alaluokka, jonka pohjalta rakennettu algoritmi koulutetaan itsenäisesti tulkitsemaan syötettä. Ohjelmistolle syötetään raakaa määrittelemätöntä dataa, josta algoritmi pääättelee ja jäsentää tiedosta saatavia riippuvaisuuksia ja kaavoja ilman ohjeistusta. Ohjaamatonta oppimista soveltavat algoritmit ovat tehokkaita monimutkaisissa tehtävissä, kuten suurten datamäärien sisällön klusteroinnissa (datapisteiden samankaltaisuuksien mukaisessa ryhmittelyssä) ja ennalta-arvaamattomien kuvioiden ja kaavojen löytämisessä suuresta määrästä tuntematonta dataa. (How Unsupervised... 2025; What is unsupervised learning? s.a.; What is unsupervised learning? 2021.)



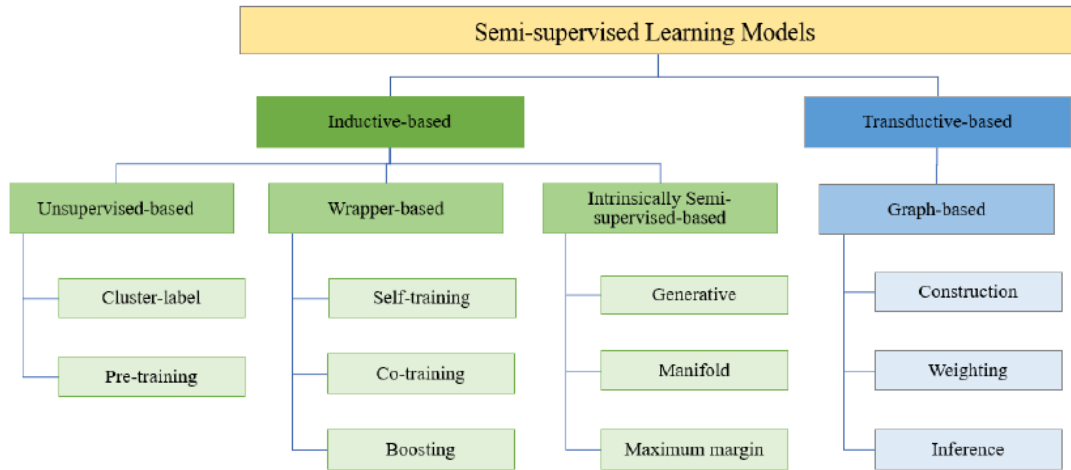
Kuva 5. Valvomattoman oppimisen mallien luokittelu (Khoei & Kaabouch 2023.)

Kuvassa 5 esitetään valvomattoman oppimisen pääluokat ja niiden keskeiset alaluokat. Mallit on jäsennetty kolmeen ryhmään, jotka havainnollistavat menetelmien keskeisiä lähestymistapoja ilman algoritmikohtaista tarkastelua. Klusterointiin perustuvat mallit, ulottuvuuksien vähentämisen menetelmät ja neuroverkkopohjaiset ratkaisut muodostavat kokonaisuuden, joka kuvaa valvomattoman oppimisen tapoja ryhmitellä, tiivistää tai mallintaa dataa ilman opetusvastineita. Kuvan tarkoituksena on antaa yleiskuva siitä, millaisia menetelmiä valvomattoman oppimisen kokonaisuus sisältää.

Puolivalvottu oppiminen

Puolivalvottu oppiminen (engl. *Semi-supervised Learning*) on koneoppimisen alaluokka, jossa on ominaisuuksia sekä valvotusta, että valvomattomasta oppimisesta. Puolivalvottuun oppimiseen perustuva järjestelmä koulutetaan ensin valvotun oppimisen tapaisesti ennalta määritettyjen syötteiden ja valmiiden tulosten avulla, jonka avulla algoritmilta muodostuu malli, jonka pohjalta jatkaa tuntemattoman datan analysointiin. Algoritmin saavutettaessa tyydyttävän tason valvotun oppimisen menetelmän osin, siirrytään valvomattoman oppimisen menetelmiin ja järjestelmä koulutetaan tuntemattomalla datalla. Puolivalvottu oppimismenetelmä on ideaali järjestelmiin, joissa koulutusdataa on hyvin

paljon, mutta syötteiden pohjalta ei ole olemassa valmiita mallituloja, vaan niiden löytäminen jää algoritmin tehtäväksi. (Bergmann 2023; Chen 2024b; Reddy ym. 2018; Semi-Supervised... s.a.)

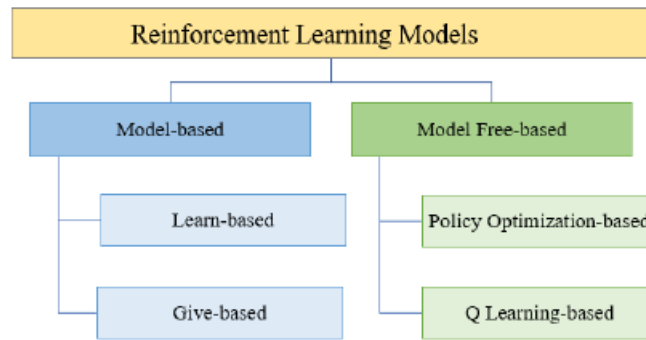


Kuva 6. Puolivalvotun oppimisen mallien luokittelu (Khoei & Kaabouch 2023.)

Kuvassa 6 esitetään puolivalvotun oppimisen pääluokat, jotka on jäsennetty induktiivisiin ja transduktiivisiin menetelmiin sekä niiden alaluokkiin. Kuvan tarkoituksena on hahmottaa puolivalvotun oppimisen keskeiset lähestymistavat ilman teoriatasoista syventymistä. Kuvan tarkoituksena on antaa yleiskuva siitä, millaisia menetelmiä puolivalvotun oppimisen kokonaisuus sisältää.

Vahvistava oppiminen

Vahvistava oppiminen (engl. *Reinforcement Learning*) on koneoppimisen alaluokka, joka pohjautuu autonomisten agenttien päätöksentekoon. Autonomiset agentit ovat mitä tahansa järjestelmiä, jotka kykenevät tekemään päätöksiä ja reagoimaan ympäristöönsä itsenäisesti, ilman ihmisen ohjausta. Vahvistetun oppimisen mallissa koulutus tapahtuu autonomisen agentin, ympäristön ja yrityksen kautta epäonnistumisen sekä onnistumisen tuottamien ”rangaistusten” ja ”palkkioiden” välillä. Vahvistavan oppimisen algoritmit kannustavat autonomista agenttia haluttuun toiminnalliseen kaavaan palkitsemalla sitä positiivisilla arvoilla halutuissa toimissa ja rankaisemalla sitä negatiivisilla arvoilla ei-toivotuissa toimissa. Vahvistettu oppiminen tuo joustavuutta mallin oppiessa kokeilemisen ja erehtymisen kautta, saaden laajat kyvyt mukautua ja oppia useita ratkaisuja saavuttaakseen onnistumisia sille määritetyissä tehtävissä. (Chen 2024a; Gillis ym. 2024b; Murel & Kavlakoglu 2024.)



Kuva 7. Vahvistetun oppimisen mallien luokittelu (Khoei & Kaabouch 2023.)

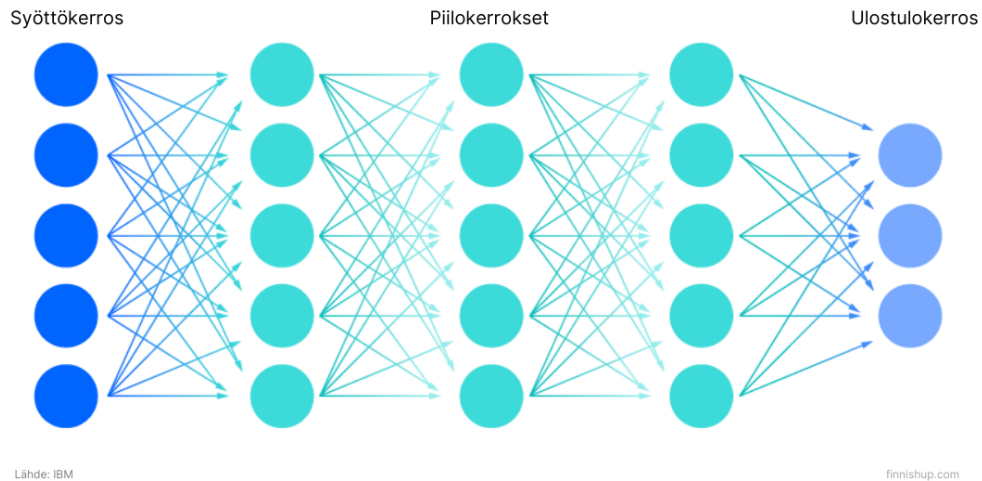
Kuvassa 7 esitetään vahvistavan oppimisen pääluokat, jotka on jaettu mallipohjaisiin ja mallivapaisiin menetelmiin sekä niiden keskeisiin alaluokkiin. Kuvan tarkoituksena on hahmottaa vahvistavan oppimisen menetelmällinen rakenne yleisellä tasolla ilman algoritmikohtaista tarkastelua.

2.3 Neuroverkot

Neuroverkot tai **keinotekoiset neuroverkot** (engl. *Artificial Neural Networks, ANN*) ovat koneoppimisen osa-alue ja syväoppimisen perusta. Neuroverkot ovat saaneet nimityksensä niiden toimintalogiikasta, joka jäljittelee ihmisaivojen hermosolujen tapaa lähettää signaaleja toisilleen. (Artificial Neural... s.a.; How Do Neural Networks... 2025; How Neural Network Models... 2022; Israelsen 2024; Kinza 2024; What is neural network? 2021.)

Kuvassa 8 havainnollistetaan neuroverkon perusrakenne, joka muodostuu **syötekerroksesta**, useista **piilokerroksista** ja **lähtökerroksesta** (kuvassa nimellä ulostulokerros). Tiedon etenemistä kerrokselta toiselle kuvataan nuolilla, jotka yhdistävät **neuroneita** kuvaavat siniset ympyrät aina seuraavan kerroksen jokaiseen **neuroniin**.

Neuroverkon kerrokset



Kuva 8. Neuroverkon rakenne (Numminen 2023)

Syötekerros (engl. *input layer*): Neuroverkon ensimmäinen kerros, joka vastaanottaa dataa ja välittää sen eteenpäin seuraavien kerrosten käsiteltäväksi. Syötekerroksen jokainen yksittäinen neuroni käsittelee syötteen yksittäistä ominaisuutta. Sanaa käsitellessä tällaisia ominaisuuksia olisivat esimerkiksi merkkimäärä, samojen merkkien määrä, tavujen määrä jne. Syötekerroksessa ei tapahdu tiedon vastaanottamisen ja sen edelleen lähettämisen lisäksi muita toimia. (Artificial Neural... s.a.; How Do Neural Networks... 2025; How Neural Network Models... 2022; Israelsen 2024; Kinza 2024; What is neural network? 2021.)

Piilokerros (engl. *hidden layer*): Neuroverkon ensimmäisen ja viimeisen kerroksen välissä sijaitsee yksi tai useampi piilokerros. Nämä kerrokset suorittavat neuroverkossa tapahtuvat laskennalliset toimet. Jokainen tämän kerroksen neuroni vastaanottaa syötteen jokaiselta edellisen kerroksen neuronilta. Tämä saatu syöte prosessoidaan matemaattisia funktioita käyttäen ja tulos syötetään jälleen seuraavan kerroksen jokaiselle neuronille. Piilokerrosten määrä, tai toisin sanoin syvyys määrittää verkon kokonaiskyvykkyyden ja tehon syöte-tiedon riippuvuuksien oppimisessa ja tunnistamisessa. (Artificial Neural... s.a.; How Do Neural Networks... 2025; How Neural Network Models... 2022; Israelsen 2024; Kinza 2024; What is neural network? 2021.)

Lähtökerros (engl. *output layer*) on neuroverkon viimeinen kerros, joka prosessoidun tiedon pohjalta tuottaa ennusteet tai muut tulokset. (Artificial

Neural... s.a.; How Do Neural Networks... 2025; How Neural Network Models... 2022; Israelsen 2024; Kinza 2024; What is neural network? 2021.)

Neuroverkkojen kerrokset rakentuvat neuroneista, jotka ovat yhteydessä toisiinsa. Näihin neuroneiden välisiin yhteyksiin ja datavirtaan vaikuttavat verkon **painoarvot** ja **aktivointifunktiot** sekä **harhat**. (Artificial Neural... s.a.; How Do Neural Networks... 2025; How Neural Network Models... 2022; Israelsen 2024; Kinza 2024; What is neural network? 2021.)

Painoarvot (engl. *weight*) ovat numeerisia arvoja, jotka määrittävät neuronien välisten yhteyksien voimakkuuden, joka puolestaan muokkaa neuronin lähtöarvojen vaikutusta neuronien tuloarvoihin. Painoarvo vaikuttaa verkossa prosessoitavan datan ominaisuuksien tärkeyteen ja täten hienosäätää järjestelmän kykyä oppia sille syötetystä datasta. Esimerkiksi käsinkirjoitettua tekstiä tunnistettaessa järjestelmä kykenee antamaan enemmän painoarvoa pikseleille, joissa esiintyy mustetta, ja täten asettamaan tämän ominaisuuden muiden edelle mahdollistaen tekstintunnistamisen. (Artificial Neural... s.a.; How Do Neural Networks... 2025; How Neural Network Models... 2022; Israelsen 2024; Kinza 2024; What is neural network? 2021.)

Aktivoinifunktion (engl. *activation function*) tehtävänä on tuoda epälineaarisuutta neuronin toimintaan ja määrittää, lähettääkö neuroni tietoa eteenpäin. Ilman kynnsarvoja neuronien tulot olisivat syötearvojen lineaarinen summa, jolloin epälineaariset riippuvaisuudet jäisivät verkon tarkastelun ulkopuolelle. Neuronin laskennallisen tuloksen ylittäessä neuronin aktivointifunktion raja-arvon lähettää neuroni prosessoidun datan edelleen seuraavan kerroksen neuroneiden käsiteltäväksi. (Artificial Neural... s.a.; How Do Neural Networks... 2025; How Neural Network Models... 2022; Israelsen 2024; Kinza 2024; What is neural network? 2021.)

Harhat (engl. *bias*) ovat yksittäisille neuroneille määritellyjä vakioita, joiden tehtävänä on tuoda joustavuutta verkon toimintaan. Harhat eivät ole sidoksissa syötteisiin, vaan ne lisätään neuronin laskelman tulokseen, mikä mahdollistaa neuronin kynnsarvon ylityksen ja täten datan eteenpäin lähetyksen, vaikka syöte itsessään ei olisi tätä mahdollistanut. Harhat luovat verkolle mah-

dollisuuden tarkastella ominaisuuksia, joilla ei ole täsmällisiä raja-arvoja. Esimerkiksi kuvan tunnistuksessa vinoumat mahdollistavat värien eri sävyjen tarkastelun. (Artificial Neural... s.a.; How Do Neural Networks... 2025; How Neural Network Models... 2022; Israelsen 2024; Kinza 2024; What is neural network? 2021.)

Neuroverkkojen tyypit

Neuroverkoilla on useita erilaisia toiminta- ja oppimusrakenteita, joita sovelletaan niiden parhaimman soveltuvuuden mukaisesti eri käyttökohteisiin.

Eteenpäin kytketty neuroverkko (engl. *Feedforward Neural Network, FNN*) on neuroverkko tyypeistä yksinkertaisin. Tässä tyypissä tieto kulkee verkossa yhteen suuntaan syötekerrokselta piilokerroksille ja niiden kautta tulokerrokselle. Tämän kaltaiset verkostot ovat tehokkaimpia tehtävissä, joissa jokainen syöte käsitellään erikseen. Näitä ovat esimerkiksi luokittelua ja regressiota käsittelevät tehtävät. Tämä neuroverkkotyyppi soveltuu erityisen hyvin valvotun oppimisen neuroverkkopohjaksi. (Lheureux 2025; Understanding Feedforward Neural... s.a.; What is neural network? 2021.)

Konvoluutioverkko (engl. *Convolutional Neural Network, CNN*) on erityisesti visuaalisen datan tarkasteluun soveltuva neuroverkko tyyppi, jota käytetään tyypillisesti paikkatiedon analysoinnissa sekä konenäkölaitteissa kuvan ja hahmon tunnistuksessa. Data kulkee pääasiallisesti tässä tyypissä **eteenpäin kytketyn neuroverkon** mukaisesti syötekerroksesta tulokerrokseen. Konvoluutioverkon oppimisprosessi käynnistyy kun syötekuvan ylitse liu'utetaan erikseen määritettyjen piirteiden tunnistamiseen suunniteltu suodatin. Tämän pohjalta muodostuu piirre kartta (engl. *feature map*), jossa korostuu määritettyjen piirteiden esiintyminen syötteessä. Seuraavat kerrokset käsittelevät tunnistettuja muotoja monimutkaisemmin ja tarkemmin jo käsitellyn datan pohjalta ja lopputuloksena muodostuu esimerkiksi kuvan luokittelupäätös sen piirteiden pohjalta. (Gillis ym. 2024a; What is a neural network? 2021.)

Toistuva neuroverkko (engl. *Recurrent Neural Networks, RNN*) käyttää datan analysoinnissa perinteisistä neuroverkoista poiketen hyödykseen muistia.

Tässä tyypissä neuronin muodostamaan tuloon vaikuttaa sen hetkisen syötteen lisäksi neuronin edelliset syötteet. (Stryker 2024; What is a neural network? 2021.)

Syväoppiminen

Syväoppiminen (engl. *Deep learning*) on koneoppimisen osajoukko, joka rakentuu monikerroksisista neuroverkoista. Syväoppimisen ja tavanomaisten neuroverkkojärjestelmien erona on näiden verkkojen syvyys. Tavallisten verkkojen koostuessa muutamista laskennallisista **piilokerroksista**, koostuvat syväoppimis pohjaiset neuroverkot puolestaan vähintään useammasta kuin kolmesta piilokerroksesta, mutta tyypillisesti nämä määrät nousevat sadoista jopa tuhansiin kerroksiin. Syväoppimisjärjestelmän toimintaperiaate pohjautuu neuroverkkojen perustoimintaperiaatteeseen ja on eroteltu omana osajoukkonansa neuroverkkojen syvyyden muodostamien ominaisuuksien sekä vaatimusten vuoksi. (Deep learning... s.a.; Holdsworth & Scapicchio 2024; What is Deep... s.a.; Yasar ym. 2024a.)

Syväoppimismallien pääpiirteenä on kyky havaita ja oppia suuresta määrästä raakaa dataa piirteitä ja käsitellä niitä hierarkkisesti ilman erillistä piirteiden etsimisen ohjausta. Lukuisat piilokerrokset havaitsevat tutkittavasta datasta piirteitä, joiden pohjalta ne muodostavat abstraktitasoja, jolloin verkko kykenee tasojen edetessä muodostamaan monimutkaisia malleja. Saatu tieto rikastuu alempien piilokerroksien havaitessa yksinkertaisia piirteitä sekä rakenteita, jotka ylemmät kerrokset punovat yhteen kokonaisuuksiksi. (Deep learning... s.a.; Holdsworth & Scapicchio 2024; What is Deep... s.a.; Yasar ym. 2024a.)

Syväoppimismallit tuovat mukanaan vaatimuksia niin käyttötehon kuin tarkasteltavan datan osilta. Mallit vaativat määrältään suurta ja laadultaan hyvää koulutusdataa mallin oppimiskyvyn tehostuessa yhdessä datan määrän kanssa. Tämän tiedon seulominen ja varastointi puolestaan vaativat merkittäviä laskennallisia resursseja, kuten tehokkaita grafiikkasuorittimia ja suuria määriä muistia, jotta mallien koulutus ja suoritus pysyvät optimaalisena. Tämän lisäksi syväoppimisen käyttöönotto edellyttää usein edistyksellisiä algorit-

misia ratkaisuja, kuten optimointimenetelmiä ja säätelytekniikoita, jotka ehkäisevät ylisovittamista. (Deep learning... s.a.; Holdsworth & Scapicchio 2024; What is Deep... s.a.; Yasar ym. 2024a.)

3 ENNAKOIVA KUNNOSSAPITO

Luvussa käsitellään ennakoivaa kunnossapitoa osana modernia teollisuutta. Luvun tavoitteena on selventää ennakoivan kunnossapidon käsitettä, menetelmien perustaa ja hyödynnettyjä teknologioita.

Teollisuus 4.0

Neljäs teollinen vallankumous (engl. *Industry 4.0*) kuvaa teollisuuden nykyistä ja edelleen kehittyvää vaihetta, jossa fyysiset, digitaaliset ja älykkäät järjestelmät yhdistyvät yhtenäisiksi verkostoiksi. Kehitysvaiheen keskeisin ajatus on tietokoneiden, teollisten laitteiden ja koneiden muodostamat älykkäät ja itseohjautuvat järjestelmät, jotka eivät vaadi ihmisten jatkuvaa valvontaa. (Zonta ym. 2020; Achouch ym. 2022.)

Teollisuus 4.0 ei rajoitu vaikutuksiltaan tuotantoteknologiaan, vaan on läsnä teollisuuden jokaisella osa-alueella (Zonta ym. 2020; Achouch ym. 2022).

Näitä osa-alueita ovat esimerkiksi:

- tuotanto
- kunnossapito ja laitehallinta
- tietoturva
- analytiikka ja tiedonhallinta
- logistiikka
- päätöksenteko ja johtaminen.

Ennakoiva kunnossapito on yksi konkreettisimpia Teollisuus 4.0:n käytännön ilmentymiä (Zonta ym. 2020; Achouch ym. 2022). Tämä kunnossapitostrategia yhdistää digitalisaation sekä älykkäät järjestelmät reaaliaikaiseen ja datalähtöiseen päätöksentekoon.

3.1 Ennakoivan kunnossapidon määritelmä

Ennakoiva kunnossapito on datalähtöinen kunnossapitomenetelmä, jonka tavoitteena on ennustaa ja täten ehkäistä laitevialt ennen niiden ilmenemistä. Se perustuu jatkuvaan datan keräämiseen ja analysointiin, jonka avulla tunnistetaan poikkeavuuksia, havaitaan alkavia vikaantumisia ja arvioidaan laitteiden jäljellä olevaa käyttöikää. (What is predic... 2023; What is predic... s.a.)

Ennakoiva kunnossapito eroaa perinteisistä kunnossapitomalleista, kuten aikataulutetusta ehkäisevästä kunnossapidosta (engl. *Preventive Maintenance*) ja vian ilmenemisen jälkeen suoritettavasta korjaavasta kunnossapidosta (engl. *Corrective Maintenance*), sen perustuessa data-analytiikan avulla määritettyyn todelliseen huoltotarpeen tunnistamiseen. Tämä mahdollistaa huolto- toimenpiteiden kohdistamisen tarkasti oikeaan aikaan ja paikkaan, vähentäen laiterikoista ja huolloista aiheutuvia käyttökatkoja. (What is predic... 2023; What is predic... s.a.)

Ennakoiva kunnossapito yhdistää reaaliaikaisen kunnonvalvonnan, analytiikan, kohdennetut huoltotoimet ja älykkäät ratkaisut laitteiden optimaalisen suorituskyvyn ja kustannustehokkuuden takaamiseksi. (What is predic... 2023; What is predic... s.a.)

3.2 Keskeiset teknologiat

Ennakoivassa kunnossapidossa hyödynnetyt teknologiat koostuvat datan keräämiseen ja sen analysointiin soveltuvista älykkäistä laitteistoista ja järjestelmistä. Näihin kuuluvat:

IoT järjestelmät (engl. *Internet of Things*) koostuvat keskenään verkotetuista laitteista ja antureista, jotka mahdollistavat datan keräämisen, siirtämisen ja käsittelyn. IoT-järjestelmät toimivat tiedonkeruun ja päätöksenteon perustana mahdollistaen datan hyödyntämisen ennakoivassa kunnossapidossa. (What is predic... 2023; What is predic... s.a.; Ran ym. 2019; Ucar ym. 2024.)

Pilvipohjaiset järjestelmät tarjoavat alustan, jossa kerätty data voidaan tallentaa, käsitellä ja analysoida keskitetysti. Ne mahdollistavat suurten tietomäärien reaaliaikaisen hallinnan ja jakamisen eri järjestelmien sekä käyttäjien välillä. (What is predic... s.a.; Ucar ym. 2024.)

Data-analytiikka ja massadata (engl. *Big data*) muodostavat kokonaisuuden, jossa suuria ja monimuotoisia tietomääriä kerätään, käsitellään ja analysoidaan päätöksenteon tueksi. Näitä menetelmiä hyödyntäen tunnistetaan datasta piileviä yhteyksiä, trendejä ja poikkeamia, joita ei olisi mahdollista havaita perinteisin menetelmin. (What is predic... s.a.; Ran ym. 2019; Ucar ym. 2024.)

Digitaaliset kaksoset (engl. *Digital Twin*) ovat fyysisiä laitteita tai prosesseja vastaavia virtuaalisia malleja, joilla simuloidaan järjestelmän toimintaa. Digitaaliset kaksoset mahdollistavat kohteena olevien laitteiden tilan ja suorituskyvyn tarkastelun ilman fyysiseen laitteeseen kohdistuvaa vuorovaikutusta. Tämä mahdollistaa vikojen, huoltotoimenpiteiden ja testien simuloimisen sekä niiden vaikutusten arvioinnin fyysisen laitteen toiminnassa. (What is predic... s.a.; Ran ym. 2019; Ucar ym. 2024.)

3.3 Tekoäly ja koneoppiminen ennakoivassa kunnossapidossa

Tekoäly ja koneoppiminen muodostavat keskeisen osan ennakoivan kunnossapidon kehitystä. Nämä teknologiat tarjoavat ratkaisun perinteisten menetelmien rajoituksiin ja kykenevät tuottamaan älykkäitä, itseoppivia järjestelmiä, jotka tukevat päätöksentekoa ja kunnossapidon optimointia (Achouch ym. 2022). Tekoäly ja koneoppiminen mahdollistavat moniulotteisen datan käsittelyn sekä perinteisiltä analytiikan keinoilta piiloon jäävien riippuvuuksien tunnistamisen.

Tekoälyllä on ennakoivan kunnossapidon keskeisistä teknologioista vahvin yhteys massadataan (Achouch ym. 2022). Ennakoivan kunnossapidon perustessa suuren tietomäärän analysointiin ja tämä analyysin hyödyntämiseen prosessin ongelmakohtien tunnistamisessa, on tekoälyn rooli data-analyysissa merkittävä.

Koneoppimisen neljä päämenetelmää valvottu, valvoton, puolivalvottu ja vahvistava oppiminen ovat kaikki hyödynnettävissä ennakoivan kunnossapidon älykkäissä järjestelmissä. Menetelmien soveltuvuus erilaisiin kunnossapidon tarpeisiin määritetään muun muassa datan rakenteen ja käyttötarkoituksen mukaisesti. Syväoppimisen neuroverkkoihin perustuvat mallit puolestaan täydentävät näitä menetelmiä tapauksissa, joissa perinteiset mallit eivät kykene havaitsemaan datassa esiintyviä monimutkaisia, epälineaarisia piirteitä tai muita perinteisten menetelmien havaitsemiskyvyn ulkopuolelle jääviä rakenteellisia riippuvuuksia. (Achouch ym. 2022.)

Tekoälyn ja koneoppimisen yhdistäminen kunnossapitojärjestelmiin tuo mukanaan entistä älykkäämmät, mukautuvammat ja autonomisemmat ratkaisut, jotka eivät ainoastaan reagoi vikoihin, vaan oppivat niistä ja kehittävät jatkuvasti kykyään arvioida laitteiden kuntoa. Tekoälyn ja koneoppimisen roolit eivät rajoitu datan analysointiin, vaan ne tulevat olemaan yhä laajemmin osana päätöksentekoa ja päätösten toimeenpanoa.

4 OPINNÄYTETYÖN TOTEUTUS

Työn tutkimus toteutetaan kuvailevana kirjallisuuskatsauksena, jonka tarkoituksena on koota ja analysoida olemassa olevaa tutkimustietoa älykkään ennakoivan kunnossapidon menetelmistä. Kirjallisuuskatsauksen avulla pyritään tunnistamaan mitä mittauksia ja mittausmenetelmiä näissä menetelmissä hyödynnetään kunnonvalvonnan näkökulmasta.

Kuvaileva kirjallisuuskatsaus on kirjallisuuskatsauksen yleinen perustyyppi, jonka tavoitteena on muodostaa kokonaiskuva tutkittavasta aiheesta ilman tarkkoja menetelmällisiä rajoituksia. Katsauksessa hyödynnetään monipuolisia lähteitä, ja aineiston valinta perustuu tutkijan harkintaan aiheen kannalta olennaisesta tiedosta. (Salminen 2011.)

Aineiston kerääminen

Aineisto on kerätty pääasiassa verkossa saatavilla olevista lähteistä hyödynnäen Google Scholar:ia ja Kaakkuri-tietokantaa. Tiedonhaku tapahtui pääasiassa yhdistämällä hakusanoja *predictive maintenance*, *condition monitoring*,

ja A/ tutkittavan laitteen nimen kanssa. Englannin käyttäminen tiedonhaussa osoittautui tehokkaimmaksi kieleksi työn aiheeseen liittyvien suomenkielisten akateemisten tutkimusten vähäisyyden ja tekijän muun kielitaidon puutteellisuuden vuoksi.

Työssä käytettävälle aineistolle määritettiin alustavat kriteerit joiden perusteella valittiin tutkimuksessa hyödynnetyt lähteet. Kriteereihin sisältyivät aineiston julkaisuajankohta, maksuttomuus, relevanssi ja aineiston laji (taulukko 1). Kriteerit perustuivat tekijän arvioon aineiston luotettavuudesta, ajankohtaisuudesta ja merkityksellisyydestä työn tavoitteen kannalta.

Taulukko 1. Alustavat kriteerit aineistolle

Kriteerit
Aineiston julkaisuvuosi alkaen 2020
Maksuton materiaali
Tutkimusaihetta käsittelevät materiaalit
Vertaisarvioidut akateemiset julkaisut

Taulukossa 2 esitellään kuusitoista kriteerit täyttävää ja opinnäytetyön tutkimuksessa hyödynnettävää tutkimusta. Taulukossa esitetään kunkin lähteen laji, lähdeviite, sovelluskohde ja sisältö. Näiden lisäksi taulukkoon on merkitty kyllä/ei- periaatteen mukaisesti aineistojen julkaisuajankohta, maksuttomuus sekä tieto siitä, onko aineisto vertaisarvioitu.

Taulukko 2. Kriteerit täyttävät materiaalit

Lähteen laji	Lähde	Tutkimusaihetta käsittelevät materiaalit		Vertaisarvioitu	Alkaen 2020	Maksuton
		Lähteen soveltuvuus	Lähteen sisältö			
Akateeminen tutkimusartikkeli	(Hafini ym. 2025)	Sähkömoottorit	Koneoppimispohjaisen ennakoivan kunnossapidon hyödyt sähkömoottoreissa, keskittyen tärinään	Kyllä	Kyllä	Kyllä
Akateeminen tutkimusartikkeli	(Hallaji ym. 2022)	Pumput	Katsaus pumppujen ennakoivan kunnossapidon nykytilanteeseen ja tuleviin suuntauksiin	Kyllä	Kyllä	Kyllä
Akateeminen tutkimusartikkeli	(Hassan ym. 2025)	Yleisesti datan hyödyntämisestä ennakoivassa kunnossapidossa	Katsaus datan hyödyntämismenetelmiin ennakoivassa kunnossapidossa	Kyllä	Kyllä	Kyllä
Akateeminen tutkimusartikkeli	(Jeon ym. 2022)	Hydrauliikkakoneikko	Tutkimus hydrauliikkaöljyn kunnonvalvonnan menetelmien todenmukaisuudesta	Kyllä	Kyllä	Kyllä
Akateeminen tutkimusartikkeli	(Kumar 2025)	Kompressorit	Kirjallisuuskatsaus tulevaisuuden näkyisiin kompressorien kunnonvalvonnassa	Kyllä	Kyllä	Kyllä
Akateeminen tutkimusartikkeli	(Laghari & Mekid 2023)	Akustinen emissio	IoT-pohjainen koneistusprosessin kunnonvalvonta	Kyllä	Kyllä	Kyllä
Akateeminen tutkimusartikkeli	(Lakal ym. 2022)	Pumput	Vaativissa olosuhteissa hyödynnetyt pumppujen kunnonvalvonnan anturitekniikat	Kyllä	Kyllä	Kyllä
Akateeminen tutkimusartikkeli	(Manjare & Patil 2025)	Sähkömoottorit	Kunnonvalvonnan menetelmät osana koneoppimispohjaisissa ennakoivan kunnossapidon menetelmiä, koskien sähkömoottoreita	Kyllä	Kyllä	Kyllä
Akateeminen tutkimusartikkeli	(Mohammed ym. 2023)	Sähkömoottorit	Koneoppimispohjaisen ennakoivan kunnossapidon järjestelmän muodostaminen sähkömoottoreille	Kyllä	Kyllä	Kyllä
Akateeminen tutkimusartikkeli	(Nambiar ym. 2025)	Kompressorit	Koneoppimisen ja anturidata fuusion yhdistäminen kompressoreiden kunnonvalvontaan	Kyllä	Kyllä	Kyllä
Akateeminen tutkimusartikkeli	(Nikfar ym. 2022)	Sähkömoottorit	Koneoppimismallien vertailua ennakoivan kunnossapidon järjestelmissä, koskien sähkömoottoreita	Kyllä	Kyllä	Kyllä
Akateeminen tutkimusartikkeli	(Omozuhiomwen ym. 2025)	Kompressorit	Katsaus kompressoreiden luotettavuuskeskeiseen kunnossapitoon	Kyllä	Kyllä	Kyllä
Akateeminen tutkimusartikkeli	(Raikar ym. 2025)	Sähkömoottorit	IoT-valvontalaitteistoa hyödyntävän koneoppimispohjaisen ennakoivan huollon järjestelmän kehittäminen sähkömoottoreille	Kyllä	Kyllä	Kyllä
Akateeminen tutkimusartikkeli	(Tolbert 2025)	Taajuusmuuttajat	Nykykaisten taajuusmuuttajien hyödyntäminen osana ennakoivaa kunnossapittoa	Kyllä	Kyllä	Kyllä
Akateeminen tutkimusartikkeli	(Zhang ym. 2023)	Venttiilit	Katsaus maakaasuverkoston venttiilien älykkääseen kunnossapitoon	Kyllä	Kyllä	Kyllä
Akateeminen tutkimusartikkeli	(Zhengjie ym. 2023)	Venttiilit	Syväoppimismenetelmien hyödyntäminen laivojen putkistojen venttiilien vuotojen havaitsemisessa	Kyllä	Kyllä	Kyllä

Kriteerien ulkopuolelle jääneitä materiaaleja valittiin neljä (taulukko 3). Nämä materiaalit valittiin työn edetessä tukemaan tutkimustyössä esiintyvien ongelmakohtien ratkaisuja ja täydentämään kriteerit täyttäviä aineistoja.

Taulukossa 3 esitellään neljä kriteerit täyttämätöntä, mutta opinnäytetyön tutkimuksessa hyödynnettävää tutkimusta. Taulukossa esitetään kunkin lähteen laji, lähdeviite, sovelluskohde ja sisältö. Näiden lisäksi taulukkoon on merkitty kyllä/ei- periaatteen mukaisesti aineistojen julkaisuajankohta, maksuttomuus sekä tieto siitä, onko aineisto vertaisarvioitu. Taulukon ”s.a.” merkintä viittaa aineiston julkaisuajankohdan puutteeseen.

Taulukko 3. Kriteerit täyttämättömät materiaalit

Lähteen laji	Lähde	Tutkimusaihetta käsittelevät materiaalit		Vertaisarvioitu	Alkaen 2020	Maksuton
		Lähteen soveltuvuus	Lähteen sisältö			
Blogi	(Shawn 2019)	Sähkömoottorit	Tukea (Raikar ym. 2025) tutkimuksen todenmukaisuuden arviointiin	Ei	Ei	Kyllä
Akateeminen tutkimusartikkeli	(Brouwer ym. 2012)	Hydrauliikkakoneikko	Hydrauliöljyn kunnonvalvonnan menetelmiä	Kyllä	Ei	Kyllä
Yrityksen tiedotusmateriaali	(Introduction to Hydraulic... s.a.)	Hydrauliikkakoneikko	Hydrauliikkakoneikkojen yleisten laitteiden esittely	Ei	s.a.	Kyllä
Kirja	(Mauntz ym. 2013)	Hydrauliikkakoneikko	Öljyn kunnan etävalvonnan järjestelmä	Kyllä	Ei	Kyllä

Shawn (2019) blogi otettiin huomioon tukemaan tekijän havaintoa Raikar ym. (2025) tutkimuksessa esiintyvistä mahdollisista virheistä, joka käsitellään sähkömoottoreiden jännitettä käsittelevässä osiossa.

Hydrauliikkakoneikkoja käsittelevässä osiossa hyödynnettiin Mauntzin ym. (2013) kirjaa ja Brouwerin ym. (2012) tutkimusartikkelia hydrauliikkaöljyn kunnonvalvontaa koskeavissa osioissa. Molemmat lähteet olivat saaneet maininnan kriteerit täyttävässä Jeonin ym. (2022) tutkimusartikkelissa, minkä vuoksi ne todettiin työssä hyödynnettäviksi luotettaviksi aineistoiksi.

Introduction to Hydraulic... (s.a.) valittiin täydentämään tekijän ymmärrystä hydrauliikkakoneikkojen yleisistä laitekoostumuksista. Lähde todettiin luotettavaksi yrityksen toimiessa hydrauliikkakoneikkojen toimittajana.

Opinnäytetyössä hyödynnettiin kokonaisuudessaan kahtakymmentä aineistoa, jotka todettiin työn kannalta merkittäviksi ja luotettaviksi.

Kerätyn aineiston analysointi

Kerättyjä aineistoja analysoitiin laadullisella sisällönanalyysillä. Analyysimenetelmän avulla jäsenneltiin tutkimusaineistojen sisältöä ja yksinkertaistettiin laajoja kokonaisuuksia yhteisten ominaisuuksien mukaisesti.

Laadullisessa sisällönanalyysissä pyritään ymmärtämään ja tulkitsemaan aineiston sisältöä. Tutkittava aineisto koodataan, luokitellaan ja tulkitaan, jotta voidaan havaita sen keskeisiä rakenteita ja ilmiöitä. (Vuori 2021.)

Tutkimustyössä keskityttiin luokittelemaan aineistojen sisältöä tavalla, joka tulisi vastaamaan tutkimuskysymyksiin. Aineistojen sisällön koodauksessa luokiteltiin niiden sisältöä kolmeen pääosaan: mitä, miksi ja miten ominaisuutta on mitattu laitteesta. Luokittelussa esiin nousseet aiheet ja teemat mahdollistivat vertailun tutkimusmateriaalista nousseiden tietojen sisällön soveltuvuudesta työn kohdelaitteistoon. Näiden tarkemman analyysin, tulkinnan ja johtopäätösten jälkeen suoritettiin raportointi opinnäytetyöhön.

Kohdelaitteiston luokittelu

Tutkimuksen laajuuden hallitsemiseksi ja selkeyttämiseksi on rakenteeltaan ja toimintaperiaatteeltaan samankaltaiset laitteet koottu yhteisten pääluokkien alle. Näiden luokkien kautta laitteita on tarkasteltu niille yhtenäisin perustein.

Biokaasureaktorin ohjaukseen kytketyt laitteistot on sisältöineen jaettu seuraaviin luokkiin:

- **mittalaitteet:** virtausmittarit, painelähettimet, pistetasoanturit, valokenoanturit, pinnantasoanturit, lämpötila-anturit ja induktiiviset anturit
- **sähkömoottorit:** kolmivaihe- ja yksivaihemoottorit
- **kompressorit:** paineilmakompressorit
- **pumput:** mäntä-, keskipako-, silppuri- ja hydrauliiikkapumput
- **venttiilit:** hydraulisesti ohjatut venttiilit, pneumaattisesti ohjatut venttiilit, solenoidiventtiilit, manuaaliset venttiilit
- **hydrauliikkajärjestelmä:** öljynlauhduttimet ja hydrauliikkakoneikko.
- **taajuusmuuttajat:** taajuusmuuttajat.

Tästä lähestymistavasta johtuen tutkimuksen tulokset ovat sovellettavissa kaikkiin pääluokan alaisiin laitteisiin, mutta yksittäisten laitteiden erityispiirteitä ja laitekohtaisia teknisiä eroja ei tarkastella. Työn tavoitteena on muodostaa yleispätevä kokonaiskuva määritetyistä laiteluokista.

Huomioita esitetyistä mittausjärjestelmistä

Työssä esitetyt tulokset **mittausjärjestelmien** osalta ovat suuntaa antavia ehdotuksia, jotka perustuvat analysoituihin tutkimuslähteisiin.

Esitetyt mittausjärjestelmät muodostavat usein laajoja kokonaisuuksia, jotka kattavat useita eri datatyyppisiä ja mittausperiaatteita. Työn tarkoituksena on kuvata, millaisia laitteistoja ja mittausmenetelmiä voidaan hyödyntää prosessidatan keräämisessä tekoälypohjaista ennakoivaa kunnossapitoa varten. Esitetyt anturit, mittarit ja muut mittauslaitteet on kuitenkin ymmärrettävä esimerkinomaisina ratkaisuna niiden teknisten ominaisuuksien, rakenteiden ja toiminta-periaatteiden vaihdellessa laitteiden valmistajien välillä.

Tästä syystä työssä kuvatut mittausjärjestelmät tulee nähdä lähtökohtina, joiden pohjalta voidaan arvioida ja valita kuhunkin järjestelmään parhaiten soveltuvat laitteet ja mittausratkaisut.

Huomioita laitteiden välisistä sidonnaisuuksista

Työssä käsitellään toisiinsa toiminnallisesti sidoksissa olevia laitekokonaisuuksia. Mikäli yksittäisen laitteen kunnossapidollisen tilan arviointi edellyttää toisen siihen liittyvän laitteen kunnan huomioimista, on tämä otettu huomioon kyseisen laitteen käsittelyssä.

5 TUTKIMUKSEN TULOKSET

Opinnäytetyön tutkimustulokset on jaettu **mittausaineistoihin ja mittausjärjestelmiin**, joiden kautta vastataan työssä esitettyihin tutkimuskysymyksiin. Tulokset on jäsennetty laitteistolle määritetyn laiteluokittelun sekä tutkimuksen suorittamisjärjestyksen mukaisesti. Tuloksissa tarkastellaan mittausaineistoa

ja sen merkitystä, minkä jälkeen esitetään siihen perustuva ehdotus mittausjärjestelmästä.

5.1 Yleistä kaikille laitteille

Kaikille tutkimuksen kohteena oleville laitteille yhteiset mittausaineistot ovat **historiatieto** ja **prosessidata**.

Kunnonvalvonnan kautta kerätty data mahdollistaa koneoppimismallien oppimisen järjestelmän käyttäytymisestä, jolloin järjestelmä kykenee tunnistamaan trendejä, havaitsemaan poikkeamia ja ennustamaan laitteiden jäljellä olevaa käyttöikää (Hassan ym. 2025).

Historiatieto viittaa laitteista kerättyyn prosessidataan ajalta ennen tekoälyn käyttöönottoa datan analysoinnissa. Historiatietojen avulla voidaan tehostaa koneoppimismallien kouluttamista takautuvasti, hyödyntäen aiempaa tallennettua tietoa.

Prosessidata viittaa ohjausjärjestelmään kytkettyjen laitteiden prosessin aikaisiin tietoihin. Näihin sisältyvät esimerkiksi laitteiden käyntijaksot, pysäytykset, huoltotauot sekä muut vastaavat käyttötilanteet.

Koska näihin käsitteisiin sisältyy lukematon määrä erilaisia laitteiden prosessia kuvaavia tilatietoja, ei niiden yksityiskohtainen erittely ole tämän työn kannalta tarkoituksenmukaista.

Taulukko 4. Yleisesti kaikista laitteista seurattava mittausaineisto ja mittausjärjestelmä

Mittausaineisto	Mittausjärjestelmä
Historiatiedot	Automaation ohjausjärjestelmä
Prosessidata	Automaation ohjausjärjestelmä

Taulukossa 4 esitetään tutkimuksen pohjalta kaikkiin tutkimuskohteisiin pätevät mittausaineistot ja mittausjärjestelmät.

5.2 Mittalaitteet

Tutkimusaineiston keräämisen yhteydessä ilmeni mittalaitteiden kunnonvalvontaa koskettavien tutkimusmateriaalien puute. Älykäs kunnonvalvonta ilman mittalaitteita on lähes mahdotonta, sillä ne tuottavat monipuolista ja reaaliaikaista analysoitavaa dataa kunnossapidon kohteesta.

Mittalaitteet toimivat mittareina suuremmille kokonaisuuksille, ne ovat kestäviä, helposti korvattavissa ja poikkeuksia lukuun ottamatta mittaavat yksittäisiä suureita. Johtopäätöksenä työssä tutkitun materiaalin pohjalta sekä mittalaitteiden suhteellisen yksinkertaisten toimintaperiaatteiden ja teknisten ominaisuuksien vuoksi voidaan todeta, ettei mittalaitteiden kunnonvalvontaa ole nähty tarpeellisena niiden luonteen vuoksi. Tämän pohjalta mittalaitteille suositellaan seurattaviksi ominaisuuksiksi kaikille laitteille yhteisiä mittaustietoja, **historiatietoja ja prosessidataa**.

5.3 Sähkömoottorit

Sähkömoottoreiden ennakoivan kunnossapidon tutkimukset käsittivät lähtökohtaisesti kaikki samoja mitattavia ominaisuuksia. Moottoreita koskettavista tutkimuksista valittiin kuusi eri tutkimusta, joiden tulokset ovat sovellettavissa tutkimuksen rajausten mukaisesti. Jännite ja ilmankosteus olivat molemmat osana hyvin vähäistä määrää tutkimusaineistoa. Nämä kaksi muuttujaa otettiin kuitenkin tutkimuksessa huomioon jännitteen ja virran käyttäytyessä toisiinsa nähden yhtenevästi ja virran merkityksen noustessa tutkimuksissa erittäin korkealle. Ilmankosteus otettiin huomioon tutkimuskohteen moottoreiden sijaintien vuoksi. Moottorit otettiin tutkimuksessa käsittelyyn ensimmäisenä, useiden muiden toimilaitteiden, kuten pumppujen, kompressoreiden ja hydraulikkakoneikkojen sisältäessä sähkömoottoreita.

Tutkimus aloitettiin Manjaren ja Patilin (2021) katsauksen A Review: Condition-Based Techniques and Predictive Maintenance for Motor pohjalta. Katsaus käsittelee moottoreiden ennakoivan kunnossapidon menetelmiä sekä perinteisten analyysien että koneoppimista hyödyntävien analyysien näkökulmasta.

Taulukossa 5 esitetään tutkimuksen pohjalta sähkömoottoreihin pätevät mittausaineistot ja mittausjärjestelmät.

Taulukko 5. Sähkömoottoreista seurattava mittausaineisto ja mittausjärjestelmä

Mittausaineisto	Mittausjärjestelmä
Historiatiedot	Automaation ohjausjärjestelmä
Prosessidata	Automaation ohjausjärjestelmä
Virta	Sähkövirtamittari/Taajuusmuuttaja
Jännite	Jännitemittari/Taajuusmuuttaja
Tärinä	Kiihtyvyyssanturi/ gyroskoopianturi/ värähtelyanturi
Moottorin lämpötila	Lämpökamera/Taajuusmuuttaja
Ilman lämpötila	Lämpötila-anturi+lähetin
Ilmankosteus	Ilmankosteusanturi+lähetin
Taajuusmuuttaja	Kts. Taajuusmuuttaja

Sähkövirta on keskeinen mitattava suure sähkömoottoreiden kunnan arvioinnissa ja ennakoivassa kunnossapidossa (Manjare & Patil 2021). Virran poikkeamat moottorin nimellisarvoista voivat paljastaa niin mekaanisia kuin sähköisiä ongelmia ja ovat usein kytköksissä muihin esiintyviin ongelmiin, kuten lämpötilan nousuun.

Tutkimuksissa sähkövirtaa on mitattu ACS712-anturin avulla. Tämä anturi on liitetty tiedonkeruualustaan, mikä mahdollistaa reaaliaikaisen datan keruun ja siirron analysoitavaksi. Saatuja tuloksia on analysoitu eri koneoppimismalleilla ja niiden merkityksellisyyttä ja onnistuneisuutta on arvioitu, niin koneoppimisen, kuin ennakoivan kunnossapidon kannalta yhdessä muiden tutkimuksessa tutkittavien suureiden kanssa. (Mohammed ym. 2023; Raikar ym. 2025.)

Sähkövirran seuranta mahdollistaa monipuolisen ja luotettavan keinon arvioida moottoreiden kunnossapidollista tilaa. Virran seuraaminen auttaa havaitsemaan viat jo varhaisessa vaiheessa ja tukee tekoälypohjaisia ennustavia kunnossapitoratkaisuja. (Mohammed ym. 2023; Raikar ym. 2025; Manjare & Patil 2021.)

Jännitteen seuranta on osa sähkömoottoreiden kunnan arviointia, sillä moottorin suorituskyky perustuu oikeanlaiseen ja vakaaseen sähkönsyöttöön. Äkilliset jännitteen laskut tai nousut voivat johtaa moottorin toimintahäiriöihin tai ilmaista ongelmia virtalähteessä tai moottorissa.

Tutkimuksessa jännitettä mitattiin virtaa ja jännitettä rekisteröivällä anturilla, joka oli kytketty tiedonkeruualustaan. Kerätyn datan pohjalta analysoitiin jännitteen ja virran suhdetta, joka ilmaisi moottorin toimivan oikein virran ja jännitteen ollessa verrannollisia Ohmin lain mukaisesti. (Raikar ym. 2025.)

Tämä jännitteen ja virran suhdetta koskettava tutkimustulos on virheellinen tutkimuksessa käytetyn anturin ACS712 ollessa kykenemätön esittämään kuormapiirin jännitetasoa. Anturin toimintaperiaate virran mittaamiseen on ”epäsuora”. Anturissa sijaitseva Hallin ilmiötä mittaava anturi tuottaa virran muodostamaa magneettikenttää vastaavan verrannollisen jännitteen, jonka pohjalta mitataan vastaava virran suuruus. (Shawn 2019.) Tästä johtuen tutkimuksessa saatava virran ja jännitteen verrannollisuus ovat jokaisessa tilanteessa täydelliset toisiinsa nähden ja täten epätodenmukaiset.

Virheellisistä tutkimustuloksista huolimatta on tämä tutkimus otettu työssä huomioon jännitteen mittaamisen osalta, johtuen todellisen jännitteen ja virran verrannollisuuden merkityksestä ennakoivassa kunnossapidossa. Jännitteen mittaaminen ei ilmennyt useimmissa moottoreiden ennakoivaa kunnossapitoa koskeavissa tutkimustuloksissa virran ollessa näistä kahdesta suuremmassa huomiossa. Mikäli sähkön ominaisuuksia mittaavat mittalaitteet menisivät epäkuuntoon, on edullista seurata moottoreissa kulkevan virran lisäksi myös jännitettä, jotta sähkön kokonaisvaltainen vaikutus ja käyttäytyminen saadaan selville. Tämän pohjalta suositeltavaa on mitata näitä molempia ominaisuuksia.

Tärinän tutkiminen sekä analysointi osana moottoreiden ennakoivaa kunnossapitoa on osoittautunut merkittäväksi tekijäksi moottoreiden kunnan ilmaisemisessa. Mekaanisen värähtelyn muutokset ilmaisevat tehokkaasti moottorin rasituksesta tai muista vaikuttavista tekijöistä johtuvaa kulumista tai muuta moottorin epänormaalia toimintaa. (Mohammed ym. 2023; Nikfar ym. 2022; Hafini ym. 2025; Manjare & Patil 2021.)

Tutkimuksissa on hyödynnetty useita sensoritekniikoita. Tärinää on seurattu matalan ja korkean tarkkuuden kiihtyvyyssantureilla, gyroskooppiantureilla ja värähtelyantureilla. Näiden avulla on mahdollista erotella tavanomaisen toiminnan aiheuttamat hetkelliset värähtely/tärinä piikit esimerkiksi ulkoisten kuormitusten aikana, jolloin erotetaan varsinaiset moottorin kuntoon liittyvät poikkeamat ympäristön vaikutuksista. Tärinän ilmetessä mahdollisesti niin aksiaalisessa, radiaalisessa kuin vääntösuuntaisessa liikkeessä, on mittauksia kerättävä kattavasti kaikilta suunnilta, jotta moottorin todellinen kunto on mahdollista arvioida. (Mohammed ym. 2023; Nikfar ym. 2022; Hafini ym. 2025; Manjare & Patil 2021.)

Tärinän analysoinnissa keskeisintä on erottaa normaalin toiminnan aikaiset vaihtelut huollollista tarvetta ennakoivista muutoksista. Esimerkiksi taajuusanalyysi mahdollistaa vikojen varhaisen tunnistamisen, moottorin rakenteellisten muutosten vaikuttaessa värähtelysignaalien piirteisiin. Lisäksi historiallisten tärinädatapisteiden pohjalta voidaan kouluttaa ennustavia malleja, jotka kykenevät arvioimaan moottorin tulevaa käyttäytymistä ja huollon tarvetta. (Mohammed ym. 2023; Nikfar ym. 2022; Hafini ym. 2025; Manjare & Patil 2021.)

Lämpötilan nousu moottorissa tai sen toimintaympäristön voi johtaa ylikuumenemiseen, joka heikentää moottorin hyötysuhdetta ja lisää vikaantumisriskiä. Pitkäaikainen toiminta kohonneissa lämpötiloissa voi nopeuttaa eristeiden vanhenemista, aiheuttaa laakerivaurioita ja pahimmillaan johtaa moottorin käyttökatkokseen.

Tutkimuksissa lämpötilaa seurattiin useilla antureilla. Moottorin pintalämpötilan mittaamisessa hyödynnettiin infrapunälämpömittaria, joka mahdollisti laajan mittausalueen, korkean tarkkuuden sekä kosketuksettoman mittaamisen. Ympäristön lämpötilaa puolestaan seurattiin digitaalisilla lämpötila/kosteusanturilla, jotka mahdollistivat moottorin käyttöolosuhteiden kokonaisvaltaisen arvioinnin. (Mohammed ym. 2023; Nikfar ym. 2022; Raikar ym. 2025.)

Lämpötiladatan analysoinnissa hyödynnettiin tilastollisia menetelmiä, joiden tulosten pohjalta rakennettiin raja-arvoihin perustuvia hälytys- ja pysäytyskyn-

nyksiä. Vaikka kaikki lämpötilamuutokset eivät suoraan ilmaise moottorin vikaa, niiden säännöllinen seuranta tarjoaa varhaisia varoituksia epänormaaleista olosuhteista. (Mohammed ym. 2023; Nikfar ym. 2022; Raikar ym. 2025.)

Ilmankosteuden merkitys nousi esille vain muutamissa tutkimuksissa. Oletuksena tälle on teollisten moottoreiden käytön keskittyminen hallittuihin ympäristöihin, kuten ilmastoituihin halleihin tai muihin vastaaviin työpisteisiin. Muuttuja on otettu työssä huomioon biokaasureaktorin moottoreiden sijaitessa yhteydessä ulkoilmaan. Tämänkaltainen hallitsematon ympäristö altistaa moottorit kosteudesta aiheutuville haitoille, kuten korroosiolle ja sähkövioille.

Tutkimuksessa ilmankosteutta on mitattu digitaalisella lämpötila/kosteusanturilla. Tutkimuksessa ilmankosteus pysyi tasapainoisena, joten sen vaikutusta moottoriin yhdessä tutkimuksen muiden muuttujien kanssa ei pystytty ilmaisemaan tarkasti. Tästä huolimatta ilmankosteus todettiin merkittäväksi tekijäksi moottorin ennakoivassa kunnossapidossa. (Raikar ym. 2025.)

5.4 Kompressorit

Vapaasti luettavissa olevia kompressoreita koskettavia tutkimuksia oli saatavilla rajallisesti. Tutkimuksista valittiin kolme eri tutkimusta, joiden tulokset ovat sovellettavissa tutkimuksen rajausten mukaisesti.

Taulukossa 6 esitetään tutkimuksen pohjalta kompressoreihin pätevät mittausaineistot ja mittausjärjestelmät.

Taulukko 6. Kompressoreista seurattava mittausaineisto ja mittausjärjestelmä

Mittausaineisto	Mittausjärjestelmä
Historiatiedot	Automaation ohjausjärjestelmä
Prosessidata	Automaation ohjausjärjestelmä
Tärinä	Kiihtyvyyssanturi ja läheisyysanturi
Kompressorin lämpötila	Lämpökamera
Ilman lämpötila	Lämpötila-anturi + lähetin
Akustinen emissio	AE-anturi
Öljy	Öljynlaatuanturi
Paine	Painelähetin
Virtaus	Virtauslähetin
Sähkömoottori	Kts. Sähkömoottori

Tärinän seuranta on vakiintunut ja laajasti käytetty menetelmä kompressorien kunnonvalvonnassa. Mittaukset tehdään tyypillisesti kiihtyvyyss- tai läheisyysantureilla ja tulosten analysointi perustuu käyttötilanteessa syntyvän tärinän taajuusspektriin. Tärinän seuraaminen soveltuu erityisesti pyörivien osien, kuten roottorien, akselien ja laakereiden vianmääritykseen. Tärinän seurantaan ja analysointiin pohjautuvat kunnossapitomenetelmät ovat tehokkaita, sillä reaaliaikaiset mittaukset havaitsevat mekaaniset poikkeamat hyvin tarkasti. (Kumar 2025; Nambiar ym. 2024.)

Useiden tutkimusten mukaan tärinän seuraamisella ja analysoimisella yhdessä muiden muuttujien ja koneoppimismallien kanssa on eri tutkimuskohdeissa saavutettu lähtökohtaisesti 90–100 % osumatarkkuuksia kytevien vikojen havaitsemisessa (Nambiar ym. 2024).

Kompressorien kunnossapidon kustannustehokkuuden parantamiseksi Omozuhomwen ym. (2025) tarkastelevat työssään luotettavuuskeskeisen kunnossapidon soveltamista integroimalla sen sisäisiä menetelmiä keskenään. Tutkimuksen tuloksissa suositellaan tärinän seuraamista ennakoivan kunnossapidon kautta muun muassa tärinästä aiheutuvien ongelmien (mm. antureiden kosketushäiriöt) ja tärinää aiheuttavien ongelmien (mm. öljyn puute) havaitsemisessa.

Lämpötilan noususta aiheutuva ylikuumeneminen kertoo tyypillisesti kompressorissa ilmenevästä sisäisestä kitkasta, voiteluongelmista tai mekaanisesta viasta. Lämpötilan seuraaminen soveltuu myös sähkövikojen, tiiviste- ja venttiilivuotojen sekä voiteluun ja kulumiseen liittyvien ongelmien paikantamiseen. (Kumar 2025.)

Lämpötilan seuraaminen lämpökuvauksella on tehokkaaksi todettu menetelmä, jonka avulla kyetään seuraamaan kompressorin ja sen osien pintojen lämpötilajakaumaa ja tunnistamaan ilmentyviä lämpötilapoikkeamia. Lämpökuvauksella suoritettavat mittaukset suoritetaan kosketuksettomasti infrapunakameroilla, jolloin muutokset on mahdollista havaita myös visuaalisesti. (Kumar 2025.)

Koneoppimisen yhdistäminen lämpökuvaukseen on edelleen lisännyt lämpötila- ja värähtelyolosuhteiden tunnistuksen sekä luokittelun automatisointia ja tukee ennakoivaa kunnossapidon menetelmiä. Lämpötilan seuranta on todettu käytännölliseksi menetelmäksi antaen yleispätevää tietoa laitteessa esiintyvistä epäkohdista. (Kumar 2025.)

Kumarin (2025) tutkimuksessa on myös huomioitu ympäristötekijöiden vaikutus kompressoreiden lämpötilaan, joten työssä huomioidaan kompressoreiden osalta myös ilman lämpötila.

Omozuhomwen ym. (2025) ovat tutkimuksessaan suositelleet lämpökuvauksen hyödyntämistä ennakoivassa kunnossapidossa.

Akustinen emissio tarkoittaa materiaalin rakenteisiin sitoutuneen energian vapautumisesta johtuvaa korkeataajuisia elastista värähtelyä (Laghari & Mekid 2023, 6). Tätä materiaalin ominaisuutta seuraamalla on mahdollista havaita tutkittavan laitteen fyysisiä muutoksia, kuten rasituksen johdosta syntyneitä pieniä murtumia tai muita muodonmuutoksia. (Kumar 2025; Nambiar ym. 2024.)

Käytännön toteutuksissa näitä korkeataajuisia AE-signaaleja seurataan AE-antureilla. Havaittujen signaalien piirteitä erotellaan ja luokitellaan koneoppimismallien avulla, jolloin todelliset merkittävät muutokset saadaan erotettua ja kohdennettua signaalien merkitsevien komponenttien avulla. Akustisen emissio tarkastelu tarjoaa erinomaisen keinon havaita laitteiston sisäistä rappeumaa varhaisessa vaiheessa ja on merkittävä tarkastelun kohde ennakoivaa kunnossapidon kannalta. (Kumar 2025; Nambiar ym. 2024.)

Kumari (2025) toteaa tutkimuksessaan AE-signaalien seurannan olevan tehottomampaa äänekkäissä käyttöympäristöissä, joka on otettava huomioon näitä signaaleja tutkittaessa.

Öljyn koostumuksen seuranta ja analysointi tarjoaa tietoa kompressorin liikkuvien osien kunnosta ja voiteluöljyn tehokkuudesta, sekä sen vaihtamisen tarpeesta. (Kumar 2025.)

Öljyn analysoinnin pääkohteina ovat liikkuvista osista irtaantuneet kulumispartikkelit (metallihiukkaset), öljyn kemialliset muutokset (viskositeetti) ja muut vierasaineet (pöly, vesi yms.), jotka jokainen osaltansa ilmaisevat kompressorin sisäisiä ongelmia, kuten liiallista kitkaa, tiiveysongelmia tai öljyn tehottomuutta. (Kumar 2025.)

Säännöllinen öljyn analysointi mahdollistaa ongelmien varhaisen toteamisen ja oikea-aikaiset toimenpiteet ennen laajempia vaurioita. Öljyn reaaliaikaista seuranta ja analysointia on mahdollista suorittaa nykyaikaisilla IoT-antureilla, jotka ovat yhdistettävissä osaksi koneoppimisjärjestelmiä kehittyneempää analyysia varten. (Kumar 2025.)

Paineen ja virtauksen tuottaminen ovat kompressoreiden päätehtävä, joten nämä molemmat parametrit ovat kompressorin suorituskyvyn, hyötysuhteen ja täten toimintakunnon mittareita. (Kumar 2025.)

Paineen ja virtauksen seuranta tapahtuu paine- ja virtausantureiden avulla. Äkilliset paineen muutokset ja virtausvaihtelut ovat merkkejä mahdollisista vuotoista tai tukoksista kompressorissa tai siihen kytketyssä järjestelmässä. Nämä muutokset voivat myös johtua kompressorin komponenttien kulumista tai muista mekaanisista vioista. Paineen ja virtauksen seuranta antavat näkyvän järjestelmätason kuntoon, mutta vaativat tarkempien, yksittäisten komponenttien, kunnon tarkastelun tueksi muita diagnostiikan tietoja. (Kumar 2025.) Näihin lukeutuvat muut työssä mainitut kompressorien kunnon valvonnan parametrit.

Sähkömoottorista saatava data on olennainen osa kompressoreiden toiminnan arviointia moottorin tuottaessa niiden käyttövoiman. Moottorin mittaustiedot tukevat suoraan kompressoreiden kunnonvalvontaa ja täydentävät muita seurattavia suureita.

5.5 Pumput

Avoimia tutkimuksia pumppujen ennakoivasta kunnossapidosta ja älykkäästä kunnonvalvonnasta on saatavilla varsin vähän. Valtaosa näistä vähäisistä tut-

kimuksista keskittyvät hyvin rajattuihin tutkimustapauksiin ja täten ollen soveltuvuudeltaan heikkoja tämän työn suhteen. Tyypillisesti nämä tutkimukset ovat käsitelleet yksittäisiä pumppumalleja sekä yksittäisiä seurattavia muuttujia, joka on useimmiten ollut tärinä. Tästä syystä tiedonkeräyksessä joustettiin julkaisuajan rajauksesta, jotta tarkasteluun saataisiin useampia ja kattavia tutkimuksia. Tästä huolimatta työhön soveltuvien tutkimusten määrä ei kasvanut.

Työn rajausten kannalta merkittäviksi ja soveltuvuudeltaan sopiviksi valittiin kaksi tutkimusta.

Tutkimuksessaan Lakal ym. (2022) tutkivat vaativissa olosuhteissa käytettäviä öljy- ja kaasuteollisuuden pumppuja. Vaikka tutkimus on erityisen tarkasti rajattu tutkimuksen teollisuuskohteiden pumppuihin ja ympäristöön, on sen tuottamat havainnot sensoriteknologioista ja pumppujen kunnonvalvonnasta sovellettavissa työn osalta. Tämä tutkimus on otettu osaksi työtä tukemaan pumppuja yleisemmin käsittelevää tutkimusta Predictive maintenance of pumps in civil infrastructure: State-of-the-art, challenges and future directions (Hallaji ym. 2022), jonka tutkimus on sovellettavissa erityisesti sensoridatan osalta.

Taulukossa 7 esitetään tutkimuksen pohjalta pumppuihin pätevät mittausaineistot ja mittausjärjestelmät.

Taulukko 7. Pumpuista seurattava mittausaineisto ja mittausjärjestelmä

Mittausaineisto	Mittausjärjestelmä
Historiatiedot	Automaation ohjausjärjestelmä
Prosessidata	Automaation ohjausjärjestelmä
Tärinä	Kuituoptiset anturi ja MEMS-anturit
Pumpun lämpötila	Lämpökamera
Paine	Painelähetin
Virtaus	Virtauslähetin
Sähkömoottori	Kts. Sähkömoottori

Tärinän seuranta on keskeisin ja laajimmin hyödynnetty menetelmä pumppujen kunnonvalvonnassa. Värähtelyt heijastavat suoraan pumpun mekaanista

tilaa, ja niiden avulla voidaan havaita muun muassa laakeri- ja tiivisteviat, epäkeskisyys sekä epätasapaino. Liiallinen tärinä johtaa usein kroonisiin vikoihin, kuten kiihtyneeseen kulumiseen ja rasiinukseen, jotka johtavat kohonneisiin huoltokustannuksiin. (Lakal ym. 2022; Hallaji ym. 2022)

Tutkimuksissa tärinän mittaamiseen on käytetty useita erilaisia antureita, kuten kuituoptisia antureita ja MEMS-anturitekniikkaa. Yksinkertaisimmillaan seuranta on toteutettu kiihtyvyyssantureilla. (Lakal ym. 2022; Hallaji ym. 2022)

Värähtelydatan analysoinnissa on sovellettu kehittyneitä menetelmiä, kuten aaltomuunnoksia ja Hilbert-Huang-muunnosta (engl. Hilbert-Huang transform). Näiden avulla on pystytty erottamaan useita pumppujen vikatyyppejä sekä luokittelemaan erinäisiä vika-asteita. (Lakal ym. 2022; Hallaji ym. 2022)

Lämpötila on pumppujen kunnonvalvonnassa tärkeä mittaussuure, joka heijastaa sekä pumpun että pumpun kuljettaman nesteen tilaa. Poikkeamat lämpötilassa voivat kertoa monista vioista, kuten laakerivaurioista ja tiivistevioista. (Lakal ym. 2022; Hallaji ym. 2022.)

Lämpötiladataa hyödynnetään yleensä yhdessä muiden muuttujien kanssa eikä yksittäisenä signaalina, sen tukiessa muiden signaalien tuottamaa kokonaiskuvaa (Hallaji ym. 2022).

Paineen ja virtauksen mittaus ovat olennaisia osia pumppujen kunnonvalvonnassa ja vikadiagnostiikassa. Molemmat suureet kuvaavat suoraan pumpun suorituskykyä, ja niiden avulla voidaan havaita toiminnan tehokkuuden heikkenemistä, joka ilmaisee mahdollisia laitevikoja. Poikkeamat näissä arvoissa voivat ilmaista sekä mekaanisista että käyttöolosuhteisiin liittyvistä ongelmista. (Lakal ym. 2022; Hallaji ym. 2022.)

Tutkimuksissa virtaus- ja painetietoja on hyödynnetty erityisesti monimuuttuja pohjaiseen vikadiagnostiikkaan, jossa virtaus yhdistetään muihin parametreihin, kuten tärinään, paineeseen ja lämpötilaan (Lakal ym. 2022; Hallaji ym. 2022). Virtausta mitataan virtausmittareilla ja painetta painemittareilla.

Molempien ominaisuuksien seuraaminen tukee pumppujen vikojen varhaista tunnistamista, parantaa ennustemallien tarkkuutta ja muodostaa tärkeän osan pumppujen ennakoivaa kunnossapitoa. (Lakal ym. 2022; Hallaji ym. 2022.)

Sähkömoottorista saatava data on olennainen osa pumppujen toiminnan arviointia moottorin tuottaessa niiden käyttövoiman. Moottorin mittaustiedot tulevat suoraan pumppujen kunnonvalvontaa ja täydentävät muita seurattavia suureita.

5.6 Venttiilit

Venttiileitä koskevat tulokset on jäsennelty tarkasteltujen tutkimuksen kohdeventtiilityyppien mukaisesti. Tässä osiossa esitetään yleisesti venttiilityypeistä mitatut ominaisuudet.

Akustisen emission seuraaminen on osoittautunut Zhangin ym. (2023) tutkimuksessa tehokkaaksi ratkaisuksi putkistovenntiileiden vuotojen havaitsemisessa. Tätä on hyödynnetty pääasiassa ultraäänisignaalien osalta useissa eri venttiilimalleissa, kuten luisti-, varo-, pallo-, ja hydraulikkavenntiileissä. AE-signaalien vahvuutena on kyky havaita venttiilin vuotoja varhaisessa vaiheessa.

Zhengjien ym. (2023) tutkimuksessa huomioidaan monianturifuusion merkitys AE-signaalien luotettavuudessa. Putkistojärjestelmien monimutkaisen luonteen ja niissä esiintyvän taustamelun vuoksi on yksittäisen anturin sijaan edullista hyödyntää useita eri signaaleja useista eri lähteistä vikadiagnostiikan tarkkuuden parantamiseksi.


Lämpötilan yhdistäminen muiden seurattavien parametrien kanssa on Zhangin ym. (2023) tutkimuksessa AE-signaalien tavoin osoittautunut tehokkaaksi keinoksi vuotokohtien paikantamisessa. Infrapunalämpökameralla venttiilistä saadut lämpötila tiedot yhdistettynä venttiilin ohjauksesta saataviin tietoihin on mahdollistanut venttiilin sisäisten vikojen laadun ja sijainnin paikantamisen.

Sähkötoimilaitteventtiilit

Zhang ym. (2023) tutkimuksessa sivulla 16, on esittänyt listauksen sähkötoimilaitteista (engl. *electric actuator*) kerättävistä signaaleista. Näihin signaaleihin sisältyvät seuraavat:

1. **Hall-anturi** (engl. *Hall sensor*)
 - a. **moottorin virta** (engl. *motor current*)
 - b. **moottorin nopeus** (engl. *motor speed*)
 - c. **venttiilin vääntömomentti** (engl. *valve torque*)
 - d. **moottorin ulostuloteho** (engl. *motor output power*)
2. **venttiilin asento** (engl. *valve position*)
3. **asentoanturi** (engl. *attitude sensor*)
4. **lämpötila** (engl. *temperature*)
5. **moottorin värähtelyn kiihtyvyyys** (engl. *motor vibration acceleration*).

Kuvassa 9 on esitetty venttiilin sähkötoimilaitte sekä siitä kerättävä mittausdata. Kuvassa havainnollistetaan läpileikkauksella sähkötoimilaitteen rakenne, jonka nimetyt ja numeroidut osat vastaavat edellisen luettelon suomennettua sisältöä.



Kuva 9. Sähkötoimilaitteesta kerättävä data (Zhang ym. 2023)

Kuvassa 9 ja luettelossa esitetyt moottorin virta, moottorin nopeus, venttiilin vääntömomentti ja moottorin ulostuloteho sisältyvät Hall-anturin suorittamiin mittauksiin.

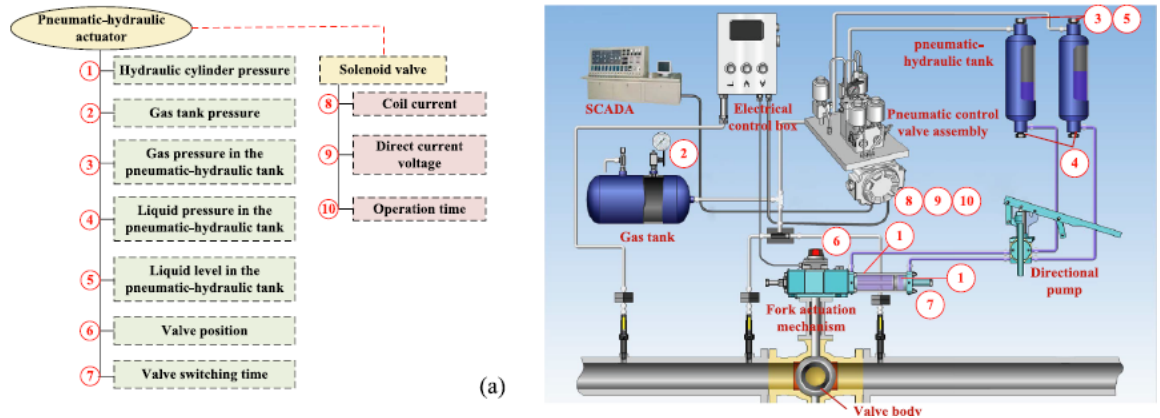
Hydraulisesti ja pneumaattisesti ohjatut venttiilit

Zhang ym. (2023) ovat tutkimuksensa sivulla 16 esittäneet listauksen pneumaattis-hydraulisia toimilaitteita (engl. *pneumatic-hydraulic actuators*) varten kerättävistä signaaleista. Koska tämän työn tutkimuskohde sisältää erilisiä pneumaattisia ja hydraulisia toimilaitteita, tuloksia sovelletaan näihin laitteisiin erikseen. Zhangin ym. (2023) tutkimuksessa esitettyihin signaaleihin sisältyvät seuraavat:

1. **hydraulisyylinterin paine** (engl. *hydraulic cylinder pressure*)
2. **paineilmasäiliön paine** (engl. *gas tank pressure*)
3. **pneumaattis-hydraulisen säiliön paine** (engl. *gas pressure in the pneumatic-hydraulic tank*)
4. **pneumaattis-hydraulisen säiliön nesteen paine** (engl. *liquid pressure in the pneumatic-hydraulic tank*)
5. **pneumaattis-hydraulisen säiliön nesteen pinnankorkeus** (engl. *liquid level in the pneumatic-hydraulic tank*)
6. **venttiilin asento** (engl. *valve position*)
7. **venttiilin kytkentäaika** (engl. *valve switching time*).

Luettelossa esitetyt hydraulisyylinterin paine, paineilmasäiliön paine, pneumaattis-hydraulisen säiliön paine, pneumaattis-hydraulisen säiliön nesteen paine, pneumaattis-hydraulisen säiliön nesteen pinnankorkeus, venttiilin asento ja venttiilin kytkentäaika vastaavat numeroinniltaan ja suomennoksiltaan kuvan 10 sisältöä.

Kuvassa 10 on esitetty venttiilin pneumaattis-hydraulista toimilaitetta varten kerättävä mittausdata sekä mittausten kohteet pneumaattis-hydraulisessa järjestelmässä. Kuvassa esitetty mittausdata jakautuu kahteen ryhmään: toimilaitteen varsinaista toimintaa kuvaaviin mittauksiin (1–7) sekä toimilaitteen sisäisiin solenoidiventtiileihin liittyviin mittauksiin (8–10).



Kuva 10. Pneumaattis-hydraulisesta toimilaitteesta kerättävä data (Zhang ym. 2023)

Zhangin ym. (2023) tutkimuksessa sivulla 16 esitetystä listauksesta on lisäksi esitetty pneumaattis-hydraulisten toimilaitteiden ohjauksen sisäiset solenoidiventtiilit ja niistä kerätyt signaalit:

- 8. **käämin virta** (engl. *coil current*)
- 9. **tasajännite** (engl. *direct current voltage*)
- 10. **käyttöaika** (engl. *operation time*).

Luettelossa esitetyt käämin virta, tasajännite ja käyttöaika vastaavat numeerinniltaan ja suomennoksiltaan kuvan 10 sisältöä.

Manuaaliset venttiilit

Laitoksessa sijaitsevat manuaaliventtiilit eivät ole suoraan yhteydessä reaktorin ohjaukseen, mutta niiden asentoja valvotaan induktiivisten antureiden avulla. Manuaaliventtiilien huoltotarve on vähäisempi niiden yksinkertaisen rakenteen ja ohjaustavan vuoksi. Tästä syystä niistä seurataan ainoastaan venttiilin tilatietoa, joka mahdollistaa käyttöajan laskemisen.

Venttiilien yhteenveto

Osio sisältää venttiileihin liittyvät tulokset, jotka on tutkimusmateriaalin pohjalta mukautettu soveltumaan tämän tutkimuksen kohdelaitteistoon.

Taulukossa 8 esitetään tutkimuksen pohjalta venttiileihin pätevät mittausaineistot ja mittausjärjestelmät. Tulokset on eritelty venttiilityypeittäin sähkötoi-

milaitte- ja solenoidiventtiileihin sekä hydraulisesti ja pneumaattisesti ohjattuihin venttiileihin. Taulukon *Venttiilit yleisesti* -osiossa esitetyt mittausaineistot ja -järjestelmät koskevat kaikkia taulukossa mainittuja venttiilityyppejä.

Taulukko 8. Venttiileistä seurattava mittausaineisto ja mittausjärjestelmä

Venttiilit yleisesti	
Mittausaineisto	Mittausjärjestelmä
Historiatiedot	Automaation ohjausjärjestelmä
Prosessidata	Automaation ohjausjärjestelmä
Akustinen emissio	AE-anturi
Lämpötila	Lämpökamera
Sähkötoimilaitteventtiilit	
Mittausaineisto	Mittausjärjestelmä
Moottorin virta	Sähkövirtamittari
Moottorin nopeus	Toimilaitte/Automaation ohjausjärjestelmä + Venttiilin asento
Venttiilin vääntömomentti	Toimilaitte
Moottorin ulostuloteho	Toimilaitte
Kulma-asento	Toimilaitte
Venttiilin asento	Induktiivinen anturi/Toimilaitte
Moottorin värähtelyn kiihtyvyys	Kiihtyvyyssanturi
Hydraulisesti ohjatut venttiilit	
Mittausaineisto	Mittausjärjestelmä
Hydraulisyliinterin paine	Painelähetin
Ohjauksen paine	Painelähetin
Nesteen paine hydraulisäiliössä	Painelähetin
Nesteen taso hydraulisäiliössä	Pinnankorkeusanturi
Venttiilin asento	Induktiivinen anturi
Venttiilin kytkentäaika	Automaation ohjausjärjestelmä
Pneumaattisesti ohjatut venttiilit	
Mittausaineisto	Mittausjärjestelmä
Ohjauksen paine	Painelähetin
Paineilmasäiliön paine	Painelähetin
Venttiilin asento	Induktiivinen anturi
Venttiilin kytkentäaika	Automaation ohjausjärjestelmä
Solenoidiventtiilit	
Mittausaineisto	Mittausjärjestelmä
Käämin virta	Sähkövirtamittari
Tasajännite	Jännitemittari
Käyttöaika	Automaation ohjausjärjestelmä

Zhangin ym. (2023) tutkimuksessa esitetyt sähköisistä toimilaitteista saatavat mittaukset ja tiedot riippuvat toimilaitteiden tyypeistä ja niiden sisältämistä antureista, esimerkiksi tutkimuksessa mainittu Hall-anturi ei ole teollisuudessa

yleisesti käytettyjen toimilaitteiden vakioanturi. Tästä johtuen taulukossa 8 esitetyt datatyypit, jotka ovat saatavilla ainoastaan toimilaitteisiin integroitujen antureiden kautta, on merkitty mittausjärjestelmäksi *Toimilaitte*.

5.7 Hydraulikkajärjestelmä

Luvussa käsitellään kohdelaitteiston hydraulikkajärjestelmä. Osio on jaettu rakenteellisesti yksinkertaisemman öljynlauhduttimen ja rakenteellisesti monimutkaisemman hydraulikkakoneikon välille.

Öljynlauhdutin

Öljynlauhdutin vastaa hydraulikkajärjestelmässä kiertävän öljyn lämpötilan hallinnasta. Sen toiminta perustuu sähkömoottorin pyörittämään propelliin, joka ohjaa ilmavirran lauhduttimen läpi siirtäen lämpöä öljystä ympäröivään ilmaan. Koska öljynlauhduttimen päätehtävänä on jäähdyttää järjestelmässä kiertävää öljyä, sen toiminnan seurannan kannalta keskeisimmät tarkasteltavat muuttujat ovat **sähkömoottorin tila** ja **öljyn lämpötila**.

Taulukko 9. Öljylauhduttimista seurattava mittausaineisto ja mittausjärjestelmä

Mittausaineisto	Mittausjärjestelmä
Historiatiedot	Automaation ohjausjärjestelmä
Prosessidata	Automaation ohjausjärjestelmä
Öljyn lämpötila	Lämpötila-anturi+lähetin
Sähkömoottori	Kts. Sähkömoottori

Taulukossa 9 esitetään tutkimuksen pohjalta öljynlauhduttimiin pätevät mittausaineistot ja mittausjärjestelmät.

Hydraulikkakoneikko

Kansainvälisen hydraulikkakomponenttien toimittajan ZEUS Hydratech LTD:een mukaan (Introduction to Hydraulic... s.a.) hydraulikkakoneikot koostuvat yleisesti ottaen seuraavista komponenteista:

- **moottori** (pumppujen voimanlähde)
- **hydraulipumppu** (pumppaa hydraulioiljyä järjestelmässä)

- **säiliö** (varastoi hydraulioöljyä)
- **hydrauliakku** (varastoi muodostunutta hydraulista energiaa)
- **öljysuodatin** (suodattaa hydraulioöljyä)
- **öljyn jäähdytysjärjestelmä** (jäähdyttää hydraulioöljyä)
- **venttiilit** (ohjaavat hydraulioöljyn virtausta).

Työn kohdejärjestelmä sisältää **hydrauliakkuja** lukuun ottamatta kaikki muut luettelossa esitetyt komponentit. Koska hydraulikkakoneikko koostuu pääasiassa työssä jo käsitellyistä laitteista, tässä osiossa keskitytään hydraulikkaöljyn ominaisuuksiin, jotka kuvaavat hydraulikkakoneikon kuntoa.

Jeon ym. (2022) tarkastelevat tutkimuksessaan hydraulikkaöljyn kunnonvalvonnan tarkkuutta maanrakennuskoneiden hydraulikkajärjestelmissä. Työssä esitellään kirjallisuuskatsauksena yleisimpiä hydraulikkaöljyn reaaliaikaisessa kunnonvalvonnassa hyödynnettyjä antureita ja niiden mittaamia suureita.

Taulukossa 10 esitetään tutkimuksen pohjalta hydraulikkakoneikkoihin pätevät mittausaineistot ja mittausjärjestelmät.

Taulukko 10. Hydraulikkakoneikosta seurattava mittausaineisto ja mittausjärjestelmä

Mittausaineisto	Mittausjärjestelmä
Historiatiedot	Automaation ohjausjärjestelmä
Prosessidata	Automaation ohjausjärjestelmä
Öljyn viskositeetti	Öljynlaatuanturi
Öljyn puhtaus	Öljynlaatuanturi
Öljyn kulumahiukkaspitoisuus	Öljynlaatuanturi
Öljyn lämpötila	Öljynlaatuanturi/Lämpötila-anturi+lähetin
Öljyn pinnankorkeus	Pinnankorkeusanturi
Öljynlauhdutin	Kts. Öljynlauhdutin
Venttiilit	Kts. Venttiilit
Sähkömoottorit	Kts. Sähkömoottori
Pumput	Kts. Pumput

Öljyn viskositeetti ilmaisee hydraulikkaöljyn virtausvastusta. Viskositeetin muutos voi johtua useista eri tekijöistä, kuten öljyn saastumisesta tai lämpötilan muutoksista. Viskositeetin muuttuminen hydraulikkajärjestelmälle epäsuotuisaksi aiheuttaa järjestelmään ylimääräistä kuormitusta ja lisää kitkaa, mikä johtaa öljyn lämpenemiseen. (Jeon ym. 2022; Brouwer ym. 2012.)

Öljyn puhtaudella viitataan öljyn sisältämiin vierasaineisiin, kuten pölyyn, veteen ja kulumahiukkasiin, jotka heikentävät öljyn tehokkuutta ja aiheuttavat hydraulijärjestelmän kulumista (Jeon ym. 2022). Vierasaineiden päätyminen hydraulijärjestelmään viittaa esimerkiksi järjestelmän tiiveysongelmiin.

Öljyn kulumahiukkaspitoisuus viittaa hydraulijärjestelmän liikkuvien osien kulumisesta syntyviin kulumahiukkasiin. Näiden hiukkasten havaitseminen on keskeistä hydraulijärjestelmissä esiintyvien normaalista toiminnasta poikkeavien olosuhteiden havaitsemisessa sekä komponenttien kulumisen ja vikaantumisen ennakoinnissa. Kulumahiukkasten määrä ja koko pysyvät normaaleissa olosuhteissa vakaina, mutta epänormaaleissa olosuhteissa niiden määrä ja koko kasvavat. (Jeon ym. 2022; Mauntz ym. 2013.)

Öljyn lämpötilan vaihtelut liittyvät moniin hydraulikkaöljyn ominaisuuksien muutoksiin, kuten viskositeetin aiheuttamaan kitkalämpöön (Jeon ym. 2022). Lämpötilan seuranta antaa tietoa myös jäähdytysjärjestelmän toimivuudesta ja mahdollisista häiriöistä sen lämmönhallinnassa.

Öljyn pinnankorkeus ilmaisee öljyn määrää hydraulikkaöljysäiliössä ja täten kuvastaa öljyn määrää hydraulikkajärjestelmässä. Muutokset öljysäiliön pinnankorkeudessa johtuvat esimerkiksi vuodoista, tai muista tiiveysongelmista hydraulikkajärjestelmissä.

Öljynlauhdutin jäähdyttää hydraulikkaöljyä ylläpitäen sen optimaalista käyttölämpötilaa. Tämä ehkäisee laitteiston ylikuumentumista ja pidentää järjestelmän komponenttien käyttöikää. Täten öljynlauhduttimen toiminnan seuraaminen on tärkeä osa hydraulikkakoneikkojen kunnon seuraamista.

Venttiilit ohjaavat hydrauliohjainvirtausta hydraulijärjestelmässä. Täten venttiilien toiminnan seuraaminen on merkittävä osa hydraulikkakoneikkojen kunnon seuraamista.

Sähkömoottorit ja pumput muodostavat hydraulikkakoneikkojen voimanlähteen ja järjestelmän toiminnan perustan. Ne vastaavat paineistetun öljyn tuot-

tamisesta ja ylläpitämisestä, mahdollistaen siihen liitettyjen toimilaitteiden toiminnan. Täten niiden toiminnan seuraaminen on merkittävä osa hydraulikkokoneikkojen kunnan seuraamista.

5.8 Taajuusmuuttajat

Taajuusmuuttajat ovat tutkimusten myötä osoittautuneet kunnossapidon kohteiden sijaan kunnossapidon mittareiksi. Taajuusmuuttajat tukevat ohjaimensa moottoreiden kunnossapidon valvontaa ja täten täydentävät tai korvaavat työssä esitettyjä sähkömoottoreiden kunnonvalvontamenetelmiä.

Taajuusmuuttajat ovat keskeinen osa nykyaikaisia teollisia ohjausjärjestelmiä, joiden päätehtävänä on ohjata sähkömoottoreiden nopeutta ja momenttia prosessin tarpeiden mukaan. Taajuusmuuttajien merkitys on kasvanut teknologian kehityksen myötä myös kunnossapidollisesta näkökulmasta. Modernit taajuusmuuttajat keräävät jatkuvasti tietoa moottorin ja sen kuormituksen toiminnasta, kuten jännitteestä, virrasta, taajuudesta, nopeudesta, tehosta ja hyötysuhteesta. Näitä mittauksia on mahdollista hyödyntää sähkömoottoreiden kunnonvalvonnassa ja ennakoivassa kunnossapidossa ilman erillisiä ulkoisia antureita. (Tolbert 2025.)

Taulukossa 11 esitetään tutkimuksen pohjalta taajuusmuuttajien moottoreista mitaamat mittausaineistot.

Taulukko 11. Taajuusmuuttajien mitaama mittausaineisto

Mittausaineisto
Moottorin jännite
Moottorin sähkövirta
Moottorin lämpötila
Moottorin nopeus
Moottorin vääntömomentti
Moottorin teho
Moottorin hyötysuhde

Tutkimuksessaan Tolbert (2025) keskittyy taajuusmuuttajien hyödyntämiseen rikkomattomassa aineenkoetuksessa (engl. *Nondestructive testing, NDT*) ja

ennakoivassa kunnossapidossa. Tutkimuksen päätavoite oli osoittaa, että taa-juusmuuttajat toimivat itsessään tehokkaina kunnonvalvontalaitteina.

5.9 Jatkokehitys

Osiossa käsitellään opinnäytetyökokonaisuuden pohjalta esiin nousseet jatko-kehitysehdotukset.

Laitekohtaisen seurattavan datan tarkempi määrittely

Tutkimuksen tulokset tarjoavat yleispätevän kuvan siitä, millaista dataa lait-teilta on syytä kerätä. Työn laajuuden ja rajauksen vuoksi kunnossapidon kan-nalta merkityksellisiä muuttujia on varmasti jäänyt työn tulosten ulkopuolelle. Jatkokehityksen kannalta olisi tärkeää suorittaa yksityiskohtaisempi kartoitus kunkin laitetyypin kunnonvalvonnasta, mikä loisi vahvemman pohjan ennakoiv-an kunnossapidon sovelluksille ja kehitykselle.

Datan keruuseen käytettävien laitteiden tarkempi määrittely

Yksittäisten suureiden kunnonvalvontaan on tarjolla useiden eri valmistajien kehittämiä laitteistoja. Huolimatta siitä, että seurattava suure on sama, nämä laitteistot eroavat toimintaperiaatteiltaan ja rakenteiltaan valmistajien välillä. Tästä johtuen työssä ei voitu suoraan esittää suureiden mittaamiseen yksit-täistä toimivaa mittalaitetta, vaan työssä esitettiin mittaamiseen yleisesti sovel-tuva laitetyyppi. Jotta mittausjärjestelmien osalta saavutetaan parhaat mahdol-liset tulokset, on tarpeen selvittää tehokkain ja varmin tarjolla oleva mittausjär-jestelmä.

Datan keruulaitteiden sijoittelun tarkentaminen

Työssä ei määritelty mittauslaitteiden sijoittelua ja sen vaikutusta mittaustulok-siin. Mittauslaitteiston sijoittelu vaikuttaa tuloksien luotettavuuteen ja täten lait-teiston kunnossapitotilan selvittämiseen, minkä vuoksi se on merkittävä jatko-tutkimuksen kohde.

Koneoppimismallien soveltuvuuden jatkotutkimus

Työssä määritettiin suureet, joiden seuraaminen ja analysointi mahdollistavat laitteen kunnossapidollisen tilan arvioinnin. Jotta kerättyä dataa voidaan analysoida mahdollisimman tehokkaasti, on tarpeen selvittää laite- ja mittaustietokohtaisesti tehtävään parhaiten soveltuva koneoppimismalli.

Suomenkielisen tekoälyterminologian määrittäminen

Opinnäytetyön tekemisen aikana havaittiin ongelmia tekoälyyn ja koneoppimiseen liittyvien suomenkielisten termien käytössä. Monet englanninkieliset termit ovat vakiintuneet käyttöön sellaisinaan, mutta niiden suomenkieliset vakiintumattomat vastineet ”elävät”. Tämä aiheuttaa väärinkäsityksiä, tulkintajeroja ja yleisiä sekaannuksia täsmällisessä kirjoitustyössä ja ammatillisessa keskustelussa. Suomalaisen tekoälykehityksen kannalta olisi merkittävää laatia yhtenäinen suomenkielinen terminologia.

6 POHDINTA

Luvussa pohditaan tutkimuksen tuloksia ja niiden suhdetta työn tavoitteisiin sekä arvioidaan opinnäytetyöprosessin onnistumista. Lopuksi esitetään tekijän omia oppimiskokemuksia ja näkemyksiä opinnäytetyöstä.

6.1 Yhteenveto

Tutkimuksen tulokset vastasivat esitettyihin tutkimuskysymyksiin. Vastaukset osoittavat, että laitteista on kerättävissä laajasti ennakoivassa kunnossapidossa hyödynnettäviä mittaustietoja ja laitteiden kunnonvalvontaan on tarjolla useita erilaisia mittareita. Tutkittu aineisto osoitti, että eri laiteluokkien kunnossapidon kannalta keskeisimmät seurattavat muuttujat voidaan jakaa sähköisiin, mekaanisiin ja prosessiperusteisiin suureisiin, joista erityisesti virta, tärinä ja lämpötila nousevat toistuvasti laitteiden kunnon merkittäviksi indikaattoreiksi.

Mittalaitteet ja taajuusmuuttajat olivat työn tulosten kannalta poikkeuksellisia. Ne eivät suoraan vastanneet tutkimuskysymyksiin: mittalaitteiden osuus jäi ilman tyhjentävää vastausta ja taajuusmuuttajien rooli muuttui tutkimuksen aikana, mikä vaikutti myös niiden tarkasteluun.

Mittalaitteiden rooli yleisesti kaikissa prosesseissa ja järjestelmissä on tuottaa dataa. Mittalaitteiden kunnonvalvontaa koskettavia tutkimuksia ei tutkimusmateriaalia kerätessä löytynyt. Tästä johdettiin karkea päätelmä, jonka mukaan mittalaitteistoa ei ole nähty tarpeellisena laajan kunnossapidollisen tutkimuksen kohteena.

Taajuusmuuttajien rooli tutkimuksessa muuttui tutkimusmateriaalia kerätessä kunnossapidon kohteesta kunnossapidon mittariksi. Nykyaikaiset taajuusmuuttajat keräävät useita mittaustietoja ohjaamistaan moottoreista ja suorittavat myös itsediagnostiikkaa taaten kunnossapidon kannalta merkittävää dataa. Taajuusmuuttajat ovat yleisesti toimintakyvyltään luotettavia ja kestäviä, kuluvien mekaanisten osien puutteen, sisäisen diagnostiikan sekä tehokkaan lämpöhallinnan ja suojaustoimintojen vuoksi. Itsediagnostiikasta ja yleisestä kestävyydestä johtuen laitteiston kunnossapitoa varten kerättävää dataa ei tarkasteltu.

Työn tulokset tarjoavat yleispätevää suuntaa ja perustan, jonka pohjalta on mahdollista lähteä rakentamaan ja kehittämään kunnonvalvontaa ennakoivaa ja älykästä kunnossapitojärjestelmää varten. Tulokset tarjoavat myös perustan syvemmälle ja yksityiskohtaisemmalle jatkotutkimukselle.

6.2 Tekijän oppimiskokemukset

Työ osoittautui kokonaisuudessaan oletettua raskaammaksi. Pelkästään tekoälyä käsittelevän teoriaosuuden laatiminen vaati useisiin eri lähteisiin perehtymistä. Aihe oli tekijälle entuudestaan tuttu, mutta syvemmän ymmärryksen ja tiedon paikkansapitävyyden varmistamiseksi tekijä joutui opettelemaan lähes kaiken teoriaosuuden sisällön uutena asiana. Tekoälyn teoriaosiossa korostui myös oikeaoppisten termien käytön ongelmallisuus, joka nostettiin yhdeksi kehitysehdotukseksi.

Tutkimusosion sisällön muodostaminen oli ehdottomasti opinnäytetyön haastavin osuus. Tekijän tekninen osaaminen teorian ja käytännön osalta juontuu lähes yksinomaan ammattikorkeakoulun opeista. Nämä loivat työn tekemistä varten erinomaiset lähtökohdat, joiden avulla tekijä kykeni osoittamaan työlle suuntaa ja etenemään sen mukaisesti. Hyvistä pohjatiedoista huolimatta työn

tekeminen oli kokonaisuudessaan jatkuvaa uuden opettelua sekä kartutetun tiedon reflektointia ja arviointia.

Jos opinnäytetyön olisi voinut aloittaa nykyisellä, työn aikana kertyneellä tietopohjalla, työn laajuus olisi rajattu selvästi keskitetyimmäksi kokonaisuudeksi. Mikäli työ olisi kohdistunut yksittäiseen laitteeseen tai laiteluokkaan, olisi työn edistyminen ollut jouhevampaa aiheeseen perehtymisen keskittyessä syvällisemmin vain yhteen aihealueeseen.

Lyhyesti esitettynä opinnäytetyön laatiminen kartutti tekijän ymmärrystä kunnossapidon eri muodoista, tekoälystä ja koneoppimisesta sekä tutkimustyökentelystä. Kuten edellä on todettu, työn jokaisessa vaiheessa oli omaksuttava jotakin uutta opinnäytetyössä käsitellyistä aihealueista.

LÄHTEET

Achouch, M., Dimitrova, M., Ziane, K., Karganroudi, S., Dhoudi, R., Ibrahim, H. & Adda, M. 2022. On Predictive Maintenance in Industry 4.0: Overview, Models, and Challenges. *Applied Sciences* 8081, 1–22. Verkkolehti. Saatavissa: <https://doi.org/10.3390/app12168081> [viitattu 25.10.2025].

AI vs. machine learning vs. deep learning vs. neural networks: What's the difference? 2023. IBM. WWW-dokumentti. Saatavissa: <https://www.ibm.com/think/topics/ai-vs-machine-learning-vs-deep-learning-vs-neural-networks> [viitattu 2.7.2025].

Ali, M. 2022. Supervised Machine Learning. DataCamp. Blogi. Saatavissa: <https://www.datacamp.com/blog/supervised-machine-learning> [viitattu 4.7.2024].

Artificial Neural Network (ANN). s.a. aiOla. WWW-dokumentti. Saatavissa: <https://aiola.ai/glossary/artificial-neural-networks/> [viitattu 2.7.2025].

Bergmann, D. 2023. What is semi-supervised learning? IBM. WWW-dokumentti. Saatavissa: <https://www.ibm.com/think/topics/semi-supervised-learning> [viitattu 4.7.2025].

Bitton-Bailey, A., Ostroff, D., James, D., Kates, F., Weisberg, L., Gitzendanner, M., Mocko, M. & Davis, J. s.a. The UF Faculty Handbook for Adding AI to Your Course. University of Florida. E-kirja. Saatavissa: <https://ufl.pb.unizin.org/artificialintelligence/front-matter/table-of-contents/> [viitattu 26.6.2025].

Boucher, P. 2020. Artificial intelligence: How does it work, why does it matter, and what we can do about it. European Parliamentary Research Service. PDF-dokumentti. Saatavissa: [https://www.europarl.europa.eu/RegData/etudes/STUD/2020/641547/EPRS_STU\(2020\)641547_EN.pdf](https://www.europarl.europa.eu/RegData/etudes/STUD/2020/641547/EPRS_STU(2020)641547_EN.pdf) [viitattu 27.6.2025].

Britannica Editors. 2009. John McCarthy. Encyclopaedia Britannica. WWW-dokumentti. Päivitetty 20.10.2024. Saatavissa: <https://www.britannica.com/biography/John-McCarthy> [viitattu 18.6.2025].

Brouwer, M., Gupta, L., Sadeghi, F., Peroulis, D. & Adams, D. 2012. High temperature dynamic viscosity sensor for engine oil applications. *Sensors and Actuators A: Physical* 1, 102–107. Verkkolehti. Saatavissa: <https://doi.org/10.1016/j.sna.2011.10.024> [viitattu 5.10.2025].

Chen, M. 2024a. What Is Reinforcement Learning? OCI. WWW-dokumentti. Saatavissa: <https://www.oracle.com/artificial-intelligence/machine-learning/reinforcement-learning/> [viitattu 4.7.2025].

Chen, M. 2024b. What Is Semi-Supervised Learning? OCI. WWW-dokumentti. Saatavissa: <https://www.oracle.com/europe/artificial-intelligence/machine-learning/semi-supervised-learning/> [viitattu 4.7.2025].

Deep learning: The mechanics of magic. s.a. ISO. WWW-dokumentti. Saatavissa: <https://www.iso.org/artificial-intelligence/deep-learning> [viitattu 10.7.2025].

Euroopan parlamentin ja neuvoston asetus (EU) 2024/1689.

Gillis, A., Craig, L. & Awati, R. 2024a. What is a convolutional neural network (CNN)? TechTarget. WWW-dokumentti. Saatavissa: <https://www.techtarget.com/searchenterpriseai/definition/convolutional-neural-network> [viitattu 15.7.2025].

Gillis, A., Hashemi-Pour, C. & Carew, J. 2024b. What is reinforcement learning? TechTarget. WWW-dokumentti. Saatavissa: <https://www.techtarget.com/searchenterpriseai/definition/reinforcement-learning> [viitattu 4.7.2025].

Hafini, S., Alkali, B., Lindsay, G., Waters, M. & McGlinchey, D. 2025. Advancements in predictive maintenance modelling for industrial electrical motors: Integrating machine learning and sensor technologies. *Measurement: Sensors* 101473. Verkkolehti. Saatavissa: <https://doi.org/10.1016/j.measen.2024.101473> [viitattu 1.9.2025].

Hallaji, S., Fang, Y. & Winfrey, B. 2022. Predictive maintenance of pumps in civil infrastructure: State-of-the-art, challenges and future directions. *Automation in Construction* 104049. Verkkolehti. Saatavissa: <https://www.sciencedirect.com/science/article/abs/pii/S0926580521005008> [viitattu 25.9.2025].

Hassan, I., Panduru, K. & Walsh, J. 2025. Predictive Maintenance in Industry 4.0: A Review of Data Processing Methods. *Procedia Computer Science*, 896–903. Saatavissa: <https://doi.org/10.1016/j.procs.2025.03.115> [viitattu 7.10.2025].

Holdsworth, J. & Scapicchio, M. 2024. What is deep learning? IBM. WWW-dokumentti. Saatavissa: <https://www.ibm.com/think/topics/deep-learning> [viitattu 10.7.2025].

How Do Neural Networks Work? Your 2025 Guide. 2025. Coursera. WWW-dokumentti. Päivitetty 4.6.2025 Saatavissa: <https://www.coursera.org/articles/how-do-neural-networks-work> [viitattu 2.7.2025].

How Neural Network Models in Machine Learning Work. 2022. Turing. WWW-dokumentti. Saatavissa: <https://www.turing.com/kb/how-neural-network-models-in-machine-learning-work> [viitattu 2.7.2025].

How Unsupervised Learning Works with Examples. 2025. Coursera. WWW-dokumentti. Päivitetty 14.3.2025. Saatavissa: <https://www.coursera.org/articles/unsupervised-learning> [viitattu 4.7.2025].

Introduction to Hydraulic Power Units. s.a. ZEUS Hydratech LTD. WWW-dokumentti. Saatavissa: <https://www.zeushydratech.com/knowledge-base/hydraulic-power-packs/what-is-a-hydraulic-power-unit/> [viitattu 3.10.2025].

- Israelsen, A. 2024. Deep learning: Understanding how neural networks work. Pluralsight. WWW-dokumentti. Saatavissa: <https://www.pluralsight.com/resources/blog/ai-and-data/deep-learning-neural-networks-explained> [viitattu 4.7.2025].
- Jeon, H., Kim, J., Na, S., Kim, M. & Hong, H. 2022. Application of Condition Monitoring for Hydraulic Oil Using Tuning Fork Sensor: A Study Case on Hydraulic System of Earth Moving Machinery. *Materials* 7657, 1–18. Verkkolehti. Saatavissa: <https://doi.org/10.3390/ma15217657> [viitattu 4.10.2025].
- Kelley, M. 2024. What is Artificial Intelligence? NASA. WWW-dokumentti. Päivitetty 13.5.2024. Saatavissa: <https://www.nasa.gov/what-is-artificial-intelligence/> [viitattu 26.6.2025].
- Khoei, T. & Kaabouch, N. 2023 Machine Learning: Models, Challenges, and Research Directions. *Future internet* 332, 1–29. Verkkolehti. Saatavissa: <https://doi.org/10.3390/fi15100332> [viitattu 3.7.2025].
- Kinza, Y. 2024. What is a neural network? TechTarget. WWW-dokumentti. Saatavissa: <https://www.techtarget.com/searchenterpriseai/definition/neural-network> [viitattu 2.7.2025].
- Kumar, A. 2025. Research overview and prospect in condition monitoring of compressors. *Expert Systems with Applications* 127284. Verkkolehti. Saatavissa: <https://doi.org/10.1016/j.eswa.2025.127284> [viitattu 12.9.2025].
- Laghari, R. & Mekid, S. 2023. Comprehensive approach toward IIoT based condition monitoring of machining processes. *Measurement* 113004. Verkkolehti. Saatavissa: <https://doi.org/10.1016/j.measurement.2023.113004> [viitattu 12.9.2025].
- Lakal, N., Shehri, A., Brashler, K., Wankhede, S., Morse, J. & Du, X. 2022. Sensing technologies for condition monitoring of oil pump in harsh environment. *Sensors and Actuators A: Physical* 113864. Verkkolehti. Saatavissa: <https://doi.org/10.1016/j.sna.2022.113864> [viitattu 25.9.2025].
- Lheureux, A. 2025. Understanding Feedforward and Feedback Networks (or recurrent) neural network. DigitalOcean. WWW-dokumentti. Päivitetty 28.4.2025. Saatavissa: <https://www.digitalocean.com/community/tutorials/feed-forward-vs-feedback-neural-networks> [viitattu 2.7.2025].
- Machine learning (ML): All there is to know. s.a. ISO. WWW-dokumentti. Saatavissa: <https://www.iso.org/artificial-intelligence/machine-learning#toc9> [viitattu 28.6.2025].
- Manjare, A. & Patil, B. 2021. A Review: Condition Based Techniques and Predictive Maintenance for Motor. *International Conference on Artificial Intelligence and Smart Systems (ICAIS)*, 807–813. Verkkolehti. Saatavissa: <https://ieeexplore.ieee.org/document/9395903> [viitattu 8.9.2025].
- Mauntz, M., Gegner, J. Kuipers, U. & Klingau, S. 2013. A Sensor System for Online Oil Condition Monitoring of Operating Components. IntechOpen.

WWW-dokumentti. Saatavissa: <http://dx.doi.org/10.5772/55737> [viitattu 5.10.2025].

Mitä on tekoäly ja mihin sitä käytetään? 2020. Euroopan parlamentti. WWW-dokumentti. Päivitetty 20.6.2023. Saatavissa: <https://www.europarl.europa.eu/topics/fi/article/20200827STO85804/mita-tekoaly-on-ja-mihin-sita-kaytetaan> [viitattu 26.6.2025].

Mohammed, N., Abdulateef, O. & Hamad, A. 2023. An IoT and Machine Learning-Based Predictive Maintenance System for Electrical Motors. *Journal Européen des Systèmes Automatisés* 4, 651–656. Verkkolehti. Saatavissa: <https://doi.org/10.18280/jesa.560414> [viitattu 8.9.2025].

Mohsen, S., Behrooz, A. & Roza, D. 2023. Artificial intelligence, machine learning and deep learning in advanced robotics, a review. *Cognitive Robotics*, 54–70. Verkkolehti. Saatavissa: <https://doi.org/10.1016/j.cogr.2023.04.001> [viitattu 28.6.2025].

Murel, J. & Kavlakoglu, E. 2024. What is reinforcement learning? IBM. WWW-dokumentti. Saatavissa: <https://www.ibm.com/think/topics/reinforcement-learning> [viitattu 4.7.2025].

Nambiar, A., Venkatesh, N., S, A., V, S., Ramteke, S. & Marian, M. 2024. Prediction of air compressor faults with feature fusion and machine learning. *Knowledge-Based Systems* 112519. Verkkolehti. Saatavissa: <https://doi.org/10.1016/j.knosys.2024.112519> [viitattu 12.9.2025].

Nikfar, M., Bitencourt, J. & Mykoniatis, K. 2022. A Two-Phase Machine Learning Approach for Predictive Maintenance of Low Voltage Industrial Motors. *Procedia Computer Science*, 111–120. Verkkolehti. Saatavissa: <https://doi.org/10.1016/j.procs.2022.01.210> [viitattu 1.9.2025].

Numminen, L. 2023. Mikä on neuroverkko ja kuinka se toimii? Finnishup. WWW-dokumentti. Saatavissa: <https://www.finnishup.com/mika-on-neuroverkko/> [viitattu 2.7.2025].

Omozuhomwen, G., Ebenuwa, S., Kure, H., Ijamaru, G., Obi, E. & Nwajana, A. 2025. Reliability-Centered Maintenance Using Reliability Parameters on Gas Compressors. *International Journal of Manufacturing, Materials, and Mechanical Engineering* 1, 1–31. Verkkolehti. Saatavissa: <https://doi.org/10.4018/IJMMME.367256> [viitattu 12.9.2025].

Raikar, M. Kulkarni, S., Patil, O., Halingali, K. & Darshan, A. 2025. Remote motor condition monitoring using IoT and Machine Learning: A predictive approach. *Procedia Computer Science*, 1096–1105. Verkkolehti. Saatavissa: <https://doi.org/10.1016/j.procs.2025.04.063> [viitattu 8.9.2025].

Ran, Y., Zhou, X., Lin, P., Wen, Y. & Deng, R. 2019. A Survey of Predictive Maintenance: Systems, Purposes and Approaches. *IEEE Communications Surveys & Tutorials* 20, 1–36. Verkkolehti. Saatavilla: https://www.researchgate.net/publication/337971929_A_Survey_of_Predictive_Maintenance_Systems_Purposes_and_Approaches [viitattu 23.10.2025].

Reddy, P., Pulabaigari, V. & Reddy, E. 2018. Semi-supervised learning: a brief review. *International Journal of Engineering & Technology* 1-8, 81–85. Verkko-lehti. Saatavissa: <https://doi.org/10.14419/ijet.v7i1.8.9977> [viitattu 4.7.2025].

Salminen A. 2011. Mikä kirjallisuuskatsaus? johdatus kirjallisuuskatsauksen tyyppeihin ja hallintotieteellisiin sovelluksiin. Vaasan yliopisto. Vaasan yliopiston julkaisuja. Opetusjulkaisuja 62. Julkisjohtaminen 4. PDF-dokumentti. Saatavissa: <https://urn.fi/URN:ISBN:978-952-476-349-3> [viitattu 16.10.2025].

Samoili, S., Lopez Cobo, M., Delipetrev, B., Martinez-Plumed, F., Gomez Gu-tierrez, E. & De Prato, G. 2021. AI Watch. Defining Artificial Intelligence 2.0. Towards an operational definition and taxonomy for the AI landscape. Luxemburg: Euroopan unionin julkaisutoimisto. E-kirja. Saatavissa: [https://publicati-
ons.jrc.ec.europa.eu/repo-
sitory/bitstream/JRC126426/jrc126426_ai_watch_defining_artificial_intelli-
gence_2.0_final_29-10-2021.pdf](https://publications.jrc.ec.europa.eu/repository/bitstream/JRC126426/jrc126426_ai_watch_defining_artificial_intelligence_2.0_final_29-10-2021.pdf) [viitattu 27.6.2025].

Semi-Supervised Learning in Artificial Intelligence. s.a. DataRobot. Blogi. Saa-tavissa: <https://www.datarobot.com/blog/semi-supervised-learning/> [viitattu 4.7.2025].

Sharma, N., Sharma, R. & Jindal, N. 2021. Machine learning and Deep Lear-ning Applications-A Vision. *Global Transitions Proceedings* 1, 24–28. Verkko-lehti. Saatavissa: <https://doi.org/10.1016/j.gltp.2021.01.004> [viitattu 29.6.2025].

Shawn. 2019. ACS712 Current Sensor: Features, How it works, Arduino Guide. Seeedstudio. Blogi. Saatavissa: [https://www.seeedstu-
dio.com/blog/2020/02/15/acs712-current-sensor-features-how-it-works-ar-
duino-guide/?srsltid=AfmBOoqz8XEBqrvQ5DfjlqeU7Q6Qi3k-
0CeC8Le0HiFhs_1KBwpP7jqr#sidr-nav](https://www.seeedstudio.com/blog/2020/02/15/acs712-current-sensor-features-how-it-works-arduino-guide/?srsltid=AfmBOoqz8XEBqrvQ5DfjlqeU7Q6Qi3k-0CeC8Le0HiFhs_1KBwpP7jqr#sidr-nav) [viitattu 8.9.2025].

Stryker, C. & Kavlakoglu, E. 2024. What is AI? IBM. WWW-dokumentti. Päivi-tetty 9.9.2024. Saatavissa: [https://www.ibm.com/think/topics/artificial-intelli-
gence](https://www.ibm.com/think/topics/artificial-intelligence) [viitattu 27.6.2025].

Stryker, C. 2024. What is a recurrent neural network (RNN)? IBM. WWW-do-kumentti. Saatavissa: [https://www.ibm.com/think/topics/recurrent-neural-net-
works](https://www.ibm.com/think/topics/recurrent-neural-networks) [viitattu 15.7.2025].

Tolbert, C. 2025. Leveraging Variable Frequency Drive Data for Nondestructive Testing and Predictive Maintenance in Industrial Systems. *Journal of Non-Destructive Testing* 2, 1–12. Verkko-lehti. Saatavissa: <https://doi.org/10.3390/ndt3020007> [viitattu 6.10.2025].

Ucar, A., Karakose, M. & Kırımça, N. 2024. Artificial Intelligence for Predictive Maintenance Applications: Key Components, Trustworthiness, and Future Trends. *Applied Sciences* 898, 1–40. Verkko-lehti. Saatavilla: <https://doi.org/10.3390/app14020898> [viitattu 23.10.2025].

Understanding Feedforward Neural Networks (FNNs): Structure, Benefits, and Real-World Application. s.a. zilliz. WWW-dokumentti. Saatavissa: [https://zilliz.com/glossary/feedforward-neural-networks-\(fnn\)](https://zilliz.com/glossary/feedforward-neural-networks-(fnn)) [viitattu 15.7.2025].

Vuori, J. 2021. Laadullinen sisällönanalyysi. Teoksessa Vuori, J. (toim.) Laadullisen tutkimuksen verkkokäsikirja. Tampere: Yhteiskuntatieteellinen tietoaristo. E-kirja. Saatavissa: <https://www.fsd.tuni.fi/fi/palvelut/menetelmaopetus/kvali/analyysitavan-valinta-ja-yleiset-analyysitavat/laadullinen-sisallonaalyysi/> [viitattu 16.10.2025].

What is Artificial Intelligence (AI)? s.a. Google Cloud. WWW-dokumentti Saatavissa: <https://cloud.google.com/learn/what-is-artificial-intelligence> [viitattu 26.6.2025].

What is artificial intelligence? 2025. SAP. WWW- dokumentti. Saatavissa: <https://www.sap.com/products/artificial-intelligence/what-is-artificial-intelligence.html> [viitattu 18.6.2025].

What is Deep Learning? s.a. Google Cloud. WWW-dokumentti. Saatavissa: <https://cloud.google.com/discover/what-is-deep-learning> [viitattu 10.7.2025].

What Is Machine Learning (ML)? 2020. UC Berkeley School of Information. WWW-dokumentti. Päivitetty 1.2.2022. Saatavissa: <https://ischoolonline.berkeley.edu/blog/what-is-machine-learning/> [viitattu 28.6.2025].

What is machine learning? s.a. SAP. WWW-dokumentti. Saatavissa: <https://www.sap.com/products/artificial-intelligence/what-is-machine-learning.html> [viitattu 28.6.2025].

What is neural network? 2021. IBM. WWW-dokumentti. Saatavissa: <https://www.ibm.com/think/topics/neural-networks?> [viitattu 2.7.2025].

What is predictive maintenance? 2023. IBM. WWW-dokumentti. Saatavissa: <https://www.ibm.com/think/topics/predictive-maintenance> [viitattu 21.10.2025].

What is predictive maintenance? s.a. SAP. WWW-dokumentti. Saatavissa: <https://www.sap.com/products/scm/apm/what-is-predictive-maintenance.html> [viitattu 21.10.2025].

What is supervised learning? 2024. IBM. WWW-dokumentti. Saatavissa: <https://www.ibm.com/think/topics/supervised-learning> [viitattu 4.7.2024].

What is supervised learning? Machine learning tasks. 2023. SuperAnnotate. Blogi. Päivitetty 2024. Saatavissa: <https://www.superannotate.com/blog/supervised-learning-and-other-machine-learning-tasks> [viitattu 4.7.2024].

What is unsupervised learning? 2021. IBM. WWW-dokumentti. Saatavissa: <https://www.ibm.com/think/topics/unsupervised-learning> [viitattu 4.7.2025].

What is unsupervised learning? s.a. Google Cloud. WWW-dokumentti. Saatavissa: <https://cloud.google.com/discover/what-is-unsupervised-learning> [viitattu 4.7.2025].

Yasar, K., Gillis, A. & Burns, E. 2024a. What is deep learning and how does it work? TechTarget. WWW-dokumentti. Saatavissa: <https://www.techtarget.com/searchenterpriseai/definition/deep-learning-deep-neural-network> [viitattu 10.7.2025].

Yasar, K., Gillis, A. & Petersson, D. 2024b. What is supervised learning? TechTarget. WWW-dokumentti. Saatavissa: <https://www.techtarget.com/searchenterpriseai/definition/supervised-learning> [viitattu 4.7.2024].

Zhang, S., Luo, M., Qian, H., Lisheng, L., Yang, H., Zhang, Y., Liu, X., Xie, Z., Yang, L. & Zhang, W. 2023. A review of valve health diagnosis and assessment: Insights for intelligence maintenance of natural gas pipeline valves in China. *Engineering Failure Analysis* 107581. Verkkolehti. Saatavissa: <https://doi.org/10.1016/j.engfailanal.2023.107581> [viitattu 1.10.2025].

Zhengjie, L., Xiaohui, Y., Mengmeng, W., Weilei, M & Guijie, L. 2023. Leveraging deep learning techniques for ship pipeline valve leak monitoring. *Ocean Engineering* 116167. Verkkolehti. Saatavissa: <https://doi.org/10.1016/j.oceaneng.2023.116167> [viitattu 30.9.2025].

Zonta, T., Costa, C., Righi, R., Lima, M., Trindade, E. & Li, G. 2020. Predictive maintenance in the Industry 4.0: A systematic literature review. *Computers & Industrial Engineering* 106889. Verkkolehti. Saatavissa: <https://doi.org/10.1016/j.cie.2020.106889> [viitattu 24.10.2025].