Tampereen yliopisto

Ville Kumpulainen

KONEOPPIMISMALLIT RESERVIMARKKINOILLE OSALLISTUVAN LÄMPÖVARASTON OHJAUKSESSA

Reservimarkkinahintojen ennustaminen

Kandidaatintyö
Tekniikan ja luonnontieteiden tiedekunta
Tarkastaja: Seppo Syrjälä
9/2023

TIIVISTELMÄ

Ville Kumpulainen: Koneoppimismallit reservimarkkinoille osallistuvan lämpövaraston ohjauksessa, reservimarkkinahintojen ennustaminen
Machine learning models in control of thermal energy storage participating in reserve markets, forecasting reserve market prices
Kandidaatintyö
Tampereen yliopisto
Tekniikan ja luonnontieteiden TkK-tutkinto-ohjelma, ympäristö- ja energiatekniikka
Elokuu 2023

Sääriippuvaisen uusiutuvan energian lisääntyessä sähköjärjestelmän tasapainon ylläpitäminen on entistä haasteellisempaa. Tasapainon ylläpitämiseksi erilaiset nopeasti reagoivat, sähköntuotantoon tai -kulutukseen kykenevät resurssit voivat tarjota joustoa, eli reserviä, jota kantaverkko-operaattorit hankkivat itselleen reservimarkkinoilta. Sähkölämmitteiset lämpövarastot ovat merkittäviä sähkönkuluttajia, ja voivat näin ollen tarjota merkittävän määrän reserviä samalla ansaiten parempia tuottoja. Reservimarkkinahintojen riittävän tarkka ja luotettava ennustaminen on edellytyksenä reservimarkkinoille osallistuvan lämpövaraston kustannustehokkaalle ohjaukselle. Tässä työssä selvitetään millaisia koneoppimismalleja voitaisiin hyödyntää reservimarkkinahintojen ennustamisessa. Lisäksi tutkitaan millaisia yleisiä suunnitteluvaiheita reservimarkkinahintojen ennustamiseen käytettäville koneoppimismalleille on. Työn tarkoituksena on toimia aloituspisteenä reservimarkkinahintoja ennustavan koneoppimismallin suunnittelulle.

Jopa puolet maailman energiankulutuksesta kulutetaan lämpönä. Lämpövarastot voivat olla merkittävässä roolissa vihreässä siirtymässä mahdollistaen kulutuspiikkien tasaamisen sekä lämmityksen sähköistymisen. Polar Night Energyn ensimmäisessä laatuaan olevassa hiekkalämpövarastossa lämpö voidaan varastoida korkeaan, jopa 600 °C lämpötilaan, joka mahdollistaa lämmön toimittamisen esimerkiksi kaukolämmön ja useimpien teollisuuden prosessien tarpeisiin.

Lämpövaraston toimintaa ohjaavat pääasiassa asiakkaan lämmöntarve, sähkön spot-hinta sekä varaston varaustaso. Lämpövarastoa pyritään ohjaamaan niin, että varastoa ladataan sähkön hinnan ollessa matalalla ja puretaan asiakkaan tarpeiden mukaisesti. Reservimarkkinoille osallistuvan lämpövaraston kohdalla myös reservimarkkinahinnat ovat merkittävä osatekijä ohjauksessa, sillä niiden ennustaminen mahdollistaa kaikista tuottoisimpien tuntien sekä markkinoiden valinnan.

Sähkö- ja reservimarkkinahintojen ennustuksessa käytetyimpiä ennustusmenetelmiä ovat tilastolliset ja koneoppimismenetelmät, ja niiden suorituskykyä usein verrataan keskenään. Tilastollisten ja koneoppimismallien teorian lisäksi työssä tutustuttiin erilaisiin tarkkuusmittareihin, joilla ennustusmenetelmien tarkkuutta voidaan mitata.

Työssä perehdyttiin reservimarkkinahintojen ennustusta koskevaan tutkimukseen mahdollisimman laajasti ja lisäksi myös sähkömarkkinahintojen ennustamista koskevaan tutkimukseen. Molempien kohdalla syvät neuroverkot antoivat parhaita tuloksia, ja useimmissa tutkimuksissa koneoppimismallit päihittivät ennustustarkkuudessa tilastolliset verrokkimallinsa. Tutkimuksissa nostettiin esiin myös ongelmia, jotka heikentävät sähkö- ja reservimarkkinahintojen ennustusta käsittelevien tutkimusten vertailukelpoisuutta. Ongelmina olivat muun muassa erilaisten datajoukkojen, ohjelmistototeutusten ja tarkkuusmittareiden käyttö, kehittyneiden mallien vertaaminen yksinkertaisiin malleihin ja liian lyhyet testausdatan pituudet. Näitä ei tässä työssä kyetty ottamaan huomioon työn laajuuden vuoksi, mutta kun tehdään päätöksiä eri tutkimuksissa esiintyvien mallien keskinäisen vertailun pohjalta, on kyseiset ongelmat syytä ottaa huomioon.

Työssä tunnistettiin myös useissa tutkimuksissa esiintyneitä koneoppimismallien suunnitteluvaiheita, joita olivat algoritmin valinta, datan ja ulkoisten tekijöiden valinta, aikasarja-analyysi, datan esikäsittely, mallin validointi, tarkkuusmittarien valinta, hyperparametrien optimointi ja tulosten tilastollisen merkittävyyden toteaminen.

Avainsanat: Lämpövarasto, reservimarkkinat, ennustusmenetelmät, koneoppiminen

Tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck –ohjelmalla.

SISÄLLYSLUETTELO

1. JOHDANTO 1
2. LÄMPÖVARASTON TOIMINTA 3
2.1 Lämpövarastojen luokittelu 3
2.2 Polar Night Energyn hiekkalämpövaraston toiminta 5
3. SÄHKÖ- JA RESERVIMARKKINAT 9
3.1 Yhtenäiset sähkömarkkinat 9
3.2 Reservimarkkinat 10
3.3 Taajuusohjatut käyttö- ja häiriöreservit 12
3.4 Lämpövarasto reservimarkkinoilla 16
4. ENNUSTUSMENETELMÄT 18
4.1 Tilastolliset mallit 18
4.2 Koneoppimismallit 19
4.3 Ennustusmenetelmien tarkkuuden arviointi 24
5. RESERVIMARKKINAHINTOJEN ENNUSTAMINEN KONEOPPIMISMALLILLA 27
5.1 Aiheeseen liittyvä tutkimus 27
5.2 Koneoppimismallin suunnitteluvaiheet 32
6. JOHTOPÄÄTÖKSET 36
LÄHTEET 38

.

1. JOHDANTO

Maailman tähdätessä kohti hiilineutraaliutta joudutaan suuri määrä fossiilista energiantuotantoa korvaamaan hiilineutraaleilla vaihtoehdoilla. Fossiiliset energiamuodot ovat kallistuneet ja uusiutuvat energiamuodot ovat halventuneet (Jaller-Makarewicz, 2021). Suomessa esimerkiksi tuulivoimahankkeita oli 11/2022 meneillään eri vaiheissaan yhteensä n. 66 GW edestä (Suomen Tuulivoimayhdistys ry, 2022), kun vertailun vuoksi sähkön kulutus Suomessa 31.1.2023 oli korkeimmillaan noin 10,6 GW (Fingrid, 2023a). Sääriippuvaisen tuotannon lisääntyessä sähköverkon tarjonnan epäsäännöllisyys ja volatiliteetti lisääntyvät merkittävästi. Tätä vastaan suojautumiseksi kysynnän jousto on käytännöllinen ratkaisu. (Golmohamadi et al., 2022, luku 1.1) Sähkölämmitteiset lämpövarastot ovat yksi toimija sähköverkon kysyntäpuolella, jotka voivat tarjota tätä joustoa.

Fingrid huolehtii sähköjärjestelmän toiminnasta ja varmistaa tuotannon ja kulutuksen tasapainon muun muassa ylläpitämällä reservimarkkinoita. Runsaasti sähköä tuottavat tai kuluttavat sähköverkon käyttäjät voivat osallistua reservimarkkinoille tarjoten ylös- tai alassäätöä tai molempia (Fingrid, 2023b). Säätötarjousten toteuttaminen on yksi keino tuoda lisää tuottoja lämpövarastolle. Ongelmana on tuottoisimpien tuntien ja markkinoiden valinta. Vaikka säätötarjouksia voidaan toteuttaa tietämättä mitään tulevista reservimarkkinahinnoista, olisi tuottojen maksimoimiseksi paras tietää millä tunneilla ja millä markkinoilla tuotot ovat suurimmat.

Sähkö- ja reservimarkkinahintojen ennustuksessa on käytetty usein tilastollisia ja koneoppimismenetelmiä, jotka kilpailevat keskenään ennustuskyvykkyydessä. Koneoppimismenetelmien etuna on niiden kyky oppia monimutkaisia epälineaarisia riippuvuuksia muuttujien välille. Koneoppimisratkaisuja on esitetty laajasti useisiin erilaisiin ennustusongelmiin kuten sään ja sääriippuvaisen energiantuotannon ennustamiseen sekä smart gridien päätöksentekoon liittyen hintoihin, kulutukseen ja tuotantoon (Rangel-Martinez et al., 2021).

Tämän työn tutkimuskohteena on reservimarkkinoilla toimivan lämpövaraston ohjauksessa käytettävä koneoppimismalli, jonka tarkoituksena on ennustaa reservimarkkinahintoja. Työ tehtiin yhteistyössä Polar Night Energy Oy:n (PNE) kanssa. PNE on yritys,

joka suunnittelee ja toteuttaa korkean lämpötilan lämpövarastoratkaisuja mahdollistaakseen ympäristöystävällisen energiatuotannon lämpösektorilla. Tutkimuskysymyksinä olivat:

- millaiset koneoppimismallit voisivat soveltua reservimarkkinoiden seuraavan päivän tuntihintojen ennustamiseen
- millaisia yleisiä suunnitteluvaiheita reservimarkkinahintojen ennustukseen käytettävän koneoppimismallin suunnitteluprosessiin kuuluu

Työn tarkoituksena on siis löytää kyseiseen ongelmaan soveltuvia koneoppimismalleja ja tarjota yleiset raamit koneoppimismallin suunnittelulle. Työssä perehdyttiin kirjallisuuteen lämpövarastojen, sähkö- ja reservimarkkinoiden, tilastollisten ja koneoppimismenetelmien sekä sähkö- ja reservimarkkinahintojen ennustamisen alueilla. Myös PNE:n toimittamia ei-julkisia materiaaleja sekä Fingridille toteutettua kyselyä käytettiin lähteinä. Aiempia opinnäytetöitä ei löytynyt suoraan tämän työn aiheesta, mutta läheisestä aihepiiristä löytyi diplomityö: ”Energianhallintajärjestelmä mikroverkon energiaresurssien käytön taloudelliseen optimointiin” (Zavertkin, Mikko, 2023), jossa käsiteltiin myös muun muassa erilaisia ennustusmenetelmiä.

Työn luvussa 2 esitellään yleisesti erilaisia lämpövarastoja ja niiden luokittelua, sekä tutustutaan PNE:n sähkölämmitteisen hiekka-akun toimintaan. Luvussa 3 tutustutaan sähkömarkkinoihin hieman yleisesti, jonka jälkeen paneudutaan syvemmin reservimarkkinoihin, taajuusohjattuihin reserveihin ja lämpövaraston toimintaan reservimarkkinoilla. Luvussa 4 esitellään erilaisia sähkö- ja reservimarkkinoilla käytettäviä ennustusmenetelmiä sekä niiden taustateoriaa. Luvussa 5 puolestaan syvennytään sähkö- ja reservimarkkinoiden hintojen ennustusta koskevaan tutkimukseen ja esitellään näihin tehtäviin soveltuvan koneoppimismallin yleiset suunnitteluvaiheet. Lopuksi luvussa 6 käydään läpi työn johtopäätökset ja tulevaisuudennäkymät.

2. LÄMPÖVARASTON TOIMINTA

Lämmön varastointi on yksi energian varastoinnin muodoista. Muita energian varastointimuotoja ovat esimerkiksi mekaanisen, sähkökemiallisen ja kemiallisen energian sekä suora sähkön varastointi (Rahman et al., 2020). Lämmön varastoinnilla on tärkeä asema energian varastoinnissa, sillä esimerkiksi vuonna 2021 jopa 50 % maailman energiasta kulutettiin lämpönä (IEA, 2022). Lämpöä voidaan varastoida lämmittämällä tai jäähdyttämällä väliainetta. Varastoitua lämpöä voidaan hyödyntää lämmittämiseen, jäähdyttämiseen tai sähkön tuotantoon (Sarbu and Sebarchievici, 2018). Lämpövarastoja on olemassa useita eri tyyppejä, jotka soveltuvat ominaisuuksiensa puolesta erilaisiin käyttökohteisiin. PNE on kehittänyt lämpövaraston, joka pohjautuu hiekan lämmittämiseen korkeisiin lämpötiloihin ja on BBC:n artikkelin (McGrath, 2022) myötä saanut julkisuudessa nimen ”hiekka-akku” (engl. sand battery). Hiekka-akku on ensimmäinen laatuaan maailmassa ja sillä on joitain merkittäviä etuja muihin saman luokan lämpövarastoihin verrattuna.

2.1 Lämpövarastojen luokittelu

Lämmön varastointia varten on olemassa suuri määrä erilaisia ratkaisuja, jotka kaikki soveltuvat omiin käyttötarkoituksiinsa. Järjestelmän rakenteeseen vaikuttaa siis useita tekijöitä. Lämpövarastot voidaan luokitella useilla eri tavoilla, mutta usein ne luokitellaan kolmeen pääkategoriaan: tuntuvan lämmön varastoihin, latentin lämmön varastoihin sekä kemiallisiin lämpövarastoihin (Alva et al., 2018; Rahman et al., 2020; Sarbu and Sebarchievici, 2018). Lämpövaraston rakenteeseen ja systeemin kokoonpanoon vaikuttaa edellisten lisäksi se, halutaanko lämpövarastosta ulos sähköä vai lämpöä.

Tuntuvan lämmön varastointi tarkoittaa lämpötilaeroon perustuvaa lämmön varastointia, kun taas latentin lämmön varastointi tarkoittaa materiaalin faasinmuutokseen liittyvän lämmön varastointia (Alva et al., 2018). Kemiallisen lämpövaraston toiminta perustuu termokemiallisten materiaalien reversiibeliin hajoamiseen, jossa lämpöä vapautuu sekä käänteisreaktioon, jossa lämpöä sitoutuu (Sarbu and Sebarchievici, 2018). Näistä kolmesta kemiallisilla lämpövarastoilla on suurin energiatiheys, latentin lämmön varastoilla toiseksi suurin ja tuntuvan lämmön varastoilla pienin. Sitä vastoin tuntuvan lämmön varastot ovat kaikkein kypsintä teknologiaa, kun latentin lämmön varastot ovat vielä enimmäkseen kehitysvaiheessa (Sarbu and Sebarchievici, 2018) ja kemialliset lämpövarastot

puolestaan ovat vielä laboratoriovaiheessa kehitteillä (Alva et al., 2018). Erityisesti tuntuvan lämmön varastot ovat siis kiinnostavaa teknologiaa keskisuuren ja suuren mittakaavan energiavarastoissa tällä hetkellä.

Tuntuvan lämmön varastoa ladattaessa varastomateriaalia lämmitetään ilman että tapahtuu faasinmuutosta. Varastoidun lämmön määrä riippuu varastomateriaalin tiheydestä, tilavuudesta, ominaislämpökapasiteetista ja lämpötilaerosta. Varastomateriaaleina tuntuvan lämmön varastoissa voidaan käyttää ainakin vettä, lämmönsiirtoöljyjä, sulatettuja suoloja, nestemäisiä metalleja, maa-aineksia ja betoniharkkoja. Nämä materiaalit ovat vettä lukuun ottamatta termisesti stabiileja – eli ne säilyttävät lämmitettäessä ominaisuutensa – jopa 400 °C ja sitäkin korkeampiin lämpötiloihin asti (Alva et al., 2018, luku 2.1.1), mahdollistaen siten korkean varaston lämpötilan. Sulatettujen suolojen, maa-ainesten ja betoniharkkojen etuina on korkean varastointilämpötilan lisäksi myös halpa hinta. Suurin haaste tuntuvan lämmön varastoissa puolestaan on, että varaston lämpötila laskee purkamisen aikana (Alva et al., 2018, luku 2.1.2). Lämpövarastosta ulos saatava maksimiteho siis laskee varaston lämpötilan laskiessa. Korkean energiatiheyden saavuttamiseksi tuntuvan lämmön varastoissa on syytä suosia suuren lämpökapasiteetin sekä korkean termisen stabiiliuden tai ainakin jommankumman omaavia materiaaleja. Lämmön varastointimateriaaleista vesi on kaikkein käytetyin (Sarbu and Sebarchievici, 2018) ja tämä johtunee varmastikin sen yleisestä saatavuudesta, halvasta hinnasta sekä korkeasta lämpökapasiteetista. Vettä ei kuitenkaan voi lämmittää yhtä korkeisiin lämpötiloihin kuin esimerkiksi maa-aineksia, jotka ovat myös halpoja varastomateriaaleja. Maa-ainesten mahdollistama satoja asteita korkeampi varastointilämpötila on selkeä etu veteen nähden ja sillä saadaan kompensoitua maa-ainesten veteen nähden pienemmän lämpökapasiteetin vaikutus varaston kapasiteettiin.

Lämpövarastoja voidaan luokitella myös muilla menetelmillä ja Alva et al. (2018) ovatkin luokitelleet lämpövarastot vielä erikseen lataussyklien taajuuden, jakelun, mekanismin sekä operoitavan lämpötilavälin mukaan, mutta näihin ei paneuduta tässä työssä tarkemmin. On siis hyvä tunnistaa, että lämpövaraston käsite pitää sisällään monenlaisia teknologisia ratkaisuja ja niitä voidaan luokitella useiden eri kriteerien perusteella.

Tässä työssä keskitytään lämpövarastoihin vain PNE:n hiekka-akun kannalta. PNE:n nettisivujen tietojen perusteella hiekka-akun voidaan todeta olevan tuntuvaan lämpöön perustuva, korkean operointilämpötilan omaava lämpövarasto (Polar Night Energy, 2023a).

2.2 Polar Night Energyn hiekkalämpövaraston toiminta

PNE:n kehittämä hiekka-akku on tuntuvaan lämpöön perustuva korkean lämpötilan lämpövarasto. Erityisesti prosessilämpöä tarvitsevat teollisuuden toimijat ja kaukolämpöyhtiöt voivat hyötyä korkean lämpötilan lämpövarastojen tarjoamasta omavaraisuudesta sekä kulutuspiikkien tasaamisesta. Hiekka-akun keskimääräinen maksimilämpötila on 600 °C (Kivioja, 2023a), joka riittää hyvin sekä teollisuuden prosessien tarpeisiin että kaukolämmön tuotantoon. Teollisuuden prosesseista jopa noin 60 % käyttää prosessilämpöä lämpötilavälillä 30 – 250 °C (Sharma et al., 2017, luku 1) ja kaukolämmön lämpötila puolestaan vaihtelee säästä riippuen välillä 65 – 115 °C (Energiateollisuus, 2023).

PNE:llä on tällä hetkellä kaksi toiminnassa olevaa laitosta, joista toinen on Hiedanrannassa sijaitseva pilottilaitos ja toinen on Kankaanpäässä sijaitseva laitos. Kankaanpään laitos on pieni kaupallisen mittakaavan laitos, jonka nimellisteho on 100 kW ja kapasiteetti 8 MWh. (Polar Night Energy, 2023b) Yhtiön nettisivuilla on tällä hetkellä tarjolla kaksi huomattavasti suurempaa tuotetta: nimellisteholtaan ja kapasiteetiltaan joko 2 MW ja 200 MWh tai 10 MW ja 730 MWh lämpövarastot (Polar Night Energy, 2023c).

Yksinkertaistettuna hiekka-akku koostuu lämmönvarastointiväliaineesta, lämmönsiirtoputkistosta, lämmitysvastuksista, lämmönvaihtimesta sekä puhaltimesta. Lämmitysvastukset on kytketty sähköverkkoon. Akkua varataan sekä puretaan kierrättämällä normaalipaineessa olevaa ilmaa varaston läpi lämmönsiirtoputkistoa pitkin, suljetussa kierrossa. Akkua varattaessa ilmaa lämmitetään lämmitysvastuksilla ja puhalletaan lämpövaraston läpi. Kuuma ilma luovuttaa lämpönsä hiekalle ja palaa viileämpänä takaisin lämmitysvastuksille ja puhaltimelle. Akkua purettaessa lämmitysvastukset ovat pois päältä, ja nyt ilmaa puhalletaan kuuman hiekkasäiliön sekä lämmönvaihtimen läpi. Ilma vastaanottaa lämpöä kuumalta hiekalta ja etenee lämmönvaihtimeen luovuttamaan tämän lämmön fluidille, jota asiakas haluaa lämmittää. Viilennyt ilma palaa taas puhaltimen kautta säiliöön lämmitettäväksi. (Kivioja, 2023b) Kuvassa 1 on esitettynä periaatekuva hiekka-akusta latauksen aikana. Purkamisen aikana lämpö siirtyy päinvastaisesti varastosta ilmaan ja siitä lämmitettävään aineeseen.

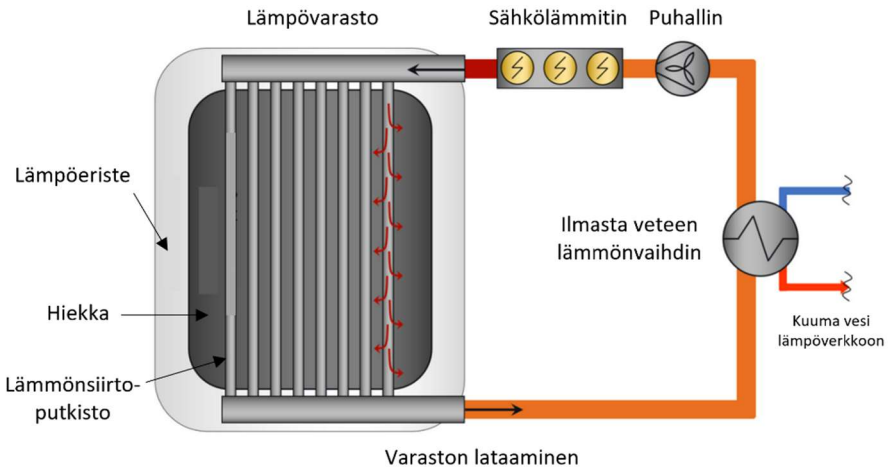

Kuva 1. *Periaatekuva Polar Night Energyn hiekka-akusta latauksen aikana. Muokattu lähteestä (Kivioja, 2023b).*

Lämpövarastoille olennaisia parametreja ovat operoitava lämpötilaväli, kapasiteetti, teho, hyötysuhde, varastointiaika, lataus- ja purkamisaika sekä hinta kapasiteettia tai tehoa kohti (Sarbu and Sebarchievici, 2018). Tämän työn näkökulmasta ehkä olennaisimpia näistä ovat lämpövaraston operoitava lämpötilaväli, kapasiteetti, teho sekä lataus- ja purkamisajat. Operoitava lämpötilaväli määrittää varaston kapasiteettia ja tehoa. Kapasiteetti kertoo sen miten paljon energiaa varastoon mahtuu, latausteho sen, kuinka nopeasti tämä energiaa saadaan varastoon laitettua ja purkamisteho sen, kuinka nopeasti energiaa saadaan otettua varastosta ulos.

Lämmönsiirto, jota prosessissa tapahtuu, edellyttää lämpötilaeroa. Tämä rajoittaa sitä kuinka matalalle varaston lämpötila voi laskea, jotta lämpöä voitaisiin vielä hyödyntää. Veden lämmittämiseksi 80 °C lämpötilaan on varaston keskimääräisen lämpötilan oltava vähintään 100 °C, jotta lämmönsiirto on riittävän tehokasta (Kivioja, 2023b). Teollisuuden prosessilämmön tarpeisiin tämä vähimmäislämpötila voi olla huomattavasti suurempi riippuen sovelluskohteesta.

Lämmönsiirto ei myöskään koskaan ole täydellistä, vaan esimerkiksi hiekka-akkua varattaessa lämmitettävä hiekka jää aina hieman viileämmäksi kuin lämmityksessä käytetty ilma ja päinvastoin akkua purettaessa. Hiekka on myös hyvä lämmöneriste, joten lämpö ei jakaannu akussa tasaisesti (Kivioja, 2023a). Varaston keskilämpötilan voidaan arvioida täydellä varauksella olevan noin 600 °C. Näin saadaan operoitava lämpötilaväli selvitettyä hiekka-akulle.

Lämpövaraston kapasiteetti E voidaan esittää muodossa (Kivioja, 2023)

$$E = \rho V c_p (T - T_{ref}) \tag{1}$$

missä ρ on varastomateriaalin tiheys, V varaston tilavuus, c_p varastomateriaalin ominaislämpökapasiteetti ja $(T - T_{ref})$ operoitava lämpötilaväli, eli lämpötilaero, jossa T on varaston suurin mahdollinen keskilämpötila ja T_{ref} matalin hyödyllinen lämpötila. Materiaalin valinnalla kiinnitetään tiheys ja ominaislämpökapasiteetti. Sovelluskohde puolestaan määrittää käytännössä lämpötilaero-termin enimmäismäärän, jolloin varaston kokoa muuttamalla voidaan määrittää haluttu kapasiteetti.

Lämpövarastosta ulos saatava maksimiteho riippuu siitä, kuinka hyvin lämpöä saadaan siirrettyä kuumasta hiekasta lämmönsiirtoaineena toimivaan ilmaan ja siitä edelleen lämmitettävään kohteeseen. Lämmönsiirron tehokkuus riippuu lämpövaraston keskilämpötilasta, lämmönsiirtoaineen tulolämpötilasta, materiaalien lämmönjohtavuuksista, lämmönsiirtopinta-alasta sekä virtauksen lämmönsiirtokertoimesta, johon puolestaan vaikuttaa virtauksen ominaisuudet, kuten virtausnopeus ja paine. (Kivioja, 2023a)

Hiekka-akusta ulos saatavaa tehoa voidaan kontrolloida ohjaamalla lämmönsiirtoaineen virtausnopeutta puhaltimen tehoa säätämällä. Varastosta voidaan ottaa ulos kullekin varaston varaustasolle ominaista maksimitehoa, kun virtausnopeus on huipussaan. Maksimiteho on sitä suurempi, mitä suurempi on varaston varaus. Hiekka-akun varauksen katsotaan olevan 100 % kun sen keskilämpötila on 600 °C ja 0 % kun sen keskilämpötila on T_{ref}, joka aiemmassa esimerkissä oli 100 °C. Maksimitehon sijasta on mielekkäämpää määrittää varastolle nimellisteho, joka kuvaa paremmin varaston kykyä keskimääräisissä olosuhteissa. Varaston nimellistehoksi voidaan valita esimerkiksi varaston maksimiteho, kun sen varaus on 50 % kokonaiskapasiteetista. Jos nimellisteho kiinnitetään kyseiseen arvoon, voidaan nyt eri varausasteilla saatavaa maksimitehoa P_{max} arvioida seuraavalla yhtälöllä

$$P_{max} = P_{nimellis} * \frac{varaston\ varaus\ \%}{50\ \%} \tag{2}$$

missä $P_{nimellis}$ on nimellisteho. (Kivioja, 2023b)

Lämpövarastolla vuodessa tehtävien lataussyklien sopivaa määrää voidaan arvioida, kun tiedetään varaston purkamiseen ja lataamiseen kuluvat ajat sekä kannattavien lataustuntien määrä vuodessa. Varaston purkamisaika voidaan arvioida sen kapasiteetin ja nimellistehon avulla ja latausaika puolestaan voidaan arvioida kapasiteetin ja sähkövastusten lämmitystehon avulla. Jos pörssisähkölle määritetään tavoitteen mukainen kattohinta, jota halvemmilla tunneilla sähköä pyritään ostamaan, voidaan arvioida kuinka

monta tuntia vuodessa sähköä kannattaa ostaa, eli varastoa ladata. Toisaalta jotta investointi lämpövarastoon olisi kannattava, on lämpövaraston lataussyklien määrä oltava riittävän suuri. Kiviojan (2023a) mukaan karkea arvio sopivaksi lataussyklien määräksi vuodessa on yleisesti välillä 20 – 50.

3. SÄHKÖ- JA RESERVIMARKKINAT

Fingrid (2023c) toteaa nettisivuillaan sähkömarkkinoista seuraavasti:

> *Toimivat sähkömarkkinat ovat kustannustehokkain tapa toteuttaa sähkön kysynnän ja tarjonnan tasapainottaminen ja varmistaa yhteiskunnan sähkönsaanti. Sähkömarkkinoilla muodostuva hinta ohjaa tehokkaasti markkinatoimijoiden sähkön tuotanto- ja kulutuspäätöksiä lyhyellä aikavälillä sekä investointeja pitkällä aikavälillä.*

Sähkömarkkinat ovat siis tärkeä väline sähkön tuotannon ja kulutuksen ohjaukseen. Kysynnän ja tarjonnan tasapainottaminen ei kuitenkaan aina onnistu täydellisesti ja yllättävät tilanteet, kuten voimalaitosten vikaantuminen tai sääriippuvaisen uusiutuvan energian, kuten tuulivoiman tuotannon vaihtelut, voivat myös horjuttaa tasapainoa. Tähän ratkaisuksi Fingrid ylläpitää reservimarkkinoita, joilla huolehditaan sähköjärjestelmän jatkuvasta tasapainottamisesta. Lämpövarastot ovat joustavia sähkönkulutuksensa suhteen ja voivat näin olla tulevaisuudessa merkittäviä toimijoita reservimarkkinoilla.

3.1 Yhtenäiset sähkömarkkinat

Suomi on osa yhteispohjoismaista sähköjärjestelmää, johon kuuluu Suomen kantaverkon lisäksi Ruotsin, Norjan ja Itä-Tanskan sähkönsiirtoverkot. Pohjoismaiset sähköverkot ovat liittyneet toisiinsa useiden vaihto- ja tasasähköyhteyksien välityksellä. Pohjoismaisesta verkosta on myös useita tasasähköyhteyksiä muihin maihin, kuten Saksaan, Puolaan ja Hollantiin kytkien sen muuhun Eurooppaan. (Fingrid, 2023d) Pohjoismaisessa sähköjärjestelmässä kantaverkonhaltijoiden kuten suomalaisen Fingridin, norjalaisen Statnetin ja ruotsalaisen Svenska kraftnätin tehtävänä on ylläpitää tuotannon ja kulutuksen tasapaino reaaliajassa (Fingrid, 2023e). Kantaverkonhaltijat ja muut sähköverkkoyhtiöt ylläpitävät sähköverkkoja ja yhdistävät tuotannon ja kulutuksen fyysisesti toisiinsa, näin mahdollistaen sähkömarkkinoiden toiminnan (Fingrid, 2023c).

Sähkömarkkinoiden kysyntä ja tarjonta muodostuvat tuottajien tuottaman ja kuluttajien käyttämän sähkön perusteella (Fingrid, 2023c) ja kaupan hinta määräytyy kysynnän ja tarjonnan kohtaamisesta. Pohjoismaat on jaettu fysikaalisen siirtokapasiteetin mukaan tarjousalueiksi, joista Suomi on yksi. Tarjousalueiden sisällä hinta on aina yhtenäinen, mutta niiden välillä hinta voi erota silloin kun verkon siirtokapasiteetti rajoittaa alueiden välillä siirrettävän energian määrää. (Fingrid, 2023f)

Sähkömarkkinoilla on useita erilaisia markkinapaikkoja, joita ovat johdannaismarkkinat, vuorokausimarkkinat, päivänsisäiset markkinat, säätösähkömarkkinat ja reservimarkkinat. Johdannaismarkkinoilla käydään kauppaa sähkön hintaan liittyvillä johdannaistuotteilla, kuten futuureilla ja optioilla, eikä siis fyysisellä sähköllä. Vuorokausimarkkinoilla käydään kauppaa aina seuraavan vuorokauden jokaiselle tunnille. Tarjoukset sähkön tuotannosta ja kulutuksesta asetetaan vuorokausimarkkinoilla klo 13 mennessä edellisenä päivänä, jonka jälkeen sähköpörssit laskevat sähkön hinnan osto- ja myyntitarjousten sekä siirtokapasiteettien perusteella kullekin tunnille. Päivänsisäisillä markkinoilla pyritään tasapainottamaan yllättävien muutosten vaikutuksia kulutuksessa, tuotannossa ja siirtokapasiteetissa lähempänä käyttöhetkeä. Päivänsisäisillä markkinoilla käydään kauppaa saman päivän käyttötunneista ja esimerkiksi Suomen sisällä päivänsisäiset markkinat sulkeutuvat 0 min ennen toimitustuntia. Vuorokausimarkkinoita ja päivänsisäisiä markkinoita ylläpitävät esimerkiksi Nord Pool ja EPEX Spot. (Fingrid, 2023c)

Fingrid ylläpitää säätösähkömarkkinoita (mFRR) yhdessä muiden pohjoismaisten kantaverkkoyhtiöiden kanssa sekä reservimarkkinoita itsenäisesti. Näiden avulla Fingrid varmistaa valtakunnallisen tehotasapainon ylläpitämisen. Säätösähkömarkkinoilla markkinaosapuolten säätösähkötarjouksia aktivoidaan tehotasapainon tarpeen mukaisesti ja niitä voi jättää 45 minuuttia ennen käyttötuntia. Reservimarkkinoilla Fingrid ylläpitää useita erilaisia reservejä, joilla on kullakin omat tehtävänsä ja tekniset vaatimuksensa. (Fingrid, 2023c) Reservimarkkinat ovat erityisen kiinnostava markkinapaikka lämpövarastojen kannalta, sillä ne voisivat normaalin toimintansa ohella saada lisäansioita reservejä toimittamalla, sen vaikuttamatta suuresti normaaliin toimintaan.

3.2 Reservimarkkinat

Sähkön tuotannon ja kulutuksen on oltava tasapainossa jokaisella ajanhetkellä. Tasapainosta kertoo sähköverkon taajuus, joka tasapainotilassa on 50,0 Hz. Sähkömarkkinoille osallistuvat osapuolet suunnittelevat etukäteen kulutuksensa ja tuotantonsa, mutta käyttötunnin aikana tapahtuvia poikkeamia varten tarvitaan erilaisia reservejä. Fingrid hankkii reservejä ylläpitämiltään markkinoilta. Reserveillä tarkoitetaan sähköä tuottavia ja kuluttavia kohteita, kuten voimalaitoksia, kulutuskohteita ja energiavarastoja, jotka voivat muuttaa tehoaan tarpeen mukaan. Pohjoismaisten järjestelmävastaavien välisessä käyttösopimuksessa on sovittu pohjoismaisen yhteiskäyttöjärjestelmän reservien ylläpitovelvoitteista. (Fingrid, 2023g)

Pohjoismaisilla sähkömarkkinoilla on käytössä useita reservituotteita, joilla on erilaisia tehtäviä. Reservituotteet voidaan jakaa kolmeen ryhmään: taajuuden vakautusreservit,

taajuuden palautusreservit ja korvaavat reservit, joista viimeinen ei ole käytössä pohjoismaisessa sähköjärjestelmässä. Taajuuden vakautusreservit ovat nopeita reservejä ja niitä käytetään taajuuden jatkuvaan hallintaan. Taajuuden palautusreservit puolestaan ovat hieman hitaampia ja niiden tarkoituksena puolestaan on palauttaa taajuus normaalialueelle 49,9 – 50,1 Hz ja vapauttaa aktivoituneet taajuuden vakautusreservit takaisin käyttöön. Lisäksi vuodesta 2020 alkaen käytössä on ollut nopea taajuusreservi, jota käytetään pienen inertian käyttötilanteissa taajuuden vakautusreservien lisäksi. (Fingrid, 2023g)

Käytössä olevia reservejä ovat nopea taajuusreservi (FFR), taajuusohjattu häiriöreservi (FCR-D) ylös, taajuusohjattu häiriöreservi (FCR-D) alas, taajuusohjattu käyttöreservi (FCR-N), automaattinen taajuuden palautusreservi (aFRR) ja manuaalinen taajuuden palautusreservi (mFRR). Manuaalinen taajuuden palautusreservi pitää sisällään säätösähkömarkkinat, säätökapasiteettimarkkinat sekä varavoimalaitokset. (Fingrid, 2023g) Kuvassa 2 on esitettynä kaavio eri reservituotteista ja aikaskaalasta, jolla ne toimivat.

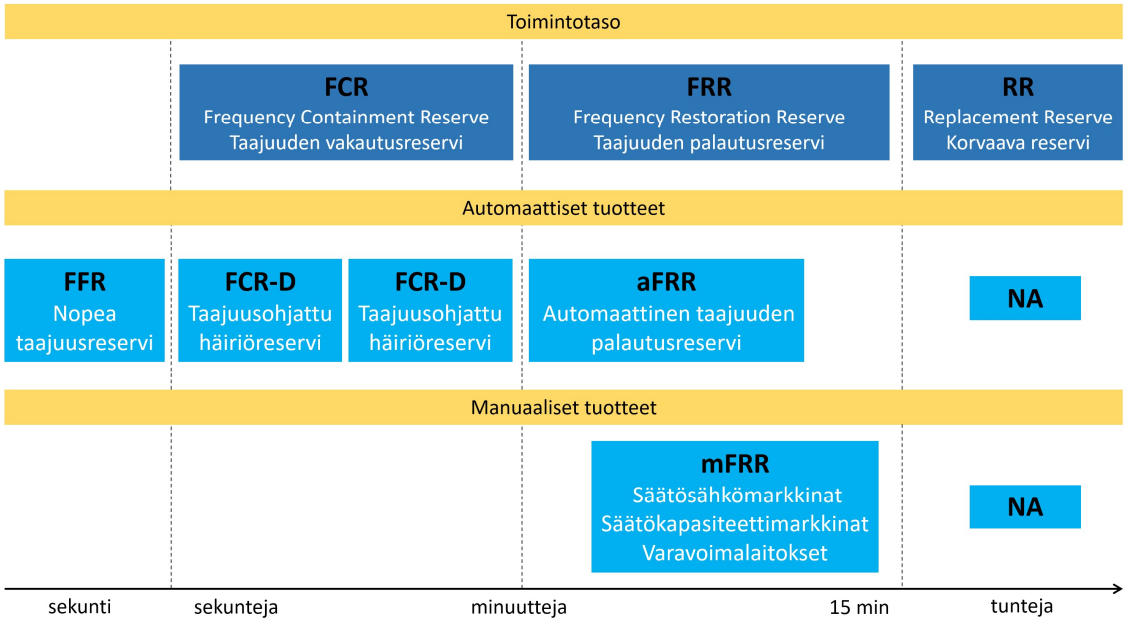

Kuva 2. *Fingridin reservilajit. Muokattu lähteestä (Fingrid, 2023h)*

Jokaisen reservituotteen kohdalla on määritetty omat tekniset vaatimukset, jotka reservitoimittajan on täytettävä, mikäli haluaa kyseisen reservin markkinoille osallistua. Näihin vaatimuksiin sisältyy: tarjouksen vähimmäiskapasiteetti, tarjouksen tarkkuus, aktivoitumisaika sekä FFR:llä aktivoinnin minimikesto. (Fingrid, 2023h) Lisäksi tarjouksille on asetettu enimmäismäärä kaikkien paitsi aFRR reservin kohdalla. Taulukossa 1 on koottuna eri reservituote kohtaiset tarjousten vähimmäis- ja enimmäiskapasiteetit, tarjousten tarkkuus sekä maksimaalinen aktivoitumisaika.

Taulukko 1. *Reservituotteiden teknisiä vaatimuksia reservin toimittajalle (Fingrid, 2023h, 2022a, 2022b, 2020, 2023i).*

	Yksittäisen tarjouksen vähimmäiskapasiteetti (MW)	**Yksittäisen tarjouksen enimmäiskapasiteetti (MW)**	**Tarkkuus, jolla tarjoukset on annettava (MW)**	**Aktivoitumisaika**
FFR	1	10	0,1	49,7 Hz 1,3 s 49,6 Hz 1,0 s 49,5 Hz 0,7 s
FCR-D (ylös ja alas)	1	10	0,1	50 % 5 s 100 % 30 s
FCR-N	0,1	5	0,1	100 % 3 min
aFRR	1		1	5 min
mFRR	1	200 *	1	15 min

* Reservikohdekohtainen maksimikapasiteetti

FCR-D, aFRR ja mFRR reservien kohdalla ylös- ja alassäätötarjoukset tehdään erikseen, toisin kuin FCR-N ja FFR kohdalla (Fingrid, 2023i, 2022a, 2022b, 2020). FCR-N on symmetrinen tuote, eli reservin on pystyttävä sekä ylös- että alassäätöön. Ylössäädöllä tarkoitetaan sähkön tuotannon lisäämistä tai kulutuksen vähentämistä. Alassäädöllä puolestaan tarkoitetaan sähkön tuotannon vähentämistä tai kulutuksen lisäämistä. (Fingrid, 2023j)

3.3 Taajuusohjatut käyttö- ja häiriöreservit

Taajuusohjattujen FCR-D ja FCR-N reservituotteiden toimittamiseen voi osallistua erikseen sekä vuosimarkkinoilla että tuntimarkkinoilla. Molemmilla markkinoilla on samat tekniset vaatimukset ja molemmilla markkinoilla kauppaa käydään erikseen FCR-N, FCR-D ylös ja FCR-D alas tuotteilla. Hyväksytyn säätötarjouksen myötä reservitoimittaja sitoutuu toimittamaan sovitun määrän reserviä. Reservintoimittajan vastuulla on tällöin huolehtia, että reserviä on käytettävissä sovittu määrä, sovitun ajan verran. Mikäli reservintoimittaja kykenee toimittamaan sekä ylös- että alassäätöä, voi se osallistua myös molempien FCR-D-reservien toimittamiseen samanaikaisesti.

Vuosimarkkinoiden tarjouskilpailu järjestetään kerran vuodessa syksyllä, jossa kallein hyväksytty tarjous asettaa kiinteän hinnan koko vuodelle. Hyväksytty vuosimarkkinatarjous ostetaan täysimääräisesti ja reservitoimittajalla on velvollisuus ylläpitää vuosimarkkinoille myymäänsä reserviä vapaan kapasiteettinsa puitteissa. Vuosimarkkinoille ei ole mahdollista tulla mukaan kesken sopimuskauden. (Fingrid, 2023j)

Tuntimarkkinoille voi osallistua tekemällä erillisen sopimuksen Fingridin kanssa. Tarjoukset kaikille seuraavan vuorokauden 24 tunnille on jätettävä klo 18.30 mennessä, jonka jälkeen Fingrid ostaa tarvittavan määrän kapasiteettia kullekin tunnille niin, että kallein

hyväksytty tarjous määrittää tunnin hinnan. (Fingrid, 2023j) Mikäli reservitoimittaja on tehnyt vuosimarkkinasopimuksen, voi se osallistua tuntimarkkinoille vain, kun vuosimarkkinasopimuksen määrä on toimitettu täysimääräisenä kyseiselle tunnille. (Fingrid, 2023i)

Taajuusohjattu käyttöreservi FCR-N on symmetrinen tuote, jolloin sitä on pystyttävä säätämään ylös sekä alas. Taajuuden laskiessa alle 49,9 Hz, on 100 % reservikapasiteetista aktivoitava ylössäätönä ja puolestaan taajuuden noustessa yli 50,1 Hz on 100 % reservikapasiteetista aktivoitava alassäätönä. Taajuusvälillä 49,9 – 50,1 Hz tapahtuu myös aktivoitumista ja aktivoidun kapasiteetin määrän tulee olla lineaarisesti tai paloittain lineaarisesti verrannollinen taajuuspoikkeaman suuruuteen. Taajuudensäädön kuollut alue saa olla korkeintaan 50 $\pm$ 0,01 Hz. (Fingrid, 2022c, p. 5) Täten FCR-N reserviin osallistuttaessa reservin aktivoitumista voi tapahtua tiheään pientenkin taajuuspoikkeamien myötä.

Taajuusohjattu häiriöreservi FCR-D puolestaan on jaettu erikseen ylös- ja alassäätötuotteisiin. Sen kohdalla reservikapasiteetin aktivointi tulee aloittaa vasta 49,9 Hz (ylössäätö) tai 50,1 Hz (alassäätö) kohdalla ja 100 % reservikapasiteetista on aktivoitava, kun taajuus alittaa 49,5 Hz (ylössäätö) tai ylittää 50,5 Hz (alassäätö). Taajuusväleillä 49,5 – 49,9 Hz ja 50,1 – 50,5 Hz aktivoidun kapasiteetin määrä tulee olla lineaarisesti tai paloittain lineaarisesti verrannollinen taajuuspoikkeaman suuruuteen. (Fingrid, 2022c, p. 7) FCR-D reservin aktivoitumiseen vaaditaan siis suurempi taajuuden poikkeama tasapainotilasta, jolloin sen aktivoitumista tapahtuu todennäköisesti myös harvemmin kuin FCR-N reservin kohdalla.

Reservin toimittaminen näyttäytyy hieman eri tavalla toimijoille, joilla on vain kulutusta tai tuotantoa, kuin toimijoille, joilla on molempia. Sekä kulutusta että tuotantoa omaavat toimijat voivat pysyä säätökykyisenä, eli kyetä aktivoimaan reserviään molempiin suuntiin, vaikka niiden tuotanto ja kulutus olisivat molemmat nollissa. Tällainen toimija voisi olla esimerkiksi sähköakku, jonka varaustaso on puolillaan. Pelkkää tuotantoa tai kulutusta omaava toimija puolestaan joutuu pitämään tuotantoaan tai kulutustaan osittain yllä pysyäkseen säätökykyisenä molempiin suuntiin. Pelkkää tuotantoa omaava toimija voi toimittaa pelkästään ylössäätöä tuotannon ollessa nollissa ja pelkästään alassäätöä tuotannon ollessa maksimissa. Vastaavasti pelkkää kulutusta omaava toimija voi toimittaa pelkkää alassäätöä kulutuksen ollessa nollissa ja pelkästään ylössäätöä kulutuksen ollessa maksimissa. Tätä on havainnollistettu kuvassa 3 esimerkkien avulla.

	Lämpövarasto (vain kulutus)	Vesivoimala (vain tuotanto)	Sähköakku, 50% varaus (kulutus sekä tuotanto)
Kulutus / tuotanto nolla	↓	↑	↑↓
Kulutus / tuotanto osittainen	↑↓	↑↓	↑↓
Kulutus / tuotanto maksimissa	↑	↓	↑↓

Kuva 3. *Erityyppisten reservitoimittajien säätömahdollisuudet erilaisissa kulutus- ja tuotantotilanteissa. Nuolilla kuvataan ylös- ja alassäätöä.*

Taajuusohjattujen käyttö- ja häiriöreservien tuntimarkkinahinnat ja hankintamäärät vaihtelevat suuresti vuoden aikana. Fingridin vuoden 2022 datan pohjalta selvitettiin kuinka suuria olivat reservin keskimääräinen hankintamäärä, keskimääräinen tuntihinta ja vuosiansiot, kun tarkasteltiin erikseen FCR-N, FCR-D alas ja FCR-D ylös reservien toimitusta eri tuntimäärillä. Tulokset näistä on kirjattu taulukkoon 2. Tuloksien laskennassa on poimittu aina kalleimmat tunnit kullakin toimitusmäärällä, ja oletuksena on, että kaikki kaupat toteutuvat. Tulokset on laskettu 1 MW tarjouskoolle.

Taulukko 2. *Reservien keskimääräiset hankintamäärät, keskimääräiset tuntihinnat ja vuosiansiot eri reserveille, erisuuruisilla toimitettujen tuntien määrillä. Laskenta tehty vuoden 2022 datan pohjalta 1 MW tarjouskoolle poimimalla kalleimmat tunnit ja olettaen että kaikki kaupat toteutuvat. (Fingrid, 2023k)*

Toimitettujen tuntien määrä vuodessa (kpl)		**FCR-N**	**FCR-D alas**	**FCR-D ylös**
4000	Reservin keskimääräinen hankintamäärä (MW)	33,66	30,91	62,66
	Keskimääräinen tuntihinta (€/h)	68,30	47,60	26,36
	Vuosiansiot (€)	273 194,93	190 396,02	105 425,01
2000	Reservin keskimääräinen hankintamäärä (MW)	35,88	32,59	66,57
	Keskimääräinen tuntihinta (€/h)	105,72	76,35	49,90
	Vuosiansiot (€)	211 443,94	152 693,17	99 793,68
1000	Reservin keskimääräinen hankintamäärä (MW)	37,05	30,14	72,17
	Keskimääräinen tuntihinta (€/h)	148,42	114,98	96,76
	Vuosiansiot (€)	148 423,61	114 976,74	96 761,89
500	Reservin keskimääräinen hankintamäärä (MW)	37,44	26,99	80,75
	Keskimääräinen tuntihinta (€/h)	186,03	175,38	180,20
	Vuosiansiot (€)	93 016,09	87 688,10	90 098,18

Taulukosta nähdään, että FCR-N reservin kohdalla vuosiansiot ovat kaikilla tuntimäärillä selkeästi suurimmat. FCR-D alas reservin vuosiansiot ovat suuremmat kuin FCR-D ylös reservillä kaikilla paitsi pienimmillä tuntimäärillä. FCR-D ylös reservin kohdalla huomataan, että suurin osa vuosiansioista tulee 500 kalleimman tunnin perusteella, eikä tuntimäärän lisäys siis juuri lisää ansioita. FCR-N ja FCR-D alas reservillä puolestaan suuremmat tuntimäärät tuovat myös enemmän tuottoja.

Reservimarkkinoilla aktivoituneiden tarjousten aiheuttama energiankulutus- tai tuotanto korvataan niin sanotun energiakäsittelyn mukaisesti. Aktivoitumisissa siirtyvät energiamäärät ovat kuitenkin Fingridin asiantuntijan (Kakkonen, 2023) mukaan verrattain pieniä, eikä energiakäsittelyä avata siksi tässä sen tarkemmin.

Mikäli reservintoimittaja on myynyt reserviä, mutta ei pysty sitä toimittamaan, joutuu se maksamaan sanktiota Fingridille. Toimittamattoman reservin sanktion määrä on FCR-vuosimarkkinoilla sekä -tuntimarkkinoilla 3-kertainen verrattuna reservin myynnistä saatuun korvaukseen. (Fingrid, 2023i)

3.4 Lämpövarasto reservimarkkinoilla

Suuret sähkönkäyttäjät ja -tuottajat voivat osallistua reservimarkkinoille. Suuret sähkölämmitteiset lämpövarastot kuluttavat merkittävästi sähköä ja toisaalta kestävät nopeita lämmitystehon vaihteluita hyvin (Kivioja, 2023a), joten ne soveltuvat hyvin ylläpitämään reservejä reservimarkkinoilla. Kuten edellä esitettiin, eri reserveillä on erilaiset tekniset vaatimukset, joita ovat tarjousten vähimmäis- ja enimmäiskapasiteetit, aktivoitumisaika sekä myös aktivoitumisen lineaarisuus. Polar Night Energyn hiekka-akku on edellä mainitun kaltainen lämpövarasto ja se täyttää kaikkien Fingridin reservien tekniset vaatimukset (Kivioja, 2023a).

Lämpövarastolla on normaalitilanteessa oltava riittävästi varausta, jotta se voi palvella asiakkaan tarpeita. Toisaalta lämpövaraston varaustasoa ei kannata pitää liian korkealla, sillä sen häviöt ovat sitä suurempia mitä korkeampi varaustaso on ja varastoa halutaan pystyä varaamaan silloin kun sähkön hinta on halpaa. Nyrkkisääntönä voidaan arvioida, että normaalitilanteessa varaston pitäminen 50 % varaustasolla on hyvä valinta (Kivioja, 2023a). Reservimarkkinoille osallistuessa lämpövaraston toimintaa ohjaavat lisäksi reservimarkkinoiden hinnat ja reservin aktivoituminen sitä toimitettaessa. Säätötarjousten hintojen ollessa korkealla kannattaa varaston toteuttaa niitä.

Jotta investointi lämpövarastoon olisi kannattava, täytyy sillä suorittaa tarpeeksi lataussyklejä vuodessa. Lataussyklien minimimäärä rajoittaa alhaalta päin, kuinka paljon energiaa vuodessa energiavarastoon halutaan vähintään laittaa sisään. Lämpövaraston kannattavuuteen vaikuttaa myös ostettavan sähkön hinta. Riittävän halpoja tunteja lämpövaraston lataamiseen on rajallisesti, mikä toisaalta rajoittaa ylhäältä päin lämpövarastoon ladattavan vuotuisen energiamäärän ja siis lataustuntien määrää.

Lämpövarasto voi toimittaa reserviä lupaamalla tarvittaessa nostaa tai laskea sähkön kulutusta. Kulutuksen ylläpito edellyttää, että lämpövaraston kapasiteetti ei ole täynnä. Jos kulutusta halutaan pystyä säätämään molempiin suuntiin, kuten FCR-N reserviä ylläpidettäessä, täytyy lämpövaraston lataustehoa pitää osittain päällä, eli 0 ja 100 % välillä. FCR-N reservin kohdalla on pystyttävä säätämään reservikohteen tehoa molempiin suuntiin yhtä paljon, joten esimerkiksi lataustehon ollessa 75 % maksimitehosta, voidaan

FCR-N reserviä toimittaa enintään 25 % maksimitehosta. Lataustuntien vuotuisen määrän ollessa rajoitettu, on myös niiden tuntien määrä rajoitettu, joilla varasto voi osallistua säätöön molempiin suuntiin. FCR-D alas reservin ylläpito puolestaan edellyttää latausteholta vain, että kulutusta voidaan tarpeen tullen nostaa, eli latausteho on alle 100 % maksimitehosta. Täten FCR-D reservin alassäätöön voidaan osallistua myös niillä tunneilla, joilla varastoa ei ladata. Reservin aktivoituminen ei usein ole pitkäaikaista, joten varastoon siirtyvän energian määrä on melko pientä (Kakkonen, 2023). Täten FCR-D reservin ylläpitoon voitaisiin teoriassa osallistua vuodessa useammalla tunnilla kuin esimerkiksi FCR-N reservin ylläpitoon. Reservien ylläpidosta saatuun ansioon vaikuttaakin tuntihintojen lisäksi toimitettavat tuntimäärät. Optimaalisen strategian kehittäminen eri reserveihin osallistumiseen on jätetty tämän työn tarkastelun ulkopuolelle.

Lämpövaraston toimintaa ohjaavat pääasiassa asiakkaan lämmöntarve, varaston varaustaso sekä sähkön spot-hinta (Kivioja, 2023a), mutta reservimarkkinoille lisätuottojen takia osallistuvan lämpövaraston ohjauksessa myös reservimarkkinahinnat olisivat tärkeitä syötteitä. Reservimarkkinoille voidaan osallistua, vaikka tulevista reservimarkkinahinnoista ei olisi mitään tietoa, mutta jotta voidaan tunnistaa tuottoisimmat tunnit ja kullakin tunnilla valita kaikista tuottoisin markkina, on reservimarkkinahintoja pystyttävä ennustamaan riittävän tarkasti. Reservimarkkinahinnat voisivatkin vaikuttaa lämpövaraston ohjaukseen esimerkiksi siten, ettei lämpövarastoa kannata ladata edes ilmaisella sähköllä, jos tiedetään, että FCR-N tai FCR-D ylös reservien hinnat tulevat nousemaan lähipäivinä korkeiksi, näin mahdollistaen hyvät tuotot.

4. ENNUSTUSMENETELMÄT

Sähkö- ja reservimarkkinahintojen ennustaminen riittävän tarkasti on tärkeää markkinaosapuolille kustannustehokkaan toiminnan takaamiseksi. Sähkön day-ahead spot-hintojen ennustamismenetelmiä käsitteleviä tutkimuksia ja kirjallisuutta löytyy runsaasti, mutta reservimarkkinahintojen ennustamista käsitteleviä lähteitä on verrattain vähän. Reservimarkkinahintojen tilastolliset ominaisuudet poikkeavat merkittävästi sähkön hintojen ominaisuuksista (Giovanelli et al., 2018, luku 1), mutta molempien ennustamisessa on kokeiltu samantyyppisiä ennustusmenetelmiä, joita tässä luvussa esitetään.

Hintadata on markkinasta riippumatta luonteeltaan ajan mukaan järjestettyä, eli puhutaan aikasarjasta. Hintojen aikasarjaennustamiseen on käytetty monenlaisia menetelmiä, joista yleisimpiä ovat tilastolliset menetelmät ja koneoppimismenetelmät. Ennustusmenetelmistä useimmiten neuroverkot ja syväoppiminen osoittivat parhaita tuloksia tässä työssä tarkastelluissa tutkimuksissa.

4.1 Tilastolliset mallit

Tilastolliset mallit suorittavat matemaattisia operaatioita ennustettavan suureen historiallisille arvoille sekä mahdollisten muiden vaikuttavien tekijöiden arvoille. Näin voidaan ennustaa esimerkiksi markkinahintoja. Tilastolliset mallit ovat laajasti käytettyjä niiden vakaan ennustuskyvyn takia ja ne voidaan jakaa yhden selittävän muuttujan regressiomalleihin sekä usean selittävän muuttujan regressiomalleihin (Luo and Miao, 2019, luku 2).

Yhden selittävän muuttujan regressiomalleissa seuraavan ajanjakson hintoja ennustetaan vain hintojen historiadatan perusteella, ja muiden vaikuttavien muuttujien vaikutus katsotaan otetuksi huomioon jo hintojen historiadatassa. Tällaisia malleja ovat esimerkiksi: autoregressiivinen malli (AR), liikkuvan (liukuvan) keskiarvon malli (MA), autoregressiivinen liikkuvan keskiarvon malli (ARMA), autoregressiivinen integroiva liikkuvan keskiarvon malli (ARIMA) ja yleistetty autoregressiivinen ehdollinen heteroskedastinen malli (GARCH). Muiden selittävien muuttujien poisjättäminen luonnollisesti vaikuttaa mallien käyttökelpoisuuteen. (Luo and Miao, 2019, luku 2)

Usean selittävän muuttujan malleissa otetaan hintojen historiadatan lisäksi huomioon muita selittäviä tekijöitä, kuten sähkön kulutus, tuulivoiman tuotanto ja lämpötila. Tällaisia malleja ovat esimerkiksi: usean muuttujan lineaarinen regressio (MLR), dynaaminen har-

moninen regressio (DHR) ja autoregressiiviset mallit, jotka hyödyntävät ulkoisia (exogenous) muuttujia (ARX, ARMAX, ARIMAX). Useamman selittävän tekijän huomioon ottaminen parantaa mallin ennustustarkkuutta verrattuna vain yhden selittävän tekijän huomioon ottamiseen. (Luo and Miao, 2019, luku 2)

Tilastollisten mallien ongelmaksi nostetaan se, että ne ovat yleensä lineaarisia ennustajia, eivätkä tällöin suoriudu hyvin, kun käytettävän datan taajuus on suurta ja heilahtelut nopeita (Lago et al., 2018, luku 1.1; Luo and Miao, 2019, luku 2). Lago et al. (2018, luku 1.1) mukaan tilastolliset mallit suoriutuvat hyvin datan taajuuden ollessa matalaa, kuten viikoittaisen datan kohdalla, mutta tuntikohtaisen hintadatan epälineaarinen käytös voi olla usein liian vaikeaa niille ennustettavaksi. Lago et al. (2018) tuovat kattavassa sähkömarkkinahintojen ennustusmenetelmien suorituskykytutkimuksessaan esiin useita lähteitä, joissa ratkaisuksi epälineaarisen käytöksen ennustamiseen on ehdotettu erilaisia koneoppimisratkaisuja.

Toisaalta Lago et al. (2021a) ehdottavat tulevan, sähkömarkkinahintojen ennustamista koskevan tutkimuksen vertailukohdaksi käytettäväksi sekä tilastollisten että koneoppimismallien huippuluokan (engl. state-of-the-art) benchmark-malleja. Niistä tilastollista LASSO estimated AutoRegressive (LEAR) -mallia luonnehditaan erittäin tarkaksi, ellei jopa tarkimmaksi lineaariseksi malliksi. Tutkimuksessa verrokkina käytetty huippuluokan koneoppimismalli oli yksinkertainen syväoppimismalli, joka päihitti niukasti LEAR-mallin ennustustarkkuudessa. Kuitenkin LEAR-mallin laskentakustannukset olivat jopa 100 kertaa pienemmät verrattuna syväoppimismalliin. Tilastollisilla malleilla on siis myös oma paikkansa ja ne ovat paras vaihtoehto silloin kun päätökset täytyy tehdä sekunneissa. (Lago et al., 2021a, luku 6.4.3)

4.2 Koneoppimismallit

Eräs määritelmä koneoppimiselle on: ”Tietokoneohjelman sanotaan oppivan, jos sen suorituskyky tiettyjä tehtäviä tehdessä paranee kokemuksen myötä.” Koneoppiminen on hyvin poikkitieteellinen tieteenala, joka yhdistelee tuloksia tekoälyn, todennäköisyys- ja tilastotieteen, laskennan vaativuusteorian, säätöteorian, informaatioteorian, filosofian, psykologian, neurobiologian ja muilta tieteenaloilta. (Mitchell, 1997, s. 2)

Koneoppimisen katsotaan usein kuuluvan osana tekoälyn (engl. Artificial Intelligence, AI) laajempaa tutkimusalaa, mutta niitä näkee käytettävän myös ristikkäin. Laskennallinen älykkyys (engl. Computational Intelligence, CI) on myös aiheeseen liittyvä tutkimusala, jonka katsotaan kuuluvan tekoälyn alle, mutta olevan erillinen koneoppimisesta, vaikka sitäkin näkee joskus käytettävän ristikkäin koneoppimisen kanssa. Koneoppimisessa

tällä hetkellä suosittu tekniikka on neuroverkot (neural network NN tai artificial neural network ANN). Syväoppimisella (engl. Deep Learning, DL) tarkoitetaan yleensä ’syviä’ neuroverkkoja (engl. Deep Neural Network, DNN), eli monikerroksisia ja usein suuria neuroverkkoja, jotka kykenevät ratkomaan monimutkaisia ongelmia.

Chandramouli et al. (2019, luku 1.4) esittävät koneoppimisen oppimisprosessin seuraavasti. Oppimisprosessi jakautuu kolmeen osaan: syötedata, abstraktio ja yleistys. Abstraktiossa syötedatan perusteella luodaan malli, joka kuvaa syötedataa laajemmin. Siinä valitun mallityypin tuntemattomat parametrit opitaan syötedatan (ts. koulutusdatan) perusteella, eli malli koulutetaan. Yleistyksessä mallin luoma kuvaus saatetaan sellaiseen muotoon, että sitä voidaan käyttää tulevaisuuden päätöksentekoon, eli ennennäkemättömien syötearvojen pohjalta voidaan ennustaa oikeita arvoja. Yleistys on usein vaikeaa ja kun koneoppimismallia testataan erillisellä tuntemattomalla testidatalla, voidaan törmätä kahteen ongelmaan: koulutettu malli on sovitettu liian hyvin koulutusdataan eikä siten kuvasta todellista ilmiötä (tätä kutsutaan ylisovittamiseksi), tai testidata sisältää ominaisuuksia, joita ei esiinny koulutusdatassa.

Mitchell (1997, luku 1.2) puolestaan esittää oppimisprosessin esimerkin kautta, tarkastellen tammipeliä opettelevaa ohjelmaa. Tammipeliohjelman tehtävänä on oppia antamaan numeroarvon kullekin pelilaudan mahdolliselle tilalle vain sen tiedon perusteella, voitettiinko kyseinen peli vai ei. Arvojen perusteella ohjelma osaa valita aina parhaan seuraavan siirron, mutta peli saa siirtojen onnistumisesta palautetta vasta pelin lopputuloksen perusteella. Tämänkaltainen epäsuora palaute tekee oppimisesta vaikeaa. Ohjelman tavoitteena tässä on siis oppia funktio, joka kuvaa lautapelin tilat johonkin reaaliseen numeroarvoon, ja tätä funktiota kutsutaan tavoitefunktioksi. Usein mahdollisia tavoitefunktioita on olemassa useita ja sopivan tavoitefunktion valinta onkin oppimisen onnistumisen kannalta tärkeää. Tavoitefunktion esitystapa (mallityyppi) on toinen tärkeä valinta ja erilaisia esitystapoja voisivat olla esimerkiksi polynomifunktio tai neuroverkko. Käytännössä todellista tavoitefunktiota ei välttämättä pystytä koskaan täysin oppimaan, mutta hyvällä mallityypin valinnalla voidaan oppia hyviä approksimaatioita siitä. Mitchellin (1997, luku 1.2.5) mukaan opittu tavoitefunktion approksimaatio on eräs koulutusdatan pohjalta luotu yleistys, joka pyrkii esittämään myös koulutusdatassa esiintymättömät tapaukset. Yleistyksen onnistuminen riippuu paljon sekä koulutusdatasta, että siitä minkälaiseen dataan sitä verrataan.

Koneoppiminen voidaan jakaa kolmeen pääkategoriaan: valvottu oppiminen (engl. supervised learning), valvomaton oppiminen (engl. unsupervised learning) ja vahvistusoppiminen (engl. reinforcement learning, RL) (Bonaccorso, 2017; Chandramouli et al.,

2019, luku 1.5). Näiden lisäksi kirjallisuudessa esiintyy myös muunlaisia kategorisointeja, ja esimerkiksi neuroverkot katsotaan joskus omaksi kategoriakseen.

Valvotussa oppimisessa koneoppimismallia koulutetaan datalla, joka sisältää pareittain syötearvot sekä niiden odotetut tulokset (engl. label). Näin malli saa tarkan mitan tekemilleen virheille ja pystyy korjaamaan parametrejaan minimoidakseen globaalin tappiofunktion (engl. loss function), näin ajaen virheen kohti nollaa. Valvottu oppiminen voidaan jakaa ongelman tyypin mukaan luokitteluun ja regressioon. Luokittelutehtävän kohdalla mallin tehtävänä on määrittää tarkasteltavan ominaisuuden luokka tai kategoria. Regressiotehtävän kohdalla puolestaan tehtävänä on määrittää jatkuva numeerinen arvo (Bonaccorso, 2017, s. 10-11). Jatkuvia numeroarvoja määritettäessä on yksittäiselle ennusteelle helppo laskea ennustevirhe, kun taas luokittelussa voi olla vaikeampi määrittää virheen suuruus. Huomionarvoista on, että valvotun oppimisen koneoppimismalli on aina korkeintaan niin hyvä kuin data, jolla se on koulutettu (Chandramouli et al., 2019, luku 1.5.1).

Valvomattomassa oppimisessa käytettävä data ei sisällä odotettuja tuloksia, eikä siten absoluuttista virhettä. Valvomatonta oppimista voidaan hyödyntää datajoukon jakamisessa osajoukoiksi tai ryppäiksi (engl. clustering) sen perusteella kuinka samankaltaisia datapisteet keskenään ovat. (Bonaccorso 2017, luku 12) Oppimisongelmana tässä on miten datajoukko tulisi jakaa osiin. Datajoukon jaottelemiseen on olemassa useita iteratiivisia algoritmeja, joista esimerkiksi k-means-algoritmi käyttää datapisteiden keskinäisiä etäisyyksiä hyödyksi. Mikäli osa datasta sisältää odotetun tuloksen, niin puhutaan semi-valvotusta oppimisesta (Bonaccorso 2017, 12). Toinen käyttötapa valvomattomalle oppimiselle on assosiaatio analyysi (engl. association analysis), jossa määritetään yhteyksiä erilaisten tekijöiden välille. (Chandramouli ym. 2019, 1.5.2)

Vahvistusoppiminen perustuu niin kutsutun agentin ja ympäristön väliseen vuorovaikutukseen sekä oppimiseen yrityksen ja erheen kautta. Vahvistusoppiminen voidaan kuvata muodollisesti Markovin päätösprosessin (engl. Markov decision process, MDP) kautta. Prosessissa on määritelty viisi ominaisuutta:

- joukko ympäristön tiloja (engl. state) $\boldsymbol{S}$
- joukko toimintoja (engl. action) $\boldsymbol{A}$
- siirtymädynamiikka $\boldsymbol{T}(s_{t+1}|s_t, a_t)$ joka kertoo mihin tilaan s_{t+1} päädytään, kun suoritetaan toiminto a_t tilassa s_t
- palkkiofunktio (engl. reward function) $\boldsymbol{R}(s_t, a_t, s_{t+1})$ joka antaa ulostulona palkkion r_{t+1}

- alennusparametri $\gamma \in [0,1]$, jonka matalammat arvot antavat suuremman painoarvon välittömälle palkkiolle

Kun agentti suorittaa toiminnon $\boldsymbol{a}_t$ tilassa $\boldsymbol{s}_t$, saa se aikaan agentin ja ympäristön siirtymisen uuteen tilaan $\boldsymbol{s}_{t+1}$. Jokaisen siirtymän myötä agentti saa ympäristöltä palautteena palkkion r_{t+1}. Agentin tehtävänä on oppia sellainen menettelytapa (engl. policy) π, joka maksimoi kumulatiivisen, alennusparametrilla kerrotun palkkion $R = \sum \gamma^t r_{t+1}$. Optimaalinen menettelytapa maksimoi palkkion, ja kun menettelytavalle annetaan syötteeksi ympäristön tila, se antaa vastauksena parhaan toiminnon, joka kyseisessä tilassa voidaan tehdä. (Arulkumaran et al., 2017) Käytännön esimerkki vahvistusoppimisesta voisi olla esimerkiksi itseajava auto, joka opettelee yrityksen ja erheen kautta ajamaan suunnittelijansa haluamalla tavalla, tehden ohjausliikkeitä (toimintoja a_t) ympäristössään (tilat s_t) ja korjaten toimintojen sarjaa maksimoidakseen saamansa kumulatiivisen palkkion, kunnes se on oppinut optimaalisen toimintojen sarjan eli menettelytavan.

Neuroverkot (ANN) ovat koneoppimisen osa-alue, joka jäljittelee aivoissa toimivia biologisia neuroverkkoja (Chandramouli et al., 2019, luku 10.3). Neuroverkoilla voidaan approksimoida epälineaarisia funktioita ja ratkaista sekä regressio- että luokitteluongelmia. Neuroverkko koostuu sisääntulo- ja ulostulokerroksesta sekä mahdollisista piilotetuista kerroksista, joiden neuronit voivat arkkitehtuurin mukaan olla yhteydessä toisiinsa useilla eri tavoilla (Chandramouli et al., 2019, luku 10.6). Sisääntulokerroksessa on yhtä monta neuronia kuin syötettävän datan dimensio on ja vastaavasti ulostulokerroksessa on yhtä monta neuronia kuin ulostulomuuttujan dimensio on, mutta piilotettujen kerrosten neuronien määrää voidaan vapaasti vaihdella. Jokaiseen neuroniin liittyy kolme pääkomponenttia (Chandramouli et al., 2019, luku 10.3):

- joukko synapseja, eli yhteyksiä i, joihin liittyy signaali x_i ja painokerroin w_i;
- summaaja $y_{sum} = \sum_{i=1}^{n} w_i x_i$, johon lisätään usein kynnysarvo (bias) b;
- aktivaatiofunktio, joka tuottaa ulostulosignaalin y_{out} vain, mikäli sen saama syötesignaali y_{sum} ylittää tietyn kynnyksen (useimpien aktivaatiofunktioiden ulostulosignaali saa arvon väliltä [0,1])

Aktivaatiofunktioiden ulostulosignaalia kutsutaan myös neuronin aktivaatioksi, josta tulee seuraavalle kerrokselle signaali x_i. Kuvassa 4 on esitetty yksittäisen keinotekoisen neuronin rakenne, missä neuroniin sisään tulevat signaalit x_i saapuvat ensin painotettuina summaajaan, johon lisätään kynnysarvo b. Summaajan ulostulosignaali y_{sum} etenee aktivaatiofunktioon, joka tuottaa ulostulosignaalin y_{out}, mikäli y_{sum} ylitti sen aktivaatiokynnyksen. Ulostulo y_{out} puolestaan etenee seuraavan kerroksen sisääntulosignaaliksi.

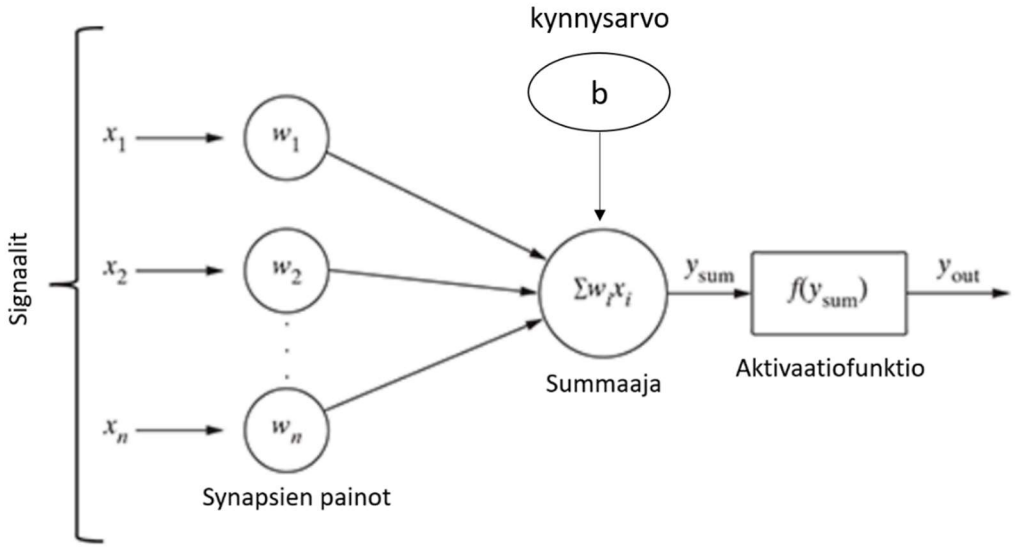

Kuva 4. *Keinotekoisen neuronin rakenne. Muokattu lähteestä (Chandramouli et al., 2019)*

Yksinkertaisin neuroverkkojen arkkitehtuuri on vain sisään- ja ulostulokerroksista koostuva, täysin kytketty ja eteenpäin syöttävä neuroverkko. Täysin kytketty verkko on sellainen, jossa jokainen neuroni on kytkettynä jokaiseen seuraavan kerroksen neuroniin. (Chandramouli et al., 2019, luku 10.6) Yleisempi tapaus on vastaavanlainen arkkitehtuuri, joka sisältää myös piilotettuja kerroksia ja tällaisia neuroverkkoja kutsutaan joskus myös nimellä monikerroksinen perceptron (engl. Multilayer Perceptron, MLP). Muita monimutkaisempia arkkitehtuureja ovat muun muassa kilpaileva (engl. Competitive Network) sekä takaisinkytketty neuroverkko (engl. recurrent neural network, RNN) (Chandramouli et al., 2019, luku 10.6). Takaisinkytketyissä neuroverkoissa on takaisinkytkettyjä osia, jotka mahdollistavat tiedon säilyttämisen, ja niitä käytetään aikariippuvaisen datan mallintamiseen. Eräitä takaisinkytkettyjä neuroverkkoja ovat Long short-term memory (LSTM) ja Gated recurrent unit (GRU). Vielä eräs tyyppi on konvoluutionaaliset neuroverkot (engl. Convolutional Neural Network, CNN), joita on käytetty muun muassa konenäössä ja lääketieteellisten kuvien analysoinnissa. (Ugurlu et al., 2018, luku 3)

Useamman kuin yhden piilotetun kerroksen omaavaa neuroverkkoa voidaan kutsua DNN:ksi, mutta eri lähteissä niitä kutsutaan ristiin myös nimityksillä MLP ja ANN. Syvien neuroverkkojen määritelmä ei ole siis erityisen selkeä. Lago et al. (2018, luku 2.2) määrittelivät tutkimuksessaan kehittämänsä yksinkertaisen DNN:n olevan jatke perinteiselle MLP:lle, joka vaatii kuitenkin tiettyjä mallimuutoksia, kuten erilaisten aktivaatiofunktioiden käyttöä tehokkaan koulutuksen takaamiseksi.

4.3 Ennustusmenetelmien tarkkuuden arviointi

Ennustusmenetelmää valittaessa on tarkkuus hyvin oleellinen, ehkä olennaisin, mittari menetelmän hyvyydestä. Tarkkuuden tutkimista varten on olemassa useita erilaisia mittareita, joilla ennustevirhettä voidaan arvioida. Kaikilla mittareilla on kuitenkin omat rajoitteensa ja jotkut niistä ovat parempia kuin toiset, joten hyvän mittarin tai mittareiden valinta on tärkeää. Mittarit voidaan jakaa neljään kategoriaan: skaalasta riippuvat, prosentuaaliset, suhteelliset ja skaalatut mittarit. Taulukkoon 3 on listattu erilaisia ennustevirheiden mittareita.

Taulukko 3. *Ennustusmenetelmien tarkkuuksien arvioinnissa käytettyjä yleisiä mittareita (Hyndman and Koehler, 2006).*

MSE	Keskineliövirhe	ka(e_t^2)
RMSE	Keskineliövirheen juuri	$\sqrt{MSE}$
MAE	Absoluuttinen keskivirhe	ka$(\lvert e_t \rvert)$
MAPE	Absoluuttinen keskivirhe prosentteina	ka$(\lvert p_t \rvert)$
RMSPE	Keskineliövirheen juuri prosentteina	$\sqrt{\mathrm{ka}(p_t^2)}$
sMAPE	Symmetrinen abs. keskivirhe prosentteina	ka$(200\lvert Y_t - F_t \rvert/(Y_t + F_t))$
MRAE	Suhteellinen abs. Keskivirhe	ka$(\lvert r_t \rvert)$
GMRAE	Geometrinen suhteellinen abs. keskivirhe	gka$(\lvert r_t \rvert)$
RelMAE	Absoluuttisten keskivirheiden suhde	MAE/MAE_b
PB(MAE)	Prosenttia parempi (MAE)	100 ka$(I\{MAE < MAE_b\})$
MASE	Skaalattu absoluuttinen keskivirhe	ka$\left(e_t/(\frac{1}{n-1}\sum_{i=2}^{n}\lvert Y_i - Y_{i-1} \rvert)\right)$

F_t on ennuste ja Y_t on todennettu tapahtuma
$e_t = Y_t - F_t$ on ennustevirhe
$p_t = 100e_t/Y_t$ on prosentuaalinen virhe
$r_t = e_t/e_t^*$ on suhteellinen virhe, missä e_t^* on vertailuna käytetyn ennustemenetelmän virhe
$I\{u\} = 1$, jos u on tosi ja 0 muuten

Skaalasta riippuvat mittarit, kuten MSE, RMSE ja MAE ovat yleisesti käytettyjä, mutta niitä voidaan käyttää eri menetelmien vertaamiseen vain saman datajoukon kohdalla. Prosentuaaliset mittarit, kuten MAPE, RMSPE ja sMAPE ovat myös yleisiä ja niiden etuna on riippumattomuus datan skaalasta, joka ratkaisee skaalasta riippuvien mittareiden ongelman. Prosentuaalisten mittareiden ongelmana kuitenkin on lähestyminen kohti ääretöntä, kun ennustettavan suureen toteutuneet arvot lähestyvät nollaa. Suhteelliset mittarit, kuten MRAE ja GMRAE, lasketaan käytetyn ennustemenetelmän ja toisen, standardin vertailumenetelmän (engl. benchmark) virheiden suhteesta, ja näillä esiintyy samankaltainen ongelma kuin prosentuaalisilla mittareilla. RelMAE puolestaan lasketaan käytetyn menetelmän MAE ja vertailumenetelmän MAE_b suhteesta, joista harvoin kumpikaan on nolla, mutta ongelmana on, että joudutaan tekemään useampi ennuste, joka ei aina ole mahdollista. PB puolestaan vertaa kuinka suuri prosenttiosuus käytetyn menetelmän ennusteista päihittää vertailumenetelmän, mutta tämä ei anna tietoa siitä kuinka paljon parempi käytetty menetelmä on. (Hyndman and Koehler, 2006, luku 2) Monet edellä mainituista mittareista on mahdollista laskea keskiarvon sijasta myös mediaanin avulla (esim. MAE ⟹ MdAE) ja toisaalta suhteellisia ja skaalattuja mittareita voidaan määritellä myös muiden, kuin MAE:n kautta (esim. RelRMSE).

Kaikilla edellä esitellyillä on omat ongelmansa, jonka vuoksi yleistä standardia ei ole ennen ole ollut käytössä. Tähän ratkaisuksi Hyndman ja Koehler (2006, luku 3) ovat esittäneet uutena ratkaisuna skaalattujen mittareiden käyttöönottamista yleiseksi standardiksi, joista MASE heidän mielestään on paras. Skaalatut mittarit lasketaan skaalatun virheen

$$q_t = \frac{e_t}{\frac{1}{n-1}\sum_{i=2}^{n}|Y_i - Y_{i-1}|} \tag{3}$$

perusteella, jossa käytetyn ennustemenetelmän virhe e_t skaalataan naiivin ennustusmenetelmän näytteen sisäisen MAE:lla, joka on yllä olevan yhtälön nimittäjässä. Naiivissa ennustusmenetelmässä aikasarjan seuraavan arvon ennustetaan olevan sama kuin nykyinen todellinen arvo. Skaalatusta virheestä saadaan MASE laskemalla sen keskiarvo aikasarjan yli. Hyndmanin ja Koehlerin (2006, luku 3) mukaan skaalatut mittarit soveltuvat lähes jokaiseen tilanteeseen, ja niitä on helppo tulkita: kun MASE > 1, suoriutuu käytetty ennustusmenetelmä huonommin kuin naiivi ennustaja ja päinvastoin kun MASE < 1 (pätee myös muille skaalatuille mittareille). Lago et al. (2021a, luku 5.4.2) kuitenkin nostavat esiin myös MASE:n kohdalla olevia ongelmia, joita ei tässä avata tarkemmin, ja esittävät paremmaksi mittariksi rMAE:a. Voidaan siis todeta, ettei MASE ole myöskään täysin ongelmaton.

Edellä mainittuja yleisiä mittareita käytetään ongelmistaan huolimatta edelleen usein. Kattavassa kokooma-artikkelissaan Weron (2014, luku 3.3) toteaa, että MAPE on ylivoimaisesti suosituin mittari. MAPE:a parempi mittari on silti siitä johdettu sMAPE, joka ei ole herkkä toteutuneiden arvojen pienille ja nolla-arvoille. Laajassa suorituskykytutkimuksessaan Lago, De Ridder ja De Schutter (2018, luku 2.4) ovatkin ottaneet juuri sMAPE:n ennustusmenetelmiensä tarkkuuden mittariksi. Voidaan todeta, että parhaita mittareita vaikuttavat lähteiden perusteella olevan sMAPE, MASE ja rMAE, mutta koska kaikilla näistä on myös omat ongelmansa, niin paras tapa on käyttää useita eri mittareita, jottei yhdelle mittarille ominaiset ongelmat pääse vääristämään tuloksia kokonaisuudessaan.

Sopivien mittareiden valitsemisen lisäksi toinen oleellinen asia on, että verrattavien menetelmien välinen tarkkuusero on tilastollisesti merkittävää, eikä johdu esimerkiksi satunnaisesta vaihtelusta. Tämän tilastollisen merkittävyyden osoittamiseen käytetään useissa lähteissä Diebold-Mariano testiä (Halužan et al., 2020; Kraft et al., 2020; Lago et al., 2018; Weron, 2014), mutta sitä ei esitellä tässä sen tarkemmin.

5. RESERVIMARKKINAHINTOJEN ENNUSTAMINEN KONEOPPIMISMALLILLA

Reservimarkkinoiden seuraavan päivän tuntihintojen tarkka ennustaminen avaa reservintoimittajille mahdollisuuden keskittää reservien toimittamisen kaikista tuottoisimmille tunneille sekä markkinoille ja näin kasvattaa voittojaan. Reservimarkkinahinnat ovat kuitenkin luonteeltaan volatiilimpia kuin sähkömarkkinoiden spot-hinnat, joka tekee ennustamisesta haastavampaa. Sähkö- ja reservimarkkinoiden hintojen ennustamiseen on käytetty samankaltaisia malleja, mutta reservimarkkinoiden erilaiset markkinadynamiikat, kuten suuret hintapiikit ja kausittaisuuden puute, vaikeuttavat hintojen ennustamista. Reservimarkkinoiden hintojen ennustamisesta löytyi huomattavasti vähemmän tutkimuksia kuin sähkön spot-hintojen ennustamisesta. Löytyneet tutkimukset osoittivat, että koneoppimismallit päihittivät tilastollisiin mallit ja syvät neuroverkot osoittivat usein parhaita tuloksia, mutta toisaalta Lago et al. (2018, luku 5.7.3) toi esiin lähteitä, joissa näin ei ollut, ja lisäksi Lago et al. (2021a) nostivat esiin yleisiä ongelmia sähkömarkkinahintojen ennustamista koskevissa tutkimuksissa.

Useat sähkö- ja reservimarkkinoiden toimijat ovat kehittäneet omia malleja hintojen ennustamiseen, mutta niitä on harvoin julkisesti saatavilla. Reservimarkkinatoimijalle voi siis olla kiinnostavaa kehittää oma ennustusmalli ja tällöin suunnitteluprosessin yleisten piirteiden tunteminen on merkityksellistä. Neuroverkkojen ja muiden koneoppimismallien suunnitteluprosessit sisältävät yleensä useita mallista riippumattomia vaiheita.

5.1 Aiheeseen liittyvä tutkimus

Reservimarkkinoiden hintojen ennustamisesta löytyi tutkimusta verrattain vähän. Tutkimustiedon löytämistä on vähäisyyden lisäksi vaikeuttanut se, että terminologia ei ole vielä vakiintunutta. Reservimarkkinoihin liittyvässä tutkimuksessa on käytetty monia englanninkielisiä termejä, kuten ”*Ancillary energy market”* ja *”Ancillary energy services”* (Giovanelli et al., 2018)*, ”Reserve and regulation markets”* (Wang et al., 2014)*, ”Reserve market”* ja *“Balancing reserve market”* (Kraft et al., 2020) sekä *”Balancing market”* (Dimoulkas et al., 2016).

Sähkömarkkinoiden day-ahead spot-hintojen ennustamisesta puolestaan löytyi paljon tutkimusta. Hintojen ennustaminen sähkö- ja reservimarkkinoilla on sikäli samanlainen tehtävä, että molemmilla pyritään ennustamaan ajasta riippuvaa hintadataa, usein seu-

raavan päivän tuntihintoja. Käsitellyissä tutkimuksissa hinta muodostuu sähkö- ja reservimarkkinoilla usein samanlaisesti, eli korkeimman hyväksytyn tarjouksen mukaan, kuten myös EU-komissio on ehdottanut reservimarkkinoiden integroimista koskevassa EBGL-asetuksessaan (ENTSO-E, 2018), poikkeuksena (Kraft et al., 2020). Ennustustehtävät poikkeavat toisistaan siinä, että sähkö- ja reservimarkkinoiden dynamiikat poikkeavat toisistaan huomattavasti. Reservimarkkinahintojen tilastolliset ominaisuudet ovat hyvin erilaisia kuin sähkön hintojen: reservimarkkinahinnoilla esiintyy toistuvia ja suuria hintapiikkejä, ne omaavat heikomman kausittaisuuden ja niiden käyttäytyminen voi muuttua merkittävästi lyhyellä aikavälillä (Giovanelli et al., 2018, luvut 1, 3.3; Wang et al., 2014). Sähkö- ja reservimarkkinoiden erilaisista dynamiikoista huolimatta molempien ennustamisessa on useissa tutkimuksissa käytetty samankaltaisia tilastollisia ja koneoppimismenetelmiä. Tästä syystä myös sähkömarkkinahintojen ennustamista käsittelevää tutkimusta on käytetty johtopäätösten vetämisessä.

Käydään ensin läpi enemmän tutkittua sähkön hinnan ennustamista. Lago et al. (2018) testasivat kattavassa suorituskykytutkimuksessaan EPEX-Belgian sähkön day-ahead hintojen ennustamiseen 6 vuoden datan pohjalta yhteensä 27 erilaista mallia, joista 7 oli erilaisia koneoppimismalleja ja 4 syväoppimismalleja. Datana käytettiin menneitä hintoja sekä seuraavan päivän ennusteita kulutuksesta ja tuotannosta EPEX-Belgia ja EPEX-France markkinoilta. Syväoppimismalleja olivat DNN, LSTM, GRU ja CNN, joista DNN tuotti parhaan tuloksen sMAPE:n arvolla 12,34% ja GRU ja LSTM seuraavaksi parhaat tuloksilla 13,04% ja 13,06%. CNN suoriutui hieman huonommin arvolla 13,91% ja useat yksinkertaisemmat koneoppimismallit päihittivät sen. (Lago et al., 2018, luku 5.5.1) Yllättävää oli se, että syväoppimismalleista yksinkertaisin, eli DNN suoriutui parhaiten (Lago et al., 2018, luku 5.7.1), sekä ehkä se, että ylipäänsä mikään malli ei vaikuttanut yltävän erittäin tarkkoihin tuloksiin.

Kuten sanottu, sähkön hinnan ennustamista käsitteleviä tutkimuksia on tehty runsaasti. Kuitenkin suuri osa tutkimuksista käyttävät erilaisia datajoukkoja, erilaisia ohjelmistototeutuksia sekä käyttävät erilaisia tarkkuusmittareita eivätkä täten useinkaan ole keskenään vertailukelpoisia (Lago et al., 2021a). Edellä mainittujen ongelmien lisäksi Lago et al. (2021a) tuovat tutkimuksessaan esiin seuraavanlaisia ongelmia: mallien välinen vertailu ei ole reilua, vaan kehittyneitä malleja verrataan yksinkertaisempiin malleihin; testausdatan pituudet ovat usein liian lyhyitä; jotkin tutkimuspaperit eivät tarjoa tarpeeksi yksityiskohtia tutkimuksen toistamiseen. Samat ongelmat koskettavat osin myös tässä työssä tarkasteltuja tutkimuksia, mutta niiden huomioon ottaminen on tämän työn tarkastelun ulkopuolella. Ratkaisuksi näihin ongelmiin Lago et al. (2021a) ovat ehdottaneet

yksinkertaisia, mutta suorituskykyisten avoimen lähteen ennustusmalleja sekä datajoukkoja käytettäväksi benchmarkkina sekä joukkoa parhaita käytäntöjä, joita noudattamalla sähkömarkkinahintojen ennustuksen alueella voidaan tehdä merkityksellisempää tutkimusta. Benchmark-malleja vertailtiin tutkimuksessa 5 eri markkinapaikan välillä, 5 eri tarkkuusmittarin avulla, ja esimerkiksi mallien sMAPE:n arvot vaihtelivat eri markkinapaikoilla väleillä: 4,970 – 5,982% (NP); 12,004 – 13,677% (PJM); 14,106 – 17,293% (EPEX BE); 11,488 – 14,054% (EPEX FR); 14,680 – 17,600% (EPEX DE). Benchmark-malleista kehitettiin myös yhdistelmämalleja (engl. ensemble), jotka tuottivat hieman parempia tuloksia. (Lago et al., 2021a) Ehdotetut benchmark-mallit ovat saatavilla avoimena lähdekoodina (Lago et al., 2021b).

Reservimarkkinahintojen ennustamisessa käytettiin samankaltaisia ennustusmenetelmiä ja algoritmeja kuin sähkön hinnan ennustuksessa. Useimmissa tässä työssä tarkastelluissa, reservimarkkinahintojen ennustusta käsittelevissä tutkimuksissa kehitettiin ennustusta varten jonkinlainen koneoppimismalli tai -malleja ja verrokkimenetelmänä käytettiin useimmiten jonkinlaista tilastollista mallia. Lähteissä käytettiin eri tarkkuusmittareita mallien ennustustarkkuuden arvioimiseen, joka on vain yksi tekijä siinä, miksi tutkimukset eivät ole keskenään kovinkaan vertailukelpoisia. Taulukossa 4 on koottuna nämä lähteet, kehitetyt mallit, verrokkimenetelmät, kohdemuuttujat, joita pyrittiin ennustamaan sekä markkinapaikat, joilla ennustuksia tehtiin. Kussakin tutkimuksessa selkeästi paremmin suoriutuneet mallit on merkitty taulukoon lihavoituina.

Taulukko 4. *Reservimarkkinoiden ennustamista koskevat tutkimukset, niissä kehitetyt mallit, verrokkimenetelmät, kohdemuuttujat sekä markkinapaikat .*

	Kehitetyt mallit	**Verrokki-menetelmät**	**Kohdemuuttujat**	**Markkinapaikat**
Wang et al. 2014	MRJD, MRS	-	Seuraavan päivän keskimääräiset hinnat	Ontario, New York – useita reservejä
Dimoulkas et al. 2016	HMM	ARMA	Hinta ja volyymi seuraavalle tunnille sekä seuraaville 12-36 tunnille	Ruotsi Nordpool SE2
Giovanelli et al. 2017	**Linearinen regressio**, Regressio puu, **SVR, GDBT**	ARIMA	Seuraavan päivän 24 tunnin hinnat	Suomi FCR-N
Giovanelli et al. 2018	**ANN**	**SVR**, ARIMA	Seuraavan päivän 24 tunnin hinnat	Suomi FCR-N
Kraft et al. 2020	**MLP (ANN)**	SARIMAX, Naiivi ennustaja	Kapasiteetilla painotettu keskiarvo seuraavan viikon hyväksytyistä tarjouksista	Itävalta, Belgia, Ranska, Saksa, Alankomaat, Sveitsi - yhteinen FCR

Lähteistä Giovanelli et al. (2017) ja (2018) sekä Dimoulkas et al. (2016) tutkivat seuraavan päivän 24 tunnin hintojen ennustamista, kun taas Wang et al. (2014) tutkivat seuraavan päivän keskimääräisiä hintoja ja Kraft et al. (2020) tutkivat seuraavan viikon hyväksyttyjen tarjousten keskimääräisiä hintoja.

Wang et al. (2014) esittivät tutkimuksessaan niin sanottuja kuvailevia malleja reservimarkkinahintojen ennustamista varten. Datana käytettiin Ontarion markkinoilta aikavälin 1.5.2002 – 31.12.2007 dataa sekä New Yorkin markkinoilta aikavälin 5.2.2005 – 31.12.2008 dataa. Käytetyt mallit olivat MRS ja MRJD, joista MRS onnistui paremmin ennustamaan reservimarkkinahintoja. Mallit eivät kuitenkaan soveltuneet lyhyen aikavälin ennustamiseen vaan pitemmän aikavälin ennustamiseen.

Dimoulkas et al. (2016) käyttivät Hidden Markov Modelia (HMM) reservimarkkinahintojen ennustamiseen, käyttäen datana Ruotsin SE2 hinta-alueen kalenterivuoden 2014 dataa. Tulokset eivät kuitenkaan poikenneet referenssimalleista, eivätkä onnistuneet ennustamaan reservimarkkinoiden day-ahead hintoja hyvin.

Giovanelli et al. (2017) loivat tutkimuksessaan arkkitehtuurin virtuaalivoimalalle, joka osallistui FCR-N markkinoille. Tutkimuksen päätavoitteena oli ennustaa Suomen FCR-N-reservin day-ahead tuntihintoja. Käytetty data oli kalenterivuosilta 2015 – 2016, josta

vuoden 2016 dataa käytettiin testaukseen. Ennustusmenetelminä vertailtiin 4 erilaista koneoppimismenetelmää sekä ARIMA-mallia. Kahta eri lähestymistapaa kokeiltiin, joista ensimmäisessä hyödynnettiin vain sellaisia ulkopuolisia muuttujia, joille oli tarkkoja ennusteita saatavilla, ja toisessa hyödynnettiin lisäksi muuttujia, joille ennusteita ei ollut olemassa, mutta jotka korreloivat vahvasti FCR-N datan kanssa. Toinen lähestymistapa osoittautui paremmaksi ja koneoppimismalleista lineaarinen regressio, SVR ja GDBT päihittivät verrokkimenetelmänä käytetyn ARIMA-mallin. Ennustustarkkuutta arvioitiin MSE:n avulla, joka oli paremman lähestymistavan kanssa 173,76 (Lineaarinen regressio), 258,04 (Regressio puu), 148,84 (SVR) ja 118,97 (GDBT).

Tuoreemmassa tutkimuksessa Giovanelli et al. (2018) pyrkivät ennustamaan FCR-N -reservin day-ahead tuntimarkkinahintoja neuroverkon (ANN) avulla. Tutkimuksessa tunnistettiin ennustamisen kannalta relevantit datalähteet ja analysoitiin Suomen FCR-N markkinoiden hintoja kalenterivuosilta 2015 – 2016, josta vuoden 2016 dataa käytettiin testaukseen. Kehitetyssä metodologiassa valittiin strategia aikasarjan ennustamiseen, määriteltiin datan esikäsittelymenetelmät, mallin validointimenetelmä sekä suorituskykymittari. Lopuksi metodologiassa määriteltiin tärkeimmät suunnitteluvalinnat, jotka neuroverkon luomisessa tehtiin. Neuroverkko suoriutui hintojen ennustamisesta paremmin kuin SVR-malli ja selkeästi paremmin kuin ARIMA-malli. Tutkimuksessa osoitettiin, että neuroverkon ennustusvirheet johtuivat pitkälti muutamista poikkeuksellisista päivistä. Neuroverkon ennustustarkkuuden havaittiin heikkenevän lineaarisesti ennustushorisonttia kasvatettaessa päivästä viikkoon. Tutkimuksen tuloksena esitettiin jokaisen kuukauden keskimääräinen MSE kullekin mallille kuvaajan muodossa, josta voidaan arvioida ennustusvirheiden olevan välillä 45 – 270 (ANN), 55 – 260 (SVR) ja 60 – 405 (ARIMA).

Kraft et al. (2020) pyrkivät tutkimuksessaan ennustamaan FCR-markkinoilla seuraavan viikon hyväksyttävien pay-as-bid tarjousten keskimääräisiä hintoja neuroverkolla. Tutkimuksessa käytetty data oli aikaväliltä 2017 – 2018 (Q1 – Q3), josta vuoden 2018 viikkohintoja käytettiin testaukseen. Dataa oli siis niukasti ja siksi mallin kouluttamiseen käytettiin ensemble-menetelmää, jossa luotiin 50 samanlaista mallia, joita koulutettiin rinnakkain satunnaisilla lähtöarvoilla. Ensemble-menetelmät soveltuvat erityisesti tilanteisiin, kun saatavissa olevaa dataa on niukasti. Keski-Euroopan yhteisellä FCR-markkinapaikalla oli tutkimuksen tekemisen aikaan pay-as-bid hinnanmuodostusmekanismi, kun taas esimerkiksi Suomen FCR-markkinoilla hinnanmuodostus tapahtuu korkeimman hyväksytyn tarjouksen mukaan. Pay-as-bid hinnanmuodostus, oli heidän tutkimuksensa aikana sittemmin muuttunut korkeimman hyväksytyn tarjouksen mukaiseksi, ja tarjousten kesto puolestaan oli muuttunut viikon mittaisesta 4 tuntiin (Kraft et al., 2020, luku 5), joka

on lähempänä Suomen FCR-markkinoiden mallia, jossa on käytössä korkeimman hyväksytyn tarjouksen mukainen hinnoittelu ja tarjousten kestona 1 tunti. Ennustustarkkuutta arvioitiin MAPE:n avulla, joka oli kaikkien kehitettyjen mallien kohdalla alle 7% ja parhaan mallin kohdalla 1,97%.

Tarkastelluissa tutkimuksissa esitetyt ennustustarkkuudet poikkeavat toisistaan huomattavasti. Tässä on tärkeää huomata aiemmin jo esiin nostetut ongelmat tutkimusten vertailukelpoisuudessa: tutkimuksissa käytetään erilaisia datajoukkoja, mallinnusperiaatteita ja tarkkuusmittareita. Siispä tutkimuksien ennustustarkkuuksia voidaan verrata vain saman tutkimuksen sisällä olevien mallien kesken.

Useimpien löydettyjen tutkimusten perusteella neuroverkot soveltuvat hyvin sähkömarkkinoiden sekä reservimarkkinoiden hintojen ennustamiseen. Muista koneoppimismalleista myös lineaarinen regressio, SVR ja GDBT suoriutuivat selkeästi verrokkina olleita tilastollisia malleja paremmin. Erityisesti syvät neuroverkot tuottivat verrokkimalleihinsa nähden hyviä tuloksia hintojen ennustamisessa niin reservimarkkinoiden kuin sähkömarkkinoiden hintojen ennustamisessa (Giovanelli et al., 2018; Kraft et al., 2020; Lago et al., 2021a, 2018). Neuroverkkojen paremmuus ei kuitenkaan ole aivan kiistatonta. Lago et al. (2018) toivat myös esiin useita sähkömarkkinahintojen ennustusta käsitteleviä tutkimuksia, joissa neuroverkot eivät suoriutuneet parhaiten, mutta toisaalta he tarjosivat siihen myös useita selityksiä (Lago et al., 2018, luku 5.7.3). Toinen huomio neuroverkoista on, että vaikka takaisinkytketyt neuroverkot, kuten GRU ja LSTM soveltuvat periaatteessa erityisen hyvin juuri aikasarjojen ennustamiseen, eivät ne suoriutuneet Lago et al. (2018) tutkimuksessa parhaiten. Tämän syyksi he arvioivat muun muassa, että takaisinkytketyt neuroverkot vaativat monimutkaisemman rakenteensa vuoksi enemmän koulutusdataa (Lago et al., 2018, luku 5.7.1).

5.2 Koneoppimismallin suunnitteluvaiheet

Ennustukseen käytettävien mallien ja erityisesti koneoppimismallien suunnittelussa ja kehittämisessä on useita samankaltaisia vaiheita riippumatta siitä mikä malli varsinaisesti on kyseessä. Ennustusmallin valinnassa olennaista on ongelman tyypin tunnistaminen ja siihen sopivan mallin valinta. Käytettävän algoritmin valinta onkin yksi alkuvaiheessa tehtävistä suunnittelupäätöksistä. Jatkuvan hintadatan, kuten sähkö- ja reservimarkkinahintojen, ennustamiseen voidaan valita regressio-ongelmien ratkaisuun soveltuvia malleja. Kuten aiemmin todettiin, erityisesti syvät neuroverkot ovat tuottaneet lupaavia tuloksia sähkö- ja reservimarkkinahintojen ennustamisessa.

Datan valinta on ehkä tärkein suunnitteluvaihe. Ensinnäkin ennustettavasta muuttujasta on oltava riittävästi dataa ensin mallin kouluttamiseen ja sen jälkeen testaamiseen koulutusdatasta erillisellä datalla. Lago et al. (2021a, luku 5.1) suosittelevat testausdatan minimipituudeksi yhtä vuotta, jotta erilaiset kausittaiset käyttäytymiset tulisi havaittua. Toisaalta Giovanelli et al. (2018, luku 3.1) valitsivat tutkimuksessaan datan kokonaispituudeksi 2 vuotta, josta 1 vuosi oli testausdataa, ja he totesivat, että energiamarkkinoilla tapahtuneiden muutosten vuoksi aiempien vuosien sisällyttämisen lisäisi malleihin kohinaa ja heikentäisi niiden ennustustarkkuutta. Toiseksi hintadataan vaikuttavien merkityksellisten ulkoisten tekijöiden valinta on avainasemassa ennustamisessa (Giovanelli et al., 2018, 2017). Ulkoisten tekijöiden valinta riippuu huomattavasti siitä mitä ennustettava data on. Ulkoisista tekijöistä valitaan sellaisia, jotka vaikuttavat suoraan ennustettavaan dataan tai korreloivat vahvasti sen kanssa. Mikäli ulkoisesta tekijästä on saatavilla tarkkoja ennusteita käytettävälle ennustushorisontille, voidaan niitä käyttää. Jos tarkkoja ennusteita ei ole saatavilla, voidaan käyttää myös viiveellisiä arvoja, mikäli ne korreloivat ennustettavan datan kanssa (Giovanelli et al., 2017, luku 4). Giovanelli et al. (2018, luku 3.1, 2017, luku 4) käyttivät esimerkiksi tutkimuksissaan yhteensä 70 ja 64 erilaista ulkoista tekijää, joita olivat esimerkiksi seuraavan päivän Elspot-hinnat, energian tuotannon ja kulutuksen ennusteet, viikonpäivät ja juhlapyhät sekä erilaiset säätiedot.

Ennustettavaa dataa voidaan analysoida aikasarja-analyysin menetelmin kuten (Giovanelli et al., 2018) tekivät. He tutkivat aikasarja-analyysin avulla ennustettavan datan autokorrelaatiota, sekä keskilukujen ja varianssin vaihtelua. Osa ennustettavan datan menneistä arvoista, kuten 24 tunnin viiveelliset arvot, korreloivat vahvasti nykyisten arvojen kanssa, jonka myötä ne otettiin mukaan nykyisten arvojen ennustamiseen. Datan keskilukujen ja varianssien vaihdellessa eri ajanjaksojen välillä, voidaan päätellä, että data on epästationääristä (Giovanelli et al., 2018, luku 3.2). Epästationäärisyys on merkille pantavaa, sillä johtopäätösten vetäminen eri aikasarjojen välillä on ongelmallista silloin, kun data on epästationääristä (Lago et al., 2021a, luku 5.4.2).

Dataa on yleensä esikäsiteltävä ennen kuin sitä voidaan käyttää mallin kouluttamiseen. Esikäsittelyyn kuuluu muun muassa datan jakaminen koulutus- ja validointidataan, piikkien prosessointi, ja datan normalisointi. Myös puuttuvia arvoja voi joutua käsittelemään, mutta sitä ei tehty tässä työssä käsitellyissä tutkimuksissa. Kuten aiemmin todettiin, Lago et al. (2021a, luku 5.1) suosittelivat tutkimuksessaan, että mallin validointiin käytettävän testidatan vähintään yhden kokonaisen vuoden. Harvinaisia datapiikkejä voidaan rajoittaa esimerkiksi enintään kolmen keskihajonnan suuruisiksi, joskin tutkimuksessa (Lago et al., 2018) tämä osoittautui hyödylliseksi tilastollisten mallien, muttei koneoppimismal-

lien kohdalla. Mallien koulutuksessa käytettävä data voidaan normalisoida mallien tarkkuuden parantamiseksi. Normalisointi voidaan tehdä esimerkiksi välille $[0,1]$ tai $[-1,1]$. Huomionarvoista on, että normalisoitua dataa käytetään vain mallien koulutuksessa parametrien estimointiin, eikä esimerkiksi tarkkuusmittareiden laskentaan tai tilastollisten testien yhteydessä. (Lago et al., 2018, luku 5.1.3)

Mallin validointi tarkoittaa sen suorituskyvyn hyväksi toteamista validointidatalla, eli sellaisella datalla, jota se ei ole käyttänyt koulutukseensa. Taulukon 4 tutkimuksista nousi esiin kaksi erilaista lähestymistapaa validointiin: laajenevan ikkunan menetelmä, jossa koulutusdatan määrä kasvaa ajan myötä ja kaikki mennyt data huomioidaan jokaisella aika-askeleella (Kraft et al., 2020), sekä liikkuvan ikkunan menetelmä, jossa jokaisella aika-askeleella käytetään yhtä suuri pätkä koulutusdataa, joka liikkuu eteenpäin ajan edetessä, näin jättäen ikkunan pituutta kaukaisemmat datapisteet huomiotta (Dimoulkas et al., 2016; Giovanelli et al., 2018, 2017).

Tarkkuusmittarien tai mittarin valinta on oleellista, sillä kuten aiemmin todettiin, on mittareilla erilaisia rajoitteita eivätkä kaikki sovellu esimerkiksi sellaisen datan ennustamiseen, jossa esiintyy 0-arvoja. Olisikin järkevää käyttää yhden tarkkuusmittarin sijaan useita, jotta saadaan kattavampi kuva mallin suoriutumisesta. Taulukon 4 tutkimuksista (Giovanelli et al., 2018, 2017) käyttivät MSE:tä, (Kraft et al., 2020) käyttivät RMSE:tä ja MAPE:a, (Dimoulkas et al., 2016) käyttivät MAE:a ja (Wang et al., 2014) laskivat yleisesti käytettyjen tarkkuusmittareiden sijaan muun muassa ennustettujen arvojen keskiarvojen ja keskihajontojen poikkeamia todellisista arvoista.

Hyperparametrien optimointi on tehtävä ennen lopullisen mallin koulutukseen ryhtymistä. Hyperparametreja ovat sellaiset parametrit, joiden arvo on valittava ennen mallin parametrien estimointia (Lago et al., 2018, luku 2.3). Tällaisia ovat neuroverkkojen kohdalla esimerkiksi: piilotettujen kerrosten lukumäärä, neuronien lukumäärä piilotetuissa kerroksissa; aktivaatiofunktiot; gradientin laskeutumisen optimointialgoritmi, esimerkiksi Stochastic gradient descent (SGD); poisjättöjen (engl. dropout) prosenttiosuus (Giovanelli et al., 2018, luku 4.5). Kraft et al. (2020, luku 3.3.2) mukaan hyperparametrien valintaan ei yleisesti ottaen ole olemassa optimaalista konfigurointialgoritmia, mutta sen sijaan on useita nyrkkisääntöjä. Giovanelli et al. (2018, luku 4.5) toteuttivat neuroverkkojen arkkitehtuurien valinnan vahvistusoppimisen avulla empiirisesti kokeilemalla, lähteen (Baker et al., 2017) mukaisesti, testaten useita erilaisia arkkitehtuureja ja valiten kaksi parhaiten suoriutuvaa. Lago et al. (Lago et al., 2018, luku 2.3) puolestaan käyttivät jokaisen mallin optimointiin samaa automatisoitua proseduuria, erityisesti puu-rakenteen

omaavaa Parzen-estimaattoria. Lago et al. (2021a, luku 5.7) huomauttivat, että hyperparametrien optimointi tulisi toteuttaa erillisellä validointidatalla, jota ei käytetä valmiiden mallien testaamiseen, jotta vältetään mallien ylisovittuminen testidataan.

Mallin tarkkuutta voi olla järkevää tarkastella eri pituisilla ajanjaksoilla. Näin voidaan huomata datassa erilaisia käyttäytymismalleja ja arvioida tiettyjen tekijöiden vaikutusta virheeseen.

Lopulta kehitettyä mallia on syytä verrata johonkin standardiin ennustusmenetelmään tai -menetelmiin, jotta mallin ennustuskykyä voidaan suhteuttaa. Kun kehitetyn mallin ja verrokkimallin ennustustarkkuus on arvioitu jollain sopivalla mittarilla tai mittareilla, on vielä hyvä tarkistaa tarkkuuksien eron tilastollinen merkitsevyys käyttäen sopivaa tilastollista testiä, kuten Diebold-Mariano testiä.

6. JOHTOPÄÄTÖKSET

Tämän työn tavoitteena oli selvittää millaiset koneoppimismallit voisivat olla soveltuvia reservimarkkinahintojen ennustamiseen sekä millaisia yleisiä suunnitteluvaiheita ennustuksessa käytettävien koneoppimismallien suunnitteluprosessiin kuuluu. Työ tehtiin yhteistyössä Polar Night Energy Oy:n (PNE) kanssa ja sen kehittämän hiekkalämpövaraston näkökulmasta. Työssä tutustuttiin lämpövarastoihin, sähkö- ja reservimarkkinoihin sekä ennustusmenetelmiin ja selvitettiin, millaisia ennustusmenetelmiä sähkö- ja reservimarkkinahintojen ennustuksessa on tutkimuksissa tähän mennessä käytetty ja mitkä niistä pärjäsivät parhaiten. Lisäksi useista eri tutkimuksista tunnistettiin samankaltaisia suunnitteluvaiheita, joita koneoppimismallien suunnittelussa ja kehittämisessä hyödynnettiin. Työ tehtiin PNE:n hiekkalämpövaraston näkökulmasta, mutta se soveltuu muidenkin reservimarkkinatoimijoiden käytettäväksi.

Useiden regressio-ongelmia ratkaisevien koneoppimismallien todettiin päihittävän tilastolliset verrokkimallit. Neuroverkkopohjaiset mallit ja erityisesti suhteellisen yksinkertaiset syvät neuroverkot nousivat useissa tässä työssä käsitellyissä tutkimuksissa parhaiten suoriutuviksi. Sähkömarkkinahintojen ennustamista käsittelevien tutkimusten vertailukelpoisuudesta nousi esiin useita ongelmia: erilaisten datajoukkojen, ohjelmistototeutusten ja tarkkuusmittareiden käyttö; kehittyneiden mallien vertailu yksinkertaisiin malleihin; testausdatan pituudet liian lyhyitä; tutkimukset eivät tarpeeksi yksityiskohtaisia toistettaviksi. Nämä pätevät myös reservimarkkinahintojen ennustamisen kohdalla, mutta niitä ei tämän työn laajuuden vuoksi otettu huomioon. Tutkimusten vertailukelpoisuuteen liittyvät ongelmat on silti syytä pitää mielessä eri tutkimuksissa esiintyviä malleja vertailtaessa. Näihin ratkaisuksi on esitetty käytettäväksi benchmark-malleja ja -datajoukkoja sekä erilaisia parhaita käytäntöjä.

Työssä tunnistettiin myös useissa tutkimuksissa esiintyneitä koneoppimismallien suunnittelu-vaiheita, joita olivat algoritmin valinta, datan ja ulkoisten tekijöiden valinta, aikasarja-analyysi, datan esikäsittely, mallin validointi, tarkkuusmittarien valinta, hyperparametrien optimointi ja tulosten tilastollisen merkittävyyden toteaminen.

Tulevaisuudessa reservimarkkinoita koskevaa tutkimusta toivottavasti nähdään runsaasti lisää. Uusissa tutkimuksissa toivottavasti huomioidaan vertailukelpoisuuteen liittyvät ongelmat ja jonkinlainen tutkimusalan laajuinen benchmark saavutetaan tutkimusten ja mallien paremman vertailun mahdollistaen. Reservimarkkinat ovat alttiita muutoksille

teknologian edistyessä ja EU:n lainsäädännön lisääntyessä. Siksi markkinoiden kehityssuunnan arvioiminen on myös tärkeää. Tulevaisuudessa jatkotutkimusaiheina voisivatkin olla reservimarkkinoiden kehityssuunnan arvioiminen maailmalla sekä toiseksi myös erilaisten ennustusmenetelmien laajempi vertailu jonkin benchmarkin pohjalta, huomioiden myös vaaditun laskentatehon aiheuttamat kustannukset.

LÄHTEET

Alva, G., Lin, Y., Fang, G., 2018. An overview of thermal energy storage systems. Energy 144, 341–378. https://doi.org/10.1016/j.energy.2017.12.037

Arulkumaran, K., Deisenroth, M.P., Brundage, M., Bharath, A.A., 2017. Deep Reinforcement Learning: A Brief Survey. IEEE Signal Process. Mag. 34, 26–38. https://doi.org/10.1109/MSP.2017.2743240

Baker, B., Gupta, O., Naik, N., Raskar, R., 2017. DESIGNING NEURAL NETWORK ARCHITECTURES USING REINFORCEMENT LEARNING.

Bonaccorso, G., 2017. Machine Learning Algorithms. Packt Publishing.

Chandramouli, S., Dutt, S., Kumar Das, A., 2019. Machine Learning. Pearson India Education Services Pvt. Ltd.

Dimoulkas, I., Amelin, M., Hesamzadeh, M.R., 2016. Forecasting balancing market prices using Hidden Markov Models, in: 2016 13th International Conference on the European Energy Market (EEM). Presented at the 2016 13th International Conference on the European Energy Market (EEM), IEEE, Porto, Portugal, pp. 1–5. https://doi.org/10.1109/EEM.2016.7521229

Energiateollisuus, 2023. Kaukolämpöverkkoja yli 15 000 km [WWW Document]. URL https://energia.fi/energiasta/energiaverkot/kaukolampoverkot (accessed 4.18.23).

ENTSO-E, 2018. AN OVERVIEW OF THE EUROPEAN BALANCING MARKET AND ELECTRICITY BALANCING GUIDELINE.

Fingrid, 2023a. Sähköjärjestelmän tila [WWW Document]. URL https://www.fingrid.fi/sahkomarkkinat/sahkojarjestelman-tila/ (accessed 4.16.23).

Fingrid, 2023b. Kuinka osallistua reservimarkkinoille [WWW Document]. URL https://www.fingrid.fi/sahkomarkkinat/reservit-ja-saatosahko/kuinka-osallistua-reservimarkkinoille/ (accessed 8.21.23).

Fingrid, 2023c. Johdanto sähkömarkkinoihin [WWW Document]. URL https://www.fingrid.fi/sahkomarkkinat/markkinoiden-yhtenaisyys/johdanto-sahkomarkkinoihin/#saatosahko--ja-reservimarkkinat- (accessed 4.10.23).

Fingrid, 2023d. Osa pohjoismaista sähköjärjestelmää [WWW Document]. URL https://www.fingrid.fi/kantaverkko/kehittaminen/pohjoismainen-sahkojarjestelma-ja-liitynnat-muihin-jarjestelmiin/ (accessed 5.15.23).

Fingrid, 2023e. Pohjoismainen tasehallinta [WWW Document]. URL https://www.fingrid.fi/sahkomarkkinat/markkinoiden-yhtenaisyys/pohjoismainen-tasehallinta/#tasehallintahankkeen-referenssiryhma (accessed 5.15.23).

Fingrid, 2023f. Yhtenäiset sähkömarkkinat [WWW Document]. URL https://www.fingrid.fi/sahkomarkkinat/markkinoiden-yhtenaisyys/ (accessed 5.15.23).

Fingrid, 2023g. Reservimarkkinat [WWW Document]. URL https://www.fingrid.fi/sahkomarkkinat/reservit-ja-saatosahko/#reservivelvoitteet-ja-hankintakanavat (accessed 4.10.23).

Fingrid, 2023h. Reservituotteet ja reservien markkinapaikat.

Fingrid, 2023i. Ehdot ja edellytykset taajuuden vakautusreservin (FCR) toimittajalle.

Fingrid, 2023j. Taajuusohjattu käyttö- ja häiriöreservi (FCR-tuotteet) [WWW Document]. URL https://www.fingrid.fi/sahkomarkkinat/reservit-ja-saatosahko/taajuusohjattu-kaytto--ja-hairioreservi/#hankinta (accessed 4.12.23).

Fingrid, 2023k. Taajuusohjattu käyttö- ja häiriöreservi (FCR-N, FCR-D ylös ja FCR-D alas), vuosimarkkinahankinta ja toteutuneet tuntikaupat [WWW Document]. URL https://www.fingrid.fi/sahkomarkkinainformaatio/reservimarkkinainformaatio/Taajuusohjattu-kaytto-ja-hairioreservi-vuosimarkkinahankinta-ja-toteutuneet-tuntikaupat/ (accessed 4.10.23).

Fingrid, 2022a. Ehdot ja edellytykset automaattisen taajuuden palautusreservin (aFRR) toimittajalle.

Fingrid, 2022b. Ehdot ja edellytykset manuaalisen taajuuden palautusreservin (mFRR) toimittajalle.

Fingrid, 2022c. Taajuuden vakautusreservien (FCR) teknisten vaatimusten todentaminen ja hyväksyttämisprosessi.

Fingrid, 2020. Ehdot ja edellytykset nopean taa- juusreservin (FFR) toimittajalle.

Giovanelli, C., Liu, X., Sierla, S., Vyatkin, V., Ichise, R., 2017. Towards an aggregator that exploits big data to bid on frequency containment reserve market, in: IECON 2017 - 43rd Annual Conference of the IEEE Industrial Electronics Society. Presented at the IECON 2017 - 43rd Annual Conference of the IEEE Industrial Electronics Society, IEEE, Beijing, pp. 7514–7519. https://doi.org/10.1109/IECON.2017.8217316

Giovanelli, C., Sierla, S., Ichise, R., Vyatkin, V., 2018. Exploiting Artificial Neural Networks for the Prediction of Ancillary Energy Market Prices. Energies 11, 1906. https://doi.org/10.3390/en11071906

Golmohamadi, H., Larsen, K.G., Jensen, P.G., Hasrat, I.R., 2022. Integration of flexibility potentials of district heating systems into electricity markets: A review. Renew. Sustain. Energy Rev. 159, 112200. https://doi.org/10.1016/j.rser.2022.112200

Halužan, M., Verbič, M., Zorić, J., 2020. Performance of alternative electricity price forecasting methods: Findings from the Greek and Hungarian power exchanges. Appl. Energy 277, 115599. https://doi.org/10.1016/j.apenergy.2020.115599

Hyndman, R.J., Koehler, A.B., 2006. Another look at measures of forecast accuracy. Int. J. Forecast. 22, 679–688. https://doi.org/10.1016/j.ijforecast.2006.03.001

IEA, 2022. Heating [WWW Document]. URL https://www.iea.org/fuels-and-technologies/heating (accessed 6.20.23).

Jaller-Makarewicz, A.M., 2021. As fossil fuel prices skyrocket globally, renewables grow steadily cheaper [WWW Document]. URL https://ieefa.org/resources/fossil-fuel-prices-skyrocket-globally-renewables-grow-steadily-cheaper (accessed 5.15.23).

Kakkonen, J., 2023. Puhelinhaastattelu koskien reservimarkkinoita.

Kivioja, V., 2023a. Lisätietoja kandiin - Polar Night Energy.

Kivioja, V., 2023b. Materiaalia kandiin - Polar Night Energyn esitteitä ja teknologiakuvaus.

Kraft, E., Keles, D., Fichtner, W., 2020. Modeling of frequency containment reserve prices with econometrics and artificial intelligence. J. Forecast. 39, 1179–1197. https://doi.org/10.1002/for.2693

Lago, J., De Ridder, F., De Schutter, B., 2018. Forecasting spot electricity prices: Deep learning approaches and empirical comparison of traditional algorithms. Appl. Energy 221, 386–405. https://doi.org/10.1016/j.apenergy.2018.02.069

Lago, J., Marcjasz, G., De Schutter, B., Weron, R., 2021a. Forecasting day-ahead electricity prices: A review of state-of-the-art algorithms, best practices and an open-access benchmark. Appl. Energy 293, 116983. https://doi.org/10.1016/j.apenergy.2021.116983

Lago, J., Marcjasz, G., De Schutter, B., Weron, R., 2021b. epftoolbox [WWW Document]. URL https://github.com/jeslago/epftoolbox (accessed 6.27.23).

Luo, B., Miao, S., 2019. A Literature Survey on Electricity Price Forecasting in Deregulated Markets, in: 2019 IEEE Sustainable Power and Energy Conference (ISPEC). Presented at the 2019 IEEE Sustainable Power and Energy Conference (iSPEC), IEEE, Beijing, China, pp. 359–365. https://doi.org/10.1109/iSPEC48194.2019.8974939

McGrath, M., 2022. Climate change: “Sand battery” could solve green energy’s big problem. BBC.

Mitchell, T.M., 1997. Machine Learning.

Polar Night Energy, 2023a. Technology.

Polar Night Energy, 2023b. References [WWW Document]. URL https://polarnightenergy.fi/references (accessed 4.18.23).

Polar Night Energy, 2023c. Solutions.

Rahman, M.M., Oni, A.O., Gemechu, E., Kumar, A., 2020. Assessment of energy storage technologies: A review. Energy Convers. Manag. 223, 113295. https://doi.org/10.1016/j.enconman.2020.113295

Rangel-Martinez, D., Nigam, K.D.P., Ricardez-Sandoval, L.A., 2021. Machine learning on sustainable energy: A review and outlook on renewable energy systems, catalysis, smart grid and energy storage. Chem. Eng. Res. Des. 174, 414–441. https://doi.org/10.1016/j.cherd.2021.08.013

Sarbu, I., Sebarchievici, C., 2018. A Comprehensive Review of Thermal Energy Storage. Sustainability 10, 191. https://doi.org/10.3390/su10010191

Sharma, A.K., Sharma, C., Mullick, S.C., Kandpal, T.C., 2017. Solar industrial process heating: A review. Renew. Sustain. Energy Rev. 78, 124–137. https://doi.org/10.1016/j.rser.2017.04.079

Suomen Tuulivoimayhdistys ry, 2022. Tuulivoimahankkeet Suomessa 11/2022.

Ugurlu, U., Oksuz, I., Tas, O., 2018. Electricity Price Forecasting Using Recurrent Neural Networks. Energies 11, 1255. https://doi.org/10.3390/en11051255

Wang, P., Zareipour, H., Rosehart, W.D., 2014. Descriptive Models for Reserve and Regulation Prices in Competitive Electricity Markets. IEEE Trans. Smart Grid 5, 471–479. https://doi.org/10.1109/TSG.2013.2279890

Weron, R., 2014. Electricity price forecasting: A review of the state-of-the-art with a look into the future. Int. J. Forecast. 30, 1030–1081. https://doi.org/10.1016/j.ijforecast.2014.08.008

Zavertkin, Mikko, 2023. Energianhallintajärjestelmä mikroverkon energiaresurssien käytön taloudelliseen optimointiin. Trepo.