DATA-ANALYTIIKAN HYÖDYT ENERGIAYHTIÖN TUOTANTO-LIIKETOIMINNASSA

Lappeenrannan–Lahden teknillinen yliopisto LUT

Tuotantotalouden diplomityö

2024

Anssi Lappalainen

Tarkastajat: Professori Juhani Ukko

Tutkijatohtori Tero Rantala

TIIVISTELMÄ

Lappeenrannan–Lahden teknillinen yliopisto LUT

LUT Teknis-luonnontieteellinen

Tuotantotalous

Anssi Lappalainen

Data-analytiikan hyödyt energiayhtiön tuotanto-liiketoiminnassa

Tuotantotalouden diplomityö

2024

75 sivua, 13 kuvaa

Tarkastajat: Professori Juhani Ukko, Tutkijatohtori Tero Rantala

Avainsanat: Tiedolla johtaminen, omaisuudenhallinta, data-analytiikka, ennakoiva kunnossapito, liiketoimintatiedon hallinta, energiayhtiö

Energia-ala kehittyy nopeasti, ja yritykset pyrkivät hyödyntämään nykyaikaisia teknologioita ja data-analytiikkaa optimoidakseen toimintaansa ja tehostaakseen päätöksentekoaan. Datan määrä on kasvanut huomattavasti, mutta sen täysimääräinen hyödyntäminen on vielä kehitysvaiheessa monilla aloilla. Energiayhtiöissä, joissa tuotanto-omaisuuden hallinta ja investointien kohdentaminen ovat kriittisiä, data-analytiikka tarjoaa merkittäviä mahdollisuuksia kustannusten vähentämiseen ja tuotannon tehokkuuden parantamiseen.

Tässä tutkimuksessa tarkasteltiin data-analytiikan hyödyntämistä energiayhtiön tuotanto-liiketoiminnassa ja sen tuottamia taloudellisia hyötyjä. Tutkimus toteutettiin kirjallisuuskatsauksen, asiantuntijahaastatteluiden ja tapaustutkimuksen yhdistelmänä. Tämän diplomityön tavoitteena on selvittää mitä konkreettisia taloudellisia hyötyjä datasta on energiayhtiön Tuotanto-liiketoiminnalle ja sitä kautta koko yhtiölle. Diplomityön tavoitteeseen pyrittiin pääsemään selvittämällä oleelliset datan lähteet, mihin tarkoituksiin tätä dataa voitaisiin hyödyntää ja mitkä ovat data-analytiikan taloudelliset hyödyt energiayhtiön tuotantoliiketoiminnassa.

Yhteenvetona voidaan todeta, että tutkimus saavutti tavoitteensa tarjoamalla selkeän kokonaiskuvan energiayhtiön käytettävissä olevista datalähteistä ja niiden hyödyntämismahdollisuuksista. Tutkimuksessa löydettiin konkreettisia esimerkkejä siitä, miten datan yhdistäminen ja data-analytiikka voivat tukea ennakoivaa kunnossapitoa, resurssien optimaalista kohdentamista ja päätöksenteon parantamista. Käytännön toteutuksissa korostui erityisesti modernien data-alustojen ja analytiikkatyökalujen rooli, jotka mahdollistavat tiedon tehokkaan jalostamisen ja hyödyntämisen päätöksenteon tukena.

ABSTRACT

Lappeenranta–Lahti University of Technology LUT

School of Engineering Science

Industrial Engineering and Management

Anssi Lappalainen

The benefits of data analytics in an energy company's production operations

Industrial Engineering and Management Master's thesis

2024

75 pages, 13 figures

Examiners: Professor Juhani Ukko, Post-doctoral researcher Tero Rantala

Keywords: business intelligence, data analytics, energy company, predictive maintenance, asset management, knowledge management

The energy sector is evolving rapidly, with companies striving to leverage modern technologies and data analytics to optimize operations and enhance decision-making processes. While the amount of data available has grown significantly, its full potential is yet to be realized in many industries. In energy companies, where the management of production assets and the allocation of investments are critical, data analytics presents substantial opportunities for cost reduction and improved operational efficiency.

This study examined the utilization of data analytics in the production operations of an energy company and the financial benefits it can generate. The research was conducted using a combination of a literature review, expert interviews, and a case study. The objective of this thesis was to identify the financial benefits that data can provide to the production operations of an energy company and, consequently, to the entire organization. To achieve this objective, the study focused on identifying the key data sources, determining the potential uses for this data, and assessing the economic advantages of data analytics in the energy company's production business.

The study successfully met its objectives by providing a clear overview of the data sources available to the energy company and their potential applications. Concrete examples were identified, illustrating how data integration and analytics can support predictive maintenance, optimize resource allocation, and improve decision-making processes. The findings highlighted the pivotal role of modern data platforms and analytics tools in enabling efficient processing and utilization of information to support strategic decisions.

ALKUSANAT

Diplomityöni tutkimus käsitti laajoja kokonaisuuksia. Sen tekeminen oli kokonaisuudessaan antoisa ja tietoa kasvattava kokemus. Opin paljon mielenkiintoisista uusista teknologioista ja niiden soveltamisesta energia-alan yhtiöihin. Tutkimustyöni herätti paljon uusia ideoita minulle ja toivon pääseväni kehittämään niillä yhtiöiden liiketoimintaa. Diplomityön tekeminen itsessään oli haastavaa ja rankkaa, koska elämääni kuului samalla normaali määrä töitä ja kaksi pientä lasta, jotka vaativat rakkautta ja huolenpitoa. Rakastan teitä Anna ja Alex. Töiden, opiskelun ja pikkulapsiarjen yhteensovittaminen oli ajoittain haastavaa, mutta tässä minua auttoivat usein vanhempani, josta haluan esittää suuret kiitokset heille. Tein tutkimustyötä hyvin itsenäisesti, koska se oli tyyliltään sellainen, ettei vaatinut muun työorganisaation suurta osallistumista siihen. Haluan kumminkin osoittaa suuret kiitokset Kotkan Energian henkilöstön niille jäsenille, jotka auttoivat minua kasaamaan tässä tutkimuksessa esitettyjä datan lähteitä Tuotanto-liiketoiminnasta. Kiitos koko yhtiölle ja erityisesti Jarille tämän diplomityön tarjoamisesta minulle. Toivon tämän tutkimustyön tuottavan paljon käyttökelpoista tietoa ihmisille ja avaavan uusia ideoita liiketoimintojen kehittämiseen.

-Anssi

SYMBOLI- JA LYHENNELUETTELO

Lyhenteet

AI	Artificial Intelligence
ANN	Artificial Neural Network
CFD	Computational Fluid Dynamics
CNN	Convolutional Neural Network
DBSCAN	Density-based spatial clustering of applications with noise
DCS	Distributed Control System
GDPR	General Data Protection Regulation
IIR	Internal Rate of Return
IoT	Internet Of Things
KPCA	Kernel Principal Component Analysis
LSTM	Long Short-Term Memory
MAE	Mean Absolute Error
NPV	Net Present Value
ORC	Organic Rankine Cycle
PdM	Predictive Maintenance
POC	Proof of concept
RMSE	Root Mean Square Error
RNN	Recurrent neural network
RUL	Remaining useful life
SCADA	Supervisory Control and Data Acquisition
STFT	Short-time Fourier transform

Sisällysluettelo

Tiivistelmä

Abstract

Alkusanat

Lyhenneluettelo

1 Johdanto ... 3
1.1 Tutkimuksen tausta ... 5
1.2 Tutkimuksen tavoite, rajaukset ja tutkimuskysymykset ... 6
1.3 Tutkimusmenetelmät ja työn rakenne ... 7
2 Teoria ja aiempi tutkimus ... 10
2.1 Omaisuudenhallinta ... 10
2.2 Tiedolla johtaminen ... 14
2.2.1 Data-analytiikka ... 16
2.3 Kunnossapito ... 24
2.3.1 Ennakoiva kunnossapito ... 28
3 Data-analytiikka energia-alalla ... 31
3.1 Tutkimuksia aihealueesta ... 31
3.2 Asiantuntijahaastattelut ... 40
4 Case tutkimus ... 47
4.1 Case-Yhtiö ... 47
4.1.1 Tuotanto-liiketoiminta ... 51
4.2 Datan lähteet ... 53
5 Tulokset ja johtopäätökset ... 63
6 Yhteenveto ... 73
Lähteet ... 75

Liitteet

Liite 1. Lähdeviittaukset

Kuvaluettelo

KUVA 1: Omaisuudenhallinnan eri tasot (Marlow, 2008)

KUVA 2: Datasta tiedoksi (David Somerville, Hugh McLeod 2016)

KUVA 3: Datan lähteet yhtiöissä (Hartmann et al.,2016)

KUVA 4: Power BI (Microsoft 2024)

KUVA 5: Kunnossapidon tasot (Mikkonen et al., 2009)

KUVA 6: Kunnossapitolajit (PSK 7501:2010)

KUVA 7: Datavarastoratkaisun havainnollistaminen.

KUVA 8: Alma liitännät (Intra, 2024)

KUVA 9: ALMAn toiminnot (Intra, 2024)

KUVA 10: ALMAsta löytyvä laitteen kriittisyysluokittelu

KUVA 11: Key Heat (Intra 2024)

KUVA 12: KL-kaivojen mittaustietoa aistiosta (Intra 2024)

KUVA 13: Lämmönjakohuoneen mittausdataa kaukolämpöverkostosta (Intra 2024)

1 Johdanto

Maailma ympärillämme muuttuu ja kehittyy nopeasti. Yhtiöt pyrkivät hyödyntämään nykyaikaista teknologiaa toimintansa kehittämisessä ja johtamisessa. Datan määrä on lisääntynyt huomattavasti ja on huomattu, että sillä on erilaisilla aloilla monenlaisia käyttökelpoisia kohteita. Dataa kerätään paljon, mutta sen tehokas hyödyntäminen on vielä usein vaiheessa. Tämä tutkimus tehtiin, koska yksi tietty energia-alan yhtiö halusi tietää, mitä taloudellisia hyötyjä sen tuotanto-liiketoiminta voisi saavuttaa data-analytiikalla. Yritys kerää paljon dataa sen tuotantolaitoksien ja asiakkaiden laitteista ja kaukolämpöverkostostaan. Yhtiö haluaa kohdentaa varojaan omaisuuseriin, jotka tukevat yrityksen strategiaa ja liiketoimintaa pitkällä aikavälillä. Nykyajan kunnossapito ei enää perustu pelkästään nopeisiin korjauksiin, vaan tietoon ja osaamiseen pohjautuvaan tuotanto-omaisuuden hallintaan. Mitä tehokkaammin tuotanto-omaisuutta hallitaan, sitä kannattavampaa tuotanto on. Tämä lisää tuotantoprosessiin sijoitetun pääoman tuottoa ja parantaa yrityksen kilpailukykyä.

Investoinnit energiantuotannon omaisuuteen ovat suuria ja uusimispäätösten ajoittaminen oikein on tärkeää. Energia-alan organisaatiot haluavat ylläpitää ja parantaa tuotannon tehokkuutta, mutta myös vähentää pääoma- ja toimintakustannuksia. Hyvä fyysinen omaisuudenhallinta on tärkeässä roolissa liiketoiminnan kannattavuuden optimoinnissa (Schuman, 2005). Tuotanto-omaisuuden hallinta on keskeinen osa nykyaikaisia kunnossapitostrategioita. Se kattaa päivittäisten työtehtävien koordinoinnin, ennakoivan kunnossapidon suunnittelun, saumattoman yhteistyön tuotannon ja kunnossapidon välillä, laitteiden luotettavuuden varmistamisen, varaosien tehokkaan hallinnan sekä ympäristö- ja työturvallisuuden huomioimisen. Siirryttäessä reagoivasta ja korjaavasta kunnossapidosta ennakoivaan ja vikaantumista ehkäisevään tuotanto-omaisuuden hallintaan tarvitaan jatkuvasti uutta ja ajankohtaista tietoa. Tavoitteena ei ole enää pelkästään korjausten nopeus, vaan vikojen ennaltaehkäisy ja kunnossapidon tarpeen vähentäminen. Tavoitteena on toteuttaa tuotanto-omaisuuden hallinta siten, että yrityksen tuotannolliset tavoitteet saavutetaan optimaalisesti. Laadukas omaisuudenhallinta tarjoaa lisäksi työkaluja investointiresurssien kohdentamiseen oikeisiin kohteisiin. (Järviö, 2017)

Tieto- ja tietokonejärjestelmien nopea kehitys avaa uusia mahdollisuuksia tietoon perustuvaan päätöksentekoon ja data-analytiikkaan, mutta lisää myös monimutkaisuutta

(Gavrikova, 2021). Digitalisaatio ja liiketoiminta-analytiikka ovat suhteellisen uusia ilmiöitä, mutta tietoon perustuvan johtamisen, liiketoimintatietojen hallinnan ja dataan perustuvan päätöksenteon käsitteistä on keskusteltu jo vuosikymmeniä. Tietoon perustuva johtaminen ja sen tavoitteet ovat ajankohtaisia aiheita monissa organisaatioissa. Digitalisaatio mahdollistaa organisaatioiden operatiivisien toimintojen optimoinnin ja parantaa kustannustehokkuutta, mikä tarjoaa niille paremmat valmiudet pysyä mukana nopeasti muuttuvissa liiketoimintaympäristöissä. (Ratia, 2022)

Data-analytiikka ja datan käyttö ovat nykyään hyvin suosittuja aiheita. Teknologiset edistysaskeleet, kuten teollisuuden esineiden internet (IoT), mahdollistavat nyt yrityksille kalliiden laitteiden toimintakunnon jatkuvan seurannan antureiden avulla. Kun valtava määrä anturidataa virtaa jatkuvasti, yhtiöt etsivät innovatiivisia data-analytiikkaratkaisuja operatiivisen datan käsittelyyn tukemaan heidän taktisia ja strategisia päätöksiään. Yhtiöille on tärkeää saada taloudellista hyötyä datasta. (Zhang, 2015)

Tämä tutkimus käsittelee teoriataustaa tästä aihealueesta ja tutkii tapauksia aiemmasta kirjallisuudesta. Tutkimuksen tavoitteena on selvittää, mitä taloudellisia hyötyjä data ja data-analytiikka voisivat tuoda yhtiölle. Tutkimusta varten on toteutettu kirjallisuuskatsaus aihealueen teoriaan, esitelty tarkoituksenmukaisia tapaustutkimuksia, suoritettu asiantuntijahaastatteluja ja esitelty case-yhtiö johon on tapaustutkimuksella sovellettu koottuja tietoja aiemmasta tutkimuksesta ja asiantuntijahaastatteluista. Tutkimusalue on todella laaja ja tästä seurauksena tutkimusta varten on käyty läpi lukematon määrä tutkimusartikkeleita, tieteellisiä julkaisuja ja ammattikirjallisuutta muun muassa tiedolla johtamisen, omaisuudenhallinnan, data-analytiikan ja kunnossapidon alueelta. Konkreettisia tapaustutkimuksia energia-alalta oli todella vaikeaa löytää juuri tähän aiheeseen ja asiantuntijaorganisaatioita haastatellessani en saanut kovin montaa vastausta eivätkä vastaukset olleet kovin konkreettisia. Kiitokset vastanneille organisaatioille. Olen kumminkin saanut kasattua eri lähteistä toimivan kokonaisuuden, jolla saadaan vastaukset tutkimuskysymyksiin ja annetaan arvokasta tietoa tutkimuksen toimeksiantaja yhtiölle. Laajemmin energiayhtiöille tarjotaan tutkimuksessani kootusti esimerkkejä ja ideoita liiketoiminnasta kerätyn datan ja ulkoisen datan tehokkaasta käytöstä taloudellisen arvon saavuttamiseksi.

1.1 Tutkimuksen tausta

Tutkimuksen taustalla on paikallisen energia-alan yhtiön halu saada tietoa mitä konkreettista hyötyä datasta on heidän liiketoiminnalleen. Yhtiöllä on halu parantaa omaisuudenhallintaansa ja tämä on erityisen tärkeää Kotkan Energian emoyhtiön pääomaintensiivisen liiketoiminnan vuoksi. Vuoden 2023 tilinpäätöksessä Kotkan Energia emoyhtiön taseeseen oli sitoutunut tuotanto-omaisuuden sisältäviin aineellisiin pysyviin vastaaviin noin 84 miljoonaa euroa. Energiayhtiöiden tuotantolaitokset ja verkostot vaativat raskaita investointeja fyysiseen omaisuuteen ja siitä on tärkeää pitää huolta mahdollisimman hyvin ja etsiä koko ajan parempia keinoja saada kaikesta omaisuudesta arvoa irti. Tuotanto-liiketoiminnan laitteista, järjestelmistä ja toiminnasta syntyy koko ajan suuri määrä reaaliaikaista dataa. Yhtiö on etsinyt itselleen kumppania, joka pystyisi auttamaan datastrategian luomisessa, sekä avustamaan liiketoiminnan tarpeita tukevan, pilvipalveluun perustuvan modernin data-alustakokonaisuuden suunnittelussa ja käyttöönotossa. Yhtiö on pyrkinyt kartoittamaan data-alustaan liittyviä liiketoiminnan tarpeita. Tiedolla johtamista pyritään kehittämään yhtiössä monella tapaa ja data-analytiikan käytön lisääminen on yksi tärkeä kehityssuunta. Yhtiön johto pyrkii etsimään konkreettisia hyötyjä data-alustan käyttöönotolle ja sinne tallennettavan datan hyödyistä. Dataahan käytetään jo hyödyksi liiketoiminnassa laajasti omissa järjestelmissään eriasteisin automaation astein. DCS-järjestelmän tuottaman datan avulla valvotaan ja operoidaan yhtiön energiantuotantoa ja jakelua. Tässä tutkimuksessa on kuitenkin oleellista miettiä mitä saadaan aikaan datan yhdistämisellä kaikista Tuotanto-liiketoiminnan datan lähteistä yhteen isoon päivittyvään datavarastoon, yhdistämällä tähän yhtiön ulkopuolisia datan lähteitä ja suorittamalla tällöin data-analytiikan menetelmiä. Yhtiölle kertyy jatkuvasti lisää dataa erilaisista mittauksista ja näiden hyödyntäminen osana muuta dataa automaattisesti data-analytiikan avulla voisi luoda mahdollisesti suurta taloudellista arvoa. Datalla ja data-analytiikalla on mahdollista luoda monenlaista arvoa liiketoiminnalle, mutta tässä työssä keskitytään taloudellisiin hyötyihin, koska taloudelliset arvot ja hyödyt ovat selkeästi havaittavissa ja mitattavissa.

Yhtiö on aiemmin selvittänyt data-alustan käyttöönoton mahdollisuutta ja toteuttanut teknisen Proof-of-conceptin (POC), jolla konkretisoitiin data-alustan kehittämistä ja tekniikan tuomia mahdollisuuksia. POC tulee sanoista ”proof-of-concept” ja se on käytännön menetelmänä erinomainen tapa varmistaa suunnitellun data-alusta toimivuus sekä liiketoiminnan

että tekniikan näkökulmasta. POC:ssa tuotiin kaukolämmön mittausdataa alustalle ja jalostettiin dataa eteenpäin. Tämä ei kuitenkaan vielä vakuuttanut yhtiötä investoimaan data-alustaan ja data-analytiikkaan laajemmin, vaan yhtiö haluaa konkreettisista hyödyistä enemmän tietoa. Tätä varten tämä tutkimus on tehty.

1.2 Tutkimuksen tavoite, rajaukset ja tutkimuskysymykset

Tässä luvussa kerron tämän diplomityön tavoitteista, tutkimukselle asetetuista rajauksista ja esittelen tutkimuskysymykset, johon työ pyrkii vastaamaan. Seuraavassa luvussa kerron myös käytetyistä tutkimusmenetelmistä ja tutkimuksen rakenteesta.

Tämän diplomityön tavoitteena on selvittää mitä konkreettisia taloudellisia hyötyjä datasta on energiayhtiön Tuotanto-liiketoiminnalle ja sitä kautta koko yhtiölle. Työn tavoitteesta on muodostettu kolme tutkimuskysymystä, joihin vastaamalla pyrin saavuttamaan tutkimuksen tavoitteen.

Tutkimuskysymykset:

1. Mitä datan lähteitä on hyödynnettävissä?

2. Mihin tarkoituksiin tätä dataa voitaisiin hyödyntää?

3. Mitkä ovat data-analytiikan taloudelliset hyödyt energiayhtiön tuotantoliiketoiminnassa?

Tutkimus on rajattu koskemaan ainoastaan Kotkan Energian Tuotanto-liiketoimintaa, koska se muodostaa selkeästi suurimman osan yhtiön liiketoiminnan laajuudesta ja siinä on potentiaalisesti data-analytiikan keinoin saatavissa irti paljon taloudellista lisäarvoa. Työ käsittelee osaksi myös Energia-liiketoiminnan toiminta-aluetta, koska myös se harjoittaa case-yhtiössä tuotannon suunnittelua ja optimointia ja siten liiketoiminnat nivoutuvat vahvasti yhteen jokapäiväisessä suorittamisessa. Tutkimus keskittyy ainoastaan taloudelliseen hyötyyn, jota on paljon helpompi mitata ja luotettavasti havaita, kuin vaikkapa arvopohjaisia hyötyjä. Tutkimuksia, joiden tuloksilla ja johtopäätelmillä voidaan saavuttaa case-yhtiössä varmuudella taloudellisia hyötyjä, joka on tutkimuksen tavoitteena, on siis mahdollista löytää. Tutkimuksessa sivutaan kumminkin mahdollisia hyötyjä laidasta laitaan. Tutkimus ei ota kantaa siihen miten mahdollinen keskitetty data-alusta kannattaa rakentaa eikä käsittele teknistä toteutusta tarkemmin. Työssä ei oteta myöskään siihen kantaa olisiko kyseinen data-alusta

data-analytiikkaratkaisuineen kannattavampi ratkaisu kokonaisuudessaan kuin vaihtoehtoiset toimintatavat vaan keskittyy ainoastaan kertomaan hyödyistä.

Suuret datavarastot ja niihin liittyvä data-analytiikka ovat hyvin uutta teknologiaa, joten niiden hyödyistä energia-alan tuotanto-liiketoiminnoissa ei ole saatavilla varmistettua tieteellistä tutkimustietoa kovinkaan paljon. Tämän takia tässä tutkimuksessa pyrin yhdistämään tieteellisten tutkimusten todettuja hyötyjä ja alan ammattilaisten lausuntoja hyödyistä ja mahdollisista käyttökohteista tällä sektorilla. Alan ammattilaisten lausunnot olen saanut kasaan asiantuntijahaastatteluilla valikoiduista asiantuntijaorganisaatioista. Aiempaa tutkimusta ja asiantuntijahaastatteluita sovellan case-yhtiön Tuotanto-liiketoimintaan, joka minulle tämän työn on toimeksi antanut. Tutkimuksessa on todella paljon monimutkaista englanninkielistä termistöä, joista käytetään lyhenteitä, liittyen data-analytiikkaan. Nämä lyhenteet ovat listattuna tutkimustyön alussa olevalla lyhenneluettelolla, mutta jokaista lyhennettä ei ollut järkevää avata laajasti tekstin seassa tai tämä tutkimus olisi venynyt tarpeettoman pitkäksi.

Seuraavassa luvussa kerron tässä diplomityössä käytetyistä tutkimusmenetelmistä ja tutkimuksen rakenteesta.

1.3 Tutkimusmenetelmät ja työn rakenne

Tutkimuksessa on käyty läpi mittava määrä tieteellisiä artikkeleita ja julkaisuja. Paljon empiiristä tutkimustietoa on käyty läpi aiemmin tehdyistä tutkimustöistä, joissa on tutkittu erilaisia data-analytiikan hyödyntämisen soveltamistapoja. Näitä on tässä työssä yhdistelty case-yhtiön liiketoimintaympäristöön ja tuotu esille konkreettisia taloudellisen hyödyn mahdollisuuksia. Tutkimusmenetelminä ovat toimineet kirjallisuuskatsaus teoriaan ja case-tutkimuksiin tältä alueelta, asiantuntijahaastattelut ja case-tutkimus koskien energiayhtiön Tuotanto-liiketoimintaa. Tämä tutkimus on laadullinen eli kvalitatiivinen tutkimus.

Kirjallisuuskatsauksen tarkoituksena on esitellä aihealueen teoriapohjaa ja käydä läpi millä tavoin aihetta on aiemmin tutkittu. Tässä tutkimuksessa on siis selvitetty, mitä aiheesta jo tiedetään olemassa olevan kirjallisuusaineiston perusteella. Kirjallisuuskatsauksessa olevat aihealueet on valittu oleellisimpina teoriataustoina tutkimustyölle. Tutkimuksen rakenne koostuu siis aikaisemmista oleellisista tutkimuksista saatujen tietojen ja havaintojen

kokoamisesta yhteen, jonka jälkeen ne yhdistellään asiantuntijahaastatteluista ja case-tutkimuksesta saatuihin tietoihin ja sen pohjalta on tehty johtopäätökset ja vastattu tutkimuskysymyksiin.

Työ muodostuu rakenteeltaan kuudesta pääluvusta, joista ensimmäinen on johdanto. Johdannossa lukija saatetaan sisään tutkimuksen aihealueeseen, käydään läpi työn taustaa ja syytä sen tekemiselle, käydään työlle asetetut tavoitteet ja rajaukset läpi sekä tavoitteiden saavuttamiseksi käytetyt tutkimusmenetelmät. Toinen luku sisältää tutkimustyön aihealueeseen kuuluvan teoriaosuuden. Luettuaan toisen luvun lukija hahmottaa laajan kokonaisuuden johon taloudellisen hyödyn etsiminen energiayhtiön tuotantoliiketoiminnasta linkittyy. Toiseen lukuun on pyritty tuomaan teoriatausta tärkeimmistä aihealueista. Toisessa luvussa käydään ensin omaisuudenhallinnan teoriaa ja keskeisiä termejä läpi. Tämän jälkeen toisessa luvussa lukijalle esitellään tiedolla johtamisen käsitteet ja perusteet ja tämän alaluvussa tutkimuksen kannalta tärkeä data-analytiikan teorian ja perusteiden esittely. Kolmas luku sisältää kirjallisuuskatsauksen energia-alan data-analytiikkaan empiiristen tapaustutkimusten kautta ja tämän jälkeen kolmannessa luvussa käydään läpi asiantuntijahaastatteluiden vastaukset. Näiden avulla saavutetaan tieto konkreettisista energia-alan mahdollisuuksista data-analytiikan saralla. Neljännessä luvussa esitellään tämän tutkimuksen case-yhtiö, Kotkan Energia, ja sen Tuotanto-liiketoiminta johon työ suuntautuu. Neljännessä luvussa käydään myös läpi tutkimuksen kannalta oleelliset datan lähteet tuotanto-liiketoiminnassa. Viidennessä luvussa työn keskeisimmät tulokset kootaan johtopäätöksiksi vastaamaan tutkimuskysymyksiin. Lopuksi kuudennessa luvussa työn tausta, tavoitteet, tutkimuksen toteutus sekä keskeisimmät tulokset ja tulevaisuuden ideat esitetään yhteenvetona.

Tutkimusaineistoksi tässä tuotantotalouden diplomityössä on valittu pääosin kirjoja, vertaisarvioituja artikkeleita ja muita tieteellisiä julkaisuja, jotka ovat saatavilla sähköisessä muodossa. Tutkimusaineistona on myös toiminut asiantuntijahaastattelut organisaatioista, jotka toteuttavat aihealueeseen liittyviä hankkeita data-analytiikan saralla. Asiantuntijahaastatteluita on myös käytetty Case-yhtiön kohdalla kertomaan tarkemmin datan lähteistä tuotanto-liiketoiminnassa. Tutkimuksen aineisto löydettiin pääsääntöisesti aiheeseen liittyvän käsitteistön avulla ja tekemällä empiiristä tutkimustyötä case-yhtiön tuotantotiloissa. Tiedonhaussa käytettiin tätä aihealueen käsitteistöä ja niiden avulla muodostettuja hakulauseita, jotta löydettäisiin aihealueesta oleellisimmat tutkimukset ja teokset. Tässä tutkimuksessa tiedonhakuun on käytetty Lappeenrannan yliopiston LUT Primoa ja Scopusta. LUT Primo on

Lappeenrannan yliopiston LUT-tiedekirjaston hakupalvelu, joka löytää painetut ja sähköiset kirjat, lehdet ja artikkelit sekä tietokannat yhdellä haulla. Scopus on tiivistelmä- ja viittaustietokanta, joka kattaa muun muassa tuhansia ja taas tuhansia tieteellisiä artikkeleita ja lehtiä lääketieteen, teknologian, taiteiden, humanististen tieteiden, yhteiskuntatieteiden sekä luonnontieteen aloilta. Aineistoa on myös jouduttu etsimään normaaleilla verkkohauilla muun muassa asiantuntijahaastatteluiden kohteita etsittäessä. Case-yhtiöstä aineistoa on kerätty yhtiön kotisivuilta, vuosikertomuksista, henkilöstön asiantuntijahaastatteluista ja itse tutkimalla paikan päällä järjestelmiä ja laitteistoa.

Kirjallisuusaineistolle valinnan kriteereinä on toiminut tekstin kieli (suomi ja englanti), julkaisuvuosi sekä kirjallisuusaineiston olemista vertaisarvioitua. Kirjallisuusaineiston, joka ei ole ollut vertaisarvioitua, kohdalla aineiston laatua arvioitiin aineiston julkaisijaa tarkastelemalla ja muun muassa tutkimalla lähteiden käyttöä niissä. Pyrkimyksenä on ollut löytää ja valita mahdollisimman tuoretta lähdemateriaalia tutkimukseen eli tavoitteena on siis ollut mahdollisimman uuden aineiston tutkiminen. Pääsääntöisesti valittuna on englanninkielistä lähdeaineistoa. Näitä kriteereitä aineistoa valittaessa käyttämällä on saatu diplomityö tutkimukseni kannalta oleellisimmat, tarkimmat ja uusimmat teokset käyttöön. Tässä tutkimuksessa on käytetty ainoastaan suomen- ja englanninkielisiä aineistoja. Diplomityön tutkimusaineistosta karsiutui monia lähteitä pois valintakriteerien myötä. Hakusanoina on käytetty esimerkiksi käsitteitä ”data analytics”, ”tiedolla johtaminen”, ”energy company”, ”predictive maintenance”, ”business intelligence”, ”omaisuudenhallinta”, ”artificial intelligence” ja näiden yhdistelmiä ja käännöksiä.

2 Teoria ja aiempi tutkimus

Tämä luku käsittelee tämän tutkimuksen kannalta keskeisiä aihealueita. Luvussa käydään läpi teoriaa ja aiempaa tutkimusta omaisuudenhallinnan, tiedolla johtamisen, data-analytiikan ja kunnossapidon alueilta.

2.1 Omaisuudenhallinta

Tämä luku kertoo omaisuudenhallinnasta ja sen teoriasta. Omaisuudenhallinnan käsitteistä ja periaatteista on olennaista kertoa tässä tutkimuksessa, koska case-yhtiö pyrkii kehittämään Tuotanto-liiketoiminnan omaisuudenhallintaa löytämällä konkreettisia taloudellisia hyötyjä sen arvokkaan omaisuusmassan tuottamasta datasta ja sen analysoinnista. Tässä työssä puhutaan tuotanto-omaisuuden hallinnasta ja omaisuudenhallinnasta. Ne tarkoittavat käytännössä samaa ja niihin soveltuu täysin samat periaatteet. Tuotanto-omaisuuden hallinnasta puhuttaessa vaan halutaan korostaa, että sillä hetkellä puhutaan tuotantoon liittyvästä omaisuudenhallinnasta. Luvussa kerrotaan omaisuudenhallinnan määritelmistä ja miten sitä tulisi toteuttaa kansainvälisen ISO 55000 standardin, Britannialaisen PAS 55 standardin ja omaisuudenhallinnan alueella tehtyjen tutkimuksien perusteella.

Kansainvälinen standardi omaisuudenhallinnalle on International Standard ISO 55000 "Asset management – Overview, principles and terminology". Tämä standardi tarjoaa yleiskuvan omaisuudenhallinnasta ja siihen liittyvistä järjestelmistä. Tästä standardista on myös suomenkielinen versio SFS-ISO 55000 ”OMAISUUDENHALLINTA. YLEISKUVAUS, PERIAATTEET JA TERMIT”. Standardin avulla organisaatiot voivat saavuttaa tavoitteensa hallitsemalla omaisuuttaan tehokkaasti ja tarkoituksenmukaisesti. Omaisuudenhallinta on kehittynyt strategiaksi, joka huomioi omaisuuden koko elinkaaren kaikki keskeiset vaiheet ideasta investointiin ja edelleen käytöstä poistamiseen. On tärkeää varmistaa, että omaisuuden potentiaalia hyödynnetään kustannustehokkaasti. Tehokkaasti toteutettuna omaisuudenhallinta tarjoaa rakenteellisen lähestymistavan omaisuuteen liittyvien päätösten tekemiseen ja auttaa organisaatioita saavuttamaan liiketoimintatavoitteensa sekä parantamaan riskienhallintaa.

ISO 55000 -standardissa omaisuudenhallinta määritellään seuraavasti: "Organisaation koordinoitu toiminta omaisuuden arvon toteuttamiseksi." Omaisuus puolestaan nähdään "esineenä, asiana tai entiteettinä, jolla on potentiaalista tai todellista arvoa organisaatiolle" (ISO 55000, 2014). Tämä määritelmä on hyvin laaja ja kattaa lähes kaikenlaiset omaisuustyypit. Esimerkiksi brittiläisessä PAS 55 -standardissa omaisuudenhallinta kuvataan järjestelmällisiksi ja koordinoiduiksi toimiksi, joiden avulla organisaatio hallitsee optimaalisesti fyysistä omaisuuttaan ja siihen liittyvää suorituskykyä, riskejä ja kustannuksia omaisuuden elinkaaren ajan strategisten tavoitteidensa saavuttamiseksi (PAS 55, 2008). Omaisuuden määrittävänä tekijänä on sen arvo tai potentiaalinen arvo omistavalle organisaatiolle eli toisin sanoen omaisuudeksi ei lasketa sellaisia asioita, joilla ei ole arvoa tai edes potentiaalista arvoa organisaatiolle. (ISO 55000, 2014)

Tehokas omaisuudenhallinta tarjoaa monia etuja, kun se suunnitellaan ja toteutetaan asianmukaisesti. Se luo jäsennellyn lähestymistavan omaisuuteen liittyvien päätösten tekemiseen, kattaen kaiken investoinnista käyttöön, kunnossapitoon ja hävittämiseen. Näiden päätösten perustana ovat konkreettiset tiedot, eivät epämääräiset visiot tai olettamukset. Omaisuudenhallinnan ensisijaisena tavoitteena on varmistaa, että päätökset tukevat liiketoiminnan tavoitteita ja yrityksen strategiaa. (Hastings, 2014)

Omaisuudenhallinta voidaan jakaa kolmeen tasoon. Korkeimmalla tasolla on strateginen omaisuudenhallinta (Strategic Asset Management, SAM), joka keskittyy pitkäjänteiseen näkökulmaan omaisuudenhallinnan prosesseissa. Tämä taso kattaa usein koko yritystä koskevat käytännöt, strategiat ja budjettipäätökset. Käytännössä strateginen omaisuudenhallinta tarkoittaa organisaation omaisuuden linjaamista sen strategisen suuntautumisen kanssa. Yksi tapa toteuttaa strategista omaisuudenhallintaa on strategisen omaisuudenhallintasuunnitelman (Strategic Asset Management Plan, SAMP) laatiminen. Tämä suunnitelma sisältää kuvaukset olemassa olevista omaisuuseristä, niiden kunnosta ja kriittisyydestä, omaisuuserien roolista ja merkityksestä, tulevista odotuksista, markkinoista, sääntelystä, teknologiasta jne. ISO 55000 määrittelee SAMP:n seuraavasti: "dokumentoitua tietoa, joka määrittää, kuinka organisaation tavoitteet muutetaan omaisuudenhallinnan tavoitteiksi". (Marlow, 2008)

Nykyhetken ja tulevaisuuden näkökulmien välillä on lähestymistapa, jota kutsutaan taktiseksi omaisuudenhallinnaksi (Tactical Asset Management, TAM). Tämä taso liittyy yleensä keskipitkän aikavälin käytäntöihin. Tämän vuoksi jotkut tutkijat käyttävät termiä "käytännön omaisuudenhallinta" (practical asset management) kuvaamaan samankaltaista

tilannetta. Taktisessa omaisuudenhallinnassa käsitellään kysymyksiä, kuten mitä toimia tulisi tehdä, milloin ja missä. Tämän seurauksena taktisen omaisuudenhallinnan tasolla tarvittavat tiedot ja data ovat tarkempia verrattuna strategiseen tasoon. (Marlow, 2008)

Päivittäiset ja konkreettisimmat toimet kuuluvat operatiiviseen omaisuudenhallintaan. Tätä termiä käytetään kuitenkin harvemmin, koska siihen liittyvät toiminnot kuvataan paremmin termillä "käyttö ja kunnossapito" (Operations and Maintenance, O&M). Käyttö ja kunnossapito sisältää rutiininomaiset uusimis- ja kunnossapitotoimet, jotka toteutetaan strategisten ja taktisten tavoitteiden mukaisesti. Näistä kolmesta tasosta O&M:llä on lyhyin aikahorisontti. Näiden käsitteiden välistä suhdetta on havainnollistettu myös kuvassa 1. (Marlow, 2008)

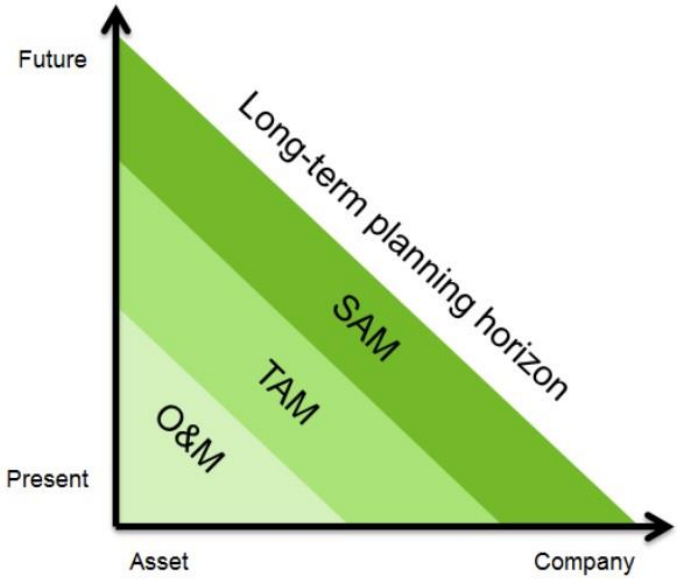

KUVA 1: Omaisuudenhallinnan eri tasot (Marlow, 2008)

Jotta omaisuutta voidaan hallita tehokkaasti, on olennaista ymmärtää selkeästi sen nykyinen kunto. Marlow (2008) toteaa, että "kunnonarviointi, prosessi, jolla arvioidaan omaisuuserän fyysistä tilaa, esitetään usein tehokkaan omaisuudenhallinnan kulmakivenä". Yleisesti omaisuuden kunnon ja vikaantumistodennäköisyyden välillä on negatiivinen korrelaatio. Marlow (2008) varoittaa, että toimiminen omaisuusintensiivisellä alalla ilman asianmukaista tietoa omaisuuden kunnosta on tulevaisuudeltaan tuhoon tuomittua. Kunnonarvioinnin taso vaihtelee huomattavasti eri teollisuudenalojen ja yritysten välillä. Nykyään laitteiden kunnonvalvonnan ei kuitenkaan pitäisi olla ongelma. Álvarez et al. (2020) toteavat, että älykkäiden sensoreiden, ilmaisimien ja niihin liittyvien laitteiden nopea teknologinen kehitys on

johtanut hintojen laskuun. Kun nämä datankeruukyvyt integroidaan esineiden internetiin (IoT), niillä on potentiaalia muuttaa täysin lähestymistapamme kunnonvalvontaan ja omaisuudenhallintaan. Nykyisin älykkäiden tehtaiden luominen on mahdollista hyödyntämällä pilvipalveluita ja dataa jota on saatavilla. Erilaiset sensorit ja anturit mittaavat ja keräävät dataa älykkäästi, mikä luo täysin uusia mahdollisuuksia erilaisten teknologioiden, kuten koneoppimisen, hyödyntämiselle. (Álvarez et al. 2020.)

ISO 55000 -standardin keskeisiä teemoja ovat arvon tunnistaminen, pitkän elinkaaren vaikutusten huomioiminen, riskien tunnistaminen, sekä riskien, kustannusten ja käytön optimointi. Lisäksi standardi korostaa yhdenmukaisia tavoitteita ja läpinäkyvää päätöksentekoa. Sen tavoitteena on varmistaa, että organisaation kaikki omaisuus tukee tehokkaasti ja läpinäkyvästi sen strategisia tavoitteita. Standardi toimii johdon työkaluna, jonka avulla organisaatio voi selkeyttää omia tavoitteitaan ja muodostaa kattavan kokonaiskuvan. Tämän avulla koko organisaation omaisuus voidaan hyödyntää entistä tehokkaammin organisaation päämäärien saavuttamiseksi.

ISO 55000 -standardin mukaan omaisuudenhallinnan hyödyt organisaatiolle ilmenevät muun muassa parantuneina taloudellisina ja kestävän kehityksen päätöksinä, riskienhallintana, lyhyen ja pitkän aikavälin suunnittelun tukemisena sekä prosessien ja toimintatapojen tehokkuuden ja vaikuttavuuden lisääntymisenä. Lisäksi järjestelmällinen hallintatapa mahdollistaa läpinäkyvän ja todennettuun tietoon perustuvan päätöksenteon. Tehokas omaisuuden hallinta edellyttää riskien ja mahdollisuuksien hallintaa sekä kustannusten, riskien ja suorituskyvyn tasapainottamista. Tämä on tärkeää erityisesti jatkuvasti muuttuvassa sääntely- ja lainsäädäntöympäristössä. (ISO 55000, 2014).

Tuotanto-omaisuuden hallinta on keskeinen osa nykyaikaisia kunnossapitostrategioita. Se kattaa päivittäisten työtehtävien koordinoinnin, ennakoivan kunnossapidon suunnittelun, saumattoman yhteistyön tuotannon ja kunnossapidon välillä, laitteiden luotettavuuden varmistamisen, varaosien tehokkaan hallinnan sekä ympäristö- ja työturvallisuuden huomioimisen. Tavoitteena on toteuttaa tuotanto-omaisuuden hallinta siten, että yrityksen tuotannolliset tavoitteet saavutetaan optimaalisesti. Laadukas omaisuudenhallinta tarjoaa lisäksi työkaluja investointiresurssien kohdentamiseen oikeisiin kohteisiin. Parhaat tulokset saavutetaan, kun koko tuotantolaitoksen henkilöstö sitoutetaan aktiivisesti mukaan prosessiin. (Järviö, 2017)

Omaisuus luokitellaan usein alaluokkiin, kuten fyysinen omaisuus, taloudellinen omaisuus, inhimillinen omaisuus, informaatio-omaisuus ja aineeton omaisuus. Yleisin omaisuustyyppi on todennäköisesti fyysinen omaisuus, kuten tehtaat, koneet, infrastruktuuri, kulkuneuvot, tiet ja sähköverkot. Vastaavasti aineettomiin omaisuuksiin kuuluvat esimerkiksi goodwill-arvo ja immateriaalioikeudet. Rahoituksessa termi omaisuus liittyy läheisesti taseeseen, jossa omaisuuden arvo vastaa velkojen ja oman pääoman summaa. (Hastings, 2014)

Tämä työ keskittyy fyysiseen omaisuuteen, koska se on energiantuotannossa keskeinen, ja sen tehokas hallinta vaikuttaa merkittävästi yrityksen suorituskykyyn. Seuraavassa luvussa kerron tiedolla johtamisesta.

2.2 Tiedolla johtaminen

Johtamisen mallit ja käytännöt kehittyvät yhteiskunnan muutoksen ja siitä syntyvien tarpeiden mukana. Suuri osa johtamisen malleista, teorioista ja työkaluista on peräisin teollistumisen aikakaudelta, jolloin järjestelmällisiä ja systemaattisia johtamistapoja kehitettiin entistä suurempien yhtiöiden ja organisaatioiden hallinnoimiseksi. Näiden keinojen avulla varmistettiin organisaatioiden kannattavuus ja tehokkuus. Nykyaikana yritysten menestys ja kilpailukyky perustuvat yhä enemmän tietoon ja osaamiseen. Tiedolla johtamisella tarkoitetaan ajantasaiseen tietoon perustuvaa päätöksentekoa. Jokainen organisaatio joutuu päivittäin monien tärkeiden operatiivisten päätösten eteen. Ajankohtainen tilannekuva ja ymmärrys päätösten seurauksista tukevat harkittua päätöksentekoa. Tiedon käsite on laaja ja voidaan jakaa eri tasoihin: dataan, informaatioon ja tietämykseen. Data muodostuu rakenteettomista tosiasioista, joista voidaan jalostaa informaatiota. Informaatiota tulkitsemalla puolestaan syntyy tietämystä. (Laihonen et al., 2013)

Tietoon perustuva päätöksenteko vaatii syvällistä ja kattavaa tietoa omaisuuden teknisistä yksityiskohdista, kunnosta, riskeistä, luotettavuudesta, ylläpito- ja käyttökustannuksista. Monimutkaiset järjestelmät ja liiketoimintaympäristöt tuottavat kasvavia määriä tietoa. Päätöksenteossa tarvittavan relevantin ja puuttuvan tiedon erottaminen edellyttää riittävää tietohallintajärjestelmää ja käytäntöjä. Omaisuusintensiivisessä liiketoimintaympäristössä omaisuustiedon laatu ja tiedon tulkinta ovat keskeisiä haasteita optimaalisen arvon luomiseksi ja riskien hallitsemiseksi pitkällä aikavälillä. (Gavrikova et al. 2021)

Tiedolla johtaminen on strateginen lähestymistapa, jossa organisaatio hyödyntää tietoa ja analytiikkaa päätöksenteon tukena. Tietojohtamisen tutkimusala on monitieteinen ja käsittelee laajoja tutkimuskysymyksiä ja -ongelmia. Se perustuu useampaan teoreettiseen viitekehykseen. Liiketoiminnasta ja organisaatiosta kerätty tieto on dataa, joka on tallennettu erilaisiin tietovarastoihin tai -kantoihin. Raaka data itsessään on rajallisen hyödyllistä; sen arvo piilee sen jalostamisessa informaatioksi. Tämä saavutetaan koostamalla, järjestämällä, analysoimalla ja visualisoimalla dataa. Jalostettu informaatio muuttuu tiedoksi, kun sitä yhdistetään eri lähteistä ja muokataan helposti ymmärrettävään muotoon. Silloin kun eri järjestelmissä tuotettu data pääsee data-analytiikan avulla oikeuksiinsa, datan ymmärtäminen syvenee ja liiketoiminnan päätöksenteon laatu paranee. Lisäksi data voi toimia perustana uusien liiketoimintamahdollisuuksien kehittämiselle. Tässä prosessissa on olennaista tunnistaa, mitkä datasta johdetut johtopäätökset ovat niin merkityksellisiä, että niiden pohjalle kannattaa ja tulisi rakentaa liiketoimintaa. (Laihonen et al., 2013)

Alla oleva piirustus kuvaa mielestäni hyvin sitä, että nykyisessä maailmassamme runsaana vyöryvä datamassa täytyy jotenkin käsitellä tehokkaasti, jotta saisimme siitä hyödyllistä tietoa irti riittävässä ajassa. Piirustus kuvaa eroa datan, informaation, tiedon, oivallusten ja viisauden välillä. Kuva erottelee, että itse datalla ei vielä tee mitään vaan dataa täytyy jollain tavalla käsitellä jonkun ihmisen tai järjestelmän toimesta, että siitä tulee käyttökelpoista tietoa, joka tuottaa viisaita ratkaisuja.

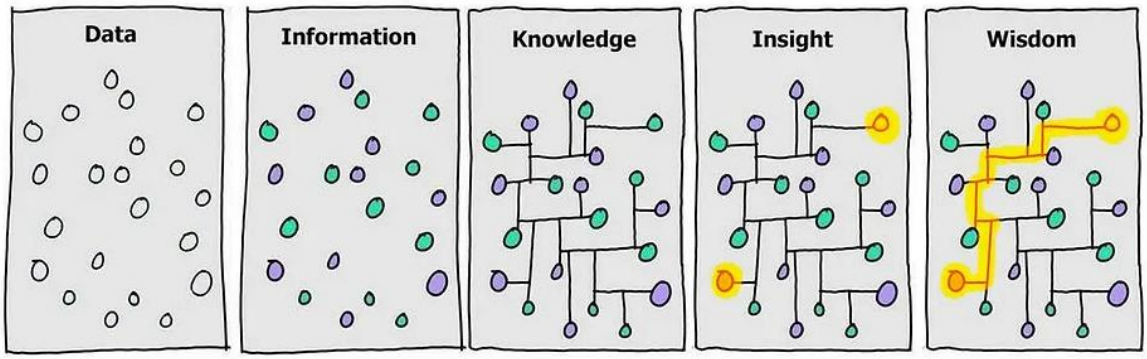

KUVA 2: Datasta tiedoksi (David Somerville, Hugh McLeod 2016)

Vanha kuuluisa sanonta kuuluu: "Tieto on valtaa". Ei siis data tai informaatio, vaan tieto. Tässä maailmassa, jossa meillä on lähes käsittämätön määrä dataa saatavilla, on tärkeää juuri se, miten kokoamme, yhdistämme ja sovellamme tätä informaatiota mikä synnyttää tietoa. Lopulta syntyy toivottavasti myös viisautta, niin kuin yllä olevassa piirustuksessa kuvataan.

Nykyään datan ja tiedon käsittelyä varten on monia keinoja ja jopa monen päätöksen saa ulkoistettua ihmiseltä erilaisille järjestelmille. Seuraavassa luvussa kerrotaan data-analytiikasta, joka pystyy auttamaan organisaatioita datan tehokkaassa hallinnassa ja hyödyntämisessä.

2.2.1 Data-analytiikka

Data-analytiikka on noussut keskeiseksi työkaluksi organisaatioille, jotka pyrkivät tekemään tietoon perustuvia päätöksiä. Tämä luku tarkastelee data-analytiikkaa käsitteenä ja sen eri osa-alueita, kuten datan keruuta, analysointimenetelmiä ja tulosten hyödyntämistä.

Teknologian kehitys ja teollinen esineiden internet mahdollistavat yrityksille suurten tietomäärien keräämisen ja tallentamisen tietokantoihin ja tietovarastoihin. Näin suuren raakadatan keskellä organisaatiot tarvitsevat kiireellisesti analytiikkatyökaluja, joiden avulla ne voivat tehokkaasti seuloa valtavia tietoaineistoja ja saada käyttökelpoista tietoa ja ymmärrystä näistä aineistoista liiketoimintojen optimoinnin tueksi (Zhang & Zhang, 2015). Nykyisessä datan yltäkylläisyyden ajassa organisaatiot kohtaavat haasteen: miten erottaa arvokas tieto suuresta tietomassasta? Vastauksen tähän tarjoaa data-analytiikka, joka mahdollistaa sekä historiallisten trendien ymmärtämisen että ennusteiden tekemisen tulevasta.

2000-luvun alkupuolella data-analytiikka yleistyi terminä, ja Runkler (2016) on määritellyt sen tietokonejärjestelmien soveltamiseksi suurten tietoaineistojen analysointiin päätöksenteon tukemiseksi. Data-analytiikkaa voidaan pitää moniulotteisena alana, joka yhdistää muun muassa tilastotiedettä, koneoppimista, järjestelmäteoriaa, kuviontunnistusta ja tekoälyä. Data-analytiikka on keskeisessä roolissa tietoon perustuvassa johtamisessa, ja sen lähtökohtien tulisi olla sidoksissa liiketoiminnan tarpeisiin pelkkien matemaattisten mallien sijaan. (Runkler 2016, Markkula 2015)

Data-analytiikka tarkoittaa raakadatan systemaattista analysointia hyödyntäen tilastollisia, matemaattisia ja koneoppimisen menetelmiä (Provost, 2013). Sen tavoite on tuottaa oivalluksia, jotka voivat parantaa liiketoimintaprosesseja, asiakaskokemusta ja organisaation kilpailukykyä. Data-analytiikalla on tärkeä rooli nykypäivän yritysmaailmassa. Analyysin tekemiseen on olemassa erilaisia tapoja, jotka tarjoavat yrityksille mahdollisuuden käyttää tietojaan eri tavoin. Aiemmista tapahtumista voidaan hankkia tietoa, ratkaista ongelmia, tehdä ennusteita tai laatia suosituksia. (Davenport, 2017).

Vaikka digitalisaatio ja liiketoiminta-analytiikka voivat olla uusia kehityskulkuja, on tärkeää tunnistaa, että tiedolla johtamisen ja tietoon perustuvan päätöksenteon konsepti on ollut keskustelun aiheena jo useiden vuosikymmenten ajan. Digitalisaatio, joka on saanut alkunsa dataohjautuvasta johtamisesta, antaa organisaatioille mahdollisuuden parantaa toimintaansa ja lisätä kustannustehokkuutta, tarjoten niille paremmat valmiudet sopeutua nykyajan nopeasti muuttuviin liiketoimintaympäristöihin. (Ratia 2022)

IoT-teknologian avulla laitteet ja esineet pystyvät keräämään ja jakamaan dataa, mikä mahdollistaa esimerkiksi näiden laitteiden valvonnan ja etäseurannan. Kun kerätty data yhdistetään data-analytiikkaan ja koneiden väliseen viestintään, voidaan tuottaa uutta tietoa, joka parantaa tuottavuutta ja tuo näin liiketoiminnallista arvoa. Esimerkiksi koneoppimistyökaluja yhdistettynä anturidataan voidaan käyttää vikojen ennustamiseen etukäteen. (Kanawaday, 2017)

Nykyään älykkäitä tuotantolaitoksia on mahdollista luoda hyödyntämällä käytettävissä olevaa dataa ja erilaisia pilvipalveluita. Älylaitteet keräävät, jakavat ja hyödyntävät tietoa. Maailman kehittyminen tähän suuntaan avaa uudenlaisen mahdollisuuden monenlaisten teknologioiden, esimerkiksi tekoälypohjaisen koneoppimisen, käyttöönottamiseen. Tekoälypohjainen koneoppiminen voi tuoda erilaisille liiketoiminnoille merkittäviä hyötyjä. Teollisen internetin ympäristössä koneoppimista voidaan käyttää esimerkiksi ennakoivassa kunnossapidossa. Yleisemmin koneoppiminen mahdollistaa yrityksille paremman datan hyödyntämisen ja ymmärtämisen. Koneoppimisen avulla voidaan optimoida tuotantoa, parantaa tuotteiden laatua, parantaa päätöksentekoa ja vähentää kustannuksia. (Álvarez et al., 2020)

Yritykset hyödyntävät dataa monista eri lähteistä, jotka voidaan jakaa sisäisiin ja ulkoisiin. Sisäisiin lähteisiin kuuluu yrityksen jo olemassa oleva data, kuten ERP-järjestelmissä säilytetty tieto, sekä itse tuotettu data, jota kerätään esimerkiksi sensoreiden tai verkkoseurannan avulla. Lisäksi yritykset voivat käyttää dataa, joka syntyy laajojen joukkojen osallistumisella, esimerkiksi verkkoyhteisöissä. (Hartmann et al.,2016)

Sisäiset datan lähteet ovat yrityksen omasta toiminnasta syntyvää tietoa, jota voidaan hyödyntää liiketoiminnan kehittämiseen ja päätöksenteon tueksi. Ensimmäinen merkittävä lähde on olemassa oleva data, joka on yrityksen aiemmin keräämää ja varastoimaa tietoa. Tämä voi sisältää esimerkiksi myyntitietoja, varastodataa, asiakastietoja ja taloudellisia raportteja, jotka löytyvät usein ERP- tai CRM-järjestelmistä. Olemassa oleva data on yleensä hyvin

jäsenneltyä ja helposti hyödynnettävissä. Toinen tärkeä lähde on itse tuotettu data, joka kerätään tarkoituksellisesti yrityksen omien prosessien tai teknologioiden avulla tiettyjä tarpeita varten. Esimerkiksi tuotantolinjojen sensorit tuottavat reaaliaikaista tietoa laitteiden toiminnasta ja ympäristöolosuhteista, kun taas verkkoseuranta tarjoaa tietoa verkkosivuston käyttäjien toiminnasta, kuten sivustovierailuista ja ostoskäyttäytymisestä. Lisäksi järjestelmien ja sovellusten tekniset lokitiedot tarjoavat arvokasta tietoa suorituskyvyn parantamiseen ja virheiden analysointiin. Kolmas sisäisen datan lähde on joukkoistettu data, joka syntyy yrityksen työntekijöiden, asiakkaiden tai laajempien yhteisöjen osallistumisella. Esimerkiksi asiakasportaalien kautta kerätyt käyttäjäarviot ja palaute tarjoavat arvokasta tietoa asiakaskokemuksesta, kun taas työntekijöiden ideointikilpailuissa tuotetut ratkaisut voivat auttaa innovaatioiden kehittämisessä. Myös sosiaalisen yhteistyön kautta syntynyt data, kuten tiimityöskentelyn aikana luodut dokumentit ja keskustelut, voi olla arvokasta organisaation sisäisen toiminnan tukemisessa. Sisäisen datan etuna on sen tarkkuus ja relevanttius, sillä se liittyy suoraan yrityksen omiin prosesseihin ja tarpeisiin. Tämä data tarjoaa yritykselle mahdollisuuden optimoida toimintojaan, tehostaa prosessejaan ja tehdä päätöksiä, jotka perustuvat todellisiin ja ajankohtaisiin tietoihin. (Hartmann et al.,2016)

Ulkoiset datalähteet ovat yrityksen ulkopuolisista lähteistä saatavaa dataa, joka voi täydentää sisäisiä datalähteitä ja tarjota uusia näkökulmia liiketoiminnan kehittämiseen. Näitä lähteitä voidaan luokitella useisiin kategorioihin. Ensimmäinen merkittävä ulkoinen lähde on ostettu data, jota hankitaan kolmansilta osapuolilta, kuten markkinatietopalveluilta, tietokantayhtiöiltä tai muilta datan tarjoajilta. Tällainen data voi sisältää esimerkiksi taloustietoja, markkinatutkimuksia tai kilpailijoiden analyysitietoja. Tämä kaupallisesti hankittu data on usein hyvin jäsenneltyä ja helposti analysoitavissa. Toinen ulkoinen lähde on asiakas- tai kumppanidata, jota yritykset saavat yhteistyökumppaneiltaan tai suoraan asiakkailtaan. Tällainen data voi sisältää yksityiskohtaisia käyttäjäprofiileja, asiakastapahtumia tai muita tietoja, jotka eivät ole yleisesti saatavilla. Asiakas- ja kumppanidata auttaa yrityksiä ymmärtämään paremmin kohderyhmiensä tarpeita ja kehittämään räätälöityjä ratkaisuja. Kolmas ulkoinen datalähde on vapaa data, joka on julkisesti saatavilla ilman kustannuksia. Tähän kuuluu avoin data, joka on yleensä jäsenneltyä, koneellisesti luettavaa ja ladattavissa esimerkiksi julkisista tietokannoista. Avoimen datan esimerkkejä ovat tilastotiedot, ympäristötiedot ja liikenteeseen liittyvät tiedot, joita hallitukset tai julkiset organisaatiot usein julkaisevat. Vapaaseen dataan kuuluu myös sosiaalisen median data, jota voidaan kerätä alustoilta, kuten Facebookista, Twitteristä ja LinkedInistä. Ulkoisista lähteistä saatava data on monipuolista

ja tarjoaa yrityksille arvokkaita mahdollisuuksia rikastaa omia tietovarantojaan. Se auttaa yrityksiä tunnistamaan uusia markkinamahdollisuuksia, parantamaan asiakaskokemusta ja tekemään strategisesti perusteltuja päätöksiä. Näiden lähteiden tehokas hyödyntäminen edellyttää kuitenkin datan laadun arviointia ja sopivien analyysimenetelmien valintaa, jotta data saadaan integroitua yrityksen sisäisiin järjestelmiin ja tavoitteisiin. (Hartmann et al.,2016)

Alla Hartmann et al. (2016) tutkimuksesta sovellettu kuva datan lähteistä yhtiölle.

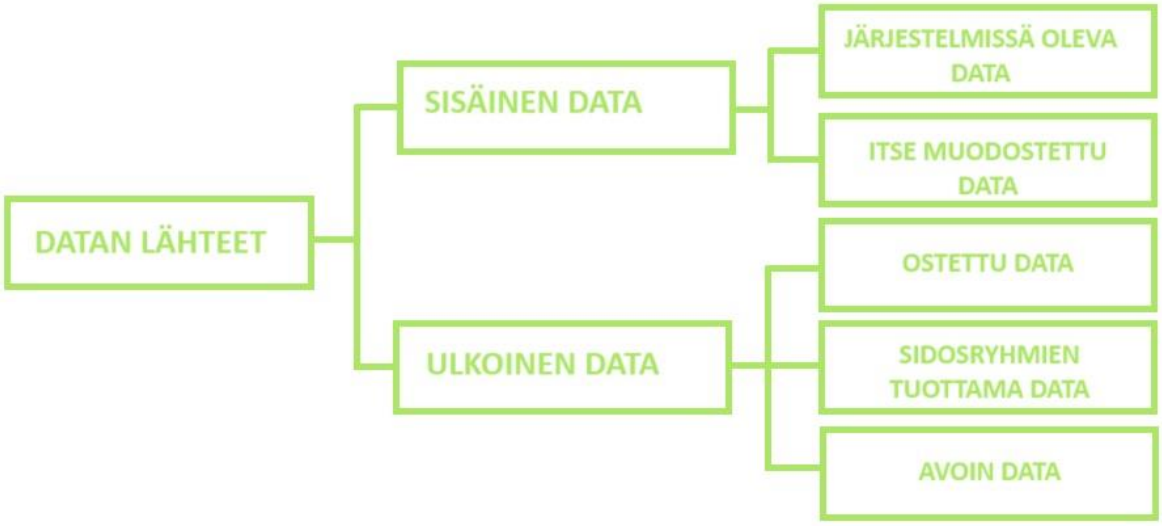

KUVA 3: Datan lähteet yhtiöissä (Hartmann et al.,2016)

Data-analytiikkaprosessi koostuu useista vaiheista, jotka muodostavat kokonaisvaltaisen prosessin datan keräämisestä johtopäätösten tekemiseen. Alla on tarkempi kuvaus prosessin vaiheista ja niiden merkityksestä.

1. Datan keruu ja esikäsittely

Datan keruu on ensimmäinen vaihe data-analytiikkaprosessissa. Se käsittää raakadatan hankinnan monista eri lähteistä, kuten IoT-laitteista, asiakaskyselyistä, yrityksen sisäisistä järjestelmistä, tietokannoista, sensoreista, verkkosivujen lokitiedostoista, julkisista lähteistä tai sosiaalisen median alustoilta. (Han et al., 2011)

Yritykset hyödyntävät dataa monista eri lähteistä, jotka voidaan jakaa sisäisiin ja ulkoisiin. Sisäisiin lähteisiin kuuluu yrityksen jo olemassa oleva data, kuten ERP-järjestelmissä säilytetty tieto, sekä itse tuotettu data, jota kerätään esimerkiksi sensoreiden tai verkkoseurannan avulla. Lisäksi yritykset voivat käyttää joukkolähteistettyä dataa, joka syntyy laajojen joukkojen osallistumisella, esimerkiksi verkkoyhteisöissä. (Hartmann et al.,2016)

Datan esikäsittely on yksi data-analytiikkaprosessin tärkeimmistä vaiheista, sillä kerätty raakadata on harvoin välittömästi käyttökelpoista ja siksi datan esikäsittely on välttämätön vaihe. Kerätty data on usein sekalaista, epätäydellistä ja virheellistä. Esikäsittelyn tavoitteena on tehdä datasta analysointikelpoista ja parantaa analyysin laatua. On tärkeää tietää mihin tarkoitukseen data-analytiikkaa käytetään, jotta osattaisiin valmiiksi karsia turhia datan lähteitä ja valita tarkoituksenmukaiset lähteet. (Han et al., 2011)

Datan puhdistaminen käsittää virheiden ja epäjohdonmukaisuuksien poistamisen. Tällaisia on esimerkiksi puuttuvat arvot, kaksoiskappaleet ja poikkeamat. Tämä vaihe on kriittinen, koska likainen data voi johtaa virheellisiin analyysituloksiin (Han et al., 2011). Puuttuvia arvoja voi käsitellä esimerkiksi korvaamalla keskiarvolla, mediaanilla tai moodilla, jos muuttuja on numeerinen. K-keskimäärämenetelmää tai ennustemalleja kannattaa käyttää, kun data on monimutkaisempaa. Poikkeavien arvojen havaitsemiseen ja korjaamiseen kannattaa käyttää menetelmiä, kuten Z-arvoa, IQR-menetelmää (kvartiiliväli) tai visualisointityökaluja. Datasta poistetaan tai korjataan ristiriitaiset tai mahdottomat arvot (esimerkiksi syntymävuosi 2100). (Little & Rubin, 2014)

Käsittelyvaiheessa data muutetaan sopivaan muotoon analyysia varten, esimerkiksi normalisoimalla tai luomalla johdettuja muuttujia (Provost & Fawcett, 2013). Datasetin ollessa liian suuri, datan vähentämisvaihe auttaa pienentämään analyysiin käytettävää datamäärää. Tätä voi tehdä muun muassa valitsemalla analyysiin vain merkityksellisimmät muuttujat, esimerkiksi käyttämällä PCA-menetelmää (Principal Component Analysis) (Goodfellow et al., 2016).

Kerätessä dataa useista eri lähteistä, ne on yhdistettävä yhdeksi yhtenäiseksi tietokannaksi. Integraatiovaihe on erityisen tärkeä suurten datavarastojen ja hajautettujen tietojärjestelmien yhteydessä. Esikäsittelyn laiminlyönti voi johtaa virheellisiin analyysituloksiin ja huonoihin päätöksiin. (McKinney, 2017)

2. Analysointi

Analysointi on data-analytiikkaprosessin keskeinen vaihe, jossa kerätty ja esikäsitelty data muuttuu hyödylliseksi tiedoksi ja oivalluksiksi. Analysointivaiheessa dataa käsitellään tarkoituksenmukaisilla menetelmillä, jotka voivat olla tilastollisia, algoritmipohjaisia tai koneoppimiseen perustuvia. Analyysimenetelmät vaihtelevat yksinkertaisista tilastollisista

menetelmistä kehittyneisiin koneoppimismalleihin, kuten syväoppimiseen. Mallin valinta riippuu analyysin tavoitteesta ja käytettävissä olevasta datasta. (Goodfellow et al., 2016)

Analysoinnin tyyppejä on muun muassa kuvaileva analyysi, joka soveltuu menneiden tapahtumien ymmärtämiseen esimerkiksi jakaumien ja trendien analysoinnilla (Davenport & Harris, 2017). Ennakoivassa analyysissä ennustetaan tulevia tapahtumia historiallisten datamallien perusteella. Hyödyntää malleja, kuten regressio- ja luokittelualgoritmeja ja koneoppimismalleja, kuten satunnaismetsät ja tukivektorikoneet ennustamaan tulevia tapahtumia (Goodfellow et al., 2016). Ohjaava analyysi tarjoaa suosituksia parhaista toimintavaihtoehdoista käyttämällä optimointimenetelmiä ja simulointia (Davenport & Harris, 2017).

Analyysin onnistuminen riippuu käytetyn menetelmän sopivuudesta ongelmaan ja datan laadusta. Analysointimenetelmän valinta riippuu datan luonteesta, analyysin tavoitteista ja käytettävissä olevista resursseista. Tilastollisia menetelmiä käytetään yleisesti kuvailevaan analyysiin. Näihin kuuluvat keskiarvot, hajonnat, korrelaatio- ja riippuvuusanalyysit. Koneoppimismallit, kuten syväoppiminen, pystyvät käsittelemään valtavia datamassoja, joita perinteiset analyysimenetelmät eivät pysty tehokkaasti analysoimaan. Koneoppimismallit voivat käyttää uusinta dataa suorituskykynsä parantamiseen ilman, että ne on ohjelmoitava uudelleen. Tämä jatkuva oppiminen tekee niistä ihanteellisia pitkäkestoisiin projekteihin (Han et al., 2011). Tekoälyllä (AI) ja koneoppimisella on merkittävä rooli nykyaikaisessa data-analytiikassa. Nämä tarjoavat kehittynyttä analytiikkaa ja mm. syväoppimismallit (esim. neuroverkot) mahdollistavat analyysin, joka pystyy käsittelemään suuria ja monimutkaisia datakokonaisuuksia, kuten kuvia ja ääntä. Koneoppiminen on erityisen hyödyllistä, kun analyysin tavoitteena on tunnistaa monimutkaisia kaavoja tai tehdä tarkkoja ennusteita suurista datamääristä. Koneoppimismallit voivat oppia ja parantaa suorituskykyään jatkuvasti ilman manuaalista ohjelmointia. Tämä tekee niistä erityisen hyödyllisiä dynaamisissa ympäristöissä, joissa data muuttuu nopeasti. Esimerkiksi tuotantolaitoksilla voidaan ennakoivien huoltomallien avulla analysoida sensoreiden keräämää dataa ja ennustaa laitteiden vikaantuminen, mikä vähentää odottamattomia seisokkeja. Automatisoitu oppiminen vähentää ihmisen työmäärää ja lisää analyysin tarkkuutta. (Goodfellow et al., 2016).

Analyysitulosten validointi ja luotettavuuden arviointi on olennainen osa analysointivaihetta. Ristiinvalidoinnilla tarkastetaan mallin suorituskyky käyttämällä erillistä validointidataa. Ennakoivien mallien suorituskykyä arvioidaan ja tarkkuutta mitataan. Poikkeamien

analysointi on tärkeää, sillä ne voivat paljastaa joko virheitä datassa tai liiketoiminnallisia riskejä. (Han et al., 2011)

3. Visualisointi ja tulkinta

Visualisointi on olennainen osa analytiikkaprosessia, sillä se auttaa esittämään löydökset ymmärrettävällä tavalla. Tietojen tulkinta voi olla vaikeaa ilman selkeitä kaavioita ja grafiikoita. Tulosten visualisointi auttaa sidosryhmiä ymmärtämään löydöksiä paremmin. Käytössä olevia työkaluja ovat esimerkiksi Tableau, Power BI ja Pythonin visualisointikirjastot. Power BI ja Tableau mahdollistavat dynaamisten raporttien luomisen, jotka auttavat seuraamaan liiketoiminnan suorituskykyä reaaliaikaisesti. Datan voi esittää muun muassa histogrammeina, lämpökartoilla tai pistekaavioina, jotka voivat paljastaa korrelaatioita ja poikkeamia. Tässä vaiheessa analyytikon on varmistettava, että löydökset esitetään selkeästi ja niistä voidaan tehdä toimivia johtopäätöksiä. (McKinney, 2017)

Alla esimerkkinä Power BI Dashboardista kuva energia-alalta.

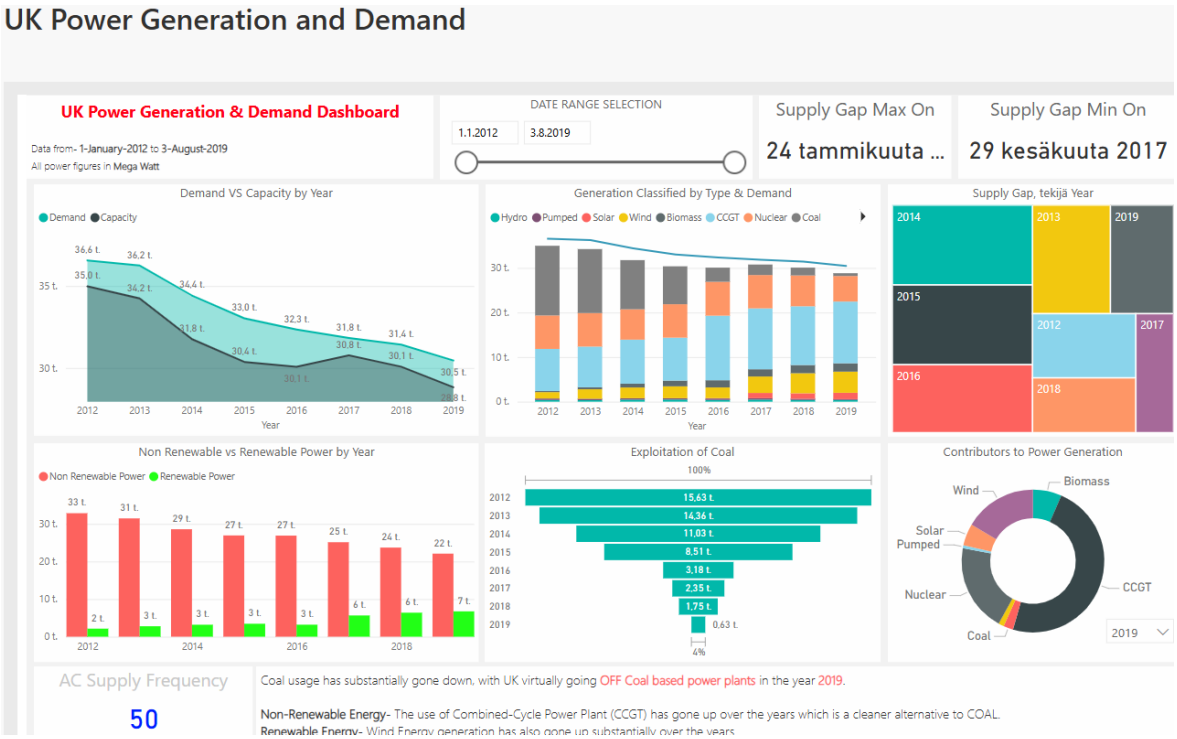

KUVA 4: Power BI (Microsoft 2024)

4. Toimeenpano ja seuranta

Tulosten käytäntöön vieminen on prosessin viimeinen ja usein liiketoiminnan kannalta tärkein vaihe. Analyysitulosten pohjalta organisaatiot voivat tehdä muun muassa päätöksiä,

jotka parantavat operatiivista tehokkuutta tai asiakastyytyväisyyttä. Tämä vaihe sisältää päätösten tekemisen analyysitulosten perusteella, ratkaisujen implementoinnin, kuten uusien strategioiden tai toimintatapojen käyttöönoton ja seurannan seuraamalla esimerkiksi analyysitulosten vaikutusta KPI-mittareihin ja arvioidaan, onko tuloksia tarvetta päivittää. Toimeenpanon onnistuminen riippuu paitsi analyysin laadusta, myös organisaation kyvystä muuttaa toimintatapojaan tulosten perusteella. (Davenport, 2017).

Data-analytiikkaan liittyy useita haasteita, jotka organisaatioiden on ratkaistava, jotta ne voivat hyödyntää analytiikan täyden potentiaalin. Data-analytiikan pohjana on laadukas data, mutta monet organisaatiot kohtaavat ongelmia datan epätäydellisyyden, epäjohdonmukaisuuden tai hajanaisuuden vuoksi. Erityisesti monimutkaisissa organisaatioissa datan kerääminen eri lähteistä ja sen yhdistäminen yhtenäiseksi kokonaisuudeksi on haastavaa (Han et al., 2011). Haasteena on myös esimerkiksi datan eettinen käyttö, tietoturva ja algoritmien läpinäkyvyys. Suurten tietomäärien kerääminen ja analysointi herättää kysymyksiä yksityisyyden suojaan liittyen. Esimerkiksi Euroopan unionin yleinen tietosuoja-asetus (GDPR) asettaa tiukat säännöt henkilötietojen käsittelylle. Datan anonymisointi ja pseudonymisointi ovat ratkaisuja, mutta ne eivät aina ole täydellisiä. Algoritmit, joita käytetään analytiikassa, voivat sisältää piilevää puolueellisuutta. Tämä voi johtaa epäoikeudenmukaisiin päätöksiin ja lisäksi on olemassa vaara, että dataa käytetään väärin ilman asianmukaista valvontaa. Tekoälypohjaisten analyysityökalujen, kuten syväoppimisen, kohdalla mallien "mustan laatikon" luonne vaikeuttaa päätösten ymmärrettävyyttä ja tämä voi heikentää luottamusta analyysin tuloksiin (Zarsky, 2016). Data-analytiikka edellyttää teknologista infrastruktuuria ja asiantuntemusta. Resurssien ja osaamisen puute on todellista nopeasti muuttuvassa ja kehittyvässä maailmassa ja monet organisaatiot kohtaavat vaikeuksia löytää osaavia data-analyytikkoja, mikä hidastaa analytiikan käyttöönottoa laajemmin (Davenport, 2017).

Tulevaisuudessa tekoälypohjaiset analytiikkaratkaisut tulevat yleistymään, mikä mahdollistaa entistä tarkemmat ja nopeammat analyysit. IoT-teknologian ja nopeutuvan datan prosessoinnin ansiosta reaaliaikainen analytiikka tulee yhä tärkeämmäksi erityisesti teollisuudessa, logistiikassa ja vähittäiskaupassa. Tämä mahdollistaa välittömän päätöksenteon ja toimintojen optimoinnin (Russell, 2020). Koneoppimisen ja tekoälyn integrointi data-analytiikkaan mahdollistaa entistä tarkempia ja nopeampia analyysejä. Esimerkiksi syväoppimismenetelmiä käytetään yhä enemmän monimutkaisten mallien rakentamiseen ja datan ennustamiseen (Goodfellow et al., 2016).

Johtopäätöksenä data-analytiikka on keskeinen tekijä tulevaisuuden päätöksenteossa ja innovaatioissa. Sen avulla yritykset voivat tunnistaa uusia mahdollisuuksia, optimoida prosessejaan ja vastata asiakkaiden tarpeisiin paremmin. On kuitenkin tärkeää kehittää menetelmiä, jotka takaavat datan eettisen ja vastuullisen käytön. Vaikka haasteita on, teknologian ja osaamisen jatkuva kehittyminen tarjoaa mahdollisuuksia näiden ongelmien voittamiseen. Tulevaisuudessa organisaatiot, jotka pystyvät yhdistämään teknologiset työkalut vastuullisiin toimintamalleihin, saavuttavat merkittävää kilpailuetua.

2.3 Kunnossapito

Tässä luvussa käydään läpi kunnossapidon perusteita ja sitä mikä se on ja millainen merkitys sillä on suurissa tuotantolaitoksissa. Tämä on oleellinen aihealue tutkimuksen kannalta, koska suurimmat potentiaaliset datan hyödyt energiayhtiön tuotanto-liiketoiminnassa löytyvät todennäköisesti kunnossapidon alueelta. Kunnossapitoa on ollut olemassa niin kauan kuin tuotantoakin on ollut ja kunnossapidon osuus tuotantolaitoksen käyttökustannuksista on merkittävä (Mobley 2005). Kunnossapito sisältää koneiden ja laitteiden huollon ja kunnossapidon, jotta laitteet pystyisivät suoriutumaan niille osoitetuista tehtävistä. Tässä luvussa kerron mitä kunnossapito on ja mitä eri lajeja sillä on.

Promaint ry on riippumaton ja voittoa tavoittelematon kunnossapitoyhdistys. Promaint on omaisuudenhallinnan, tuotantotehokkuuden ja kunnossapidon asiantuntijaverkosto. Kunnossapitoyhdistys Promaint ry:n mukaan kunnossapito on yleiskäsite, joka kattaa tuotantoon liittyvien koneiden, laitteiden ja tuotantokiinteistöjen toimintakunnon ylläpidon. Kattoterminä kunnossapito on huomattavasti laajemmalle levittyvä käsite kuin huolto. Ajattelutapa liittyy omien toimien ohella kunnossapitoon oleellisesti. Kunnossapitoa voidaan selvin perustein pitää omana tieteenalanaan ja sen merkitys kasvaa jatkuvasti. Kunnossapitoyhdistys ry määrittelee kunnossapidon teknisten, hallinnollisten ja johtamiseen liittyvien toimenpiteiden kokonaisuudeksi, jonka tavoitteena on säilyttää prosessi toimintakuntoisena tai palauttaa se toimintakuntoon, jotta se voi täyttää vaaditut tehtävänsä koko elinkaarensa ajan. Laitoksen suunnittelu- ja hankintavaiheessa määritetään käytettävyyden ja kunnossapidettävyyden perusta, jolloin kunnossapidon rooli alkaa muotoutua. Laitoksen toiminnan aikana kunnossapito painottuu ehkäiseviin ja parantaviin toimenpiteisiin, häiriöiden korjaamiseen sekä kunnossapitovarmuuden ylläpitoon ja kehittämiseen. (Promaint 2024)

Tuotantolaitosten kunnossapidon tarkoituksena on pitää tuotanto käynnissä ilman tarpeettomia keskeytyksiä laitteiden vikojen vuoksi ja tehdä se mahdollisimman kustannustehokkaasti. Kunnossapito jaetaan yleisesti korkeimmalla tasolla suunniteltuun ja suunnittelemattomaan kunnossapitoon. Suunniteltu kunnossapito sisältää ehkäisevän, kunnostavan ja parantavan kunnossapidon. Ehkäisevään kunnossapitoon sisältyy jaksotetut ja aikataulutetut suunnitellut huollot ja korjaukset. Siihen kuuluu myös ennakoivat huolto- ja korjaustoimenpiteet laitteille, joissa on havaittavissa vaikkapa kulumisen merkkejä kunnonvalvonnan perusteella. Ennakoivaa kunnossapitoa tehdään laitteille, jotka välttämättä eivät ole vielä vikaantumassa, mutta vaikkapa kunnonvalvontamittausten tai muun datan perusteella lähestyvät sitä ja vaativat kunnossapitoa täydellisen vikaantumisen estämiseksi. Suunnittelematon kunnossapito tarkoittaa kunnossapitoa, jossa laitteisto on yllättäen vikaantunut jollain tapaa tai hajonnut yllättäen. Kunnossapito on liikkunut koko ajan enemmän suunniteltuun kunnossapitoon poispäin pelkästä hajonneiden laitteiden korjaamisesta tai korvaamisesta. (Duffuaa, 2015)

Mikkonen et al (2009) kirjoittavat, että kunnossapito on laaja käsite, jolle ei ole yhtä yksiselitteistä määritelmää, vaan sitä voidaan tarkastella monista eri näkökulmista. Nykyään kunnossapito on olennainen osa tuottavan yrityksen toimintaa. Sen ensisijaisena tehtävänä on pitää laitteet käyttökunnossa siten, että tuotanto voi toimia mahdollisimman tehokkaasti. Kunnossapito on yleisesti yrityksen suurimpia kuluja heti pääoma- ja raaka-ainekustannusten jälkeen. Monesti yritykset arvioivatkin kunnossapidon taloudellista merkitystä lähinnä kustannusten tai kunnossapidosta johtuvien tuotannonmenetysten perustella. Aiemmin kunnossapito miellettiin ensisijaisesti rikkoutuneiden laitteiden ja komponenttien korjaamiseksi. Vaikka tämä on yhä osa kunnossapitoa, se ei ole enää sen päätarkoitus. Nykyään kunnossapitoa ei nähdä pelkästään kustannuseränä, vaan se on keskeinen tekijä, jolla varmistetaan tuotantolaitoksen kilpailukyky ja pitkäjänteinen toiminta. (Mikkonen et al., 2009)

Alla kuva kunnossapidon tasoista Mikkosen et al. (2009) mukaan. Kunnossapidon tasot lähtevät korjaavasta kunnossapidosta ja nousevat ylöspäin aina jokaisella portaalla kunnossapito taso on hieman edellistä parempi ja kehittyneempi.

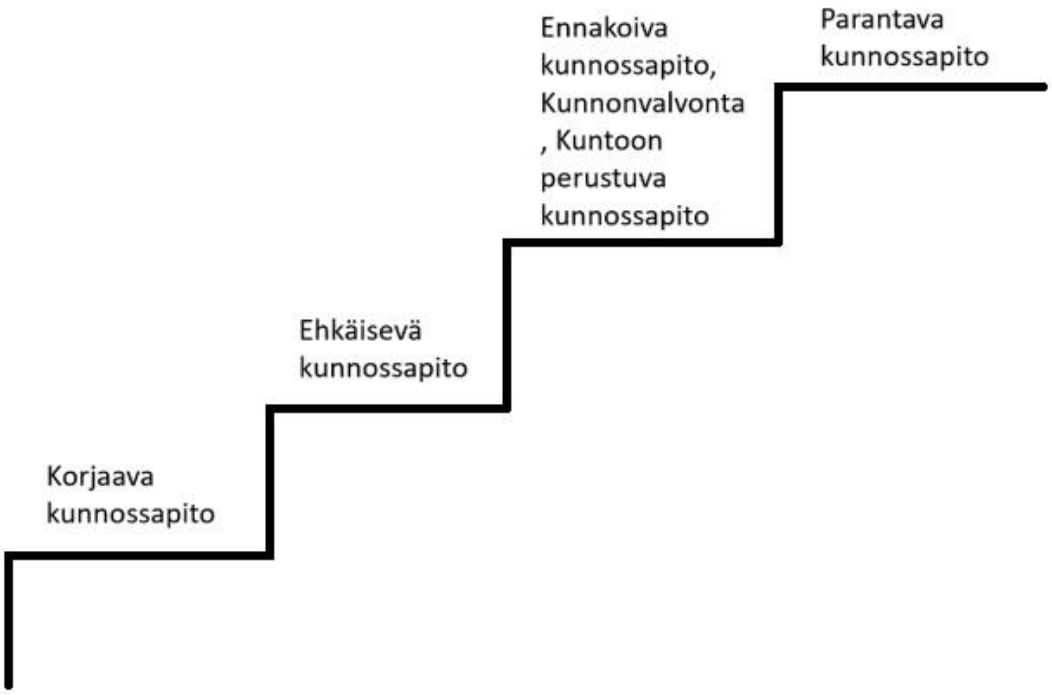

KUVA 5: Kunnossapidon tasot (Mikkonen et al., 2009)

Kunnossapito voidaan myös jaotella eri lajeihin PSK:n mukaan. Standardi PSK 7501 jakaa kunnossapidon eri lajeihin sen mukaan ovatko ne suunniteltua kunnossapitoa vai suunnitte-lematonta korjausta. Alla kuva kunnossapitolajeista PSK mukaisesti.

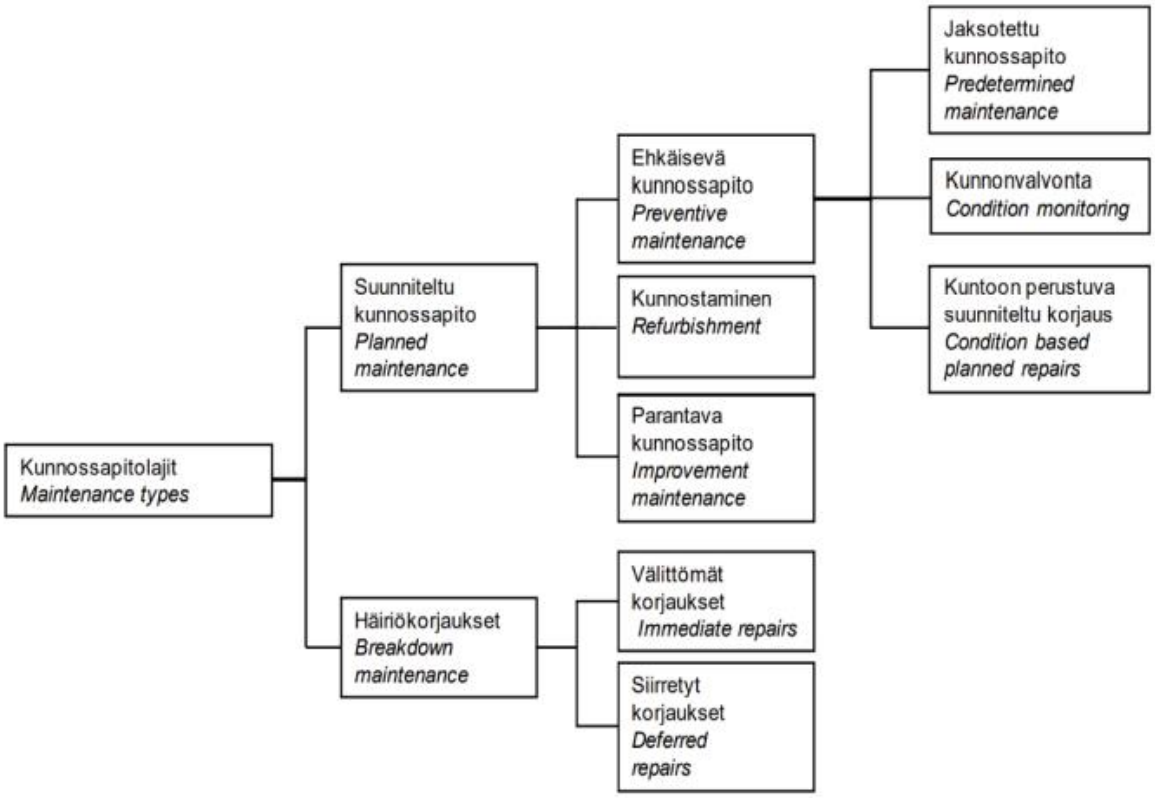

KUVA 6: Kunnossapitolajit (PSK 7501:2010)

Nykyajan kunnossapito ei enää perustu pelkästään nopeisiin korjauksiin, vaan tietoon ja osaamiseen pohjautuvaan tuotanto-omaisuuden hallintaan. Tämä hallinta on yritykselle sijoitus, jonka tuotto syntyy tuotantoprosessin optimaalisesta ja tarkasti hallitusta toiminnasta. Mitä tehokkaammin tuotanto-omaisuutta hallitaan, sitä kannattavampaa tuotanto on. Tämä lisää tuotantoprosessiin sijoitetun pääoman tuottoa ja parantaa yrityksen kilpailukykyä. Siirryttäessä reagoivasta ja korjaavasta kunnossapidosta ennakoivaan ja vikaantumista ehkäisevään tuotanto-omaisuuden hallintaan tarvitaan jatkuvasti uutta ja ajankohtaista tietoa. Tavoitteena ei ole enää pelkästään korjausten nopeus, vaan vikojen ennaltaehkäisy ja kunnossapidon tarpeen vähentäminen. Koska kunnossapito on usein yksi yrityksen merkittävimmistä palvelun tuottajista, se muodostaa myös huomattavan kustannuserän. Kunnossapidon luonne edellyttää hallittua, kontrolloitua ja määrätietoista johtamismallia. Ilman tätä on vaarana, että kunnossapito muuttuu yrityksen suurimmaksi hallitsemattomaksi kustannukseksi. (Järviö, 2017)

Tässä työssä ei ole tarvetta kertoa tarkemmin yleisesti kunnossapidosta ja sen toteuttamisesta. Ennakoiva kunnossapito on se tapa millä dataa pystyy uudella tapaa hyödyntämään

kunnossapidon saralla, joten seuraavassa luvussa kerrotaan lisää ennakoivasta kunnossapidosta (predictive maintenance)

2.3.1 Ennakoiva kunnossapito

Tässä luvussa kerrotaan ennakoivasta kunnossapidosta (Predictive Maintenance, PdM).

Ennakoivalla kunnossapidolla tarkoitetaan kunnossapitokäytäntöä, jossa prosessilaitteistoja huolletaan käyttämällä erilaisia menetelmiä, jotka estävät tuotantokatkoksia vikaantumisten tai muiden syiden vuoksi. Monissa teollisuuden tuotantolaitoksissa on edelleen virheellinen käsitys, että laitteet tulisi korjata vasta kun ne rikkoutuvat, eikä laitteiden vikaantumisen ehkäisemiseksi tarvitse tehdä toimenpiteitä laitteiden vikojen välillä. Tämä ajattelutapa on kuitenkin vanhentunut, ja siitä tulisi luopua, jos tavoitteena on aidosti kustannustehokas ja luotettavuutta parantava kunnossapito. Nykymaailman kovassa kilpailutilanteessa tuotantolaitokset toimivat usein maksimikapasiteetillaan, minkä vuoksi ennakoivan kunnossapidon (PdM) roolia kannattaa kasvattaa tuotantolaitoksissa. Hyvin ja kattavasti suunnitellun ennaltaehkäisevän kunnossapidon tavoitteena on välttää laitteiden vikaantuminen tai ainakin vähentää niitä, erityisesti kriittisten laitteiden osalta. Tämä tehdään tuotantoprosessin luotettavuuden parantamiseksi ja jatkuvan tuotannon varmistamiseksi ilman tarpeettomia keskeytyksiä. Ennakoivan kunnossapidon hyödyntäminen mahdollistaa tarpeettomien ennaltaehkäisevien kunnossapitotoimenpiteiden välttämisen, mikä luo merkittävän mahdollisuuden vähentää kunnossapitokustannuksia (Gross, 2008).

Tuotantojärjestelmien laitteiden ja komponenttien kulumisen ennustamiseen voidaan käyttää erilaisia lähestymistapoja. Näitä ovat fysikaalisiin periaatteisiin perustuvat tieto-ohjatut menetelmät sekä dataan pohjautuvat lähestymistavat. Fysikaaliset mallit soveltuvat erityisesti tilanteisiin, joissa kulumisprofiili voidaan mallintaa yksinkertaisesti fysiikan avulla. Näiden mallien etuna on niiden tarkkuus, mutta niiden kehittäminen ja käyttöönotto voi olla monimutkaista ja kallista, etenkin silloin, kun järjestelmä sisältää suuren määrän muuttujia, kuten monimutkaisissa koneissa tai vaihtelevissa ympäristöolosuhteissa. Datalähtöiset mallit tarjoavat vaihtoehdon tieto-ohjatuille järjestelmille, kun käytettävissä on riittävä määrä dataa. Kunnonvalvontateknologian kehittyminen on mahdollistanut suurempien datamäärien keräämisen, mikä on tehnyt datalähtöisistä malleista luotettavia ja käytännöllisiä ennakoivan kunnossapidon toteutuksessa. Näiden mallien merkittävä etu on, että ne eivät ole

sidoksissa järjestelmän fysikaaliseen kulumisprofiiliin, mikä tekee niistä helposti sovellettavia erilaisiin tilanteisiin. Nykyään saatavilla on useita datalähtöisiä malleja, jotka hyödyntävät koneoppimisen algoritmeja ja joita voidaan käyttää ennakoivan kunnossapidon sovelluksissa. Näiden mallien helppokäyttöisyys ja joustavuus ovat tehneet datalähtöisistä menetelmistä ensisijaisen vaihtoehdon laitteiden kulumisen ja vikaantumisen ennustamiseen. (Dong et al., 2019)

Ennakoiva kunnossapito voi olla tehokasta vain, jos laitteiden kunnosta on saatavilla jatkuvaa tietoa. Esimerkiksi nykyisin useimpiin tuulivoimaloihin on asennettu antureita, jotka seuraavat järjestelmän eri suorituskykymittareita, kuten värähtelyä, lämpötilaa, nopeutta, jännitettä, virtaa, öljynpainetta, vääntömomenttia, kiihtyvyyttä jne. Nämä anturit ovat olleet merkittävässä roolissa vähentämässä suunnittelematonta seisokkiaikaa ja parantamassa tuulivoimaloiden toiminta- ja kunnossapito-ominaisuuksia (Zhang, 2015).

Edellisessä kappaleessa kuvatut anturit ovat kunnonvalvontaa varten. Kunnonvalvonta on prosessi, jossa seurataan parametreja, jotka antavat tietoa komponentin tai järjestelmän kunnon tai suorituskyvyn muutoksista. Kunnonvalvontaa voidaan toteuttaa reaaliajassa jatkuvan toiminnan tukemiseksi. Kunnonvalvonta kattaa kaikki toimenpiteet datan keruusta sensoreilla aina valvotun komponentin kunnon arviointiin. Ensimmäiseksi täytyy valita mitkä laitteet vaativat tai ovat kunnonvalvonnan arvoisia. Isoissa tuotantolaitoksissa kriittiset laitteet valitaan yleensä kunnonvalvonnan piiriin. Laitteeseen liitetään tarkoituksenmukainen sensori, jonka ensisijainen tehtävä on kerätä dataa laitteesta. Datan keruulaitteet sisältävät yleensä mittalaitteita, kuten lämpömittareita tai kiihtyvyysantureita. Kunnonvalvonnassa on käytetty useita mittaustekniikoita, joiden tavoitteena on tarjota tietoa valvottavan komponentin tai järjestelmän todellisesta kunnosta. Yksinkertaisin kunnonvalvonnan muoto ovat rutiinitarkastukset, joita laitoksen henkilöstö suorittaa paikallisten poikkeavuuksien, kuten melun, hajun tai värähtelyn, havaitsemiseksi käynnissä olevassa laitteessa. Vaikka kokeneen henkilöstön suorittamien tarkastusten merkitystä ei voida vähätellä, tarvitaan tarkempia, automatisoituja ja älykkäitä kunnonvalvontajärjestelmiä, erityisesti hajautetussa tuotannossa, jossa laitteet ja tuotantolaitokset voivat olla isojen etäisyyksien päässä. Yleisimpiä kunnonvalvonnan mittaustekniikoita ovat muun muassa värähtelymittaus ja voiteluaineanalyysi. Värähtelymittaus on yleisimmin käytetty menetelmä kunnonvalvonnassa ja erityisen tehokas dynaamisten ilmiöiden tutkimisessa. Se soveltuu erinomaisesti teollisuuden pyörivien

koneiden ja laitteiden kunnonvalvontaan, kuten laakereiden kulumisen ja akselien tasapainotuksen tarkkailuun. Mittauksen perusidea on, että dataa kerätään laitteiden ollessa toiminnassa, ilman että se häiritsee tuotantoprosessia. (Marwala, 2012)

Ennakoiva kunnossapito (PdM) on yksi keskeinen tulos, joka voidaan saada kerätystä sensoridatasta. Tyypillisillä teollisuuden ja prosessilaitosten kunnossapitomenetelmillä, kuten käyttö loppuun asti -kunnossapidolla (run-to-failure) ja aikataulutetulla kunnossapidolla, on merkittäviä puutteina joko korkeita kustannuksia tuotantolaitosten seisokkien vuoksi tai korkeita kustannuksia tarpeettomasta kunnossapidosta. Ennakoivan kunnossapidon tavoitteena on parantaa tuotannon ja valmistusprosessien kokonaistehokkuutta hyödyntämällä eri laitteiden todellisia toimintakuntoja koko tuotannon toiminnan optimointiin. Kunnossapitotoimenpiteiden ajoittaminen tarpeen mukaan parantaa tuottavuutta minimoimalla seisokkiajan ja kunnossapitokustannukset. (Mobley, 2005)

Carvalho et al. (2019) kertovat tutkimuksessaan ”A systematic literature review of machine learning methods applied to predictive maintenance” ennakoivan kunnossapidon perustuvan laitteiden jatkuvaan tilan seurantaan ja analysointiin. PdM-strategioiden toteutus koneoppimisen avulla voi merkittävästi parantaa kunnossapidon tehokkuutta. Tämä johtaa kustannussäästöihin, laitteiden käyttöajan maksimointiin ja turvallisuuden parantamiseen. Tämä strategia mahdollistaa kunnossapidon toteuttamisen vain, kun se on tarpeen. PdM-strategiat edellyttävät kuitenkin laadukasta historiallista ja reaaliaikaista dataa sekä asiantuntemusta koneoppimisen soveltamisessa. Ennakoiva kunnossapito on erityisen tärkeä teollisuudessa, jossa koneiden toimintakunto suoraan vaikuttaa tuotannon tehokkuuteen ja jatkuvuuteen. Kriittisiksi määriteltyihin laitteisiin tulee asentaa tarvittavat mittaavat sensorit, jotta dataa on saatavilla data-analyysien tueksi. Yhtiöiden ennakoiva kunnossapito toiminta kannattaa kehittää hyödyntämään reaaliaikaista dataa ja koneoppimista vikaantumisen ennustamisessa ja näin auttaa välttämään odottamattomat seisokit. PdM myös mahdollistaa resurssien tehokkaan käytön, turvallisuuden parantamisen ja tuotantokustannusten alentamisen. (Carvalho et al. 2019)

Seuraavassa luvussa käsitellään data-analytiikkaa energia-alalla.

3 Data-analytiikka energia-alalla

Tässä luvussa esittelen aiempaa empiiristä tutkimusta tältä aihealueelta ja asiantuntijoiden haastatteluja. Tutkimusalue on täytynyt laajentaa koko energia-alaan, koska samankaltaisesta tuotanto-liiketoiminnasta, kuin case-yhtiössä, ei löydy tutkimusta. Yleisestikin aiempaa tieteellistä tutkimusta alalta oli vaikea löytää ja tästä syystä oli turvauduttava myös asiantuntijahaastatteluihin. Näistä lähteistä saatuja tietoja yhdistelen tutkimustyön lopussa case-yhtiön liiketoimintaan. Tässä käytän apuna omaa empiiristä tutkimustani case-yhtiöstä. jotta saa konkreettisia esimerkkejä millä tavoin dataa voi hyödyntää saavuttaen taloudellisia hyötyjä.

3.1 Tutkimuksia aihealueesta

Tässä luvussa esittelen useita case-tutkimuksia aihealueesta. Nämä tutkimukset avaavat ymmärrystä aihealueesta ja tarjoavat konkreettisia esimerkkejä hyödyistä, jota data-analytiikalla voi energia-alalla saavuttaa. Olen käynyt tätä tutkimusta varten lukemattoman määrän tutkimusartikkeleita ja muita tutkimustöitä läpi. Tähän lukuun olen tuonut esille ne, joiden olen arvioinut tuovan eniten lisäarvoa tälle tutkimustyölle. Näitä tutkimuksia olen etsinyt Scopus tiivistelmä- ja viittaustietokannasta, joka kattaa muun muassa tuhansia tieteellisiä artikkeleita ja lehtiä lääketieteen, teknologian, taiteiden ja humanististen tieteiden, yhteiskuntatieteiden sekä luonnontieteen aloilta ja Lappeenrannan yliopiston LUT-tiedekirjaston hakupalvelu LUT Primoa. Esittelen nämä valitut tutkimukset pääpiirteittäin niiltä osin, jotka ovat oleellisia oman tutkimukseni kannalta ja analysoin niiden antia. Jokaisen kappaleen alussa kerrotaan lähdeviittauksin tutkimus, jota siinä käsitellään ja alkuperäislähde löytyy lähdeluettelosta. Näin tämän tavan järkevimmäksi tavaksi toteuttaa tutkimuksista kertominen, koska jokaiselle tässä esille tuodulle tapaustutkimukselle oman alaluvun alaluvun tekeminen olisi ollut jo sisällysluettelonkin kannalta ikävää.

Vaara et al (2014) ovat tutkineet avoimen säädatan käyttöä tuulivoimaloiden tuotantoennustemallin luomisessa artikkelissaan ”Wind turbine sensor data analysis and production forecast”. Artikkeli on julkaistu ”UKSim-AMSS 8th European Modelling Symposium on Computer Modelling and Simulation” julkaisussa. Tässä tutkimuksessa käytettiin suomalaisen energiayhtiön ja Ilmatieteen laitoksen toimittamia tuulivoima- ja säätietoja

tutkimusmateriaalina. Ilmatieteen laitos tarjoaa tarkkaa ja erittäin kattavaa avointa dataa osoitteessa https://ilmatieteenlaitos.fi/avoin-data. Tutkimuksessa selvitettiin tärkeimmät tekijät, jotka vaikuttivat tuulivoimalan sähköntuotannon tehokkuuteen. Mallissa merkittävimmäksi tekijäksi havaittiin tuulennopeus, sillä sen vaikutus oli eksponentiaalinen ainoana muuttujana. Toinen merkittävä tekijä ennustemallin luomisessa oli lämpötila. Vaikka sen vaikutus ei ollut yhtä voimakas kuin tuulennopeuden, se oli silti huomattava. Nämä havainnot vahvistettiin myös tilastollisen tulkinnan avulla. Kohteena olevalle tuulivoimalalle kehitettiin näiden tekijöiden pohjalta räätälöity ennustemalli. Tulokset, erityisesti ennustemalli, nähtiin merkittävinä, ja niitä käytettiin energiayhtiön tuotantoennusteohjelman ensimmäisen version luomisessa.

Mikko Nykyrin (2018) diplomityö "Data analytics for predictive maintenance in a pulp mill - case electric motors" havainnollistaa data-analytiikan ja koneoppimisen mahdollisuuksia teollisessa ympäristössä. Data-analytiikan mahdollisuuksia tutkittiin luomalla koneoppimismalleja. Diplomityössä vahvistettiin data-analytiikan ja koneoppimisen mahdollisuudet sellutehtaan ympäristössä mallien avulla, jotka keskittyivät ylikuormitustilanteiden havaitsemiseen ja ennustamiseen. Kehitetyt koneoppimismallit pystyivät ennustamaan sähkömoottoreiden ylikuormitustilanteita tarkkuudella, joka ylsi jopa 98,85 prosenttiin. Tämä tehtiin hyödyntämällä historiallista dataa Metso DNA-automaatiojärjestelmästä (Nykyään Valmet DNA) ja kehittämällä ennakoivia malleja Python-ohjelmointikielellä sekä Microsoft Azure -pilvipalvelussa. Koneoppimismallit tarjoavat mahdollisuuden vähentää odottamattomia tuotantokatkoja ja optimoida huoltotoimia. Diplomityön tärkeimpinä tuloksina ja johtopäätöksinä oli, että kerätty data voidaan jalostaa koneoppimisella ja data-analytiikalla uudeksi tiedoksi. Automaatiodatan pohjalta voidaan luoda koneoppimismalleja, jotka pystyvät tekemään ennusteita ja tuottamaan uutta tietoa operaattoreille. Mallien luomiseen tarvittava data on jo olemassa, koska automaatiojärjestelmä tallentaa tätä tietoa historiatietoina. Tutkimuksessa ehdotettiin IoT-järjestelmän rakentamista koko tehtaanlaajuiseksi ratkaisuksi, joka yhdistäisi automaatiojärjestelmien datan, koneoppimismallit ja reaaliaikaiset ennusteet. Tämä järjestelmä mahdollistaisi operaattoreille nopeamman päätöksenteon ja parannetun näkyvyyden tehtaan toimintaan. Yhdistämällä data kaikista tietolähteistä voidaan rakentaa koko tehtaan kattava IoT-järjestelmä. Tämä järjestelmä voidaan toteuttaa pilvipalvelussa, esimerkiksi Microsoft Azuren avulla, hyödyntäen pilvipalvelun tarjoamia työkaluja. Järjestelmän kehittäminen vaatii kuitenkin laaja-alaista osaamista data-analytiikasta ja prosessitekniikasta, sillä järjestelmä edellyttää kaikkien prosessilaitteiden mallinnusta ja tietolähteiden

yhdistämistä. Diplomityössä lopullisena tulevaisuuden tavoitteena oli yhdistää kaikki data yhteen järjestelmään, josta kaikki tarvittavat toiminnot ja tiedot ovat nähtävissä, mukaan lukien sensoridata ja ennakoivan kunnossapidon ennusteet koko tehtaan laajuisesti. Järjestelmän avulla voidaan tarkkailla tehtaan toimintaa kokonaisuutena ja ennustaa vikatilanteita, mikä lisää tehtaan tuotantotehokkuutta. Tulevaisuuden näkymänä tutkimus esitti myös digitaalisen kaksosen (digital twin) konseptin, jossa koko tehdasmalli olisi virtuaalisesti edustettuna. Tämä mahdollistaisi simulaatioiden, optimoinnin ja tuotannon tehostamisen virtuaaliympäristössä. Tutkimus osoitti, että datan käsittelyyn liittyvät manuaaliset prosessit, kuten Excel-pohjainen datan käsittely, ovat tehottomia. Lisäksi järjestelmien, kuten Metso DNA:n, SAP:n ja Azure-pilvipalvelun, integroinnissa on suuria haasteita. Näiden ongelmien ratkaisemiseksi tarvitaan korkeampia kaistanopeuksia ja parempia API-ratkaisuja. Tutkimus vahvistaa, että data-analytiikalla ja koneoppimisella on merkittävä potentiaali sellutehtaiden toimintojen optimoinnissa, erityisesti kunnossapidon ja tuotannonhallinnan näkökulmasta. Se myös tarjoaa lähtökohdan IoT-pohjaisen järjestelmän laajentamiselle ja hyödyntämiselle teollisuudessa. Tekniikka sellutehtaan toiminnan seuraamiseen ja ennustamiseen on jo olemassa.

Ahmed et al. (2023) tutkivat artikkelissaan ”A Smart-Anomaly-Detection System for Industrial Machines Based on Feature Autoencoder and Deep Learning” älykkään anomaliantunnistusjärjestelmän kehittämistä teollisuuden koneille, perustuen ominaisuuksien autoenkooderiin ja syväoppimiseen. Sen tavoitteena on parantaa koneiden kunnonvalvontaa ja vikojen havaitsemista erityisesti vaihdelaatikoiden osalta. Ominaisuuksien autoenkooderi on erityinen syväoppimismalli, joka on suunniteltu vähentämään datan ulottuvuuksia ja tunnistamaan merkityksellisiä piirteitä (ominaisuuksia) monimutkaisesta datasta. Autoenkooderit ovat erityisen hyödyllisiä anomaliantunnistuksessa, koska ne pystyvät oppimaan datan "terveiden" (normaalien) tilojen piirteet ilman tarvetta manuaaliselle ominaisuuksien suunnittelulle. Tutkimus hyödyntää julkisesti saatavilla olevaa vaihdelaatikoiden värähtelydatan tietokantaa, joka sisältää tietoja sekä terveistä että viallisen hammaspyörän sisältävistä vaihdelaatikoista. Tutkimuksessa kehitettiin kuusikerroksinen autoenkooderiin perustuva syväoppimismalli, joka osoitti korkean tarkkuuden (91 %) anomaliantunnistuksessa. Malli analysoi värähtelysignaaleja ja tunnisti poikkeavuuksia tehokkaasti ilman, että tiedot oli ennalta merkitty anomaalisiksi. Aika- ja taajuusanalyysien avulla saatiin tarkempaa tietoa värähtelydatan rakenteesta ja poikkeavuuksista. Fourier-muunnosten avulla tunnistettiin eroja taajuuskomponenteissa terveiden ja viallisten vaihdelaatikoiden välillä. Kehitetty malli osoitti parempaa

tarkkuutta verrattuna perinteisiin menetelmiin, kuten SVM:ään (Support vector machine), KNN:ään (k-nearest neighbor method) ja satunnaismetsiin. Autoenkooderin kyky vähentää datan ulottuvuuksia osoittautui tehokkaaksi korkealuokkaisen datan analysoinnissa. Malli pystyi myös havaitsemaan uusia poikkeavuuksia, joita ei ollut mukana harjoitteluvaiheessa. Johtopäätöksenä tutkimus vahvisti syväoppimismallien käyttökelpoisuuden teollisuuden anomaliantunnistuksessa, erityisesti vaihdelaatikoiden vikatilanteiden analysoinnissa. Tutkimuksessa ehdotettiin laajentamaan mallin käyttöä muihin teollisuuden koneisiin ja tarkastelemaan sen sovellettavuutta muihin datalähteisiin. Tutkimus osoittaa, että syväoppimiseen perustuvat anomaliantunnistusjärjestelmät voivat merkittävästi parantaa teollisuuden koneiden kunnossapidon tehokkuutta ja luotettavuutta, tarjoten samalla skaalautuvia ratkaisuja tulevaisuuden tarpeisiin. (Ahmed et al. 2023)

Juha Juseliuksen (2018) diplomityö "Advanced Condition Monitoring Methods in Thermal Power Plants" havainnollistaa kunnonvalvontadatan mahdollisuuksia. Työssä keskityttiin erityisesti neuroverkkopohjaisten mallien soveltuvuuteen voimalaitosympäristössä. Tapaustutkimuksessa arvioitiin Intelligent Health Monitor-nimistä kaupallista kunnonvalvontaohjelmistoa tapaustutkimuksessa, jossa seurataan kattilan kohonnutta savukaasulämpötilaa. Työssä luotiin ja arvioitiin 96 mallia eri koulutusparametreilla terveessä tilassa tapahtuvan valvonnan ja vikojen havaitsemisen aikana. Tulokset osoittivat, että luotettavia malleja, joilla on hyvä vikojen havaitsemiskyky, voidaan kouluttaa automaattisesti valituilla syöttömuuttujilla, jotka perustuvat pääkomponenttianalyysiin ja korrelaatioanalyysiin. Tulokset osoittivat myös suurta vaihtelua ja korostivat mallien validoinnin tärkeyttä. Työ osoitti, että neuroverkkopohjainen kunnonvalvonta voi parantaa voimalaitoksen tehokkuutta ja vähentää tarpeettomia kunnossapitotoimia. Mallit pystyvät havaitsemaan poikkeavuuksia automaattisesti ilman ihmisen jatkuvaa valvontaa. Tutkimuksessa painotettiin tarvetta jatkotutkimukselle, jossa neuroverkkopohjaista valvontaa sovellettaisiin laajemmin erilaisiin prosessiparametreihin. Lisäksi ehdotettiin, että laitoksen laajuisen kunnonvalvontajärjestelmän kehittäminen edellyttää kattavaa osaamista sekä data-analytiikasta, että prosessitekniikasta.

De Fabritiis et al. (2024) tutkimuksessaan “A Self-supervised Learning Approach for Anomaly Detection in Rotating Machinery” käsittelivät uuden menetelmän kehittämistä pyörivien koneiden vikojen varhaiseen havaitsemiseen värähtelydatan avulla. Tutkimuksessa luotiin tekoälyyn (AI) itseohjautuvaa oppimista (self-supervised learning) hyödyntävä syväoppimismalli, joka soveltuu erityisesti anomaliantunnistukseen pyörivissä koneissa.

Menetelmä hyödyntää itseohjautuvaa syväoppimista ja syklisen konsistenssin oppimista tehokkaiden ominaisuuksien erotteluun merkityksellisistä signaaleista ilman tarvetta merkitä dataa manuaalisesti. Tämä menetelmä testattiin julkisesti saatavilla olevalla IMS-laakeritietokannalla, joka sisältää värähtelydataa laakereista, joita käytettiin kiihdytetyissä elinkaaritesteissä. Tutkimuksessa datan manuaalisilla merkinnöillä (manual data labeling) viitataan prosessiin, jossa ihminen analysoi ja luokittelee kerättyä dataa antamalla sille kontekstiin liittyviä tunnisteita, kuten "terve" tai "viallinen". Tämä tarkoittaa, että asiantuntija käy läpi raakadatan (esimerkiksi värähtelysignaalit) ja määrittää, mitkä datan osat liittyvät tiettyihin koneen tiloihin, kuten normaaliin toimintaan, poikkeavuuksiin tai vikoihin. Manuaaliset merkinnät ovat olennaisia monille koneoppimismalleille, erityisesti ohjatun oppimisen (supervised learning) menetelmille, joissa mallin koulutus vaatii suuria määriä merkittyä dataa (eli dataa, jossa jokaisella esimerkillä on tunnettu tila tai luokka). Merkintäprosessi tarjoaa mallille opetusdataa, jonka avulla se oppii erottamaan esimerkiksi terveet ja vialliset tilat. Datan merkintä on iso haaste, koska se vaatii huomattavat asiantuntijaresurssit, erityisesti kun dataa on kerätty suuria määriä (esim. jatkuvasti toimivista antureista). Ihmisen tekemät arviot voivat sisältää virheitä tai vaihdella asiantuntijan mukaan, mikä voi johtaa epäluotettavuuteen. Usein myös dataa on vain vähän tiloista, joissa kone on viallinen, koska laitteet pyritään pitämään mahdollisimman pitkään terveinä. Tutkimuksessa itseohjautuva oppiminen (self-supervised learning) tarjoaa ratkaisun näihin haasteisiin, koska se ei vaadi manuaalisesti merkittyä dataa koulutusvaiheessa. Malli oppii erottamaan datan piirteitä (esimerkiksi värähtelysignaalien eroja) automaattisesti analysoimalla muutoksia ja samankaltaisuuksia raakadatassa. Tämä vähentää tarvetta manuaaliseen merkintään ja tekee menetelmästä tehokkaan erityisesti teollisissa ympäristöissä, joissa suuri osa datasta voi olla merkitsemätöntä. Tutkimuksessa kehitettiin ja testattiin itseohjautuvaan oppimiseen perustuva malli ja värähtelydatan esikäsittelyyn käytettiin lyhytaikaista Fourier-muunnosta (STFT) luomaan ajallista ja taajuudellista edustusta. Mallin oli opittava samankaltaisuudet ja erot muuttuneiden ja alkuperäisten signaalien välillä. Malli perustuu konvoluutioverkkoon (Convolutional Neural Network, CNN), joka on erityisen hyvä käsittelemään aikasarjadatan ja spektridatan kaltaisia monimutkaisia syötteitä. CNN oppii automaattisesti piirteitä, jotka ovat olennaisia kunnonvalvonnassa, kuten värähtelydatan erikoisuuksia. Malli testattiin ja arvioitiin IMS-laakeritietokannan avulla, joka sisältää laakereiden värähtelydatan terveistä ja viallisista tiloista useiden käyttöolosuhteiden aikana. Tutkimuksen tärkeimpinä tuloksina oli vikojen havaitseminen, kun kehitetty malli onnistui tehokkaasti havaitsemaan

poikkeavuuksia laakereiden tilassa. Se pystyi erottamaan terveet ja vialliset tilat vähäisellä koulutusdatalla. Malli oli joustava niin, että sitä voitiin soveltaa sekä yksittäisen anturin dataan että koneen tason dataan useiden anturien avulla. Mallin tulokset olivat linjassa muiden kirjallisuudessa esitettyjen mallien kanssa, mutta se vaati vähemmän manuaalista merkintää ja oli joustavampi datan käsittelyssä. Tutkimuksen johtopäätöksenä menetelmä osoitti, että itseohjautuva oppiminen voi tarjota tehokkaita ja joustavia ratkaisuja pyörivien koneiden kunnonvalvontaan ja STFT-tekniikka tarjosi luotettavan tavan käsitellä monimutkaista värähtelydataa ja valmistella se syväoppimismalleille. Menetelmää voidaan laajentaa teollisiin sovelluksiin, joissa laajamittainen datan manuaalinen merkintä ei ole käytännöllistä. Tutkimus korostaa itseohjautuvan oppimisen potentiaalia teollisuuden kunnonvalvonnassa ja tarjoaa mallin, joka voi parantaa varhaista vianhavaitsemista ja ehkäistä käyttökatkoksia. Menetelmä on erityisen hyödyllinen sovelluksissa, joissa dataa on runsaasti, mutta manuaaliset merkinnät ovat rajallisia. Lisäksi mallin kyky toimia osana IoT-järjestelmää tarjoaa pitkän aikavälin arvoa, koska se mahdollistaa datalähtöisen päätöksenteon ja jatkuvan parantamisen. (De Fabritiis et al. 2024)

Zhu, A. et al. (2023) käsittelivät tutkimuksessaan “Condition monitoring of wind turbine based on deep learning networks and kernel principal component analysis” uuden menetelmän kehittämistä tuuliturbiinien kunnonvalvontaan ja poikkeavuuksien tunnistamiseen hyödyntämällä syväoppimista ja ydinkomponenttianalyysiä (Kernel Principal Component Analysis, KPCA). Menetelmä yhdistää KPCA:n kyvyn käsitellä monimutkaisia ja epälineaarisia ominaisuuksia syväoppimisverkostojen, kuten konvoluutioverkon (CNN) ja pitkäkestoisen lyhytkestomuistin (Long Short-Term Memory, LSTM), kykyyn analysoida spatiaalisia ja ajallisia piirteitä. LSTM on takaisinkytkeytyvä neuroverkko (RNN), jota käytetään laajasti syväoppimisessa. Tutkimuksessa kehitetty menetelmä perustuu tekoälyyn, erityisesti syväoppimisen ja koneoppimisen tekniikoihin. Menetelmä yhdistää tekoälypohjaisia komponentteja, kuten konvoluutioverkkoja (CNN) ja pitkän lyhyen aikavälin muisteja (LSTM), sekä ydinkomponenttianalyysin (KPCA), jotka yhdessä muodostavat tehokkaan ratkaisun tuuliturbiinien kunnonvalvontaan ja poikkeavuuksien havaitsemiseen. Tutkimuksessa käytettiin tuuliturbiinin SCADA-dataa (Supervisory Control and Data Acquisition), eli valvonta- ja ohjausjärjestelmän mittausdataa, joka sisältää paljon muuttujia, kuten tehoa, lämpötilaa, tuulen nopeutta ja vääntömomenttia. SCADA-järjestelmä on tietokonepohjainen ohjelmisto- ja laitteistokokonaisuus, jota käytetään valvomaan ja ohjaamaan laajoja hajautettuja prosesseja. SCADA-järjestelmät ovat tuuliturbiinien, ja muidenkin

energiantuotantolaitosten, valvonnassa keskeisiä, sillä ne tarjoavat reaaliaikaista dataa ja historiatietoa tuotantolaitoksen tilasta ja suorituskyvystä. Ehdotettu KPCA–CNN–LSTM-malli pystyi havaitsemaan varhaisessa vaiheessa poikkeavuuksia ja antamaan ennakkovaroituksia tuuliturbiinien epänormaalista toiminnasta. Tutkimuksen toteutuksessa datan esikäsittelyssä DBSCAN-klusterointialgoritmia käytettiin SCADA-datan suodattamiseen ja poikkeavan datan poistamiseen. Pearsonin korrelaatioanalyysin avulla valittiin merkittävät muuttujat, jotka liittyvät vahvasti tavoitemuuttujaan, kuten generaattorin staattorin lämpötilaan. Mallin kehittämisessä KPCA:a käytettiin ydinkomponenttien analysointiin ja CNN-LSTM-malli yhdisti spatiaaliset ja ajalliset ominaisuudet tarkkaa analyysiä varten. Case-tapauksina tutkimuksessa analysoitiin kaksi todellista tapausta tuulivoimapuiston SCADA-datasta. Molemmissa tapauksissa malli pystyi havaitsemaan poikkeavuudet ennen kuin vakava vika, kuten generaattorin ylikuumeneminen tai päälaakerin vika, ilmeni. Tutkimuksen tulokset osoittivat, että kehitetty KPCA–CNN–LSTM-malli on erittäin tehokas tuuliturbiinien kunnonvalvonnassa ja poikkeavuuksien havaitsemisessa. Malli pystyi analysoimaan monimutkaisia, epälineaarisia ominaisuuksia SCADA-datasta, kuten generaattorin lämpötilaa, tuulen nopeutta ja vääntömomenttia, ja yhdisti ne ajallisten ja spatiaalisten piirteiden tarkkaan analyysiin. Testitapauksissa malli havaitsi poikkeavuudet merkittävästi ennen vakavien vikojen ilmenemistä, kuten generaattorin ylikuumenemista ja päälaakerin vikoja. Tämä kyky tarjota ennakkovaroituksia mahdollistaa energiayhtiöille huolto- ja korjaustoimenpiteiden ajoittamisen siten, että käyttökatkokset ja kustannukset vähenevät. Malli oli tarkempi kuin perinteiset koneoppimismallit, mukaan lukien pelkät CNN- ja LSTM-pohjaiset menetelmät. Mallin suorituskyky mitattiin virheindikaattoreilla, kuten RMSE:lla (Root Mean Square Error) ja MAE:lla (Mean Absolute Error), jotka osoittivat, että malli pystyi ennustamaan koneiden epänormaalin käyttäytymisen pienellä virhemarginaalilla. Tulokset korostivat KPCA:n roolia datan epälineaaristen ominaisuuksien tiivistämisessä ja syväoppimisen kykyä tulkita monimutkaisia ajallisia ja spatiaalisia ilmiöitä. Johtopäätöksenä todettiin, että KPCA–CNN–LSTM-mallilla on merkittävä potentiaali parantaa tuuliturbiinien kunnossapidon tehokkuutta, luotettavuutta ja kustannustehokkuutta. Malli tarjoaa mahdollisuuden siirtyä reaktiivisesta kunnossapidosta ennakoivaan kunnossapitoon, mikä on keskeistä uusiutuvan energian tuotannon kestävyyden parantamisessa. Tulevaisuudessa mallia voidaan laajentaa kattamaan vielä monimutkaisempia ja laajempia järjestelmiä, mikä vahvistaisi sen käytettävyyttä eri teollisuudenaloilla. Näin malli ei vain tehosta yksittäisten tuuliturbiinien

valvontaa, vaan myös edistää koko energiasektorin toimintaa tekemällä uusiutuvasta energiasta entistä kilpailukykyisempää ja luotettavampaa.

Kamat et al. (2024) tutkimus "Vibration-based anomaly pattern mining for remaining useful life (RUL) prediction in bearings" käsittelee laakereiden jäljellä olevan käyttöiän (RUL) ennustamista hyödyntämällä tärinädataa ja syväoppimista. Laakereiden toiminta on kriittistä pyörivien koneiden luotettavuuden ja kunnossapidon tehokkuuden kannalta, ja niiden vikojen ennakointi voi estää vakavat toimintahäiriöt. Tutkimuksessa vertailtiin ja analysoitiin erilaisia malleja laakereiden RUL-ennustamiseen ja tehokkain oli Enkooderi-dekooderi-LSTM-malli, joka yhdistää poikkeavuuskuvioiden analysoinnin ja RUL-ennustamisen. Enkooderi-dekooderi-LSTM-malli perustuu tekoälyn syväoppimisen periaatteisiin ja LSTM-verkot voivat muistaa ja analysoida pitkäaikaisia riippuvuuksia, mikä tekee niistä tehokkaita RUL-ennusteessa. Syväoppiminen on tekoälyn osa-alue, joka keskittyy monikerroksisiin neuroverkkoihin, jotka kykenevät oppimaan datasta automaattisesti ilman tarvetta manuaalisille merkinnöille. Tutkimus on toteutettu käyttämällä PRONOSTIA-laakeridataa, joka sisältää tärinämittauksia erilaisissa toimintaympäristöissä. PRONOSTIA-laakeridataa sisältää tietoa erityyppisistä kuulalaakereista, joita käytetään pyörivissä koneissa. PRONOSTIA-tietokanta on laajasti käytetty akateemisessa tutkimuksessa laakereiden RUL-ennustamisessa ja kunnonvalvonnassa. Se sisältää tärinämittauksia laakereista kiihdytetyissä elinkaaritesteissä. Datan ominaisuuksia analysoitiin sekä aika- että taajuusalueella. Optimoidut piirteet valittiin käyttämällä tekniikoita, kuten Spearmanin korrelaatiokertoimia ja satunnaismetsäregressiota. Poikkeavuuksia tunnistettiin autoenkoodereihin perustuvilla syväoppimismalleilla, jotka havaitsevat tärinädatan poikkeamat. Mallien suorituskyky arvioitiin käyttämällä mittareita, kuten RMSE ja mallit koulutettiin historiallisella datalla, joka sisältää sekä normaaleja että epänormaaleja tilanteita. Tutkimus osoittaa, että kehitetty järjestelmä saavuttaa korkean ennustetarkkuuden. Parhaat tulokset saavutettiin enkooderi-dekooderi-LSTM-mallilla ja se kykenee tunnistamaan poikkeavuudet ajoissa ja ennustamaan jäännöskäyttöiän tarkasti, mikä mahdollistaa ennakoivan kunnossapidon ja resurssien optimoinnin. Tutkimus osoittaa syväoppimismallien potentiaalin ja että niillä voidaan saavuttaa merkittäviä parannuksia laakereiden, ja tätä kautta kriittisten tuotantovälineiden, kunnossapidon päätöksenteossa. Mallin kyky käsitellä sekä aikaisempaa että reaaliaikaista dataa tekee siitä käytännöllisen erilaisiin teollisiin ympäristöihin. Enkooderi-dekooderi-LSTM-mallia voidaan hyödyntää monilla teollisuudenaloilla, erityisesti kunnossapidon ja resurssienhallinnan optimointiin. Tekoäly mahdollistaa mallin skaalautuvuuden ja oppimisen uusista olosuhteista,

mikä tekee siitä tulevaisuuden ratkaisun monimutkaisille koneiden kunnonvalvontajärjestelmille.

Hussain et al. (2023) tutkimus, jonka otsikko on "Adoption of Big Data Analytics for Energy Pipeline Condition Assessment," käsittelee big data analytiikan hyödyntämistä energiainfrastruktuurin, erityisesti öljy- ja kaasulinjojen, kunnon arvioinnissa ja hallinnassa. Se on systemaattinen kirjallisuuskatsaus, jossa tutkittiin data-analytiikan nykytilaa, sovelluksia ja haasteita alalla. Menetelmänä toimi systemaattinen kirjallisuuskatsaus, jossa käytettiin PRISMA-protokollaa ja tutkittiin tieteellisiä artikkeleita sekä konferenssijulkaisuja. Analyysin fokuksessa olivat big data -teknologiat, koneoppiminen, ennakoiva analytiikka ja dataintegraatio. Tarkasteltiin, miten nämä teknologiat voivat parantaa putkistojen kunnonhallintaa, turvallisuutta ja tehokkuutta. Tutkimuksessa ”big datalla” tarkoitetaan suuria määriä rakenteista, puolirakenteista ja rakenteetonta dataa, jota syntyy reaaliaikaisesti ja monenlaisista lähteistä. Tämä data sisältää esimerkiksi sensorien, mittareiden ja muiden valvontalaitteiden keräämää tietoa. Big data-analytiikka hyödyntää näitä suuria datamääriä kaavojen, korrelaatioiden ja trendien löytämiseen, jotka tukevat päätöksentekoa ja parantavat liiketoimintaprosesseja. Big dataa käytetään erityisesti reaaliaikaisessa monitoroinnissa, vikaantumisten ennustamisessa, kunnossapidon optimoinnissa ja operatiivisen tehokkuuden parantamisessa. Data voi sisältää rakenteellista tietoa (esim. sensoridataa), rakenteetonta tietoa (kuten kuvia, videoita ja ääntä) sekä puolirakenteista dataa (esim. toimintaparametreja ja analyysiraportteja). Tutkimuksessa hyödynnetty data oli monipuolista ja kattoi useita osa-alueita, kuten putkistojen suunnittelun, käytön, ympäristöolosuhteet, tarkastukset ja ylläpidon. Data sisälsi esimerkiksi tiedot putkiston rakennusvuodesta, käytetyistä materiaaleista ja niiden ominaisuuksista, sekä rakennusprosessiin liittyvistä laadunvalvontaraporteista. Lisäksi mukana olivat tiedot putkiston katodisen suojauksen järjestelmistä, jotka ehkäisevät korroosiota. Käyttödatan osalta tutkimuksessa tarkasteltiin esimerkiksi virtausnopeutta, painetta ja lämpötilavaihteluita, jotka voivat vaikuttaa putkiston kuntoon ajan myötä. Käyttödataan kuuluivat myös vuotojen ja vikojen historia, jotka auttavat tunnistamaan riskialttiita alueita ja toistuvia ongelmia. Kuljetettavan aineen, kuten kaasun, laatu oli myös olennainen osa dataa, koska se voi vaikuttaa putken sisäpinnan kuntoon. Ympäristödata oli tärkeässä roolissa, sillä se tarjosi tietoa putkiston sijaintiin liittyvistä olosuhteista, kuten säästä ja maaperän ominaisuuksista. Esimerkiksi maaperän kemialliset ominaisuudet ja geologiset tekijät voivat lisätä putkiston ulkoista korroosiota. Tarkastusdata käsitti monenlaisia mittaus- ja analyysimenetelmiä, kuten painekokeita, magneettivuoanalyysiä ja ultraäänitarkastuksia, jotka paljastivat putkiston

rakenteellisia ongelmia, kuten halkeamia tai seinämien ohenemista. Sisäisiä tarkastuksia tehtiin älykkäillä tarkastuslaitteilla, jotka tuottivat yksityiskohtaista tietoa putkiston sisäisestä kunnosta. Kunnossapitodata sisälsi tiedot huoltokustannuksista, huoltokatkoista, korjauksista ja niiden vaikutuksista tuotantoon. Näitä tietoja käytettiin analysoimaan huoltokäytäntöjen tehokkuutta ja optimoimaan tulevia toimia. Lisäksi attribuuttidata, kuten putken seinämän paksuus, halkaisija ja materiaaliominaisuudet, tarjosi teknisiä tietoja putken fyysisestä kunnosta ja rakenteellisesta kestävyydestä. Näiden erilaisten datatyyppien avulla oli saatu tutkimuksen mukaan rakennettua kokonaisvaltaisia malleja, jotka mahdollistivat putkistojen kunnon tarkemman arvioinnin ja ennakoivan ylläpidon. Yhdistämällä suunnittelu-, käyttö-, ympäristö- ja tarkastusdata pystyttiin muodostamaan kattava näkemys putkiston nykytilasta, mikä tuki paremmin päätöksentekoa ja auttoi välttämään odottamattomia vikoja. Tutkimuksessa selvisi, että dataintegraatio ja -harmonisointi olivat olennaisia, jotta kaikki eri lähteistä saatu tieto voitiin yhdistää tehokkaasti ja luotettavasti. Johtopäätöksenä laajasta kirjallisuusanalyysista oli, että Big data tarjoaa merkittäviä mahdollisuuksia energiaputkistojen kunnon arvioinnissa ja ylläpidossa.

Seuraavassa luvussa kerron tekemistäni asiantuntijahaastatteluiden tuloksista.

3.2 Asiantuntijahaastattelut

Tässä luvussa kerron asiantuntijahaastatteluiden tuloksista. Tämä tutkimuksen osa oli syytä toteuttaa, koska kirjallista tieteellistä tutkimusaineistoa tältä aihealueelta on vielä hyvin vähän. Haastatteluun valitut asiantuntijaorganisaatiot ja henkilöt niistä toimivat data-analytiikka ratkaisujen toimittajina energia-alalle. Yhtiöt olivat kaikki suomalaisia. Kysyin samat kysymykset joka organisaatiolta ja lähetin 11 organisaation henkilöstölle haastattelupyynnön. Valitettavasti vain neljästä yhtiöstä tuli haastatteluun vastauksia. Valitettavasti yhtiöt eivät voineet avata kovin spesifisti tapauksia eikä tietenkään asiakkaita voitu paljastaa, jonka tiesinkin ennalta ja huomioin haastattelukysymyksissä. Tässä luvussa luetellaan myös energia-alalla tyypillisiä ja oleellisia datan lähteitä. Datan lähteissä keskitytään tuotanto-liiketoimintaan, joten esimerkiksi energiayhtiön markkinointipuolelle hyödyllisiä sosiaalisen-median dataa ei luetella. Alla vastaukset haastatteluista on liitetty eheäksi kokonaisuudeksi. Kiitokset vastanneille henkilöille.

1. Millä tavalla olette toteuttaneet datavarastoratkaisuja energiayhtiöille?

Vastaukset sekalaisessa järjestyksessä:

- Olemme toteuttaneet datavarastoratkaisuja energiayhtiöille huomattavan moninaisilla ratkaisuilla. Azure SQL + ADF + muut Azuren palvelut, Dataprox sekä erilaiset tiedostopohjaiset ratkaisut kuten Qlik-teknologian hyödyntäminen ja Qlik-tiedostoperusteinen tietovarastoratkaisu.
- Toteutustavat riippuvat tarpeesta. Pilvipohjaiset ratkaisut ovat tietysti tänä päivänä yleisiä, Azure ja AWS ovat meille tuttuja. Emme sinänsä ole toimittaneet tietovarasto-alustan pystytyksiä nollasta (emme myy softaa tai toimi yhteistyössä tietyn alustatoimittajan kanssa). Voimme auttaa tietovaraston tarpeiden määrittelyssä ja toimia tilaajan projektipäällikkönä hankkeiden läpiviennissä.
- Azure + AWS pilvipohjaisia ratkaisuja erilaisiin tarpeisiin ja kokoluokkiin
- Lähtökohtamme on toteuttaa asiakkaan omistama data-alusta, johon data integroidaan kustakin lähteestä kertaalleen, mutta eri lähteiden dataa voidaan linkittää keskenään, mallintaa ja rikastaa. Näin syntyy keskitetty data-alusta, jonka päältä eri lähteiden datasta voidaan tehdä analyysiä, dataa voidaan visualisoida ja jakaa niin haluttaessa kolmansille osapuolille tai hyödyntää kolmansien osapuolten analytiikkaa datan rikastamiseen.

Rakennamme ratkaisut pääosin Azureen / Fabriciin, mutta myös AWS on käytössä. Meillä on oma teollisen data-alustan assetti, joka ratkaisee tyypillisimmät tarpeet automaatiodatan keräämiseksi OPC UA -lähteistä pilveen sekä asiakkaan Azureen pystytettävä data-alustan pohja, joka pystyy syömään suuria määriä aikasarjadataa eri lähteistä ja tarjoilemaan sitä edelleen metadatoineen. Näillä voidaan merkittävästi nopeuttaa datan hyödyntämistä tapauksissa, joissa asiakkaalla ei vielä valmiiksi ole data-alustaratkaisua pilvessä. Meillä on olemassa valmiit ratkaisut myös esimerkiksi aikasarjadatan visualisointiin, OEE-laskentaan, BI/DW/raportointiin jne. Tässä ajatuksemme on, että mahdollisimman paljon asiakkaan perustarpeista saataisiin ratkaistua pienellä vaivalla ja kehitysponnistukset tulisi käyttää niihin asioihin, jotka tuottavat asiakaskohtaista lisäarvoa (joka on asiakaskohtainen). Rakennamme asiakkaille ratkaisun, jossa data ja data-alusta ovat heidän omiaan.

Alla yhden vastaajan kuva joka havainnollistaa datavarastoratkaisua.

KUVA 7: Datavarastoratkaisun havainnollistaminen.

2. Oleelliset datan lähteet energiayhtiölle tehtävässä data-analytiikassa?

   -Omaisuustiedot:

   -tuotantolaitokset

   -komponenttien valmistajat

   -mitat

   -materiaalit

   -kiinnitykset, kannakkeet

   -varastot

   - asiakastiedot

   - tekninen dokumentaatio

   Käyttötieto:

   -Mittausdata automaatiojärjestelmästä mm. eri laitteiden tai järjestelmien lämpötila, värähtely, virtaus, paine, teho, virta, taajuus jne. voi olla satoja eri mittauksia. esim. kuormitusdata sähköverkosta.

   -Mittausdataa asiakkailta. Sitä käyttökelpoisempaa data-analytiikassa mitä enemmän ja tiheämmin päivittyvää.

-Kaikki kirjallinen data laitteista tai järjestelmistä. Tallenteet ja ilmoitukset vikaantumisista ja häiriöistä. Kirjatut havainnot ja toimenpiteet.

-Ilmasta tallennettu materiaali kuten lämpökuvaukset kaukolämpöverkosta. Sovitetaan ilmakuvien päälle ja voidaan analysoida tekoälyratkaisuilla löytäen vuotoja.

Ulkoinen avoin data: esimerkiksi sää, energian hintahistoria, sähköfutuurit, nordpool sähkön hinnat. Muun muassa todella käyttökelpoinen sivusto avoimen datan etsimiseen on Avoindata.fi. Tälle sivustolla on pyritty listaamaan Suomen kaikki avoin data. Energia-alalle toimii esimerkkinä Espoon geoenergiakartta, joka on maalämpöinvestoinnille suoraan hyödyllistä dataa. Kallio- ja maaperän soveltuvuudesta geoenergian tuotantoon Geoenergiakartta soveltuu hyvin. Kartta pohjautuu Geologian tutkimuskeskuksen kallio- ja maaperätietoihin, Espoon kaupungin maaperäkarttoihin, maanmittauslaitoksen kartta-aineistoihin sekä geologin näiden pohjalta tekemään tulkintaan.

Tekoälystä on hyötyä, kun on paljon käsiteltävää dataa. Käytetään toistuvaan tarpeeseen. Tarkat selkeästi määritellyt tehtävät ovat hyväksi. Esimerkiksi ennustetaan jotain tai luokitellaan tai optimoidaan.

3. Käytetyt teknologiat datan analysoinnissa ja mitä konkreettisia hyötyjä on asiakkaille syntynyt näistä ja millä tavalla?

   - Hyötyjen ja asiakkaalle luodun arvon voi jakaa kolmeen pääryhmään: teollinen tilannekuva, älykäs kunnossapito ja tuotannon optimointi.

   Teollinen tilannekuva tarjoaa operatiivisen näkymän yhdestä paikasta, korvaten perinteisen valvomon useiden näyttöjen hajanaisen tiedonhallinnan. Keskeiset mittaukset automaatiosta, IoT-laitteista ja muista lähteistä yhdistetään lähes reaaliajassa, jolloin olennaiset tiedot ovat saatavilla valvomossa, tietokoneella ja älypuhelimessa. Tämä mahdollistaa tilannekuvan hahmottamisen helposti ja tehokkaasti. Lisäksi KPI-luvut, tuotantomäärät ja taloudelliset tiedot yhdistetään yhteen paikkaan, tarjoten lähes viiveettömän näkymän esimerkiksi kuukauden alun tuloksista ja poikkeamien syistä. Näin toimintaa voidaan ohjata aktiivisesti reaaliaikaisen tiedon perusteella, eikä pelkästään tarkastella jälkikäteen tehtyjä raportteja.

   Älykäs kunnossapito keskittyy ennakoimattomien seisokkien välttämiseen, poikkeamien tunnistamiseen ja turvallisuuden parantamiseen. Tämä saavutetaan hyödyntämällä matemaattisia analyysejä, kuten laakerivikojen tunnistamista, ja seuraamalla trendejä ennen kuin hälytysrajat ylittyvät, jolloin ongelmiin voidaan puuttua ajoissa.

Neuroverkkopohjaiset digitaaliset kaksoset tunnistavat prosessin epätavallisen toiminnan ja poikkeavat mittaukset, mikä auttaa myös erottamaan toisistaan merkitykselliset ja virheelliset hälytykset. Lisäksi kunnossapito hyödyntää laitteiden elinkaarimallinnusta ja muiden vastaavien laitteistojen vertailua.

Tuotannon optimoinnissa pyritään maksimoimaan nykyisen laitekannan tuotto, minimoimaan kulut ja stabiloimaan laatu. Tämä sisältää koko tuotanto- ja kulutusjärjestelmän mallintamisen, jossa huomioidaan esimerkiksi sääolosuhteet ja markkinahintojen kehitys. Optimaaliset tavoitearvot jaetaan itsenäisille järjestelmän osille, jotta ne voivat toimia kokonaisuutta tukevasti. Neuroverkkopohjaiset digitaaliset kaksoset ehdottavat ajotilanteeseen sopivia parametreja tai jopa ohjaavat tuotantoa suoraan. Lisäksi järjestelmä reagoi nopeasti markkinamuutoksiin, kuten sähkön hinnan vaihteluihin, polttoainemiksin optimoimiseksi ja maksimaalisen tuoton saavuttamiseksi.

Arvon luominen datan avulla voi tapahtua monilla eri teknisillä ratkaisuilla riippuen käytettävissä olevasta datasta ja tarpeista. Yksinkertaisimmillaan arvoa voi tuottaa ihmisen tietotaidon muuntaminen algoritmiksi, joka suoritetaan koko ajan sen sijaan, että ihminen suorittaa analyysin vaikkapa aamuisin. Pienillä datamäärillä hyödynnetään usein tilastollisia menetelmiä ja lean six sigma -työkaluja. Laajemman automaatiodatan avulla koneoppiminen ja neuroverkot ovat käyttökelpoisia, ja suorituskykyisten simulaattoreiden avulla voidaan hyödyntää vahvistusoppimista.

Kyky hyödyntää omaa dataa kattavasti ja turvallisesti sekä integroida se lisäarvoa tuottaviin kolmansien osapuolten palveluihin korostuu yhä enemmän. EU:n NIS2-direktiivi ja Data Act -säädökset ohjaavat osaltaan toimintaa tähän suuntaan.

- Ratkaisut kattavat kaiken perustason raportoinnista koneoppimiseen.
  Perusraportoinnin lisäksi tarjolla on ratkaisuja, jotka tuottavat lisäarvoa erityisesti ennustamisen ja analytiikan avulla. Näihin kuuluu esimerkiksi kysynnän ja tuotantovolyymin ennustaminen sekä niiden muuntaminen taloudellisiksi arvoiksi. Tämä prosessi alkaa volyymiennustemallin luomisella, jonka pohjalta ennusteet muutetaan euroiksi huomioiden sekä fyysisen maailman että finanssimaailman, kuten johdannaismarkkinoiden tulokset. Ratkaisu toimii sekä lyhyellä aikavälillä (24 tuntia eteenpäin) että pitkällä aikavälillä (2–3 vuotta), mikä mahdollistaa monipuoliset käyttötarkoitukset. Lyhyellä aikavälillä ratkaisu tukee

päivittäisten hankintaennusteiden laskentaa, kun taas pitkällä aikavälillä se palvelee esimerkiksi riskienhallintaa ja liiketoiminnan talousraportointia, mahdollistamalla myös rullaavan budjetoinnin.

Muita merkittäviä ratkaisuja ovat kaukolämpöön liittyvät sopimustehon laskentamallit sekä jakelutoiminnan, kuten verkostojen, verkkoarvon määritys ja laskenta. Näihin sisältyvät jälleenhankinta-arvon ja nykykäyttöarvon laskelmat sekä ennusteet jopa 50 vuoden päähän. Lisäksi järjestelmät tukevat huoltotoimenpiteiden ja kunnossapito-ohjelmien seurantaa ja analysointia, mikä parantaa operatiivista tehokkuutta ja strategista päätöksentekoa.

Näiden ratkaisujen avulla yritykset voivat yhdistää lyhyen ja pitkän aikavälin ennusteet, hallita riskejä ja optimoida resurssejaan entistä tehokkaammin.

- Olemme toteuttaneet tekoäly- ja analytiikkaratkaisuja silloin, kun niistä on ollut asiakkaalle todellista hyötyä. Usein myös perinteisillä analytiikkamenetelmillä voidaan saavuttaa merkittäviä oivalluksia yhdistämällä dataa eri lähteistä uusilla tavoilla. Tyypillisesti asiakkailla on joko ratkaistavana tietty haaste, kuten liian usein hajoava komponentti, tai selkeä strateginen tavoite, jonka he haluavat saavuttaa. Ratkaisut ovat sisältäneet esimerkiksi vikaantumisennusteita, joiden avulla on voitu toteuttaa ennakoivaa kunnossapitoa ja näin alentaa kustannuksia. Myös jäljellä olevan käyttöiän (RUL) ennusteita on ollut mahdollista tuottaa. Toinen esimerkki on resonanssia aiheuttavien tekijöiden tunnistaminen värähtelydatasta, jotta ongelman aiheuttavat tekijät voidaan poistaa, mikä vähentää melua ja parantaa toimintaympäristöä.

  Näiden ratkaisujen tuomat hyödyt ovat olleet moninaisia. Ne ovat vähentäneet manuaalista työtä, mikä on mahdollistanut enemmän tuotoksia samalla henkilömäärällä. Toiminta on ollut laadukkaampaa verrattuna täysin ihmisen toteuttamaan analyysiin, ja priorisointia sekä toiminnan kohdentamista on voitu tukea tehokkaammin. Käyttöaste on parantunut, koska resursseja on hyödynnetty aiempaa tehokkaammin. Lisäksi kaupankäynnin kokonaisseurantaa on selkeytetty, mikä on mahdollistanut kauppojen ajoituksen optimoinnin ja position suuruuden hallinnan. Tärkeää on myös ollut varmistaa, että työt tehdään oikein, mikä vähentää ongelmien todennäköisyyttä tulevaisuudessa.

  Vaikka hyödyt eivät aina liity keskitettyyn tietovarastointiin, se on usein helpottanut toimintaa. Yhden totuuden periaatteen mukainen tietojen hyödyntäminen

on ollut tehokkaampaa kuin erillisten Excel-taulukoiden pyytäminen ja käsittely. Tämä on mahdollistanut selkeämmän ja yhtenäisemmän tiedonhallinnan organisaation sisällä.

- Olemme käyttäneet tekoälyratkaisuja kunnossapidon alueella. Esimerkiksi tällaisa ratkaisuja on mahdollista tehdä:

  Vikaantumisalttiutta yli ajan ennustavat mallit, johdetaan vikaantumistodennäköisyys ja käyttöikäennuste (RUL)

  Kausaaliset menetelmät, juurisyyanalyysi tunnistaa laitevikojen todelliset syyt eli pystymme erilaisilla menetelmillä tunnistamaan mistä loppujen lopuksi asiat johtuvat.

  Reunalaskenta (Edge AI) virheiden tunnistamiseksi ja niihin reagoimiseksi jopa millisekunneissa.

  Tekoälyn käyttökohteita kunnossapidossa:

  -yhteenvedot, palautteet ja analyysit kunnossapito/huoltokirjauksista

  -turvallisuushavaintojen analysointi

  -toimenpidekirjaukset puhumalla.

  -Varaosien tarpeen ennustaminen

  -Optimoidun huoltoaikataulun luominen

  Mihin tulevaisuudessa menee teknojättien (NVIDIA&Microsoft) mukaan ja mihin suuntaan viemässä: Tulee helpottamaan kunnossapitäjän arkea, seuraa koko ajan mitä kunnossapitäjä tekee mukana liikkuvan kameran+mikrofonin kanssa ja ottaa kirjaukset vastaan ja tallentaa mitä tehdään.

Tässä vielä muutama esimerkki minkälaisia työkaluja nämä haastattelututkimuksessa olevat asiantuntijaorganisaatiot ovat tehneet asiakkaiden avuksi:

ESIMERKKI 1: Sähköverkon huolto

Otetaan lennokki, eli drone, tai vaihtoehtoisesti helikopteri ja otetaan kuvia sähkönsiirtoon tarkoitetuista pylväistä. Voidaan käyttää myös lämpökuvasta. Tekoäly analysoi kuvat automaattisesti esimerkiksi onko kaikki tarvittavat komponentit paikallaan. Tehdään automaattisesti jokaiselle pylväälle huoltosuunnitelma mitä niille pitää tehdä. Pylväitä todella paljon ja vaikea päästä paikalle eli raskasta analysoida ihmisenä, mutta tehokasta näin toteutettuna.

ESIMERKKI 2: Aikasarjojen data-analytiikaa

Kerätään IoT-dataa esim. pumpuista, lämmönvaihtimista tai muista erilaisten laitteiden osista. Data kertoo miten laite käyttäytyy eri tilanteissa esimerkiksi resonointi, lämpötilat jne. ja näiden perusteella voidaan luoda vikaantumisalttiusmalli jonka perusteella voidaan laskea ja arvioida mitkä laitteet tai laitteiden osat ovat suurimmassa vikaantumisriskissä ja tämän perusteella optimoida kunnossapidon toimenpiteet. Voidaan esimerkiksi 10 sekunnin välein tehdä välittömät arviot laitteista mitkä laitteet tai komponentit tarvitsevat huoltoa. Tämä kaikki tapahtuu automaattisesti ilman ihmistä ja tuottaa jatkuvasti ennakoivan kunnossapidon suunnitelmat laitteille.

ESIMERKKI 3: Kaukolämpövuotojen tunnistaminen

Helikopterilla voidaan mennä ottamaan lämpökamerakuvat kaukolämpöverkosta ja kuvat analysoidaan ja yhdistellään ilmakuviin automaattisesti koneoppimismallilla. Saadaan tietoja siitä missä kaukolämpöverkossa mahdollinen vuoto ja sen perusteella tehdä huoltosuunnitelma. Mahdollista säästää paljon rahaa löytämällä ja korjaamalla vuodot.

Tässä luvussa olen esitellyt aiempaa empiiristä tutkimusta tältä aiheesta data-analytiikka energiayhtiöissä ja käyty läpi asiantuntijahaastatteluita aihealueesta.

4 Case tutkimus

Tässä luvussa esitellään kohdeyhtiö, Kotkan Energia Oy, ja sen Tuotanto-liiketoiminta johon tutkimus kohdistuu. Tämän jälkeen käydään läpi Tuotanto-liiketoiminnasta saatavaa oleellista dataa, josta voisi saada merkittävää taloudellista hyötyä yhtiölle.

4.1 Case-Yhtiö

Tässä luvussa käydään läpi Case- tutkimuksen toteutusta ja esitellään kohdeyhtiö, energiayhtiö Kotkan Energia Oy, ja sen Tuotanto-liiketoiminta johon tutkimus kohdistuu. Kotkan Energia konserni on kokonaan Kotkan kaupungin omistama. Kotkan Energian perustamisvuosi on 1993 ja nykyinen konsernirakenne muodostui vuonna 2021. Kotkan Energia on kehittynyt paljon toimiessaan osakeyhtiönä 30 vuoden ajan. Energiantuotantoa on uudistettu

bio- ja jätepohjaiseen energian tuotantoon, hiilestä luovuttu ja uusia liiketoimintoja, kuten jätteiden energiahyödyntäminen ja tuulivoima on kehitetty matkan varrella. Tavoitteena Kotkan Energialla on pitää kaukolämpö parhaana lämmitysratkaisuna kokonaistaloudellisesti asiakkaille ja se pyrkii siihen pitämällä kaukolämmön hinta kilpailukykyisenä verrattuna vaihtoehtoihin. Yhtiö tukee tarjoamalla kustannustehokkaita ja kestävästi tuotettuja energiapalveluita myös paikallisen teollisuuden kilpailukykyä. Kotkan Energia-konserni on muodostunut yrityskauppojen kautta sekä toimintoja yhdistelemällä nykymuotoonsa. Kotkan Energia-konserni työllisti 133 henkilöä vuonna 2023. Kotkan Energiaverkot Oy, KotkaGas Oy ja KotkaTec Oy toimivat tärkeänä osana energiakonsernia. (Vuosikertomus 2023)

KUVA. Kotkan Energia Oy (Vuosikertomus 2023)

Kotkan Energiaverkot Oy harjoittaa suljetun sähköverkon siirtoliiketoimintaa Korkeakoskella, Kotkassa ja Karhulassa sijaitsevassa teollisuuspuistossa. Kotkan Energiaverkkojen asiakkaina ovat keskisuuret ja teollisuusasiakkaat sekä muut alueen yritykset. Kotkan Energiaverkko Oy toimittaa sähkönsiirron lisäksi pääasiassa omalla verkkoalueellaan alueiden yrityksille ja operaattoreille valokuituverkon vuokrauspalveluita. (Kotkan Energiaverkot 2024)

KotkaGas Oy tarjoaa maakaasutoimituksia Suomeen luotettavasti eri maahantuontipisteiden kautta. KotkaGas Oy toimittaa maakaasua täysin joustavasti, luotettavasti ja läpinäkyvästi, avaimet käteen -periaatteella, asiakasta kuunnellen. Yhtiö tarjoaa tuotteitaan teollisille toimijoille sekä Kotkassa että muualla Suomessa. (KotkaGas 2024)

KotkaTec Oy tarjoaa teollisuudelle räätälöityjä sähkölaitteistojen huolto-, kunnossapito- ja käytönjohtopalveluita sekä projektinhallinta- ja asiantuntijapalveluita. Yrityksen palveluvalikoimaan kuuluvat sähköurakointi, sopimuspohjaiset käytönjohtopalvelut, relekoestukset, käyttöönotot, lämpökuvauspalvelut sekä valokuituverkkojen rakentaminen. Lisäksi yhtiö tarjoaa sähkölaitteistojen kuntotarkastuksia, sähkönlaatumittauksia ja tarjoamme lisäksi sähkövalvojapalveluita asiakkaiden projekteihin.. (KotkaTec 2024)

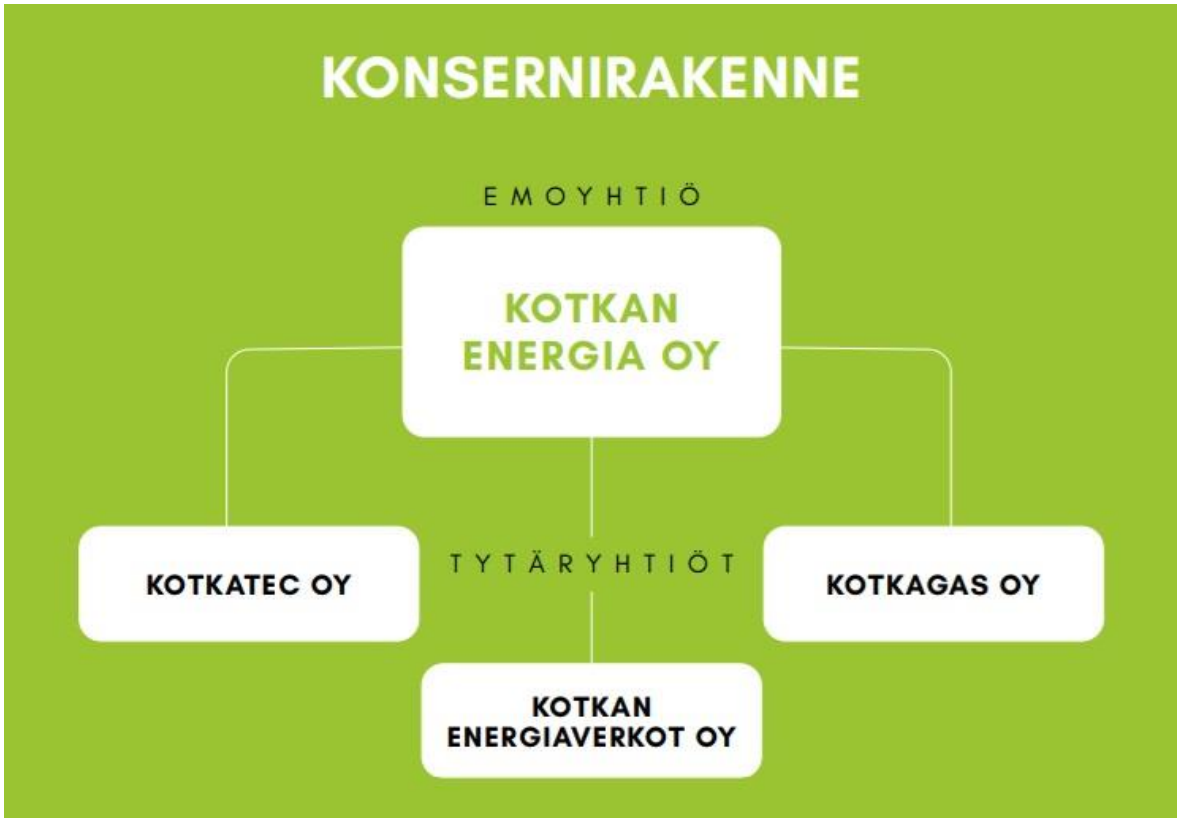

KUVA. Konsernirakenne (Vuosikertomus 2023)

Kotkan Energia -konsernin merkittävimmät liiketaloudelliset riskit liittyvät voimalaitosten ja energiaverkkojen odottamattomista keskeytyksistä aiheutuviin katemenetyksiin, korjaus- ja huoltokustannuksiin, polttoaineiden hintavaihteluihin ja verotukseen, sähkön johdannaiskauppaan sekä sääolosuhteiden vaikutuksiin kaukolämmön myynnissä. Voimalaitosten ja energiaverkkojen käytettävyysriskejä hallitaan säännöllisillä tarkastuksilla ja

ennakkohuolloilla. Polttoaineiden hintavaihteluun ja verotukseen varaudutaan monipuolisella ja joustavalla polttoainevalikoimalla. Sähkön myyntiin ja ostoon liittyviä sekä rahoitussalkun korkoriskejä hallitaan johdannaisten avulla hallituksen hyväksymän riskipolitiikan mukaisesti. Merkittävä osa yhtiön tuotannon optimointi ja suunnittelua ovat päästökauppa ja päästöoikeudet. (Vuosikertomus 2023)

Edellisessä kappaleessa kerrotut merkittävimmät konsernin riskit kohdistuvat melkein kaikki emoyhtiön Tuotanto-liiketoimintaan, johon tämä tutkimustyö kohdistuu. Energiayhtiölle tyypilliseen tapaan myös Kotkan Energialla on huomattavan suuri laitekanta, paljon tuotantolaitoksia ja verkostoja, jotka vaativat jatkuvaa kunnossapitoa, investointeja ja kehittämistä. Energia-ala on kokenut lyhyessä ajassa paljon muutoksia tuotannon siirtyessä fossiilisista energianlähteistä uusiutuvia kohti ja Kotkan Energian on täytynyt kehittää toimintaansa paljon. Yhtiön vuoden 2023 vuosikertomus kertoo yhtiön strategian olevan päästöttömän energiatulevaisuuden edelläkävijä ja asiakkaiden paras kumppani sekä toimiminen vastuullisena alueellisen elinkeinoelämänedistäjänä. (Vuosikertomus 2023)

Alla on yhtiön päivitetty kaukolämmöntuotannon hiilineutraaliustiekartta, joka viitoittaa yhtiön tietä uutta kohti ja näyttää mitä historiassa on tehty strategian toteuttamiseksi.

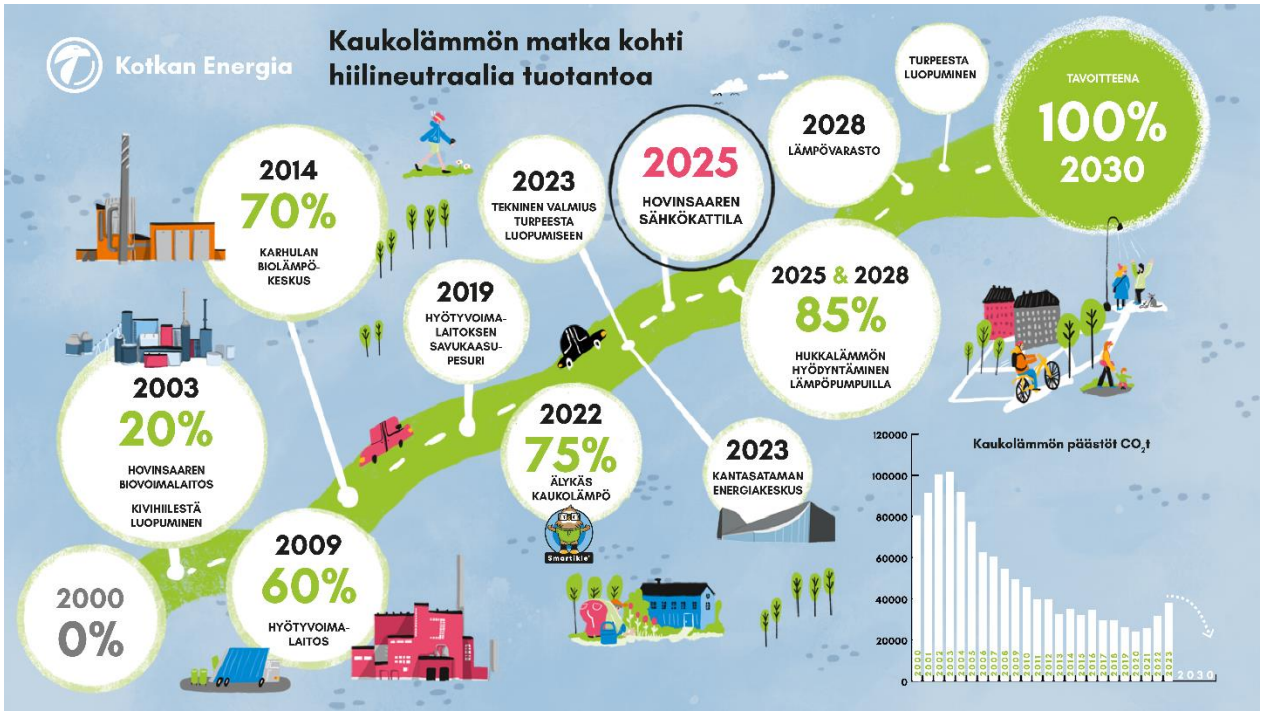

KUVA. Tiekartta (Intra 2024)

Emoyhtiö Kotkan Energiassa Hallinto-liiketoiminta vastaa yhtiön yleishallinosta, henkilöstötoiminnoista, EHSQ-toiminnoista sekä viestinnästä ja markkinoinnista. Taloustoiminto vastaa rahoituksesta, taloudesta, controllereista sekä laskutuksesta. Tuotantoliiketoiminta, jota tässä tutkimuksessa käsitellään, vastaa tuotantolaitoksien ja kaukolämpöverkon käytöstä ja kunnossapidosta sekä yhtiön tekniikasta ja teknisestä suunnittelusta. Tuotanto on yhtiön suurin liiketoiminta, joka vaatii jatkuvaa kehitystä ja tehostamista useilla eri osa-alueilla. Tuotanto-liiketoiminnalla on paljon järjestelmiä ja sovelluksia kunnonvalvontaa varten. Kriittisyysluokituksia on tehty laajasti laitteille, voimalaitoksille, lämpölaitoksille ja kaukolämpöverkostolle. Yhtiö kerää paljon dataa sen tuotantolaitoksien ja asiakkaiden laitteista ja kaukolämpöverkostostaan. Energialiiketoiminta vastaa energianhankinnasta, energianmyynnistä, kaupankäyntitoiminnoista, asiakkuuksista sekä tuotannon suunnittelusta ja optimoinnista. Energialiiketoiminnan tavoitteena on hankkia energia kustannustehokkaasti varmistaen yhtiön tuloksentekokykyä. Kaupankäynnin, optimoinnin ja tuotantosuunnittelun avulla parannetaan sisäistä tehokkuutta ja tuotetaan lisäarvoa aktiivisella kaupankäynnillä. Työssä käsitellään myös Energia-liiketoiminnan aluetta, koska Energia- ja Tuotanto-liiketoiminta nivoutuvat niin voimakkaasti yhteen aivan päivittäisessä työskentelyssä.

4.1.1 Tuotanto-liiketoiminta

Kotkan Energian Tuotanto-liiketoiminta vastaa tuotantolaitoksien ja kaukolämpöverkon hallinnasta, käytöstä ja kunnossapidosta sekä yhtiön tekniikasta ja teknisestä suunnittelusta. Tuotanto-liiketoiminta koostaa taloudellisesti merkittävimmän osan emoyhtiön liiketoiminnasta. Energiantuotantoa harjoitetaan kahdella voimalaitoksella, biolämpökeskuksella, neljällä lämpökeskuksella, jossa käytetään maakaasua ja/tai öljyä polttoaineena sekä MM Kotkamillsiltä ostetaan kaukolämpöä varten energiaa. Kotkan Energialla on myös kolme tuulivoimalaa Mussalon sataman vieressä joiden yhteisteho on noin 7,05 MW. Tuotanto-liiketoiminta tuotti vuonna 2023 sähköä 83 GWh, kaukolämpöä myytiin asiakkaille 372 GWh ja höyryä myytiin 163 GWh. (Vuosikertomus 2023)

Kotkan Energian päätuotantolaitos on Hovinsaaren voimalaitos, joka tuottaa kaukolämpöä, sähköä sekä prosessihöyryä viereiselle tehtaalle. Hovinsaaren voimalaitos on niin sanottu yhteistuotantolaitos (Combined heat and power, CHP). Tuotantomuotona CHP tarkoittaa prosessia, jossa tuotetaan samalla sähkön lisäksi lämpöä. Höyry- tai kaasuturbiineilla

esimerkiksi tuotetaan sähköä ja turbiinin jälkeinen lämpö hyödynnetään yhteistuotannossa vaikkapa kaukolämpönä tai teollisissa prosesseissa. Hovinsaaren voimalaitoksen pääkattila on polttoaineteholtaan 72 MW Biokattila. Se on vuonna 2003 valmistunut kerrosleijukattila, joka mahdollistaa monenlaiset polttoaineet kuten hakkeen, kuoret, turpeen ja erilaisia kierrätyspolttoaineita. Lisäksi tukipolttoaineina on mahdollista käyttää öljyä ja maakaasua. Kattila tuottaa korkeapainehöyryä, jota on myös mahdollista reduktioventtiilillä muuttaa matalapainehöyryksi. Hovinsaarella sijaitsee myös kombivoimala jossa on sähköä tuottavan kaasuturbiinin perässä lämmöntalteenottokattila korkeapainehöyryn ja kaukolämmöntuotantoa varten. Hovinsaaren voimalaitoksella on höyryturbiini jolla voidaan tuottaa sähköä korkeapainehöyryn avulla ja turbiinin perässä on lauhdutin jota käytetään kaukolämmön tuotantoon. Kolmas kattila Hovinsaarella on apukattila, joka on maakaasukäyttöinen ja tuottaa matalapainehöyryä joka käy viereisellä tehtaalle prosessihöyryksi tai kaukolämmön tuotantoon. Hovinsaarelle on myös rakenteilla neljäs kattila. Se on 30 MW tehoinen sähkökattila, jolla pystyy tuottamaan matalapainehöyryä. Tämä monipuolistaa Kotkan Energian energiatuotantoportfoliota entisestään ja lisää mahdollisuuksia tuotannon kuin myös kunnossapidon optimointiin merkittävästi. Toinen voimalaitos on Hyötyvoimalaitos, jossa tuotetaan energiaa polttamalla kotitalousjätettä. Hyötyvoimalaitos ja sen 34 MW polttoainetehon arinakattila on valmistunut vuonna 2009. Voimalaitos tuottaa sähköä, prosessihöyryä ja kaukolämpöä. Prosessihöyry menee viereisen tehtaan käyttöön. Voimalaitoksien viereiset tehtaat ovat todella tärkeitä ja isoja asiakkaita yhtiölle ja niillä on myös suuri merkitys työllistäjänä Kotkan alueella. Tehtaiden vieressä on siksi tärkeää olla edullista ja luotettavaa energiantuotantoa tarjolla. Voimalaitoksien lisäksi 20 MW tehoinen lämpölaitos Karbio käyttää uusiutuvaa polttoainetta eli pääasiassa haketta kaukolämmön tuotannossaan. Muut lämpölaitokset (4 kpl) ovat tällä hetkellä fossiilisia polttoaineita käyttäviä, mutta yhtiölle on valmistumassa seuraavan vuoden aikana uusi lämpöpumpputekniikkaa käyttävä lämpökeskus MM Kotkamillssin tehtaan viereen Kotkansaarelle. Lämpöpumppulaitos tulee käyttämään tehtaan hukkalämpöä hyödykseen, kun se tuottaa lämpöpumpuillaan kaukolämpöä Kotkan Energian kaukolämpöverkkoon. Tällä tavalla yhtiö pystyy taas vähentämään fossiilista ja muutakin polttavaa tuotantoaan ja energiantuotantoportfolio monipuolistuu ja tuo lisää optimointimahdollisuuksia.

Yhtiön merkittävä omaisuuserä on kaukolämpöverkosto, jolla jaellaan asiakkaille yhtiön tuottamaa energiaa. Yhtiön kaukolämmöntuotanto tulee uudistumaan tulevina vuosina voimakkaasti lämpöpumppujen, sähkökattilan ja polttamisen vähenemisen vaikutuksesta.

Kaukolämpöverkko ei kumminkaan välitä mistä energialähteestä siihen energia tuotetaan, joten yhtiö pystyy suhteellisen nopeastikin uudistamaan tuotantorakennettaan. Vuonna 2023 kaukolämpöä myytiin asiakkaille 372 GWh. Vuonna 2023 kaukolämpöverkoston pituus oli 202 kilometriä ja vuonna 2024 verkostoa on laajennettu usealla kilometrillä lisää. Yhtiö kerää paljon dataa sen asiakkaiden kaukolämpölaitteista ja kaukolämpöverkostostaan. (Vuosikertomus 2023)

4.2 Datan lähteet

Tässä luvussa kerron Tuotanto-liiketoiminnan tämän tutkimuksen kannalta olennaisista datan lähteistä. Datan mahdollisia hyötyjä mietittäessä täytyy ensin selvittää minkälaisia datan lähteitä yhtiön tuotanto-liiketoiminnalla on saatavanaan. Datan määrä, laatu ja sen tarkoituksenmukaisuus on oleellinen osa toimivaa data-analytiikkaratkaisua. Yhtiöllä on tuotannon operointijärjestelmiä ja sovelluksia kunnonvalvontaa varten. Kriittisyysluokituksia on tehty laajasti laitteille, voimalaitoksille, lämpölaitoksille ja kaukolämpöverkostolle. Dataahan käytetään jo hyödyksi liiketoiminnassa laajasti omissa järjestelmissään eriasteisin automaation astein. DCS-järjestelmän tuottaman datan avulla valvotaan ja operoidaan yhtiön energiantuotantoa ja jakelua. Tässä tutkimuksessa on kuitenkin oleellista miettiä mitä saadaan aikaan datan yhdistämisellä kaikista Tuotanto-liiketoiminnan datan lähteistä yhteen isoon päivittyvään datavarastoon ja suorittamalla tällöin data-analytiikan menetelmiä. Tämän luvun tiedot Tuotanto-liiketoiminnan datan lähteistä on saavutettu omalla empiirisellä tutkimustyöllä paikan päällä tuotantolaitoksilla ja asiantuntijahaastatteluilla valiten yhtiön henkilöstöstä sopivat henkilöt kertomaan datan lähteistä tarkemmin.

Yleisesti ottaen voidaan todeta, että yli 98 % energia-alan datasta koostuu erilaisista mittausdatoista, kun taas muiden osa-alueiden osuus on vähäisempi puhtaan datavolyymin näkökulmasta. Mittausdataa kertyy monipuolisesti eri liiketoimintayksiköistä, kuten verkostoista, lämmöntuotannosta ja sähköntuotannosta. Tämän datan hyödyntäminen edellyttää tehokkaita keinoja sen käsittelyyn laajassa mittakaavassa sekä ennusteiden tuottamiseen käyttötarkoituksen mukaisesti. (Ready 2024)

Energiayhtiöillä, kuten Kotkan Energialla, on valtava koko ajan päivittyvä datamäärä tuotantolaitoksilta, verkostoista ja asiakkailta. Datan volyymimielessä selvästi suurin osa siitä tulee yhtiön DCS-järjestelmistä josta suurin on VALMET DNA järjestelmä. Hajautettu ohjausjärjestelmä (DCS) on tietokonepohjainen automaation ohjausjärjestelmä prosessille tai

tuotantolaitokselle tai voimalalle. Valmet DNA on tulevaisuuden tarpeet huomioiva hajautettu ohjausjärjestelmä (DCS), joka on suunniteltu täyttämään prosessiautomaation vaatimukset eri teollisuudenaloilla, kuten sellutehtaissa, paperikoneissa, energian tuotannossa, merenkulussa ja prosessiteollisuudessa. Valmet DNA:n avulla saat täyden hallinnan kaikista prosesseistasi ja tämä monipuolinen DCS soveltuu prosessiohjauksiin, koneohjauksiin, käyttöohjauksiin, laadunvalvontaan ja kunnonvalvontaan. Tiedonhallinta on saumattomasti integroitu järjestelmään, ja yhtenäinen järjestelmäarkkitehtuuri vähentää kustannuksia ja takaa myös järjestelmän skaalautuvuuden. Valmet DNA-käyttöliittymä mahdollistaa hyvän suorituskyvyn valvomossa ja sen ulkopuolella. Se keskittyy tarjoamaan merkityksellisimmän tiedon kaikille prosessiautomaation käyttäjille. (Valmet DNA, 2024)

Yhtiön Valmet DNA DCS-järjestelmään (vrt. SCADA) on myös liitettynä Valmet DNA Machine Monitoring kunnonvalvontajärjestelmä. Käyttämällä langattomia tai langallisia sensoreita sekä kehittyneitä sovelluksia järjestelmä tarjoaa reaaliaikaista värähtelykunnon seurantadataa, joka on saatavilla missä ja milloin tahansa. Valmet DNA Machine Monitoring-järjestelmää voidaan käyttää itsenäisenä ratkaisuna tai osana Valmet DNA-automaation järjestelmää, jolloin kaikki prosessi- ja kunnonvalvontadata on saatavilla yhdessä järjestelmässä. Valmetin kunnonvalvontaratkaisut tuottavat reaaliaikaista tietoa koneiden kunnosta. (Valmet DNA, 2024)

Kotkan Energialla on käytössä toiminnanohjausjärjestelmä ALMA. ALMA on suomalaisen Vitec Alma Oy:n kehittämä toiminnanohjausjärjestelmää ja sitä käytetään nykyään laajasti erilaisissa tuotantolaitoksissa Suomessa. ALMA on omaisuuden-, tiedonhallinnan ja toiminnanohjauksen tietojärjestelmä. Kaikki Kotkan Energian liiketoiminnot käyttävät ALMAa. Dataa kerätään käyttäjien lisäksi taloushallinnon järjestelmästä, tuntikirjausjärjestelmästä, asiakastietojärjestelmästä ja kaukolämmön verkostotietojärjestelmästä. ALMA otettiin käyttöön 2018 alussa (kunnossapidossa koekäyttöön jo 2017 kesällä). Järjestelmän käyttö on pysynyt vuosien mittaan hyvin vakaana. Käyttöä on arvioitu mm. järjestelmään vuosittain luotujen objektien määrän perusteella. Käyttäjämäärässä ei ole tapahtunut suuria muutoksia. Laadullisesti käyttö on parantunut alkuvuosista ja nykyään asiat kirjataan järjestelmään huolellisemmin. Alkuvuodesta 2020 käyttöönotettu kojelautanäkymä on tuonut järjestelmään kerätyn tiedon paremmin käyttäjien nähtäville. Alla kuvassa havainnollistetaan ALMA järjestelmän liitännäisyyksiä.

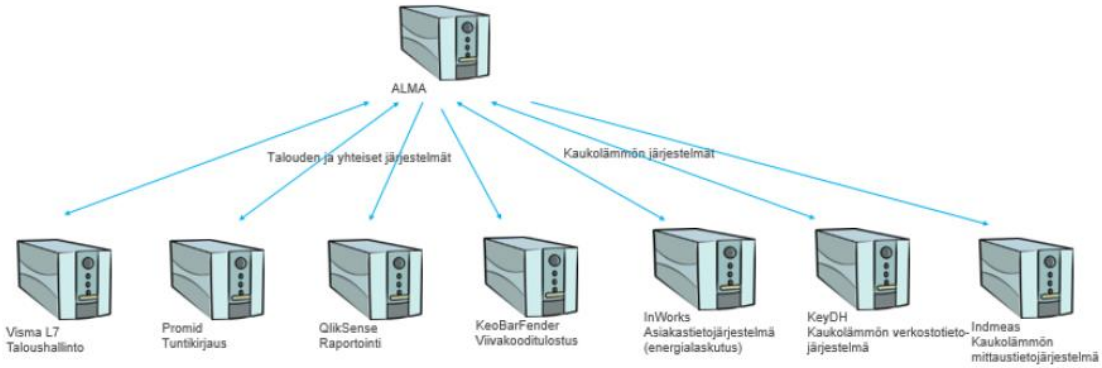

KUVA 8: Alma liitännät (Intra, 2024)

Kotkan Energialla on ALMAssa paljon dataa monesta eri paikasta kootusti paikasta. Järjestelmän käyttöönotto on parantanut merkittävästi töihin ja laitteisiin liittyvää dokumentointia. Muun muassa seuraavia datan lähteitä Kotkan Energialla ALMAssa on:

Tässä luettelo uudelleen järjestettynä loogisemman työnkulun mukaisesti:

- Työturvallisuuden hallinta: riskiarvioinnit, työluvat, turvallisuuskeskustelut

- Hälytykset ja muistutukset

- Korjaava kunnossapito: vika- ja häiriöilmoitukset sekä vikatyöt

- Ennakko- ja seisokkihuoltojen resursointi, suunnittelu, ohjeistus sekä seuranta

- Päivittäiset/viikoittaiset/kuukausittaiset huollot

- Mittavan kunnossapidon analyysit

- Vuoro- ja käyttöpäiväkirja

- Monipuoliset kalenterinäkymät eri tasoille: johto, päälliköt, työnjohto, asentajat

- Kustannusseuranta ja monipuoliset raportit eri tasoille: johto, päälliköt, työnjohto, asentajat

- Varasto- ja materiaalin hallintatoiminnot, viivakooditukset

- Hankinnat ja sopimukset

- Teknisen dokumentaation hallinta

- Toimittaja-, henkilö-, asiakas-, tuote-, aine- yms. rekisterit

- Projektit: tiedonhallinta, suunnittelu, projektien edistymän, toteuman sekä kustannusten seuranta

- Projektien ja suunnittelun tietojen ja dokumentaation haltuunotto

ALMA sisältää siis todella kattavan ja päivittyvän datan lähteen Tuotanto-liiketoiminnan laitteista, verkostosta, asiakkaista ja oikeastaan kaikesta yhtiön toimintaan oleellisesta liittyvästä. Alla kuva joka kuvaa ALMAN toimintoja.

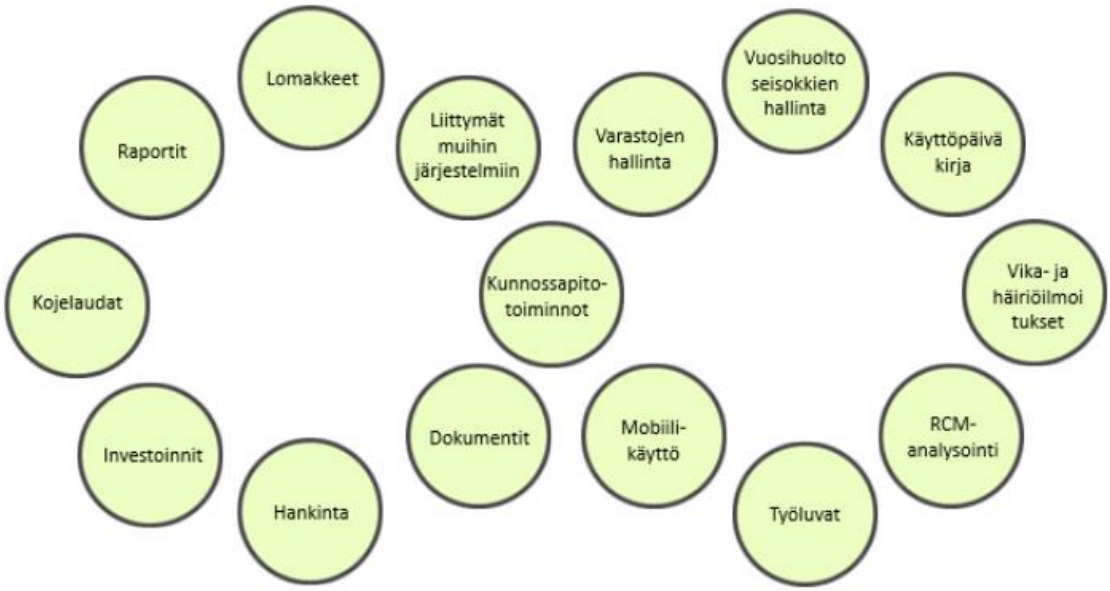

KUVA 9: ALMAn toiminnot (Intra, 2024)

ALMAlla onnistuu myös helposti mobiilikäyttö joten siihen saa hyvin kirjattua omat työt, varasto-otot, kaukolämpölaitteiden asiakaslaitetarkastukset yms. suoraan ”kentällä” ja ne päivittyvät järjestelmään heti.

ALMAsta löytyy kaikki tuotantolaitoksien laitteet tietoineen ja niihin on liitetty vikavaikutusanalyysiin (VVA) perustuva kriittisyysluokittelu. VVA eli vika- ja vaikutusanalyysi on menetelmä, jolla pyritään tunnistamaan viat, jotka heikentävät laitteiden tai järjestelmien suorituskykyä. Analyysi kattaa kaikki mahdolliset vikamuodot, mikä tekee siitä kattavan työkalun. Koneiden ja laitteiden kriittisyyden arviointiin on kehitetty useita menetelmiä, joista yksi on kotimainen PSK-6800-standardi. Tämän standardin mukaan kriittisyys tarkoittaa ominaisuutta, joka kuvaa laitteen riskiin liittyvää vakavuutta. Ennen kriittisyysluokitusta riskit arvioidaan, ja ne voivat liittyä esimerkiksi henkilöstön turvallisuuteen, ympäristöön, tuotannon menetyksiin, korjauskustannuksiin tai muihin ei-hyväksyttäviin seurauksiin. Laite

määritellään kriittiseksi, jos siihen liittyvä riski ylittää hyväksyttävän tason. Riski lasketaan kertomalla tapahtuman todennäköisyys sen seurauksilla.

Alla on kuvattu yhden tuotantolaitteen kriittisyysluokittelu ALMAsta asian havainnollistamiseksi. Kuvasta sensuroitu mahdollisesti liikaa informaatiota tarjoavat seikat.

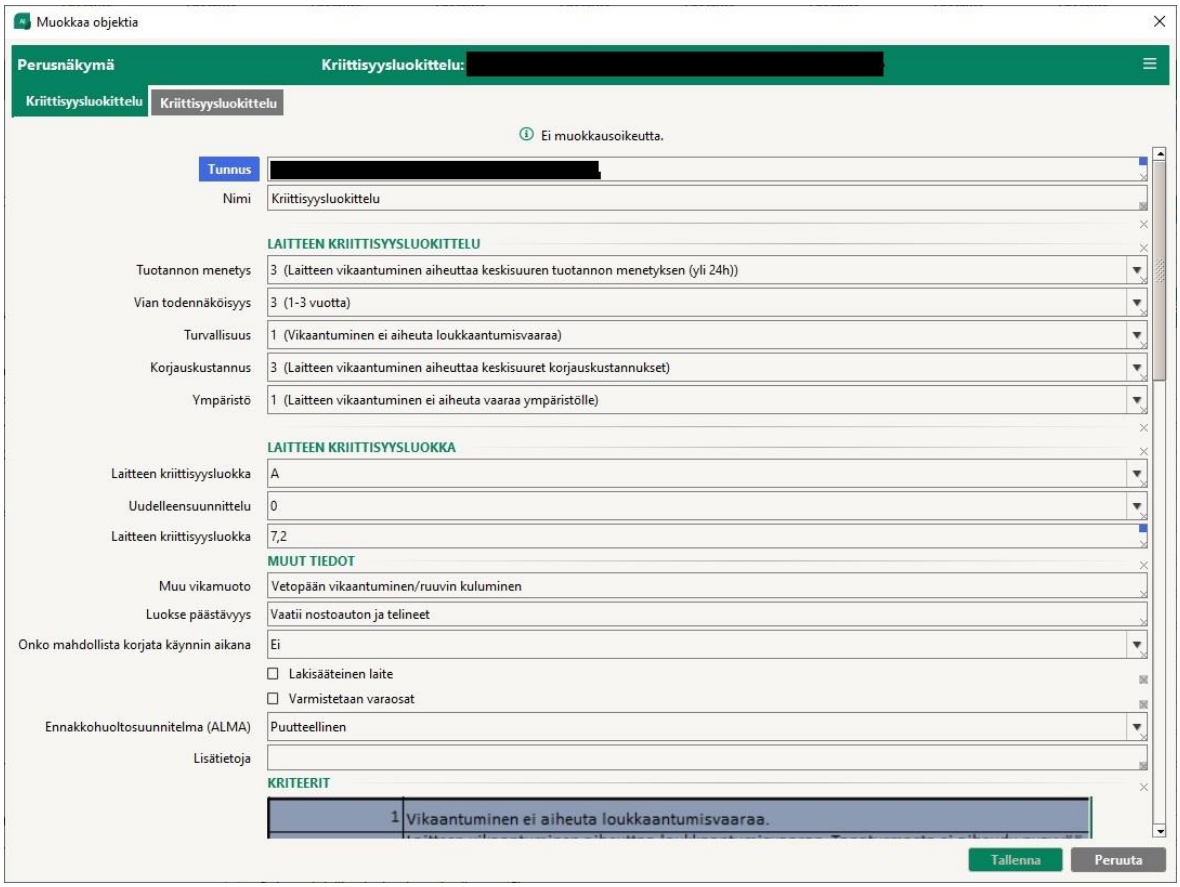

KUVA 10: ALMAsta löytyvä laitteen kriittisyysluokittelu

Kotkan Energialla on käytössään myös TOPi Browser. Se on Fortumin kehittämä helppokäyttöinen verkkoselaintyökalu, joka sisältää raportteja, trendejä, prosessinäkymiä ja erityissovelluksia KPI-arvojen ja mittaustietojen visualisointiin. Se kuuluu osana Fortumin TOPi-energianhallintajärjestelmään. TOPi-järjestelmän käyttöliittymä on verkkopohjainen ja mahdollistaa näin etäkäytön, joka on tärkeää Energia-liiketoiminnan henkilöstölle. TOPia käytetään enemmän Energia-liiketoiminnassa, mutta on oleellinen Tuotanto-liiketoiminnalle myös. Käyttöliittymä sisältää muun muassa raportointia, tietokannan arvojen muokkausta ja uudelleenlaskentoja varten kehitetyt työkalut, tuotannon suunnitteluun ja taloudellisen tilanteen tarkasteluun tarkoitetun Balancer-sovelluksen sekä prosessinäkymien tarkasteluun ja piirtämiseen käytettävän ProView-työkalun. Lisäksi järjestelmässä on erikoispäivien

tarkasteluun ja muokkaamiseen tarkoitettu Calendar-sovellus sekä pääkäyttäjille suunnatut työkalut, kuten käyttäjähallinta. Ohjeita ja laskentakuvauksia varten järjestelmässä on Help-osio. Kaikki tiedot tallennetaan tietokantaan, ja niiden arvoja voi tarkastella useiden vuosien ajalta. Tiedot päivittyvät jatkuvasti tietokannassa ja käyttöliittymässä, joten käyttäjillä on aina pääsy tuoreeseen ja tarkkaan tietoon. Laskelmat suoritetaan automaattisesti eri sykleissä, kuten minuutti-, kymmenminuutti- tai tuntitasolla, ja tulokset sisältävät sekä historiallisia että ennustearvoja. Laskelmat voidaan käynnistää myös manuaalisesti. Tiedonsiirto järjestelmien välillä on pääosin automaattista, mutta se voidaan aloittaa myös manuaalisesti. Hyvin toteutettu tiedonsiirto vapauttaa käyttäjät keskittymään prosessien hallintaan ilman tarvetta siirtää tietoja manuaalisesti esimerkiksi Excel-taulukoiden välillä.

Kotkan Energiassa on myös käytössä IAM käyttövaltuushallintajärjestelmä. IAMissa näkyy henkilöstön käyttöoikeudet, mihin heillä on pääsy ja muun muassa mitä avaimia heillä on.

Kotkan Energialla on käytössään myös erilaisia laitetoimittajien omia järjestelmiä. Haastattelin kunnossapitopäällikköä tutkimukseni aihealuetta koskien ja kysyin samalla näiden laitetoimittajien omien järjestelmien käytöstä ja onko niiden datasta oikeastaan mitään hyötyä nopeaan reagointiin. Seuraavaksi esittelen Kotkan Energian kunnossapitopäällikön vastaukset haastatteluuni muokattuna eheäksi helposti luettavaksi kokonaisuudeksi:

Työssäni käytän useita datan lähteitä, joita hyödynnetään eri tarkoituksiin. Almasta saadaan kunnossapidon dataa, kuten tietoa laitosten käytettävyydestä, suoritetuista kunnossapitotöistä ja kustannusten seurannasta. Lisäksi Almasta löytyy laitteiden huoltohistoria, joka on tärkeä osa kunnossapidon suunnittelua ja analysointia. Alma tarjoaa laajan valikoiman dataa, ja voin näyttää tarkemmin, mitä kaikkea sieltä on mahdollista seurata.

Talouden budjetointiin ja seurantaan käytän FPM-järjestelmää. Vaikka en tunne kaikkia talouden järjestelmiä yksityiskohtaisesti, seuraan FPM:n avulla toteutuneita kustannuksia ja vertaan niitä Almassa oleviin tietoihin, mikä auttaa talouden ja kunnossapidon tietojen yhteensovittamisessa. Lisäksi hyödynnän prosessidataa, kuten värähtelymittauksia, jotka kuuluvat osaksi DCS-järjestelmää.

Määräaikaishuollot eri laitteille nähdään Alman työmääräimiltä, jotka laaditaan itse. Tällä hetkellä kehityksen suuntana on, että laitteen kriittisyys vaikuttaa huolto-ohjelmaan, ja tavoitteena on tarkastella kaikkien laitteiden huolto-ohjelmia laajemmin. Värähtelymittaukset tarjoavat hyvissä ajoin tietoa laitteen kulumisesta tai vikaantumisesta. Näiden mittausten

avulla voidaan arvioida optimaalinen huoltoajankohta hyödyntämällä omaa ammattitaitoa. Tämä toimintamalli ei aina perustu ennalta määriteltyihin määräaikaishuoltoihin, vaan kunnossapitoa tehdään tarpeen mukaan. Esimerkiksi vierintäelimen ulkokehän vikataajuuden nousu voi antaa vihjeitä kulumisesta. Joissain tapauksissa määräaikaishuollot tehdään kuitenkin edelleen laitetoimittajan suositusten mukaisesti, erityisesti turbiinien ja takuunalaisten laitteiden kohdalla.

Tietoa mahdollisesta laitteen vikaantumisesta saadaan useista lähteistä. Ennakkohuoltokierrokset, kuten viikko- ja operaattorikierrokset, ovat edelleen merkittävin vikailmoitusten lähde, sillä ihmisen tekemät tarkastukset tuottavat usein arvokasta tietoa. Lämpökameraa hyödynnetään ennakoivasti esimerkiksi voiteluongelmien tai sähköpuolen vikojen, kuten löysien liitosten, havaitsemiseen. Lisäksi DMM- ja värähtelymittaukset tarjoavat arvokasta tietoa erityisesti pyörivien laitteiden vikaantumisesta jo hyvissä ajoin. Näiden mittausten pohjalta asentajat tekevät analyysin ja antavat arvion laitteen mahdollisesta vikaantumisajankohdasta, mikä tukee ennakoivan kunnossapidon suunnittelua ja toteutusta.

Käytän useiden laitetoimittajien verkkosivupohjaisia järjestelmiä, kuten TGS, Atlas Copco, Konecranes, Aistio ja Woikoski, mutta näistä ei tällä hetkellä saada merkittävää apua reagoivan eikä ennakoivan kunnossapidon tarpeisiin. Reagoivan kunnossapidon vastuu on täysin meidän omalla vastuullamme. Atlas Copcon järjestelmä on poikkeus, sillä se lähettää suoraan tiedon, jos koneessa ilmenee vika. Tätäkään järjestelmää ei kuitenkaan seurata aktiivisesti tai päivittäin laitetoimittajan toimesta, vaan vastuu tietojen käsittelystä jää meille.

Pitkän aikavälin näkökulmasta monet näistä järjestelmistä tarjoavat hyödyllistä tietoa, erityisesti talouden hallinnan kannalta. Niiden avulla voidaan seurata, kuinka paljon eri kunnossapitotoimia on tehty vuosittain ja kuinka paljon rahaa niihin on käytetty. Tämä tukee kunnossapidon suunnittelua ja budjetointia. Lisäksi järjestelmät auttavat sopimusten ylläpidossa, sillä niistä on helppo tarkastaa sopimusten voimassaoloaika ja sisältö. Tätä tietoa seurataan myös omissa järjestelmissämme, kuten Almassa, joten nämä laitetoimittajien järjestelmät täydentävät kokonaiskuvaa ja tukevat pitkäjänteistä kunnossapidon suunnittelua.

Kunnossapitopäällikön haastattelu tarjosi kattavan näkymän tämän hetken datan hyötyihin ja käyttöön kunnossapitotoiminnassa. Seuraavaksi kerron kaukolämpöpuolen datan lähteistä. Kotkan Energialla on laaja kaukolämpöverkko, jonka piirissä on yli 30 000 ihmistä ja monia isoja teollisia ja kaupan alan asiakkaita. Tästä asiakasmassasta on valmiiksi paljon

dataa ja siitä tulee jatkuvasti lisää. Perusasiakas ja verkkotiedot löytyvät Key DH:sta (nykyisin Key Heat). Se on Kotkan Energian kaukolämmön verkostotietojärjestelmä. Täältä löytyy muun muassa eri putkien koot, materiaalit ja asennusvuosi. Alla näyttökuva, josta rajattu pois infoa nykyisen maailmantilanteen vuoksi, havainnollistamaan Key Heat näkymää.

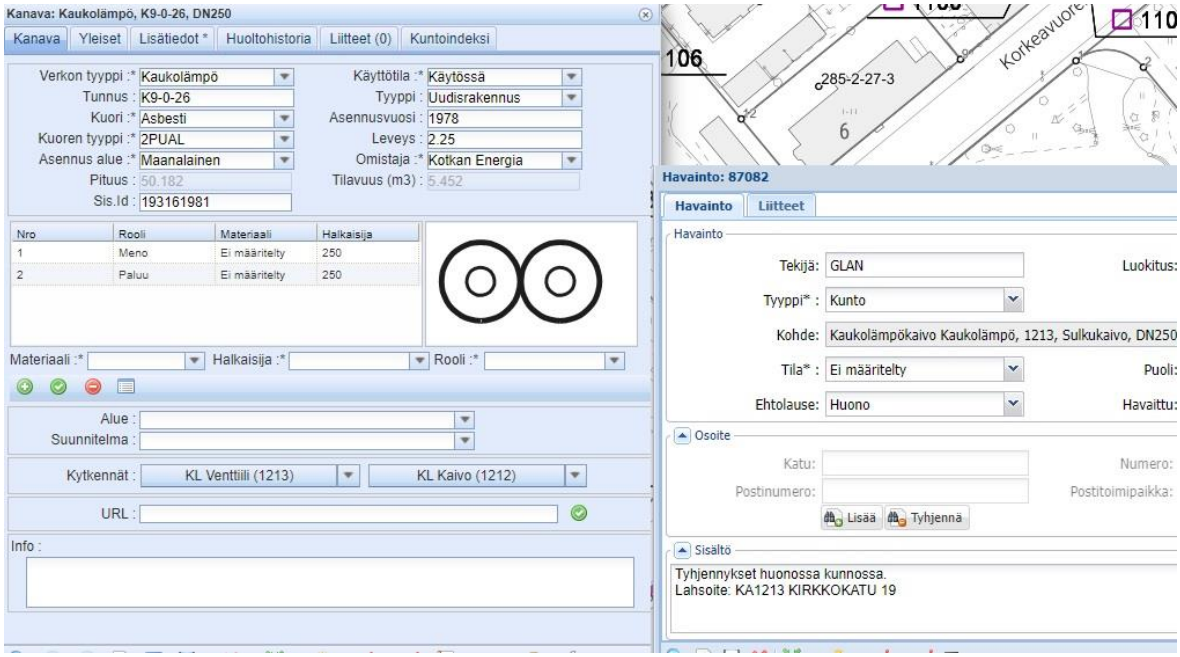

KUVA 11: Key Heat (Intra 2024)

Aistio järjestelmää käytetään KL-kaivovalvontaan (kaukolämpökaivo) ja lämmönjakohuoneessa antamaan tietoa kaukolämpöpaketin eri arvoista ja verkoston toiminnasta. Yhteys toteutettu LoRaWan tekniikalla. KL-kaivoissa mitataan mm. veden pintaa, lämpötilaa ja ilman kosteutta. Näistä pystyy havaitsemaan mahdolliset vuodot. Mittauspisteitä ei ole lähellekään kaikissa KL-kaivoissa. Myöskään Aistio-dataa ei tule, kun pienestä osaa lämmönjakohuoneista. Aistion data on todella informatiivista ja kohteita siihen lisätään koko ajan, joten tällä datalla on potentiaalia olla tehokkaan data-analytiikan lähteenä. Alla kaksi kuvaa havainnoimaan KL-kaivon mittauksia ja lämmönjakohuoneen mittauksia.

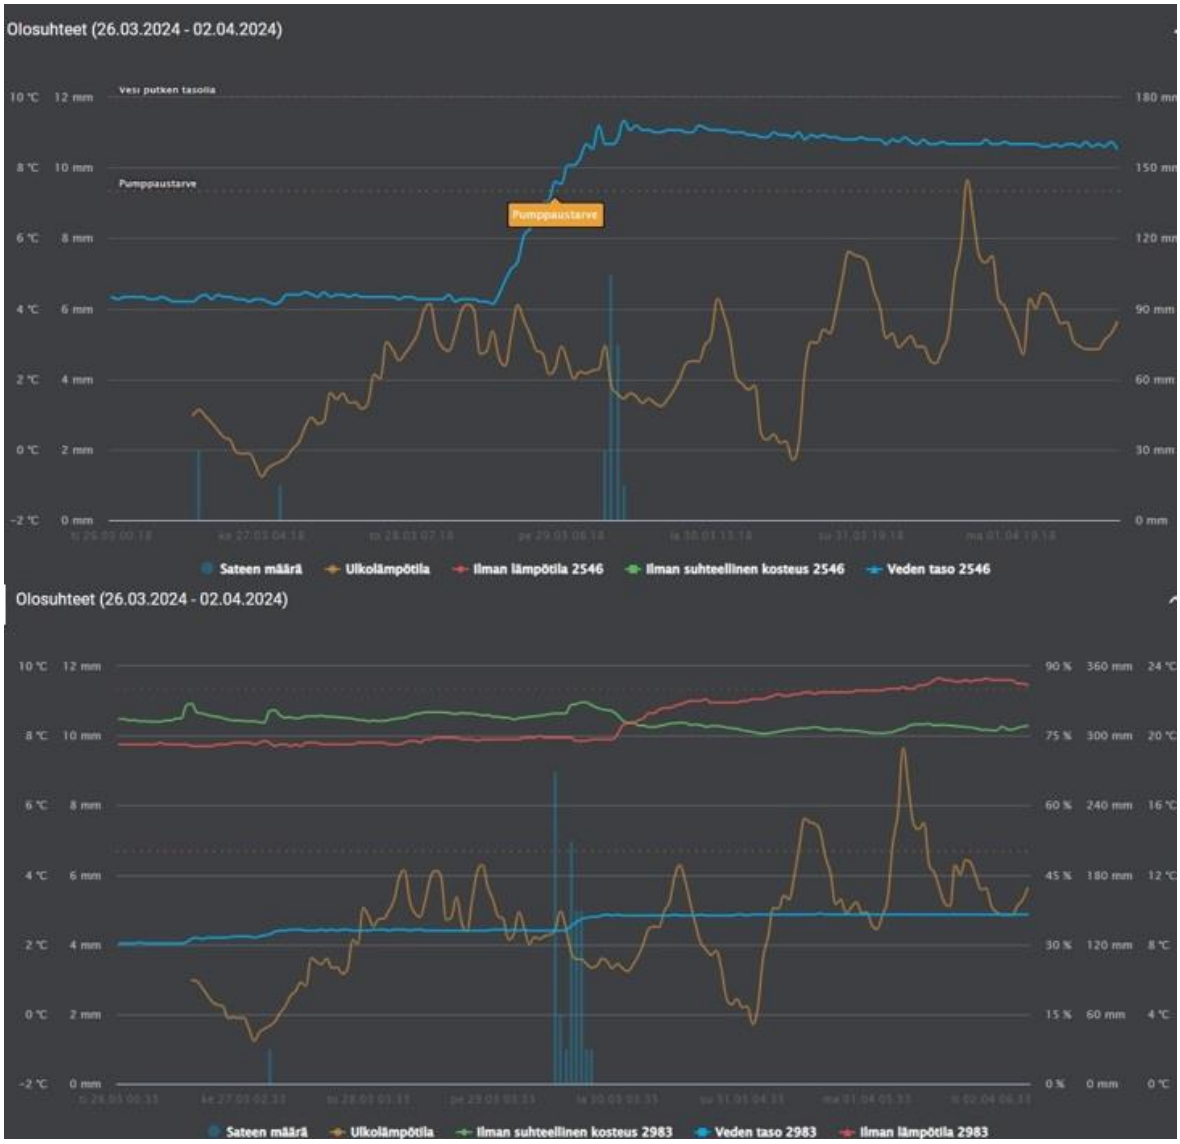

KUVA 12: KL-kaivojen mittaustietoa aistiosta (Intra 2024)

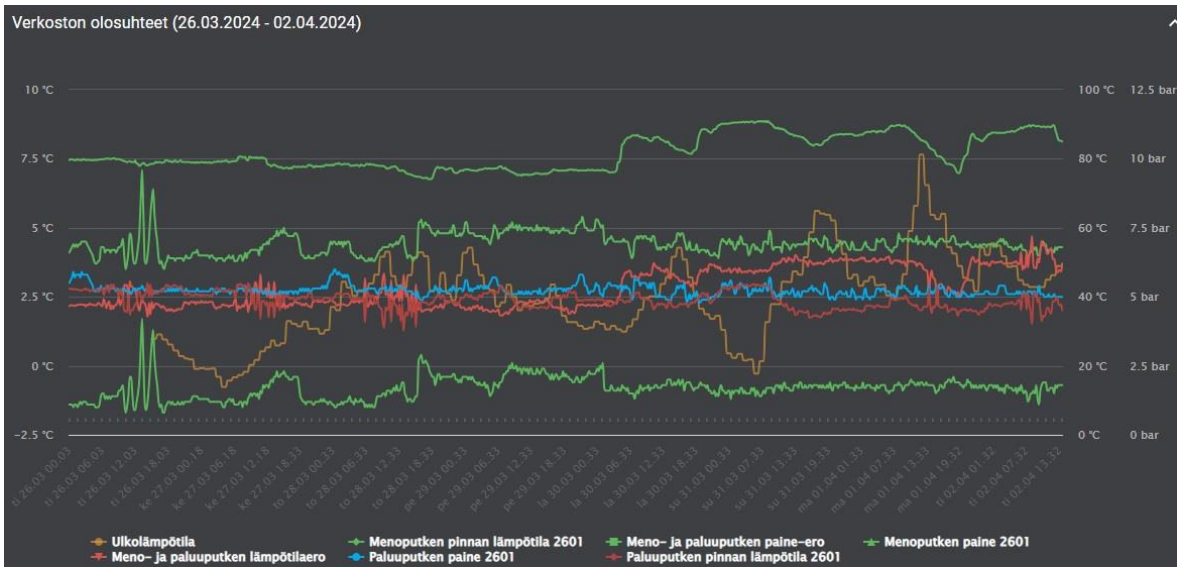

KUVA 13: Lämmönjakohuoneen mittausdataa kaukolämpöverkostosta (Intra 2024)

Kaukolämpöasiakkaiden mittarien luentaan käytetään Kamstrup READy Manageria. Kamstrup READy Manager on helppokäyttöinen PC-ohjelmisto ja sovellus lämpö-, jäähdytys- ja vesimittarien datan käsittelyyn. Käytännössä kuinka uusi kaukolämpöpaketti asiakkaalla on määrittää sen onko kuinka nopean mittarinluennan piirissä. Kaukolämpömittareiden luennat suoritetaan 2g/4g tekniikalla tai radio luennalla. Noin 2300 asiakasta on kuukausiluennan piirissä eli mittarit luetaan vain kerran kuussa. Vanhojen mittarien tiedot liikkuvat radioyhteyksien kautta 1 kerran kuukaudessa ja luentakierros kestää noin 8 tuntia. Suuri osa mittareista on pattereilla toimivia. Patterit kuluvat enemmän luennassa, joten siksi luenta tahtia ei kannata lisätä. Muuten täytyisi käydä asentajien vaihtamassa pattereita mittareihin useasti. Kerran vuorokaudessa tehtävän mittauksen piirissä on noin 1000 asiakasta. Tuntiluennan piirissä on noin 150 asiakasta, mutta tämä uusien nopeiden mittarien määrä kasvaa koko ajan nopeasti. Näillä uusilla mittareilla voisi lukea dataa useamminkin, mutta siihen ei ole nähty tarvetta. Nopeiden mittauksien määrä tulee kasvamaan vuosivuodelta, kun asiakaslaitteet vaihtuvat luonnollisesti uudempiin Tämä nopeiden mittauksien määrän kasvu tekee datasta käyttökelpoisempaa data-analytiikan tarpeisiin.

Visma ohjelmistoja käytetään Kotkan Energialla laajasti talouden alueella. Täältä pystyy hakemaan tarvittavat taloudelliset tiedot data-analyysien tueksi.

Tässä luvussa olen kertonut Case-yhtiön Tuotanto-liiketoiminnan datan lähteistä ja seuraavassa tutkimuksen johtopäätökset-luvussa yhdistän aiemman tutkimuksen ja keräämäni tiedot aiheesta tähän energiayhtiön tuotanto-liiketoimintaan saadakseni vastaukset tutkimuskysymyksiin ja saavuttaakseni tutkimuksen tavoitteet.

5 Tulokset ja johtopäätökset

Tässä luvussa käydään läpi tämän diplomityön tulokset ja johtopäätökset vastaamalla tutkimuskysymyksiin. Tämä tutkimus asetti tavoitteekseen selvittää, millä tavoin data ja data-analytiikka voivat tuottaa taloudellisia hyötyjä energiayhtiöiden tuotantoliiketoiminnassa. Erityisesti tutkimuksessa keskityttiin tunnistamaan keskeiset datan lähteet, niiden hyödyntämismahdollisuudet sekä arvioimaan analytiikan käytännön vaikutuksia taloudelliseen tehokkuuteen, operatiiviseen toimintaan ja päätöksentekoon.

Tutkimuskysymykset:

1. Mitä datan lähteitä on hyödynnettävissä?

2. Mihin tarkoituksiin tätä dataa voitaisiin hyödyntää?

3. Mitkä ovat data-analytiikan taloudelliset hyödyt energiayhtiön tuotantoliiketoiminnassa?

Näihin tutkimuskysymyksiin vastaaminen tapahtui kirjallisuusanalyysin, asiantuntijahaastatteluiden ja tapausesimerkkien avulla. Kaikkiin tutkimuskysymyksiin saatiin kattavat vastaukset ja konkreettisia taloudellisia hyötyjä case-yhtiön Tuotanto-liiketoiminnalle löytyi paljon. Tutkimus vastasi asetettuihin tavoitteisiin kattavasti. Se toi esiin konkreettisia esimerkkejä siitä, kuinka data-analytiikkaa voidaan hyödyntää energiayhtiöissä taloudellisten hyötyjen saavuttamiseksi. Yhtenäisen ja keskitetyn datavaraston luominen on kriittinen askel datan hyödyntämisen maksimoimiseksi. Tämä varasto mahdollistaa erilaisten datalähteiden yhdistämisen, analysoinnin ja hyödyntämisen tehokkaasti. Tällainen infrastruktuuri tukee sekä lyhyen aikavälin operatiivista päätöksentekoa, kuten ennakoivaa kunnossapitoa, että pitkän aikavälin strategista suunnittelua, esimerkiksi budjetoinnissa ja investointien kohdentamisessa. Tämän tutkimuksen sisällöstä havaitaan, että data-analytiikka on loistava työkalu nykyaikaisille energia-alan organisaatioille. Sen avulla yhtiöt voivat tehostaa kunnossapitotoimintaa, parantaa omaisuudenhallintaa, optimoida prosessejaan ja tunnistaa uusia mahdollisuuksia liiketoiminnassaan. Seuraavaksi esitelen tässä luvussa laajasti tutkimuksen tulokset ja johtopäätökset.

Energiayhtiöiden datan lähteet ovat monimuotoisia, ja niitä on käyty läpi tässä diplomityössä kattavasti. Yksi keskeinen datan lähde on omaisuustiedot, jotka sisältävät tuotantolaitosten

ja niiden laitteiden yksityiskohtaisia teknisiä tietoja. Tämä käsittää keskeiset tiedot tuotantolaitoksista, laitteista, verkostosta, polttoainevarastoista ja lisäksi varastotiedot tarjoavat tietoa varaosien ja materiaalien saatavuudesta, mikä on olennaista kunnossapidon ja huoltojen suunnittelussa.

Käyttötieto muodostaa toisen tärkeän tiedonkeruukokonaisuuden. Prosessiautomaation, kuten DCS- ja SCADA-järjestelmien, tuottama reaaliaikainen data on tässä keskiössä. Näistä järjestelmistä saadaan mittaustietoja, kuten lämpötila-, paine-, virtaus- ja värähtelyarvoja. Lisäksi laitteiden tilatiedot, kuten käytettävyys ja häiriöilmoitukset, ovat kriittisiä operatiivisessa päätöksenteossa. Käyttötietoon kuuluu myös manuaalinen data, kuten operaattoreiden ja kunnossapitohenkilöstön tekemät havainnot ja kirjaukset. Kunnossapidon ja tarkastusten data on olennainen osa energiayhtiöiden tiedonhallintaa. Tämä sisältää esimerkiksi laitteiden huoltohistorian, jossa dokumentoidaan kaikki aiemmat kunnossapitotoimenpiteet, korjaukset ja havaitut viat. Lisäksi kunnonvalvonnasta saadaan tarkkaa tietoa esimerkiksi värähtelyanalyysien, lämpökuvauksien ja ultraäänimittausten avulla. Työmääräimet ja huolto-ohjelmat auttavat puolestaan priorisoimaan kunnossapidon toimenpiteitä kriittisyyden perusteella ja takaamaan toimintojen jatkuvuuden. Asiakastiedot tarjoavat tärkeää informaatiota energiankulutuksesta ja asiakassopimuksista.

Ulkoinen avoin data tuo lisäarvoa energian tuotannon optimoinnissa ja markkinadynamiikan ymmärtämisessä. Esimerkiksi säädata, kuten tuulen nopeus, lämpötila ja aurinkosäteilyn voimakkuus, ovat tärkeitä energian tuotannon suunnittelussa, optimoinnissa ja kaupankäynnissä. Markkinadata, kuten Nord Poolin sähkön hintatiedot ja futuurimarkkinat vaikuttavat suunnittelemaan energian tuotannon optimointiin.

Näiden datalähteiden avulla pystytään tehdä kattavia data-analyysejä eri tekniikoin. Jokainen lähde tuo oman tärkeän lisänsä kokonaisuuteen ja tukee liiketoiminnan tavoitteiden saavuttamista. Tuotantoympäristöstä kerättyä dataa voidaan käyttää uusien tietojen tuottamiseen vikatilanteista ja prosessin pullonkauloista. Teollisuus käy läpi neljättä teollista vallankumousta, kun sensorit ja laitteet yhdistetään Internetiin. Kerätty data voidaan jalostaa data-analytiikan ja koneoppimisen keinoin, mikä luo uutta arvoa yrityksille (Nykyri, 2018). Seuraavaksi käyn kattavasti läpi mihin tarkoituksiin näitä datan lähteitä voidaan hyödyntää.

Koneoppiminen on erityisen hyödyllistä, kun analyysin tavoitteena on tunnistaa monimutkaisia kaavoja tai tehdä tarkkoja ennusteita suurista datamääristä. Koneoppimismallit voivat

oppia ja parantaa suorituskykyään jatkuvasti ilman manuaalista ohjelmointia. Voimalaitoksilla voidaan ennakoivien huoltomallien avulla analysoida sensoreiden keräämää dataa ja ennustaa laitteiden vikaantuminen, mikä vähentää odottamattomia seisokkeja. Automatisoitu oppiminen vähentää ihmisen työmäärää ja lisää analyysin tarkkuutta (Goodfellow et al., 2016).

De Fabritiis et al. (2024) tutkimus "A Self-supervised Learning Approach for Anomaly Detection in Rotating Machinery" avasi hyvin tekoälyn ja koneoppimisen mahdollisuuksia energia-yhtiön tuotanto-liiketoiminnalle. Tutkimuksessa kehitettiin ja testattiin itseohjautuvaan oppimiseen perustuva koneoppimismalli. Tarkemmin sanottuna kyseessä on itseohjautuvaa oppimista (self-supervised learning) hyödyntävä syväoppimismalli, joka soveltuu erityisesti anomaliantunnistukseen pyörivissä koneissa. Datan avulla havaittiin laakerien vaurioitumisen eri vaiheet, kuten sisäkehän ja ulkokehän viat. Tämä on suoraan verrattavissa energiayhtiöiden tarpeisiin, joissa esimerkiksi moottoreiden, pumppujen, turbiinien, kompressoreiden tai generaattorien laakereiden seuranta on kriittistä toimintakatkosten ehkäisemiseksi. Tutkimuksen malli on erityisen sopiva tilanteisiin, joissa on paljon raakadataa mutta vain vähän manuaalisesti merkittyä dataa. Malli on tehokas ja skaalautuva, ja se tarjoaa huipputeknologisen lähestymistavan teollisuuden kunnonvalvonnan tarpeisiin. Mallin kyky käsitellä sekä yksittäisten antureiden että koneen tason yhdistettyä dataa osoittaa sen soveltuvuuden laajasti erilaisiin teollisiin sovelluksiin. Tämä joustavuus tekee mallista hyödyllisen monimutkaisissa järjestelmissä, kuten energiayhtiöiden voimalaitoksissa, joissa on useita eri antureita kunnonvalvontaa varten. Malli pystyy tehokkaasti havaitsemaan poikkeavuuksia tästä datasta. Tutkimuksessa esitetty koneoppimismallin kyky havaita laitteiden viat varhaisessa vaiheessa mahdollistaa nopean reagoinnin ja ennakoivan kunnossapidon.

Zhu, A. et al. (2023) tutkimuksessa "Condition monitoring of wind turbine based on deep learning networks and kernel principal component analysis" keskityttiin pääasiassa tuuliturbiinien kunnonvalvontaan ja poikkeavuuksien havaitsemiseen SCADA-datan avulla, mutta sen menetelmillä ja lähestymistavalla on selkeästi potentiaalia myös muissa teollisissa sovelluksissa. Vaikka tutkimus ei suoraan käsittele muita käyttömahdollisuuksia, menetelmän yleispätevyys ja modulaarisuus tekevät siitä sovellettavan erilaisiin ympäristöihin, joissa pyörivien koneiden ja monimutkaisten järjestelmien kunnonvalvonta on kriittistä. Tutkimuksen kehittämä KPCA–CNN–LSTM-malli ja analyysimenetelmät ovat mielestäni selkeästi sovellettavissa muihin pyöriviin koneisiin ja teollisuuden järjestelmiin, joissa

monimutkaisten ja epälineaaristen prosessien kunnonvalvonta on tarpeellista. Menetelmä soveltuu esimerkiksi höyry- ja kaasuturbiinien, generaattoreiden, kompressoreiden, pumppujen, sähkömoottoreiden ja muiden kriittisten teollisuuslaitteiden kunnonvalvontaan.

Kamat et al. (2024) tutkimuksessaan käsitteli laakereiden jäljellä olevan käyttöiän (RUL) ennustamista hyödyntämällä tärinädataa ja syväoppimista. Tutkimuksen menetelmä ja käyttämä data keskittyvät laakereihin, jotka ovat kriittisiä pyörivissä koneissa. Vaikka tutkimuksessa ei suoraan mainita tiettyjä käyttökohteita kuulalaakereiden sovelluskohteita ovat tyypillisesti esimerkiksi erilaiset teollisuuden koneet. Kuten pumput, kompressorit ja puhaltimet, jotka ovat yleisiä voimalaitoksissa ja prosessiteollisuudessa. Tutkimuksessa kehitetty lähestymistapa laakereiden RUL-ennustamiseen ja poikkeavuuksien havaitsemiseen soveltuu erinomaisesti energia-alan sovelluksiin, joissa laitteiden, kuten pumppujen, puhaltimien ja kompressoreiden, kunnossapito on kriittistä toimintavarmuuden ja taloudellisen tehokkuuden kannalta. Energia-alan kriittiset laitteistot käyttävät laakereita, jotka altistuvat jatkuvalle kulutukselle, ja niiden tarkka kunnonvalvonta voi estää vakavia vikoja ja toimintahäiriöitä. Kehitetty malli voisi hyödyntää energia-alan DCS- ja SCADA-järjestelmiä, jotka keräävät jatkuvasti valtavia määriä dataa. Soveltamalla tutkimuksen menetelmiä DCS- ja SCADA-järjestelmiin voitaisiin analysoida reaaliaikaista dataa ja tuottaa tarkkoja ennusteita laitteiston tilasta ja jäljellä olevasta käyttöiästä.

Idea datan käytön mahdollisuudesta kaukolämpöpuolella. Käytön optimointityökalun tarjoamista asiakkaille keillä on uudempi kaukolämpöpaketti mistä saa riittävästi ja riittävällä nopeudella päivittyvää dataa. Voisi olla sellainen, että tiettyinä päivinä asiakas saisi kaukolämpönsä edullisemmin, jos leikkaisi kulutusta kalliimmilta tuotantotunneilta. Eli siis niiltä tunneilta, jotka ovat kalleimpia kaukolämmöntuottajalle. Tämä olisi kummallekin osapuolelle kannattava diili. Kaukolämmöntuotannossa tuotannon hinta voi vaihdella todella paljon eri tuotantovälineiden välillä. Esimerkkinä kotitalousjäte polttoaineena on ilmaista tai tarkemmin sanottuna siitä saa rahaa ja öljyn polttaminen maksaa tällä hetkellä noin 110 € MWh. Kaukolämmönkulutus on yleensä suurinta aamulla ja illalla ja muuten siihen vaikuttaa sää. Sellaisessa kaukolämmöntuotannon tilanteessa, jossa joudutaan lämmöntuotantokapasiteetissa siirtymään seuraavaan kalliimpaan tuotantotapaan. Edellisenä päivänä saa tietää sähkön hinnat seuraavalle päivälle ja myös sääennuste on aika tarkka päivän päähän, joten tällöin tiedettäisiin seuraavan päivän ajotilanne tietyllä tarkkuudella. Havaittaessa tunteja, joilla joudutaan siirtymään huomattavasti kalliimpaan tuotantotapaan, pystyttäisiin tarjoamaan

asiakkaalle näitä tunteja, joista leikatulla energiankulutuksella hän saisi muun sen vuorokauden kaukolämmön halvempaan hintaan. Tästä kalliimpien kaukolämmöntuotantotuntien kulutusjoustosta hyötyisi kumpikin, tuottaja eli myyjä ja asiakas eli ostaja, osapuoli.

Kaukolämpöpuolella data-analytiikan menetelmiä voidaan käyttää laajemmin, kun datan määrä ja laatu paranee. Uudempia mittareita asennetaan koko ajan enemmän, joten tämä laajempi mahdollisuus tulee kyllä tulevaisuudessa eteen. Aistion kaivovalvonta datasta saadaan helposti viitteitä kaukolämpövuodoista ja näidenkin mittauspaikkojen määrä on kasvussa. Kaukolämpöpuolella verkostotasolla data-analytiikkaa voitaisiin käyttää automaattiseen joustokapasiteetin ja varastointipotentiaalien laskentaan. Tarkemman mittausdatan asiakaskohteissa voidaan data-analytiikan keinoin määrittää jokaiselle kaukolämpöasiakkaalle alhaisimman riittävän tulolämpötilan vuoden jokaiselle tunnille. Tämä mahdollistaa kaukolämpöverkon menolämpötilan hallitun alentamisen ja nopeuttaa järjestelmän mukautumista uusien kaukolämmönvaihtimien mitoitussuositusten mukaisiin lämpötiloihin. Data-analytiikan avulla voidaan saada myös tietoa kunkin asiakaskohteen vaikutuksesta kaukolämpöverkon kokonaispaluulämpötilaan ja virtauksiin, mikä perustuu prosessi- ja asiakasdatan yhdistämiseen. Poikkeama-analytiikalla on mahdollista tunnistaa asiakkaat, joiden lämmönjakolaitteiden suorituskyky tai lämmönsaanti on heikentynyt tai joiden toiminnassa ilmenee poikkeamia. Näiden analyysien avulla voidaan paikantaa vialliset tai tehottomasti toimivat laitteet ja usein ennakoida mahdolliset laiterikot ennen kuin ne aiheuttavat ongelmia asiakkaalle. Poikkeamien havaitseminen perustuu kulutuksen, jäähtyvyyden ja paluulämpötilan muutosten analysointiin.

Kotkan Energialla on tarkoituksena tulevaisuudessa rakentaa iso kaukolämpövarasto joten sen optimaaliseen käyttöön data-analytiikan keinot auttaisivat varmasti. Itselläni on mielessä ollut pienempi kaukolämpöakku, jonka etuna olisi pieni investointikustannus, pieni tilantarve, joka mahdollistaa sen sijoittamisen nykyisten tuotantolaitoksien yhteyteen, ja se, että sillä pystyisi hyödyntämään todella hyvin nykyistä sähkömarkkinatilannetta optimoimalla sen lämmön purkamista ja lataamista muun muassa sähkön hintojen mukana. Seuraavana kesänä Hovinsaarelle valmistuu 30 MW sähkökattila, jonka optimaaliseen ajoon data-analytiikan keinoin voi myös päästä. Tämä sähkökattila korostaa tuota pienemmän kaukolämpöakun kannattavuutta, koska käytännössä suurimman osan vuoden päivistä pystyisi kierrättämään pienen kaukolämpöakun koko lämpövaraston arvon. Tämä tietenkin niin, että

lataus tapahtuu halvimpaan tuotantoaikaan ja purku kalleimpaan tai silloin kuin lämmölle on tarve. Nopea varastonkierto nostaa pääoman tuottoa merkittävästi.

Data-analytiikan keinoja voisi käyttää tuotantolaitoksilla myös suorituskyvyn parantamiseen. Tarkemmin sanottuna helppoa olisi nykyisen teknologian, mittauksien ja datan avulla havaita suorituskyvyn alenemat poikkeama-analytiikan avulla. Case-yhtiön tuotantolaitoksista kerätään jatkuvasti suuri määrä mittausdataa energiantuotantoprosesseista ja se tallennetaan ja tämä historiadata tarjoaa hyvin arvokasta tietoa suorituskyvyn parantamiseen ja virheiden analysointiin. Poikkeama-analyysillä voidaan esimerkiksi tunnistaa normaalista poikkeavat tilat. DCS:n historiadatasta saadaan data-analyysin tueksi kattava määrä ajotilanteita, josta malli oppii mitkä arvot ovat normaaleita missäkin tilanteessa. Kun malli havaitsee poikkeamaa tästä historiasta niin se ilmoittaa siitä. Poikkeamat ovat suurella todennäköisyydellä jollakin tapaa jonkin laitteen tai prosessin suorituskyvyn alenemaa ja/tai jonkin laitteen alkavaa hajoamista/vikaantumista. Yhtenä esimerkkinä, laajasta mahdollisuuksien joukosta, esitän tässä vaikkapa kattilan suorituskyvyn laskemisen havainnoinnin mahdollisuutta. Historiadatasta malli on voinut oppia eri tilanteiden, esimerkiksi kattilan eri tehoalueiden, normaalit lämpötilamittauksien tasot tulipesässä ja savukaasukanavassa. Kun tässä tulee poikkeamaa normaalista, voidaan havaita lämmönsiirtokyvyn heikkenemistä eli suorituskyvyn alenemista. Kattilan lämmönsiirtopinnat ovat todennäköisesti likaantuneet. Lämpötilamittauksista ja savukaasukanavan eri kohtien paine-eromittauksista voidaan myös havaita esimerkiksi nuohoustarvetta likaisuuden ja tukkoisuuden takia. Eri asioita voi havaita monista eri muuttujista. Edellä mainittuja asioita voi kyllä havaita osaava ihminenkin, mutta se on laajasti ajateltuna huomattavasti työläämpää. Poikkeama-analytiikka voi havainnoida aivan koko tuotantojärjestelmän kaikkia prosesseja ja laitteita koko ajan ja ilmoittaa näistä poikkeamista viipymättä. Tällöin asiantuntijat saavat tiedot mahdollisista ongelmista ajoissa ja hyvin tehokkaasti. Kyseisen poikkeama data-analytiikan potentiaalinen hyödyntämisalue on todella laaja ja merkittävä Tuotanto-liiketoiminnassa. Taloudellisten hyötyjen potentiaali on merkittävä suorituskykyongelmien nopeiden korjaamisista seuraavien kustannussäästöjen kautta.

Myös neuroverkkopohjaisia digitaalisia kaksosia voi käyttää edellisessä kappaleessa kuvattuihin asioihin. Digitaaliset kaksoset tunnistavat prosessin epätavallisen toiminnan ja poikkeavat mittaukset, mikä auttaa myös erottamaan toisistaan merkitykselliset ja virheelliset hälytykset. Neuroverkkopohjaiset digitaaliset kaksoset voivat myös ehdottaa ajotilanteeseen

sopivia parametreja tai ne voivat jopa ohjata tuotantoa suoraan. Digitaalisia kaksosia voidaan käyttää myös esimerkiksi perehdytyksessä ja käyttäjäkoulutuksessa, joka voisi olla arvokasta uusia voimalaitosoperaattoreita kouluttaessa ja olemassa olevien operaattoreiden osaamisen ylläpidossa.

Data-analytiikkaa voidaan mielestäni käyttää myös taajuusmuuttajista saatavaan dataan. Jostain syystä näistä ei löytynyt oikeastaan yhtään esimerkkiä aiemmasta tutkimuskirjallisuudesta tai edes asiantuntijahaastatteluista, vaikka ne mittaavat laajasti eri parametrejä ja keräävät dataa. Tähän minulla ei siis ole mitään lähdettä, mutta ihan ajattelemalla kerättäviä parametreja ja yhdistämällä niitä mahdollisiin tuotantoprosesseihin päädyin tällaiseen varmasti oikeaan päätelmään. Energiayhtiöissä ja muissakin suurissa tuotantoyhtiöissä sähkömoottoreita ohjataan nykyään yleensä taajuusmuuttajalla. Etenkin niitä tärkeimpiä ja kalleimpia sähkökäyttöjä ohjataan taajuusmuuttajilla. Nykyiset taajuusmuuttajat tarjoavat monipuolisia ominaisuuksia, joiden avulla voidaan tallentaa tietoa niiden toiminnasta käytön aikana. Näitä mittaustietoja voitaisiin hyödyntää tehokkaasti myös ennakoivan kunnossapidon tarpeisiin. Esimerkiksi virran tai vääntömomentin muutoksia analysoimalla olisi mahdollista tulkita, millainen vika saattaisi olla kehittymässä. Tämä täydentäisi erinomaisesti värähtely- ja lämpötilamittauksista saatuja tuloksia ja niihin perustuvia analyyseja. Data-analytiikan keinoin olisi mahdollistaa yhdistää mittaustiedot taajuusmuuttajasta, joka ohjaa sähkömoottoria, joka pyörittää pumppua ja näistä analytiikan keinoin, erityisesti tekoälypohjaisilla syväoppimistekniikoilla, saada hyvinkin mielenkiintoista ennustavaa tietoa. Tuotantojärjestelmän vikatilanteissa taajuusmuuttajilta tallennettua dataa voitaisiin käyttää apuna vikatilanteiden selvittämisessä. Tallennetun datan avulla voitaisiin vikatilanteiden lisäksi ennakoida mahdollisia tulevia vikoja ja myös optimoida laitteiden operointia. Tallennettua dataa taajuusmuuttajilta voidaan hyödyntää myös laitoksien ja prosessien suunnitteluvaiheessa analysoimalla kuormitettavuutta erilaisissa tilanteissa. Tämän analyysin perusteella voidaan välttää hankintavaiheessa tehtävät taajuusmuuttajan yli- tai alimitoitukset ja näin tehdään onnistuneempi investointi. Myös taajuusmuuttajan mahdollista hajoamista voidaan pyrkiä havaitsemaan lämpötilamittauksilla taajuusmuuttajasta tai vaikkapa lämpökamerakuvan perusteella yhdistäen ne taajuusmuuttajan käyntitietoihin ja analysoimalla poikkeavan tilan eli mahdollisen vikaantumisen. Tällöin on mahdollisuus välttää suuria tuotannollisia tappioita, kun tuotannolle kriittisten laitteiden mahdolliset vikaantumiset huomataan ajoissa ja reagoidaan tilanteeseen parhaalla mahdollisella tavalla.

Seuraavassa kappaleessa vielä yhteenvetona tiiviimmin mihin tarkoituksiin energiayhtiöt voisivat dataa hyödyntää.

Tuotannon optimointi keskittyy maksimoimaan nykyisten tuotantolaitteistojen tuoton ja minimoimaan kulut. Mallintamalla tuotantojärjestelmää huomioiden esimerkiksi sääolosuhteet, polttoaineiden hinta ja laatu sekä sähkömarkkinahintojen kehitys, voidaan määritellä optimaalisia tavoitearvoja, jotka ohjaavat tuotantojärjestelmiä toimimaan tehokkaasti. Näiden optimointien avulla voidaan reagoida nopeasti markkinamuutoksiin, kuten sähkön hinnan vaihteluihin, ja optimoida esimerkiksi polttoaineiden käyttöä ja energian tuotantoa. Data-analytiikka vähentää manuaalisen työn tarvetta, mikä mahdollistaa enemmän tuotoksia pienemmällä työmäärällä. Lisäksi analytiikka parantaa toiminnan laatua, mahdollistaa tarkemman priorisoinnin ja lisää resurssien käyttöastetta. Kunnossapidon resursseja voi kohdentaa eri tavalla ja käyttää vain todellisen tarpeen mukaan. Tekoälyn ja koneoppimisen sovellukset energiayhtiöissä ovat laajoja. Ennakoivat mallit, kuten käyttöiän (RUL) ennusteet ja juurisyyanalyysit, tarjoavat uusia mahdollisuuksia kunnossapidon ja resurssien hallintaan. Vikaantumisennusteiden avulla voidaan toteuttaa ennakoivaa kunnossapitoa, mikä lisää laitteiden käyttöikää. Neuroverkkopohjaiset digitaaliset kaksoset tarjoavat mahdollisuuden tunnistaa prosessien epätavallisia toimintoja ja kohdistaa huomiota kriittisiin poikkeamiin. Tämä mahdollistaa tarkemmat ennusteet ja resurssien tehokkaamman hyödyntämisen. Reunalaskennan (Edge AI) avulla voidaan tunnistaa virheitä ja reagoida niihin lähes välittömästi. Tekoälyä hyödynnetään myös varaosien tarpeen ennustamiseen, optimoitujen huoltoaikataulujen luomiseen ja kunnossapidon prosessien automatisointiin. Tulevaisuudessa tekoäly tulee entistä enemmän integroitumaan kunnossapitäjien päivittäiseen työhön, kuten mobiilikameroiden ja mikrofonien avulla tapahtuvaan toiminnan dokumentointiin ja analysointiin. Data-alustat ja pilvipalvelut ovat keskeisessä roolissa mahdollistamassa tätä siirtymistä tekoälyn käyttöön. Keskitetyt data-alustat, jotka yhdistävät eri tietolähteet, mahdollistavat tehokkaamman analyysin ja tiedon visualisoinnin yhteen järjestelmään. Näiden ratkaisujen avulla yritykset voivat hyödyntää yhdenmukaista ja tarkkaa tietoa päätöksenteossaan ja auttaa seuraamaan tuotannon etenemistä suhteessa suunnitelmiin.

Seuraavaksi kerron mitkä ovat data-analytiikan taloudelliset hyödyt energiayhtiön tuotantoliiketoiminnassa.

De Fabritiis et al. (2024) tutkimuksessa esitetty koneoppimismalli tarjoaa energiayhtiöille merkittäviä taloudellisia etuja, erityisesti kunnossapidon ja operatiivisen tehokkuuden

osalta. Mallin kyky havaita laitteiden viat varhaisessa vaiheessa mahdollistaa nopean reagoinnin ja ehkäisee odottamattomia käyttökatkoksia, mikä vähentää merkittävästi tulonmenetyksiä ja estää pienten vikojen kehittymisen laajoiksi ja kalliiksi vaurioiksi. Tämä puolestaan tukee ennakoivaa kunnossapitoa, jossa huoltotoimenpiteet tehdään vain tarvittaessa, vähentäen turhia huoltotoimia ja optimoiden resurssien käyttöä. Varhainen vianhavaitseminen myös pidentää kriittisten laitteiden käyttöikää, mikä vähentää tarvetta suuriin pääomainvestointeihin. Mallin avulla energiayhtiöt voivat ylläpitää keskeytyksetöntä kannattavaa energiantuotantoa. Tämä edistää koko tuotannon sujuvuutta ja varmistaa korkeamman tuottavuuden. Koska malli analysoi datasta johdettua tietoa tehokkaasti, se tukee myös päätöksentekoa sekä operatiivisella että strategisella tasolla. Mallin integrointi osaksi teollista IoT-järjestelmää mahdollistaa useiden laitteiden datan yhdistämisen, tarjoten kokonaisvaltaisen näkymän laitoksen tilasta ja toimintojen hallinnasta. Kunnonvalvontadatan hyödyt energiayhtiölle ovat täten selviä käyttäessä tällaista koneoppimismallia data-analytiikassa. Mallin avulla energiayhtiö voi siis vähentää kokonaiskustannuksia, tehostaa tuotantoa ja saavuttaa pitkän aikavälin kannattavuutta sekä kestävää kilpailukykyä.

Zhu, A. et al. (2023) tutkimuksessa keskityttiin poikkeavuuksien havaitsemiseen SCADA-datan avulla. Mallin kyky käsitellä monimutkaista ja suurta datamäärää sekä tarjota varhaisia varoituksia mahdollisista vioista olisi selkeästi arvokasta diplomityöni Case-energiayhtiön Tuotanto-liiketoiminnalle, jossa DCS-dataa on käytetty ja kerätty vuosikausia. Case-yhtiön datan keruu tuotantolaitteista, jakeluverkosta ja asiakkaiden laitteista on lisääntynyt vuosi vuodelta kiihtyvään tahtiin ja tuotantolaitoksien kriittisimmät laitteet on varusteltu värähtely ja lämpötilamittauksin. Datan ja mittaavien sensorien määrä jatkaa kasvuaan tulevaisuudessa nopeasti, joten menestyksekkäälle data-analytiikalle on oiva mahdollisuus. Reaaliaikaisen mittauksen, datan keräämisen ja analysoinnin avulla on mahdollista toteuttaa ennakoivaa kunnossapitoa tehokkaasti eli oikea aikaisesti niin, että vältetään tuotannolle tärkeiden laitteiden hajoaminen ilman turhaa resurssien, työ ja materiaali, tuhlaamista liiallisella tai liian vähäisellä kunnossapidolla. Tällä vältetään myös tuotannon suunnittelemattomat alasajot ja kalliit tuotannonsiirrot vaihtoehtoisiin kalliimpiin tuotantovälineisiin.

Varhaisen poikkeavuuksien tunnistamisen avulla energiayhtiöt voisivat ajoittaa ennakoivan kunnossapidon huoltotoimenpiteet tarkasti ennen vakavia vikoja, mikä vähentäisi turhia huoltoja, käyttökatkoksia ja kunnossapitokustannuksia. Tämä mahdollistaisi kriittisten laitteiden käyttöiän pidentämisen, mikä vähentäisi varaosien hankinnan ja suurien

pääomainvestointien tarvetta. Optimointi heijastuisi myös energiantuotannon tehokkuuteen, koska kannattavimpien tuotantolaitteiden toiminta olisi jatkuvasti huipputasolla, mikä vähentäisi esimerkiksi kalliiden ja ympäristölle haitallisten fossiilisten polttoaineiden kulutusta ja parantaisi näin monella tavalla yhtiöiden kannattavuutta. Yhteenvetona data-analytiikan suurimmat taloudelliset hyödyt energiayhtiön Tuotanto-liiketoiminnassa syntyvät ennakoivasta kunnossapidosta, resurssien tehokkaasta käytöstä, suorituskyvyn laskun havainnoinnista, investointien oikea-aikaisuudesta ja suunnittelemattomien alasajojen välttämisestä syntyvistä kustannussäästöistä ja tuotannon optimoinnista.

Diplomityössäni esiteltävien data-analytiikkamenetelmien soveltaminen tukisi myös riskienhallintaa, sillä sen avulla voitaisiin vähentää laitteistovikojen aiheuttamia ympäristö- ja turvallisuusriskejä. Tämä on erityisen tärkeää energia-alalla, joka toimii tiukasti säännellyssä ympäristössä. Pitkällä aikavälillä ennakoivan kunnossapidon mahdollistava data-analytiikka auttaisi energiayhtiöitä säästämään merkittäviä summia huolto- ja käyttökatkoskustannuksissa, samalla kun se parantaisi tuotannon tehokkuutta ja laitosten turvallisuutta. Näin energiayhtiöt voisivat yhdistää teknologisen edistyksen ja taloudellisen tehokkuuden luodakseen kestävämpiä ja kannattavampia liiketoimintamalleja.

Energiayhtiössä tutkimuksessani esiteltyjä menetelmiä ja ideoita voisi aluksi tehdä pilotti-projekteina tärkeimmissä kunnonvalvontasensoreita käsittävissä laitteissa ja sen jälkeen laajentaa kattavaksi kunnossapidon ja tuotannon valvontajärjestelmäksi, joka hyödyntää data-alustalle kerättyä DCS/SCADA-dataa, omaisuus- ja asiakastietoja ja ulkoista oleellista dataa ja käyttää tekoälyä data-analytiikassa koko yhtiön mittakaavassa.

6 Yhteenveto

Teknologian nopea kehitys on avannut uusia mahdollisuuksia tiedolla johtamisessa. Data-analytiikka mahdollistaa organisaatioiden operatiivisien toimintojen optimoinnin ja parantaa kustannustehokkuutta. Energiayhtiöiden pääomaintensiivinen liiketoiminta edellyttää tehokasta omaisuudenhallintaa ja data-analytiikkaratkaisujen hyödyntäminen kiinnostaa yhtiöitä. Nykyajan energiayhtiön tuotanto-omaisuuden hallinta ei perustu pelkästään nopeisiin korjauksiin, vaan tietoon ja osaamiseen perustuvaan strategiseen johtamiseen. Ennakoiva kunnossapito ja vikaantumisen ehkäisy ovat nousseet keskeisiksi tavoitteiksi. Tämän lähestymistavan avulla voidaan vähentää huoltokustannuksia, parantaa laitteiden luotettavuutta ja lisätä yrityksen kilpailukykyä. Digitalisaation ja teollisuuden esineiden internetin (IoT) kehitys ovat tuoneet uusia mahdollisuuksia. IoT mahdollistaa anturien avulla kalliiden laitteiden toimintakunnon jatkuvan seurannan, ja kerätty valtava datamäärä voidaan analysoida operatiivisten, taktisten ja strategisten päätösten tukemiseksi. Data-analytiikka on noussut kriittiseksi työkaluksi energiayhtiöille.

Tässä tutkimuksessa tarkasteltiin data-analytiikan hyödyntämistä energiayhtiön tuotanto-liiketoiminnassa ja sen tuottamia taloudellisia hyötyjä. Tutkimus toteutettiin kirjallisuuskatsauksen, asiantuntijahaastatteluiden ja tapaustutkimuksen yhdistelmänä. Tämän diplomityön tavoitteena oli selvittää mitä konkreettisia taloudellisia hyötyjä datasta on energiayhtiön Tuotanto-liiketoiminnalle ja sitä kautta koko yhtiölle. Diplomityön tavoitteeseen pyrittiin pääsemään selvittämällä oleelliset datan lähteet, mihin tarkoituksiin tätä dataa voitaisiin hyödyntää ja mitkä ovat data-analytiikan taloudelliset hyödyt energiayhtiön tuotantoliiketoiminnassa.

Yhteenvetona voidaan todeta, että tutkimus saavutti tavoitteensa tarjoamalla selkeän kokonaiskuvan energiayhtiön käytettävissä olevista datalähteistä ja niiden hyödyntämismahdollisuuksista. Tutkimuksessa löydettiin konkreettisia esimerkkejä siitä, miten datan yhdistäminen ja data-analytiikka voivat tukea ennakoivaa kunnossapitoa, resurssien käytön ja prosessien optimointia ja päätöksenteon parantamista. Tutkimuksen rajoituksina oli aihealueen laajuus, jonka takia tutkimus piti rajoittaa ainoastaan Tuotanto-liiketoimintaan ja taloudellisiin hyötyihin. Tutkimuksessa ei myöskään käyty kaikkia mahdollisia hyötyjä ja data-analytiikan soveltamiskeinoja läpi, koska niitä on todella paljon aihealueen laajuuden takia.

Tulevaisuuteen riittää siis vielä paljon tutkittavaa aiheesta. Data-alustan ja data-analytiikan käytöstä olisi myös varmasti paljon hyötyä koko yhtiölle ja muillekin liiketoiminnoille. Niissä data-analytiikkaa onkin varmasti helpompi ottaa käyttöön ja käyttää, koska muiden liiketoimintojen prosessit ja itse data ovat huomattavasti yksinkertaisempia. Tutkimuksen käytännön toteutuksissa korostui erityisesti modernien data-alustojen ja analytiikkatyökalujen rooli, jotka mahdollistavat tiedon tehokkaan jalostamisen ja hyödyntämisen päätöksenteon tukena.

Tutkimuksen tulokset osoittavat, että datan keruu ja analytiikka voivat tuottaa merkittäviä taloudellisia hyötyjä energiayhtiöille. Teoreettisesti tutkimus vahvistaa tiedolla johtamisen ja omaisuudenhallinnan periaatteiden tärkeyttä ja tuo esiin data-analytiikan mahdollisuudet niiden toteuttamisessa. Käytännön tasolla tutkimus tarjoaa hyödyllisiä suosituksia energiayhtiöille, jotka haluavat hyödyntää dataansa tehokkaammin taloudellisen hyödyn saavuttamiseksi. Tutkimuksen tulokset osoittavat, että data-analytiikka ei ainoastaan tehosta energiayhtiöiden operatiivista toimintaa, vaan myös tukee strategista päätöksentekoa, parantaa kunnossapitoa ja lisää tuotannon kannattavuutta. Sen avulla energiayhtiöt voivat siirtyä reaktiivisista toimintamalleista ennakoivaan ja optimoituun toimintaan, mikä on olennaista tulevaisuuden energiamarkkinoilla menestymiselle. Tulevaisuudessa teknologisten ratkaisujen kehitys, kuten digitaalisten kaksosten hyödyntäminen ja edistynyt koneoppiminen, voivat tuoda entistä suurempia hyötyjä energiayhtiöille, jotka pyrkivät parantamaan operatiivista tehokkuuttaan ja kilpailukykyään. Tämän työn johtopäätökset antavat yhtiöille selkeät suuntaviivat kohti datavetoisempaa tulevaisuutta.

Vanha sanonta kuuluu: "Tieto on valtaa" – ei data tai informaatio, vaan tieto. Maailmassa, jossa meillä on lähes rajoittamaton määrä dataa käsiemme ulottuvilla, juuri se, miten kokoamme, yhdistämme ja sovellamme tätä informaatiota, synnyttää tietoa. Ja toivottavasti lopulta myös viisautta.

Lähteet

Ahmed, I., Ahmad, M., Chehri, A., & Jeon, G. (2023). A Smart-Anomaly-Detection System for Industrial Machines Based on Feature Autoencoder and Deep Learning. *Micromachines*, *14*(1), 154. https://doi.org/10.3390/mi14010154

Álvarez, V. L., Castillón, D. C., Martín, J. C., Damaso, P.-M. S. & Martínez, Á. R. (2020). Automation Trends in Industrial Networks and IIoT. Teoksessa: Industrial IoT: Challenges, Design Principles, Applications, and Security. Springer International Publishing.

Davenport, T. H., & Harris, J. G. (2017). Competing on Analytics: The New Science of Winning. Harvard Business Review Press.

Carvalho, T. P. et al. (2019) A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & industrial engineering*. [Online] 137106024-.

De Fabritiis, F. and Gryllias, K. (2024) "A Self-supervised Learning Approach for Anomaly Detection in Rotating Machinery", *Annual Conference of the PHM Society*, 16(1). doi: 10.36001/phmconf.2024.v16i1.3911.

Dong J., Wang, J. and Guo, R. (2019) Remaining useful life prognostics for the electro-hydraulic actuator using relevance vector machine and optimized on-line incremental learning. MATEC Web of Conferences 277 article no: 02009.

Duffuaa, S. O., Raouf, A. (2015) Planning and Control of Maintenance Systems Modelling and Analysis. 343 s. Springer, Sveitsi.

Gavrikova, E., Volkova, I. & Burda., Y. (2021) Implementing asset data management in power companies. International Journal of Quality & Reliability Management, Vol. aheadof-print

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

Gross, John, M. 2008. Fundamentals of preventive maintenance. New York, American Management Association.

Han, J., Kamber, M., & Pei, J. (2011). Data Mining: Concepts and Techniques. Morgan Kaufmann.

Hartmann, P. M. et al. (2016) Capturing value from big data – a taxonomy of data-driven business models used by start-up firms. International journal of operations & production management. [Online] 36 (10), 1382–1406.

Hastings, N.A.J. (2014) Physical asset management – with an introduction to ISO 55000. 2nd edition. Springer International Publishing Switzerland. 540p.

Hussain, M. et al. (2023) Adoption of big data analytics for energy pipeline condition assessment - A systematic review. The International journal of pressure vessels and piping. [Online] 206105061-.

Intra (2024) Yhtiön sisäinen suljettu verkko

ISO 55000 (2014) Asset Management – Overview, Principles and Terminology, International Organization for Standardization, BSI London, UK.

Järviö, J. & Lehtiö, T. (2017) Kunnossapito – tuotanto-omaisuuden hoitaminen. 6. täydennetty painos. Helsinki: Promaint ry

Kamat, P. et al. (2024) Vibration-based anomaly pattern mining for remaining useful life (RUL) prediction in bearings. Journal of the Brazilian Society of Mechanical Sciences and Engineering. [Online] 46 (5), .

Kanawaday, A. and Sane, A. (2017) Machine learning for predictive maintenance of industrial machines using IoT sensor data. In: 2017 8th IEEE International Conference on Software Engineering and Service Science (ICSESS), pp. 87–90.

Kotkan Energiaverkot (2024), https://www.kotkanenergia.fi/kotkan-energia/kotkan-energiaverkot-oy/

KotkaGas (2024), https://www.kotkanenergia.fi/kotkan-energia/kotkagas-oy/

KotkaTec (2024), https://www.kotkanenergia.fi/kotkan-energia/kotkatec-oy/

Kortelainen, H., Räikkönen, M., Komonen, K. (2015) “Corporate asset management-a semi-quantitative business-driven approach to support the evaluation of improvement options”,

International Journal of Strategic Engineering Asset Management, Vol. 2 No. 2, pp. 208-222.

Laihonen, H., Hannula, M., Helander, N., Ilvonen, I., Jussila, J., Kukko, M., Kärkkäinen, H., Lonnqvist, A., Myllärniemi, J., Pekkola, S., Virtanen, P., Vuori, V., & Yliniemi, T. (2013). Tietojohtaminen. Tampereen teknillinen yliopisto - Tiedonhallinnan ja logistiikan laitos.

Little, R. J. A., & Rubin, D. B. (2014) *Statistical Analysis with Missing Data*. Wiley.

McKinney, W. (2017) Python for Data Analysis. O'Reilly Media.

Markkula, T. & Syväniemi, A. (2015) Analytiikkamatka: datasta tietoon ja tiedolla johtamiseen. Suomen liikekirjat.

Marlow, D. R. & Burn, S. (2008) Effective use of condition assessment within asset management. Journal - American Water Works Association. [Online] 100 (1), 54–63.

Mobley, K., R. (2005) Maintenance Fundamentals. 416. p. Burlington, Elsevier Inc.

Mikkonen, H. et al. (2009) Kuntoon perustuva kunnossapito : käsikirja. Helsinki: KP-Media.

Nykyri, M. (2018) Data analytics for predictive maintenance in a pulp mill — case electric motors. Master’s Thesis

PAS55 standard. (2008) Asset Management. London, British Standards Institution.

Promaint (2024) Kunnossapitoyhdistys Ry, internet sivut, www.promaint.net

Provost, F., & Fawcett, T. (2013) Data Science for Business. O'Reilly Media.

Ratia, M. (2022) Arvonluontia analytiikalla: Käsikirja analytiikan johtamiseen. Helsinki, Basam Books Oy.

Ready (2024) (https://readysolutions.fi/mita-on-energia-alan-data-analytiikka/)

Runkler, T. (2016) Data Analytics Models and Algorithms for Intelligent Data Analysis. 2. painos. Wiesbaden, Springer Fachmedien Wiesbaden.

Russell, S., & Norvig, P. (2020) Artificial Intelligence: A Modern Approach. Pearson.

Schuman, C. A. & Brent, A. C. (2005) Asset life cycle management: towards improving physical asset performance in the process industry. International journal of operations & production management. [Online] 25 (6), 566–579.

Somerville David, McLeod Hugh (2016) https://www.analytikus.com/post/2016/04/06/a-favorite-datarelated-cartoon

Vaara, V., Pitkänen, M., Hämäläinen, T. (2014) Wind turbine sensor data analysis and production forecast. UKSim-AMSS 8th European Modelling Symposium on Computer Modelling and Simulation, EMS 2014, art. no. 7154017, pp. 309-314

Valmet DNA (2024) https://www.valmet.com/automation/control-systems/dna/

Vuosikertomus (2023) https://www.kotkanenergia.fi/kategoria/vuosikertomus2023/

Zarsky, T. Z. (2016) "The Trouble with Algorithms: An Analysis of the Ethical Issues Associated with Automated Decision Making." Science and Engineering Ethics.

Zhang, Z. & Zhang, P. (2015) Seeing around the corner: an analytic approach for predictive maintenance using sensor data. Journal of management analytics. [Online] 2 (4), 333

Zhu, A. et al. (2023) Condition monitoring of wind turbine based on deep learning networks and kernel principal component analysis. *Computers & electrical engineering*. [Online] 105108538-.