KONENÄÖN HYÖDYNNETTÄVYYS AURINKOVOIMALOIDEN KUNNOSSAPIDOSSA

Lappeenrannan–Lahden teknillinen yliopisto LUT

Tuotantotalouden diplomityö

2025

Antti Kortman

Tarkastajat: Tutkijatohtori, Dosentti Lasse Metso

Yliopisto-opettaja Tiina Sinkkonen

TIIVISTELMÄ

Lappeenrannan–Lahden teknillinen yliopisto LUT

LUT Teknis-luonnontieteellinen

Tuotantotalous

Antti Kortman

Konenäön hyödynnettävyys aurinkovoimaloiden kunnossapidossa

Tuotantotalouden diplomityö

2025

84 sivua, 11 kuvaa, 5 taulukkoa ja 1 liite

Tarkastajat: Tutkijatohtori, dosentti Lasse Metso ja Yliopisto-opettaja Tiina Sinkkonen

Avainsanat: Konenäkö, Syväoppiminen, Aurinkovoima, Älykäs kunnossapito

Aurinkovoimaloiden määrän ja kokoluokan nopea kasvu on lisännyt tarvetta kustannustehokkaille sekä älykkäille kunnossapitomenetelmille. Samalla digitalisaation myötä konenäkö- sekä koneoppimisratkaisut ovat kehittyneet nopeasti ja niiden soveltaminen aurinkovoimaloiden kunnossapitoon tarjoaa uudenlaisia ratkaisumahdollisuuksia. Tämän diplomityön tavoitteena oli selvittää, miten konenäköä voidaan hyödyntää aurinkovoimaloiden kunnossapidossa ja millaista lisäarvoa se tuottaa suhteessa perinteisiin menetelmiin. Lisäksi työssä tarkasteltiin, millaisin edellytyksin ja kuinka konenäkö voitaisiin liittää osaksi kohdeyrityksen palveluprosessia.

Tutkimus toteutettiin laadullisena tapaustutkimuksena, joka koostui kirjallisuuskatsauksesta sekä empiirisestä osuudesta. Kirjallisuuskatsauksessa käsiteltiin tekoälyn, konenäön ja koneoppimisen keskeisiä aihepiirejä sekä aurinkovoimaloiden kunnossapidon menetelmiä ja kehityssuuntia. Empiirinen aineisto kerättiin kohdeyrityksen ja sen sidosryhmien edustajilta puolistrukturoiduilla teemahaastatteluilla ja sitä analysoitiin induktiivisella sisällönanalyysilla temaattisesti.

Tutkimuksessa selvisi, että konenäön avulla aurinkovoimaloiden tarkastusprosessiin voidaan saavuttaa tehokkuutta sekä tarkkuutta ja samalla parantaa prosessin resurssisitovuutta. Konenäön hyödynnettävyydelle tunnistettiin potentiaalia erityisesti suurissa voimaloissa, joissa manuaalisemmat menetelmät ovat hitaita ja kalliita. Työ tuotti kohdeyritykselle konseptitason ehdotuksen siitä, kuinka konenäkö voidaan liittää osaksi nykyistä tarkastuspalvelua sekä tunnisti jatkokehityksen kannalta keskeiset liiketoiminnalliset ja tekniset edellytykset.

ABSTRACT

Lappeenranta–Lahti University of Technology LUT

School of Engineering Science

Industrial Engineering and Management

Antti Kortman

Utilization of machine vision in the maintenance of solar power plants

Master's thesis

2025

84 pages, 11 figures, 5 tables and 1 appendix

Examiners: Post-doctoral researcher, Docent Lasse Metso and University lecturer Tiina Sinkkonen

Keywords: Machine vision, Deep learning, Photovoltaic systems, Smart maintenance

The number and size of solar power plants are growing rapidly, increasing the need for cost-effective and intelligent maintenance solutions. At the same time, digitalization has accelerated the development of machine vision and machine learning solutions and their application to solar power plant maintenance offers new opportunities for improved inspection solutions. The aim of the study was to examine how machine vision can be utilized in the maintenance of solar power plants and what added value it provides compared to traditional inspection methods. In addition, the thesis explores how a machine vision solution could be integrated into an existing service process of the case company.

The study was conducted as a qualitative case study consisting of a literature review and an empirical component. The literature review addresses key themes related to artificial intelligence, machine vision and machine learning, as well as maintenance methods and development trends in solar power plants and photovoltaic systems. Empirical data were collected through semi-structured interviews with representatives of the case company and its stakeholders and analyzed using inductive content analysis supported by thematic categorization.

The results show that machine vision can significantly improve the efficiency and accuracy of solar power plant inspection processes while reducing their labor intensity. The technology was found to be particularly beneficial for large-scale solar power plants, where traditional manual inspections are slow and costly. The thesis produced a concept-level proposal for integrating machine vision into the case company's existing inspection service and identified the key technical and business requirements for further development.

KIITOKSET

Tämän työn myötä opiskeluni LUT:issa tuotantotalouden opintojen parissa tulee päätökseen. Opiskeluaikani LUT:issa on tarjonnut elämäni tähänastista parasta aikaa. Opintovuosistani käteen jäi sekä ystäviä, että merkittävää oppia tulevaisuutta varten. Diplomityön kirjoittaminen oli erityisen opettavainen kokemus, ja tutkimuksen saattaminen päätökseen täysipäiväisen työelämän ohella vaati ponnistelua, johon en aiemmin ole joutunut. Kuten kuitenkin usein käy, sinnikkään työn tuloksena myös tämä projekti tuli päätökseensä - täytyi vain uskoa prosessiin.

Haluan esittää lämpimät kiitokset ystävilleni, perheelleni sekä erityisesti puolisolleni tukemisesta ja kärsivällisyydestä opintojeni aikana. Kiitän myös ohjaajiani sekä kohdeyrityksen että yliopiston puolelta arvokkaista näkemyksistänne ja ohjauksestanne työn eri vaiheissa. Ne auttoivat minua etenemään erityisesti tilanteissa, joissa työn eteneminen tuntui pysähtyvän.

Mikkelissä 27.11.2025

Antti Kortman

Sisällysluettelo

Tiivistelmä

Abstract

Kiitokset

1 Johdanto ... 8
1.1 Työn tausta ... 8
1.2 Tavoitteet ja rajaus ... 9
1.3 Tutkimuksen toteutus ... 10
1.4 Tutkimusraportin rakenne ... 11
2 Tekoäly ja koneoppiminen ... 13
2.1 Tekoälyn käsite ... 13
2.2 Kohteentunnistus ja konenäkö ... 16
2.3 Koneoppiminen ... 17
2.4 Neuroverkot ja konvoluutioneuroverkot ... 19
2.5 Kohteentunnistusmallin opettaminen ja validointi ... 22
3 Aurinkosähköjärjestelmät ja kunnossapito ... 24
3.1 Aurinkosähköjärjestelmien toiminta ja rakenne ... 24
3.2 Kunnossapito ja sen muodot ... 25
3.3 Aurinkovoimaloiden kunnossapito ... 30
3.4 Aurinkosähköjärjestelmien lämpökuvaus ... 31
3.5 Aurinkopaneelien vikaantumistyypit ... 32
3.6 Aurinkovoimaloiden älykäs kunnossapito ja konenäkö ... 34
4 Tutkimusmenetelmät ja toteutus ... 37
4.1 Tutkimuksen kohdeyritys ... 37
4.2 Tutkimusmetodologia ... 38
4.3 Tutkimusaineiston keruu ... 39
4.4 Tutkimusaineiston analysointi ... 41
5 Haastattelutulokset ja aineiston analyysi ... 44
5.1 Haastattelutulokset ... 44
5.2 Haastattelutulosten analyysi ... 54
6 Palvelukonseptin konstruointi ... 56

6.1 Palvelukonseptin nykytila 56
6.2 Palvelukonseptin kehitys 59
6.3 SWOT-Analyysi 63
7 Johtopäätökset ja tutkimuksen arviointi 71
7.1 Tutkimuksen keskeiset tulokset 71
7.2 Tutkimuksen luotettavuus ja rajoitteet 73
7.3 Jatkotutkimuskohteet 74
Lähteet 75

Liitteet

Liite 1. Haastattelukysymykset

ILMOITUKSET

Turnitin

Tämän opinnäytetyön alkuperäisyys on tarkistettu Turnitin – samankaltaisuuden tarkastuspalvelun avulla.

Tekoäly

Tämän opinnäytetyön kirjoittaja Antti Kortman on käyttänyt seuraavia tekoälytyökaluja opinnäytetyön tekemisessä:

1. OpenAI – ChatGPT
    a. Työkalun käytön tarkoitus: Lähdeviitteiden muotoilu, rakenteen ideointi, lähdemateriaalien etsiminen sekä kielenhuolto.
    b. Selvitys työkalun käytöstä: Lähdeluettelon alustava muotoilu annettujen ohjeiden mukaisesti, myöhemmin täydennetty ilman tekoälyä päivitetyn viittausohjeen mukaisesti. Rakennetta ideoitu työn alkuvaiheessa. Aihepiirin tutkimuksia etsitty tekoälyä hyödyntäen perinteisin menetelmin löydettyjen lähteiden tueksi. Kielenhuoltoa toteutettu työn aikana satunnaisesti tarkastamalla lausekokonaisuuksia.

Vastuu

Kirjoittaja, Antti Kortman, ottaa täyden vastuun tämän opinnäytetyön sisällöstä ja on tarkistanut ja muokannut mahdollisen tekoälytyökalujen käytön myötä syntyneen sisällön.

1 Johdanto

Johdantoluvun ensimmäisessä alaluvussa käsitellään lukijalle työn kannalta merkityksellisiä taustatietoja sekä perustellaan lukijalle tutkimuksen toteuttamisen tarpeellisuus. Lisäksi johdantoluvussa esitellään työn tavoitteet, rajaukset sekä tutkimuskysymykset, jotka ohjaavat työn suuntaa. Johdantoluvun lopussa käsitellään tutkimuksen toteutusmenetelmiä ja -periaatteita, jonka jälkeen siirrytään esittelemään työn rakenne.

1.1 Työn tausta

Aurinkoenergian rooli globaalissa energiantuotannossa on kasvanut merkittävästi viime vuosikymmeninä, kun ilmastonmuutos ohjaa energiantuotantoa kohti kestävämpiä ratkaisuja (Khan & Arsalan 2016). Aurinkosähköjärjestelmät ovat nousseet keskeiseksi menetelmäksi tuottaa uusiutuvaa ja ympäristöystävällistä energiaa yhteiskunnan käyttötarpeisiin (Jieb & Hossain 2022; Lai et al. 2017). Uusia suuren mittaluokan aurinkovoimaloita rakennetaan ja otetaan tuotantoon jatkuvasti, jolloin niiden toimintavarmuuden ja tuotannon ylläpito vaatii ratkaisuja, jotka ovat sekä tehokkaita, että varmoja (Bamisile et al. 2025). Modernien ja tehokkaiden kunnossapitoratkaisujen tarve korostuu erityisesti suurilla, teollisen mittakaavan aurinkopuistoilla, jolloin perinteiset kävelytarkastukset eivät ole enää kustannustehokas ratkaisu niiden hitauden takia suhteessa voimaloiden mittakaavaan (Abro et al. 2024).

Aurinkopaneelien käyttöiän pidentäminen sekä tuotantotehokkuuden maksimointi ovat keskeisiä tavoitteita sekä taloudellisesta, että ympäristöllisestä näkökulmasta (Babu et al. 2024). Suomessa uusia, teollisen luokan aurinkovoimaloita rakennetaan jatkuvasti ja tehokkaita sekä älykkäitä kunnossapitotoimia tukevia ratkaisuja vaaditaan. Energiaviraston (2024; 2023) mukaan Suomessa oli vuoden 2023 lopussa asennettuna teholtaan 50 megawattia teollisen mittakaavan aurinkovoimaa, mutta mikäli kaikki samaan aikaan käynnissä olleet hankkeet toteutuvat, niin teho voi nousta jopa yli 9500 megawattiin vuoteen 2030 mennessä. Työn kohdeyritys tuottaa aurinkovoimaloiden ilmasta tehtäviä lämpökuvauksia palveluna, keskittyen tähän saakka pieni- ja keskikokoisiin teollisiin aurinkovoimaloihin. Palvelun markkinoiden kasvaessa on kuitenkin löydettävä

kustannustehokkaampia keinoja tarkastusten ja tarkastusdatan analysoinnin eri vaiheille, jotta tarkastuksia pystytään toimittamaan kannattavasti niin palveluntuottajan, kuin asiakkaankin näkökulmasta.

Tässä kontekstissa konenäön integroiminen osaksi tarkastuspalvelua tarjoaa potentiaalisesti tehokkaan ratkaisun (Constantin 2023; Mellit & Benghanem 2020). Ilmasta kerättävän kuvadatan analysoiminen konenäön avulla voi mahdollistaa sekä tarkemman, että tehokkaamman tavan havaita poikkeamia aurinkosähköjärjestelmien toiminnassa (Tang et al. 2024). Tämän lisäksi miehittämättömät ilma-alukset tarjoavat tehokkaan keinon kerätä laajalta alueelta kuvadataa voimaloista (Spajić et al. 2024). Nämä elementit yhdistettynä voidaan potentiaalisesti saavuttaa merkittäviä hyötyjä aurinkovoimaloiden kuntotarkastusten tehokkuuteen, tarkkuuteen sekä resurssi-intensiivisyyteen (Corley et al. 2025).

1.2 Tavoitteet ja rajaus

Tämän diplomityön tavoitteena on selvittää, miten konenäköä voidaan hyödyntää aurinkovoimaloiden kunnossapidon tukena lämpökuvamateriaalin analysoinnissa sekä millaisia mahdollisuuksia se tarjoaa olemassa olevan tarkastuspalvelun tehostamiseen. Työssä tutkitaan konenäön soveltuvuutta osana aurinkovoimaloiden kunnossapitoprosessia, sen tuottamaa lisäarvoa sekä käyttöönoton edellytyksiä kohdeyrityksen näkökulmasta. Tutkimuksen tavoitteisiin pyritään pääsemään vastaamalla kolmeen tutkimuskysymykseen:

1) *Miten konenäköä voidaan hyödyntää aurinkovoimaloiden kunnossapidossa?*

2) *Mitä lisäarvoa kuvadataan perustuva kohteentunnistusalgoritmi tuo aurinkovoimaloiden kunnossapitoon?*

3) *Miten konenäköä hyödyntävä analytiikka voidaan liittää osaksi olemassa olevaa aurinkovoimaloiden tarkastuspalvelun konseptia?*

Tutkimus on konenäön osalta rajattu ilmasta otettujen lämpökuvien analysointiin, sillä tämä kuvantamismenetelmä on kohdeyrityksen toiminnan sekä tutkimusaiheen kannalta keskeisin.

Tutkimuksessa muodostetaan kohdeyritykselle suosituksia konenäön hyödyntämisestä osana olemassa olevaa tarkastuspalvelua. Suositukset perustuvat konenäköalgoritmien hyödynnettävyyteen osana palvelua sekä konseptin jatkokehitysmahdollisuuksiin, jotka tutkimuksen aikana on todettu. Työssä ei toteuteta varsinaista algoritmien ohjelmointia tai määrällistä suorituskyvyn arviointia, vaan keskitytään konenäköratkaisujen soveltuvuuden, hyödyntämisen edellytysten sekä liiketoiminnallisen potentiaalin tarkasteluun kohdeyrityksen palvelun kontekstissa.

1.3 Tutkimuksen toteutus

Tutkimus toteutetaan laadullisena tapaustutkimuksena, jossa tarkastellaan kohdeyrityksen aurinkovoimaloiden tarkastuspalvelun kehittämismahdollisuuksia hyödyntämällä konenäköä lämpökuvadatan analysointiin. Tutkimuksen alussa perehdyttiin aihealueen aiempaan kirjallisuuteen, tieteellisiin artikkeleihin sekä aurinkovoiman kunnossapitoon ja konenäön soveltamiseen liittyviin raportteihin. Tätä kautta tutkimukselle muodostettiin teoreettinen perusta, jonka avulla muodostettiin työn tutkimuskysymykset sekä rajaukset. Teoreettinen viitekehys rakentui tekoälyä, koneoppimista, konenäköä ja aurinkovoimaloiden kunnossapitoa käsittelevästä ajantasaisesta tutkimuksesta, jota hyödynnettiin myöhemmin tutkimuksen empiirisen osion tulosten tulkinnassa.

Työn empiirisen aineiston keruu toteutettiin puolistrukturoitujen teemahaastattelujen avulla. Haastattelujen kohteena oli kohdeyrityksen hallitus, johtoryhmä sekä keskeiset sidosryhmät. Haastattelujen tarkoituksena oli kartoittaa aurinkovoimaloiden kunnossapidon nykytilaa, markkinatarpeita sekä konenäön hyödyntämisen tuomia teknologisia sekä liiketoiminnallisia mahdollisuuksia. Haastatteluaineisto analysoitiin temaattisen sisällönanalyysin keinoin ja analyysissä tunnistettuja keskeisiä teemoja hyödynnettiin palvelukonseptin kehittämisessä.

Tutkimuskysymyksiin vastattiin tarkastelemalla haastatteluaineiston löydöksiä yhdessä kirjallisuudesta muodostettujen teorialöydösten kanssa ja tulkitsemalla niitä kokonaisuutena analyysivaiheessa. Toteutusmenetelmän valinnan myötä varmistuttiin siitä, että tutkimuksen

johtopäätökset rakentuvat sekä haastateltujen näkemyksiin, että aiempaan tutkimukseen ja alan kehityssuuntiin perustuvaan teoreettiseen ymmärrykseen.

1.4 Tutkimusraportin rakenne

Työ rakentuu seitsemästä pääluvusta. Ensimmäisenä työssä on johdantoluku, jossa käydään läpi työn tausta, tavoitteet, rajaukset, toteutusmenetelmät sekä rakenne. Johdantoluvussa käsiteltäviin asioihin kuuluu myös valittujen tutkimusmenetelmien esittely.

Tutkimuksen toinen luku avaa työn teoreettisen osuuden käsittelemällä tekoälyn ja koneoppimisen teoriaa sisältäen myös työlle oleellisten tekoälyn alakäsitteiden teoriakokonaisuuksien, kuten konenäön, syväoppimisen ja kohteentunnistuksen käsittelyn. Luku kolme on tutkimuksen toinen teorialuku, jossa käsitellään tutkimuksen kannalta tärkeää kirjallisuuteen pohjautuvaa teoriaa aurinkovoimasta, kunnossapidosta sekä aurinkovoimaloiden kunnossapidosta. Luvut 2 ja 3 rakentavat työn teoreettisen viitekehyksen luoden pohjan työssä myöhemmin käsiteltävälle empiiriselle osuudelle.

Luvussa neljä esitellään tarkemmin tutkimusmetodologia, kohdeyritys sekä tutkimusaineiston kuvaus. Luku neljä toimii siltana teoreettisen ja empiirisen osuuden välille, antaen tutkimukselliselle osuudelle sille vaadittavan pohjustuksen. Luvut viisi, kuusi ja seitsemän muodostavat työn varsinaisen empiirisen osuuden. Luvussa viisi esitellään haastattelujen tulokset sekä analysoidaan tulokset muodostaen synteesin ja perustan työn seuraavalle luvulle. Kuudennessa luvussa toteutetaan haastatteluaineiston analyysin pohjalta palvelukonseptin kehitysehdotuksen muodostaminen sekä konseptin arviointi SWOT-analyysilla. Viimeisessä eli seitsemännessä luvussa luodaan yhteenveto tehdystä tutkimuksesta vastaamalla tutkimuskysymyksiin ja jatketaan tutkimuksen tuloksia arvioimalla jatkotutkimuskohteet sekä tutkimuksen rajoitteet ja luotettavuus. Työn rakenne ja lukujen sisältö on jäsennelty input/output -kaavioon, jota esittää kuva 1.

Input Lähtötiedot työn aiheesta, tutkimustapauksen kuvaus	**Luku 1: Johdanto** Lähtötietojen jäsentely tutkimuskokonaisuudeksi	**Output** Tavoitteet, rajaus, rakenne sekä tutkimuskysymykset ja -menetelmät
Input Tekoälyn sekä sen alakäsitteiden teoreettinen kirjallisuus.	**Luku 2: Tekoäly ja koneoppiminen** Tutkimukselle oleellisten käsitteiden teoriallinen katselmointi	**Output** Kirjallisuuskatsaus ja ymmärrys tekoälyn sekä koneoppimisen käsitteistä ja alakäsitteistä.
Input Aurinkosähkön ja kunnossapidon teoreettinen kirjallisuus.	**Luku 3: Aurinkosähkö-järjestelmät ja kunnossapito** Tutkimukselle oleellisten käsitteiden teoriallinen katselmointi	**Output** Kirjallisuuskatsaus ja ymmärrys aurinkosähkön sekä kunnossapidon teoriasta.
Input Tutkimuksen lähtötiedot, tutkimusmenetelmäkirjallisuus	**Luku 4: Tutkimus-menetelmät ja toteutus** Valittujen tutkimusmenetelmien esitteleminen ja perustelu	**Output** Kohdeyrityksen esittely, tutkimusmetodologia, tutkimusaineiston kuvaus
Input Haastatteluaineistot	**Luku 5: Haastattelutulokset ja analyysi** Haastattelutulosten esittely ja analysointi	**Output** Analyysi konenäköä hyödyntävän konseptin liiketoiminta- ja markkinatarpeesta.
Input Luvun 5 output. Kirjallisuus konenäön mahdollisuuksista aurinkopaneeleiden kunnontarkastuksessa.	**Luku 6: Palvelukonseptin konstruointi** Tulosten ja kirjallisuuden perusteella ehdotusten muodostaminen ja arviointi.	**Output** Konenäköä hyödyntävän palvelun konseptuaalinen ehdotus.
Input Tutkimuksen tausta ja tavoitteet, kirjallisuuden ja aineistojen analyysin tulokset ja johtopäätökset	**Luku 7: Johtopäätökset ja tutkimuksen arviointi** Tulosten käsittely, jatkotutkimuskohteiden ja luotettavuuden arviointi	**Output** Vastaukset tutkimuskysymyksiin, tutkimuksen rajoitteet, luotettavuus ja jatkotutkimuskohteet

Kuva 1: Tutkimuksen input/output -kaavio

2 Tekoäly ja koneoppiminen

Jotta konenäkömallien hyödynnettävyyttä voidaan arvioida tutkimuksessa, edellytetään ymmärrystä tekoälyn ja koneoppimisen keskeisistä käsitteistä sekä toimintaperiaatteista. Luvun tarkoituksena on esitellä tekoälyn, koneoppimisen sekä konenäön taustaa ja luoda teoreettinen pohja myöhemmin työssä käsiteltäviin konenäköön perustuviin tarkastusmenetelmiin sekä niiden soveltuvuuden arvioinnille aurinkovoimaloiden kunnossapidossa. Luvussa käsitellään tekoälyn ja koneoppimisen perusteita, kehitystä sekä sovelluksia, jotka ovat olennaisia ymmärtääksemme näiden teknologioiden varsinaisen vaikutuksen sekä tutkimuskohteeseen, että myös laajemmin eri toimialoille.

2.1 Tekoälyn käsite

Tekoäly ja koneoppiminen ovat mullistaneet mahdollisuutemme käsitellä ja analysoida saatavilla olevaa tietoa, tarjoten uusia ja innovatiivisia sovelluskohteita eri tieteenhaaroille sekä toimialoille. Tekoälyllä tarkoitetaan koneita ja järjestelmiä, joilla on kyky suorittaa tehtäviä, jotka vaativat ihmisenkaltaista älykkyyttä sekä loogista päättely- ja ongelmanratkaisukykyä (Jakhar & Kaur 2020). Koneoppimisella puolestaan viitataan algoritmeihin, jotka voivat oppia ja joita voidaan opettaa tekemään päätöksiä tai ennusteita datan perusteella ilman, että niitä ohjelmoidaan erikseen tekemään näin (Janiesch et al. 2021; Lecun et al. 2015). Viime vuosien aikana tapahtuneet kehitysaskeleet alalla ovat osoittaneet koneoppimisen soveltuvuuden moninaisiin sovellusalueisiin, kuten kuvantunnistukseen, ennakoivan analytiikkaan sekä luonnollisen kielen analysointiin ja generointiin (Jiao & Zhao 2019; Khurana et al. 2023). Tämä toimii myös osoituksena sen potentiaalista tulevaisuuden teknologioiden kehittämisessä.

Kuva 2 esittää tekoälyn käsitteellistä hierarkiaa. Kuvan mukaisesti tekoäly toimii kokonaisuudessa ylimpänä tasona (Mueller & Massaron 2019). Tekoälyn alle hierarkiassa sijoittuu koneoppiminen, joka on joukko menetelmiä, jonka avulla järjestelmät kykenevät oppimaan datasta toistuvia kuvioita tai rakenteita ilman erillistä ohjelmointia (Alpaydin 2014). Koneoppimisesta käsitteet jakautuvat kahteen merkittävään koneoppimisen

alahaaraan: syväoppimiseen ja konenäköön. Syväoppiminen perustuu monikerroksisiin neuroverkkoihin, joka mahdollistaa erityisesti kuvien monimutkaisen analyysin (LeCun et al. 2015). Konenäkö taas keskittyy koneiden kykyyn tulkita ja analysoida visuaalista dataa (Zou et al. 2023). Kun yhdistetään konenäön ja syväoppimisen ominaisuudet päästään kohteentunnistuksen menetelmiin, jotka ovat keskeisessä roolissa työn tutkimuskohteen kannalta (Zhao et al. 2019; Zou et al. 2023). Yleisesti ottaen kohteentunnistus kuitenkin nähdään konenäön osa-alueena (LeCun et al. 2015). Terminologian yhtenäistämisen kannalta työn myöhemmissä vaiheissa konenäköä käytetään kattoterminä, jonka alle sijoittuvat kohteentunnistus- sekä syväoppimisratkaisut.

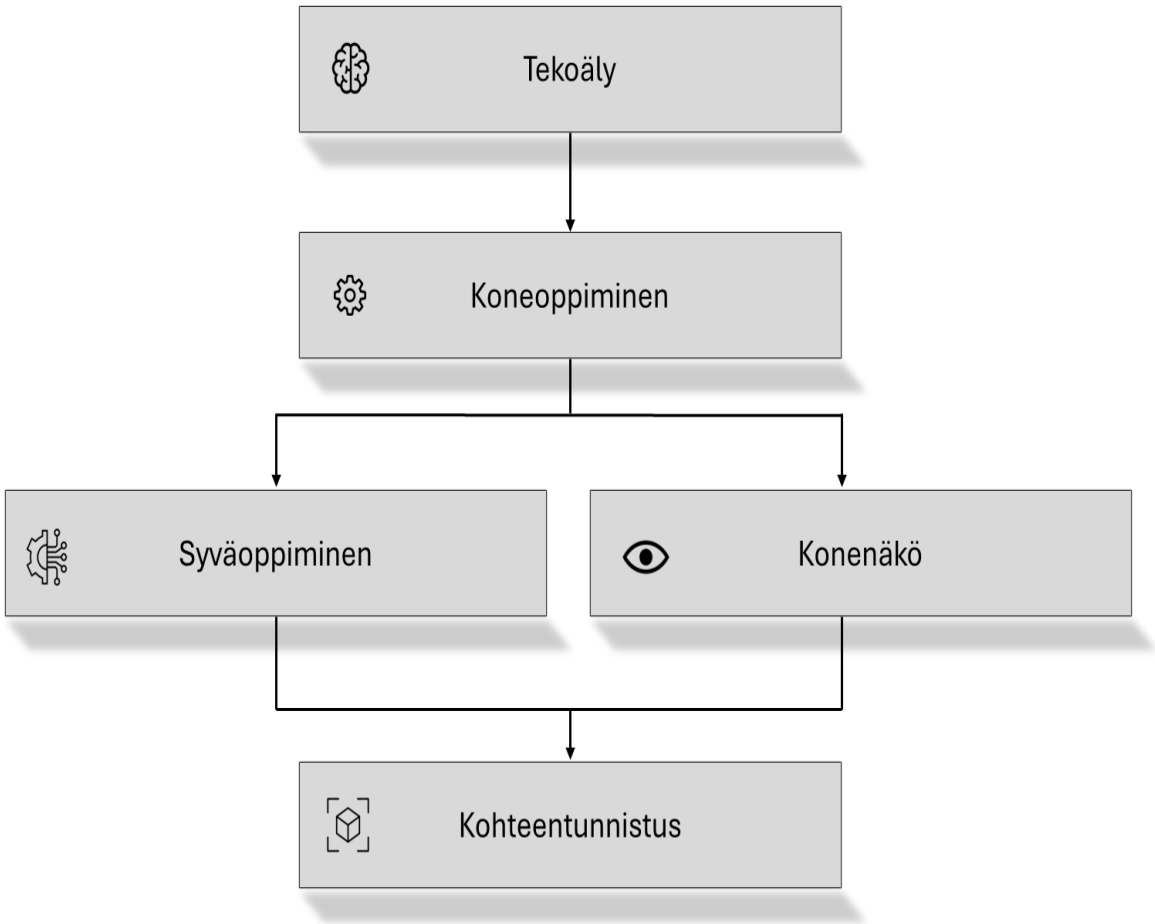

Kuva 2: Tekoäly ja sen alahaarat hierarkisesti järjesteltynä (mukaillen Mueller & Massaron 2019)

Tekoäly on raivannut tiensä yhdeksi teknologisten innovaatioiden keskeisimmäksi voimaksi viime vuosina. Tekoäly käsitteenä sai syntynsä vuonna 1956, kun Dartmouthin yliopistossa käynnistettiin projekti, jonka tavoitteena oli luoda koneita, jotka olisivat kyvykkäitä

jäljittelemään ihmisälyä (Buchanan 2005; Moor 2006). Koneoppiminen puolestaan nähdään olevan tekoälyn tutkimuksen aikaansaama tuote (Lecun et al. 2015). Ensimmäisenä koneoppimisen sovelluksena nähdään Arthur Samuelin luoma tietokoneohjelma, joka kykeni oppimaan pelaamaan shakkia sekä analysoimaan pelityylejä, joilla häviämisen mahdollisuus olisi mahdollisimman pieni (Fogel 2002).

Kohteentunnistus on ollut yksi konenäön tutkituimmista tutkimuskohteista sen varhaisvaiheista lähtien. Sen päämääränä on luokitella kuvissa näkyvät objektit ennalta määriteltyihin ryhmiin tai kategorioihin. Vaikka tehtävä vaikuttaakin päällin puolin yksinkertaiselta, se on vuosien kuluessa osoittautunut monimutkaiseksi haasteeksi, sillä tunnistettavien objektien sekä kuvien ominaisuudet voivat vaihdella suuresti (Neittaanmäki & Tuominen 2019). Esimerkiksi objektien piirteiden monimuotoisuus, kuvien valotus sekä kuvakulma ovat vaikuttavia tekijöitä kohteiden tunnistettavuuteen (Ahmed et al. 2021). Myöhemmin tähän haasteeseen on pyritty vastaamaan kehittämällä erilaisia malleja sekä menetelmiä, jotka parantavat myös monimuotoisten objektien tunnistustarkkuutta. (Lecun et al. 2015; Zhao et al. 2019)

Kohteentunnistuksen tutkiminen ja harjoittaminen koki 2000-luvulla nousun ja vuonna 2001 nähtiinkin ensimmäinen reaaliajassa toimiva kasvojentunnistusalgoritmi, joka nimettiin algoritmin kehittäjien Paul Violan ja Michael Jonesin mukaan Viola-Jones algoritmiksi. Viola-Jones algoritmi vaati paljon laskentatehoa, jota tuohon aikaan ei ollut koneisiin tarjolla. Teknologisten kehitysaskelten, joista etenkin näytönohjainten kehitysten myötä yhä nopeampien kohteentunnistusalgoritmien kehitys on kokenut merkittävän kasvun. (Wai et al. 2015)

Varsinaisen kohteentunnistuksen sekä yleisesti ottaen koneoppimisen aikakauden voidaan nähdä alkaneen vuoden 2012 aikana, kun tietotekniset kehitysaskeleet saavuttivat tason, joka mahdollisti neuroverkkojen ja syväoppimisen hyödyntämisen (Schmidhuber 2015). Tältä ajanjaksolta merkittävänä kehitysaskeleena voidaan pitää Alex Krizhevskyn ja kanssatutkijoiden kehittämän AlexNet konvoluutioneuroverkon esittelyä, jonka myötä grafiikkasuorittimien laskentatehoa hyödyntävien konvoluutioneuroverkkojen käyttäminen kohteentunnistuksessa koki merkittävää kasvua (Krizhevsky et al. 2017). Syväoppimisen ja neuroverkkojen kehityksen myötä mahdollistui automaattinen ja huomattavasti tehokkaampi ominaispiirteiden oppiminen kuvadatasta, mikä on johtanut tunnistustarkkuuden ja -nopeuden merkittävään parantumiseen (LeCun et al. 2015). Erityisesti graafisten

prosessointiyksiköiden parantunut käsittelykapasiteetti on ollut olennaisessa osassa nopeiden, neuroverkkopohjaisten kohteentunnistusjärjestelmien kehityksessä (Lecun et al. 1998). Suurin osa tämän päivän kohteentunnistusalgoritmeista perustuu syvien neuroverkkojen toimintaan (Zou et al. 2023).

2.2 Kohteentunnistus ja konenäkö

Konenäkö mahdollistaa koneiden sekä järjestelmien kyvyn havaita, tulkita ja prosessoida visuaalista informaatiota ympäristöstään (Zhao et al. 2019). Konenäön toiminta jäljittelee ihmisen näkökykyä sekä siihen perustuvaa havainnointikykyä (Serey et al. 2023). Kohteentunnistuksella puolestaan tarkoitetaan konenäön tehtävää, jonka tarkoituksena on tunnistaa visuaalisia objekteja sekä pystyä lajittelemaan ne tiettyihin luokkiin (Malhotra & Garg 2020; Kellil et al. 2025). Luokkana voi toimia yksinkertaistettuna esimerkkinä autot, ihmiset tai eläimet (Zou et al. 2023).

Kohteentunnistuksen kehitykseen on vaikuttanut merkittävästi koneoppimisen modernien teknologioiden, kuten konvoluutioneuroverkkojen kehittyminen, joka on aikaansaanut mahdollisuuden suorittaa kohteentunnistusta huomattavasti tarkemmin sekä tehokkaammin. Tarkkuus ja tehokkuus ovatkin kohteentunnistuksen toimivuuden kaksi tärkeintä mittaria. (Zou et al. 2023)

Nykypäivänä kohteita pystytään tunnistamaan reaaliaikaisesti suurella tarkkuudella ja tehokkuudella syväoppivien algoritmien laaja-alaisen käytön ansiosta (Zou et al. 2023). Alan kehitys on mahdollistanut monimutkaisissa ympäristöissä toimivien tunnistusjärjestelmien luotettavan toteutuksen, kun käytetään edistyneitä malleja kuten Faster R-CNN, Mask-R-CNN ja YOLO (Malhotra & Garg 2020; He et al. 2017). Kohteentunnistusratkaisujen lisäksi aurinkopaneelien ja muiden visuaalisten aineistojen analysoinnissa hyödynnetään nykyään yhä useammin myös ohjaamattoman oppimisen menetelmiä, kuten autoencoder-neuroverkkoja, jotka soveltuvat piilevien piirteiden oppimiseen ja poikkeamien tunnistukseen ilman erillisiä luokkamerkintöjä (Li et al. 2023). Autoencodereita on hyödynnetty esimerkiksi anomaliatunnistuksessa, jossa tavoitteena on tunnistaa poikkeavat kohteet normaalien seasta (Vlaminck et al. 2022).

Faster R-CNN, Mask R-CNN ja YOLO ovat kohteentunnistukseen kehitettyjä neuroverkkoarkkitehtuureja, jotka ovat luotu erityisesti kohteentunnistukseen. Arkkitehtuurit hyödyntävät syväoppimista, eli ne oppivat suurista määristä kuvadataa, miltä eri objektit näyttävät, jopa eri kuvakulmissa ja valaistusolosuhteissa. Faster R-CNN on kaksivaiheinen arkkitehtuuri, joka etsii ensiksi kuvista mahdollisia ehdokkaita tunnistettaville kohteille, jonka jälkeen se käy ehdokkaat läpi erikseen. Tämä arkkitehtuuri on tarkka, mutta hieman hitaampi, kuin vielä modernimmat arkkitehtuurit ja siksi se soveltuu paremmin käyttötarkoituksiin, joissa tarkkuus on tärkeämpää, kuin nopeus. YOLO taas käsittelee koko kuvan yhdellä kertaa hyvällä tarkkuudella, joka tekee siitä erittäin nopean ja näin ollen se soveltuu paremmin reaaliaikaiseen tunnistukseen. Mask R-CNN puolestaan kykenee tarkkaan muodon analyysiin ja esimerkiksi osittain peittyneiden alueiden tarkempaan rajaukseen, eli segmentointiin, mikä tekee siitä erinomaisen esimerkiksi aurinkopaneelien tunnistuksessa. (He et al. 2017; Sumit et al. 2020; Zhao et al. 2019)

Teollisuudessa kohteentunnistusta ja konenäköä on hyödynnetty jo onnistuneesti eri prosesseissa tuomaan tehokkuutta tai parantamaan prosessin laatua. Esimerkkinä konenäön hyödyntämisestä valmistavasta teollisuudesta on laadunhallinnan parantaminen, jossa konenäkösovellus on kytketty osaksi tuotantoprosessia tarkkailemaan valmistettujen komponenttien laatua ja poistamaan valmistusvirheelliset komponentit ennen kuin ne etenevät tuotantoketjussa pidemmälle (Landgraf et al. 2023). Vastaavasti YOLO-arkkitehtuuripohjaista konenäköä on hyödynnetty rakennustyömailla turvallisuuden parantamiseen tunnistamalla, onko työmaalla liikkuvilla henkilöillä turvavarusteet käytössä (Shetye et al. 2023).

2.3 Koneoppiminen

Koneoppiminen on tekoälyn yksi keskeisimmistä haaroista. Koneoppimisen perustarkoituksena on mahdollistaa tietokoneiden itsenäinen oppiminen annetusta datasta ilman, että sitä erikseen ohjelmoidaan tekemään niin (LeCun et al. 2015; Jakhar & Kaur 2020). Koneoppimisen perusperiaatteisiin kuuluu ohjelmiston kyky tunnistaa toistuvia kuvioita ja rakenteita annetussa datassa, mikä luo mahdollisuuden sille tehdä ennusteita uudesta datasta aiemmin saamiensa oppien perusteella (Janiesch et al. 2021).

Koneoppiminen on jaettavissa kolmeen eri pääkategoriaan: ohjattuun oppimiseen, ohjaamattomaan oppimiseen sekä vahvistusoppimiseen. (Alpaydin 2014; Braga-Neto 2024)

Ohjatulla oppimisella tarkoitetaan koneoppimisalgoritmia, jota koulutetaan opetusaineistolla, johon on merkitty sille opetettava tieto. Toisin sanoen ohjatussa oppimisessa opetusdata sisältää merkittynä syötteen sekä selitteen, jonka avulla malli oppii tunnistamaan opetusdatan syötetietoihin perustuen luokalle ominaisia piirteitä. Ohjattua oppimista hyödyntävä algoritmi pyrkii siis opettelemaan syötteiden ja osoitetun tuloksen rakenteellisen suhteen osatakseen tunnistaa asioita uudesta, vielä näkemättömästä datasta. Ohjattu oppiminen on yleisin koneoppimisen muoto ja sitä hyödynnetään laajalti tehtävissä, joissa mallille on syötettävissä esimerkkejä halutusta käyttäytymisestä, kuten kuvantunnistuksessa ja kielenkäsittelyssä. Ohjatusta oppimisesta yksinkertaistettuna esimerkkinä voidaan käyttää esimerkiksi algoritmia, joka opetetaan tunnistamaan sähköposteista roskapostit. Syöteaineistona kyseisen algoritmin opettamiseen voidaan käyttää tekstisisältöä ja merkitä se joko luokkaan ”roskaposti (1)” tai ”ei roskaposti (0)”. Kun opetusdataa on algoritmille syötetty tarpeeksi, alkaa se tunnistamaan ennalta merkitsemättömistä viesteistä, kuuluvatko ne roskapostiin vai eivät. (Gupta et al. 2022; Hu et al. 2021)

Siinä missä ohjatun oppimisen algoritmit pyrkivät ennustamaan tai luokittelemaan dataa sille aiemmin syötetyn opetusdatan perusteella, pyrkivät ohjaamattoman oppimisen algoritmit löytämään syötedatasta piileviä rakenteellisia yhtäläisyyksiä tai ominaisuuksia ilman opetusdatana käytettyjä tulossyötteitä (Berry et al., 2020). Toisin muotoiltuna ohjatussa oppimisessa käytetään opetusdataa, joka sisältää merkittynä myöhemmin uudesta datasta ennustettavan tuloksen, kun taas ohjaamattomassa oppimisessa algoritmi pyrkii itse löytämään datasta säännöllisiä jatkuvuuksia tai yhtäläisyyksiä. Ohjaamatonta oppimista on perinteisesti käytetty esimerkiksi klusterointitehtäviin. Yleinen esimerkki ohjaamattoman oppimisen hyödyntämisestä on esimerkiksi asiakasklusterointialgoritmit verkkokaupoissa, jotka pystyvät tunnistamaan asiakkaiden ostokäyttäytymisistä yhtäläisyyksiä ja jaottelemaan asiakkaat tämän myötä segmentteihin. Vastaavanlaiset algoritmit pystyvät myös oppimaan tunnistamaan esimerkiksi, mitä tuotteita ostetaan usein yhdessä. (Hemadharshini et al. 2024; Li et al. 2020)

Kolmannella koneoppimisen muodolla, vahvistusoppimisella puolestaan tarkoitetaan koneoppimista, jossa algoritmi pyrkii maksimoimaan toimintansa tehokkuuden kokeilun ja

erehdyksen kautta. Algoritmin oppiminen perustuu sen saamaansa palkinto- tai rangaistuspalautteeseen. Algoritmi kokeilee satunnaisesti eri strategioita ratkaisemaan sille määritetyn ongelman ja pitkällä aikavälillä pyrkii löytämään toimintatavan, jolla se onnistui maksimoimaan saamansa palkinnon. Algoritmin saama palkinto perustuu siihen, kuinka hyvin se on pystynyt ratkaisemaan sille määritetyn ongelman. Yhtenä esimerkkinä vahvistusoppimisesta voidaan käyttää ajoneuvon ohjausalgoritmia, joka oppii simulaatioympäristössään ohjaamaan autoa halutussa ympäristössä törmäämättä esteisiin. Simulaatioympäristönä voi olla esimerkiksi videopeli, jossa algoritmi kokeilee eri ohjausstrategioita ja saa rangaistuksia törmäyksistä ja vastaavasti palkkioita onnistuneista ohjauspäätöksistä. Saman tyylistä menetelmää on käytetty myös autonomisten ajoneuvojen ohjausalgoritmien kehityksessä. (Nian et al. 2020; Ye et al., 2021)

2.4 Neuroverkot ja konvoluutioneuroverkot

Neuroverkot ovat koneoppimisen menetelmiä, jotka hyödyntävät samoja periaatteita toiminnassaan, kuten ihmisen aivot. Neuroverkot koostuvat suuresta määrästä verkostomaisesti toisiinsa kytkeytyneistä neuroneista. Neuroverkot pyrkivät jäljittelemään aivojen hermoverkkojen toimintaa tietojen käsittelyn, muistin ja oppimisen osalta. Neuroverkot ovat keskeinen osa-alue moderneja kohteentunnistusmenetelmiä, mutta ne soveltuvat muihinkin käyttökohteisiin, kuten luonnollisen kielen käsittelyyn tai perinteisen taulukkomuotoisen datan luokitteluun. (Wu & Feng 2018; Zhao et al 2019; Zou et al. 2023)

Neuronit ovat järjestetty tyypillisesti kerrosmaiseen järjestelmään neuroverkkojen sisällä. Neuronikerrokset jaetaan usein syöte-, piilo- ja ulostulokerroksiin. Syötekerroksen tehtävänä on vastaanottaa syötetietoa sekä muuntaa se neuroverkolle käsiteltävään muotoon. Piilokerrokset käsittelevät ja jalostavat tietoa laskennallisin operaatioin. Piilokerroksia saattaa olla useampia ja tiedon kulkiessa niiden sisältämien funktioiden läpi, mahdollistuu syötedatasta piilevien yhteneväisyyksien oppiminen ja tunnistaminen. Ulostulokerros lopulta tuottaa näiden aikaisempien vaiheiden perusteella tuloksen, kuten ennusteen. Näiden edellä mainittujen kerrosten neuronit eivät kuitenkaan toimi täysin itsenäisesti, vaan niiden toiminta perustuu painoarvoihin, vakiotermeihin sekä aktivointifunktioon. Kuva 3 esittää neuroverkon rakennetta sisältäen syöte-, piilo- ja ulostulokerroksen neuronit x_i, a_i ja t sekä

neuronien väliset painokertoimet w ja piilokerroksen neuronien vakiotermit b_i. (Albawi et al. 2017; Neittaanmäki & Tuominen 2019)

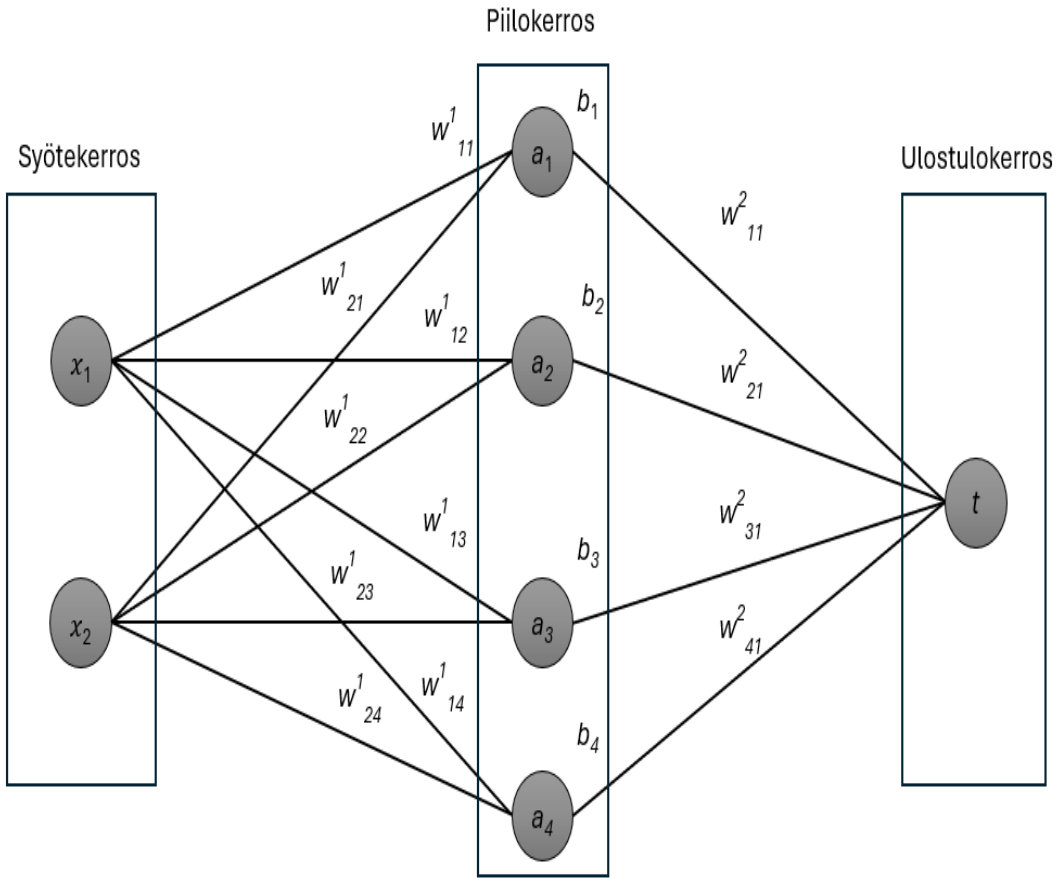

Kuva 3: Yhden piilokerroksen neuroverkon rakenne (Neittaanmäki & Tuominen 2019)

Silloin, kun neuroverkkoarkkitehtuurissa piilokerroksia on useita, puhutaan syväoppimisesta. Syväoppiminen soveltuu hyvin kohteentunnistukseen sen rakenteen vuoksi, jossa ensimmäiset kerrokset pystyvät tunnistamaan yksinkertaisempia piirteitä kuvasta ja myöhemmät kerrokset yhdistävät näitä tietoja luomaan abstraktimpien kokonaisuuksien tunnistuksia. Kun piilokerroksia neuroverkossa on useampia, nousee myös opetettavien parametrien määrä. Kun puolestaan opetettavien parametrien määrä nousee, myös tarvittavan opetusdatan määrä nousee. Tämä voi johtaa laskennan kuormittavuuden ongelmiin varsinkin, jos neuroverkkoarkkitehtuuri on monimutkainen. (LeCun et al. 2015; Neittaanmäki & Tuominen 2019)

Siinä missä perinteiset neuroverkot ovat monikäyttöisiä ja soveltuvat useampiin käyttökohteisiin, ovat syväoppimiseen perustuvat konvoluutioneuroverkot puolestaan rakenteeltaan optimaalisempia nimenomaan kohteentunnistuksen ja konenäön sovelluksissa. Konvoluutioverkkojen tehokkuus kohteentunnistuksen tehtävissä perustuu siihen, että syötekerroksessa tarkasteltava kuva jaetaan erikseen tarkasteltaviin alueisiin sen sijaan, että tutkittaisiin jokainen kuvan pikseli erikseen. Tämän lisäksi konvoluutioneuroverkoissa suoritetaan konvoluutio-operaatioita, jotka hyödyntävät paikallisesti painotettuja suodattimia. Painotettujen suodattimien tehtävä on liikkua kuvan päällä alueittain ja luoda kuvan käsitellyistä pikseliryhmistä aktivointeja, jotka voidaan yhdistää kuvan piirteiksi. (Albawi et al. 2017; Neittaanmäki & Tuominen 2019)

Konvoluutioneuroverkkojen rakenne koostuu kolmesta oleellisesta elementistä, konvoluutiotasosta, pooling-tasosta ja täysin yhdistetystä tasosta (ks. Kuva 4). Konvoluutiotasolla suoritetaan varsinainen ominaisuuksien etsintä, jossa suodattimet havaitsevat yleisiä piirteitä kuvasta, kuten reunoja, selkeitä tekstuureja ja kulmia muodostaen piirteistä ominaisuuskartan. Piirteiden havaitseminen ja etsintä tapahtuu konvoluutiotasossa edellä mainituilla painotetuilla suodattimilla. Nämä havaitut piirteet siirtyvät seuraaviin neuroverkon tasoihin, jossa havaituista piirteistä yhdistellään suurempia ja monimutkaisempia kokonaisuuksia. Prosessin edetessä konvoluutioneuroverkko oppii tunnistamaan abstraktimpia piirteitä, kuten objekteja tai muotoja, mikä tekee siitä erityisen hyödyllisen monimutkaisessa kuvantunnistuksessa. (Goodfellow et al. 2016; Rawat & Wang 2017)

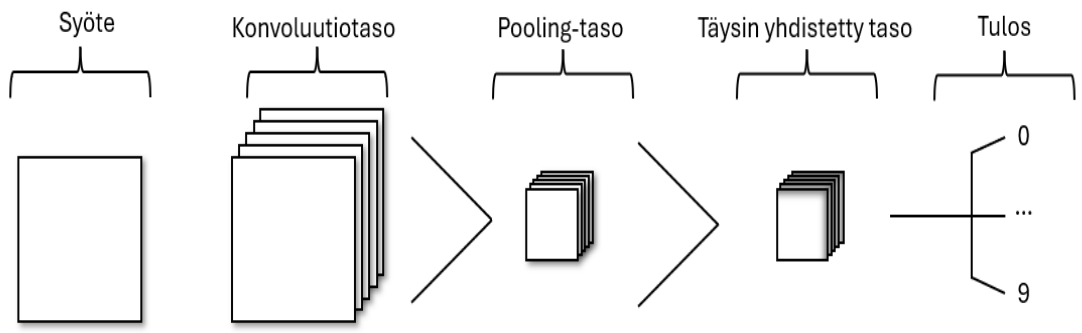

Kuva 4:Konvoluutioneuroverkon yksinkertaistettu arkkitehtuurikuvaus (mukaillen O'Shea & Nash 2015)

Pooling-layereiden tehtävänä on pienentää konvoluutiotasossa muodostettujen ominaisuuskarttojen kokoa, jolloin neuroverkosta tulee laskennallisesti kevyempi. Tämän lisäksi ominaisuuskarttojen pienentäminen auttaa neuroverkkoa olemaan vähemmän herkkä syötedatan pienille eroavaisuuksille. Ominaisuuskarttojen pienentäminen tapahtuu pooling-operaatioilla, kuten maksimi- tai keskiarvofunktio, jossa ominaisuuskartasta osia saadaan skaalattua pienemmäksi laskemalla niiden keskiarvo tai valitsemalla alueen maksimiarvo. Pooling-tasossa tapahtuvat pooling-operaatiot vähentävät myös mahdollisuutta ylioppimiselle, jolla tarkoitetaan tilannetta, jossa neuroverkko oppii liian hyvin syötedatan yksityiskohtaiset piirteet ja näin ollen, ei osaa tunnistaa yleisempiä piirteitä uusista kuvista. Pooling-tasossa tapahtuvat, edellä mainitut toiminnallisuudet mahdollistavat neuroverkon tehokkaamman oppimisen varsinkin runsasmääräisillä ja laadultaan monimuotoisilla syötedatoilla. (Albawi et al. 2017; Goodfellow et al. 2016)

Täysin yhdistetty taso toimii kuten aiemmin kappaleessa kuvailtu perinteinen neuroverkko. Täysin yhdistetty tason tehtävänä on konvoluutioneuroverkon loppuvaiheessa yhdistää käsitellyt piirteet ja tehdä niiden perusteella kohteen luokittelu perustuen neuroverkon tekemään ennusteeseen. Esimerkkinä aurinkovoimaloiden kohdalla täysin yhdistetyssä tasossa voidaan yhdistää konvoluutio- ja pooling-tasolta saatuja piirteitä paneelien poikkeamien havaitsemiseksi (Jumaboev et al. 2022).

2.5 Kohteentunnistusmallin opettaminen ja validointi

Kohteentunnistuksen sovellukset ovat pääsääntöisesti ennustetehtäviä, joissa kohteentunnistusmallia opetetaan tekemään kohteista ennusteita, jotka vastaavat mahdollisimman tarkasti totuutta (Zhao et al. 2019; Zou et al. 2023). Kohteentunnistuksessa käytettäessä kuvadataa voidaan todeta käytetyn datan olevan diskreettiä, eli luokiteltavissa olevaa dataa. Kohteentunnistuksessa useimmat ennustetehtävät ovatkin luokittelutehtäviä, jossa koneoppimismallin tehtävä on asettaa kuvassa oleva objekti oikeaan luokkaan. Luokittelutyyppiset ennusteet ovat mahdollisia tuottaa vain diskreetistä datasta. Mikäli data on jatkuvaa liittyvät siitä tehtävät ennusteet useimmiten regressiotehtäviin, joissa lopputuloksena on tavoitteena tehdä numeerisien arvojen ennusteita. (Neittaanmäki & Tuominen 2019)

Kohteentunnistuksessa perinteisesti yleisin käytetty menetelmä on ohjattu oppiminen (Zhao et al. 2019). Ohjatussa oppimisessa mallia opetetaan syöttämällä sille merkittyä kuvadataa, johon on merkattu opetettava objekti annotaatiolla, eli luokkamerkinnällä (Berry et al. 2020). Kuvadataan on merkitty pohjatotuusmerkinnät kuvan sisältämästä, opetettavasta objektista (Sumit et al. 2020). Toisin sanoen pohjatotuusmerkinnät esittävät, mitä kuvassa esiintyy ja missä esiintyvä objekti sijaitsee. Kun mallille syötetään suurempi määrä kuvadataa, jossa opetettavan kohteen pohjatotuusmerkinnät ovat tehty, oppii malli vähitellen tunnistamaan objektin keskeiset tunnuspiirteet ja erottelemaan sen muista kohteista tunnistuslaatikon avulla. Tunnistuslaatikko on kohteentunnistuksen tuottama suorakulmion muotoinen rajaus, joka määrittää tekemänsä ennusteen sijainnin ja koon kuvassa (Zhao et al. 2019).

Aurinkopaneelien lämpöpoikkeamia havaitsevan mallin kouluttaminen tapahtuisi ohjatun oppimisen keinoin, jolloin mallin opetusmateriaaleina toimii ilmasta otetut lämpökuvat (Imenes et al. 2021; Vlaminck et al. 2022). Mallille opetukseen käytettävät kuvat tulee ensiksi annotoida, eli merkitä pohjatotuusmerkinnöillä (Korkmaz & Acikgoz 2022). Annotaatioissa määritetään lämpöpoikkeaman sijainti sekä tyyppi, jolloin malli oppii erottamaan normaalin ja poikkeavalta vaikuttavan paneelirakenteen toisistaan. Tällainen opetusprosessi mahdollistaa sen, että koulutuksen jälkeen malli kykenee automaattisesti analysoimaan uusia kuvia aurinkopaneeliryhmistä ja havaitsemaan kunnossapitoa vaativat kohteet suurella tarkkuudella ja nopeudella (Mellit & Kalogirou 2025).

3 Aurinkosähköjärjestelmät ja kunnossapito

Tämän luvun tarkoituksena on antaa teoreettinen ymmärrys lukijalle aurinkosähköjärjestelmistä sekä niiden kunnossapidosta. Luvussa käsitellään aurinkosähköjärjestelmien toimintaperiaatteet, kunnossapidon merkitys, keskeiset toimintatavat sekä älykkäiden kunnossapitoratkaisujen rooli suurten aurinkovoimaloiden ylläpidossa.

3.1 Aurinkosähköjärjestelmien toiminta ja rakenne

Aurinkopaneelien tehtävänä on tuottaa tasasähköä auringon säteilyenergiasta. Tasasähköä aurinkopaneeli tuottaa fotovoltaisilla kennoilla niiden altistuessa valosäteilyn fotoneille. Kun tasasähköä tuottavat, puolijohdemateriaaleista valmistetut fotovoltaiset kennot asennetaan paneeliin sarjaan kytkettynä, saadaan niiden tuottama jännite kasvamaan. Sarjaan kytkettynä kennot muodostavat aurinkopaneelin, jonka tuottaessa tarpeeksi korkeaa tasavirtaa mahdollistuu energianmuuntaminen vaihtovirraksi ja näin edelleen käytettäväksi. Paneelin sisäisesti kennorivejä voidaan kytkeä myös rinnan, kunhan sarjaan kytkettyjä kennoja on tarpeeksi monta varmistamaan riittävän jännitetason. Rinnan kytkettynä paneelin tuottama virta kasvaa, mutta jännite pysyy samana (Green 2000; Singh 2013; Nozik & Miller 2010)

Paneeliketjuiksi aurinkopaneelit asennetaan sarjaan kytkettyinä, jolloin niiden jännite on korkea, mutta virranantokyky matala. Aurinkopaneeliketjut taas puolestaan kytketään keskenään rinnan, jolloin myös virranantokyky saadaan nousemaan. Tämä kytkentärakenne on siinä mielessä tärkeä, että saadaan varmistettua riittävä jännitetaso energian muuntamisen mahdollistamiseksi, mutta myös virranantokyky on tarpeeksi suuri tehokkaalle energiantuotannolle. Kun jännitetaso on riittävän korkea, voidaan aurinkosähköjärjestelmä kytkeä invertteriin, jonka avulla tasavirta muunnetaan vaihtovirraksi ja voidaan kytkeä verkkoon tai akustoon edelleen käytettäväksi. (Green 2000; Singh 2013)

Aurinkopaneeleissa on usein käytetty myös suojamekanismeja, jotta luotettavasta toiminnasta voidaan mahdollisimman pitkälle varmistua. Lähes aina aurinkopaneeli on

varusteltu ohitusdiodeilla, joiden tehtävä on ohittaa paneelin sisällä oleva sarjaan kytketty kennoketju, mikäli siitä yksi kenno on vioittunut tai esimerkiksi varjostunut. Tällä suojamekanismilla vältytään suuremmilta tuotannonmenetyksiltä. Perinteisesti yhdessä paneelissa on kolme kennoketjua ja näin ollen myös kolme ohitusdiodia, eli yksi ohitusdiodi jokaista kennoketjua kohden. (Green 2000; Singh 2013)

Aurinkosähköjärjestelmien rakenteen ja toimintaperiaatteiden ymmärtäminen on keskeistä, kun tutkitaan näiden järjestelmien tarkastus- sekä kunnossapitoprosesseja, kuten tässä työssä tehdään. Vikaantumiset tai toimintapoikkeamat aurinkopaneelissa voivat tapahtua yksittäisten aurinkokennojen, paneelien tai jopa koko paneeliketjun tasolla. Kuva 5 esittää yksinkertaistettua kuvaa aurinkosähköjärjestelmästä. (Hindocha & Shah 2020; Restrepo-Cuestas et al. 2025)

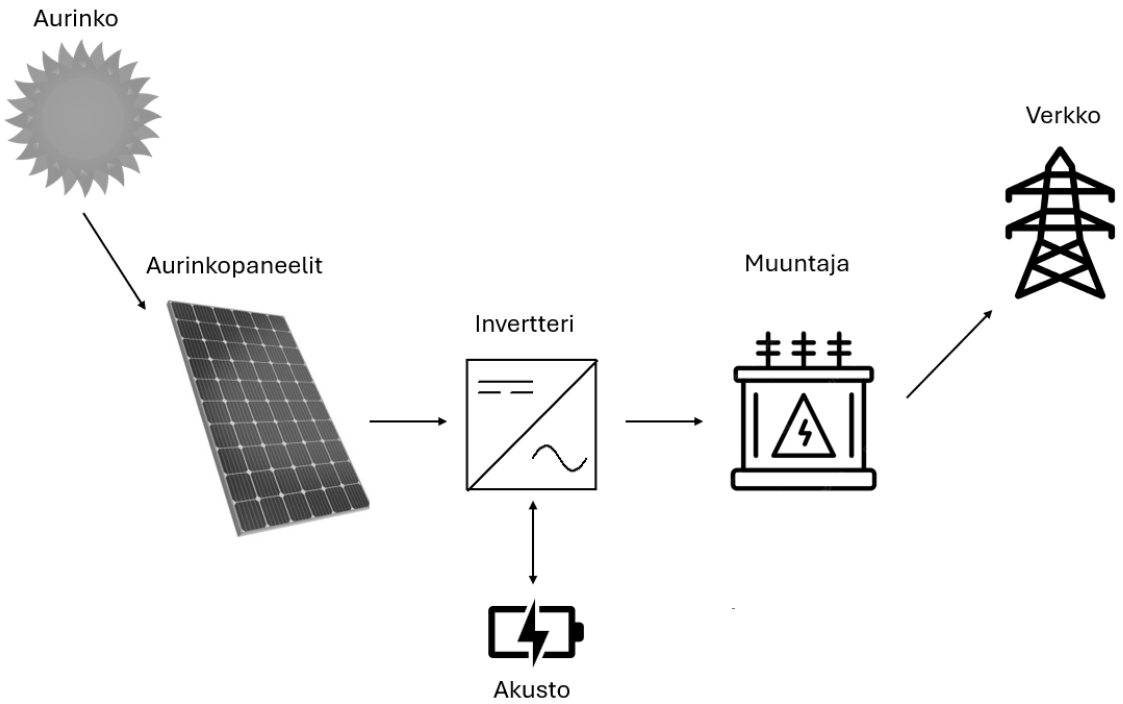

Kuva 5: Aurinkosähköjärjestelmän kuvituskuva (mukaillen Hindocha & Shah 2020)

3.2 Kunnossapito ja sen muodot

Kunnossapito on prosessi, jonka tarkoituksena on varmistaa laitteiden, komponenttien ja infrastruktuurin turvallinen ja luotettava toiminta koko elinkaaren ajalle (Järviö 2007). Kunnossapidon standardin SFS-EN 13306 (2017) mukaan kunnossapito on toimintaa, jolla

on tarkoitus ylläpitää tai palauttaa kohteen toimintakyky sellaiseksi, että kohde pystyy suorittamaan sille vaaditun tehtävän. Hyvin toteutetun kunnossapidon tehtävänä on vähentää odottamattomia vikoja ja seisokkeja, optimoi laitteiden toimintaa ja käytettävyyttä sekä pitkällä aikavälillä laskee huoltokustannuksia (Mobley 2002).

Kunnossapidon muotoja on useampia erilaisia perustuen siihen, milloin ja millä perusteella kunnossapitotoimenpiteet suoritetaan. Kunnossapitotoimenpiteet ovat jaoteltavissa ennakoivaan sekä korjaavaan kunnossapitoon, jossa ennakoivalla tarkoitetaan, että kunnossapitotoimet suoritetaan jo ennen varsinaista vikaantumista, kun taas korjaavassa kunnossapidossa toimenpiteet suoritetaan vasta, kun vikaantuminen on tapahtunut (Järviö 2007; SFS-EN 13306 2017).

SFS-EN 13306 (2017) kunnossapidon terminologian standardin mukaan kunnossapidon muodot voidaan jaotella Kuvan 6 mukaisesti korjaavaan-, ehkäisevään-, välittömään korjaavaan-, siirrettyyn korjaavaan-, jaksotettuun-, kuntoperusteiseen-, aikataulutettuun-, ennustavaan- ja ei ennustavaan kunnossapitoon.

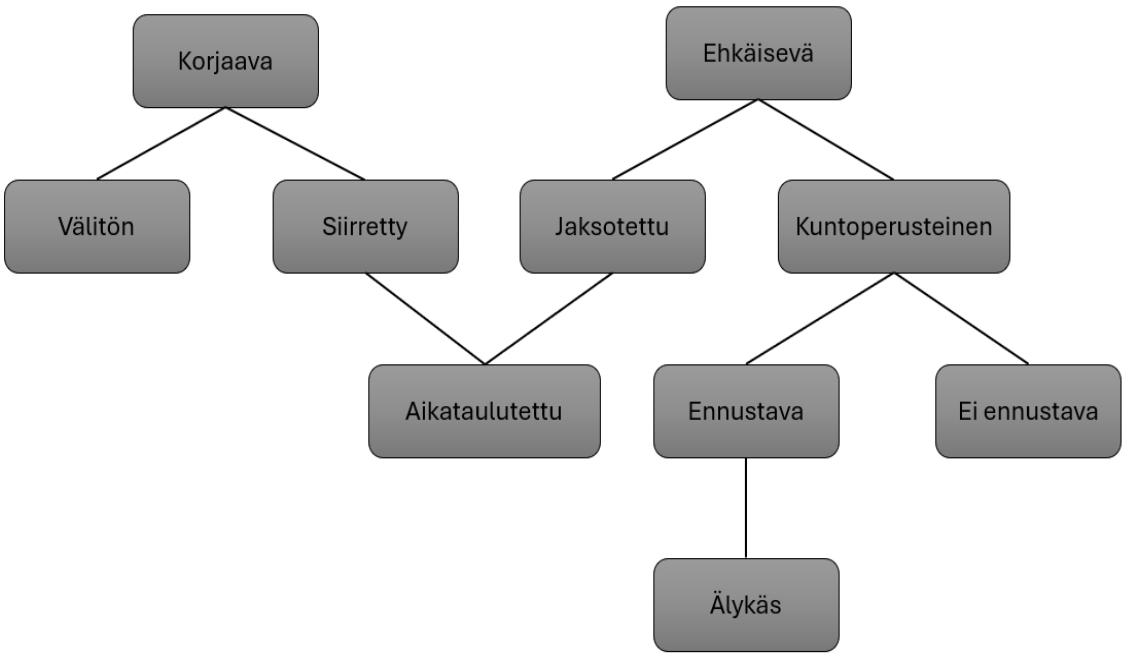

Kuva 6: Kunnossapidon muodot (mukaillen SFS-EN 13306 2017)

Korjaavassa kunnossapidossa vioittunut systeemin osa pyritään palauttamaan toimintakuntoon joko välittömästi vian havaitsemisen jälkeen tai siirretysti, esimerkiksi suoritettavaksi muiden tarkastuksien tai kunnossapitotoimien yhteydessä, mikäli vika ei aiheuta huomattavaa haittaa prosessille. Vianpaikannus, - tunnistus, -määritys ja -korjaus kuuluvat korjaavan kunnossapidon toimiin. Korjaavan kunnossapidon haittapuolena voi olla, että sitä hyödynnettäessä kunnossapidettävät laitteet voivat olla muihin kunnossapitostrategioihin verrattuna suhteessa enemmän poissa käytöstä, joka puolestaan esimerkiksi aurinkovoimaloiden tapauksessa johtaa suurempiin tuotantotappioihin. (Blanchard et al. 1995; Järviö 2007; Mobley 2002)

Jaksotetussa kunnossapidossa kunnossapidettävälle kohteelle suoritetaan kunnontarkastuksia sekä korjaavia toimenpiteitä säännöllisin väliajoin, ilman että sille suoritetaan erillisiä, tarkempia toimintakunnon tarkastuksia. Jaksotetun kunnossapidon perusajatuksena on, että kunnossapitopäätöksiä voidaan tehdä olemassa olevien elinkaaritietojen perusteella. Jaksotettu kunnossapito voidaan nähdä kuuluvan ehkäisevän kunnossapidon menetelmiin, koska elinkaaritietojen perusteella määritettyjen määräaikaiskorjausten ja -tarkastusten tehtävänä on ehkäistä kriittisiä vikaantumistilanteita. (de Jonge et al. 2017; Järviö 2007; SFS-EN 13306 2017)

Kuten jaksotettu kunnossapito, kuuluu myös kuntoperusteinen kunnossapito ehkäiseviin kunnossapitomenetelmiin. Kuntoperusteisen kunnossapidon toiminta perustuu säännöllisiin, tietyn väliajoin tehtäviin kunnontarkastuksiin, jolloin saadaan ylläpidettyä tietoa kohteen toimintakunnon tilasta. Tämä kunnossapitomalli nojautuu olettamukseen, jonka mukaan lähes kaikki vikaantumiset aiheuttavat tietyn kaltaisia merkkejä toiminnassaan jo ennen varsinaisen vian syntymistä. Kyseisiä merkkejä monitoroimalla voidaan kunnossapitotoiminnot suunnitella ajoissa ja ehkäistä kriittisempi vikaantuminen. Kuntoperusteiseen kunnossapitoon liittyvän monitoroinnin avulla myös vikojen aiheuttajan arvioiminen sekä oikeanlaisten korjaustoimenpiteiden valitseminen voi helpottua, sillä usein tietyn tyyppisille vioille on ennen varsinaista vikaantumista tyypillistä oireilla jollakin tietyllä tavalla, joka käy ilmi monitoroidessa. (PSK 6201 2022; SFS-EN 13306 2017)

Ennustavalla kunnossapidolla tarkoitetaan kuntoperusteisen kunnossapidon alatyyliä, jonka toimiminen perustuu nimensä mukaisesti vikaantumisien ja toiminnan poikkeamien ennustamiseen. Mallissa on keskeistä hyödyntää ennustavia, edistyksellisiä työkaluja. Mallissa voidaan muun muassa hyödyntää systeemin toiminnan kannalta oleellisia

historiadatoja ja tehdä siitä ennustemalleja esimerkiksi koneoppimisen menetelmin. Ennustavassa kunnossapidossa laitteen toimintaa monitoroidaan jatkuvasti ja tarkkaillaan kohteen tilan muutoksia kuvaavia arvoja, jotta tunnistetaan toimintahäiriöt ja pystytään puuttumaan niihin, jo ennen niiden varsinaista vaikutusta laitteen kriittiseen toimintaan. (SFS-EN 13306 2017; PSK 6201 2022) Ei-ennustava kunnossapito taas viittaa kunnossapitostrategiaan, jossa laitteisiin kohdistuvat kunnossapitotoimet perustuvat niiden kuntoon, mutta ilman ennakoivaa analytiikkaa tai muita kehittyneitä ennustusmenetelmiä (Mobley 2002).

Älykäs kunnossapito on puolestaan käsite, jota ei kunnossapidon terminologian standardeissa vielä määritellä, mutta on tieteellisessä kirjallisuudessa saanut merkityksen digitalisaation tuomien mahdollisuuksien ja sen myötä edistyneen kunnossapitomenetelmien kehityksen myötä (Bokrantz et al. 2020a; 2020b). Älykkäällä kunnossapidolla tarkoitetaan kunnossapitostrategiaa, joka hyödyntää laaja-alaisesti kunnossapidettävässä prosessissa olevaa dataa luodakseen kokonaisvaltaisen käsityksen systeemin tilasta, mahdollistaen ennusteiden ja sitä myötä myös kunnossapitotoimien aikataulutuksen ennalta luonnin (Ayad et al. 2018). Älykkäälle kunnossapidolle ominaisia piirteitä ovat ennen kaikkea ennustavuus sekä reaaliaikaisen datan hyödyntäminen, mutta muita olennaisia piirteitä sille ovat myös kunnossapitohenkilöstön ja teknologian toimiva yhteistyö, tietopohjainen päätöksenteko sekä kunnossapidon integroituvuus muuhun systeemin toimintaan (Bokrantz et al. 2020b). Bokrantzin et al. (2020a) kunnossapitoa käsittelevistä artikkelista voidaan koostaa älykkään kunnossapidon tarkoittavan järjestelmällistä tapaa hallita kunnossapitotoimintoja hyödyntämällä dataan perustuvaa päätöksentekoa, inhimillistä osaamista sekä organisaation verkostoja, tavoitteena kestävä, ennakoiva sekä tehokas toiminnan ylläpito.

Kaiken kaikkiaan kunnossapidon muotoja on useita, ja niiden keskeisimmät eroavaisuudet liittyvät pääosin kunnossapitotoimien ajankohtaan suhteessa vikaantumiseen sekä analytiikan ja edistyksellisten menetelmien hyödyntämisen laajuuteen (SFS-EN 13306 2017). Taulukko 1 esittää kunnossapidon muodot sekä niiden määritelmät koostettuna.

Taulukko 1: Kunnossapidon muodot ja määritelmät (SFS-EN 13306 2017; PSK 6201 2022).

Kunnossapidon muoto	**Määritelmä**
Korjaava kunnossapito	Vian korjaaminen vasta, kun se on jo tapahtunut. Voi olla suunniteltua tai hätäkorjausta.
Ehkäisevä kunnossapito	Säännöllisesti aikataulutettuja huoltotoimenpiteitä, joilla pyritään estämään vikaantuminen.
Välitön korjaava kunnossapito	Korjaustoimenpiteet suoritetaan välittömästi vian havaitsemisen jälkeen.
Siirretty korjaava kunnossapito	Vian korjaaminen siirretään myöhempään ajankohtaan, esimerkiksi muiden huoltotoimenpiteiden yhteyteen.
Jaksotettu kunnossapito	Kunnossapito suoritetaan säännöllisin väliajoin, ilman erillisiä kunnon tarkastuksia.
Kuntoperusteinen kunnossapito	Kunnossapitotoimenpiteet perustuvat kohteen tilan säännöllisiin tarkastuksiin.
Aikataulutettu kunnossapito	Kunnossapito toteutetaan ennalta määritellyn aikataulun mukaan, riippumatta laitteen tilasta.
Ennustava kuntoperusteinen kunnossapito	Hyödyntää data-analytiikkaa ja tekoälyä vikaantumisten ja poikkeamien ennustamiseen.
Ei-ennustava kuntoperusteinen kunnossapito	Kunnossapito perustuu laitteen kuntoon, mutta ilman ennakoivaa analytiikkaa.
Älykäs kunnossapito	Hyödyntää digitalisaatiota, data-analytiikkaa ja reaaliaikaista valvontaa kunnossapidon optimointiin.

3.3 Aurinkovoimaloiden kunnossapito

Aurinkovoimaloiden kunnossapito on keskeisessä roolissa niiden tehokasta sekä pitkäaikaista toimintaa, vaikka aurinkosähköjärjestelmät yleisesti ottaen vaativatkin lähtökohtaisesti vain vähäisen määrän huoltotoimenpiteitä. Aurinkovoimaloiden kunnossapidon pääasiallisena tarkoituksena on vähentää sähköntuotannonmenetyksiä sekä ehkäistä järjestelmän kannalta kriittisien komponenttien vikaantumisia. Aurinkovoimaloiden kunnossapidossa voidaan hyödyntää useampia eri muotoja, mitä käsiteltiin edellisessä luvussa (Kurtz et al. 2009).

Aurinkopaneeleiden ylläpito perustuu pääasiassa tarkastuksiin, puhtaanapitoon sekä tuotannonseurantaan. Aurinkovoimalan sähköntuotanto keskimääräisesti alenee vuodessa noin 0,5 %, mutta aurinkovoimalan ensimmäisinä käyttövuosina tuotannonalenema voi olla huomattavasti suurempikin. Mikäli sähköntuotannon alenema on useampina vuosina yli 5 % edellisestä vuodesta, on voimalalle syytä suorittaa laajempia tarkastuksia, jotta tuotannonaleneman aiheuttajat saadaan tunnistettua ja kunnossapitotoimenpiteet suoritettua. (ST-Käsikirja 40).

Standardissa SFS-EN IEC 62446:2 (2020) esitellään suosituksia ja vaatimuksia sähköverkkoon kytketyn aurinkosähköjärjestelmän kunnossapidolle. Kunnossapidon muodoista standardi mainitsee esittävänsä toimenpiteitä aurinkosähköjärjestelmien ennakoivalle, korjaavalle sekä suorituskykyyn perustuvalle kunnossapidolle. Standardin mukaan aurinkovoimaloiden kunnossapitoprosessi pitää sisällään kunnossapidon toimet järjestelmän komponenttien sekä liitäntöjen luotettavuudelle, paloriskin ehkäisylle sekä turvallisuudelle.

Tyypillisesti aurinkovoimalalle tehdään määräaikaistarkastuksia perustuen joko takuuehtoihin tai standardeista saatuihin suosituksiin. Suunnitelluilla tarkastuksilla on tarkoitus ennaltaehkäistä vikaantumisia ja havaita ajoissa poikkeamat aurinkovoimalan toiminnassa ja niin edelleen vähentää aurinkovoimaloiden tuottavuuden alenemasta johtuvia tappioita. Tarkastukset voivat pitää sisällään sekä ennakoivaa-, että korjaavaa kunnossapitoa. Ennakoivan kunnossapidon kannalta tarkastuskäyntien tarkoituksena on säännöllisillä tarkastuskäynneillä kartoittaa voimalalle myöhemmin tehtäviä kunnossapitotoimia jo ennen kuin poikkeamat johtavat vikaantumisiin tai tuotantokatkoihin. Korjaavan kunnossapidon osalta tarkastuskäynneillä puolestaan voidaan vaihtaa tai korjata

jo vikaantuneita komponentteja ennakoivan tarkkailun ohella. Tämän kaltainen ennakoivan ja korjaavan kunnossapidon yhdistäminen tarkastuskäynneille soveltuu erityisesti tilanteisiin, jossa vikaantumiset eivät ole aiheuttaneet merkittävää tuotannonmenetystä voimalalle, mutta ovat kuitenkin hoidettava, jolloin kunnossapitotoimet voidaan siirtää samalle käynnille tarkastusten kanssa huoltokustannusten laskemiseksi. (Constantin et al. 2023; SFS-EN IEC 62446:2 2020)

Perinteisesti tarkastuskäyntejä tehdään sykleittäin. Nämä tarkastussyklit määräytyvät pääasiallisesti joko komponenttivalmistajien takuuehtojen tai suositusten mukaisesti tai vastaavasti standardeissa määriteltyjen suositusten mukaisesti, mikäli komponenttivalmistajien osalta ei suosituksia ole saatavilla. Tarkastuksia suositellaan IEC 62445-2:2020 standardin mukaan tehtävän koko aurinkovoimalan elinkaaren ajalle.

3.4 Aurinkosähköjärjestelmien lämpökuvaus

Aurinkopaneelien lämpökuvaus on yksi keskeisistä osista aurinkovoimaloiden kunnossapitoa. Aurinkopaneelien lämpökuvauksessa mitataan aurinkopaneelien lähettämän infrapunasäteilyn määrää, minkä avulla saadaan luotua kuva aurinkopaneelin lämpötilajakaumasta, jossa eri lämpötilat ovat esitetty kuvassa eri värein. Aurinkopaneelin lämpötilasta voidaan tämän jälkeen havainnoida lämpötilapoikkeamia, joita voidaan verrata täysin poikkeuksettomiin paneeleihin analyysin suorittamiseksi. Poikkeamia analysoimalla ja vertaamalla oikein toimiviin paneeleihin voidaan tehdä johtopäätöksiä paneelin toimivuudesta, sähköntuotannosta sekä kunnossapidon tarpeesta. Täysin oikein toimivan paneelin lämpökuvassa ei ole havaittavissa juurikaan lämpötilaeroja tai laitetuottajan teknisissä tiedoissa mainitsemien rajojen ylittäviä lämpötiloja. Tähän olettamukseen perustuen lämpötilapoikkeamat useimmiten viittaavat paneelin toiminnan häiriöön tai vikaantumiseen. (Restrepo-Cuestas et al. 2025)

Aurinkopaneelien lämpökuvausta voidaan suorittaa säännöllisesti osana aurinkovoimaloiden ennakoivaa kunnossapitoa ja IEC/TS 62446-3 (2017) standardissa lämpökuvauksia suositellaan tekemään 4 vuoden välein. Lämpökuvauksen avulla voidaan havaita mahdolliset ongelmat ajoissa ja suunnitella tarvittavat korjaavat toimenpiteet, kuten esimerkiksi paneelien puhdistus, korjaus tai vaihto. Tämä voi auttaa optimoimaan

aurinkovoimaloiden suorituskyvyn ja sähköntuotannon tehokkuuden, sekä vähentämään mahdollisia seisokkeja ja tuotantohäiriöitä. (Akay et al. 2024)

Lämpökuvausta aurinkopaneeleille voidaan suorittaa pääsääntöisesti joko käsikäyttöisellä lämpökameralla tai miehittämättömään ilma-alukseen (UAV) kytketyllä lämpökameralla. Käsikäyttöiset lämpökamerat soveltuvat paremmin tarkastuksiin, jossa tarkastettava voimala-alue on pienikokoinen ja vaativat tarkkuutta tarkastelemalla lähietäisyydeltä Miehittämättömillä ilma-aluksilla voidaan puolestaan tehokkaasti tarkastaa laajoja alueita ja kerätä lämpökuvadatan lisäksi myös muuta sensoridataa, kuten esimerkiksi värikameralla tallennettavia kuvia, sillä useimpiin ilma-aluksiin on liitettävissä useampia sensoreita. Miehittämättömillä ilma-aluksilla voidaan lisäksi suorittaa lämpökuvadatan keruu esiohjelmoiduilla lennoilla, jolloin kuvausasetelma kuvia otettaessa pystytään pitämään huomattavasti homogeenisempänä, johtaen tasalaatuisempaan lämpökuvadataan. Tasalaatuinen datankeruu puolestaan antaa hyvät lähtökohdat datan jatkohyödyntämiseen edistyksellisemmin, kuten tekoälyn ja koneoppimisen menetelmin. (Di Tommaso et al. 2021; Korkmaz & Acikgoz 2022)

3.5 Aurinkopaneelien vikaantumistyypit

Aurinkopaneelien viat voivat heikentää sähköntuotantoa tai aiheuttaa turvallisuusriskin, kuten palovaaran. Kaikki tarkastuksissa havaitut poikkeamat eivät kuitenkaan vaikuta tuotantoon tai turvallisuuteen, vaan osa on kosmeettisia poikkeamia. Vika voidaan todeta visuaalisesti, mittauksilla, lämpökuvauksella tai muilla kuvantamismenetelmillä. Viat luokitellaan syntyhetken mukaan asennus-, kuljetus- tai valmistusvaiheessa syntyneisiin vikoihin, käytönaikaisiin vikoihin sekä käyttöiän loppumisesta johtuviin vikoihin. Näistä suurimmin paneelin tuotantokykyyn vaikuttavat tyypillisesti käyttöiän loppuun kulumisen viat. Vaikka aurinkovoimala sisältää useita vikaantuvia komponentteja, työn rajauksen myötä luvussa keskitytään vain aurinkopaneelien toiminnan häiriöihin ja vikaantumisiin. (IEC/TS 62446-3 2017; SFS-EN IEC 62446-2 2020)

Lämpökuvauksella voidaan havaita vikoja kenno-, kennorivi-, paneeli- tai paneeliketjutasolla (IEC/TS 62446-3:2017 2017). Taulukko 2 esittää yleisimpiä lämpökuvauksissa havaittavia paneelipoikkeamia sekä niiden syyt ja vaikutukset toimintaan.

Taulukko 2: Aurinkopaneelin lämpökuvista havaittavat poikkeamatyypit (Köntges et al. 2014, s. 35)

Kuvio	Kuvaus	Syy	Vaikutus
	Paneelit kokonaisuudessaan lämpimämpiä, kuin ympäröivät paneelit	Avoimen piirin tila. Lämmenneet paneelit eivät ole toiminnassa osana systeemiä.	Kun yhdistetty takaisin järjestelmään, toiminta normaalia.
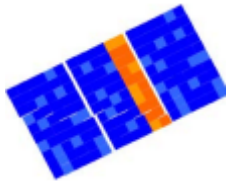	Yksi kennorivi lämpimämpi, kuin muut kennorivit paneelissa.	Avoin ohitusdiodi tai oikosulku. Avoin virtapiiri yhdessä kennosarjoista.	Tehon alenemat sarjaankytkennän ohituksen myötä. Jännitteen alenema.
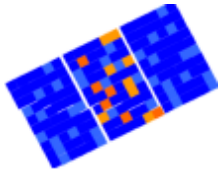	Yksittäiset kennot lämmenneet satunnaisesti paneelissa. Ei tiettyä tunnistettavaa lämpökuviota.	Koko paneelimoduulin oikosulku, kaikki ohitusdiodit aktivoitunut tai virheellinen kytkentä	Voimakkaat teho- ja jännitehäviöt.
	Yksittäiset kennot lämmenneet paneelin reunoista. Alareunoissa selkeämpi lämpeneminen, kuin yläreunoissa	Suuret ohivirrat, potentiaalierojen aiheuttama rappeutuminen.	Paneelin tehon alenema. Tehohäviöt korostuvat matalan säteilyn olosuhteissa
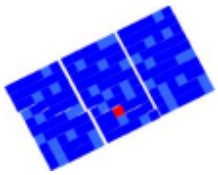	Yksittäinen aurinkokenno selkeästi lämpimämpi.	Varjostuma, kennon viallisuus tai delaminaatio.	Ohimenevä tehon alenema, jos lian tai varjon aiheuttama. Jos kennovika, voi johtaa peruuttamattomiin vaurioihin.
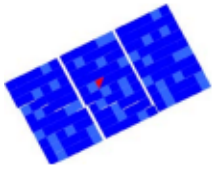	Osa yksittäisestä kennosta lämpimämpi.	Rikkinäinen kenno, Kytköksestä irronnut kenno	Reilu tehon alenema.
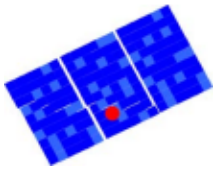	Pistemäinen lämpenemä. Lämpökuvio voi olla epäsymmetrinen.	Varjostuma, lika	Tehon alenema riippuu lämpöpoikkeaman koosta sekä muodosta.
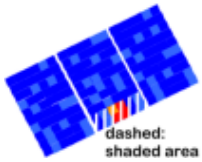	Varjostuman kohdalla epäsymmetrinen lämpenemä kennorivissä	Ohitusdiodi puuttuu tai on viallinen	Voimakas oikosulkuvirran ja tehon alenema. Vakava paloriski.

3.6 Aurinkovoimaloiden älykäs kunnossapito ja konenäkö

Niin kuin suuressa osassa muitakin yritysten toimintoja, on digitalisaatio tuonut myös kunnossapidon tehostamiseen suuren skaalan mahdollisuuksia. Jatkuvasti kehittyvät mahdollisuudet kerätä, varastoida ja analysoida dataa eri prosesseista on mahdollistanut myös tarkempien, tietoon pohjautuvien ja ennakoivien kunnossapitoratkaisujen syntymisen (Mobley 2002). Teknologiat kuten IoT ja reunalaskenta ovat mahdollistaneet kunnossapidon vastaaville henkilöille reaaliaikaisen tiedonsaannin tuotantoprosesseista sekä kunnossapidon kohteista (Ayad et al. 2018; Babu et al. 2024).

Myös aurinkovoimaloiden tapauksessa voidaan hyödyntää moderneja teknologioita, kuten lämpö-, väri- ja elektroluminesenssi kuvantamista datan keräämiseen voimalan toiminnasta ja niin edelleen sitä voidaan hyödyntää kunnossapidon suunnittelemiseen, aikatauluttamiseen ja toteuttamiseen (Fernando et al. 2025; Imenes et al. 2021; Mellit & Benghanem 2020) Aurinkovoimala-alueelta datankeräys laajalla mittakaavalla erilaisin sensorein ja eri muodoissa mahdollistaa data-analyysit, joiden avulla voidaan pyrkiä löytämään korrelaatioita aurinkovoimalan toiminnassa tapahtuvien muutoksien sekä datasta löydettävien poikkeamien kesken (Spajić et al. 2024). Kun tämän tyyppisiä korrelaatioita kerätyn datan ja aurinkovoimalan toiminnan poikkeamien välillä havaitaan, voidaan teoriassa luoda myös ennustemalleja, joiden avulla ennakoidaan vikaantumistilanteita dataan perustuen (Ayad et al. 2018; Babu et al. 2024; Bosman et al. 2020). Konenäön nähdään myös kirjallisuudessa toimivan hyödyllisenä työkaluna analysoimaan kaikkia edellä mainittuja: aurinkovoimaloiden lämpö-, väri- sekä elektroluminesenssikuvia (Mellit & Kalogirou 2025).

Esimerkkinä aurinkovoimalan älykkäästä kunnossapidosta Di Tommaso et al. (2021) esittivät monivaiheisen mallin, joka hyödyntää YOLOv3-arkkitehtuurin neuroverkkoa havaitakseen poikkeamia ilmasta otetuista lämpö- ja valokuvista. Mallin avulla onnistuttiin tunnistamaan erilaisia vikaantumisia ja poikkeamia, kuten lämpenemiä ja paneelien likaantumista, jotka voivat mahdollistaa tuotannonaleneman. Näiden havaintojen avulla voidaan mahdollistaa ennakoiva kunnossapito ja suunnitella toimenpiteet jo ennen kuin merkittäviä poikkeamia systeemin toiminnassa havaitaan.

Di Tommason esittämää viitekehystä laajentaen, Spajić et al. (2024) osoittivat, kuinka yhdistämällä UAV-teknologiat ja syväoppimiseen perustuvat konenäkömallit voidaan

tarkastusprosesseja merkittävästi tehostaa. Heidän esittämä aurinkovoimaloiden älykkään kunnossapidon viitekehys perustuu kolmivaiheiseen prosessiin koostuen:

1. UAV-laitteilla tapahtuvaan systemaattiseen kuvadatan keräämiseen
2. Konenäköalgoritmeilla tapahtuvaan poikkeamien tunnistamiseen, sekä
3. Saadun tiedon integroimiseen kunnossapidon operatiiviseen ja kunnossapidolliseen suunnitteluun

Tämänkaltaisten menetelmien hyödyntämisellä voidaan paitsi lyhentää tarkastus- ja reagointiaikoja, myös parantaa havaintojen tarkkuutta ja siten edistää kunnossapidon kokonaisvaltaista tehokkuutta ja luotettavuutta. Näin ollen kyseessä ei ole vain teknologinen edistysaskel, vaan konkreettinen parannus koko kunnossapidon arvoketjuun (Spajić et al., 2024).

Mellit & Kalogiroun (2025) viittaamassa kirjallisuudessa konenäköratkaisujen hyödyntäminen aurinkovoimaloiden kuntotarkastuksissa perustuen ilmasta otettuihin lämpökuviin perustuu pääosin kolmeen mahdolliseen käyttökohteeseen: paneelien kohteentunnistukseen, poikkeman tunnistukseen ja poikkeamaluokitteluun. Segovia Ramirez et al. (2022) esittivät lähestymistavan, jossa Faster-RCNN pohjaista mallia hyödynnettiin ensiksi aurinkopaneelien tunnistamiseen 96 % tarkkuudella ja sen jälkeen lämpöpoikkeamien tunnistamiseen 99 % tarkkuudella, mutta poikkeamien luokittelua ei suoritettu.

Vlaminck et al. (2022) puolestaan esittivät viitekehyksen, jossa paneelit tunnistettiin Mask-RCNN:llä ja poikkeamat Faster RCNN:llä, minkä jälkeen värikuvien autoencoder-perusteisella analyysilla tunnistettiin vianaiheuttajat. Tässä poikkeamaluokittelu perustuu värikuviin, joita autoencoder käy läpi ja poimii visuaalisesti poikkeavat paneelit, jonka jälkeen asiantuntija tekee niille tarkemman diagnostisen luokittelun. Värikuviin perustuvalla autoencoderilla havaitaan silmälle näkyvissä olevat vianaiheuttajat. Ne viat, jotka näkyivät lämpökuvissa, mutta ei kuvissa, todettiin olevan luultavasti vakavampia sisäisiä vikaantumisia, mutta niitä ei luokiteltu tässä tutkimuksessa.

Imenes et al. (2021) puolestaan esitti komposiittikuvista, joissa väri- ja lämpökuvat yhdistetään, tehtävän analyysin YoloV3-mallilla. Heidän esittämässään viitekehyksessä tehtiin ensiksi poikkeamatunnistus ja sen jälkeen poikkeamaluokittelu. Tulokset osoittivat, että poikkeamien tunnistaminen menetelmällä oli onnistunutta ja jopa parempaa, kuin

pelkistä lämpökuvista tehtävä tunnistus, mutta vikojen luokittelu jäi ihmisanalyytikkoa heikommalle tasolle. Korkmaz & Acikgoz (2022) puolestaan esittivät moniskaalaisen konvoluutioneuroverkon ja transfer learning-strategian, jonka avulla onnistuttiin 11 vikaluokan luokittelussa 93.5 % tarkkuudella. Tutkimuksessa hyödynnettiin data-augmentoinnin menetelmällä laajennettua, yli 120 000 kuvaa sisältävää opetusaineistoa, mikä osoittaa opetusdatan määrän ratkaisevan merkityksen kokonaisvaltaisten mallien toteutettavuudelle. Data-augmentaatio tarkoittaa opetusaineiston keinotekoista laajentamista ja monipuolistamista luomalla synteettistä ainestoa mallin koulutukseen, esimerkiksi muokkaamalla kuvia rajauksilla, kierroilla tai kirkkaus- ja värimuutoksilla. (Shorten & Khoshgoftaar 2019).

Mellit & Kalogirou (2025) laativat systemaattisen kirjallisuuskatsauksen, jossa verrattiin julkaistuja artikkeleja aihepiiristä ja kirjallisuuskatsauksen lopputulemana todettiin, että konvoluutioneuroverkot pääsivät useissa tutkimuksissa hyviin tuloksiin poikkeamantunnistuksessa, mutta poikkeamien luokittelussa oikeisiin vikaluokkiin nähtiin vaikeuksia. Haasteita aiheuttivat alueelliset eroavaisuudet raakadatassa johtuen eri paneeliteknologiasta tai esimerkiksi ilmasto-olosuhteiden aiheuttamista muutoksista datan laatuun, koska saatavilla ei ole globaalia datasettiä, jonka avulla voitaisiin opettaa kaikille alueille ja voimaloille sopiva algoritmi. Katsauksen mukaan asiantuntijaa tarvitaan edelleen tunnistamaan vikatyyppi ja analysoimaan aiheuttaja. Useat tutkimukset kuitenkin osoittavat potentiaalia konenäössä myös poikkeamaluokitteluun, mutta tämä vaatii suuren määrän opetusdataa.

4 Tutkimusmenetelmät ja toteutus

4.1 Tutkimuksen kohdeyritys

Tutkimus on toteutettu toimeksiantona energia-alalla toimivalle energiakonsernin spin-off yritykselle. Kohdeyritys tarjoaa drone- sekä tekoälyteknologioihin perustuvia data-analytiikkapalveluita energia-alan kunnossapitotarpeisiin. Kohdeyritys on alun perin syntynyt tarpeesta modernisoida ja luoda älykkäitä ratkaisuja sähköverkkojen kunnossapitoon, mutta myöhemmin tarve on tunnistettu muillakin energia-aloilla, kuten esimerkiksi aurinkosähkön tuotannossa.

Kohdeyritys tarjoaa droneteknologioilla kerättyyn dataan perustuvia data-analytiikkapalveluita energia-alan yrityksille kunnossapidon päätöksenteon tueksi. Toistaiseksi energia-alalta kohdeyritys on luonut dataan ja analytiikkaan perustuvat myytävät palvelut sähköverkkojen sekä aurinkovoimaloiden kunnossapitoon. Kohdeyrityksen palveluiden tarkoituksena on luoda tietoa asiakkaalle omaisuudestaan, jonka avulla he saavat näkemyksen omaisuutensa tilasta ja voivat sen perusteella tehdä kunnossapidon päätöksiä.

Kohdeyrityksen palveluiden tarkoituksena on tarjota ehkäisevää sekä ennustavaa kunnossapitoa data-analytiikan avulla. Kohdeyrityksen suorittama datankeruu sekä sähköverkoista, että aurinkovoimaloista toteutetaan toistaiseksi ilmasta käsin, joko droneilla tai helikoptereilla. Ilmasta kerätty ja jalostettu data voidaan yhdistää asiakkaan jo omistamiin datalähteisiin analyysin yhteydessä, mahdollistaen kokonaisvaltaisemman analyysin asiakkaan infrastruktuurin tilanteesta. Kohdeyrityksen palveluiden tarkoituksena onkin mahdollistaa kokonaisvaltaisen kunnossapidollisen kuvan luonti asiakkaalle omaisuudestaan.

Kohdeyrityksen palvelut tähtäävät tarjoamaan kunnossapitoon älykkyyttä sekä ennakoitavuutta. Sähköverkoille kohdeyritys tarjoaa kunnossapitotarkastuksia rakentaen asiakkaalle kuvan sähkökomponenttiensa sekä niitä ympäröivän kasvillisuuden tilasta. Tämän lisäksi kohdeyritys tarjoaa sähköverkkoyhtiöille myrskyjen jälkeistä vianpaikannusta sekä verkonosien luotettavuusanalyysiä. Aurinkovoimaloille kohdeyritys on puolestaan

tarjonnut toistaiseksi ketteriä kuntotarkastuksia tuotannon aikaiseen operointiin perustuen lämpö- sekä värikuvamateriaaleihin. Kohdeyritys on tämän lisäksi tarjonnut palveluita aurinkovoimalahankkeiden eri elinkaaren vaiheisiin suunnittelusta tuotantovaiheeseen saakka. Pääosin palveluita on kuitenkin tuotettu käytönaikaiseen kunnontarkastukseen ja tässä työssä tutkitaankin mahdollisuutta tehostaa kohdeyrityksen tarjoamaa tuotannonaikaista tarkastuspalvelua konenäön avulla.

4.2 Tutkimusmetodologia

Tutkimus toteutetaan laadullisena eli kvalitatiivisena tapaustutkimuksena, jossa hyödynnetään konstruktiivista tutkimusotetta. Kvalitatiivisella tutkimuksella tarkoitetaan tutkimusta, jonka tavoitteena on ilmiöiden ymmärtäminen niiden luonnollisessa ja tosiasiallisessa kontekstissaan (Tuomi & Sarajärvi 2024). Tapaustutkimuksella puolestaan tarkoitetaan tutkimusmenetelmää, jossa tutkitaan yksittäistä ilmiötä sen kontekstissa, kuten kohdeyrityksen prosessia syvällisesti ja useista tietolähteistä saadun aineiston avulla (Gerrand 2004). Kvalitatiivinen tutkimus soveltuu erityisesti tilanteisiin, joissa tutkittava ilmiö on uusi, monimutkainen tai kontekstisidonnainen, eikä siitä ole olemassa valmiiksi jäsentyneitä teorioita tai määrällistä dataa (Recker 2021). Kvalitatiivinen tutkimus tuottaa tietoa ilmiöistä sellaisina kuin ne ilmenevät tutkittavassa kontekstissa, jolloin korostuu aineistolähtöisyys ja osallistujien kokemusten, merkitysten ja tulkintojen ymmärtäminen (Tuomi & Sarajärvi, 2024).

Työssä valittua lähestymistapaa sovelletaan analysoimalla kohdeyrityksen nykyistä palveluprosessia ja sen kehittämismahdollisuuksia tilanteessa, jossa konenäköpohjaiset kunnossapitoratkaisut ovat vasta kehittymässä (Tang et al. 2024). Menetelmä mahdollistaa sekä konenäköteknologian soveltuvuuden ja liiketoiminnallisten edellytysten kokonaisvaltaisen tarkastelun.

Tutkimuksen empiirisen osuuden aineisto kerättiin puolistrukturoitujen teemahaastattelujen avulla. Haastattelujen kautta kartoitettiin kohdeyrityksen sekä keskeisien sidosryhmien näkemystä konenäön hyödyntämisen hyödyistä, mahdollisuuksista ja rajoitteista. Haastattelujen tulosten analyysi suoritettiin induktiivisesti, eli aineistolähtöisesti, rakentamalla tulkintaa haastateltavien kokemusten ja näkemysten varaan.

Teoreettinen viitekehys tutkimukselle muodostettiin hyödyntämällä sekä liiketoimintalähtöistä että teknologista kirjallisuutta tekoälystä, koneoppimisesta ja konenäöstä, joita peilataan aurinkovoimaloiden kunnossapidon nykykäytäntöihin ja kehityssuuntiin. Empiiristä sekä teoreettista aineistoa hyödynnetään toistensa kanssa analyysivaiheessa, jossa muodostetaan ehdotus uudenlaisen tarkastuspalvelun konseptista. Teoreettinen aineisto on oleellisessa osassa empiirisen aineiston tulkintaa ja tukee tutkimuskysymyksiin vastaamista sekä kohdeyritykselle konstruktion luomista. Tutkimuksen lähestymistapa on konstruktiivinen. Se ei ainoastaan kuvaa ilmiötä, vaan pyrkii myös tuottamaan käytännöllisesti hyödyllisen ratkaisuehdotuksen (Lukka, 2003).

4.3 Tutkimusaineiston keruu

Tutkimusaineiston keruu toteutettiin työssä puolistrukturoitujen teemahaastattelujen avulla, joka on laadullinen menetelmä. Teemahaastattelujen sisältö rakentui tutkimuskysymysten ympärille antaen mahdollisuuden tarkempaan keskittymiseen tutkimuksen aihealueisiin sekä myös haastateltavien näkökulmien vapaamuotoisempaan esiin tuomiseen. Puolistrukturoiduissa teemahaastatteluissa käytetään ennalta määritettyä joukkoa kysymyksiä, mutta niiden järjestystä ja muotoilua on mahdollista muuttaa haastattelun kuluessa (Eskola & Suoranta 1998). Teemahaastattelut soveltuvat hyvin tilanteisiin, joissa halutaan ohjata haastateltavien ajattelua ja vastauksia tiettyyn aihepiiriin, jättäen silti tilaa vastaajien omille näkemyksille (Hirsjärvi et al. 2009). Tämä menetelmä mahdollisti, että kohdejoukolta saatiin kerättyä aihepiiristä monipuolinen näkemys rajoittamatta ajattelua liian tiukan kysymysasetannan kautta.

Haastattelujen kohdejoukko muodostui kohdeyrityksen hallituksen ja johtoryhmän jäsenistä sekä valikoiduista sidosryhmien edustajista. Haastateltavat valittiin harkinnanvaraisella otannalla, siten että heidän asiantuntemuksensa mahdollisti monipuolisen näkemyksen aurinkovoimaloiden kunnossapidon menetelmistä, teknologisesta kehityksestä sekä markkinapotentiaalista. Yhteensä haastatteluun osallistui kymmenen henkilöä, sisältäen sekä strategisen tason päättäjiä, kuin myös operatiivisen tason asiantuntijoita. Tämä mahdollisti kattavan käsityksen luonnin siitä, miten konenäköä voitaisiin hyödyntää, sekä mitä lisäarvoa se tuo palvelulle niin liiketoiminnallisesta, kuin teknisestäkin näkökulmasta.

Taulukko 3 esittää haastateltavia, niiden roolia, organisaatiotasoa ja yritystä suhteessa energiakonserniin.

Taulukko 3: Haastateltavat anonymisoituna

Haastateltava	*Pelkistetty rooli*	*Organisaatiotaso*	*Yritys*
H1	Liiketoiminnan kehitys	Päällikkö	Tytäryhtiö
H2	Liiketoiminnan kehitys	Päällikkö	Kohdeyritys
H3	Johto	Johtaja	Kohdeyritys
H4	Johto	Johtaja	Konsernin osakkuusyhtiö
H5	Johto	Johtaja	Konsernin osakkuusyhtiö
H6	Johto	Johtaja	Emoyhtiö
H7	Johto	Johtaja	Konsernin osakkuusyhtiö
H8	Analytiikka	Asiantuntija	Emoyhtiö
H9	Analytiikka	Päällikkö	Emoyhtiö
H10	Myynti	Päällikkö	Kohdeyritys

Ennen haastattelujen aloittamista tutkija laati teemahaastattelurungon, jonka tarkoituksena oli ohjata keskustelu kokonaisuuksiin, jotka liittyivät tutkimuskysymyksiin sekä tutkimusaiheeseen, eli konenäköön sekä aurinkovoimaloiden kunnossapitoon. Haastattelukysymyksiä laatiessa tutkija pyrki määrittämään kysymykset niin, että niihin vastaamalla haastateltavat antaisi näkemyksensä seuraaviin aihepiireihin, jotta tutkimusaiheen kokonaisvaltainen tarkastelu mahdollistuu:

- Aurinkovoimaloiden kunnossapidon markkinan nykytilanne ja kehityssuunnat
- Modernien kunnossapitopalveluiden liiketoiminnallinen potentiaali ja tarve
- Konenäköön perustuvien älykkäiden kunnossapitomenetelmien hyötyihin, mahdollisuuksiin, rajoitteisiin ja uhkiin
- Konenäköä hyödyntävän kunnossapitopalvelun muotoiluun ja kaupallistamiseen
- Kohdeyrityksen kilpailukykyyn ja strategiseen asemaan.

Laadullisen tutkimuksen periaatteiden mukaisesti kysymykset laadittiin siis siten, että ne tukevat aineistolähtöisen analyysin toteuttamista (Tuomi & Sarajärvi 2024). Tämä tarkoittaa, että haastateltaville annettiin tilaa tuoda esiin omia kokemuksiaan ja tulkintojaan, mutta samalla kysymykset ohjasivat keskustelua teemoihin, jotka ovat oleellisia tutkimuskysymysten ja -tavoitteiden kannalta. (Hirsjärvi et al. 2009)

Haastatteluja ennen haasteltaville toimitettiin tutkimustiedote, johon on sisällytetty pyyntö tutkimukseen osallistumisesta. Tämän lisäksi tutkimustiedotteessa kuvattiin työn toteuttaja, -tarkoitus, aineiston käsittely ja osallistumisen vapaaehtoisuus. Haastattelut toteutettiin Microsoft Teamsin kautta etähaastatteluina. Ennen haastattelun aloittamista haastateltavilta pyydettiin suullisesti suostumus osallistumisesta tutkimukseen sekä haastattelun nauhoittamiseen ja litterointiin. Suostumus dokumentoitiin osaksi haastattelutallennetta. Haastattelut litteroitiin sanatarkasti tutkimusaineiston systemaattista analyysia varten. Litteroinnin avulla varmistutaan siitä, että analysoitavat aineistot vastaavat täsmällisesti haastateltavien esittämiä näkemyksiä. Kuva 7 esittää toteutettuja tutkimusaineiston keruun vaiheita järjestyksessä.

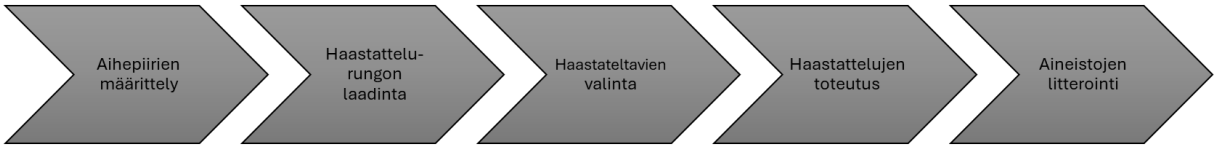

Kuva 7: Tutkimusaineiston keruun vaiheet

4.4 Tutkimusaineiston analysointi

Haastatteluaineistoille suoritettiin analyysi laadullisen sisällönanalyysin periaatteita noudattaen. Menetelmä on valittu käytettäväksi työssä, koska se mahdollistaa haastatteluaineistojen systemaattisen tarkastelun sekä näkemyksien luokittelun, jolloin tutkimuskysymyksiin perustuvista haastatteluteemoista on mahdollista muodostaa kattava kokonaiskuva ja näin ollen vastata tutkimuskysymyksiin perustellusti. Sisällönanalyysi

toteutettiin induktiivisesti, eli aineistolähtöisesti, jonka mukaan analyysin luokittelut muodostettiin haastatteluaineistosta nousevien teemojen mukaisesti, ilman valmiita teoreettisia luokkia. (Eskola & Suoranta 1998; Tuomi & Sarajärvi 2019)

Haastatteluaineistojen analyysiprosessi eteni vaiheittain (ks. Kuva 8). Aluksi aineistosta muodostettiin näkemyksellisiä pelkistyksiä, joiden avulla onnistuttiin tunnistamaan työn tutkimusongelman ja -kysymysten mukaisia vastauksia. Tämän vaiheen tehtävänä on erotella analyysin kannalta oleelliset ilmaisut muusta aineistosta. Tämän jälkeen pelkistetyt ilmaukset ryhmiteltiin luokittain alateemoihin niiden näkemyksellisten yhtäläisyyksien perusteella. Alateemat ryhmiteltiin edelleen kattoteemoiksi, joka mahdollisti haastateltavien näkemysten tarkastelun laajemmissa teemoissa. Tämä lähestyminen mahdollisti haastatteluaineistosta tutkimusaiheeseen liittyvien näkemysten ja merkitysten jäsentämisen tavalla, jonka avulla pystyttiin jäsentämään haastattelutulokset ja perustelemaan palvelukonseptin kehitystä liiketoiminnallisesta ja teknisestä näkökulmasta. (Naeem et al. 2023)

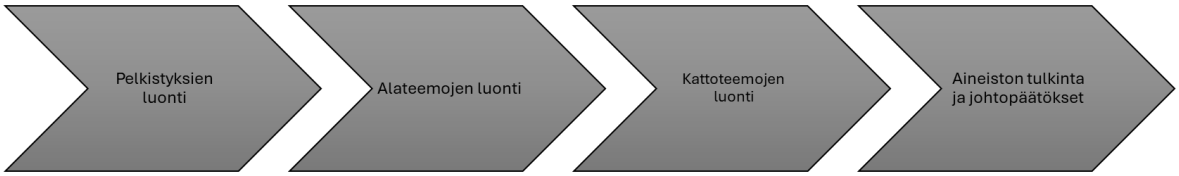

Kuva 8: Tutkimusaineiston analyysin vaiheet

Tutkimusaineistosta muodostui yhteensä seitsemän kattoteemaa. Taulukko 4 esittää kattoteemat sekä kattoteeman merkityksen tutkimuksen näkökulmasta. Alateemoja jokaisen kattoteeman alle koostui yhteensä 4–10 kappaletta. Tämä toimii osoituksena haastatteluaineiston moninaisuudesta.

Eri kattoteemat kytkeytyvät empiriaan tutkimuskokonaisuuden kannalta eri tavoin. Kahden ensimmäisen kattoteeman *”Aurinkovoimaloiden kunnossapidon markkina ja kehitys”* sekä *”Liiketoiminnallinen tarve ja potentiaali”* avulla luodaan kokonaiskuva toimialasta, joka

toimi perustana konenäköön perustuvan palvelukonseptin tarpeen arvioinnille. Seuraavaksi, teemat ”*Kohdeyrityksen kilpailukyky ja palvelukonseptin luonti*” sekä ”*Älykkään kunnossapidon ja konenäön lisäarvo ja mahdollisuudet*” muodostavat aineiston, jota hyödynnetään palvelukonseptiehdotuksen kehittämisessä teorialöydösten kanssa. Näiden rinnalla teema ”*Älykkään kunnossapidon ja konenäön rajoitteet ja epävarmuudet*” tuottaa aineiston esitettävälle SWOT-analyysille.

Taulukko 4: Sisällönanalyysin kattoteemat

Kattoteema	**Tarkoitus tutkimuksen näkökulmasta**
Aurinkovoimaloiden kunnossapidon markkina ja kehitys	Kuvaa toimialan nykytilaa ja kehityssuuntia, johon konenäköön perustuva palvelukonsepti sijoittuu.
Liiketoiminnallinen tarve ja potentiaali	Kuvaa toimialan luonteenpiirteitä, jotka ohjaavat kunnossapidon ratkaisujen kehittymistä.
Kohdeyrityksen kilpailukyky ja palvelukonseptin luonti	Käsittelee yrityksen vahvuuksia, heikkouksia ja mahdollisuuksia markkinassa. Kuvaa miten konenäköön perustuva palvelu voidaan rakentaa osaksi kunnossapidon prosessia.
Älykkään kunnossapidon ja konenäön lisäarvo ja mahdollisuudet	Tuo esiin, mitä hyötyä konenäön ja automaation käytöstä syntyy sekä mahdollisuuksia aihepiirin ympärillä.
Älykkään kunnossapidon ja konenäön rajoitteet ja epävarmuudet	Tuo esiin, mitä uhkia ja heikkouksia liittyy konenäköön perustuvaan tarkastusmalliin.

5 Haastattelutulokset ja aineiston analyysi

Tässä luvussa käydään läpi haastattelututkimuksen keskeisimmät tulokset. Ensimmäisessä alaluvussa käsitellään haastattelutulokset teemoittain ilman tutkijan tulkintaa tai analyysiä. Luvun jäsentämiseksi käytetään aineistosta nousseita kattoteemoja. Tämän jälkeen aineistolle suoritetaan analyysi, joka luo sillan seuraavalle luvulle osoittamalla perusteet ja keskeiset aineistosta nousseet seikat palvelukonseptin kehittämiselle.

5.1 Haastattelutulokset

Aurinkovoiman kunnossapidon markkina ja kehitys

Haastatteluaineistoista ilmeni, että markkinan nykytilannetta ja kehityssuuntia kommentoivat näkemykset olivat jaoteltavissa neljään alateemaan: markkinakasvu, markkinakypsyys, toimiala-asenteet ja markkinaa ohjaavat ulkoiset tekijät.

Markkinakasvun osalta haastateltavat näkivät aurinkovoimaloiden kunnossapitomarkkinan yksiselitteisesti olevan kasvava sekä alkuvaiheessa. Jokainen haastateltavista tunnisti uusiutuvien energiantuotantomenetelmien olevan kasvussa ja tämän myötä luonnollisesti nähtiin myös kunnossapidon tarpeen näillä aloilla kasvavan. H7 tunnisti markkinan olevan siirtymävaiheessa, jossa kunnossapitopalvelut muuttuvat välttämättömäksi osaksi aurinkovoimalan elinkaarta:

> *”Markkina ei ole vielä kasvanut kunnolla, mutta teollisen mittakaavan hankkeiden myötä kunnossapito tulee osaksi standardia.”*

Haastateltavat tunnistivat kaikki, että erityisesti teollisen mittakaavan voimaloiden määrä on suuressa kasvussa, mutta tällä hetkellä liiketoiminnan maturiteetti on Suomessa vielä pientä. Sen sijaan kansainvälisesti tunnistettiin, että markkina on pidemmällä, kuin Suomessa. H6 tunnistaa markkinan alueelliset erot kehityksen asteessa:

> *“Etelä-Euroopassa markkinaa on jo olemassa – Suomessa se on vasta muodostumassa.”*

Vaikka toimiala on Suomen mittakaavassa kehitykseltään vasta alkuvaiheessa, näkivät haastateltavat, että aurinkovoimakapasiteetin merkittävä kasvu tulee tuomaan mukanaan alalle kunnossapitotoimijoita, jotka sekä kasvattavat kilpailun astetta että tuovat kohdeyritykselle mukanaan myös mahdollisuuksia. Samalla nähtiin, että myös tarve uusille kunnossapitotoimijoille tulee kasvamaan ja todennäköisenä kehityssuuntana tunnistettiinkin, että aurinkovoimaloiden omistajat haluavat ostaa kunnossapitopalvelut ulkoistettuna, kuten muussakin teollisuudessa. H10 arvioi, että suurten aurinkovoimaloiden määrän nopea kasvu tulee houkuttelemaan mukanaan alalle uusia toimijoita:

> *"Uusia toimijoita aurinkovoimaloiden kunnossapidon alalle tulee varmasti, koska voimaloiden määrä kasvaa ja markkina laajenee."*

Markkinakypsyyden osalta haastatteluissa tunnistettiin, että kunnossapidon menetelmät eivät ole vielä toimialalla vakiintuneita. Yhtenä selittävänä tekijälle tälle aineistosta nousi luonnollisesti markkinan nuoruus ja Suomeen asennetun aurinkovoimakapasiteetin toistaiseksi vähäinen määrä. H7 kiteytti markkinan kypsymättömyyden Suomeen asennetun aurinkovoimakapasiteetin ympärille ja siihen, että järjestelmät ovat suurimmilta osin tähän mennessä olleet pienikokoisia, joissa kunnossapito on ollut toissijaista:

> *"Suomessa on ylitetty 1000 MWp asennettu aurinkovoimakapasiteetti, mutta valtaosa on kotitalouksia ja pieniä järjestelmiä, joissa kunnossapitoon ei ole kiinnitetty juuri huomiota."*

Markkinakypsyyttä tai sen puutetta selittävänä tekijänä haastattelijat näkivät myös luonnollisesti omistajien tai kunnossapidosta vastaavien toimijoiden näkemyksen puutteen siitä, kuinka useasti ja millä tasolla kunnossapitotoimia tulisi suorittaa. Tämän lisäksi toimialalla uskottiin osaltaan vielä vallitsevan virheellinen näkemys siitä, että aurinkopaneelit asennuksen jälkeen ovat huoltovapaita ja paneelit kestäisivät vuosikymmeniä ilman toiminnallisia ongelmia. H4 esittää nämä näkemykset seuraavissa sitaateissa:

> *"Suomessa aurinkovoimaloiden kunnossapitomarkkina on vielä kehittymätön, koska laitokset ovat uusia ja omistajilla on vähän kokemusta kunnossapidosta. Markkina kuitenkin kasvaa nopeasti uusien aurinkopuistojen myötä."*

> *"Moni ei ehkä vielä ymmärrä, kuinka paljon tarkastuksia ja valvontaa oikeasti tarvitaan – ajatus voi olla, että paneelit kestävät vuosikymmeniä ilman ongelmia."*

Toimiala-asenteiden osalta haastateltavien näkemyksissä ilmeni hieman poikkeavuutta. Osa haastateltavista oli sitä mieltä, että kuten muullakin energia-alalla, niin myös aurinkovoimassa toimialalla toimijat jakautuvat niihin, jotka rohkeasti uudistavat toimintamallejaan digitalisaation mahdollistamien ratkaisujen myötä ja toiset puolestaan ovat näkemykseltään konservatiivisempia toimijoita, jotka toteuttavat kunnossapitoa perinteisemmin menetelmin ja toimintamallien muutos heidän osaltaan on suuremman työn takana. H1 kiteyttää kokemuksensa kautta tunnistamansa energia-alan heterogeenisyyden:

> *"Energia-alan suhtautuminen konenäön ja tekoälyn hyödyntämiseen on heterogeenistä: osa toimijoista on hyvin perinteisiä, kun taas toiset etsivät digitalisaation avulla lisäarvoa."*

Aineistosta nousi vaihtoehtoinen näkemys toimialan kypsyydestä vastaanottaa ja omaksua moderneja kunnossapitomenetelmiä. Tämän näkemyksen mukaan aurinkovoimayritysten nähdään olevan joustavia ja vastuullisia toimijoita, jotka ovat tottuneet navigoimaan muutoksen eturintamassa. H4 ja H5 sitaatit allekirjoittavat tätä näkemystä:

> *"Aurinkovoimayritykset ovat eturintamassa ja tottuneita uusiin asioihin, joten ne ovat melko valmiita ottamaan uutta teknologiaa vastaan."*

> *"Suhtautuminen on positiivista – dronet tai dataperusteinen kunnossapito ei ole enää täysin uusi asia, ja vihreän energian tuottajat ovat vastuullisia."*

Markkinaa nähtiin ohjaavan myös erinäiset ulkoiset tekijät. Erityisesti toimialan ollessa toistaiseksi vielä niin nuori, nähtiin parhaillaan kehittyvän lainsäädännön ja regulaatioiden tuovan vaikutuksen siihen, mihin suuntaan kunnossapitoon liittyvien palveluiden markkina tulee kehittymään. Lisäksi erityisesti älykkäiden ratkaisujen kehittyessä ja kilpailun kiristyessä alalle voi mahdollisesti tulla heikkolaatuisia palveluntarjoajia, jotka voivat luoda negatiivistä mielikuvaa perinteisistä poikkeavia ratkaisuja kohtaan ja näin ollen jarruttaa markkinakehitystä. Haastatteluista nousi, että lainsäädännön kiristyminen voidaan nähdä

joko mahdollisuutena tai uhkana älykkäiden ratkaisujen kehittymiselle, riippuen siitä, millä tasolla lainsäädännön perusteella kunnossapidon valvontaa tullaan vaatimaan. H4 tiivistää:

> *”Uusien palveluiden käyttöönottoa voi jarruttaa epäluottamus ja huonot kokemukset – jos markkinoille tulee toimijoita, jotka lupaavat liikaa ja laatu ei vastaa todellisuutta.”*

Liiketoiminnallinen tarve ja potentiaali

Haastatteluaineiston perusteella aurinkovoimaloiden kunnossapitopalveluiden liiketoiminnallisen tarpeen ja potentiaalin kuvattiin liittyvän neljään alateemaan: asiakkaiden vaatimuksiin, voimaloiden kokojen kasvuun, voimaloiden määrän kasvuun sekä tarpeeseen optimoida aurinkovoimaloiden tuotantoa. Vaikka teollisen mittakaavan aurinkovoimalat ovat vasta parasta aikaa nousemassa Suomeen, tunnistavat haastateltavat asiakkaiden kuitenkin vaativan jo kunnossapitopalveluita osana aurinkovoimahankkeita. H7 esittää, että aurinkovoimaloiden ollessa pitkäaikaisia investointeja on alalla herätty siihen, että kunnossapitoa tulee suunnitella pidemmälle aikajänteelle jo aurinkovoimalan elinkaaren alkuhetkillä:

> *“Isommissa teollisen mittakaavan voimaloissa käyttö- ja kunnossapito sekä huolto ovat osa elinkaarta, ja asiakkaat edellyttävät niitä osana toimitusta.”*

> *“Kun voimala on rakenteilla, investoijan pitää jo miettiä käyttö- ja kunnossapidon järjestämistä koko elinkaaren ajalle – nämä voivat olla 40+ vuoden investointeja.”*

Investoijien heräämisen kunnossapidon merkitykseen lisäksi haastateltavat tunnistivat, että kuten työn teoriaosuudessakin esitettiin, voimaloiden määrä ja yksikkökoko on merkittävässä nousussa. Tämän nähtiin luovan tarpeen tehokkaammille ja uudenlaisille ratkaisuille, jotta kasvaviin kunnossapitovaatimuksiin pystytään vastaamaan ajallaan sekä kustannustehokkaasti. H10 näkee, että kunnossapitopalveluiden tarve kasvaa suoraan voimaloiden koon ja vikaantumisten riskitason nousun myötä:

> *“Kun paneelien määrä kasvaa, myös vikojen ja ääritilanteiden riski kasvaa.”*

Selkeästi myös kunnossapitopalveluiden tarvetta ajaa haastateltavien näkemysten mukaan omistajien halu optimoida aurinkovoimalansa tuotanto. Useat haastateltavat nostivat, että aurinkovoimaloita voidaan sijoittajien näkökulmasta ajatella investointina, jonka tuotantoastetta ylläpitämällä onnistut optimoimaan sijoituksesi kannattavuuden. H1 uskoo, että sijoittajat haluavat optimoida voimaloiden tuotannon ja sitä kautta saada mahdollisimman hyvän takaisinmaksuasetelman investoinnilleen, mutta hän uskoo myös, että investoijat eivät ole vielä välttämättä ymmärtäneet kunnossapidon merkitystä taloudellisessa mielessä:

> *”Väistämättähän tilanne menee siihen, että aurinkovoimalan omistajat ja sijoittajat haluavat optimoida tuotannon ja sitä kautta voitot. Yritykset saattavat tällä hetkellä ajatella, että voitat säästämällä kunnossapidossa. Kysymys kuuluu, milloin ymmärretään se, että kunnossapitoa kannattaa tietyissä määrin tehdä, että optimoidaan tuottavuus ja sitä kautta jäädään voitolle."*

H1 pohdinnasta nousee myös ilmi huoli siitä, missä menee kulminaatiopiste, että missä mittakaavassa kunnossapitotoimia on järkevää tehdä taloudellisessa mielessä ja missä mittakaavassa kunnossapitotoimia on perusteltua jättää tekemättä. Tämän vuoksi H1:n mukaan markkina todennäköisesti tulee hakemaan ratkaisuja, jotka ovat kustannustehokkaita eivätkä sido merkittävästi ihmisresursseja toteutukseen. H9 näkee automatisoitujen ratkaisujen merkittävän potentiaalin erityisesti suurissa voimaloissa, joissa jatkuva tilannekuva on tärkeä ja perinteisin menetelmin hankala saada sekä jatkuva ihmistyövoiman saatavuus rajallista.

> *“Suurissa voimaloissa on tarvetta automaattisille tarkastuksille – autonomiset dronet yhdistettynä konenäköalgoritmiin voivat toimia 24/7 ilman ihmisen läsnäoloa.”*

Kohdeyrityksen kilpailukyky ja palvelukonseptin luonti

Haastateltavien mukaan palvelun menestys rakentuu ennen kaikkea sen arvolupauksen ja asiakaslähtöisyyden varaan. Haastateltavien näkemyksen mukaan asiakkaat eivät ole ensisijaisesti kiinnostuneita siitä, toteutetaanko analyysi tekoälyn vai ihmisen avulla, vaan siitä, kuinka luotettavasti poikkeamat havaitaan ja kuinka palvelu vaikuttaa voimalan tuotantoon sekä käyttöasteeseen. H2 tiivisti näkemyksen seuraavasti:

> *"Tärkeintä on lopputulos – ei ole väliä, onko analyysin tehnyt ihminen vai kone, kunhan poikkeamat löytyvät."*

Lisäarvon osoittamisen lisäksi haastateltavat painottivat yksinkertaisen sekä ymmärrettävän viestinnän tärkeyttä. Palvelun arvon tulee olla helposti hahmotettavissa ja esitettävissä, kuten H5 kuvasi:

> *"Tuote pitää pystyä esittämään yhdellä kalvolla – asiakkaan on ymmärrettävä, mitä kohdeyritys tarjoaa ja mitä lisäarvoa palvelu tuo."*

Kustannustehokkuus nähtiin yhtenä selkeistä arvolupauksista, jota palvelun hankkijalle tulisi pystyä lupaamaan. Haastatteluissa korostui, että konenäköratkaisujen käyttöönoton perustelut nojaavat todennäköisesti vahvasti niistä saataviin taloudellisiin hyötyihin. Haastateltavien mukaan asiakkaille ratkaisut on pystyttävä perustelemaan esimerkiksi kustannussäästöjen, aikasäästön tai tuotannon luotettavuuden kautta. H2 korostaa tarvetta tuoda esille selkeitä liiketoiminnallisia hyötyjä:

> *"Monesti raha ratkaisee – konenäköratkaisut on perusteltava kustannustehokkuudella."*

Tähän liittyen haastateltavat korostivat myös tarvetta mitata ja todentaa palvelun tuottamaa hyötyä, esimerkiksi sähköntuotantoasteen kasvuna tai huoltokustannusten vähenemisenä.

Myynnin ja markkinoinnin osalta haastatteluissa nähtiin, että uuden palvelun lanseeraaminen edellyttää aktiivista myyntityötä ja tietoisuuden kasvattamista. Haastateltavat pitivät erityisen tärkeänä, että markkinoille onnistuttaisiin viestimään kunnossapidon todellisesta merkityksestä ja älykkäiden ratkaisujen konkreettisista hyödyistä, sillä edelleenkin alalla voi vallita virheellinen käsitys teollisen mittakaavan aurinkovoimaloiden huoltovapaasta luonteesta. Tietoisuuden lisäämisen nähtiin olevan keskeinen tekijä myös kysynnän luomisessa, kuten H4 esittää:

> *"Tietoisuuden kasvattaminen ja asiantuntija-artikkelit voisivat auttaa aurinkopuistojen omistajia ymmärtämään palvelun arvon."*

Haastatteluissa nousi myös tuotelähtöisiä näkemyksiä uuden palvelun pystyttämiseen. Tuotelähtöisyys esiintyi näkemyksinä, joissa tärkeimpänä seikkana palvelun menestykseen on, että kohdeyrityksen tulee priorisoida tuotteen tekninen toimivuus ennen laajempaa

kaupallistamista. Haastatteluissa korostui, että palvelun tulee olla teknisesti valmis ja luotettava ennen sen laajempaa kaupallistamista. H8 sanoitti tämän:

> *"Algoritmi pitäisi saada tehokkaaksi, eli pitää olla palvelu, joka toimii, ennen kuin sitä lähdetään myymään."*

Kansainvälistymisen näkökulmasta haastateltavat näkivät laajentumisen potentiaalin suurena, mutta edellyttävän vaiheittaista etenemistä. Näkemyksissä korostui ajatus, että kotimaiset referenssit ja pilotit muodostavat perustan uskottavalle kansainväliselle kasvulle. Samalla kansainvälistymisen liiketoimintamallin valinta nähtiin ratkaisevana. H6 korosti liiketoimintamallin valinnan tärkeyttä:

> *"Kyllä siinä kansainvälistymisen potentiaalia on – mutta pitää miettiä liiketoimintamalli, kannattaako lähteä laajentumaan fyysisesti vai tarjotaanko datapalvelua ulkoistetulla datankeruulla."*

Kohdeyrityksen sisäisten edellytysten osalta aineistosta nousi esiin useita vahvuuksia. Haastateltavat pitivät teknistä osaamista, analytiikkakyvykkyyttä ja organisaation taustoja merkittävinä kilpailuetuina. Lisäksi kumppanuuksien hyödyntäminen nousi aineistosta keskeiseksi keinoksi vahvistaa markkina-asemaa ja laajentua hallitusti. Erityisesti yhteistyöverkostojen ja sisäisten synergioiden nähtiin tukevan kilpailukykyä. Kansainvälistymistä puolestaan ehdotettiin toteutettavaksi kumppanuus- tai lisensointimallilla, jossa paikalliset toimijat vastaisivat datankeruusta ja yritys keskittyisi analytiikkaan ja koulutukseen. Tämä nähtiin kustannustehokkaana tapana laajentua ilman raskaita investointeja.

Aineistossa korostui myös markkina-ajoituksen merkitys. Uuden palvelun lanseeraaminen liian varhaisessa vaiheessa nähtiin riskinä, mutta oikea-aikainen avaus voisi tuoda merkittävän kilpailuedun. H1 korostaa markkina-ajoituksen tärkeyttä:

> *"Kohdeyrityksellä on mahdollisuuksia menestyä, mutta ajoitus ratkaisee – liian varhainen panostus voi lisätä riskiä, kun taas oikeaan aikaan tehty avaus voi tuoda etumatkaa."*

Älykkään kunnossapidon ja konenäön lisäarvo ja mahdollisuudet

Haastattelujen perusteella älykkään kunnossapidon ja konenäön tuottamaa lisäarvoa koskevat näkemykset olivat jaoteltavissa viiteen eri alateemaan: kustannustehokkuuteen, vikojen havaitsemiskykyyn, datalähtöisyyteen, resurssitehokkuuteen ja skaalautuvuuteen. Haastateltavat kuvasivat, että suurten teollisen mittakaavan aurinkovoimaloiden tarkastaminen manuaalisesti ei ole enää toteutettavissa tehokkaasti ja automatisoitujen tarkastusratkaisujen nähtiin olevan tulevaisuuden kannalta välttämättömiä. Tämä korostuu etenkin suurimpien voimaloiden kohdalla, kuten H7 kuvasi, viitaten Suomeen suunniteltujen voimaloiden kokoon:

> *"120 000 paneelin tarkastaminen ei ole ihmisvoimin realistista – niiden kuntoa ja mahdollisia vikoja ei voi enää tarkastaa silmämääräisesti, vaan automatisoiduille tarkastuksille on selvä tarve."*

Ilmasta suoritettujen tarkastusten hyötynä yhdistettynä konenäköön nähtiin erityisesti tarkastusprosessin nopeutuminen suhteessa perinteisiin jalkatarkastuksiin sekä manuaalisen työmäärän väheneminen. Useat haastateltavat toivat esiin, että suurien aurinkovoimaloiden läpikäyminen onnistuu droneilla ja ilmasta käsin huomattavasti manuaalista tarkastusta nopeammin, mikä nähtiin yhtenä keskeisenä kustannustehokkuuden lähteenä. Tätä kuvasi esimerkiksi H6:

> *"Dronet ja konenäkö tarkastusmenetelmänä ovat nopeita. Muutamassa tunnissa pystyy lennättämään ja koneellisesti tarkastamaan isonkin puiston."*

Vikaantumisten ja toimintapoikkeamien havaitsemisen osalta haastateltavat näkivät lämpökuvauksen mahdollistavan sellaisten paneelipoikkeamien tunnistamisen, joita ei voida silmämääräisellä tarkastuksella havaita. Konenäön tasalaatuisuuden ja objektiivisuuden nähtiin täydentävän näitä menetelmiä, sillä konenäön suorittaman analyysin katsottiin olevan johdonmukaista riippumatta kohteen koosta tai tarkastajan kokemuksesta:

> *"Konenäön etuna on väsymättömyys ja tasalaatuisuus – näitä piirteitä tulisi ratkaisussa tavoitella."*

Datalähtöisyyden osalta haastateltavat näkivät älykkään kunnossapidon perustuvan pitkän aikavälin dataan, jonka avulla voitaisiin tunnistaa aurinkovoimalan kuntotilanteen

kehityssuuntia ja optimoida huoltotoimenpiteitä. Kuvantamismenetelmien tuottaman datan arvioitiin toimivan mahdollistajana ennustaville kunnossapitomalleille ja tekoälyalgoritmien kehittämiselle. Tätä kuvasi H6:

> *"Kunnossapitoa kannattaa tehdä datan avulla – kuvantamismenetelmät ja tarpeeksi tiheä datankeruu mahdollistavat kunnossapitomallien ja tekoälyalgoritmien kehittämisen."*

Resurssien käytön näkökulmasta konenäön arvioitiin vähentävän tarvetta manuaaliseen työpanokseen ja nopeuttavan tarkastusprosessien läpimenoaikaa. Haastateltavat kuvasivat, että automaattinen datankeruu yhdistettynä konenäköalgoritmeihin voi vähentää fyysisen läsnäolon tarvetta tarkastusprosessissa ja tehostaa operatiivista toimintaa. Lisäksi konenäön nähtiin tukevan palvelun kustannustehokkuutta vähentämällä kalliista työvoimasta toteutuvia kustannuksia ja parantamalla tarkastusten laatua pitkällä aikavälillä.

Skaalautuvuuden osalta haastateltavat tunnistivat mahdollisuuden hyödyntää analytiikkaa eri markkina-alueilla ilman välttämätöntä fyysistä läsnäoloa, mikä mahdollistaisi palveluiden kansainvälisen tarjoamisen. Tämän lisäksi autonomisten dronejärjestelmien arvioitiin mahdollistavan tarkastusten tihentämisen ja kustannusten edelleen pienentämisen. Tätä kuvasi H10 seuraavasti:

> *"Konenäköalgoritmien hyödyntäminen avaa uusia markkinoita – dataa voidaan analysoida globaalisti ilman fyysistä läsnäoloa."*

Älykkään kunnossapidon ja konenäön rajoitteet ja epävarmuudet

Haastatteluaineiston perusteella älykkään kunnossapidon ja konenäön rajoitteita ja epävarmuustekijöitä koskevat näkemykset olivat jaoteltavissa seuraaviin alateemoihin: aurinkovoimatekniikan kehitys, ihmisen läsnäolon tarve, investointikustannukset, datan saatavuus, teknologiset rajoitteet sekä ulkoiset tekijät. Haastateltavat korostivat, että paneelitekniikan kehittyessä niiden ominaisuudet toimivat määrittäjänä sille, millaisia tarkastus- ja valvontamenetelmiä jatkossa tarvitaan. Tämä liittyi myös siihen, että uusien teknologioiden myötä myös konenäköpohjaisten ratkaisujen soveltuvuus voi muuttua, kuten H1 totesi:

> *"Aurinkovoimateknologian kehitys ja paneelien laatu sekä elinkaari vaikuttavat siihen, millaisia valvontamenetelmiä jatkossa tarvitaan ja miten konenäkö soveltuu pitkällä aikavälillä ratkaisuksi"*

Haastatteluissa yhdeksi keskeisimmistä rajotteista tunnistettiin ihmisen läsnäolon tarve. Vaikka drone- ja konenäköratkaisut tuovat tehokkuutta visuaaliseen tarkastukseen, niitä ei nähty riittäviksi korvaamaan fyysistä huoltoa, erityisesti invertterein ja sähköasemiin liittyvissä huoltotehtävissä. Suuri osa haastateltavista totesi, että kunnossapidossa vaaditaan edelleen teknistä osaamista ja paikalla olevaa henkilöstöä, mikä luo tarpeen hybridimalleille, joissa automaattisemmat ratkaisut ja manuaaliset toimenpiteet täydentävät toisiaan. Lisäksi haastateltavat nostivat esiin sen, että pelkkä lämpökuviin perustuva tarkastus voi jäädä irralliseksi palveluksi, ellei sitä liitetä osaksi laajempaa huoltokokonaisuutta.

Konenäköratkaisujen kehittämiseen liittyvistä teknisistä rajoitteista keskeisin oli opetusdatan saatavuus. Haastateltavat kuvasivat, että Suomen markkina on edelleen pieni, ja teollisen kokoluokan aurinkopuistoja on vähän, mikä rajoittaa tekoälyalgoritmien koulutukseen tarvittavan datan määrää ja hidastaa ratkaisujen kypsymistä, mikäli opetusdataa ei ole saatavilla muista lähteistä. Myös reaaliaikaiset mittausjärjestelmät ja halventuvat paneeleihin asennettavat sensorit nähtiin mahdollisena tulevaisuuden kehityssuuntana, joka voisi osittain korvata dronetarkastusten tarvetta erityisesti suurissa voimaloissa.

Teknologisiin rajoitteisiin liittyivät muun muassa komponenttien heikko näkyvyys, kalibrointihaasteet sekä järjestelmien monimutkaistuminen. Haastateltavat toivat esiin, että ilmasta otettavat lämpökuvat soveltuvat hyvin paneelipintojen tarkastukseen, mutta eivät välttämättä tavoita kaikkia voimalan rakenteita. Lisäksi lämpökameran kalibrointiin liittyvät haasteet voivat vaikuttaa analyysin luotettavuuteen, vaikka ne arvioitiin ohjelmallisesti korjattavissa oleviksi. Autonomiset datankeruun ratkaisut puolestaan vaativat haastateltavien näkemysten mukaan toimivia tietoliikenneyhteyksiä, minkä nähtiin voivan vaikeuttaa laajamittaista käyttöönottoa. Lisäksi lainsäädännöllä ja sääntelyllä haastateltavat näkivät voivan olla vaikutuksia siihen, missä määrin droneja ja konenäköä voidaan hyödyntää tai tarvitaan kunnossapidossa. H10 kuvasi tätä seuraavasti:

> *"Lainsäädäntö voi vaikuttaa siihen, kuinka paljon droneja tarvitaan tarkastuksissa."*

5.2 Haastattelutulosten analyysi

Haastatteluaineistoa tulkitsemalla voidaan muodostaa näkemys aurinkovoimaloiden kunnossapidon markkinasta, älykkäiden kunnossapitomenetelmien tarpeesta sekä palvelukonseptin rakentamisen edellytyksistä. Analyysissa kootaan yhteen tutkimuksen tavoitteiden ja konstruktion luonnin osalta merkittävimmät havainnot ja tulkinnat ja suhteutetaan niitä tutkimuksen tavoitteisiin.

Aineiston perusteella on tulkittavissa, että aurinkovoimaloiden kunnossapidon markkina on selkeässä kasvuvaiheessa, mutta vielä kypsymätön. Haastateltavat kuvasivat markkinaa kokonaisuutena, jossa teollisen mittakaavan aurinkovoimalat yleistyvät, ymmärrys kunnossapidon merkityksestä kasvaa sekä kunnossapitovastuu siirretään todennäköisesti useammin ulkoistetuille palveluntarjoajille. Nämä tekijät tukevat palvelun muodostamisen markkinaikkunaa, sillä tarve kehittyneille menetelmille tunnistetaan laajasti, mutta markkinalla ei vielä ole täysin standardoituneita käytäntöjä älykkäiden menetelmien suhteen. Toimiala-asenteet puolestaan ovat tulkittavissa aineiston mukaan kaksijakoisiksi, sillä osan toimijoista nähtiin suhtautuvan digitalisaatioon ja konenäköratkaisuihin varauksella, mutta toisaalta myös aurinkovoima-alan nähtiin olevan keskimääräistä modernimpi ja uusiin ratkaisuihin positiivisesti suhtautuva. Tästä voidaan päätellä, että palvelun vieminen alalle vaatisi selkeää arvolupausta ja uskottavia referenssejä, mutta ei välttämättä kohtaisi koko toimialan kattavaa vastustusta.

Liiketoiminnallisen tarpeen konseptille voidaan nähdä aineiston perusteella synnyttävän neljä ajuria:

- Asiakkaiden vaatimukset
- Voimaloiden kokojen kasvu
- Voimaloiden määrän kasvu
- Tarve tuotannon optimoinnille

Nämä ajurit tukevat konenäköön perustuvan tehokkaan tarkastuspalvelun pystyttämistä. Erityisesti suurimpien voimaloiden kohdalla perinteisten kävelytarkastusten todettiin olevan kustannustehottomia ja resurssi-intensiivisiä, mikä vahvistaa automatisoinnin ja

modernimpien ratkaisujen liiketoiminnallista perustetta. Samanaikaisesti markkina hakee ratkaisuja, jotka ovat kustannustehokkaita ja vähentävät ihmistyövoiman tarvetta.

Haastateltavien näkemysten mukaan konenäköön perustuvien aurinkovoimatarkastusten tuottama arvo nähtiin perustuvan tarkastusten nopeutumiseen, vaadittavien ihmistyöpanosten vähenemiseen, tasalaatuiseen ja objektiiviseen analyysiin sekä mahdollisuuteen hyödyntää dataa ja tuloksia pidemmän aikavälin kunnossapitomalleissa. Rajoitteet ja epävarmuustekijät nähtiin puolestaan liittyvän ihmisen läsnäolon tarpeeseen tietyissä huoltotehtävissä, opetusdatan niukkuuteen, teknologisiin rajoitteisiin ja lainsäädännön tuomiin epävarmuuksiin. Aineistosta nousseet hyödyt, mahdollisuudet, rajoitteet ja epävarmuustekijät muodostavat kokonaisuuden, joka huomioidaan työn myöhemmässä vaiheessa muodostettaessa palvelukonseptin kehitysehdotusta ja SWOT-analyysiä. Lisäksi palvelua perustettaessa arvokkaaksi nähtiin seuraavat tekijät, jotka tulee huomioita palvelukonseptin kehittämisen vaiheessa, mutta erityisesti kaupallistamisessa:

- Selkeä arvolupaus
- Mahdollisuus osoittaa palvelusta koituva konkreettinen hyöty
- Tekninen luotettavuus

Aineston tulkinnan yhteenvetona markkinatilanne, teknologiset mahdollisuudet sekä kohdeyrityksen kyvykkyydet muodostavat tukevan perustan konenäköön perustuvan kunnossapitopalvelun kehittämiselle.

6 Palvelukonseptin konstruointi

Tässä luvussa muodostetaan kohdeyritykselle konenäköä hyödyntävä tarkastuspalvelun konseptiehdotus. Ensin kuvataan palvelun nykytila, jonka jälkeen haastatteluaineistosta johdettuja analyysihavaintoja ja kirjallisuuden keskeisiä löydöksiä hyödyntämällä muodostetaan konenäköä hyödyntävän palvelukonseptin ehdotus. Luvun lopussa konseptia arvioidaan SWOT-analyysin avulla, joka perustuu empiirisestä aineistosta muodostettuihin teemoihin ja aiempaan tutkimuskirjallisuuteen.

6.1 Palvelukonseptin nykytila

Tässä luvussa esitetään kohdeyrityksen nykyisen tarkastuspalvelun analyysi. Nykytilan kuvaamisen avulla jäsennetään, mistä prosessivaiheista kohdeyrityksen tarkastuspalvelu muodostuu. Prosessirakenteen ymmärtäminen on tutkimuksen kannalta keskeistä, jotta havaittuja kehitystarpeita ja -mahdollisuuksia voidaan myöhemmin hyödyntää systemaattisesti konenäköpohjaisen palvelukonseptin ehdotuksen rakentamisessa.

Nykyinen prosessimalli esitetään tarkoitetusti tiivistetyssä muodossa. Prosessimallinnukseen sisällytetään ne osa-alueet, jotka ovat tutkimuksen kannalta keskeisiä, kun taas yksityiskohtaisemmat ja tutkimuksen ulkopuolelle kohdistuvat prosessiosat rajataan tarkastelun ulkopuolelle. Luvussa tarkastellaan sekä datankeruuprosessi että analyysiprosessi, mutta tarkastelun painopiste kohdistuu analyysiprosessiin, sen muodostaessa olennaisen osan konenäön liitettävyyden arviointia. Kuva 9 esittää datankeruun prosessimallia.

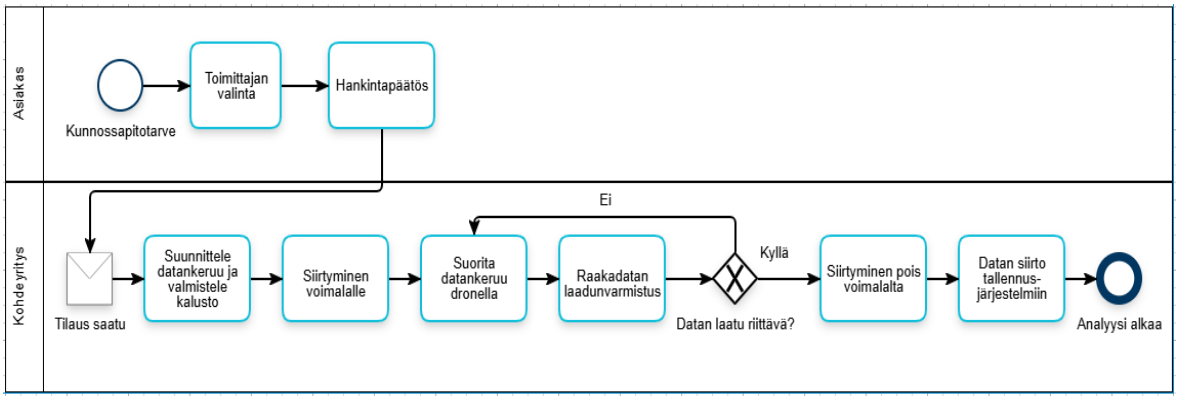

Kuva 9: Datankeruun prosessimalli

Kohdeyrityksen tarjoamat palvelut aurinkovoimaloiden kunnossapitoon perustuvat drone- ja lämpökamerateknologiaan. Prosessimallin mukaisesti kohdeyritys on pääasiallisesti suorittanut datankeruun itse. Prosessi käynnistyy asiakkaan voimalan kunnossapidon tarpeesta ja tämän myötä tehtävästä hankintapäätöksestä. Kun kohdeyritys on saanut tilauksen, alkaa datankeruun suunnittelu, jossa käydään läpi kohteen sijainti, miehittämätöntä ilmailua rajoittavat tekijät sekä suunnitellaan datankeruu ohjelmoimalla ilma-alukseen syötettävä automaattireitti. Tämän jälkeen kohdeyrityksen henkilöstö siirtyy aurinkovoimala-alueelle paikan päälle mukanaan lennokkikalusto ja lämpö- sekä värikuvaukseen tarvittavat sensorit. Datankeruu suoritetaan seuraavaksi aurinkovoimala-alueella suunnitelman mukaisesti. Kun datankeruu on suoritettu, tehdään kerätylle datalle laadunvarmistus. Mikäli laadunvarmistuksen tuloksena on, että data on laadultaan haluttua, siirrytään pois voimala-alueelta ja jos laatu ei ole riittävää, suoritetaan datankeruu uudestaan. Kun alueelta on siirrytty pois, siirretään kerätty data kohdeyrityksen tallennusjärjestelmiin analyysiä varten.

Toinen osa tarkastusprosessia on analyysivaihe, jossa varsinainen asiakkaalle tuotettava kunnossapitotieto voimalasta muodostetaan. Kuva 10 esittää prosessimallia nykyisestä analytiikan prosessista.

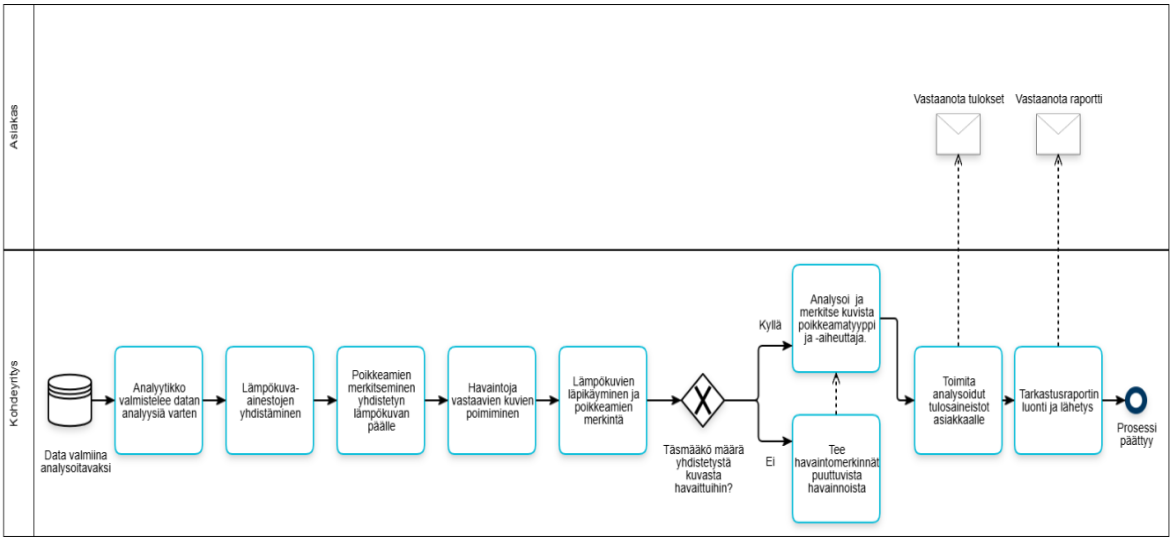

Kuva 10: Nykyinen tarkastuspalvelun analyysin malli

Nykyinen analytiikkaprosessi alkaa siitä hetkestä, kun kerätty raakadata on säilötty kohdeyrityksen tallennusjärjestelmiin ja on analyytikolle sieltä saatavilla. Raakadatalla tarkoitetaan tässä tilanteessa voimala-alueelta systemaattisesti kerättyjä lämpökuvia sekä värikuvia ilman, että niille on suoritettu vielä minkäänlaista käsittelyä. Kun raakadatat löytyvät tallennusjärjestelmistä, lataa analyysin suorittava henkilö datat työasemalleen valmiiksi analyysille. Tämän jälkeen aineistoille suoritetaan yhdistäminen, jossa kaikki lämpökuvat yhdistetään sijaintitietoa ja kuvien keskinäistä kuvapeittoa hyödyntäen yhdeksi suureksi kokonaiskuvaksi voimalasta. Kun yhdistäminen on tehty, asetetaan yhdistetty kuva karttanäkymään paikkatieto-ohjelmistoon, jonka jälkeen se käydään systemaattisesti paneeli kerrallaan lävitse ja poikkeavat paneelit merkitään poikkeamahavainnolla paneelin ulkoreunojen mukaisella paikkatietomerkinnällä. Tämän jälkeen hyödyntämällä kuvanottosijainteja suhteessa yhdistetystä kuvasta havaittuihin poikkeamiin paikallistetaan yksittäiset kuvat, joissa poikkeamat ovat esiintyneet ja nämä kuvat merkitään tai siirretään omaan sijaintiinsa seuraavaa vaihetta varten. Lopuksi, jotta varmistutaan siitä, että kaikki lämpökuvista havaittavissa olevat poikkeamat on huomattu, käydään loputkin lämpökuvat vielä manuaalisesti läpi ja niistä havaitut uudet poikkeamat on merkittävä. Seuraavaksi verrataan yksittäisistä kuvista tehtyjen havaintojen lukumäärää ja sijaintia yhdistetystä kuvasta tehtyihin. Mikäli yksittäisistä kuvista vertailussa nousi uusia havaintoja, joita ei ollut merkitty havainnoin, tehdään niistäkin havaintomerkinnät. Seuraavaksi alkaa itse poikkeamien analysointi. Analyytikko kirjaa havainnoille poikkeamatyypin sekä

mahdollisen aiheuttajan, joka ilmenee joko lämpöpoikkeaman muodosta tai värikuvista. Kun havainnoille on analysoitu aiheuttajat ja poikkeamatyypit, julkaistaan tulokset asiakkaalle verkkoselainpohjaiseen palveluun, josta löytyy karttapohjalta yhdistetty lämpökuva voimalasta, havainnot yhdistettyyn kuvaan merkittyinä sekä havaintotiedoista poikkeamatyyppi ja mahdollinen aiheuttaja. Lisäksi tarkastuksesta kirjataan tarkastusraportti, jossa on luotu yhteenveto projektin etenemisestä, tehdyistä havainnoista sekä projektin tuloksista.

Kuten prosessimalleista ja -kuvauksesta käy ilmi, ilman konenäköä tai automatisointia suoritettava tarkastusanalyysi on sellaisenaan hyvin resurssisitovaa eikä erityisen kustannustehokasta. Manuaalisia työvaiheita on useita ja jokainen analyysin vaiheista vaatii tarkkaavaista ihmistyötä ja näin ollen altistaa analyysin ihmisvirheille. Aurinkovoimaloiden koon kasvaessa myös ihmistyön määrä kasvaa verrannollisesti ja tätä kautta myös virheiden mahdollisuus kasvaa. Lisäksi lämpö- ja niitä tukevien värikuvien analyysi perustuu pitkälti analyytikon kokemukseen, mikä tekee analyysin laadun ja tulosten toistettavuudesta ongelmallista ilman erikseen määritettyä analyysin viitekehystä, jonka täsmällinen noudattaminen on mahdollista. Nämä tekijät muodostavat selkeitä kipupisteitä ja haasteita palvelun toteuttamiselle isossa skaalassa, erityisesti tilanteissa, joissa tarkastuksia tehdään useille kohteille lyhyen ajan sisään ja asiakkaat edellyttävät nopeaa raportointia. Tässä luvussa havaittuja palvelun kipupisteitä tullaan käyttämään perusteena myöhemmin empiriassa muodostettaville kehitysehdotuksille palvelun kehittämisestä.

6.2 Palvelukonseptin kehitys

Aiemmissa vaiheissa analysoitiin tarkastuspalvelun nykytilaa sekä liiketoiminnallista tarvetta. Nykytilan analyysissa ja haastatteluaineiston analyysissa nousi esille selkeät perusteet palvelukonseptin kehittämiselle. Nykyisellään ilman konenäköä tai suurempia automatisoituja prosessinvaiheita tarkastuspalvelu on vahvasti manuaalinen, aikaa vievä sekä altis ihmisvirheille. Nämä asiat rajoittavat palvelun skaalautuvuutta kasvavassa markkinassa.

Haastattelutuloksista ja sen analyysistä nousi esiin selkeä liiketoiminnallinen ja teknologinen tarve automaattisemmille ja kustannustehokkaille kunnossapitoratkaisuille. Markkinan kehityssuunta, asiakkaiden kasvavat kunnossapidolliset vaatimukset sekä

toimiala-asenteiden siirtyminen kohti elinkaariajattelua tukevat konenäköä hyödyntävän palvelukonseptin kehittämistä. Ratkaisu voisi potentiaalisesti mahdollistaa prosessin osittaisen automatisaation, johdonmukaisemman analyysin sekä nopeamman analyysin.

Seuraavaksi luvussa kehitetään ehdotus konenäköön perustuvasta palvelukonseptista ja sen keskeisistä elementeistä. Palvelun kehitysehdotukset tullaan esittämään prosessimallinnuksena. Palvelukonseptin kehitysehdotukset perustuvat nykyprosessin haasteisiin, haastatteluaineistoista nousseisiin markkina- ja liiketoimintaperusteisiin, kohdeyrityksen tunnistettuihin valmiuksiin sekä kirjalliseen konstruktioon, joka on sovellettuna hyödynnettävissä osana palveluprosessia.

Kirjallisuuden pohjalta voidaan muodostaa kehitysehdotukset palveluprosessiin niin, että konenäköä hyödynnetään suoraviivaistamaan prosessia, mutta ei täysin automatisoimaan diagnostiikkaa, sillä opetusdatan saatavuus voi koitua myös tutkimuksen kohdeyrityksen haasteeksi (Mellit & Kalogirou 2025). Kuva 11 esittää prosessimallinnusta konenäköä hyödyntävästä toimintamenetelmästä aurinkovoimaloiden kuntotarkastukseen.

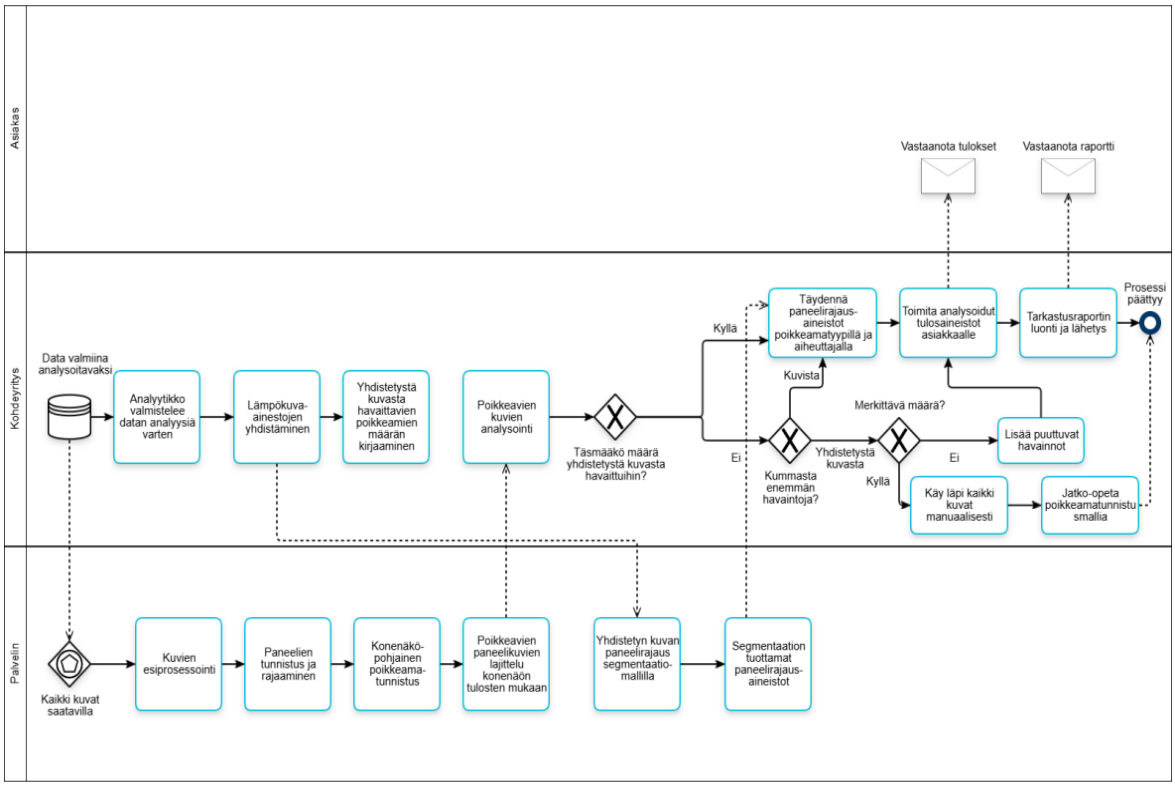

Kuva 11: Konenäköä hyödyntävän analytiikan ehdotus

Kirjallisuuden tutkimisen myötä kehityskohteita tunnistettiin olemassa olevaan tarkastusprosessiin erityisesti poikkeamatunnistuksen ja paneelisegmentoinnin kautta, jotka tukevat haastatteluissa noussutta tarvetta nostaa prosessin automaatioastetta. Prosessi alkaa niin, että kun data on saatavilla tallennusjärjestelmässä, alkaa automaattisesti kuvien esiprosessointi. Kuvien esiprosessoinnilla tarkoitetaan tehtäviä, joiden avulla syöteaineistosta muodostetaan mahdollisimman laadullisesti yhtenäinen. Mellit & Kalogirou (2025) esittivät kirjallisuuskatsauksessaan esiprosessoinnin pitävän sisällään tyypillisesti geometristä oikaisua, kontrastin ja valaistuksen normalisointia sekä kohinanpoistoa. Kun esiprosessointi on suoritettu, siirrytään prosessissa konenäköpohjaiseen paneelirajaukseen, jonka tehtävänä on luoda seuraavaa mallia varten syöteaineisto kuvista, jotka sisältävät vain paneeleja. Paneelitunnistuksen jälkeen prosessissa siirrytään poikkeamantunnistuksen konenäkömallille, joka saa syöteaineistoksi paneelitunnistuksen tulokset. Tämän lähestymisen avulla, jossa konenäköprosessi pitää sisällään ensiksi paneelintunnistuksen ja sen jälkeen poikkeamatunnistuksen parantaa prosessin luotettavuutta, vähentää väärien positiivisten määrää ja laskentatehon tarvetta, kun poikkeamien kannalta tarkasteltava alue on ennalta rajattu vain paneeleihin (Segovia Ramirez et al. 2022).

Saman aikaisesti prosessissa analyytikko on suorittanut lämpökuvien sijaintitietoon perustuvan yhdistämisen, kuten nykypalvelussakin. Kun yhdistetty kuva on valmis, tehdään laadunvarmistusta varten silmämääräinen tarkastus yhdistetystä kuvasta havaittujen poikkeamien määrästä, jotta tätä voidaan myöhemmässä vaiheessa verrata konenäön tekemien havaintojen määrään. Yhdistetyn kuvan valmistuttua syötetään aineisto palvelimelle, jotta se voidaan syöttää paneelisegmentaatiomallille paneelin ulkoreunojen mukaisen aineiston luontiin. Yhdistetystä kuvasta tehdään paneelirajaukset Mask RCNN-tyyppisen mallin tunnistamien tunnistuslaatikkojen perusteella (Vlaminck et al. 2022). Tämän perusteella saadaan kaikille kuvatun voimalan paneeleille luotua ulkorajausten mukainen paikkatietotaso, mikä mahdollistaa haluttaessa jopa koko paneelikentän digitoinnin asiakkaalle paneelikohtaisesti ilman suurempaa manuaalista työtä. Pääosin tarkastusprosessissa paneelirajausaineistoa hyödynnetään kuitenkin havaintojen esittämiseen.

Kun poikkeamat kuvista on tunnistettu ja yhdistetty kuva-aineisto paneelidigitointeineen on luotu, siirtyy poikkeavaksi luokitellut kuvat takaisin asiantuntevan analyytikon käsittelyyn. Asiantuntija käy poikkeamat läpi ja merkitsee kuvia vastaaviin paneelirajausaineistoihin

havainnon tyypin sekä aiheuttajan. Tämän jälkeen laadunvarmistuksen toimenpiteenä asiantuntija tekee määrällisen vertailun havainnoille, jotka tehtiin konenäön toimesta yksittäisistä kuvista sekä yhdistetystä kuvasta silmämääräisesti. Jos määrä täsmää, on konenäköalgoritmi todennäköisesti onnistunut poikkeamatunnistuksessa. Jos määrä poikkeaa merkittävästi, on merkityksellistä, kumpi havaitsi enemmän havaintoja: asiantuntija silmämääräisesti yhdistetystä kuvasta vai konenäkö yksittäisistä kuvista. Mikäli konenäkö teki enemmän havaintoja, tehdään puuttuvista havainnot yhdistetyn kuvan päälle ja väärät positiiviset havainnot poistetaan. Mikäli taas yhdistetystä kuvasta on selvästi nähtävissä enemmän havaintoja, kuin mitä konenäkö teki, on oletettavaa, että konenäöltä on jäänyt poikkeamia havaitsematta. Tässä tapauksessa tulee kaikki kuvat käydä manuaalisesti läpi, jotta voidaan varmistua toimituksen laadusta ja jatko-opettaa konenäkömallia suuremmalla määrällä opetusdataa, jotta tunnistuksen luotettavuus paranee. Lopuksi aineistojen toimitus asiakkaalle toteutetaan tuotetuilla aineistoilla sekä raportilla.

Tämä esitetty konenäköä hyödyntävä prosessimalli parantaa prosessia vähentämällä huomattavasti manuaalisia työvaiheita prosessista sekä tehostamalla koko analytiikkaprosessia. Kehitetyn prosessimallin myötä asiantuntijan työ keskittyy yhä enemmän poikkeamien tulkintaan ja laadunvarmistukseen, kun taas suurin osa kuvien käsittelystä sekä alustavasta analyysista suoritetaan automaattisesti. Keskeisimpiä tunnistettavia hyötyjä kehitetyllä palveluprosessilla voidaan nähdä:

- Lämpökuvien manuaalinen läpikäyminen poistuu, sillä konenäkömallien avulla poikkeavuudet tunnistetaan automaattisesti
- Manuaalinen paneelireunojen digitointi ei ole tarpeellista, sillä paneelien segmentointimallin myötä paneelikohtaiset maskit voidaan georeferoida suoraan yhdistettyyn kuvaan
- Analyysin johdonmukaisuus sekä toistettavuus paranee.
- Prosessin läpimenoaika lyhenee
- Laadunvarmistus vahvistuu, sillä konenäön tuottamat havainnot voidaan vertailla asiantuntijan silmämääräisiin tarkastuksiin, mikä parantaa tulosten luotettavuutta ja yhtenäisyyttä.

Prosessin onnistumisella on kuitenkin myös edellytyksiä. Päällimmäisenä edellytyksenä on opetusdatan määrä ja laatu. Kuten Korkmaz & Acikgoz (2022) osoittivat, monipuolinen ja tasapainotettu datasetti on edellytys konenäkömallin onnistumiselle. Tämä pätee erityisesti

jatko-opetuksessa, mikäli esitettyä prosessimallia kehitetään eteenpäin siihen pisteeseen, että poikkeamien luokittelukin tapahtuu konenäön toimesta, mutta on olennaista jo pelkässä poikkeamatunnistuksessa. Lisäksi opetusdatan laatu on suorassa yhteydessä siihen, kuinka skaalattavissa palvelu on. Mikäli halutaan kehittää oma malli, joka on sopeutettavissa eri voimalatyyppeihin ja kuvausolosuhteisiin, on opetukseen käytettävän datasetin oltava laajuudeltaan ja laadultaan erinomainen (Mellit & Kalogirou 2025). Mikäli luokittelukin halutaan automatisoida myöhemmässä vaiheessa, on palveluntarjoajan sisällytettävä mallien jatkokehitys keskeiseksi osaksi toimintamallejaan. Jatkokehityksen tulisi perustua asiantuntijan tekemiin korjauksiin ja havaintoihin, joita käytetään mallien jatkokoulutukseen.

Täydellinen automaatio ei tämän tarkastelun perusteella ole vielä realistista toteuttaa, mutta luvussa esitetty konenäön vaiheittainen integrointi tarjoaa kohdeyritykselle luontevan polun kohti kustannustehokkaampaa, skaalautuvaa sekä johdonmukaista aurinkovoimaloiden tarkastuspalvelua. Mallin myötä polku myös entistä automaattisempiin ja kustannustehokkaampiin ratkaisuihin aukeaa.

6.3 SWOT-Analyysi

Tutkimusraportin empiirisen osuuden viimeisessä luvussa ennen johtopäätöksiä muodostetaan SWOT-analyysi konenäköä hyödyntävästä aurinkovoimaloiden älykkään kunnossapidon palvelukonseptista. SWOT-analyysi muodostetaan perustuen sekä haastatteluaineistoissa tunnistettuihin vahvuuksiin, heikkouksiin, uhkiin ja mahdollisuuksiin sekä kirjallisuudesta nousseisiin vastaaviin. Tavoitteena on luoda kattava ymmärrys konenäön tuomista vaikutuksista palveluun sekä kuinka ulkoiset mahdollisuudet ja uhat vaikuttavat konseptin kehittämis- sekä markkinaedellytyksiin. Taulukko 5 esittää konenäköä hyödyntävän tarkastuskonseptin vahvuudet, heikkoudet, uhat ja mahdollisuudet SWOT-nelikenttämatriisissa.

Taulukko 5: SWOT-analyysimatriisi

Vahvuudet (sisäiset)	**Heikkoudet** (sisäiset)
● Kustannustehokkuus ● Vähentynyt ihmistyön sitovuus ● Johdonmukaisemmat ja tarkemmat analyysit ● Tiheämpi ja ennakoivampi tarkastaminen	● Ihmisen läsnäolon välttämättömyys tietyissä tarkastuksissa ● Laajan ja monipuolisen opetusdatan tarve ● Annotointi ja esiprosessointimenetelmien määritys vaativat investoinnin ● Vikatyyppi ei aina tunnistettavissa lämpökuvista ● Segmentointi rajoittaa laajojen vikojen automaattista havaitsemista
Mahdollisuudet (ulkoiset)	**Uhat** (ulkoiset)
● Teollisen mittakaavan voimaloiden määrän kasvu ● Skaalautuvat ja kansainväliset palvelumallit ● Kumppanoituminen osaksi laajempaa kunnossapidon arvoketjua ● Markkinan siirtyminen tuotannon optimointiin datalähtöisesti ● Algoritmien kehityspotentiaali	● Vaihtoehtoiset menetelmät ● Markkinan kypsymättömyys ja vaihtelevat asenteet ● Kova kilpailu ja kansainvälinen etumatka ● Lainsäädäntö ja regulaatio

Vahvuudet

Konenäköä hyödyntävän aurinkovoimaloiden tarkastusprosessin hyödyt perustuvat pitkälti alan tarpeeseen löytää toimialaa mullistavia, kustannustehokkaita ratkaisuja, jolla aurinkovoimaloiden omistajat ja kunnossapidosta vastaavat tahot pystyvät pysymään tietoisina voimalansa kunnosta ja reagoimaan poikkeamiin, ennen kuin voimalan tuottavuus laskee. Perinteiset tarkastukset sitovat paljon ihmistyövoimaa, ovat kalliita sekä joskus jopa vaarallisia. Toimialalla haetaan tehokkaampia viantunnistamis- ja paikantamismenetelmiä, ei pelkästään siksi, että ne ovat kustannustehokkaampia vaan myös siksi, että viat voidaan havaita mahdollisimman ajoissa, jolloin aika, minkä vika vaikuttaa tuotantoon olisi minimaalinen (Vlaminck et al. 2022). Keskeisimpänä etuna verrattuna perinteisiin tarkastusmenetelmiin on konenäköä hyödyntävässä ratkaisussa menetelmän **kustannustehokkuus** ja automatisaation tuoma **kyky vapauttaa ihmistyövoimaa** muihin tehtäviin (Mellit & Kalogirou 2025; Memari et al. 2024). Myös haastatteluissa sama ilmiö tunnistettiin keskeisimpänä potentiaalin lähteenä konseptissa, jonka H2 tiivistää seuraavasti:

> *"Konenäköanalyysillä on potentiaalia erityisesti suurissa voimaloissa, joissa paneeleja on kymmeniä tai satojatuhansia – manuaalinen tarkastus on liian työlästä."*

Tehokkuuden ja automatisaation lisäksi konenäön hyödyntäminen vaikuttaa merkittävästi analyysiprosessiin vahvistaen sitä. Kun konenäkö yhdistetään osaksi analyysiprosessia, nousee tulosten toistettavuus ja henkilöstä riippuvaisten tulkintaerojen vaikutus analyysissä pienenee (Spajić et. al 2024). Vaikkakin työssä ehdotettu portaittainen konenäön integrointi osaksi tarkastuspalvelua ei tee analyysiä täysin automaattiseksi ja asiantuntijaa tarvitaan vielä havaintojen luokitteluun, on ensimmäinen analyysi ja vikojen paikantaminen toteutettu täysin samojen parametrien mukaisesti, mikä johtaa **johdonmukaisempaan lopputulokseen**. Suuren luokan voimaloissa, jossa paneeleja voi olla kymmeniä tai satojakin tuhansia, voi konenäkö olla jopa ihmissilmää tarkempikin. Spajic et. al (2024) esittikin että oikein toteutettu konvoluutioneuroverkkoratkaisu ei paranna ainoastaan tehokkuutta, vaan myös tarkastustarkkuutta varmistaen paneelien luotettavan toiminnan koko elinkaaren ajalle. Haastatteluaineiston analyysissä yksi konenäön tuoman keskeisimmistä vahvuuksista olikin johdonmukaisuus.

Vahvuuksia konenäköä hyödyntävällä konseptilla ovat tehokkuuden lisäksi myös johdannaisvaikutukset, jotka ovat peräisin siitä, että palvelua voidaan tarjota kustannustehokkaammin sekä vähemmän ihmistyötä vaatien. Positiiviset vaikutukset heijastuvat sekä palveluntarjoajan, että aurinkovoimalan omistajien suuntaan. Kustannustehokkaampien ja automaattisempien ratkaisujen myötä aurinkovoimalan **tiheämpi tarkastusväli** on mahdollista ylläpitää ja ennakoivampi kunnossapitomalli mahdollistuu samalla, kun palveluntarjoaja pystyy tarjoamaan palvelua myös liiketoiminnallisen kannattavuuden näkökulmasta tehokkaammin ja kannattavammin (Abro et al. 2024).

Heikkoudet

Heikkouksista keskeisimpinä tunnistettiin, että aurinkovoimalan lämpökuvaukseen perustuva tarkastus **ei automaattisesti poista tarvetta ihmisen tekemällä tarkemmalle tarkastukselle**. Droneperusteinen datankeruu sekä konenäön yhdistelmä soveltuu erinomaisesti visuaaliseen tarkastukseen, mutta konsepti ei kykene korvaamaan ihmisen

tekemää fyysistä huoltoa tai syvällisempää teknistä arviointia. Useat vakavammat viat voivat vaatia kenttätestausta tai fyysistä pääsyä paneelin luokse (Bosman et al. 2020). H10 tiivistää:

> *"Drone ei pysty täyttämään koko tarkastustarvetta, kuten korjaustoimenpiteitä tai sähkökomponenttien yksityiskohtaisia tarkastuksia."*

Vaikka useat tutkimukset osoittivatkin lupaavia tuloksia erityisesti poikkeamatunnistuksessa, on teknisen toteutettavuuden osalta realiteetteja, jotka voidaan nähdä palvelukonseptin kehittämisen kannalta heikkouksina. Selkeimpänä heikkouksista on **laajan ja monipuolisen opetusdatan tarve** mallin luontiin. Vaikka aurinkopaneelit ovat tekniikaltaan sekä ulkomuodoiltaan pääasiallisesti hyvin samannäköisiä, voi kuvattavassa aurinkovoimatekniikassa tai kuvausolosuhteissa esiintyä poikkeavuuksia, mikä voi aiheuttaa mallin tarkkuuden kannalta lähtödataan ongelmia, mikäli mallia on koulutettu tästä poikkeavalla datalla (Mellit & Kalogirou 2025). Mikäli konenäköratkaisusta halutaan globaali ja skaalautuva ratkaisu, jota on sovellettavissa suurimpaan osaan puistoista, tulee mallin opetus toteuttaa riittävän monipuolisella ja laajalla datalla. Tämä heikkous korostuu erityisesti vikaluokitteluun tarkoitetulla mallilla, jossa jokaisesta eri vikaantumistyypistä tarvitaan tasapainoinen sekä laaja määrä opetusdataa (Korkmaz & Acikgoz 2022). Tämän lisäksi mallin kehittämiseen vaadittu **annotointityö on merkittävä aikainvestointi sekä vaatii asiantuntemusta** (Peng et. al 2025). Tästä syystä luokittelumallin opetus tulisi yhdistää asiantuntijan tekemiin havaintoihin tarkastusten yhteydessä. H3 tunnistaa alueellisen opetusdatan saatavuuden heikkoutena:

> *"Konenäön kehittäminen edellyttää laajaa opetusdataa – Suomessa ei vielä ole riittävästi teollisen kokoluokan voimaloita datan keruuseen."*

Viimeisinä merkittävinä heikkouksina tarkastusmenetelmään, joka perustuu lämpökuvaamiseen, tunnistettiin että vaikka lämpökuvat ovat erinomainen tapa tunnistaa poikkeavuuksia paneelien toiminnassa, **ei lämpökuvasta välttämättä pysty tunnistamaan vianaiheuttajaa**, jolloin lämpökuva-analyysiä tukevaa dataa tarvitaan luotettavan analyysin suorittamiseksi (Mellit & Kalogirou; Vlaminck et. al 2022). Lisäksi menetelmällä, jossa paneeleille tehdään paneelisegmentaatio konenäöllä ennen poikkeamatunnistusta, on heikkoutena **hankaluus tunnistaa laajempia toimintahäiriöitä**, jonka vaikutus kohdistuu useampaan, kuin yksittäiseen paneeliin (Memari et al. 2024).

Mahdollisuudet

Mahdollisuuksia konenäköä hyödyntävän konseptin ympärillä tunnistettiin runsaasti sekä haastatteluissa, että kirjallisuudessa. Keskeisimpänä mahdollisuutena on aurinkovoimaloiden **voimakkaassa kasvussa oleva kunnossapitomarkkina**. Aurinkovoima-alan nopea kasvu sekä teollisen mittakaavan voimaloiden yleistyminen luovat merkittäviä mahdollisuuksia moderneille tarkastusmenetelmille, erityisesti automatisoiduille tarkastus- ja kunnossapitopalveluille. Kasvutrendi ilmeni sekä kirjallisuuden kautta, jossa toistuvasti todettiin aurinkovoimaloiden määrän olevan kasvussa uusiutuvien energiantuotantomuotojen yleistyessä sekä myös haastatteluissa (Polymeropoulos et al. 2024; Spajić et al. 2024; Tang et al. 2024). H5 tiivistää markkinan kasvutilanteen näkemyksensä mukaan:

> *"Aurinkovoima on nyt samassa murrosvaiheessa kuin tuulivoima oli 2010-luvun alussa – teollisen mittakaavan hankkeet ovat kasvussa ja suunnittelupöydällä on valtavasti uusia projekteja."*

Toisena konenäköpohjaisen analytiikan merkittävänä mahdollisuutena voidaan pitää palvelun **skaalautuvuutta ja kansainvälistettävyyttä**. Sekä teorian, että haastateltavien näkemyksen mukaan analytiikkapalvelut on mahdollista irroittaa paikallisesta suorituskyvystä ja tuottaa keskitetysti esimerkiksi pilvipalveluna, mikä tukee skaalattavuutta. (Vlaminck 2022; Segovia Ramirez 2024). Haastattelut tukevat tätä vahvasti, sillä useat haastateltavat korostivat näkevänsä potentiaalia konseptilla kansainvälistymiselle, kunhan liiketoimintamalli valitaan oikein. Haastatteluaineiston analyysissa korostui teknologian ja oikean liiketoimintamallin valinnan myötä aukeavan uusia sijainnista riippumattomia markkinamahdollisuuksia.

Näiden lisäksi tunnistettuna mahdollisuutena on **liittyminen kumppanuuksiin osana laajempaa kunnossapidon arvoketjua**. Teorian mukaan aurinkovoimaloiden kunnossapitoratkaisut ovat kehittymässä kohti verkostomaisia ratkaisuja, joissa analytiikka, datankeruu ja kenttätoimenpiteet voivat olla eri toimijoiden vastuulla (Bokrantz et al. 2020a; Mohanty 2025). Liittyminen osaksi laajempaa kunnossapidon arvoketjua voisi madaltaa kohdeyrityksen kynnystä edetä markkinoille sekä vähentää vaadittavia investointeja.

Haastatteluissa ilmeni, että markkinoille palveluntarjoajaksi eteneminen tulisikin toteuttaa kumppanuuksien kautta.

Neljäs mahdollisuus on aurinkovoimaloiden kunnossapidon markkinan **siirtymä datalähtöiseen ja ennakoivaan kunnossapitoon**, jonka kirjallisuus tunnistaa aurinkovoimaloiden kunnossapidon todennäköisenä seuraavana kehitysvaiheena (Mellit & Kalogirou 2025 & Spajić et al. 2024). Haastatteluissa tuotiin esiin, että datan keruun mahdollisuudet ovat digitalisaation myötä kasvaneet ja samalla asiakkaat alkavat nähdä kunnossapitotoimet investointina tuotannon optimointiin. Tämä kehityssuunta mahdollistaa modernimpien ja älykkäämpien palvelumallien luonnin, jossa lämpökuvien tehtävä ei ole tuottaa vain tarkastushetken tilannekuva vaan olla osana jatkuvaa tilannekuvaa.

Edellä mainittu markkinan siirtyminen datalähtöisyyteen tukee myös seuraavaa mahdollisuutta, joka liittyy konenäköalgoritmien ja älykkäiden kunnossapitoratkaisujen **jatkokehityspotentiaaliin**. Haastatteluaineistossa tunnistettiin selkeä tarve poikkeamien automaattiselle luokittelijalle, vaikkakin sen realistisessa toteuttamisessa nähtiinkin toistaiseksi rajoitteita. Kirjallisuus kuitenkin esittää, että laajemman opetusdatan avulla myös vikojen luokittelulle konenäöllä on olemassa potentiaalia ja että useissa tutkimuksissa vikojen luokittelun haasteet johtuvat nimenomaan riittämättömästä ja liian homogeenisestä opetusdatasta (Mellit & Kalogirou 2025). Korkmaz & Acikgoz (2022) esittivät, että erityisesti data-augmentaation keinoin voidaan kuitenkin luoda synteettistä dataa luokittelumallin opetukseen ja tätä kautta kiertää saatavilla olevan opetusdatan niukkuutta. Tämä viittaa siihen, että teknologian kypsyessä entisestään ja datamäärien kasvaessa voidaan myös automaattiset vikojen luokittelijat muuttaa kilpailueduksi, joka täydentää automaattista poikkeamien tunnistusta ja vähentää asiantuntijan manuaalista työmäärää entisestään. Tämän lisäksi jatkokehityspotentiaalia kohti kokonaisvaltaisempaa kunnossapitoa voidaan nähdä muiden datalähteiden, kuten sähköteknisten virta- tai tehotietojen yhdistämisessä visuaaliseen dataan (Segovia Ramirez 2024). H3 esitti, että konenäön tuloksia jalostamalla kerätyllä sähköteknisellä datalla palvelun tuoma kokonaisarvo kasvaa sekä kunnossapidon ennustettavuus paranee entisestään:

> *"Jos konenäön tuloksiin yhdistetään tuotantotietoja ja aiempaa kunnossapitodataa, voidaan rakentaa ennustemalleja vikaantumisista."*

Uhat

Uhkiakin konseptiin liittyen on olemassa. Keskeisimpinä tunnistettavissa olevista uhista voidaan nähdä **vaihtoehtoisten kunnossapitoratkaisujen kehityksen** ylivertaiseksi suhteessa esitettyyn konenäköön perustuvaan konseptiin. Kirjallisuudessa Mellit & Kalogirou (2025) sekä Mohanty (2025) toivat esiin paneeleihin ja komponentteihin asennettavien sensorijärjestelmien nopean kehityksen sekä niiden potentiaalin tarjota myös kustannustehokkaita tarkastusratkaisuja. Fernando et al. (2025) ja Spajić (2024) puolestaan korostivat artikkeleissaan, että konenäköön perustuvat visuaaliset tarkastukset ovat kilpailukykyinen ja tehokas tapa tarkastaa aurinkovoimaloita, mutta eivät ole ainoa teknologinen polku isojen voimaloiden tarkastukseen. Myös haastateltavat vaihtoehtoiset teknologiat uhkana, esimerkiksi H8 esitti näkemyksensä sensorikehityksen vaikutuksesta tarkastustarpeisiin:

> *"Isoissa voimaloissa ilmasta suoritetuilla konenäkötarkastuksille on varmasti tarvetta, mutta paneelikohtainen data voi osittain vähentää niiden tarvetta."*

Liiketoiminnallisena uhkana konenäköön liittyvässä palvelussa on, että **kunnossapidon markkina on vasta kehittymässä ja asiakkaiden vaihtelevat asenteet** voivat hidastaa palvelun kysyntää. Vaikka vasta kehittymässä oleva markkina voidaan nähdä myös mahdollisuutena, liittyy siihen uhkia, sillä markkinalla ei välttämättä vielä täysin ymmärretä kunnossapidon arvoa, joka voi siirtää kysynnän kasvua myöhemmäksi. Tämä näkemys toistui haastatteluissa, kun useat haastateltavat totesivat, että päätöksentekijöillä ei välttämättä vielä ole kokemusta kunnossapidosta ja siihen kytkeytyy tietämättömyys siitä, kuinka useasti tarkastuksia tulisi suorittaa tai jopa illuusio siitä, että paneelit olisivat huoltovapaita.

Kohdeyrityksen näkökulmasta selkeänä uhkana on alalle kehittyvä **kova kilpailun taso.** Dronet sekä konenäköratkaisut eivät ole täysin uniikkeja teknologioita ja kaupallisia ratkaisuja on jo saatavilla (Mellit & Kalogirou 2025). Lisäksi Suomessa aurinkovoimaloiden määrä on vähäisempää, kuin useissa muissa Euroopan maissa, jonka takia kansainvälisillä yrityksillä voi olla jo ratkaisun kaupallistamisessa selkeä etulyöntiasema. H5 korostaa, että dronet ja konenäkö eivät ole suomalaisia keksintöjä ja on oletettavaa, että muissa maissa ollaan kehityksessä edellä Suomea. Tämä tarkoittaa, että teknologinen osaaminen ei

automaattisesti riitä kilpailueduksi, vaan avaimet onnistuneeseen kaupallistamiseen voivat löytyä vahvan konseptoinnin ja kumppaniverkostoitumisen kautta.

Viimeisenä uhkana tunnistettiin drone-operointiin, että teollisen mittakaavan voimaloiden monitorointiin liittyvä **lainsäädäntö ja regulaatiot.** Drone-operoinnin lainsäädännön kiristymistä voidaan ohittaa ulkoistamalla datankeruuprosessi, mutta aurinkovoimaloiden tarkastusten tasoa ohjaa kunnossapitotoimien sääntely teollisen mittakaavan voimaloiden yleistyessä. H10 tuo esiin, että lainsäädännön mahdolliset velvoitteet manuaalisille tarkastuksille voivat rajoittaa droneilla ja konenäöllä suoritettavien visuaalisten tarkastusten yleistymistä kunnossapitomenetelmänä:

> *"Lainsäädäntö voi vaikuttaa siihen, kuinka paljon droneja ja konenäköä tarvitaan tarkastuksissa."*

7 Johtopäätökset ja tutkimuksen arviointi

Tutkimuksessa tutkittiin konenäön soveltuvuutta osana aurinkovoimaloiden kunnossapitoprosessia, sen tuottamaa lisäarvoa sekä käyttöönoton edellytyksiä kohdeyrityksen näkökulmasta. Tässä luvussa vastataan työlle määritettyihin tutkimuskysymyksiin tutkimustulosten perusteella. Tämän lisäksi luvussa arvioidaan tutkimuksen luotettavuutta ja rajoitteita, jonka jälkeen esiteen tutkimuksen myötä nousseet jatkotutkimuskohteet.

7.1 Tutkimuksen keskeiset tulokset

Tutkimuksen ensimmäisenä tutkimuskysymyksenä oli: *Miten konenäköä voidaan hyödyntää aurinkovoimaloiden kunnossapidossa?* Tutkimuksen mukaan konenäköä voidaan hyödyntää erityisesti visuaalisten tarkastusten automatisoinnissa. Tutkimuksen aikana ilmeni, että konenäköä voidaan hyödyntää paneeleista otettujen lämpö-, väri- sekä elektroluminesenssikuvien automaattisessa analysoinnissa ja vikaluokittelussa. Tutkimus rajattiin kuitenkin käsittelemään vain ilmasta otettujen lämpökuvien käsittelyä konenäöllä, sillä se oli kohdeyrityksen kontekstissa luonnollinen rajaus sekä lämpökuvat nähtiin tehokkaimpana näistä kolmesta kuvausmenetelmästä vikojen ja poikkeamien tunnistamiseen aurinkovoimaloista. Haastatteluaineistosta keskeisimpänä vastauksena nähtiin, että konenäköä voidaan hyödyntää ilmasta otettujen kunnossapitokuvien analysointiin ja siitä kunnossapitotiedon luontiin.

Tutkimuksen aikana selvisi, että konenäköä voidaan hyödyntää lämpökuvien analysoinnin eri vaiheissa eri menetelmin. Konenäön hyödyntämisen vaiheisiin tunnistettiin tutkimuksen aikana kolmiportainen malli, jossa

1) Paneelit tunnistetaan
2) Poikkeamat tunnistetaan
3) Poikkeamat luokitellaan

Jokaisella vaiheella on oma funktionsa osana aurinkovoimalan kunnossapitotarkastuksen prosessia. Paneelien tunnistamisella tarkoituksena on rajata poikkeamatunnistusta varten

syöteaineisto, jotta voidaan vähentää väärien positiivisten havaintojen määrää, sekä minimoida laskennallista kuormitusta analyysiprosessissa, kun poikkeamien etsintä kohdistetaan vain paneelialueille. Poikkeamatunnistuksen tarkoituksena on havaita lämpökuvista tai yhdistetyistä komposiittikuvista normaalista poikkeavat lämpötilajakaumat, jotka voivat viitata esimerkiksi viallisesti toimiviin kennoihin, varjostumiin tai sähköisiin ongelmiin. Kolmannessa, eli vikojen luokittelun vaiheessa havaintoja pyritään luokittelemaan toisistaan vikatyypin, aiheuttajan tai vakavuuden perusteella. Vikojen luokitteluun konenäöllä nähtiin tutkimuksessa potentiaalia, mutta rajoitteena nousi tarvittavan opetusdatan määrä ja saatavuus.

Toisena tutkimuskysymyksenä tutkimuksessa oli: *Mitä lisäarvoa lämpökuvadataan perustuva kohteentunnistusalgoritmi tuo aurinkovoimaloiden kunnossapitoon?* Tutkimuksen haastatteluosuudessa nousseet sekä kirjallisuudesta tunnistetut keskeisimmät lisäarvotekijät liittyivät tarkastusprosessin tehokkuuteen, tarkkuuteen sekä toistettavuuteen. Algoritmien avulla voidaan automatisoida merkittävä osuus manuaalisista prosessin työvaiheista, erityisesti kaikista lämpökuvista tehtävä poikkeamatunnistus, joka lyhentää prosessin läpimenoaikaa ja vähentää prosessin ihmisresurssisitovuutta. Hyöty nähtiin konenäköön perustuvalla ratkaisulla olevan sitä suurempi, mitä suurempi tarkastettavan voimalan paneelimäärä on. Konenäköratkaisun nähtiin tarjoavan lisäarvoa siis erityisesti kasvavilla teollisen mittakaavan aurinkovoiman markkinoilla.

Toisena lisäarvoa tuovana komponenttina konenäön hyödyntämisessä nähtiin tarkastuksen automaation mahdollistuminen, varsinkin jos se yhdistetään automatisoidun datankeruun, toimintaan suunniteltujen dataputkien sekä toimivien tietoliikenneyhteyksien kanssa. Mitä automaattisemmaksi tarkastusprosessi on mahdollista kehittää, sitä kustannustehokkaammaksi palvelu käy sekä aurinkovoimalan omistajille, että palvelun tarjoajalle. Tämä puolestaan mahdollistaa tarkastussyklin tihenemisen, joka taas tarkoittaa kunnossapidon tilannetietoisuuden merkittävää kasvua sekä ennustavan kunnossapidon mahdollistumista.

Kolmantena ja työn viimeisenä tutkimuskysymyksenä oli: *Miten konenäköä hyödyntävä analytiikka voidaan liittää osaksi olemassa olevaa aurinkovoimaloiden tarkastuspalvelun konseptia?* Tutkimuksen perusteella konenäkö voidaan liittää osaksi palveluprosessia vaiheittain siten, että konenäkömallit tukevat ja tehostavat nykyisiä työvaiheita ilman, että poistavat täysin asiantuntijan roolia prosessista.

Palveluprosessia tarkasteltaessa todettiin, että konenäkö voidaan liittää osaksi analyysivaihetta, jossa konenäkömallien avulla voidaan automatisoida paneelien rajaus, lämpöpoikkeamien tunnistus ja riittävällä opetusdatalla myös alustavan luokittelun. Konenäön avulla poikkeamat saadaan tunnistettua väsymättömästi ja tasalaatuisesti, minkä jälkeen asiantuntija voi kohdistaa keskittymisensä havaintojen tulkintaan ja vianaiheuttajiin, sen sijaan että aikaa kuluisi manuaalisiin työvaiheisiin.

Konenäön liittämisen myötä osaksi tarkastuspalvelua, palvelu kehittyy vaiheittain manuaalisesta analyysistä kohti dataohjautuvaa, automatisoidumpaa palvelukonseptia. Lopputuloksena on palvelu, jossa on vähemmän manuaalisia työvaiheita, on skaalautuva, lyhentää raportointiviiveitä ja on laadulliselta toistettavuudeltaan parempi. Samalla vapautunut asiantuntijatyö voidaan kohdistaa suuremman lisäarvon tehtäviin. Tällä tavoin konenäkö toimii osana palveluprosessia sekä teknologisena komponenttina, niin myös strategisena välineenä palvelun skaalautuvuuden ja kilpailukyvyn parantamisessa.

7.2 Tutkimuksen luotettavuus ja rajoitteet

Tutkimuksen jatkuva luotettavuuden arviointi on keskeinen osa tutkimusprosessia. Laadullisessa tutkimuksessa yksi keskeisistä luotettavuustavoitteista on tutkimuksen toistettavuus sekä tutkimusprosessin läpinäkyvyys (Tuomi & Sarajärvi 2024). Tämä tutkimus toteutettiin tapaustutkimuksena yhden kohdeyrityksen toimintaympäristössä, mikä tarkoittaa, että tulokset heijastavat tämän organisaation prosesseja ja käytäntöjä. Tämä esitetty tapaustutkimuksen kontekstisidonnaisuus voi lisätä tutkimuksen toistettavuuden haasteita sekä rajoittaa tulosten yleistettävyyttä. Toistettavuutta sekä tutkimuksen luotettavuutta on parannettu dokumentoimalla tutkimuksen vaiheet mahdollisimman tarkasti. Hirsjärvi et al. (2009) mainitsevatkin laadullisen tutkimuksen luotettavuuden parantuvan yksityiskohtaisella kuvailulla tutkimuksen toteutuksen vaiheista.

Toisena tutkimuksen rajoitteena voidaan nähdä konenäköratkaisun sekä muodostetun konstruktion teknisen testauksen rajaus työn laajuuden ulkopuolelle. Työn tavoitteena ei ollut kehittää valmista algoritmia tai suorittaa konenäköalgoritmien kvantitatiivista arviointia, minkä vuoksi ehdotettu palvelukonsepti sekä sen hyödyt jäävät konseptuaaliselle tasolle. Lukan (2003) esittämän konstruktiivisen tutkimusotteen mukaisesti työssä tuotetaan käytännöllinen ratkaisuehdotus, mutta sen teknisen ja taloudellisen validointi vaatisi

tulevaisuudessa kvantitatiivisen tutkimuksen. Esimerkiksi euromääräisen kustannussäästöjen, tarkkuuden tai tehokkuuden arvioimiseksi tulisi toteuttaa määrällinen vertailututkimus suhteessa perinteisiin tarkastusmenetelmiin.

7.3 Jatkotutkimuskohteet

Tutkimuksen rajausten vuoksi keskeisiä osa-alueita jäi toteutettavaksi jatkotutkimuskohteina. Ensimmäinen ja merkittävin jatkotutkimuskohde liittyy konenäköpohjaisen analytiikan tekniseen sekä taloudelliseen arviointiin. Tässä työssä ehdotettu palvelukonsepti perustuu laadulliseen tutkimukseen, jolloin ehdotukset ovat konseptuaalisella tasolla, eikä sen suorituskykyä arvioitu kvantitatiivisesti. Jatkotutkimuksena olisi siis perusteltua toteuttaa kvantitatiivinen tutkimus, jossa eri konenäköalgoritmien tarkkuutta, soveltuvuutta ja tehokkuutta verrattaisiin perinteisiin tarkastusmenetelmiin.

Toisena tunnistettuna jatkotutkimuskohteena voidaan nähdä aurinkovoimaloiden tarkastusmenetelmien tutkiminen laajemmalta, kuin vain ilmasta kerättyjen lämpökuvien kontekstissa. Mellit & Kalogirou (2025) esittivät artikkelissaan, että aurinkovoimaloiden kunnossapito vaatii visuaalisen aineiston lisäksi muita datalähteitä, jotta kunnossapidon ennustettavuus mahdollistuu. Tutkimuksena aikana ilmeni lisäksi, että lämpökuvista toimintapoikkeamien tunnistaminen on mahdollista, mutta niiden juurisyyanalyysi voi vaatia tukevaa aineistoa. Tästä syystä selkeä jatkotutkimuskohde on kokonaisvaltaisemman ratkaisun tutkiminen, jossa tämän työn ehdotettuun ratkaisuun yhdistetään sekä muun tyyppistä visuaalista aineistoa, kuin myös muitakin tietolähteitä, kuten sähköteknistä tuotantodataa paneelien toiminnasta.

Lähteet

Abro, G.E.M., Ali, A., Memon, S.A. & Memon, T.D. 2024. Strategies and Challenges for Unmanned Aerial Vehicle Based Continuous Inspection and Predictive Maintenance of Solar Modules. IEEE Access. 12. Saatavissa DOI: 10.1109/ACCESS.2024.3505754.

Ahmed, M., Hashmi, K.A., Pagani, A., Liwicki, M., Stricker, D. & Afzal, M.Z. 2021. Survey and performance analysis of deep learning based object detection in challenging environments. Sensors. 21(15).

Akay, S.S., Özcan, O., Özcan, O. & Yetemen, Ö. 2024. Efficiency analysis of solar farms by UAV-based thermal monitoring. Engineering Science and Technology, an International Journal. 53.

Albawi, S., Mohammed, T.A. & Al-Zawi, S. 2017. Understanding of a convolutional neural network. In: 2017 International Conference on Engineering and Technology (ICET). IEEE. Saatavissa DOI: 10.1109/ICEngTechnol.2017.8308186.

Alpaydin, E. 2014. Introduction to Machine Learning. Cambridge, Massachusetts: MIT Press.

Ayad, S., Chibani, A., Amirat, Y. & Benbouzid, M. 2018. An IoT approach for a smart maintenance. 2018 International Conference on Advanced Systems and Electric Technologies (IC_ASET). IEEE, 210–214. Saatavissa DOI: 10.1109/ASET.2018.8379861.

Babu, P., Sharma, M., Khan, M.T. & Sahu, S.K. 2024. Solar panel maintenance using IoT. In: 2024 International Conference on Recent Advances in Electrical, Electronics, Ubiquitous Communication, and Computational Intelligence (RAEEUCCI), 1–5. Saatavissa DOI: 10.1109/RAEEUCCI61380.2024.10547916.

Bamisile, O., Acen, C., Cai, D., Huang, Q. & Staffell, I. 2025. The environmental factors affecting solar photovoltaic output. Renewable and Sustainable Energy Reviews. 208. Saatavissa DOI: 10.1016/j.rser.2024.115073.

Berry, M.W., Mohamed, A. & Yap, B.W. 2020. Supervised and Unsupervised Learning for Data Science. Cham: Springer International Publishing.

Blanchard, B.S., Verma, D. & Peterson, E.L. 1995. Maintainability: A Key to Effective Serviceability and Maintenance Management. New York: Wiley.

Bokrantz, J., Skoogh, A., Berlin, C., Wuest, T. & Stahre, J. 2020a. Smart Maintenance: an empirically grounded conceptualization. International Journal of Production Economics. 223. Saatavissa DOI: 10.1016/j.ijpe.2019.107534.

Bokrantz, J., Skoogh, A., Berlin, C., Wuest, T. & Stahre, J. 2020b. Smart Maintenance: a research agenda for industrial maintenance management. International Journal of Production Economics. 224. Saatavissa DOI: 10.1016/j.ijpe.2019.107547.

Bosman, L.B., Leon-Salas, W.D., Hutzel, W. & Soto, E.A. 2020. PV system predictive maintenance: Challenges, current approaches, and opportunities. Energies. 13(6). Saatavissa DOI: 10.3390/en13061398.

Braga-Neto, U. 2024. Fundamentals of Pattern Recognition and Machine Learning. Cham: Springer International Publishing.

Buchanan, B.G. 2005. A (Very) Brief History of Artificial Intelligence. The AI Magazine. 26(4), 53–60. Saatavissa DOI: 10.1609/aimag.v26i4.1848.

Constantin, A., Iosif, G., Chihaia, R., Marin, D., Abu Shehadeh, G., Umut, Karahan, M., Gerikoglu, B. & Stavrev, S. 2023. Preventive maintenance in solar energy systems and fault detection for solar panels based on thermal images. Electrotehnica, Electronica, Automatica. 71(1), 1–12.

Corley, I., Wallace, C., Agrawal, S., Putrah, B. & Lwowski, J. 2025. Aerial infrared health monitoring of solar photovoltaic farms at scale. IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops. IEEE. Saatavissa DOI: 10.1109/CVPRW67362.2025.00431.

de Jonge, B., Teunter, R. & Tinga, T. 2017. The influence of practical factors on the benefits of condition-based maintenance over time-based maintenance. Reliability Engineering & System Safety. 158, 21–30.

Di Tommaso, A., Betti, A., Fontanelli, G. & Michelozzi, B. 2022. A multi-stage model based on YOLOv3 for defect detection in PV panels based on IR and visible imaging by unmanned

aerial vehicle. Renewable Energy. 193, 941–962. Saatavissa DOI: 10.1016/j.renene.2022.04.046.

Energiavirasto. 2024. Aurinkosähkön tuotantokapasiteetti nousi 1000 megawattiin. [Verkkojulkaisu]. [Viitattu 10.06.2025]. Saatavilla: https://energiavirasto.fi/-/aurinkosahkon-tuotantokapasiteetti-nousi-1000-megawattiin.

Energiavirasto. 2023. Suurten aurinkovoimaloiden tuotantokapasiteetti voi olla jopa 190-kertainen vuoteen 2030 mennessä. [Verkkojulkaisu]. [Viitattu 10.06.2025]. Saatavilla: https://energiavirasto.fi/-/suurten-aurinkovoimaloiden-tuotantokapasiteetti-voi-olla-jopa-190-kertainen-vuoteen-2030-mennessa.

Eskola, J. & Suoranta, J. 1998. Johdatus laadulliseen tutkimukseen. Tampere: Vastapaino.

Fernando, N., et al. 2025. Efficient hotspot detection in solar panels via computer vision and machine learning. Information (Basel). 16(7), 608. Saatavissa DOI: 10.3390/info16070608.

Fogel, D.B. 2002. 8 – Samuel's Learning Machine. Teoksessa Fogel, D.B. (toim.): Blondie24. San Francisco: Morgan Kaufmann. 129–149.

Gerring, J. 2004. What is a case study and what is it good for? The American Political Science Review. 98(2), 341–354. Saatavissa DOI: 10.1017/S0003055404001182.

Goodfellow, I., Bengio, Y. & Courville, A. 2016. Deep Learning. MIT Press.

Green, M.A. 2000. Photovoltaics: technology overview. Energy Policy. 28(14), 989–998. Saatavissa DOI: 10.1016/S0301-4215(00)00086-0.

Gupta, V., Mishra, V.K., Singhal, P. & Kumar, A. 2022. An Overview of Supervised Machine Learning Algorithm. IEEE, 87–92. Saatavissa DOI: 10.1109/SMART55829.2022.10047618.

Haque, A., Bharath, K. & Jaffery, Z.A. 2019. Fault diagnosis of photovoltaic modules. Energy Science & Engineering. 7(3), 622–644. Saatavissa DOI: 10.1002/ese3.255

He, K., Gkioxari, G., Dollar, P. & Girshick, R. 2020. Mask R-CNN. IEEE Transactions on Pattern Analysis and Machine Intelligence. 42(2), 386–397. Saatavissa DOI: 10.1109/TPAMI.2018.2844175.

Hemadharshini, S.M., Kanchana Devi, R., Rajakumari, S., Adline Freeda, R., Reddy, V.S., Wang, J. et al. 2024. E-commerce customer segmentation by unsupervised learning. Teoksessa: Anonymous. Singapore: Springer Nature Singapore. 285–296.

Hindocha, K. & Shah, S. 2020. Design of 50 MW grid connected solar power plant. International Journal of Engineering Research & Technology (IJERT). 9(4).

Hirsjärvi, S., Remes, P., Sajavaara, P. & Sinivuori, E. 2009. Tutki ja kirjoita. Helsinki: Tammi.

Hu, L., Chen, J., Vaughan, J., Aramideh, S., Yang, H., Wang, K., Sudjianto, A. & Nair, V.N. 2021. Supervised machine learning techniques: An overview with applications to banking. International Statistical Review. 89(3), 573–604. Saatavissa DOI: 10.1111/insr.12430.

IEC/TS 62446-3:2017. 2017. Aurinkosähköjärjestelmät. Vaatimukset testaamiselle, dokumentaatiolle ja kunnossapidolle. Osa 3: Aurinkosähköpaneelit ja -voimalat. Lämpökuvaus ulkotilassa. Helsinki: SESKO ry.

Imenes, A.G., Saad Noori, N., Uthaug, O.A.N., Kröni, R., Bianchi, F. & Belbachir, N. 2021. A deep learning approach for automated fault detection on solar modules using image composites. In: 2021 IEEE 48th Photovoltaic Specialists Conference (PVSC). IEEE, 1925–1930. Saatavissa DOI: 10.1109/PVSC43889.2021.9518540.

Jakhar, D. & Kaur, I. 2020. Artificial intelligence, machine learning and deep learning: definitions and differences. Clinical and Experimental Dermatology. 45(1), 131–132. Saatavissa DOI: 10.1111/ced.14029.

Janiesch, C., Zschech, P. & Heinrich, K. 2021. Machine learning and deep learning. Electronic Markets. 31, 685–695. Saatavissa DOI: 10.1007/s12525-021-00475-2.

Jiao, L. & Zhao, J. 2019. A survey on the new generation of deep learning in image processing. IEEE Access. 7. Saatavissa DOI: 10.1109/ACCESS.2019.2956508.

Jieb, Y.A. & Hossain, E. 2022. Photovoltaic Systems: Fundamentals and Applications. Cham: Springer International Publishing. Saatavissa DOI: 10.1007/978-3-030-89780-2.

Jumaboev, S., Jurakuziev, D. & Lee, M. 2022. Photovoltaics plant fault detection using deep learning techniques. Remote Sensing. 14(15). Saatavissa DOI: 10.3390/rs14153728.

Järviö, J. 2007. Kunnossapito. Helsinki: KP-Media.

Kellil, N., Mellit, A., Rus Casas, C. & Benghanem, M. 2025. Hybrid vision transformer model for defect classification in photovoltaic modules using thermographic imaging: Leveraging self attention mechanisms for enhanced accuracy. Renewable Energy. 256. Saatavissa DOI: 10.1016/j.renene.2025.124138

Khan, J. & Arsalan, M.H. 2016. Solar power technologies for sustainable electricity generation – A review. Renewable & Sustainable Energy Reviews. 55, 414–425. Saatavissa DOI: 10.1016/j.rser.2015.10.135.

Khurana, D., Koli, A., Khatter, K. & Singh, S. 2023. Natural language processing: State of the art, current trends and challenges. Multimedia Tools and Applications. 82(3). Saatavissa DOI: 10.1007/s11042-022-13428-4.

Korkmaz, D. & Acikgoz, H. 2022. An efficient fault classification method in solar photovoltaic modules using transfer learning and multi-scale convolutional neural network. Engineering Applications of Artificial Intelligence. 113. Saatavissa DOI: 10.1016/j.engappai.2022.104959.

Krizhevsky, A., Sutskever, I. & Hinton, G. 2017. ImageNet classification with deep convolutional neural networks. Communications of the ACM. 60(6), 84–90. Saatavissa DOI: https://doi.org/10.1145/3065386

Kurtz, S., Granata, J. & Quintana, M. 2009. Photovoltaic-reliability R&D toward a solar-powered world. Reliability of Photovoltaic Cells, Modules, Components, and Systems II. SPIE, 258–269.

Köntges, M., Kurz, S., Packard, C., Jahn, U., Berger, K., Kato, K., Friesen, T., Liu, H. & Van Iseghem, M. 2014. Review of failures of photovoltaic modules. IEA PVPS Task 13: Performance and Reliability of Photovoltaic Systems: Subtask 3.2, 1–132.

Lai, C.S., Jia, Y., Lai, L.L., Xu, Z., McCulloch, M.D. & Wong, K.P. 2017. A comprehensive review on large scale photovoltaic system with applications of electrical energy storage. Renewable & Sustainable Energy Reviews. 78, 439–451. Saatavissa DOI: 10.1016/j.rser.2017.04.078

Landgraf, J., Kompenhans, M., Christ, T., Roland, T. & Heinig, A. 2023. Computer vision for industrial defect detection. Proceedings of the 20th International Conference on Sheet Metal, Erlangen-Nürnberg, Germany, 2–5.

LeCun, Y., Bengio, Y. & Hinton, G. 2015. Deep learning. Nature (London). 521(7553), 436–444. Saatavissa DOI: 10.1038/nature14539.

Lecun, Y., Bottou, L., Bengio, Y. & Haffner, P. 1998. Gradient-based learning applied to document recognition. Proceedings of the IEEE. 86(11), 2278–2324. Saatavissa DOI: 10.1109/5.726791.

Li, N., Shepperd, M. & Guo, Y. 2020. A systematic review of unsupervised learning techniques for software defect prediction. Information and Software Technology. 122. Saatavissa DOI: 10.1016/j.infsof.2020.106287.

Li, P., Liu, X., Zhang,J. & Li, S. 2023. A comprehensive survey on design and application of autoencoder in deep learning. Applied Soft Computing. 138. Saatavissa DOI: 10.1016/j.asoc.2023.110176.

Lukka, K. 2003. The constructive research approach. Case Study Research in Logistics. Publications of the Turku School of Economics and Business Administration, Series B. 1(2003), 83–101.

Malhotra, P. & Garg, E. 2020. Object detection techniques: A comparison. In: 2020 7th International Conference on Smart Structures and Systems (ICSSS). IEEE, 1–4. Saatavissa DOI: 10.1109/ICSSS49621.2020.9202254

Mellit, A. & Benghanem, M. 2020. A practical guide for advanced methods in solar photovoltaic systems. 1st ed. Cham: Springer International Publishing. Saatavissa DOI: 10.1007/978-3-030-43473-1.

Mellit, A. & Kalogirou, S. 2025. Recent advances in the application of infrared thermographic imaging and embedded artificial intelligence for fault diagnosis and predictive maintenance of photovoltaic plants: Challenges and future directions. Renewable & Sustainable Energy Reviews. 223. Saatavissa DOI: 10.1016/j.rser.2025.116057.

Memari, A., Debich, T., Bramer, M. & Stahl, F. 2024. Drone Assisted Infrared Thermography and Machine Learning for Enhanced Photovoltaic Defect Detection: A Comparative Study of Vision Transformers and YOLOv8. In: Artificial Intelligence XLI. Switzerland: Springer, 59–72. Saatavissa DOI: 10.1007/978-3-031-77918-3_5.

Mobley, R.K. 2002. An introduction to predictive maintenance. Chantilly: Elsevier Science & Technology.

Moor, J. 2006. The Dartmouth College Artificial Intelligence Conference: The Next Fifty Years. The AI Magazine. 27(4), 87–91. Saatavissa DOI: 10.1609/aimag.v27i4.1911.

Mueller, J.P. & Massaron, L. 2019. Deep learning for dummies. Hoboken: John Wiley & Sons.

Naeem, M., Khan, S., Khan, A., Anwar, S. & Al-Sharif, A. 2023. A step-by-step process of thematic analysis to develop a conceptual model in qualitative research. International Journal of Qualitative Methods. 22. Saatavissa DOI: 10.1177/16094069231205789.

Nian, R., Liu, J. & Huang, B. 2020. A review on reinforcement learning: Introduction and applications in industrial process control. Computers & Chemical Engineering. 139, 106886. Saatavissa DOI: 10.1016/j.compchemeng.2020.106886.

Nozik, A.J. & Miller, J. 2010. Introduction to solar photon conversion. *Chemical Reviews.* 110(11), 6443–6445. Saatavissa DOI: 10.1021/cr1003419.

O'Shea, K. & Nash, R. 2015. An introduction to convolutional neural networks. Ithaca: Cornell University Library, arXiv.org.

Peng, Y., Saeeda, H., Heyn, H. & Horkoff, J. 2025. Data annotation: A requirements engineering for machine learning systems perspective. IEEE, 572–575. Saatavissa DOI: 10.1109/RE63999.2025.00053.

Polymeropoulos, I., Bezyrgiannidis, S., Vrochidou, E. & Papakostas, G.A. 2024. Enhancing Solar Plant Efficiency: A Review of Vision-Based Monitoring and Fault Detection Techniques. Technologies (Basel). 12(10), 175. Saatavissa DOI: 10.3390/technologies12100175.

PSK 6201. 2022. Kunnossapito. Käsitteet ja määritelmät. 4. painos. Helsinki: PSK Standardisointiyhdistys ry.

Rawat, W. & Wang, Z. 2017. Deep convolutional neural networks for image classification: A comprehensive review. Neural Computation. 29(9), 2352–2449. Saatavissa DOI: 10.1162/neco_a_00990.

Recker, J. 2021. Scientific research in information systems: a beginner's guide. 2. painos. Cham: Springer International Publishing.

Restrepo-Cuestas, B.J., Guarnizo-Lemus, C., Montoya-Marín, J.A. & Montano, J. 2025. Dataset of photovoltaic panel performance under different fault conditions: cracks, discoloration, and shading effects. Data in Brief. 59.

Schmidhuber, J. 2015. Deep learning in neural networks: An overview. Neural Networks. 61, 85–117. Saatavissa DOI: 10.1016/j.neunet.2014.09.003.

Segovia Ramirez, I., Das, B. & Garcia Marquez, F.P. 2022. Fault detection and diagnosis in photovoltaic panels by radiometric sensors embedded in unmanned aerial vehicles. Progress in Photovoltaics: Research and Applications. 30, 240–256. Saatavissa DOI: 10.1002/pip.3479.

Serey, J., Araya, I., Alfaro, M., Morales, G., Vásquez, F. & Salazar, M. 2023. Pattern recognition and deep learning technologies, enablers of Industry 4.0, and their role in engineering research. Symmetry (Basel). 15(2), 535. Saatavissa DOI: 10.3390/sym15020535.

SFS-EN 13306. 2017. Kunnossapito. Kunnossapidon terminologia. 3. painos. Helsinki: Suomen standardisoimisliitto.

SFS-EN IEC 62446-2. 2020. Aurinkosähköjärjestelmät. Vaatimukset dokumentaatiolle, kunnossapidolle ja testaamiselle. Osa 2: Sähköverkkoon kytketyt järjestelmät. Aurinkosähköjärjestelmän kunnossapito. Helsinki: Suomen Standardisoimisliitto.

Shetye, S., Shetty, S., Shinde, S., Madhu, C. & Mathur, A. 2023. Computer vision for industrial safety and productivity. IEEE, 117–120. Saatavissa DOI: 10.1109/CSCITA55725.2023.10104764.

Shorten, C. & Khoshgoftaar, T.M. 2019. A survey on image data augmentation for deep learning. Journal of Big Data. 6(1), 60. Saatavissa DOI: 10.1186/s40537-019-0197-0.

Singh, G.K. 2013. Solar power generation by PV (photovoltaic) technology: A review. Energy (Oxford). 53, 1–13. Saatavissa DOI: 10.1016/j.energy.2013.02.057.

Sumit, S.S., Watada, J., Roy, A. & Rambli, D. 2020. In object detection deep learning methods, YOLO shows supremum to Mask R-CNN. Journal of Physics: Conference Series. 1529(4). Saatavissa DOI: 10.1088/1742-6596/1529/4/042086.

Tang, W., Yang, Q., Dai, Z. & Yan, W. 2024. Module defect detection and diagnosis for intelligent maintenance of solar photovoltaic plants: Techniques, systems and perspectives. Energy. 297. Saatavissa DOI: 10.1016/j.energy.2024.131222.

Tuomi, J. & Sarajärvi, A. 2024. Laadullinen tutkimus ja sisällönanalyysi. Uudistettu laitos. Helsinki: Kustannusosakeyhtiö Tammi.

Tuominen, H. & Neittaanmäki, P. 2019. Tekoälyn perusteita ja sovelluksia.

Vlaminck, M., Heidbuchel, R., Philips, W. & Luong, H. 2022. Region-based CNN for anomaly detection in PV power plants using aerial imagery. Sensors. 22(3), 1244.

Wai, A.W.Y. et al. 2015. GPU acceleration of real-time Viola-Jones face detection. In: 2015 IEEE International Conference on Control System, Computing and Engineering (ICCSCE). IEEE, 183–188. Saatavissa DOI: 10.1109/ICCSCE.2015.7482181.

Wu, Y. & Feng, J. 2018. Development and application of artificial neural network. Wireless Personal Communications. 102(2), 1645–1656. Saatavissa DOI: 10.1007/s11277-017-5224-x.

Ye, F., Zhang, S., Wang, P. & Chan, C. 2021. A survey of deep reinforcement learning algorithms for motion planning and control of autonomous vehicles. IEEE, 1073–1080. Saatavissa DOI: 10.1109/IV48863.2021.9575880.

Zhao, Z., Zheng, P., Xu, S. & Wu, X. 2019. Object detection with deep learning: A review. IEEE Transactions on Neural Networks and Learning Systems. 30(11), 3212–3232. Saatavissa DOI: 10.1109/TNNLS.2018.2876865.

Zou, Z., Chen, K., Shi, Z., Guo, Y. & Ye, J. 2023. Object detection in 20 years: A survey. Proceedings of the IEEE. 111(3), 1–20. Saatavissa DOI: 10.1109/JPROC.2023.3238524.

Liitteet

Liite 1. Haastattelukysymykset

1. Kuinka näet aurinkovoimaloiden kunnossapitopalveluiden markkinan kehittyneen?

2. Minkälaisena näet aurinkovoimaloille tarjottavien kunnossapitopalveluiden tulevan markkinapotentiaalin?

3. Onko droneilla suoritettaville automatisoiduille tarkastuksille mielestäsi tilaa aurinkovoimaloiden kunnossapidon markkinoilla?

4. Näetkö ilmasta otettuja lämpökuvia analysoivalla konenäköratkaisulla olevan potentiaalia aurinkovoimaloiden kunnossapidossa?

5. Kuinka näet toimialan yritysten suhtautuvan konenäkömallien tai tekoälyn hyödyntämiseen aurinkovoimaloiden kunnossapidossa?

6. Näetkö kohdeyrityksellä olevan mahdollisuutta menestyä aurinkovoimaloiden kunnossapitomarkkinoilla Suomen sisäisesti?

7. Näetkö kohdeyrityksellä olevan mahdollisuutta menestyä aurinkovoimaloiden kunnossapitomarkkinoilla kansainvälisesti?

8. Mitä kohdeyrityksen pitää tehdä, jotta se menestyisi aurinkovoimaloiden tarkastuspalveluiden tarjoajana?