

Roope Lepistö

**TUOTANNON JA KULUTUKSEN ENNUS-  
TAMINEN TULEVAISUUDEN SÄHKÖ-  
ENERGIAJÄRJESTELMISSÄ**  
15 minuutin aikaresoluutioon siirtyminen

Diplomityö  
Tekniikan ja luonnontieteiden tiedekunta  
Matti Vilkkö  
Yrjö Majanne  
Toukokuu 2021

# TIIVISTELMÄ

Roope Lepistö: Tuotannon ja kulutuksen ennustaminen tulevaisuuden sähköenergiajärjestelmissä – 15 minuutin aikaresoluutioon siirtyminen

Diplomityö

Tampereen yliopisto

Automaatiotekniikka

Toukokuu 2021

---

Sähkön kulutuksen ja tuotannon tasapainottaminen on tärkeä aihe teknologian näkökulmasta. Ongelmat pohjautuvat sähköenergiajärjestelmän luonteeseen, sillä sähkön varastoiminen on erittäin hankalaa, kun on kyse suurista määristä. On siis tärkeää, että sähköä tuottavilla tahoilla on jonkinlainen käsitys siitä, kuinka paljon sähköä tarvitaan kulutettavaksi seuraavana päivänä. Siihen kuinka paljon sähköä kuluu vuorokauden aikana vaikuttaa moni yksittäinen tekijä. Sähkönkulutukseen kotitalouksissa vaikuttavat esimerkiksi asukaslukumäärä, asukkaiden aktiviteetit, kodin elektroniikka, mutta myös ympäristötekijät, kuten ulkolämpötila, ilmankosteus ja auringonpaiste. Sähkönkulutukseen vaikuttaa myös sähkömarkkinoilla vallitsevat energiahinnat ja sähkömarkkinaa säätelevät lait. Nämä monet tekijät määrittävät sen, miten kuluttajat ovat tottuneet sähköä käyttämään. Näiden tekijöiden avulla kulutusta pyritään ennustamaan erilaisin metodein. Lisäksi sähkönkulutukseen vaikuttavat sääolosuhteet ja kulutustottumukset. Sellaisille henkilöille, joilla on pörssisähkösopimus, voi myös spot-hinta vaikuttaa kulutukseen. Siksi tässä diplomityössä tutkitaan pääasiallisesti lyhyen aikavälin kulutuksen ennustamista. Myös työn alaotsikko ”15 minuutin aikaresoluutioon siirtyminen” viittaa siihen, että työssä on kiinnostuttu lyhyen aikavälin sisällä tapahtuvista muutoksista.

Euroopan komission linjauksen 2017/2095 mukaan jokainen Euroopan Unionin jäsenmaa oli velvollinen siirtämään 15 minuutin tase selvitysjaksoon vuoden 2020 loppuun mennessä. Monissa maissa on kuitenkin jouduttu lykkäämään käyttöönottoa myöhemmäksi käytännöllisten tai teknologisten ongelmien takia. Esimerkiksi Suomessa 15-minuutin tase otetaan näillä näkymin käyttöön vasta vuonna 2023. 15-minuutin tase tulee vaikuttamaan sähköenergiajärjestelmiin yleisesti, mutta erityisesti vaihtelevan tuotannon osalta. Tasejakauksissa esimerkiksi aurinkovoiman osalta voi tapahtua 15 minuutin aikana suurtakin heilahtelua, kun kokonainen aurinkovoimala jää hetimitäisesti pilvirykelmän takia ilman tuotantoa.

Tämän työn tarkoituksena on tutustua joihinkin ennustusmenetelmiin ja analysoida, miten 15-minuutin taseeseen siirtyminen tulee vaikuttamaan kulutuksen ja tuotannon ennustamiseen sekä ennustusparametreihin eri aikaresoluutioilla. Keskihajontoja ja poikkeamia tutkimalla analysoidaan datassa esiintyviä muutoksia eri tase selvitysjaksoilla.

Sekä tuulivoimatuotannon että aurinkovoimatuotannon havaittiin olevan vaikeasti ennustettavaa. Kummankin tuotantomuodon tunti- ja 15-minuutin keskiarvojen välille syntyi merkittäviä poikkeamia, jotka voivat vaikeuttaa myytävän sähköenergian hinnan määrittämistä. Keskihajonnat kuvastivat hyvin tuotantomuotojen vaihtelevuutta ja epävarmuutta.

Avainsanat: Tuntitase, varttitase, koneoppiminen, tekoäly

Tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck –ohjelmalla.

# ABSTRACT

Roope Lepistö: Forecasting production and demand in the future electrical energy systems –  
Shifting to 15 minutes time resolution

Master of Science Thesis

Tampere University

Automation Engineering

May 2021

---

Balancing production and consumption of the electricity is one key point from the technological point of view. The problems base on the characteristics of electricity since storing electricity is very difficult. The producers have importance to know how much electricity they need to produce during the following day. There are many individual variables which affect how much electricity the consumers will consume in one day. Different variables inside households include for example number of tenants, their activities, their electronical devices, but also variables external to households like solar radiation, temperature, humidity, precipitation etc. There are also other factors to electricity consumption such as electricity prices and laws which are adjusting the energy market. Previously presented variables are key factors to determine how the consumers are used to consume electricity. These variables are the basis of the methods for consumption forecasting. The weather outside and the consumption behavior can also affect to consumption of electrical energy. Electricity price is one key factor for those with the contract, which bases on the Spot-price. That is why this thesis will concern mostly short-term forecasting. The subtitle “Shifting to 15 minutes time resolution” also indicates this phenomenon.

Based on the alignment of European commission (2017/2095), every member country of the European Union was obliged to use the 15-minutes imbalance settlement period (ISP) due to end of the year 2020. Several countries have had to postpone the implementation of the 15-minutes ISP because of either the practical or the technological issues. It seems that Finland will apply stricter ISP in 2023. The 15-minutes ISP will have general consequences in the grid, but more evidently amongst the variable renewable energy sources. The solar energy production distributions can vary a lot among the adjacent 15-minute’s time periods. This can be caused by big clusters of clouds blocking the sunlight that radiates the solar plant.

The purpose of this thesis is present some of the forecasting methods and analyze how shifting to different ISP will affect forecasting of consumption and especially production. Some analysis on standard deviation and the differences of 15-minutes and 1-hour averages is also done to research how the data behaves and how the 15-minutes ISP will affect to operation of making forecasts.

Both wind power and solar power were observed to be hard to forecast. There were significant differences between hourly and quarter hourly averages, which will make adjusting the price of electrical energy to be sold tough. The standard deviations described the variability and uncertainty of the production form well.

Keywords: hourly balance settlement, quarter hourly balance settlement, machine learning, Artificial Intelligence

The originality of this thesis has been checked using the Turnitin OriginalityCheck service.

# ALKUSANAT

Tahdon kiittää Kampusareenan aurinkovoimalan sähköenergiadatoista Hildenin Anttia ja muita henkilöitä, jotka olivat niitä hankittaessa projektissa mukana. Haluan kiittää myös työtä varten saadusta tuulidatasta vastuussa olleita henkilöitä sekä ohjaajiani Yrjö Majannetta ja Matti Vilkkoa kaikesta ajasta, jolloin sain tukea ja apua diplomityöhöni. Kiitos myös kihlatulleni Oonalle sekä omalle perheelleni kaikesta tuesta, jota sain opinnäytetyön kirjoittamisen aikana.

Tampereella, 20.5.2019

Roope Lepistö

# SISÄLLYSLUETTELO

1. JOHDANTO .....	1
1.1    Motivointia.....	1
1.2    Tutkimuskysymys.....	3
1.3    Työn menetit .....	3
1.4    Työn rakenne.....	4
2. SÄHKÖMARKKINAT.....	5
2.1    Nord Pool.....	5
2.2    Säätösähkömarkkinat.....	8
2.3    Taajuusreservimarkkinat .....	9
2.4    Tasemalli ja -selvitys .....	10
2.5    Tasehallinta ja taseselvityksen osapuolet.....	11
3. TUOTANTO, KULUTUS JA ENNUSTAMINEN .....	14
3.1    Sähköntuotanto pohjoismaissa .....	14
3.2    Tuotannon suunnittelu.....	15
3.3    Sähkönkulutus .....	18
3.4    Sähkönkulutukseen vaikuttavat muuttujat .....	19
3.5    Mitä ennustetaan ja miksi?.....	19
4. ENNUSTAMISEN MENETELMÄT .....	27
4.1    Koneoppiminen ja tekoäly kulutuksen ja tuotannon ennustamisessa .	27
4.2    Aikaresoluution muutoksen vaikutukset ennustusmenetelmiin .....	43
5. VARTTITASE.....	44
5.1    Miksi tarpeellinen? .....	44
5.2    Vaikutukset kantaverkkoon .....	45
5.3    Vaikutukset ennustamiseen .....	46
5.4    Vaikutukset tuotantojakaumiin.....	47
5.5    Tuloksien tulkintaa .....	79
6. YHTEENVETO.....	80
LÄHTEET .....	81

# LYHENTEET JA MERKINNÄT

AI	engl. Artificial Intelligence, tekoäly
AIC	engl. Akaike's Information Criterion
ANN	engl. Artificial Neural Network, neuroverkko
ARIMA	engl. Auto Regressive Integrated Moving Average
ARMA	engl. Auto Regressive Moving Average
BELM	engl. Bootstrap-based Extreme Learning Machine
CET	engl. Central European Timezone
ED	engl. Economic Dispatch
ELM	engl. Extreme Learning Machine
EML	engl. Exact Maximum Likelihood
EnKF	engl. Ensemble Kalman Filter
ESM	engl. Exponential Smoothing Method
EU	engl. European Union, Euroopan Unioni
f-ARIMA	engl. Auto Regressive Fractionally Integrated Moving Average
FCRBM	engl. Factored Conditional Restricted Boltzmann Machine
FCR-D	engl. Frequency Containment Reserve – Disturbances, taajuusohjattu häiriöreservi
FCR-N	engl. Frequency Containment Reserve – Stochastic Imbalances, taajuusohjattu käyttöreservi
FFR	engl. Fast Frequency Reserve
HVDC	engl. High Voltage Direct Current, Suurjännitetasavirta
LSTM	engl. Long Short-Term Memory
MAPE	engl. Mean Absolute Percentage Error, prosentuaalinen keskipoikkeama
METAR	engl. Meteorological Aerodrome Report
OPF	engl. Optimal Power Flow
PICP	engl. Prediction Interval Coverage Probability
PSO	engl. Particle Swarm Optimization
RMSE	engl. Root-Mean-Square Deviation, keskipoikkeama
RNN	engl. Recurrent Neural Network, takaisinkytketty neuroverkko
SARIMA	engl. Seasonal Auto Regressive Integrated Moving Average
SLFN	engl. Single-hidden Layer Feedforward Neural networks
SLNN	engl. Single Layer Neural Network
SPA	engl. Solar Position Algorithm
SSA-SVR	engl. Seasonality-adjusted Support Vector Regression
SVM	engl. Support Vector Machine, tukivektorikone
WAsP	engl. Wind Atlas Analysis and Application Program

## Muuttujat

$a_j, b_j, c_j$	Yksikön $j$ kustannuskertoimia
$C_i(P)$	Yksikön $i$ kustannusfunktio.
$F_j(P_j)$	Yksikön $j$ kustannusfunktio
$I(i, t)$	Yksikön $i$ sitoutumisaste tuotantoon ajan hetkellä $t$ .
$N_g$	Yksiköiden lukumäärä.
$N_t$	Aikasykliin lukumäärä.
$P(i, t)$	Yksikön $i$ todellinen tuotanto ajan hetkellä $t$ .
$P_j$	Yksikön $j$ todellinen tuotto (MW)
$SD(i, t)$	Yksikön $i$ sammutuskustannukset ajan hetkellä $t$ .
$SU(i, t)$	Yksikön $i$ käynnistyskustannukset ajan hetkellä $t$ .

# 1. JOHDANTO

## 1.1 Motivointia

Sähköenergia on nykymaailmassa välttämätöntä, sillä kaikki elektroniset laitteet vaativat toimiakseen sähköä. Pienelektronikassa laitteet sisältävät usein akun tai paristoja, joissa sähköenergia on varastoituna käyttöä varten. Oğcun et. al. tutkimuksessa [71] kerrotaan, että isoissa sähköverkoissa suurien sähkömäärien varastoiminen on käytännössä mahdotonta. Tämän seurauksena sähkönkulutuksen ja -tuotannon ennustaminen on tärkeää, jotta sähköntuottajat osaisivat vastata kuluttajapuolen kysyntään, eikä hukkaan menevää ylijäämää syntyisi.

Miksi sähkönkulutusta ennustetaan? Koska varastointi on hankalaa, täytyy sähkö välittää suoraan tuotannosta tarvittavien välikäsien kautta loppukäyttäjälle. Tuotannon on tärkeää osata suunnitella tuotantovolyymit sen mukaan, kuinka paljon tarvetta sähkölle on lähitulevaisuudessa. Lisäksi sähköntuotanto tarvitsee tietoa siitä, millä yksiköillä heidän kannattaa tuottaa sähköä, jotta kokonaiskysyntä saadaan tuotettua mahdollisimman halvalla ja tehokkaasti. Vaihtelevan uusiutuvan tuotannon lisääntyminen vaikeuttaa sähköverkon tasapainottamista ja uusiutuvan energian integroimista verkkoon, joten uusiutuvan energian ennustamisen tarve kasvaa. Ennusteita tekevät kantaverkkoyhtiöt, sähköyhtiöt, tuuliyhtiöt, sähkölaitokset sekä muut sähkömarkkinoilla toimivat tahot.

Ennusteita tehdään erilaisiin tarpeisiin eri aikaikkunoihin. Pisimmät ennusteet ovat vuoden tai jopa 10 vuoden luokkaa. Lyhyempiin ennusteisiin lukeutuvat viikkoennusteet, joissa suunnitellaan eri tuotantoyksiköiden käyttöä, seuraavaksi päiväksi tehtävät ennusteet sekä lähituntien ennusteet. Sähköön liittyen ennustetaan monia asioita kulutuksen lisäksi, kuten säätilaa sekä sähkön hintaa. Saatuja ennusteita käytetään mm. tuotannon suunnitteluun sekä sähkömarkkinoille osallistumiseen.

Tuotannon suunnittelu on kokemassa haasteita, kun uusiutuvat energianmuodot ovat integroitumassa sähköverkkoon yhä laajemmin. Sähköntuotanto perinteisillä fossiilisia polttoaineita käyttävillä tuotantolaitoksilla on ollut kuluttajapuolelle vaivaton tapa, sillä sähköä on ollut saatavilla aina, kun sitä on tarvinnut [30]. Fossiilisten polttoaineiden käyttöä kuitenkin rajoitetaan nykyään paljon, joten sähköntuottajat tarvitsevat uusia

lähestymistapoja, miten fossiilisilla polttoaineilla tuotettua sähköä saadaan korvattua uusiutuvia energialähteitä käyttävillä sääriippuvaisilla tuotantomenetelmillä.

Uusiutuviin energianlähteisiin pohjautuvia sähköntuotantomenetelmiä tutkitaan tällä hetkellä paljon, sillä ne eivät fossiilisten polttoaineiden tavoin päästä kasvihuonekaasuja ilmakehään ja näin kuormita planeettaamme samalla tavalla. Uusiutuvat energialähteet ovat ehtymättömiä (pois lukien biomassa), sillä ne ovat luonnonvoimien aiheuttamia ilmiöitä. Ne ovat myös puhtaita ja vapauttavat vain vähän hiiltä luontoon ja lähiympäristöön, joten ne ovat hyvin ympäristöystävällisiä. [88]

Työ- ja elinkeinoministeriön verkkosivujen [84] mukaan Suomi on yksi maailman johtavimpia maita uusiutuvien energiamuotojen käytössä. Energian loppukulutuksesta yli 40 %:a tulee uusiutuvista energialähteistä, kuten bioenergiasta, vesivoimasta, tuulivoimasta ja maalämmöstä.

Uusiutuvien energianlähteiden ehtymätön luonne ei tarkoita kuitenkaan rajatonta kapasiteettia. Monet uusiutuvista energianlähteistä tulevat luonnosta ja ovat riippuvaisia vallitsevasta säätilasta. Jos esimerkiksi kuluvana päivänä aurinko ei paista ollenkaan niin aurinkoenergiaa ei pystytä keräämään merkittävästi.

Sähkönkulutuksen ennustamiseen on tutkittu ja käytetty monenlaisia eri menetelmiä, joista monet pohjautuvat tekoälyyn (AI) ja koneoppimiseen. Oğcu et. al. [71] ja Azadeh et. al. [5] ovat käyttäneet sähkönkulutuksen ennustamisessa neuroverkkoja (ANN). Tukivektorkoneita (SVM) tai tukivektoregressiota ovat hyödyntäneet Ferreira et. al. [15] sekä Ceperic et. al. [8]. Aikasarjamenetelmien käyttöä ennustamisessa ovat tutkineet mm. Williams [90] ja Karabiber & Xydis [46]. Mehta ja Basak [57] ovat tutkineet sumean logiikan käyttöä auringon irradianssin ennustamisessa. Lisäksi kulutusta ja tuotantoa on ennustettu mm. hiukkasparviontimoinnilla [72] ja Kalman-suotimella [82]. Kulutuksen ja tuotannon ennustamisen kriittisyyden takia tekoäly- ja koneoppimismenetelmien tutkimusta on tärkeää jatkaa ja tietotaitoa syventää, jotta tarkempien ennusteiden tekeminen olisi mahdollista.

Sähkönkulutukseen vaikuttava merkittävä tekijä on sähkön markkinahinta. Tällä hetkellä markkinahinta määritellään Suomessa tuntitasolla, eli sähköllä on joka tunti kiinteä muuttumaton hinta kilowattituntia kohden, jolla sähköä ostetaan ja myydään. Fingridin verkkosivujen [28] mukaan eurooppalainen ohjeistus velvoittaa jokaista Euroopan Unionin jäsenmaata siirtymään 15 minuutin taseselvitysjaksoon vuoden 2020 loppuun mennessä. Pohjoismaissa on jouduttu hakemaan lisäaikaa vuoden 2023 loppuun asti.

Oman tutkimukseni pohjalta oletan, että 15 minuutin taseeseen siirtyessä suurin ongelma on mittauslaitteiden ja -algoritmien yhtenäistäminen ja ohjelmointi viidentoista



minuutin aikaresoluutioon. Datamäärä tulee lisääntymään, mutta kun laitteita joudutaan vaihtamaan uusiin, niin nykyaikaisten laitteiden muistikapasiteetti ja suorituskyky ovat parempia kuin nykyisten mittausslaitteiden. Käytettyjen AI- ja koneoppimismetodien näkökulmasta mikään metodi ei ole täydellinen, ja jotkut kärsivät merkittävästi lisääntyvästä datasta ja epävarmuudesta vaihtelevan tuotannon lisääntymisen takia. Osa menetelmistä tulee sopimaan uuteen aikaresoluutioon ja epävarmuuksiin paremmin kuin toiset.

## 1.2 Tutkimuskysymys

Diplomityön tutkimuskysymys määrittyi muotoon ”Miten tuntiresoluutiosta varttiresoluutioon siirtyminen vaikuttaa nykyisten sähkömarkkinoilla käytettävien ennustusmenetelmien toimintaan, ja millaisia haasteita ennustamiseen ja ennusteiden luotettavuuteen kohdistuu. Tämän diplomityön tutkimuskysymys etsiikin vastausta siihen, mitkä tämänhetkisistä sähkönkulutuksen ennustusmenetelmistä soveltuvat 15 minuutin aikaresoluutioon, sekä millaisia vaikutuksia ja haasteita tiheämpään aikaresoluutioon siirtymisellä on.

## 1.3 Työn metodit

Tämä diplomityö on luonteeltaan kirjallisuustutkimus, joka perustuu tehtävään data-analyysiin ja loogiseen päättelyyn. Tutkimukseeni on etsitty tietoa käyttäen Tampereen Yliopiston tarjoamia tietokantoja, kuten Andor, ScienceDirect ja Springer. Muiden yliopistojen opinnäytetöitä on haettu Googlen kautta. Lähteitä on haettu mm. hakutermein:

- ”renewable energy” AND ”forecasting”
- ”forecasting” AND ”energy consumption”
- ”forecasting” AND ”machine learning”
- forecast AND ”15 minutes load”

Lisäksi työssä tullaan tekemään erään tuulivoimapuiston tuulidatasta ja Tampereen Yliopiston Hervannan kampuksen aurinkovoimadatasta analyysia, mitä mahdollisia vaikutuksia taseselvitysjakson vaihtumisella on tuotantodatan tilastollisiin ominaisuuksiin.

## 1.4 Työn rakenne

Tämä diplomityö alkaa johdannosta, jonka jälkeen siirrytään toiseen lukuun, jossa esitellään tutkimuksen tausta. Taustaluvussa esitellään, miten sähkömarkkinat toimivat ja mitä tasehallintaan sisältyy. Kolmannessa luvussa käydään lyhyesti läpi sähköntuotantoa, -kulutusta ja ennustamista yleisesti. Neljännessä luvussa esitellään ennustamisen metodeja sekä käydään läpi tekoäly- ja koneoppimismenetelmiä, joita sähkönkulutuksen ja -tuotannon ennustamisessa on käytetty. Luvussa esitetään myös, mitä lähtötietoja ennustemetodit tarvitsevat ja miten niitä käytetään. Viidennessä luvussa esitellään 15-minuutin tase sekä ratkaisuja ja analyysi, joilla uuteen taseselvitysrakenteeseen liittyviä ongelmia selvitetään. Kyseisessä luvussa vertaillaan neljännessä luvussa esitettyjen metodien ominaisuuksia sekä analysoidaan, miten näitä eri metodeja voidaan soveltaa 15-minuutin taseen aikakaudella. Lisäksi viidennessä luvussa tehdään johtopäätöksiä uuden taseselvitysjakson vaikutuksista energiantuottajille, miten taseselvitysjakso vaikuttaa energianmyyntiin. Viimeisestä luvusta löytyy yhteenveto työn analyysiosassa tehdyistä johtopäätöksistä ja tärkeimmistä kohdista.

## 2. SÄHKÖMARKKINAT

Sähkömarkkinat pohjoismaissa käsittävät sähköntuotannon, kaupankäynnin, sähkönsiirron, sähköjakelun ja vähittäismyynnin [54]. Sähkön tuottaminen ja kauppa ovat lainsäädännöllisesti vapaata kauppaa, eivätkä näin ollen tarvitse erillistä lupaa. Suomessa sähkömarkkinoita säädetään Sähkömarkkinalailla (588/2013) [51], EU:n sähkökauppa-asetuksella sekä muulla lainsäädännöllä, kuten valtioneuvoston asetuksella sähköntoimituksen selvityksestä ja mittauksesta (66/2009) ja työ- ja elinkeinoministeriön asetuksella sähköntoimitusten selvitykseen liittyvästä tiedonvaihdosta [69][14].

Suomessa sähkönsiirtoon tarkoitettusta runkoverkosta vastaa Fingrid. Tähän runkoverkkoon on kytketty voimalaitokset, tehtaot ja alueelliset jakeluverkot, jotka tarvitsevat toimintaansa sähköenergiaa. Alueelliset jakeluverkot välittävät sähkön edelleen pienempiin kohteisiin, kuten kotitalouksiin. Fingrid vastaa Suomessa siitä, että sähköä on saatavissa ilman häiriöitä. Lisäksi Fingrid vastaa kantaverkon käytöstä, suunnittelusta ja valvonnasta. Fingridin toimintaan kuuluu myös verkon ylläpitäminen ja kehitystyö. [19] Fingrid toimii monopoliasemassa, sillä useamman kalliin päällekkäisen runkoverkon rakentaminen ei ole taloudellisesti eikä käytännöllisesti järkevää [17].

Sähkömarkkinoiden yksi pääedellytys on niiden avoimuus ja vapaa kilpailu. Sähköä tuotetaan siten, että tuotanto on muuttuvilta kustannuksiltaan mahdollisimman edullista. Tällä tarkoitetaan sitä, että ensin tuotetaan sähköä käyttäen saatavilla olevista vaihtoehdoista edullisinta tuotantomenetelmää. Jos sähköä tarvitsee tuottaa vielä lisää, niin sitten käytetään kalliimpia tuotantomenetelmiä. [12]

### 2.1 Nord Pool

Nord Pool on Euroopan johtava sähkömarkkinoiden operaattori, joka toimii pohjoismaiden, Baltian maiden, Britannian, Saksan, Ranskan, Alankomaiden, Belgian, Luxemburgin, Puolan ja Itävallan alueella. Nord Pool on laajentamassa ja ottamassa toimintaansa mukaan myös Irlannin. Nord Poolin palveluita toimitetaan mainittujen alueiden ohella myös Kroatiaan ja Bulgariaan. [63]

Nord Pool pitää yllä seuraavan päivän ja saman päivän sisäisiä sähkömarkkinoita. Pääasiassa kauppaa käydään kulutusta edeltävänä päivänä, mutta vuorokauden sisäiset markkinat ovat tarkoitettu tukemaan kulutuksen ja tarjonnan tasapainoa. [63]

Näistä markkinoista käytetään nimityksiä Elspot- ja Elbas-markkinat, joihin tutustutaan alaluvuissa 2.1.1 ja 2.1.2.

### 2.1.1 Elspot-markkinat

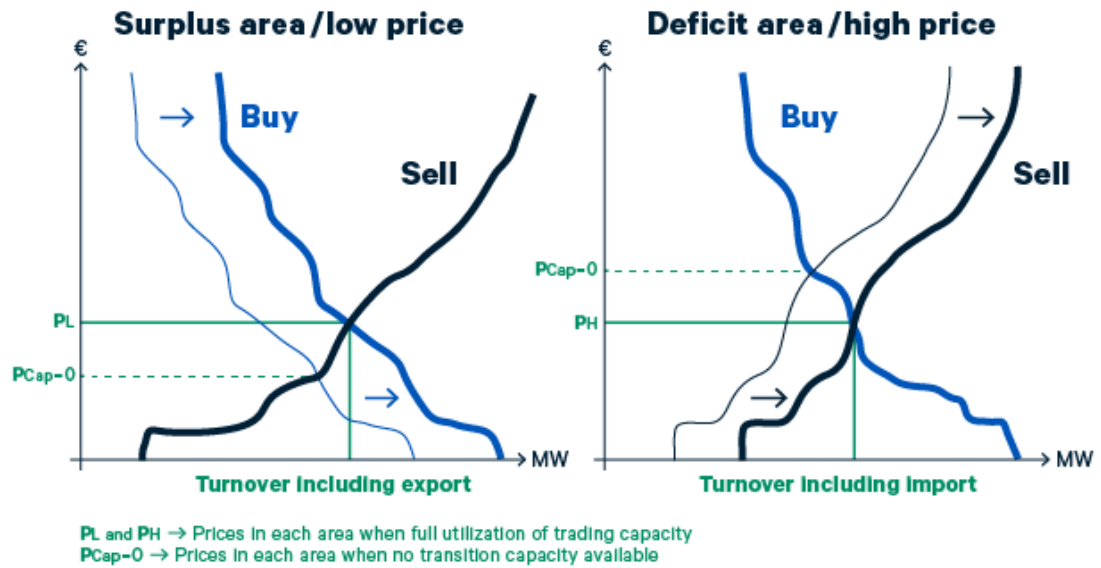
Sähkön tukkuhinta sähkömarkkinoilla perustuu tunneittain määräytyvän spot-hinnan muutoksiin. Spot-hinta tarkoittaa lyhyesti sitä, että vuorokauden jokaisella tunnilla on oma sähkömarkkinoilla määritetty sähkön tuntihinta [68]. Tunneittain vaihtuva spot-hinta Elspot-markkinoilla mahdollistaa sähkön oikean hinnan määrittelyn jokaiselle vuorokauden hetkelle kysynnän ja tarjonnan mukaisesti [6][12].

Spot-hinnat lasketaan seuraavan vuorokauden tunneille aina 24 tunnin välein. Pörssisähkön tunneittaiset hintaerot mahdollistavat kuluttajien sähkökulutuksen ajoittamisen vuorokauden halvimpien tuntien ajalle.

Elspot-markkinoilla voi tehdä erityyppisiä tilauksia. Sähköä voi tilata tuntikohtaisesti tai pidemmissä blokeissa. Tuntikohtaiset tilaukset ovat suurin erä Elspot-markkinoilla. Tilauksen voi tehdä joko hinnasta riippuen tai riippumattomana. Hinnasta riippumattomassa tarjouksessa ostaja voi määrittää määrän tilaukselle sekä ala- ja ylähinnan, joiden välillä jäävällä hinnalla ostaja on valmis sähköä ostamaan. Hinnasta riippuvaisessa tarjouksessa on mahdollista määrittää useampia hintaportaita. Nord Poolilla on oikeus tehdä lineaarinen interpolaatio rinnakkaisten hintaportaiden hankintamäärien välillä, jotta löydetään saatua tarjousta vastaava kauppahinta. [67]

Toinen perustyyppi tilauksille on blokki. Tarjouksessa annetaan määrä ja hinta useamman tunnin yhtäjaksoiselle ajalle saman vuorokauden sisällä. Blokkitilauksia voi tehdä erilaisia, joista löytyy lisää tietoa lähteestä [64]. Erot blokkitilausten välillä perustuvat niiden hyväksymisperiaatteisiin, eli hyväksytäänkö tilausta ollenkaan, vai hyväksytäänkö se osittain tai kokonaan.

Elspot-markkinoilla myynti- ja ostotarjoukset seuraavan päivän markkinoille tulee jättää edellisenä päivänä kello 12:00 CET:a mennessä. Kaikki saadut tarjoukset ohjataan kysyntäkäyrään ja tarjontakäyrään. Järjestelmähinta määräytyy näiden käyrien mukaan. Hinnassa ei ole huomioitu sähkönsiirtoon liittyviä rajoitteita. Eri alueilla voi esiintyä joko ylijäämää tai vajetta sähköenergian tuotannossa suhteessa kulutukseen. Tällöin ylijäämäalueelta viedään sähköä alueille, joilla on vajetta. Kuvassa 1 on esitetty, miten täysimittaisen siirtokapasiteetin käyttäminen tarjonnan ylijäämä- ja vajealueella vaikuttaa sähköenergian hintaan. [66]



**Kuva 1.** Siirtokapasiteettia hyödyntämällä alueiden välinen hinta saadaan tasapainotettua [66].

Kuvassa 1 vasemmanpuoleinen kuvaaja esittää sähkön osto- ja myyntikäyriä alueella, jossa sähköä on saatavilla paljon. Kun sähköä siirretään toiselle alueelle, sähkön hinta tuotantoalueella kasvaa. Jos siirtokapasiteettia ulkomaille ei ole käytettävissä, on sähkön hinta tällöin matalampi. Vastaavasti vajealueella sähkön hinta on korkealla, kun sähköä ei ole mahdollista siirtää muualta siirtokapasiteetin rajoittuvuuden takia. Jos siirtokapasiteetti on täydeltä kapasiteetiltaan käytettävissä, sähkön hinta vajealueella tasapainottuu samalle tasolle kuin ylijäämäalueella. [66]

Pohjoismaat on jaettu erikseen omiksi tarjousalueiksi. Jos tarjousalueiden välinen siirtokapasiteetti rajoittuu, voivat tarjousalueiden väliset hinnat poiketa kuvan 1 tavoin. [66]

### 2.1.2 Elbas-markkinat

Sähköntarve voi sähkömarkkinoilla muuttua, jos ennustukset osoittautuvat virheellisiksi sääolosuhteiden oltua ennusteesta poikkeavat, tai kulutus on jostain muusta syystä eri tasolla kuin odotettiin. Myös voimalaitosten vikaantumiset tai seisahdukset voivat aiheuttaa muutoksen sähköntarpeeseen. Näitä ongelmia varten on perustettu vuorokauden sisäiset Elbas-markkinat, joilta tuotannosta vastaavien osapuolten on mahdollista ostaa lisäsähköä jaettavaksi kuluttajille. Elbas-markkinoiden markkinahinta poikkeaa usein Elspot-markkinoiden markkinahinnasta. [12]

Elbas-markkinoillakin on mahdollista lähettää erilaisia tarjouksia. Rajatarjous tarkoittaa tarjousta ostaa tai myydä sähköä siten, että sähkönosto toteutetaan, mikäli

myyntitarjouksen summa alittaa hintarajan. Vastaavasti myynti toteutetaan, jos ostotarjouksen summa ylittää hintarajan. Rajatarjoukset voidaan toteuttaa tarvittaessa vain osittain. [65]

Blokkitarjouksista yleisin Elbas-markkinoilla on käyttäjämääritely blokkitarjous. Tarjous on luonteeltaan kaikki-tai-ei-mitään-tarjous, joka hyväksytään, jos koko tarjous menee läpi. [65]

Elsport-markkinoilta poikkeava tarjoustyyppi on jäävuoritarjous, jossa yksi kokonainen tarjous jaetaan pienempiin osiin ja alemmat osat paljastetaan, kun edeltävät osat ovat käsitelty. Jäävuoritarjous on tyypiltään eräänlainen rajatarjous. [65]

## 2.2 Säätosähkömarkkinat

Säätosähkömarkkinat ovat tulleet Suomeen vuonna 2016. Säätosähkömarkkinoilla tuotannosta ja kulutuksesta vastaavat osapuolet voivat antaa säätötarjouksia säätökykyisestä kapasiteetistaan. Fingridin mukaan säätosähkömarkkinoilla reservimyyjä sitoutuu jättämään hyväksytyjä kapasiteettitarjouksia vastaavan määrän ylössäätokapasiteettia säätosähkömarkkinoille kapasiteettikorvausta vastaan. [24]

Säätötarjoukset voidaan antaa kaikista resursseista, joilla kyetään toteuttamaan 10 MW muutos 15 minuutin kuluessa. Jos kyseessä on elektroninen aktivointi (xml-muotoinen sanomalähetys tehon muutoksesta) niin 5 MW riittää. Säätötarjoukset on annettava Fingridille vähintään 45 minuuttia ennen käyttöönotton tunnin alkua. Tarjous sisältää seuraavat tiedot: teho (MW), hinta (€/MWh), tuotanto/kulutus, siirtoalue, jossa tarjottu resurssi sijaitsee sekä säätöresurssin nimi, esimerkiksi voimalaitos. Tarjouksista laaditaan pohjoismainen tarjouslista hintajärjestykseen, josta ylössääötötarjouksista valitaan halvin käytettäväksi ensin ja alassääötötarjouksista kallein käytettäväksi ensimmäisenä. Ylössääötötarjous tarkoittaa tuotannon lisäämistä tai kulutuksen vähentämistä, kun taas alassääötötarjous tarkoittaa tuotannon vähentämistä tai kulutuksen lisäämistä. Ylössääötötarjouksessa resurssinhaltija voi myös myydä sähköä Fingridille ja vastaavasti alassääötötarjouksessa ostaa sähköä Fingridiltä. Tarjous voidaan jättää käyttämättä, jos se ei käyttötilanteen vuoksi ole mahdollista. [24]

Säätosähkön hinnoittelu perustuu pohjoismaisten säätosähkömarkkinoiden toteutuneisiin säätöihin. Jokaisella käyttötunnilla on omat määritetyt ylös- ja alassääötö hinnat. Ylössääötöhinta on kalleimman käytetyn ylössääötötarjouksen hinta, jonka on kuitenkin oltava korkeampi kuin Nord Poolin Suomen hinta-alueen hinta. Kaikki, joilta Fingrid on tilannut ylössääötöä tunnin aikana, saavat maksun sovitusta energiasta määritetyn ylössääötöhinnan mukaan. Alassääötöhinta on puolestaan halvimmalla käytetyn

alassäättötarjouksen hinta. Hinnan on oltava kuitenkin halvempi kuin Nord Poolin Suomen hinta-alueen hinta. Kaikki, joilta Fingrid on tilannut alassäättöä tunnin aikana, maksavat alassäättöhinna sovitusta energiasta. [24]

## 2.3 Taajuusreservimarkkinat

Taajuusreservimarkkinoista puhuttaessa on kyse nopeasta taajuusreservistä (FFR). Sähköjärjestelmän käytössä täytyy noudattaa mitoitusperiaatetta, jonka mukaan sähköntuotantoyksikön tai HVDC-siirtoyhteyden (engl. High Voltage Direct Current) menetyksestä johtuvan häiriön seurauksesta taajuus ei saa pudota alle 49 Hz:n. Tarvittavan FFR:n määrä riippuu sähköenergiajärjestelmässä sillä hetkellä olevasta inertian määrästä sekä mitoitettavan vian suuruudesta. [20]

Nopean taajuusreservin tarpeeseen vaikuttaa sähköjärjestelmän inertian määrä. Inertiaalla tarkoitetaan sähköenergiajärjestelmän pyöriin massoihin varastoituneen liikeenergian kykyä vastustaa sähköjärjestelmän taajuuteen kohdistuvia muutoksia. Hankintatarve on suurimmillaan kevät-, kesä- ja syyskuukausina, jolloin inertia on pienimmillään. [20] Tämä johtuu siitä, että tuuli- ja aurinkovoima liittyvät sähköverkkoon ilman pyörivää massaa [53]. Talvella sähköä joudutaan tuottamaan paljon, mikä tarkoittaa perinteisten voimalaitosten runsasta käyttöä. Niissä pyörivät massat luovat järjestelmiin inertiaa, jolloin nopean taajuusreservin tarve vähenee.

Fingrid hankkii FFR:ä kansalliselta tuntimarkkinalta. Seuraavan vuorokauden tunneille tulevat tarjoukset tulee jättää tuntimarkkinoille edellisenä iltana. Kullekin tunnille määräytyy erikseen reservikapasiteetin hinta kalleimman käytetyn tarjouksen mukaan. Reservitoimittajalla on mahdollisuus jättää yhteistarjous taajuusohjattuun häiriöreserviin (FCR-D) ja nopeaan taajuusreserviin. Yhteistarjous mahdollistaa joustavan tarjoamisen reservikapasiteetille ja sen kapasiteetti voidaan käyttää joko FCR-D:n tai FFR:n hankintaan. Taajuusohjatun häiriöreservin vuosimarkkinalle osallistuvaa reservikapasiteettia voidaan tarjota FFR:in. [20]

Taajuusreservimarkkinoilla FFR:in ylläpitoon osallistuvien reservikohteiden pitää täyttää joitakin teknisiä vaatimuksia, jotka täytyy osoittaa säätökokein ennen osallistumista taajuusreservimarkkinoille [20]. Reservitehon aktivointitaajuus täytyy valita taulukosta 1. Eri aktivointitaajuuksille on määritetty omat maksimit aktivointiajalle, jonka reservin aktivointi saa kestää.

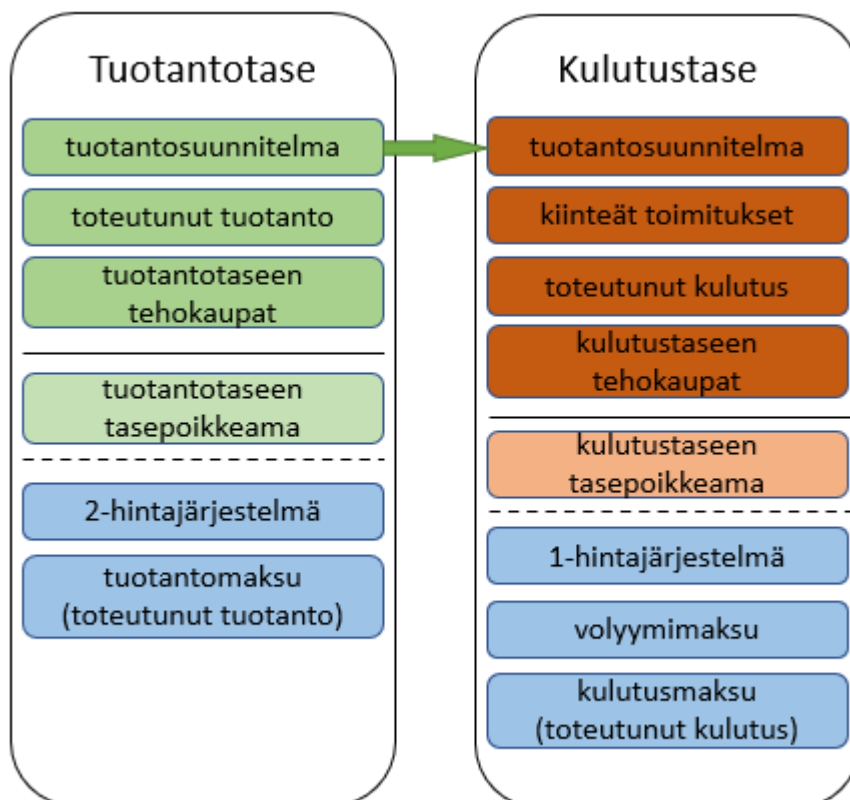
Taulukko 1. *Tekniset vaatimukset reserville. [20]*

Aktivointitaajuus (Hz)	Max. aktivointiaika (s)
49,7	1,3
49,6	1,0
49,5	0,7

Vähimmäiskesto aktivoinnille on Fingridin verkkosivujen [20] mukaan 5 sekuntia, mikäli tehon deaktivointinopeus on max. 20 % FFR-kapasiteetista per sekunti. Suuremmalla deaktivointinopeudella aktivoinnin vähimmäiskesto kasvaa 30 sekuntiin. Tehon deaktivoimisella tarkoitetaan reservikohteen palauttamista takaisin tilaan, jossa reservikapasiteetti ei ole aktivoituna [21]. Reservikohteen täytyy pystyä uuteen aktivointiin 15 minuutin kuluttua edellisestä aktivoinnista [20].

## 2.4 Tasemalli ja -selvitys

Pohjoismaissa otettiin käyttöön vuonna 2009 kahden taseen malli, jossa merkittävimpiä muutoksia edeltävään tasemalliin olivat erillisten tuotanto- ja kulutustaseiden käyttöönotto, sitovat tuotantosuunnitelmat, tuotantosuunnitelmien ja säätötarjousten raportointi 45 minuuttia ennen käyttötunnin alkua sekä tasepalveluun liittyvän kustannusrakenteen muuttuminen. [25] Kahden taseen tasemallin rakenne on esitetty kuvassa 2.



**Kuva 2.** Kahden taseen tasemalli (lähteen [25] mukaan).

Kuvan 2 mukaisessa kahden taseen mallissa kulutus- ja tuotantotase on jaoteltu omiksi taseikseen. Tuotantotaseessa käsitellään tuotanto. Kulutustaseessa käsitellään



puolestaan sähkön ostot ja myynnit sekä kulutus. Nuoli taseiden välillä kuvaa tuotantosuunnitelman siirtymistä kulutustaseeseen, jotta sitä voidaan käsitellä taseselvityksessä. Kuten kuvasta 2 voidaan huomata, tuotantotaseessa olevalle tasepoikkeamalle (tasesähkölle) käytetään eri hintajärjestelmää kuin kulutustaseen tasepoikkeamalle. [25]

Pohjoismaissa ollaan tasejakson muuttumisen myötä siirtymässä yksitasemalliin [78]. Yksitasemallissa luovutaan erillisistä kulutus- ja tuotantotaseista, jolloin taseselvityksessä käytetään samaa hinnoittelumallia, kuin nykyisin kulutustaseelle. Uusi taseselvitysmalli on tarkoitus ottaa käyttöön 1. marraskuuta 2021. [27]

## 2.5 Tasehallinta ja taseselvityksen osapuolet

Tällä hetkellä Suomessa on käytössä tunnin aikaresoluutiolla toimiva energiatasehallinta. Taseselvityksen tavoitteena on eSettin Pohjoismaisen taseselvityksen käsikirjan [14] mukaan muodostaa sähkömarkkinoille taloudellinen tasapaino jokaisen käyttötunnin jälkeen. Fingridin verkkosivujen [26] mukaan sähköjärjestelmän taajuutta pyritään pitämään 49,9-50,1 Hz:n taajuusalueella ylläpitämällä tuotannon ja kulutuksen välistä tasapainoa. Verkon yli 50 Hz:n taajuus tarkoittaa, että sähkönkulutus on pienempää, kuin sähköntuotanto. Kun verkko on alle 50 Hz:n taajuudella, kulutus on tuotantoa suurempaa.

Verkon käyttäytymisessä täytyy kuitenkin huomioida, että sähköverkko pyrkii aina tasoittamaan taajuudenmuutosta. Jos taajuus on yli 50 Hz, niin sähköverkkoa säätelevät tahtigeneraattorit laskevat jännitettä ja taajuus alkaa laskea. Vastaavasti taajuuden jäädessä alle 50 Hz:n aletaan tahtigeneraattoreiden jännitettä kasvattaa ja taajuus alkaa nousta.

Verkon ollessa epätasapainossa kutsutaan yli- tai alijäämää **tasesähköksi**. Tasesähköllä tehtävää kauppaa kutsutaan puolestaan tasesähkökaupaksi. Tasesähkön määrän määrittää taseselvitys. Tasesähkö hinnoitellaan erikseen tuotanto- ja kulutustasesähkölle erilaisten hintajärjestelmien mukaan. [74]

Kaksihintajärjestelmässä lasketaan oma hinta tasesähkön ostolle ja myynnille. Yksihintajärjestelmässä osto- ja myyntihinnat ovat suuruudeltaan samat. [18]

Tasehallinta toteutetaan taajuusohjatuilla reserveillä sekä manuaalisesti tehtävillä säädöillä. Automatisoitua taajuusohjattua käyttö- ja häiriöreserviä käytetään sähköjärjestelmän tasapainotilan ylläpitämisessä. [26]

Tasehallintaan liittyy monia eri toimijoita, joilla on omat vastuunsa ja vaatimuksensa. **Taseselvitysyritys** (eSett) vastaa eSettin käsikirjan [14] mukaan taloudellisesta taseselvityksestä ja sen vastuulla olevia tehtäviä ovat mm. taseselvityksen rakenteellisten tietojen kerääminen ja ylläpito, taseselvityksen tekeminen ja tasesähkön laskutus/hyvitys tasevastaavilta sekä vakuutustasoista päättäminen siten, että ne kattavat taseselvitykseen liittyvät riskit.

**Kantaverkkoyhtiöt** vastaavat sähköjärjestelmän fyysisen tasapainon valvomisesta. Ne ovat vastuussa tasapainon palauttamisesta, jos järjestelmä on joutunut epätasapainoon. Kantaverkkoyhtiöiden tehtäviä ovat vaaditulla 50 Hz:n taajuusalueella pysymisen lisäksi mm. tasepoikkeamiin vaikuttavien säätöjen tekeminen ja hinnoittelu sekä tasepoikkeamien hinnoittelu, riittävien tasevastaavakohtaisten tietojen toimittaminen taseselvitysyritykselle sekä markkinatalousalueiden ja mittausalueiden rakenteellisten tietojen ja niiden välisten riippuvuuksien raportointi. [14]

**Verkonhaltijat** vastaavat tuottajien ja kuluttajien kytkemisestä omaan verkkoonsa. Verkonhaltijoiden vastuulla ovat tärkeimpinä tehtävinä sähkömyyjien tuotannon ja kulutuksen käyttöpaikkojen rekisteröinti kullakin mittausalueella sekä mittausjärjestelmän ylläpito ja vaadittujen mittaustietojen toimittaminen sähkömyyjille, tasevastaaville, kantaverkkoyhtiöille sekä taseselvitysyritykselle. [14]

**Tasevastaavalla** on voimassa oleva sopimus taseselvitysyrityksen ja alueensa kantaverkkoyhtiön kanssa. Tasevastaavan vastuisiin kuuluu mm. taseselvityssopimuksen tekeminen ja vaadittavien vakuuksien asettaminen, tuntitason suunnitelmat ja kahdenvälisen kauppajen raportointi taseselvitysyritykselle. [14]

**Sähkön myyjä** on markkinaosapuoli, joka vastaa sähkön myynnistä loppukuluttajalle, tuotannon ostamisesta tai kaupan harjoittamisesta. Sähkön myyjät ovat veloitettuja rekisteröitymään taseselvitysyritykselle, ja heillä on oltava tasevastaavan kanssa sopimus kulutuksesta ja tuotannosta kaikille mittausalueille, joilla myyjä toimii. Lisäksi myyjät voivat käyttää yhtä tasevastaavaa kulutusta varten ja toista tuotantoa varten saman mittausalueen sisällä ja käyttää eri tasevastaavaa eri mittausalueilla. [14]

**Markkinaoperaattorin** vastuut sähköpörssin roolissa ja taseselvityksessä ovat sähköpörssikauppajen raportointi taseselvitysyritykselle, muiden sähköpörssien kanssa tehtävien rajasiirtojen raportointi, markkinaoperaattoreiden välisten bilateraalkauppajen raportointi sekä markkinoiden valvonnan harjoittaminen ja sääntörikkomuksien ilmoittaminen. [14]

**Palveluntoimittajat** ovat operationaalisten tasehallinta- ja taseselvityspalveluiden tarjoajia muille markkinaosapuolille. Palveluntoimittajien tehtäviä ovat mm.

taseselvitystietojen raportointi ja syöttäminen taseselvitysyhtiön järjestelmään, tasepoikkeamalaskennan tulosten tarkistaminen ja vakuuksien hallinta markkinaosapuolten puolesta. [14]


**Mittaustietojen aggregaattorin** tehtäviin kuuluu sähkön myyjän tuotannon ja kulutuksen rekisteröinti kullakin mittausalueella, mitatun ja profiloidun tiedon vastaanottaminen sekä aggregoitujen kulutus- ja tuotantoaikasarjojen laskeminen kullakin mittausalueella sekä aggregoitujen aikasarjojen raportointi taseselvitysyhtiölle. [14]

## 3. TUOTANTO, KULUTUS JA ENNUSTAMINEN

### 3.1 Sähköntuotanto pohjoismaissa

Sähköntuotanto pohjoismaissa on melko monipuolista. Erilaisia pohjoismaissa käytettyjä sähköntuotantomenetelmiä ovat vesi-, ydin- ja tuulivoima. Näiden lisäksi sähköä tuotetaan voimalaitoksilla, jotka käyttävät toiminnassaan kivihiiltä, turvetta, maakaasua ja biomassaa. [12]

#### Pohjoismainen sähköntuotanto 2018



**Kuva 3.** Sähköntuotanto pohjoismaissa 2018 [59]. Luvut pohjautuvat Entso-E:n tilastolliseen datalehteen 2018 [13].

Kuvan 3 mukaan vuonna 2018 esimerkiksi Tanskassa tuotannosta likimain puolet tulee tuulivoimasta. Norjassa vesivoimalla on vuonna 2018 tuotettu peräti 95 % koko sähköntuotannosta. Suomessa ja Ruotsissa sähköenergiaa tuotetaan melko monipuolisesti ydinvoiman ollessa suurin tuotantomuoto. Ruotsissa myös vesivoimalla tuotetaan lähes ydinvoimatuotannon määrä. [59]


Pohjoismaat käyvät sekä pohjoismaiden sisäistä kauppaa sähköenergiasta, mutta myös kauppaa muidenkin naapurimaiden kanssa. Esimerkiksi Suomi käy kauppaa itärajan ylitse Venäjän kanssa ja Itämeren yli Viron kanssa [22].

## 3.2 Tuotannon suunnittelu

### 3.2.1 Unit Commitment

”Unit Commitment” (UC) on sähköenergiajärjestelmien tuotantopuoleen liittyvä kysymys, jonka tavoitteena on minimoida sähköntuotannon kokonaiskustannukset tietyllä ajanjaksolla määrittäen samalla tuotantoyksiköt, joiden vastuulla tuotanto on. Vaadittava kulutus pyritään siis tuottamaan useiden tuotantolaitosten yhteistyönä siten, että polttoainekustannukset ovat mahdollisimman alhaiset. [7]

Yleensä sähkönkulutus vaihtelee vuorokaudenajan mukaan. Piikit osuvat aikaisin aamun tunneille noin klo 7-9, sekä illalle noin klo 16 ja 20 välille, kun alkaa hämärtaa ja kotona tehtävien askareiden määrä ja vapaa-ajan viihde-elektronikan käyttö lisääntyy. Kulutuksen minimit ovat pääsääntöisesti öisin. Esimerkki kahden vuorokauden kulutuskäyttäytymisestä talvikaudella Suomessa on esitetty kuvassa 4.



**Kuva 4.** Sähkönkulutus Suomessa 14.1.2021 00:00-15.1.2021 23:59. Data Fingridin avoimesta datasta [23].

Kuvasta 4 voidaan nähdä, että tammikuun 14. päivänä kulutus kasvaa yön tunneilta mentäessä aamuun päin. Iltapäivällä on havaittavissa tasaantumista ja yöllä kulutus laskee taas alas. Vuorokausien välisenä aikana on ollut mahdollisesti kylmä yö, sillä kulutus ei laske samalle tasolle kuin 14. päivänä.

Epävarmuutta "unit commitment" -ongelmaan tuo myös uusiutuvien energialähteiden laajentunut käyttö. [77] Nykyisin energiajärjestelmiltä vaaditaan mukautumiskykyä, kun uusiutuvat energianlähteet tuottavat energiaa vaihtelevalla teholla johtuen vallitsevista sääolosuhteista [39].

"Unit commitment" -ongelmassa Lun ja Shahidehpourin artikkelin [56] mukaan tavoitteena on minimoida sähkökuorman tuottamiseen liittyvät kustannukset kustannusfunktion (1) mukaan:

$$\text{Min} \sum_{t=1}^{N_t} \sum_{i=1}^{N_g} [C_i(P(i, t))I(i, t) + SU(i, t) + SD(i, t)]. \quad (1)$$

Kaavassa (1) tuotannon kustannukset muodostuvat kunkin yksikön yksikkökustannusfunktion ( $C_i(P(i, t))$ ) ja laitoksen käyntitiedon ( $I(i, t)$ ) tulona, johon summataan energiajärjestelmän yksikön käynnistämisestä ( $SU(i, t)$ ) ja pysäyttämisestä ( $SD(i, t)$ ) aiheutuvat kustannukset [56]. Summaoperaattorit kaavassa (1) tarkoittavat, että jokaisen tuotantoyksikön kustannusfunktio jokaisella ajanhetkellä vaikuttaa lopullisen kustannusfunktion laskennassa.  $N_t$  kaavassa (1) kuvaa tarkastelun kohteena olevia tunteja ja  $N_g$  kuvaa verkkoon liitettyjen generaattoreiden lukumäärää.

Tuotantojärjestelmät sisältävät useita rajoitteita. Tuotantolaitoksia ei voida käynnistellä sattumanvaraisesti tuotantopäivän aikana, vaan niille on laadittu tarkasti suunnitellut käynnistys- ja sammutusajankohdat. Tämän lisäksi yksiköille on määritetty vähimmäisajat, jotka niiden tulee olla käynnissä sen jälkeen, kun järjestelmä on käynnistetty. Vastaavasti yksiköillä on vähimmäisajat, jotka niiden tulee olla suljettuina, kun ne ovat operaattorin toimesta suljettu. [39]

Muita rajoitteita ovat esimerkiksi lämmön tuottamiseen liittyvät rajoitukset, tuotantoreservin rajoitukset, siirto rajoitukset, päästö rajoitukset, häviörajoitukset sekä loistehon tuotannon rajoitukset. Näistä voi lukea tarkemmin lähteestä [39].

### 3.2.2 Taloudellinen kuormanjako

Taloudellinen kuormanjako (engl. Economic dispatching (ED)) tarkoittaa jokaisen tuotantoyksikön tehon tuotannon aikatauluttamista siten, että polttoaineen kulutukseen menevät kustannukset saadaan minimoitua tuotantoon liittyvät rajoitteet ja vaatimukset huomioon ottaen. [4]

ED:n päätavoite on kustannusten minimointi. ED pyrkii myös minimoimaan tuotantolaitoksien päästöt (mm. hiilidioksidi ja rikkidioksidi), maksimoimaan taloudelliset voitot sekä ylläpitämään energiajärjestelmän stabiiliuden ja turvarajoitteet. [4]

Taloudelliseen kuormanjakoon liittyy tiiviisti käsite "optimal power flow" (OPF). OPF tarkoittaa sitä, että tuotetun sähkötehon on mahdollista vaihdella tiettyjen rajojen sisällä, jotta polttoaineen hinnasta aiheutuvat kulut saadaan minimoitua. Tämä on toteutettu minimoimalla kustannusfunktio samalla ylläpitäen sallitulla välillä oleva suorituskyky. [4] OPF:ssa otetaan huomioon generaattoreiden kapasiteettirajoitteet ja kompensoivien laitteiden ulostulot ja mahdolliset häviöt, kuten esimerkiksi siirtohäviöt, jos sähköntuotanto ei tapahdu lähellä loppukulutuspaikkaa [76].

ED-ongelman tavoitteena on minimoida kustannusfunktio (2):

$$F_{cost} = \sum_{j=1}^{N_g} F_j(P_j) \quad (2)$$

missä jokaisen tuottavan sähkögeneraattorin operointikustannuksia mallinnetaan tietyllä ulostuloteholla kaavalla:

$$F_j(P_j) = a_j + b_j P_j + c_j P_j^2 \quad (3)$$

Kaavoissa (2) ja (3) esiintyvät merkinnät ovat selitetty taulukossa 2.

Taulukko 2. ED-ongelman symbolit ja niiden selitteet.


Symboli	Selite
$a_j, b_j, c_j$	Yksikön $j$ kustannuskertoimia
$F_j(P_j)$	Yksikön $j$ kustannusfunktio (\$/h)
$P_j$	Yksikön $j$ todellinen tuotto (MW)
$N_g$	Generaattorien kokonaismäärä energiajärjestelmässä.

Kuten UC-ongelmassa, on ED-ongelmassakin rajoitteita. Rajoitteet on jaettu kahteen luokkaan: tuotantorajoitteisiin ja siirtoverkon rajoitteisiin. Tuotannon rajoitteet koostuvat

mm. järjestelmän rajoitteista, polttoainerajoitteista, lämpöyksiköiden rajoitteista yms. Siirtoverkon rajoitteisiin kuuluu verkon turvallisuusrajoitteet ja siirtolinjojen kapasiteetit. [4]

### 3.3 Sähkönkulutus

Suomessa sähkönkulutuksesta noin puolet on teollisuuslaitosten kuluttamaa sähköä. Sähkönkulutus sektoreittain vuonna 2019 on esitetty kuvassa 5.



**Kuva 5.** Sähkönkulutus sektoreittain 2019 [81].

Teollisuus käyttää Suomessa selvästi suurimman osan Suomen sähköenergian kokonaiskulutuksesta. Kulutukseltaan suurin yksittäinen teollisuudenala on puu- ja paperiteollisuus 22 %:lla. Myös metalliteollisuus (10 %), kemian teollisuus (8 %) ja muu teollisuus (6 %) vievät merkittävän osan kokonaiskulutuksesta.

Koti- ja maataloudet vievät Suomen tasolla kokonaiskulutuksesta vähän yli neljänneksen (28 %). Palvelut ja julkinen sektori (23 % kulutuksesta) täydentävät toisen puolikkaan koko valtion kokonaiskulutuksesta. Kolme prosenttia kokonaiskulutuksesta katoaa siirto- ja jakeluhäviöinä sähköverkossa.



### 3.4 Sähkönkulutukseen vaikuttavat muuttujat

Sähkön suhteen ihmisten kulutustottumukset voivat olla hyvin toisistaan poikkeavia. Siksi sähkönkulutuksen ennustamisessa on monia epävarmuustekijöitä, joita pitää ottaa huomioon. Hafeezin et. al. [32] tutkimuksessa kuluttajien sähkön kulutuksen sanotaan olevan luonteeltaan epälineaarista ja stokastista eli satunnaista. Tätä voidaan miettiä pyykinpesuesimerkin avulla. Talouden sisäiseen pyykinpesutarpeeseen vaikuttaa lukuisia tekijöitä: asukkaiden lukumäärä, asukkaiden tekemien askareiden vaikutus vaatteiden likaantumiseen, asukkaiden harrastaman hikiurheilun määrä, vuodevaatteiden vaihtoväli jne. Yhdessä muiden kotitalouksien askareiden kanssa yhdenkin kotitalouden kulutuksen ennustamisesta voi tulla varsin kompleksista. Kompleksisuus kuitenkin vähenee, kun siirrytään yhdestä taloudesta asuinalueen, kaupungin ja edelleen kokonaisen valtion kulutuksen ennustamiseen. Tällöin on helpompaa löytää säännöllisyyksiä, miten kulutus vaihtelee suuremmissa kokonaisuuksissa.

Kulutukseen ei vaikuta pelkästään talouksien tai teollisuuden sisäiset muuttujat. Sähkönkulutukseen vaikuttaa myös ympäristöstä aiheutuvat muuttujat, kuten lämpötila ja ilmankosteus [32], tuulen nopeus, sademäärät, maailmanlaajuinen auringon irradianssi sekä aika, jolloin aurinko paistaa kirkkaasti [3][47].

### 3.5 Mitä ennustetaan ja miksi?

Termillä ennustaminen tarkoitetaan jonkin tulevaisuuden tapahtuman arviointia ja esittämistä. El-Hawaryn mukaan [11] ennustaminen on ennen kaikkea työkalu, jonka avulla tulevaisuuden tapahtumia voidaan ennakoita, ja tuloksia voidaan hyödyntää mm. toiminnan suunnittelussa sekä budjetoinnissa. Ennustaminen käyttää apunaan historiatietoa ja asiantuntijoiden havaintoja.

Sähköntuotannossa ennusteet ovat El-Hawaryn havaintojen mukaisia suunnittelun työkaluja. Niiden avulla pystytään määrittämään, paljonko sähköä tarvitsee tuottaa, jotta tuotanto vastaa kokonaiskulutusta. Al-Alawin ja Islamin artikkelin [3] mukaan sähkönkulutuksen ennusteilla pyritään tuotannon, sähkönsiirron ja talouden suunnitteluun. Lisäksi kulutuksen ennustaminen auttaa määrittämään tuotannon varareservin ja polttoaineen tarpeen, sekä suunnittelemaan järjestelmälle soveltuvan huoltoaikataulun.

Ennusteet ovat tärkeitä myös sähkömarkkinoille osallistumisen näkökulmasta. Zairepourin [94] mukaan markkinaosapuolet suunnittelevat lyhyen aikavälin toimintaansa heidän sähkön tarpeen ennusteiden mukaan ja antavat tarjouksen, mihin

hintaan he ovat valmiita ostamaan sähköä. Ennusteet seuraavan päivän energian markkinahinnalle sekä operoivat reservit ovat tärkeässä roolissa tuotannon aikatauluttamisessa. Keskipitkän välin ennustamista tehdään mm. budjetoinnin, johdannaisten hinnanasetteluun ja kahdenkeskisten energia- ja polttoainesopimusten tekemisen avuksi. Pitkän aikavälin (n. 10 vuoden) ennustamista tehdään suurempien hankkeiden suunnitteluun, esimerkiksi uuden tuotantolaitoksen suunnittelun avuksi, jotta pystytään ennustamaan, onko uuden voimalaitoksen rakentaminen taloudellisesti kannattavaa.

Sähkөөn liittyen tärkein ennustettava asia on sähkönkulutus. Sähkönkulutus määrittää puolestaan monia muita suureita, joiden ennustaminen sähkömarkkinoille osallistumisen takia on kannattavaa. Näitä suureita ovat mm. sähkön hinta, vaihtelevan tuotannon määrä, ydinvoimaloiden tuotannon tarve ja sääolosuhteet. Erityisesti vaihtelevan tuotannon roolin kasvaessa sähköenergian tuotannossa täytyy vaihtelevan tuotannon ennustetarpeisiin vastata asiaankuuluvalla tavalla, sillä vaihtelevan tuotannon on määrä syrjäyttää perinteisiä tuotantomenetelmiä, kun erilaisilla kampanjoilla pyritään hiilivapaaseen tuotantoon.

D. Pajusen artikkeli [73] FINGRID-lehdessä painottaa, että erilaisten ennusteiden, kuten siirto-, tuotanto- ja kulutusennusteiden tekeminen on tärkeää sähköjärjestelmän tasapainon ylläpitämiseksi. Artikkelissä korostaa myös vaihtelevan tuotannon lisääntyessä ennusteiden merkityksen vain kasvavan. Artikkelissä haastatellun Fingridin käyttösuunnitteluyksikön suunnitteluinsinööri Mika Laatikaisen mukaan sähkön riittävyys on tärkeä ennustettava tekijä. Toinen tärkeä ennuste on siirtoennuste, joka kertoo, miten kulutus ja tuotanto jakautuvat eri alueilla ja onko sähkö mahdollista siirtää näiden alueiden välillä. Nämä kaksi ennustetta tarvitsevat pohjadataksi kulutus- ja tuotantoennusteet. Tuotantoennuste rakentuu voimalaitoksien tuotantosuunnitelmista sekä vaihtelevan tuotannon ennusteista. Kulutusennuste pohjautuu monien vuosien aikana kerättyyn dataan ja sääennusteeseen, jotka kytkeytyvät voimakkaasti kulutukseen.

### **3.5.1 Sääennustemallit**

Sää on yksi merkittävämmistä tekijöistä, joka vaikuttaa suoraan sähkönkulutukseen, sähköntuotantoon ja sähkön hintaan. Tämän takia säätilan ennustaminen lyhyellä aikavälillä on tärkeää. Tarkat sääennusteet voivat estää sähköenergiajärjestelmää ylikuormittumasta ja vähentää järjestelmävahinkoja, jotka aiheutuvat virheellisistä ennusteista [45].

Jovanovićin et. al. artikkelissa [45] tutkittiin vuorokauden lämpötilan keskiarvoja ja niiden vaikutusta sähkönkulutukseen. Tutkimuksessa havaittiin, että lämpötilan keskiarvot vaikuttavat suorasti sähkönkulutukseen Kragujevacin kaupungin alueella Serbiassa. Tutkimus osoitti laajalla otannalla keskiarvolämpötilojen piikkien aiheuttavan selviä piikkejä kulutukseen.

Sähkönkulutus voi olla hyvin paikallista, koska lämpötila voi lyhyenkin etäisyyden päässä mittauspaiosta muuttua hyvin paljon. Sijainnilla on myös vaikutus säähän, joka pitää huomioida ennustaessa. Vallinheimon artikkelin [85] mukaan, sääennustemalleja on globaaleja ja alueellisia, joista alueellisilla on omat tehtävänsä. Globaalimalli antaa linjaukset kaikille alueellisille sääennusteille. Vastaavasti Keski-Euroopan alueelle on oma mallinsa, ja edelleen pienemmille alueille on omat erilliset rajatut alueensa.

Säähän, kuten muihinkin luonnonilmiöihin liittyy ilmiöiden epävarmuus [61]. Sääennustemalleissa luodaan tietokoneella malli ilmakehästä, jolle määritetään tietyt alkuarvot. Epävarmuutta malliin tuovat mahdolliset virheet havainnoissa sekä paikat, joista ei ole olemassa havaintoja. Tämän takia täydellistä sääennustemallia on mahdotonta luoda. Siitä syystä on myös itse kyettävä ennustamaan sääennustusmallien epävarmuutta. [85]

Havaintoihin pohjautuvaa dataa on saatavissa lukuisilta eri havaintoasemilta ympäri maailmaa. Yhtenä luotetuimmista maanpinnan läheisistä havaintotietokannoista pidetään meteorologista ilmailuraporttia (METAR), joka päivittyy normaalisti aina tunneittain tai 20 minuutin välein. METAR-havaintopisteitä on lähes jokaisella lentokentällä maailmanlaajuisesti. Niitä suositetaan havaintojen tekemisessä, koska sensoreita huolletaan hyvin ilmaliikenteen riskialttiuden takia. METAR-pisteiden väleissä on maalla erilaatuisia mesoverkkoja, joilta saadaan tietoa lentokenttien välialueiden sääolosuhteista. Valtamerillä säähavaintoja voidaan tehdä havaintopöijujen tai laivaliikenteen havaintojen avulla. [47]

Myös korkeammalta ilmakehästä tehdään havaintoja, joita hyödynnetään ennustamisessa. Ilmakehän troposfäärin ja stratosfäärin säähavaintoja tehdään esimerkiksi sääilmapalloilla kuljetettavilla radiosondeilla ja lentokoneista tiputettavilla pudotussondeilla sekä kaupallisen lentoliikenteen ja satelliittien tekemiin havaintoihin perustuen. [47]

### 3.5.2 Vaihteleva tuotanto

Vaihtelevan tuotannon ennustaminen edellyttää ymmärrystä energiamuotojen vaihtelevasta luonteesta sekä kykyä ennustaa ilmakehässä tapahtuvia ilmiöitä. Esimerkiksi aurinko- ja tuulivoiman osalta ilmakehän käyttäytymistä täytyy pystyä ennakoimaan jopa minuuttitasolla, jotta pystytään suunnittelemaan, millaisin keinoin tarvittava määrä sähköä pystytään tuottamaan tuotantolaitoksien tarjoamilla resursseilla. On myös pystyttävä ennustamaan, miten ennakoidut muutokset vaihtelevassa tuotannossa vaikuttavat, jotta muutokset voidaan ottaa huomioon muiden laitosten toiminnan ja huoltotoimenpiteiden suunnittelussa. [47]

Sääilmiöt vaikuttavat vaihtelevan tuotannon tuottaman sähkön määrään. Siksi sääilmiöitä pitää pystyä ennustamaan mahdollisimman tarkasti, sillä reaaliaikaiseen tuotantoon vaikuttavat mm. pilvi- ja tuulirintamien liikkeet. Jos näiden rintamien ennustamisessa on epäonnistuttu, täytyy tuotannolla olla jonkinlainen varareservi, josta puuttuva määrä sähköä saadaan tuotettua. [47]

Vaihtelevan tuotannon ennustamiseen tarvitaan monenlaista dataa ilmastosta ja säätilasta. Tätä dataa hyödynnetään, kun erilaisia numeerisia säänennustusmalleja käytetään ennustamisessa joko suoraan prognostisilla yhtälöillä tai epäsuorasti diagnostisilla yhtälöillä.

Vaihtelevan uusiutuvan tuotannon tehokkaassa integroimisessa sähköverkkoon on monia eroavaisuuksia niiden luonteenpiirteiden mukaan. Vaihtelevan uusiutuvan tuotannon täydellinen ennustaminen ei ole mahdollista, sillä päivittäinen vaihtelevuus voi olla todella suuri. Tämän takia on tärkeää, että on saatavilla tuotantoa, jota voidaan ottaa käyttöön nopeasti, kun sääriippuvaa energiaa ei ole saatavilla tai kysyntä kasvaa nopeasti. [91]

Vaihtelevan uusiutuvan tuotannon tuotantovälineistö kuten esimerkiksi aurinkopaneelit voivat sijaita paikallisissa jakeluverkoissa siirtoverkkojen sijaan, jolloin tuotannossa ja tuotantoennusteissa täytyy huomioida se, että tuotanto ei näy suoraan verkonhaltijoille vaan se on nähtävillä verkon kokonaiskysynnästä. Tämä tuo oman haasteensa ennustamiseen ja vaihtelevan uusiutuvan tuotannon hallintaan. Lisäksi vaikka vaihtelevuus olisi ennalta-arvattavaa, niin tuotannon muutosnopeudet voivat olla haasteellisia nopean rampittumisen takia. Suomessa ja muissa maissa, joissa

vuodenaikojen vaihtelu vaikuttaa esimerkiksi aurinkovoiman saatavuuteen, tarvitsee verkonhallinta jonkinlaista pitkän aikavälin tasapainottamista. [91]

Wynnin [91] mukaan myös vaihtelevan uusiutuvan tuotannon tuotantolaitosten sijainti vaikuttaa verkonhallintaan. Jos tuotanto sijaitsee kaukana alueelta, jonne sähköä tarvitaan niin siirtoennusteiden rooli, siirtohäviöt sekä siirtokustannukset kasvavat.

Vaihtelevan tuotannon kaksi tärkeintä muotoa ovat **tuulivoima** ja **aurinkovoima**. Tuulivoiman ennustaminen lyhyellä aikavälillä voidaan jakaa edelleen lyhyen ja todella lyhyen aikavälin ennustamiseksi. Holttisen et. al. tutkimuksen [38] mukaan todella lyhyen aikavälin ennustaminen tehdään minuuttitasolta vain muutamien tuntien tasolle. Tätä hyvin lyhyen aikavälin ennustamista hyödynnetään tuuliturbiinien ohjauksessa. Lyhyen aikavälin ennustamiseksi kutsutaan ennustamista, joka tapahtuu muutaman vuorokauden sisällä ennustusajanhetkestä (enintään 72 h). Kantaverkkoyhtiöt ja sähkön myyjät käyttävät tämän aikaikkunan ennusteita toimintansa tukena. 15-minuutin taseen käyttöönoton myötä tueksi tullaan tarvitsemaan vielä lyhyemmän aikavälin ennusteita.

Hyvin lyhyen aikaresoluution tuulivoimaennusteet hyödyntävät vain tilastollisia menetelmiä, sillä mallit, jotka perustuvat globaaleihin tai paikallisiin numeerisiin säänennustusmalleihin eivät ole käytännöllisiä niin lyhyellä aikavälillä. Alle kuuden tunnin aikavälin ennusteissa selvittää tuulen karakterististen ominaisuuksien vuoksi hyvin pelkkien tilastollisten menetelmien kanssa, jotka käyttävät historiadataa. Tuuliolosuhteiden ennustaminen tuulen luonteenpiirteiden takia yli kuusi tuntia nykyhetkestä eteenpäin alkaa kuitenkin vaatia algoritmeihin lähtötietoja sääennusteista. Näitä arvoja voidaan hankkia numeerisilla säänennustusmenetelmillä. [38]

Holttisen et. al. tutkimuksen [38] mukaan ennustemalleja voidaan jakaa sen mukaan, onko käytetty tilastollista vai fyysistä lähestymistapaa. Fyysinen malli yrittää luoda mallin tuulialasta ja tuulen käyttäytymisestä hyödyntäen informaatiota kyseisestä alueesta, kuten kalliomuodostelmista ja muista tuulen kulkua vaikeuttavista esteistä.

Tilastolliset mallit eivät mallinna tuulen käyttäytymistä fyysisesti tuulivoimalaitoksessa. Sen sijaan tilastolliset mallit pyrkivät löytämään riippuvuuksia tuotetun tuulivoiman ja selittävien muuttujien välillä esim. numeeristen säänennustusmenetelmien tuottamien tuuliennusteiden. Riippuvuuksien löytäminen tapahtuu monesti minimoimalla kustannusfunktio, joka on funktio sekä todellisesta energiantuotannosta sekä tilastollisesta mallista ennustetusta energiasta.

Lyhyen aikaikkunan tuulivoimaennusteista on hyötyä sähkömarkkinoilla toimiville osapuolille. Pajusen [73] haastatteleman Fingridin käytönsuunnitteluyksikön suunnitteluinsinööri Mika Laatikaisen mukaan Suomessa tuulipuistojen tuotantoa

ennustetaan säähavainnoilla. Säähavaintoja verrataan aikaisemmin samanlaisissa oloissa toteutuneeseen tuotantoon. Tällä tavoin on Laatikaisen mukaan päästy hyvinkin tarkkoihin tuloksiin.

Jäätymisennusteet ovat tärkeitä tuulivoiman tuottajille talvisissa olosuhteissa. Jos tuulivoimalan lavat jäätyvät pahasti, niin tuotanto voi olla lähellä nollassa, vaikka ennusteiden mukaan tuotannon pitäisi olla korkealla tasolla. [92]

Tuulivoiman ennustamisessa voidaan huomioida myös tunnettuja lintujen lentoreittejä. Tuulivoimapuistojen alueella voidaan käyttää tutkalaitteistoja, joilla havainnoidaan uhanalaisia lintulajeja. Kun uhanalaiset lintulajit lentävät tuuliturbiinien alueella, voidaan yksittäinen turbiini pysäyttää hetkeksi. Varttitunnille suunnattu tuotanto saattaa kärsiä huomattavasti yhden turbiinin alasajosta, varsinkin jos tuulivoimapuistossa ei ole montaa tuuliturbiinia. [92]

Kaikkien vaihtelevan tuotannon energianmuotojen saatua lisää poliittista tukea ja kannattavuutta, myös aurinkovoiman tuotantomäärät ovat kasvussa. Tämän takia aurinkovoimaa ja aurinkopaneeleilla tuotetun sähkön määrää täytyy ennustaa tarkemmin, jotta koko sähköntuotantoprosessia voidaan suunnitella ja aikatauluttaa tehokkaammin ja paremmin [41](viittaa tämän lähteen lähteisiin [3]-[5]).

Inmanin et. al. artikkelissa [41] painotetaan, että aurinkovoiman ennustaminen usealla eri aikaresoluutiolla on tärkeää, sillä ennusteita tarvitaan toiminnanohjaukseen, kulutuksen määräämään tuotantoon, tuotantoyksiköiden käytön suunnitteluun sekä UC-ongelman ratkaisemiseen. Lyhyen aikavälin ennustaminen on tärkeää voimalaitoksen toiminnan, sähköverkon tasapainottamisen, reaaliaikaisen yksiköiden toiminnan suunnittelun, automaattisen ohjauksen ja kaupanteon kannalta [55]. Pidemmän aikavälin ennustamista tarvitaan puolestaan UC-ongelman ratkaisemiseen, toiminnan suunnitteluun sekä ohjauksen suorituskyvyn kehittämiseen. [41] Pilvimassojen liikettä olisi hyvä pystyä ennustamaan etukäteen, jotta omaa tuotantoa voidaan suunnitella paremmin. Jos seuraavan vuorokauden vallitsevan sään tiedetään olevan puolipilvistä niin on tärkeää tietää, miten tuotanto sijoittuu ajallisesti. Varsinkin varttitasolla pilvien liikkeestä tällaisessa säässä on tärkeä olla mahdollisimman tarkka ennuste

Uusia aurinkovoiman ennustusmenetelmiä ja -järjestelmiä tarvitaan, koska pilvien muodostuminen ja niiden liike ovat luonteeltaan kaotista ja epälineaarista. 2010-luvun alkupuolelta asti on kuitenkin luotu parempia menetelmiä ja järjestelmiä, jotka perustuvat mm. ilmakehän liikkeisiin ja koneoppimiseen. [41] Pajusen artikkelin [73] mukaan aurinkovoiman ennusteet perustuvat eri alueiden aurinkovoimakapasiteettiin ja säteilyennusteeseen.

### 3.5.3 Residuaalikuorma

Residuaalikuormalla tarkoitetaan sitä kokonaiskulutuksen täyttämiseen tarvittavaa sähköä, jota ei pystytä tuottamaan vaihtelevalla uusiutuvalla tuotannolla. Residuaalikulutus voidaan kattaa oman valtion tuotantolaitosten tuottamalla tuotannolla, hankkimalla sähkö ulkomailta tai omista varareserveistä. [10]

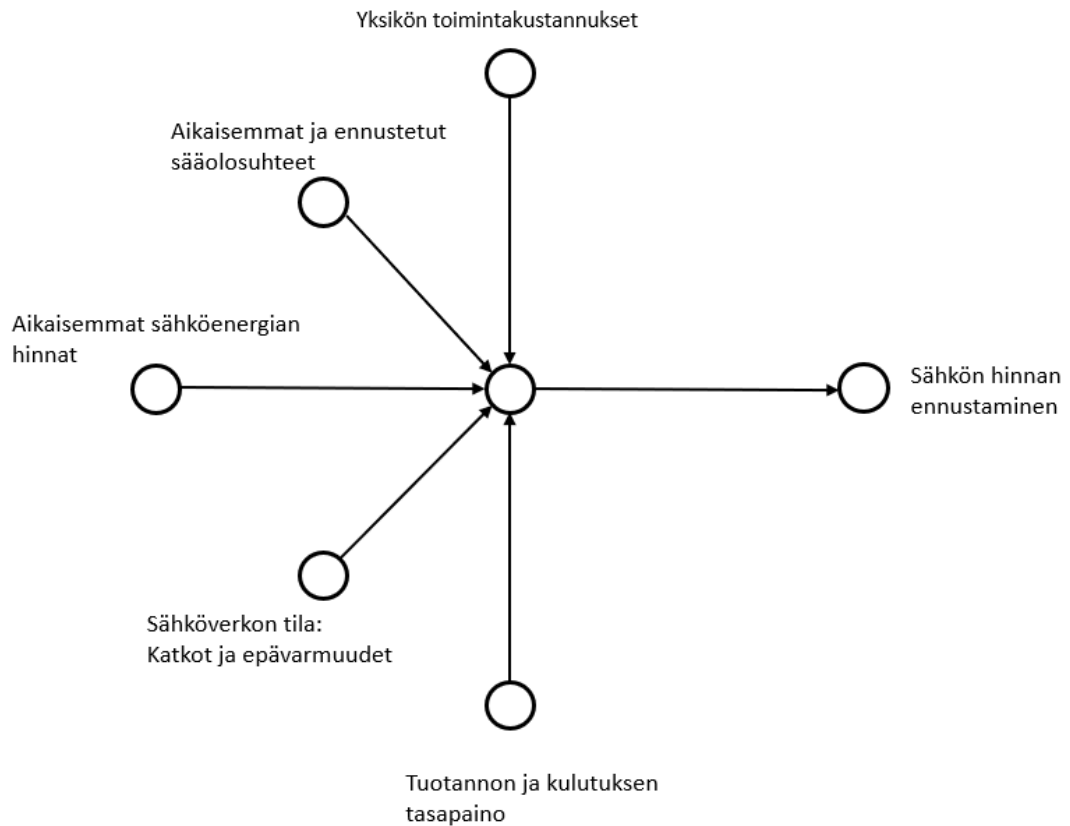
Residuaalikuorman ennustamisesta on tullut tärkeä osa nykypäivää, kun monet valtiot tukevat ympäristöystävällistä vaihtelevaa tuotantoa. [10] Vaihteleva uusiutuva tuotanto on luonteeltaan melko epävakaa sääolosuhteiden takia, jonka seurauksena päivittäisen residuaalisähkönkin määrä voi vaihdella paljon. Don et. al. artikkelin [10] mukaan maat, esimerkiksi Saksa, joissa vaihtelevan tuotannon määrä on merkittävää, tarvitsevat parempia malleja, jotta residuaalikulutus saadaan määritettyä tarkasti ja tehokkaasti. Korkea residuaalikysyntä syntyy, kun sähkön kysyntä on korkea ja vaihtelevan tuotannon määrä on matala. Tällöin tarvitaan paljon perinteistä tuotantoa ja mahdollisesti sähkön maahantuontia tai varastoreservejä. Matala residuaalikysyntä johtuu tilanteesta, kun kysyntä sähkölle yleisesti on matalaa, mutta vaihtelevaa uusiutuvaa tuotantoa on paljon. Tällainen tilanne on yleensä viikonloppuisin ja loma-aikoina, kun sääolosuhteiden takia vaihteleva tuotanto on runsasta. [10]

Tuotantoennusteiden tarkkuus on tärkeää residuaalituotannon kannalta. Residuaalikysyntä on täytettävä kokonaan, joten ennustamisessa on huomioitava vaihtelevan tuotannon epävarmuudet.

### 3.5.4 Sähkön hinta

Sähkön hinnan ennustaminen on tärkeää sähkömarkkinoille osallistuvien osapuolien näkökulmasta. El-Hawaryn [11] mukaan kulutuksen ja hinnan ennusteet ovat hyvin riippuvaisia toisistaan, sillä sähkönkulutuksen ennustevirheet vaikuttavat suoraan hinnan ennusteiden tarkkuuteen. Seuraavan päivän hintatarjoukset valmistellaan tehtyjen ennusteiden pohjalta. Tuotanto pyrkii kehittämään strategian, jolla se pystyy maksimoimaan oman voittonsa ja luomaan kaupankäyntistrategian, jolla se pystyy maksimoimaan tuotannosta saatavan taloudellisen hyödyn. Kulutuspuolella vastaavasti suunnitellaan, miten markkinoilta ostettu sähkö auttaa maksimoimaan oman toiminnan tuotot. Jos kuluttajilla on mahdollisuus omaan sähköntuotantoon esim. aurinkopaneeleilla, voidaan markkinahinnan kasvaessa turvautua itsetuotettuun sähköön. [62]

Sähkön hinnan ennustaminen on kulutuksen ennustamista monimutkaisempaa, sillä siihen vaikuttavat monet tekijät. Tekijät ovat esitetty kuvassa 6.



**Kuva 6.** Sähkön hintaan vaikuttavat tekijät (muokattu lähteestä [11]).

Toiminnan epävarmuus, markkinaosapuolten tarjousstrategiat sekä se, että sähkön varastointi on vaikeaa, tekevät markkinoista ainutlaatuiset. Hintaan vaikuttavat myös energian tuotannon vaatiman polttoaineen hinta, energian tuotannosta syntyvät kustannukset sekä sääolosuhteet. Myös historiadataa tarkastellaan sekä säätilan että sähkön hinnan osalta. Viimeisimpänä hintaan vaikuttaa sähköenergiajärjestelmän yleinen tasapainotilanne kulutuksen ja tuotannon välillä. [11]



## 4. ENNUSTAMISEN MENETELMÄT

Sähkönkulutuksen ennustaminen on vaativaa, koska kulutus on luonteeltaan vaihtelevaa eli sähköä ei kuluteta minkään valmiin mallin mukaan, vaan kulutus määräytyy luvussa 3.4 esiteltyjen muuttujien pohjalta. Ennustamisessa voidaan hyödyntää aiempia säätietoja, aiempien vuosien kulutusdataa sekä muuta dataa, joidenka perusteella voidaan ennakoita, milloin sähköä tarvitaan enemmän. Esimerkiksi kuumana päivänä asuinalueilla käytetään paljon ilmastointilaitteita, jolloin sähkön kulutukseen syntyy piikkejä [82]. Vastaavasti kylmällä säällä piikit aiheutuvat sähkökäyttöisestä lämmityksestä.

Kulutuksen ennustamisen menetelmät on jaettu kahteen ryhmään: parametriin ja ei-parametriin menetelmiin. Parametrisilla tekniikoilla kerätty data seuraa todennäköisyysjakamaa, joka pohjautuu määrättyyn joukkoon parametreja. Parametrisia tekniikoita ovat mm. lineaarinen regressio, eksponentiaalinen tasoitus ja autoregressiivinen liikkuvan keskiarvon menetelmä (ARMA). Ei-parametriset tekniikat puolestaan ovat pääasiallisesti tekoälyyn perustuvia ja niillä on joustavat parametrit, jotka voivat vaihdella perustuen uuteen saatavilla olevaan informaatioon. Ei-parametrisia tekniikoita ovat mm. neuroverkot, tukivektorikone sekä ”Extreme Learning Machine” (ELM). [2] Tässä työssä näihin menetelmiin tutustutaan myöhemmin tässä luvussa.

### 4.1 Koneoppiminen ja tekoäly kulutuksen ja tuotannon ennustamisessa

Koneoppimisen ja tekoälyn käyttämisestä sähkönkulutuksen ja -tuotannon ennustamisessa on paljon hyötyä, sillä sähkömarkkinat ovat kokonaisuudessaan todella monimutkainen järjestelmä. Tähän on kaksi syytä. Porteiron et. al. tutkimuksessa [75] esitetään, että nykymaailmassa ennusteiden tekoon saatavilla olevan datan määrä on moninkertaistunut, kun elektronisten mittausantureiden ja mittalaitteiden määrä on kasvanut. Tämän on mahdollistanut laitemyönteisyys, kun mittalaitteiden käyttöä tuetaan ja mittareiden yhteensopivuutta toisiinsa kehitetään. Lisäksi Porteiro et. al. väittävät, että energian käyttöön on kehittynyt uusia tapoja.

Miten kulutusta ennustetaan? Porteiron et. al. [75] mukaan kulutuksen ennustamisongelmaa lähestytään yleensä matemaattisin keinoin, joissa historiadataa käytetään ennustamaan sähköenergian kysyntää. Historiadatan avulla on helpompaa määrittää, mikä algoritmi toimii sovelluksen tarkoituksiin tehokkaimmin.

Porteiron et. al. tutkimus [75] perustuu kulutuksen ennustamiseen teollisuuslaitoksissa. Ennustaminen voi tässä tapauksessa poiketa asuinalueiden kulutuksen käyttäytymisestä sen takia, että teollisuuslaitoksien tarve pohjautuu yleensä toiminnan tai prosessin ylläpitoon melko tasaisesti riippumatta ajanjaksosta, säästä tai jostain muusta syystä.

Lähes poikkeuksetta koneoppimiseen pohjautuvat ennustusmenetelmät vaativat toimiakseen jonkin mallin. Porteiron et. al. [75] mukaan malleja on tilastollisia tai fysikaalisia. Mallien on tarkoitus toimia suunnitellun aikaikkunan mukaan. Tilastolliset mallit ovat vähemmän monimutkaisia ja laskennallisesti kevyempiä kuin fysikaaliset mallit ja toimivat hyvin lyhyen aikavälin ennusteissa. Fysikaaliset mallit ovat luonteeltaan monimutkaisempia ja käsittelevät ympäristön olosuhteita differentiaaliyhtälöiden avulla. Niitä hyödynnetään yleensä pitkän aikavälin ennusteiden tekemiseen.

Ennustamisongelman ratkaisu alkaa ongelman formuloimisella sekä toteutusstrategian suunnittelulla. Porteiron et. al. tutkimuksessa [75] luotiin tilastollinen malli, jossa tavoitteena oli muodostaa ennuste sähkönkulutukselle 24 h:n päähän. Tutkimuksessa on käytetty tunnin aika-askelta. Historiadataa on saatavilla tunnin aika-askeleella, joten luontaisesti askel askeleelta on helpointa ennustaa seuraavan tunnin kulutusta.

Koska ennustaminen ja malli tarvitsevat toimiakseen historiadataa, on ensimmäinen askel toimivan koneoppimismenetelmän luomiseksi datan kerääminen ja sen esikäsittely. Dataa täytyy prosessoida ja valmistella huolellisesti, jotta lopputulos on laadukas ja luotettava. Datasta pitää esimerkiksi karsia selvästi virheelliset mittausarvot tai hyödyttömät mittaukset (mittauslaite voi esimerkiksi toimia silloin, kun prosessi ei ole käynnissä). [75] Datan keräämisen ja esikäsittelyn jälkeen on vuorossa käytettävän mallin rakenteen valinta ja mallin opettaminen. Mallin arvioimiseen ja valitsemiseen opetusvaiheessa voidaan käyttää joitakin matemaattisia mittareita kuten ”Mean Absolute Percentage Error” (MAPE) tai ”Root-Mean-Square Error” (RMSE). Kun malli on opetettu lyhyelle aikavälille, voidaan aikaikkunaa kasvattaa soveltamalla lyhyellä aikavälillä toimivaa mallia. [75]

Kun sopiva mallin rakenne on löydetty, täytyy mallin parametreja muokata tarkoituksiin sopivasti, jotta ennustemalli saadaan optimoitua parhaalla mahdollisella tavalla. Optimoitu ratkaisu löydetään testaamalla mallia useissa erilaisissa toimintatilanteissa. [75]

Seuraavaksi tutustutaan, mitä menetelmiä lyhyen ajan tuotannon ennustamisessa käytetään, miten menetelmiä hyödynnetään, ja mitä lähtötietoja eri menetelmät tarvitsevat ennusteiden tekemiseen.

Ennen eri menetelmien vaatimuksia tarkistellaan yleisiä vaatimuksia, mitä kaikki ennustemenetelmät tarvitsevat. Ennusteita ei voida luoda täysin tyhjästä, vaan kaikki ennustemenetelmät tarvitsevat lähtötietonaan jonkin kuvauksen järjestelmästä, jotta tiedetään, millainen ennustettava järjestelmä tai kokonaisuus on. Tuotantopuolella on tärkeää tietää, millaisia laitteita on käytettävissä ja millainen niiden tuotantokapasiteetti on.

#### 4.1.1 Neurosumeat oppivat järjestelmät

**Neuroverkot** pohjautuvat teknologialtaan ihmisen hermostoon. Verkko muodostuu suuresta matriisista keinotekoisia neuroneita, jotka ovat yhteydessä toisiinsa. Jokaisella neuroverkkoon kuuluvalla neuronilla on sille ominainen syöte, tuloste, paino ja aktivaatio-funktio [34]. Neuroverkon määritellään olevan yksinkertaisten prosessiyksiköiden muodostama suuri matriisi rinnakkaiskombinaatioita. Rinnakkaiskombinaatiot voivat muokata parametrejaan oppimisprosessin kautta reagoiden toimintaympäristöön, jotta ne voivat varastoida informaatiota. Neuroverkon opettaminen mahdollistaa muuttumattomuuden tunnistamisen ja tallentamisen sellaisten muuttujien välillä, mihin verkkoa ei ollut alun perin opetettu. [2]

Neuroni toimii neuroverkossa laskentaelementtinä. Neuroni ottaa vastaan joukon syötteitä, joista jokaisella on oma painokertoimensa. Tämän jälkeen joukko summataan yhteen ja välitetään aktivointifunktiolle, joka määrittää neuronin tulosteen arvon. Tuloste voi olla joko neuroverkon lopullinen tuloste tai syöte toiselle neuronille neuroverkon eri tasolla. [2]

Neuroverkoilla on tyypillisesti kolme eri kerrosta: syöte-, piilo- ja tulostekerros. Neuroverkoista, joilla ei ole piilokerrosta, käytetään nimeä yksikerroksinen neuroverkko (SLNN). Neuroverkot, joilla on yksi tai useampi piilokerros, kutsutaan monikerroksisiksi perseptronverkoiksi. [2]

Neuroverkkojen opetusprosessi voi olla kahta tyyppiä: valvottu tai ei-valvottu. Valvotussa menetelmässä neuroverkon halutut syötteet ja tulosteet ovat annettu, ja neuroverkko vertaa omia laskennallisia tulosteitaan annettuihin tulosteisiin ja muokkaa käyttäytymistään virheiden avulla uutta iteraatiota varten. Ei-valvotussa menetelmässä haluttua tulostetta ei neuroverkolle anneta, vaan sen täytyy itse ryhmittää data jonkin ominaisuuden mukaan. [37]

**Deep learning** eli syväoppiminen on koneoppimisen osa-alue, jossa monikerroksiset neuroverkot saadaan toimimaan ihmisaivojen tapaan ja suorittamaan monimutkaisia

tehtäviä. Jokaisella neuroverkon kerroksella algoritmit suorittavat laskutoimenpiteitä ja tekevät toistuvasti ennusteita samalla oppien ja kehittäen suorituskykyä ja mallin tarkkuutta. Deep learning -tekniikoita käytetään mm. puheentunnistuksen sovelluksissa, autonomisissa kulkuneuvoissa tai kohteiden tunnistamisessa kuvista tai tekstistä ilman ihmisen vaikutusta tunnistamisprosessiin. [40]

Deep Learning on käytetty myös sähkönkulutuksen ja -tuotannon ennustamisessa. Hafeezin et. al. [32] tutkimuksessa tutkittiin Deep Learningiin pohjautuvaa kulutuksen ennustamista mallilla, johon oli integroitu datan esikäsittely- ja piirteervalintamoduuli, opetus- ja ennustusmoduuli sekä optimointimoduuli. Deep Learning oli toteutettu opetus- ja ennustusmoduuliin ”Factored conditional restricted Boltzmann machine”:n (FCRBM) avulla. FCRBM-metodi tarvitsee lähtötiedokseen ennustettavan suuren historiadataa, jotta neuroverkko voi oppia, miten ennustettava suure käyttäytyy erilaisissa tilanteissa. Lisäksi FCRBM-metodiin voidaan liittää säästä riippuvia tekijöitä, tapahtumamalleja tai kalenteridataa, joiden havaitaan vaikuttavan selvästi ennustettavaan suureeseen.

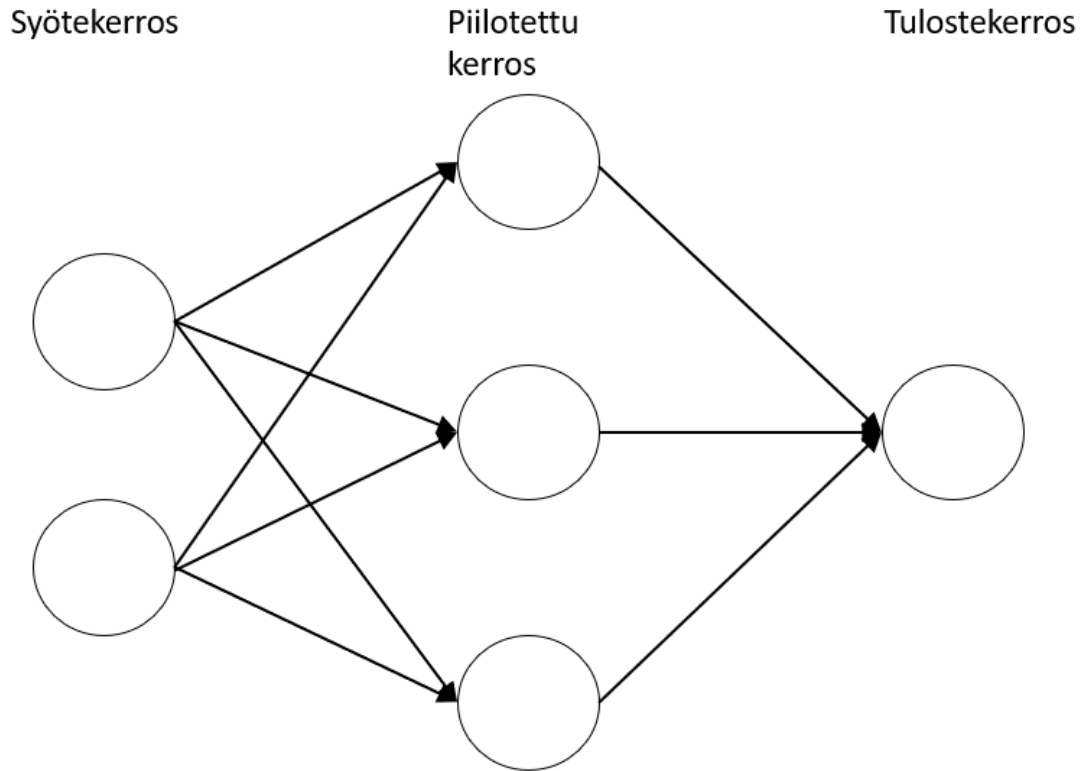
Yusuf et. al. viittaavat konferenssiartikkelissaan [93] useaan lähteeseen, joissa on käytetty takaisinkytkettyä neuroverkkoa (RNN) ennusteiden tekemiseen. He soveltavat RNN:a sekä 15 minuutin että päivittäisen aikavälin yli. Perinteiset RNN-metodit eivät voi oppia ja hyödyntää pidemmän aikavälin peräkkäisiä arvoja ennusteen tekemisessä. Tästä on kuitenkin päästy eroon käyttämällä ”Long Short-Term Memory” -menetelmää (LSTM), joka estää syötegradienttien katoamisen tai kasvamisen äärettömäksi pidemmällä aikavälillä [36].

LSTM-metodissa on piiloyksikkö, joka muodostuu neljästä eri kerroksesta. Ensimmäinen niistä on ns. ”unohtamisportti” ( $f_t$ ), jonka tehtävä on päättää, onko data turhaa vai ei. Kaksi muuta porttia ovat syöte- ( $i_t$ ) ja tulosteportti ( $o_t$ ). Kaikki kolme porttia ovat muodoltaan sigmoid-funktioita. Uudet solun tilat ( $c_t$ ) ja piilotetun kerroksen ulostulo ( $h_t$ ) päivitetään esitettyjen porttien arvoihin perustuen.

**Extreme Learning machine** (ELM) on paljon käytetty menetelmä uusiutuvien energianlähteiden kuten tuuli- ja aurinkovoiman ennustamisessa. Wan et. al [87] tutkivat ELM:en käyttöä tuulivoimatuotannon ennustamisessa. Le Cadre et. al. [52] puolestaan aurinkovoiman tuotannon ennustamisessa. ELM on oppimisalgoritmi, jota käytetään opettamaan yhden piilotetun kerroksen myötäkytkettyjä neuroverkkoja (SLFN) [52][87]. Wanin et. al. [87] mukaan ELM:n toimintaperiaate on seuraavanlainen. Algoritmi valitsee satunnaisesti syötteiden painoarvot ja poikkeamat käyttäen jatkuvia todennäköisyysjakautumia ja jälkeinpäin määrittää tulosteiden painoarvot käyttäen matriisilaskentaa. Tutkimuksessa [87] on käytetty buuttaus-perusteista ELM:tta (BELM),

joka ottaa paremmin huomioon tuulen ja tuuliaikasarjojen vaihtelevan luonteen. ELM:en rakennetta on demonstroitu kuvassa 7.

E



**Kuva 7.** ELM:en mallin rakenne (muokattu lähteestä [87]).

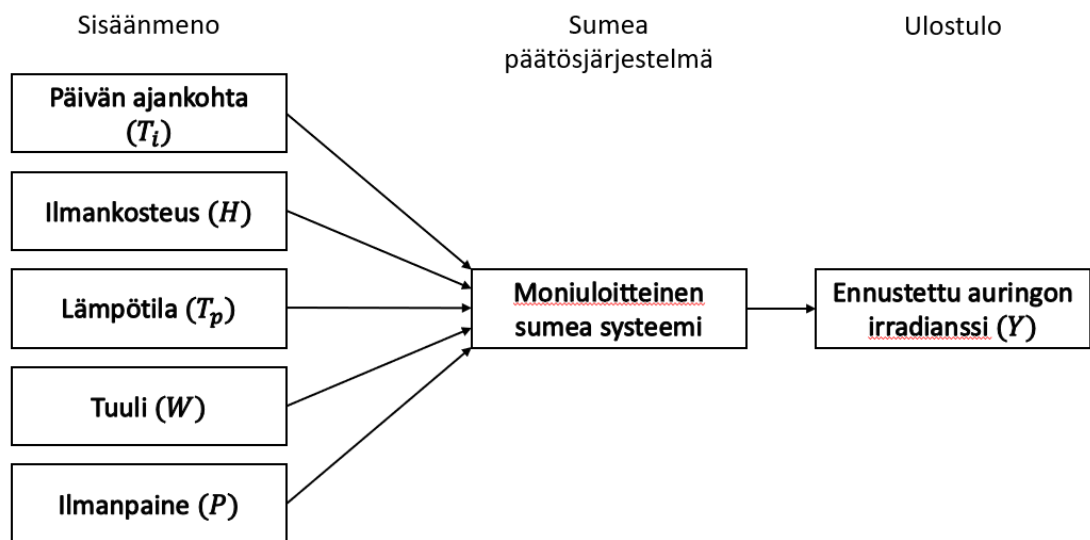
Wanin et. al. rakentama ELM-algoritmi tarvitsee lyhyellä tunnin päähän tehtävällä ennusteella lähtötiedoksi ainoastaan aikaisempaa tuulivoimadataa. Pidemmälle aikavälille tehtävässä ennustamisessa systeemiin on helppo integroida lisää numeerista sääennustedataa lisäsyötteeksi. BELM-algoritmeilla saatiin lupaavia tuloksia verrattuna muutamiin eri metodeihin, kuten eksponentiaalisen tasoituksen (ESM) ja pysyvyysmetodiin. BELM:en havaittiin jopa olevan parempi tarkasteltuna PICP-menetelmällä (Prediction Interval Coverage Probability), joka mittaa ennustevälien luotettavuutta. [87]

Ennusteen perusteiksi tarvitaan tietoa siitä, kuinka luotettava ELM-malli on sekä kuinka luotettavaa data on. Tuulivoiman ennustamisessa on Wanin et. al. [87] mukaan mahdotonta saada täysin luotettavaa informaatiota kohinaisesta datasta, jotta datan epävarmuutta pystyttäisiin vähentämään.

Le Cadren et. al. tutkimuksessa ELM käyttää päivittäistä tuotantodataa ja paikallista säätietodataa (auringonsäteily, tuulen suunta ja nopeus, pilvipeite, lämpötila,

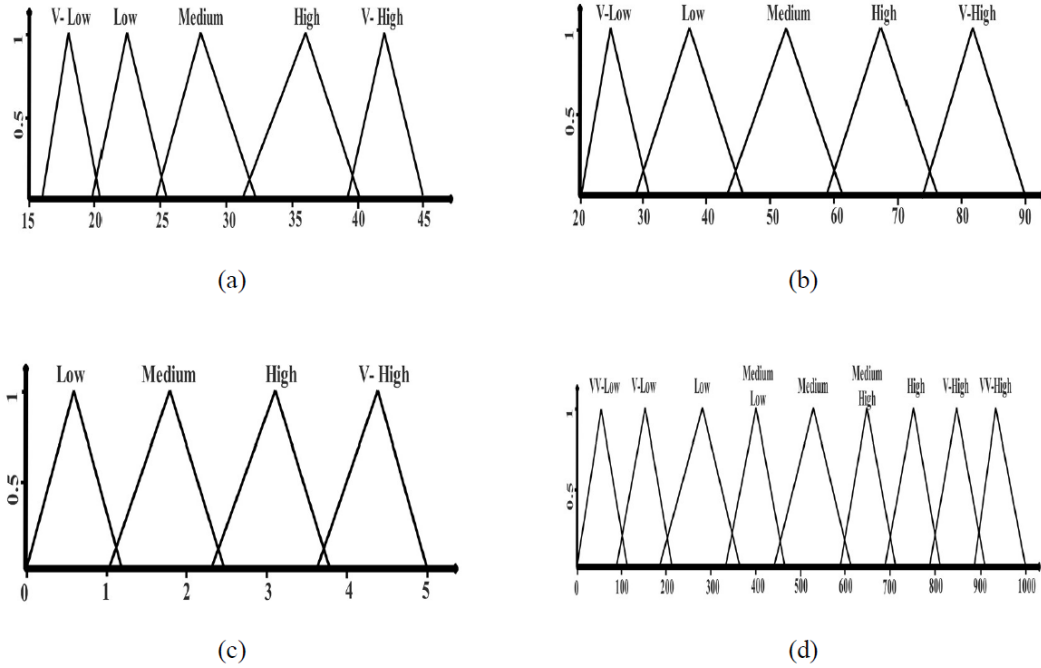
sademäärä, ilmanpaine ja suhteellinen kosteus) 24 tunnin horisontille tehtävän valosähköisen (engl. photovoltaic, PV) tehontuotannon ennustamiseen. Lisäksi auringon sijainnin määrittämisessä käytetään SPA-algoritmia (Solar Position Algorithm). Ennusteen aikaväli seuraavaan tehtävään ennusteeseen oli 30 minuuttia. Syöteinä ennusteille tällä aikavälillä oli senhetkisen päivän PV-tuotanto 30 minuutin jaksoissa sekä ennusteen kohdealueelta saatavat meteorologiset havainnot paikallisilta havaintoasemilta. [52]

**Sumea logiikka** on käytetty menetelmä uusiutuvien energianlähteiden tuotannon ennustamisessa. Sen toimintaperiaate pohjautuu epälineaariseen syötteiden ja tulosteiden kuvaukseen. Mehtan ja Basakin [57] tutkimuksessa kehitetty sumean logiikan malli on esitetty kuvassa 8:



**Kuva 8.** Sumean logiikan mallin rakenne (muokattu lähteestä [57]).

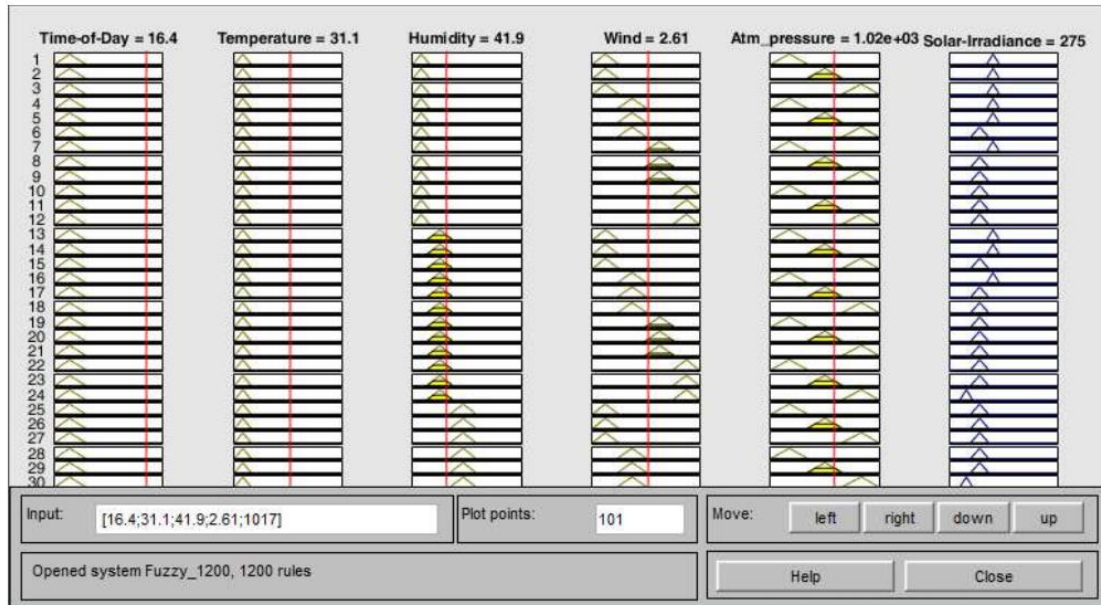
Rakenne ottaa kuvan 8 esittämällä tavalla syötteikseen viisi kalenteri- tai meteorologista parametria ja tuottaa tulosteenaan irradianssin ennusteen. Säätilyötteitä oli kerätty minuutin aikaväleihin. Sumeassa systeemissä syötteille määritellään jäsenyysfunktioilla arvo väliltä [0,1]. Jäsenyysfunktio kuvaavat sitä, kuinka paljon suure kuuluu sitä vastaavaan kielellisen muuttujan joukkoon. Kuvassa 9 on esimerkit jäsenyysfunktioista ilmankosteudelle, lämpötilalle ja tuulen nopeudelle sekä irradianssille.



**Kuva 9.** Jäsenyysfunktiot (a) lämpötilalle, (b) ilmakesteudelle, (c) tuulen nopeudelle ja (d) auringon irradianssille [57].

Eri muuttujien jäsenyysarvot on jaettu muuttujille riippuvaisella tavalla eri kielellisiin muuttujiin (Very Low, Low, Medium, High jne.) kuvan 9 mukaan. Jokainen suure voi saada jokaisella kielellisen muuttujan arvolla todennäköisyyden 0:n ja 1:n väliltä. Kuvassa 9a lämpötila 30 astetta celsiusta kuuluu keskimääräiseen kielelliseen muuttujaan ja sen jäsenyysarvo on noin 0,5.

Tutkimuksessa saadun mallin jäsenyysarvojen pohjalta saatiin viiden parametrin yhdistelmille 1200 erilaista kombinaatiota. Näitä kombinaatiota varten oli luotu ns. ”rule-viewer”-ikkuna, joka on kuvassa 10.



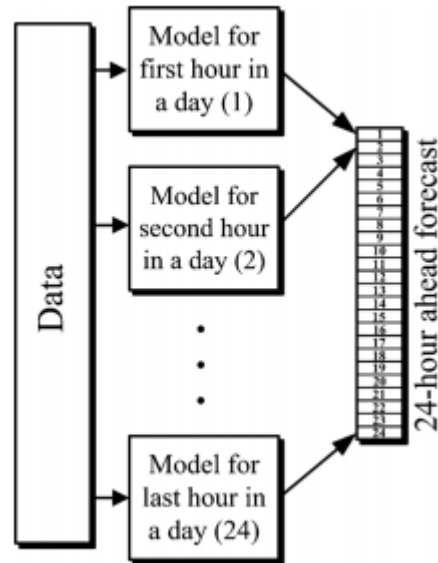
*Kuva 10. Rule viewer-ikkuna [57].*

Ikkunasta on nähtävissä syötteiden arvot, sijainti jäsenyysfunktiossa sekä tulosteen arvo irradianssille.

#### 4.1.2 Geneettiset menetelmät

**Tukivektorikoneita** käytetään jonkin verran lyhyen aikavälin ennusteiden tekemisessä. Ceperic et. al. [8] rakensivat kausitasoitettua tukivektoriregressiokoneen (SSA-SVR) sähkön kulutuksen ennustamiseen. SSA-SVR-malli tarvitsee historiadataa säästä ja kulutuksesta sekä sääennusteen.





**Kuva 11.** Seuraavalle vuorokaudelle tehtävän ennusteen malli [8].


Kuvassa 11 on malli, jolla seuraavan vuorokauden ennusteet on luotu. Jokaisen tunnin malli ottaa syötteen aiempaa kulutusdataa aiemman viikon ajalta, lämpötiloja ja ilmankosteuden. Lisäksi binääridatana saadaan tietoa siitä, mikä viikonpäivä ja kuukausi on, tai onko lomapäivä vai ei. [8] Ennusteen jokainen tunti on muodostettu erikseen omalla mallillaan.

Tukivektorikoneregression formuloimisessa tyypillinen tapa on Vapnikin  $\varepsilon$ -SVR ( $\varepsilon$ -SVR).  $\varepsilon$ -SVR-menetelmä tekee lineaarisen regression moniulotteisessa Kernel-funktion luomassa piirreavaruudessa käyttäen  $\varepsilon$ :n kokoisen virheen sallivaa häviöfunktioita, ja samaan aikaan yrittäen vähentää mallin kompleksisuutta minimoimalla mallin painokertoimia.  $\varepsilon$ -SVR-menetelmän tavoitteena on siis löytää funktio  $f$ , jolla on mahdollisimman suuri hajonta  $\varepsilon$  koko opetusosan datasta ja se on samanaikaisesti mahdollisimman tasainen. [86] Kaava funktiolle  $f$  on esitetty seuraavaksi:

$$f(x) = \sum_{i=1}^l w_i K(x_i, x) + b \quad (4)$$

$x_i$  on  $p$ -ulotteinen syötevektori, jolla on yhteys tulostevektoriin ja  $K$  on Kernel-funktio. Muuttuja  $l$  kuvaa opettavien datanäytteiden lukumäärää. Funktiosta  $f$  tehdään mahdollisimman tasainen etsimällä pienet painokertoimet  $w$ :lle. Yksinkertainen tapa tasaisuuden varmistamiseksi on minimoida yhtälö  $\|w\|^2 = \langle w, w \rangle$ . [8] Kernel-funktion tehtävä on erottaa lineaarisesti erottamattomasta datajoukosta kaksi eri luokkaa laajentamalla syöteavaruutta. Kahden eri joukon väliin muodostetaan ns. päätöstaso

siten, että kahden datajoukon väliset marginaalitasot ovat mahdollisimman kaukana päätöstasosta kuvan 12 mukaisesti. [44]



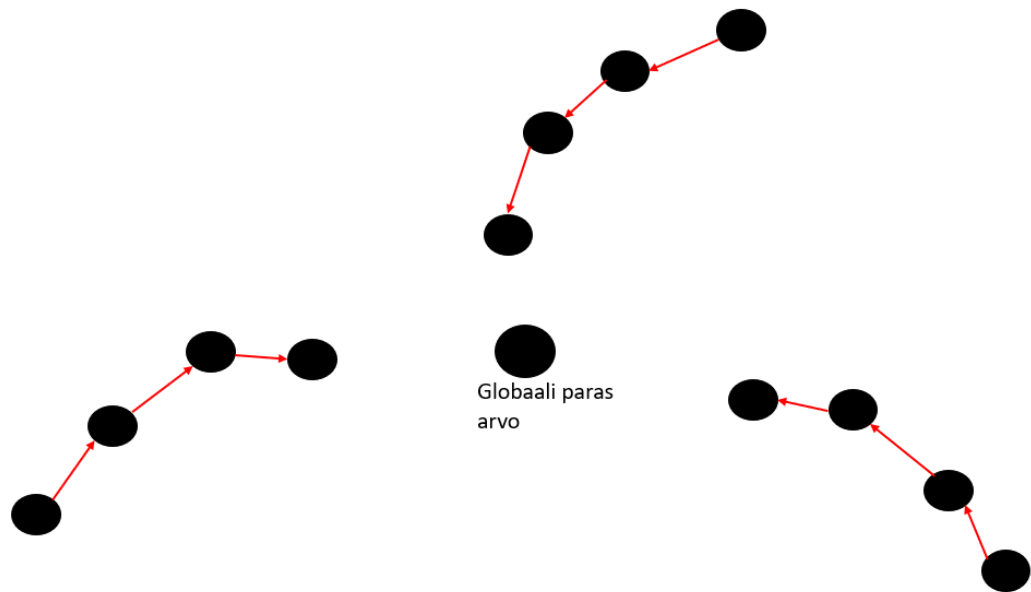
**Kuva 12.** Tukivektorikone (pätöstaso kiinteällä viivalla ja marginaalitasot katkoviivalla, mukailtu lähde [44]).

Tukivektorikoneilla on kolme hyperparametria, jotka täytyy optimoida ja virittää parhaan suorituskyvyn saamiseksi. Ensimmäinen parametreista on regulointiparametri  $C$ , joka on arvoltaan vakio. Sitä voidaan pitää säätöparametrina mallin kompleksisuuden ja epsilona suurempien virheiden hyväksymisen välillä. Osa päätöksen väärälle puolelle joutuneista syötteistä voidaan siis sallia. Toinen hyperparametri on epsilonputken halkaisija  $\epsilon$  ja kolmas Kernel-funktion lisäparametrit. [8]

SVR-hyperparametreilla on merkittävä rooli kulutuksen ennustamisessa. Esimerkiksi  $C$ :n ollessa liian suuri ylisovittamisen riski kasvaa [8]. Tällöin malli mallintaa opetusdataa liian hyvin eikä toimi suorituskyvyltään yhtä hyvin uuden datan kanssa.

**Hiukkasparviontimointi** eli **Particle swarm optimization** (PSO) on kuorman ennustamisessa käytetty menetelmä, jonka ideana on luoda joukko "hiukkasia", joista algoritmi etsii sopivimman kandidaatin annettujen hakuehtojen perusteella. Muut

hiukkaset kulkevat jokaisen laskentakierroksen aikana kohti hiukkasta, joka on saanut parhaimmat laskenta-arvot ja parhaan arvon saanut hiukkanen liikkuu lähemmäs virhetermin minimiä [50]. Periaatetta on havainnollistettu kuvassa 12. Tällöin hiukkasten positiot ja nopeudet päivittyvät parempaan suuntaan ja saavuttavat paremman ennustetuloksen. [72]



**Kuva 13.** Hiukkasparvioptimoinnin periaatekuva (mukailltu lähteestä [49]).

Aluksi hiukkaset määritellään satunnaisesti ja niillä on neljä parametria: positio, nopeus, yksilöllinen paras sopivuus ja globaali paras sopivuus. [72]

Ozerdemin et. al. tutkimuksessa [72] PSO:n ja neuroverkon välillä saatiin hyvät tulokset Kyproksen sähkökuorman ennustamisessa. PSO-algoritmin avulla ei päästy ihan yhtä tarkkoihin tuloksiin kuin neuroverkolla, mutta laskennan havaittiin olevan huomattavasti kevyempää.

### 4.1.3 Aikasarjamenetelmät

Aikasarjamenetelmät ovat paljon käytettyjä sähköön liittyvien suureiden, kuten kulutuksen ja hinnan ennustamisessa ja hyödyntävät historiatietoa ennusteen tekemisessä. Karabiber ja Xydis [46] tutkivat sähkön hinnan ennustamista käyttäen **integroitua autoregressiivistä liukuvan keskiarvon** menetelmää (ARIMA) seuraavan vuorokauden markkinahinnan ennusteessa.

Williamsin [90] sekä Karabiberin ja Xydiksen [46] mukaan ARIMA-mallin ymmärtämiseksi on tärkeää ymmärtää käsitteet differenssi sekä stationaarisuus. Differentoimalla luodaan muunnettu aikasarja, joka sisältää viiveellisten havaintojen aiheuttamat poikkeamat alkuperäiseen aikasarjaan verrattuna.

Differentoimista voidaan käyttää myös kausittaiselle viiveelle. Esimerkiksi aikasarjalle, jossa on 15 kausittaista sykliä, ensimmäinen niistä kirjoitettaisiin  $\nabla_{15}X_t = X_t - X_{t-15}$ . Yleisesti ARIMA-mallien esittämisessä suositaan "backshift"-operaattorin  $B$  käyttöä. [90]

Stationaarisuudella viitataan aikasarjoissa monesti heikkoon stationaarisuuteen. Aikasarjan  $\{X_t\}$  sanotaan olevan heikosti stationaarinen, kun aikasarjan odotusarvo on sama kaikilla  $t$ :n arvoilla ja kovarianssi minkä tahansa kahden havainnon välillä on riippuvainen ainoastaan havaintojen välisestä viiveestä. [90] Jotta ARIMA-malleja voidaan käyttää, on käytettävän datan oltava stationaarista [93].

Kavasserin ja Seetharamanin tutkimusartikkelissa [48] ennustettiin seuraavan vuorokauden tuulen nopeutta (tuulivoimaa) käyttäen **paloittain integroitua autoregressiivistä liukuvan keskiarvon menetelmää** (f-ARIMA). F-ARIMA muodostuu parametreista  $p$  (autoregressiivinen osa),  $q$  (liukuvan keskiarvon osa) sekä  $d$  (differentoiminen, lähteessä [48]  $d \in (-0,5, 0,5)$ ). Integraaliosa ARIMA-mallissa liittyy differenssiin ja parametriin  $d$ : ellei differenssiä ole, niin aikasarjoja voidaan mallintaa ARMA ( $p, q$ ) -menetelmin [90]. ARMA:sta poiketen ARIMA-mallilla tuodaan Kumarin et. al. [51] mukaan stationaarisuutta epästationaarisiiin datajoukkoihin, kun differentoimalla datasta tehdään stationaarista.

Kavasseri ja Seetharaman [48] käyvät tutkimuksensa läpi Box-Jenkins-tyylisen lähestymistavan kautta. Ensin he formuloivat f-ARIMA mallin, seuraavaksi estimoivat parametrit ja viimeiseksi validoivat tulokset. He käyttivät ennusteensa lähtötietona aikasarjaa tuulten nopeuksien tunneittain mitatuilla keskiarvoilla. Keskiarvot olivat muodostettu kahden sekunnin välein saadusta datasta, josta oli muodostettu 10 minuutin keskiarvot. 10 minuutin keskiarvoista oli vastaavasti edelleen muodostettu tuntikeskiarvot.

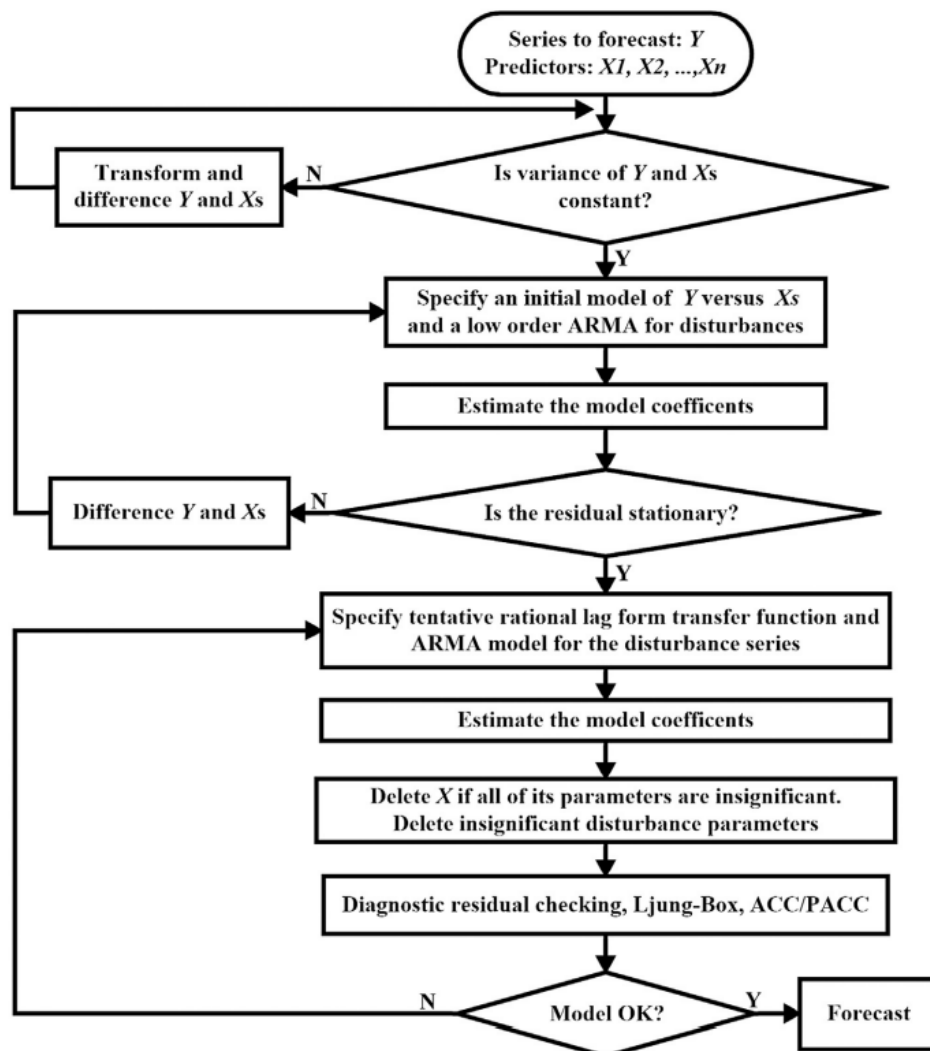
Parametrien estimoinnissa on käytetty suurimman todennäköisyyden estimaattia (engl. Exact Maximum Likelihood). EML-metodia käytetään tyypillisesti tutkimuksissa, joissa datamäärä on pieni tai keskikokoinen.

Optimaalisen f-ARIMA ( $p, q, d$ ) -mallin Kavasseri ja Seetharaman [48] valitsivat seuraavin menetelmin. He loivat joukon f-ARIMA-malleja antamalla  $p$ :n ja  $q$ :n kertaluvun vaihdella välillä [0 - 5], joten lopputuloksena oli 36 erilaista f-ARIMA-mallia. Paras malli valittiin Akaiken informaatiokriteerillä (AIC), joka on menetelmä, jolla voidaan valita

optimaalisin malli tarkasteltavien mallien joukosta. Artikkelin lopuksi malli on validoitu toimivaksi ja tulokset on esitelty. F-ARIMA-mallin todettiin toimivan paremmin ja antavan tarkemman tuloksen kuin perinteisen ARIMA-mallin tai jatkuvan ennusteen, joka ei käytä alkutietonaan muuta kuin edellisen tunnin keskiarvoa.

ARIMA-mallien toimivuutta aurinkovoiman ennustamisessa on kyseenalaistettu Lin et al. [55] mukaan, sillä ARIMA-mallit eivät vaadi meteorologista dataa auringonsäteilyn irradianssin ennustamiseen. Parempia tuloksia on arveltu saavutettavan menetelmillä, jotka huomioivat meteorologisen datan ennustusparametreissa.

**ARMAX-mallit** sisältävät ulkoisten muuttujien vaikutuksia ennusteprosessiin. ARMAX-mallin muodostaminen lineaarisella siirtofunktio menetelmällä on esitetty kaaviona kuvassa 14:



**Kuva 14.** Lineaarinen siirtofunktio malli [55].

ARMAX-mallin muodostaminen on ARIMA-mallien tavoin iteratiivista. Prosessi koostuu kuvan 13 mukaisesti identifioimisesta, estimoinnista ja diagnostisista testeistä.

Tutkimuksen [55] mukaisen ARMAX-mallin parametrien  $p$  ja  $q$  määrittämiseen tarvittiin noin puolentoista vuoden mittainen jakso esikäsiteltyä aurinkovoimadataa. Tämä data sisälsi sekä tuotetun aurinkovoiman määrän sekä globaalin horisontaalisen irradianssin. Tästä datasta kerättiin minuutin aikaresoluutiolla keskimääräinen tuotettu aurinkovoima, josta luotiin tuotetun määrän päivittäiset keskiarvot. Artikkelin mukaan globaalia horisontaalista irradianssia on kuitenkin vaikea ennustaa, joten ennusteen teossa on otettu huomioon seuraavan päivän sääennusteesta seuraavia muuttujia: keskimääräinen vuorokauden lämpötila, kastepiste, vuorokauden korkein ja matalin lämpötila, tuulen nopeus ja suunta, sademäärä, auringonpaisteen kesto, kosteus ja ilmanpaine. [55]

Aikasarjamalleja voidaan mallintaa myös kausittaisuuden mukaan, jolloin ARIMA-mallista voidaan käyttää nimitystä **kausittainen ARIMA** (engl. Seasonal ARIMA tai SARIMA). Kausittaisuus kuvaa aikasarjamallin toistuvuutta jonkin aikayksikön välein. Jos jokin ilmiö tapahtuu vastaavalla tavalla ja on ennakoitavissa esimerkiksi kuukauden välein, voidaan puhua kausittaisuudesta. Tällöin on kannattavaa käyttää kausittaiseen ARIMAAn pohjautuvaa menetelmää.

Kausittaista ARIMA:a merkitään  $S - ARIMA(p, d, q)(P, D, Q)_m$ . Se on siis kahden polynomin tulo, joka muodostuu ei-kausittaisesta osasta  $ARIMA(p, d, q)$  ja kausittaisesta osasta  $ARIMA(P, D, Q)_m$  [83]. Taulukossa 3 on esitetty  $S - ARIMA$ -mallin parametrit.

Taulukko 3.  $S - ARIMA$ -mallin parametrit.

$p$	Mallin autoregressio-osan kertaluku
$d$	Differentoimisjakson pituus
$q$	Mallin liikkuvan keskiarvon kertaluku
$P$	Mallin kausittaisen autoregressiokomponentin kertaluku
$D$	Kausittaisuustekijä
$Q$	Mallin kausittaisen liikkuvan keskiarvon kertaluku
$m$	Jaksojen lukumäärä per sykli/kausi.


Ei-kausittaiset ARIMA-mallit eivät aina toimi odotetulla tavalla. Yusufin et. al konferenssijulkaisussa [93] ARIMA-mallin tuottamat ennusteet vesilaitoksen kulutuksen

ennustamisessa tuottivat heikot ennusteet. Vaikka data oli stationaarista niin heidän optimoimansa ARIMA-malli ei pysty seuraamaan todellista kulutusta.

#### 4.1.4 Mallipohjaiset menetelmät


Takedan et. al. tutkimuksessa [82] luotiin **Kalman-suodin**-kokonaisuus (EnKF) sähkönkulutuksen ennustamiseen ja analysointiin. Kokonaisuus on luotu sen takia, että tavallisilla Kalman-suotimilla ei pysty mallintamaan systeemin epälineaarista dynamiikkaa. Kalman-suodin-kokonaisuudessa tavalliseen Kalman-suotimeen on otettu mukaan Monte Carlo -approksimointia, jolloin näytekeskisarvo ja varianssi-kovarianssimatriisi ovat asympotoottisesti samat kuin Kalman-suotimella. EnKF muodostuu lineaarisesta Gaussista kohinaa sisältävästä havaittajamallista sekä lineaarisesta tai epälineaarista systeemimallista, jolla voi olla minkä vain tyyppinen kohinajakauma. EnKF:n on todettu vähentävän laskentatarvetta huomattavasti ja se onkin laajalti käytetty meteorologisten algoritmien datan mukauttamisessa.

Takedan et. al. tutkimuksessa malli luotiin Tokion metropolialueen ja sen ympäristön kulutusdatasta. Dataa oli saatavilla tuntitasolla. Mallin pohjana oli tyypillisen päivän energiantuotant jakauma. Jakauma on esitetty kuvassa 15.



**Kuva 15.** Sähköntuotanto tuotantotyypeittäin tyypillisen vuorokauden aikana (Japanissa ei Takedan et. al. tutkimuksen aikana ollut saatavilla ydinvoimaa) [82].

Paksu musta viiva kuvassa 15 esittää tavoitekuormaa vuorokauden sisällä. Tyypillisenä trendinä havaittiin, että päiväsaikaan kuorma on suurempi kuin yöllä, kuten jo luvussa 2.8.1 on todettu. Kulutusdatan lisäksi malli tarvitsee sää- ja kalenteri-informaatiota. Kalenteri-informaatiolla tarkoitetaan viikonpäivien ylläpitoa ja juhlapyhien huomioimista. [82] Muita mallin vaatimia syötteitä ovat varianssit sekä parametrien rajoitteet (kuva 16).



**Kuva 16.** EnKF:n vaatimat input-arvot (leikattu lähteestä [82]).

Takedan et. al. EnKF:n mallia kuvataan kaavan (5) mukaan:

$$\begin{aligned}
 Y_t = & TREND_t + INWK_t + f(INDAY_t, DAY_t) + AR_t \\
 & + TP_t + RA_t + HM_t + WS_t + PV_t + W_t,
 \end{aligned}
 \tag{5}$$

missä  $t$  on kulunut aika tunteina,  $Y_t$  on kuvassa 15 esitetty tavoitekuorma,  $TREND_t$  on trendikomponentti,  $INWK_t$  on viikonsisäinen jaksoittainen komponentti,  $INDAY_t$  on vuorokaudensisäinen jaksoittainen komponentti,  $DAY_t$  on viikonpäivän vaikutusta kuvaava komponentti,  $AR_t$  on autoregressiivinen komponentti,  $TP_t$  on lämpötilan vaikutus,  $RA_t$  on auringonsäteilyn vaikutus,  $HM_t$  on kosteuden vaikutus,  $WS_t$  on tuulen vaikutus,  $PV_t$  on valosähköinen vaikutus,  $W_t$  on havainto-kohina-komponentti ja  $f(\cdot)$  kuvaa funktiota, joka ottaa huomioon suhteen päivänsisäisten ja vuorokaudesta johtuvien efektien välillä [82].

Takedan et. al. tutkimuksessa tarvitaan lähtötietoina kuvan 16 mukaisesti joitakin raja-arvoja. Näitä raja-arvoja ovat esimerkiksi lämpötilat, missä ilmastointi kytketään lämmittämään huoneilmaa ja missä se kytketään viilentämään huoneilmaa. Myös eri



sääolosuhteista riippuvilla termeillä oli useita eri rajoitteita, joista voi lukea enemmän lähteestä [82].

Kuvan 16 mukaan lähtötietoina tarvitaan myös variansseista. Takedan et. al. tutkimuksessa [82] varianssi  $R$  kuvaa havaintokohinaa, joka esitetään muodossa  $\{W_t\} \sim i. i. d. N(0, R)$ . Järjestyksessään  $n$ :nes systeemikohina kuvataan vastaavasti  $\{v_t^{(n)}\} \sim i. i. d. N(0, R/L_i)$ , missä  $L_i$  on valintaparametrit.

## 4.2 Aikaresoluution muutoksen vaikutukset ennustusmenetelmiin

Ennustettavan aikaresoluution muokkaaminen vaikuttaa moniin ennustemenetelmiin vain siinä näkökulmassa, että niiden algoritmeja täytyy muokata luomaan ennusteita tiheämmällä aikavälillä. Tässä luvussa tarkasteltujen ennustemenetelmien suorituskyky ei kokenut merkittäviä muutoksia niissä tutkimuksissa, joissa ennustemenetelmiä sovellettiin eri aikavälien tarkasteluun. Jotkin menetelmät saattavat kärsiä merkittävästi laskennan hidastumisesta, kun ennusteen lähtötietovektorit ja -matriisit kasvavat lisääntyvän datamäärän seurauksena.

Lisäksi ennusteiden tekemiseen tarvittavien muuttujien saavutettavuudessa voi esiintyä ongelmia, jos datan toimittajat eivät esimerkiksi tuota meteorologisia suureita niin tiheällä aikavälillä. Tällöin taho, jolle ennusteita tuntitasolla toimitetaan, saattaa joutua käsittelemään saatua dataa siten, että tuntidatasta voidaan luoda 15 minuutin ennusteita. 15 minuutin taseen käyttöönoton myötä on kuitenkin oletettavaa, että ennusteita laativat osapuolet siirtyvät myös tiheämpään aikaresoluutioon, jolloin ennusteisiin tarvittavan datan kerääminenkin ei ole ongelmallista.

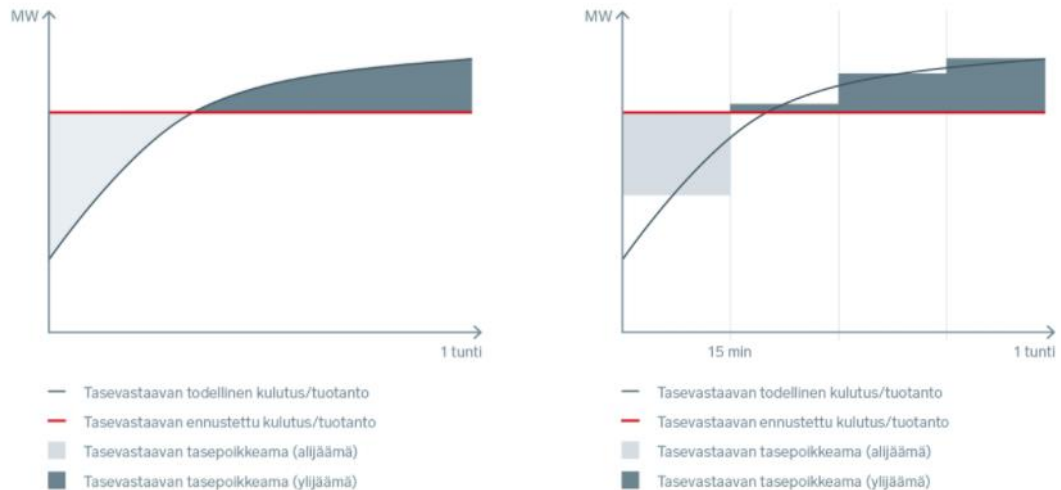
Neurosumeista metodeista neuroverkkoihin pohjautuvat metodit eivät käytä parametreinaan mitään aikariippuvuuteen yhteydessä olevia suureita, joten niiden tulisi soveltua hyvin myös 15 minuutin mittaussykliin. Aikasarjamallit puolestaan hyödyntävät historiadataa ennustamisessa, jolloin historiadataa täytyy olla saatavilla vähintään ennusteaikavälin mittaisin välein eli tämän opinnäytetyön tapauksessa 15 minuutin välein. Geneettisten menetelmien kohdalla voidaan tarvita muutoksia ennusteen rakenteeseen. Esimerkiksi Cepericin et. al. [8] tutkimuksessa luotavien mallien määrä täytyisi nelinkertaistaa, kun jokaiselle varttitunnille pitäisi luoda omat mallinsa.

## 5. VARTTITASE

Energiajärjestelmät ovat kokemassa muutoksen 2020-luvun alkupuolella. Entisen tunnin aikaresoluutiolla tapahtuvan tasehallinnan on korvaamassa Euroopan Unionin (EU) tasehallinnan ohjeistuksen (komission säännös 2017/2195 [9]) mukainen 15 minuutin taseselvitysjakso. Tämän säännöksen mukaan jokainen EU:n jäsenmaa on veloitettu siirtymään 15 minuutin taseselvitysjaksoon vuoden 2020 loppuun mennessä. Fingrid ja muut pohjoismaiset kantaverkkoyhtiöt ovat joutuneet hakemaan viivästystä käyttönotolle, ja pohjoismaissa onkin tavoitteena ottaa 15 minuutin taseselvitysjakso käyttöön vuoden 2023 puolenvälin aikoihin. Tämän opinnäytetyön tekemisen aikana energiavirasto teki päätöksen 15 minuutin taseen käyttöönotosta 22.5.2023 klo. 01.00 Suomen aikaa. 15 minuutin sisäiseen kaupankäyntiin siirrytään tuolloin säätösähkö- ja päivänsisäisten markkinoiden osalta. Vuorokausimarkkinoilla varttikaupankäyntiin siirrytään Fingridin mukaan vuoteen 2025 mennessä. 15 minuutin taseella pyritään yhdenmukaistamaan Euroopan alueella tapahtuvia säätösähkömarkkinoita, sillä osassa Eurooppaa kauppaa käydään jo lyhyemmillä kuin tuntikohtaisilla tuotteilla. [28]

### 5.1 Miksi tarpeellinen?

Miksi tämä siirtymä nähdään tarpeelliseksi? 15 minuutin taseselvitysjaksoon siirtyminen mahdollistaa tasepoikkeamista (katso kuva 17) aiheutuvien kustannusten tarkemman, aiheuttamisperustaisen jakamisen markkinatoimijoiden kesken. Lisäksi se lisää energiajärjestelmän markkinapohjaista tasapainotusta. [28]



**Kuva 17. Tasepoikkeamat tunti- ja varttiresoluutioissa [28].**

Kuvasta 17 nähdään, että tuntitasolla ei ole mahdollista määrittää seuraavan 15 minuutin aikajakson yli- tai alijäämää niin tarkasti, kuin se on mahdollista 15 minuutin aikaresoluutiolla. Esimerkiksi kuvan 17 tapauksessa vasemmanpuoleisessa kuvaajassa tunnin sisäiset poikkeamat nettoutuvat ja kumoavat toisensa, jolloin tunninsisäisen tuotannon kustannuksia on hankala kohdentaa tarkasti.

15 minuutin tase ohjaa markkinatoimijoita tukemaan sähköjärjestelmää ja avustamaan kantaverkkoyhtiötä sähköjärjestelmän tasapainotuksessa [60][78]. Sen on määrä kannustaa markkinatoimijoita pitämään sähköverkon taajuus nimellisarvossaan. 15 minuutin taseen käyttöönotossa vastuu tasehallinnasta siirtyy enimmäkseen sähköntuottajalle, jolloin ennusteiden tarkkuus korostuu, kun ennustevirheistä aiheutuu enemmän kustannuksia. Ennustevirheet koskevat erityisesti vaihtelevaa uusiutuvaa tuotantoa, jonka osan kokonaistuotannosta on määrä kasvaa merkittävästi tulevien vuosien aikana. Esimerkiksi Saksassa 15 minuutin tasejaksoon siirryttiin sen takia, että tuotanto voi reagoida nopeammin tuulivoiman ennustevirheisiin, kun tuotannon rampittaminen nopeammin tasepoikkeamien takia on mahdollista [91].

15 minuutin taseeseen siirryttäessä siirrytään kohti reaaliaikamarkkinoita. Tällöin markkinoilla toimivien tahojen toiminta edellyttää uusia lähestymistapoja, ja oman yrityksen teknologian automatisointia uuteen aikaikkunaan, kun kaupankäynti tuntitasolla ei enää ole mahdollista. [60]

## 5.2 Vaikutukset kantaverkkoon

Solovian väittää diplomityössään [78], että 15 minuutin taseselvitysjaksoon siirtymisellä pohjoismaissa on oletettavasti samoja hyötyjä kuin mitä Saksassa on havaittu

saavutettavan. Kantaverkon systemaattiset tunneittaiset tasepoikkeamat vähenevät, tasehyppyt vähenevät sekä kantaverkon tasapainottaminen siirtyy kantaverkonhaltijoilta asiakaskunnan vastuulle. Solovian kuitenkin huomauttaa, että Saksan sähköverkko poikkeaa pohjoismaisesta sähköverkosta siinä, että pohjoismainen sähköverkko on jaettu 11 eri alueeseen, jotka ovat yhdistetty toisiinsa ns. ”interconnectoreilla”. Lisäksi pohjoismaat ovat yhteydessä vielä useisiin muihin valtioihin, jonne sähköä toimitetaan tai sitä vastaanotetaan. Tämä vaikeuttaa ja monimutkaistaa osaltaan 15 minuutin taseselvitysjakson käyttöönottoa pohjoismaissa.

Taseselvitysjakson lyhentyessä tunnista varttituntiin muuttuu kantaverkkoon kohdistuvat rajoitteet. Pohjoismaiset kantaverkkoyhtiöt mainitsevat raportissaan [70] taajuuden laaduntakaamisen yhtenä suurena ongelmana, kun taseselvitysjakso lyhentyy. Taseselvitysjakson lyhentyminen tulee aiheuttamaan suurempia tunneittaisia tasepoikkeamia ja ennustevirheitä ja reservien kasvavaa tarvetta samalla kun niiden käyttö tulee rajoitetummaksi. Lisäksi reserveille täytyy varmistaa tarkoituksenmukainen siirtokapasiteetti.

### **5.3 Vaikutukset ennustamiseen**

15 minuutin taseen suorista vaikutuksista ennustamiseen ja ennustusmenetelmiin ei ole vielä tehty paljon tutkimusta. Tämä johtuu siitä, että 15 minuutin taseselvitysjakso on vasta hyvin aikaisessa käyttövaiheessa ympäri Eurooppaa.

Heikuran diplomityössä [33] on tehty päätelmä, että ennustejärjestelmien täytyy mukautua siten, että metodeilla voidaan luoda uusia ennusteita vähintään 15 minuutin välein. Heikuran [33] ja Gylénin [31] diplomitöiden mukaan ohjelmistot ja tietojärjestelmät, kuten Datahub [16] tulevat vaatimaan muutoksia, kun käsiteltävän datan määrä nelinkertaistuu 15 minuutin taseen käyttöönoton myötä.

15 minuutin tase tulee vaikuttamaan erityisesti vaihtelevan tuotannon ennusteisiin. Esimerkiksi tuulivoiman ennustaminen tarkasti on hyvin hankalaa, jolloin tasapainottamisesta aiheutuvat kustannukset voivat moninkertaistua ennustusvirheiden vaikutuksesta [43]. Ennustusvirheet puolestaan aiheutuvat siitä, kun tiheämmällä aikaikkunalla täsmällisen ennusteen tekeminen tuulen nopeuden muutoksista tuulivoiman osalta ja auringon säteilyn määrästä aurinkovoiman osalta vaikeutuu. Myös laskentatarve ennustamisessa tulee lisääntymään, kun aikaväli ennustamisessa lyhenee, joten laskentatehoa tarvitaan lisää [82].

## 5.4 Vaikutukset tuotantojakaumiin


Abdulkarimin et. al. tutkimuksessa [1] esitettiin tuulen nopeuden ja auringonsäteilyn analysoinnissa käytettyjä tilastollisia jakaumia, jotka voidaan sovittaa vastaamaan dataprofiileja. Tuulen nopeutta analysoitiin käyttäen Weibullin jakaumaa, gamma-jakaumaa ja Rayleighin jakaumaa. Ennusteiden hyvyttä verrattiin arvioimalla virhettä todellisen ja ennustettujen tehojen välillä. Parhaimmaksi sovituksiksi osoittautui Weibullin jakauma ennen gamma- ja Rayleighin jakaumaa.

Aurinkovoimaa oli analysoitu tutkimalla keskimääräistä auringonsäteilyä Belfastissa ja Abujassa. Datahistogrammiin sovitettiin Weibullin jakauma, gamma- ja beta-jakaumat, logistinen jakauma sekä log-normaalijakauma. Tutkimuksen yhteenvedon mukaan parhaan sovituksen antoi beta-jakauma ennen gamma-jakaumaa, logistista jakaumaa, log-normaalijakaumaa ja Weibullin jakaumaa kyseisessä järjestyksessä. [1]

Myös Suomen tuuliatlaksen verkkosivuilla sanotaan [80], että tuulienergiasovelluksissa tuulen nopeuden jakaumaa mallinnetaan usein Weibullin jakaumalla. Kaksiparametrinen Weibull-jakauman tiheysfunktio voidaan esittää muodossa:

$$F(u; A, k) = \frac{k}{A} \left(\frac{u}{A}\right)^{k-1} e^{-\left(\frac{u}{A}\right)^k} \quad (7)$$

Kaavassa (7) symboli  $u$  kuvaa tuulen nopeutta,  $A$  skaalausparametria ja  $k$  muotoparametria.  $A$  ja  $k$  muuttuvat, kun WAsP-mallissa muutetaan korkeutta tai maaston muotoja. WAsP-malli kuvaa rajatun alueen tuuli-ilmastoa, tuulisuusjakaumaa, tuulienergiapotentiaalia ja tuulivoimaloiden tuottamaa energiaa [79].



**Kuva 18.** Weibull-jakauman muotoja joillain  $k$ :n arvoilla. [80]

Kuvassa 18 on esitetty Weibull-jakauma useilla eri muotoparametrin  $k$  arvoilla. Mitä suurempi  $k$  on, sen korkeamman piikin Weibull-jakauman havaitaan muodostavan.

Aurinkovoimaa tutkittaessa parhaimman sovituksen antoi tutkimuksessa [1] beta-jakauma. Beta-jakauman  $Beta(\alpha, \beta)$  tiheysfunktio voidaan kirjoittaa kaavan (8) mukaisesti:

$$f(x) = \frac{1}{B(\alpha, \beta)} x^{\alpha-1} (1-x)^{\beta-1} \quad (8)$$

missä beta-jakauman parametreille pätee  $\alpha > 0, \beta > 0$ . Lisäksi  $0 \leq x \leq 1$ . [58]

### 5.4.1 Aurinkodata

Tätä diplomityötä varten saatiin dataa Tampereen Yliopiston Hervannan kampuksen Aurinkovoimalasta. Aurinkovoimala on sijoitettu kampusareenan kolmelle seinälle. Aurinkopaneelit on sijoitettu rakennuksen ikkunoiden alle. Kampusareenan seinille on asennettu aurinkopaneeleja kolmeen suuntaan. Länteen osoittavien paneelien nimellisteho on 8 kW, kaakkoon 2 x 17 kW ja lounaaseen 15 kW [35]. Koko Kampusareenan nimellisteho on siis 57 kW. Kampusareena on kuvassa 19.



**Kuva 19.** Tampereen yliopiston Hervannan kampuksen rakennus Kampusareena (korkea rakennus taustalla) [89].


Dataa saatiin mm. voimalan inverttereiden pätötehoista, aurinkovoimalan kokonaispätötehosta sekä säähän liittyvistä suureista, kuten säteilytehosta ja ilmentötehosta. Aurinkodataa on käsitelty Matlabilla. Tehodataa oli saatavilla kahden vuoden ajalta vuosilta 2019-2020 sekunnin aikaresoluutiolla.

Sähkönmyyjien kannalta tärkein aikaväli ja markkinat ovat seuraavan vuorokauden Elspot-markkinat. Tästä syystä tuloksia laskettiin vuorokauden mittaisella aikajaksolla. Sähkönmyyjien kannalta on tärkeää tietää tulevaisuudessa, kuinka paljon varttiennusteet tulevat vaikuttamaan sähkönmyyjien ennusteiden ennustevirheeseen verrattuna tuntitasolla tehtyihin ennusteisiin ja suunniteltava sen pohjalta uudet strategiat, paljonko sähköä tehtyjen ennusteiden pohjalta uskalletaan luvata myytäväksi.

Tässä työssä aurinkovoiman tuotantoa tutkittiin päivittäisen toteutuneen tuotannon ja varttitunnin sekä tunnin keskiarvotuotannon välistä poikkeamaa ideaalituotantoon nähden (yksikössä %). Lisäksi datan luotettavuuden mitaksi määritettiin vartti- ja tuntikeskihajonnat. Ideaalituotantoa varten määritettiin verhoikäyrä, joka muodostettiin mittausdatasta valitsemalla selvästi aurinkoisesta tai voimakkaasti puolipilvisen päivän tuotantodataa, josta maksimiarvojen mukaan luotiin ns. ideaalipäivän tuotantokäyrä. Verhoikäyrää voitiin käyttää päiville, jotka ovat hyvin lähellä päivää, johon verhoikäyrää verrataan. Tällaisissa olosuhteissa auringon käyttäytymisen voitiin olettaa pysyvän samanlaisena riippumatta aurinkovoimalan ympäristön aiheuttamista varjostumista. Ennustamisessa verhoikäyrän hyödyntäminen ei ole käytännöllistä, sillä verhoikäyrällä ei

ole mahdollista yksiselitteisesti määrittää, onko päivä ollut täysin selkeä vai puolipilvinen. Sen takia ennusteisiin on usein kytketty säätietoon pohjautuvaa tilastodataa.

Esimerkkidatana on tuotantodata aikakeskiarvoineen ja verhokäyrineen 6.4.2019.




**Kuva 20.** Aurinkovoiman pätöteho 6.4.2019.

Kuvan 20 mittausdatasta (sininen käyrä) voidaan päätellä koko päivän olleen hyvin aurinkoinen, sillä suuria vaihteluita ei lyhyellä aikavälillä datassa esiinny. Varttikeskisarvon (punainen käyrä) huomataan seuraavan dataa ja sen muutoksia paremmin, kuin tuntikeskiarvon (vihreä käyrä). Verhokäyrä eli ideaalituotanto (vaaleanpunainen) asettuu lähes kaikkien mittausarvojen yläpuolelle.


Kuvan 20 tuotantokeskiarvojen ja ideaalituotannon väliset poikkeamat on esitetty kuvassa 21. Datassa on huomioitu vain klo 9-17 välinen ajanjakso, jotta voidaan olettaa, että aurinko paistaa sen verran korkealta, että tuotantoon eivät vaikuta muut kuin ilmakehälliset tekijät eivätkä esimerkiksi voimalaa ympäröivät rakennukset ja niiden varjot. Lisäksi tämän ajanjakson ulkopuolella tuotettu energia on määrältään sen verran pieni, ettei se vaikuta jakaumiin merkittävästi. Lopputuloksena suhteellisia poikkeamia on varttikeskisarvon tapauksessa 32 kappaletta ja tuntikeskiarvon tapauksessa 8 kappaletta.





**Kuva 21. Tuotantokeskiarvojen ja ideaalituotannon suhteelliset poikkeamat 6.4.2019.**


Kuvasta 21 nähdään, että vartti- ja tuntikieskiarvojen poikkeamat ideaalituotannosta käyttäytyvät selkeänä päivänä samalla tavalla. Poikkeamat pysyvät tässä tapauksessa pieninä, sillä kyseessä on selkeä päivä ja tuotanto on lähellä ideaalituotantotasoa.



**Kuva 22. Tunti- ja varttikieskihajonnat 6.4.2019.**

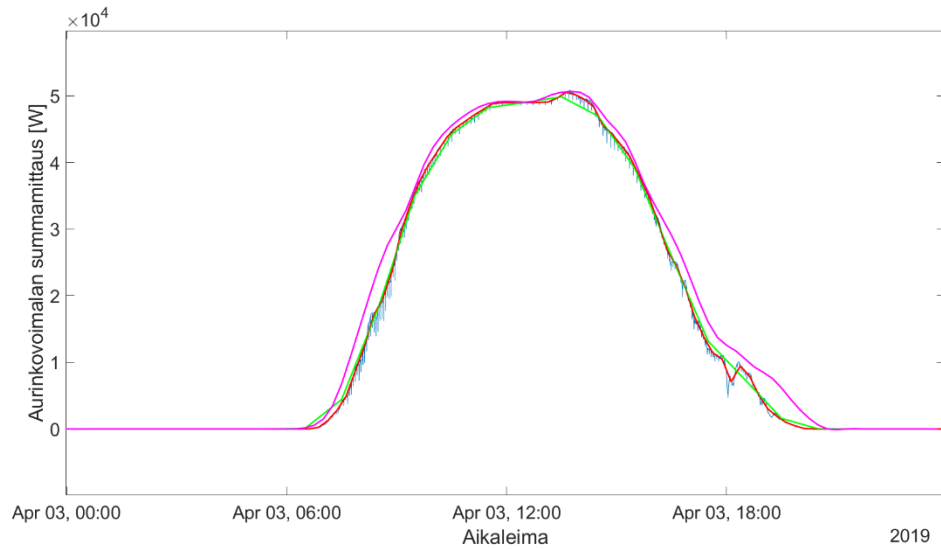
Kuva 22 näyttää, että keskiarvotusjaksolle lasketut varttikieskihajonnat keskittyvät tarkemmin pienelle hajonta-alueelle kuin tuntikieskihajonnat. Tämä johtuu siitä, että selkeänä päivänä varttitunnin sisällä tuotanto ei ennäätä aamupäivän ja alkuillan aikana nousta tai laskea yhtä paljon kuin tunnin aikana, jolloin suuret keskihajonnat muodostuvat pidemmällä aikavälillä.

Työn tutkimuskysymyksen varttitason ja tuntitason välisien eroavaisuuksien kannalta mielenkiintoista kuvan 20 kuvaajassa on todellisen tuotannon piikkien aikaiset hetket. Kello 09:00 jälkeen ilmenevä tuotannon lasku aiheuttaa poikkeaman vartti- ja tuntikeskiarvon välillä.



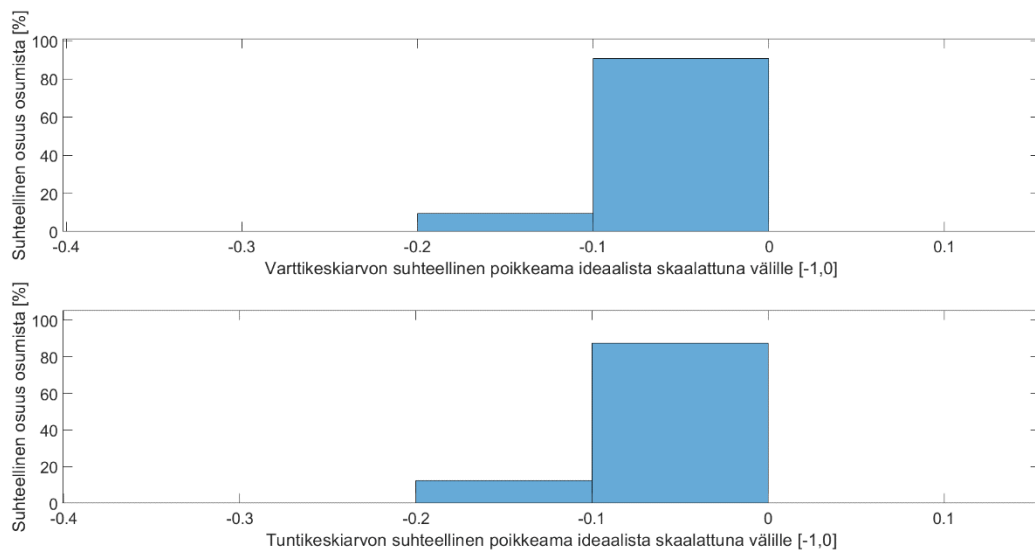
**Kuva 23.** Vaihtelua varttikeskisarvossa.

Kuvan 23 kaltaisten tapahtumien analysointi on relevanttia tämän tutkimuksen tasekysymyksen kannalta. Tarkastellaan siis kyseisen hetken aikaista keskihajonnan käyttäytymistä. Tuntitasolla 09:00-10:00 välisen ajanhetken keskihajonta oli 3819 W, mikä tarkoittaa hieman alle 10 %:n suuruista osuutta sen hetkisestä ideaalituotannosta. Varttitasolla keskihajonta oli vartin välein ilmoitettuna 1582 W, 928 W, 2674 W ja 2872 W eli noin 2,5-7,5 %:n suuruista osuutta. Tuntitason korkea keskihajonta selittyy aamulla tapahtuvasta tehon kasvusta ja pidemmästä aikaikkunasta. Varttitasolla vaihtelut ovat kuitenkin huomattavia ja se taas selittyy todellisen tuotannon vaihtelulla. Seurauksena käyrien välille syntyy noin 2 kW:n poikkeama. Kuten kuvasta 22 nähdään, tuntikesiarvo ei huomioi lyhyttä notkahdusta tuotannossa samalla tavoin kuin varttikeskisarvo, vaan huomioi notkahduksen vasta koko tunnin mittaisella ajanjaksolla. Vastaavanlaista vaihtelua on nähtävissä myös kuvassa 24 3.4.2019 klo 18.

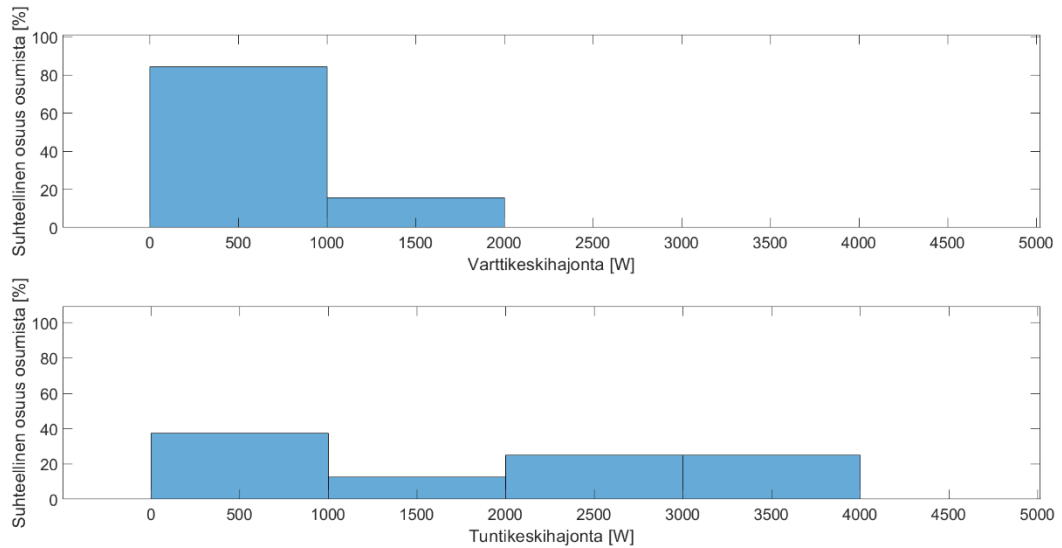


**Kuva 24.** Aurinkovoiman pätöteho 3.4.2019.

Kuvassa 24 on toinen selkeä päivä 3. huhtikuuta, jolle on käytetty vertailukohtana 6.4.2019 tehtyä verhoikäyrää. Kuvissa 25 ja 26 ovat vastaavat pylväsdiagrammit suhteelliselle poikkeamalle ja keskihajonnalle kuin vertailupäivälle.

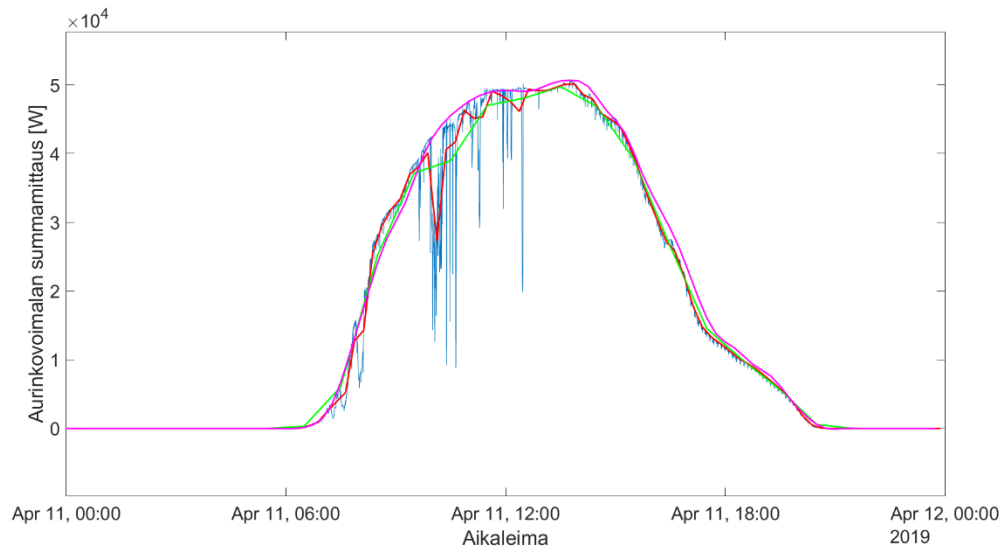


**Kuva 25.** Tuotantokeskiarvojen ja ideaalituotannon suhteelliset poikkeamat 3.4.2019.




**Kuva 26. Tunti- ja vartikeskihajonnat 3.4.2019.**

Kuvista 25 ja 26 nähdään, että poikkeamat ideaalituotannosta eivät ole merkittäviä, kun tarkastelussa on vastaavanlainen päivä kuin vertailupäivänä käytetty päivä. Kuvassa 27 on esitetty 11.4.2019 tuotantodataa.



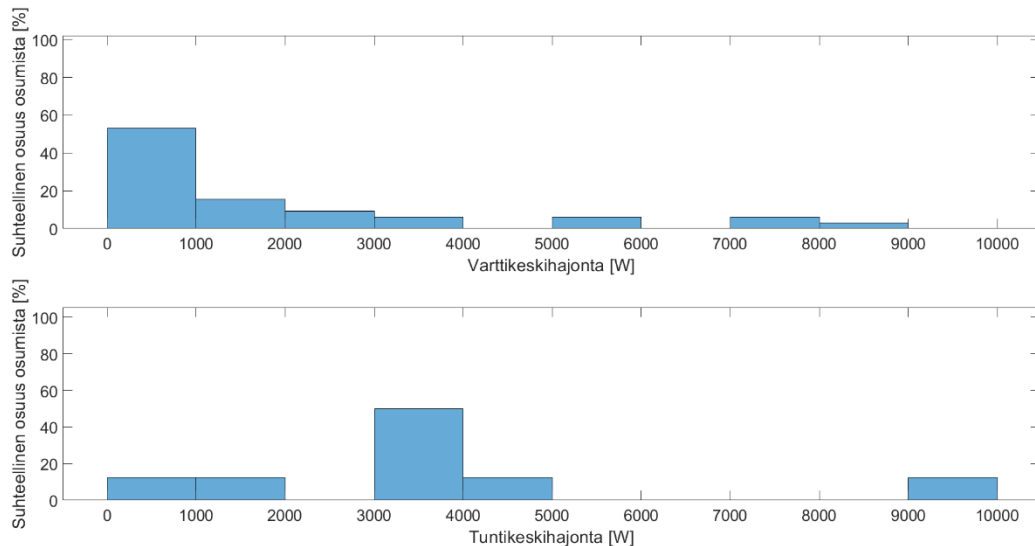
**Kuva 27. Aurinkovoiman pätöteho 11.4.2019.**

11.4.2019 on ollut selvästi puolipilvisempi aamupäivän osalta, joka voidaan nähdä klo 6-14 välillä esiintyvistä piikeistä. Suurimmillaan tuotannon vaihtelut ovat noin klo 10 aikaan, jolloin tunti- ja vartikeskiarvojen välillä on jopa 11 kW:n poikkeama, joka on noin 25 % sen hetkisestä ideaalituotannosta.



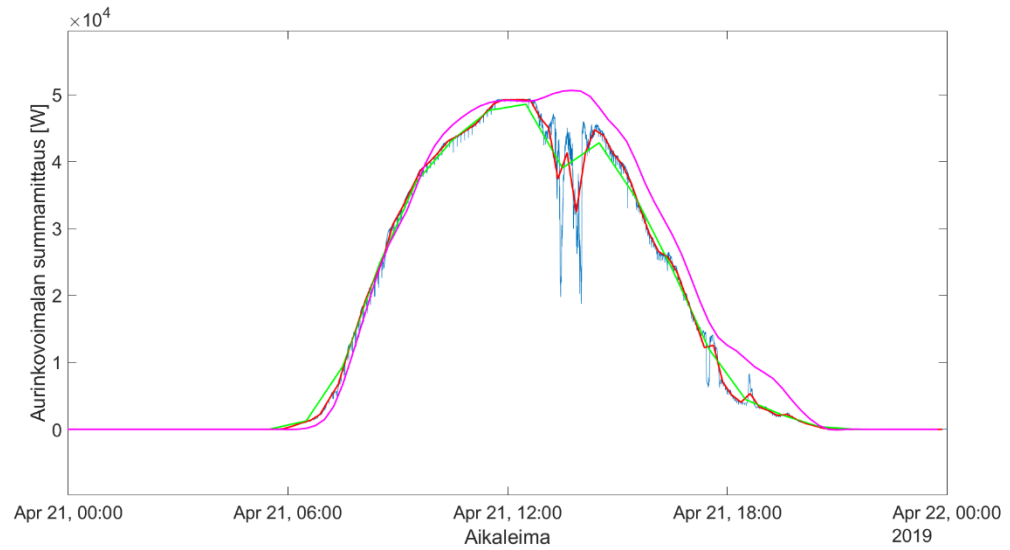
**Kuva 28.** Tuotantokeskiarvojen ja ideaalituotannon suhteelliset poikkeamat 11.4.2019.

Lievästi puolipilvisenä päivänä 11.4. suhteellisista poikkeamista kuvassa 28 voidaan havaita, että varttikeskiarvot ylittävät osittain referenssikäyränä käytettävän ideaalituotannon aamupäivän aikana. Lisäksi varttitasolla poikkeamat ylittävät 20 %:n rajan kahden varttitunnin aikana. Tämä kertoo nopeista vaihteluista säteilyn intensiteetissä, joiden ennustaminen on vaikeaa.

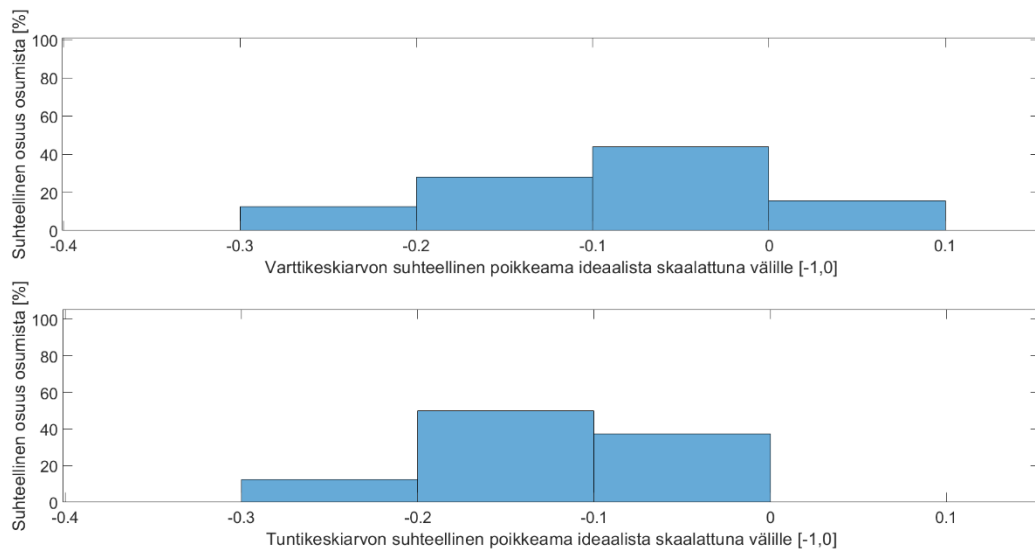


**Kuva 29.** Tunti- ja varttikeskihajonnat 11.4.2019.

Merkittävin ero kuvassa 29 selkeän päivän keskihajontakuvaajiin on se, että keskihajonnat ovat jakautuneet selvästi laajemmalle alueelle jopa 10 kW:in asti. Pääosa hajonnoista klo 9-17 on kuitenkin painottunut alle 5000 W:n alueelle, josta on pääteltävissä, että päivän aikainen pilvisuus ole ollut pitkäkestoista.




**Kuva 30. Aurinkovoiman pätöteho 21.4.2019.**



**Kuva 31. Tuotantokeskiarvojen ja ideaalituotannon suhteelliset poikkeamat 21.4.2019.**

Huhtikuun 21. päivänä on havaittavissa, että prosentuaalinen poikkeama ideaalituotannosta on ollut sekä tunti- että vartittasolla suurempaa kuin kuvassa 28 esitetystä huhtikuun 11. päivän datassa. Kuvasta 30 nähdään, että tuotanto jää iltapäivällä ideaalituotannon alapuolelle merkittävästi pilvisyyden takia. Runsaampi pilvisuus kuin huhtikuun 11. päivänä aiheuttaa 20-30 %:n poikkeamia sekä tunti- että varttikeskiarvoille.

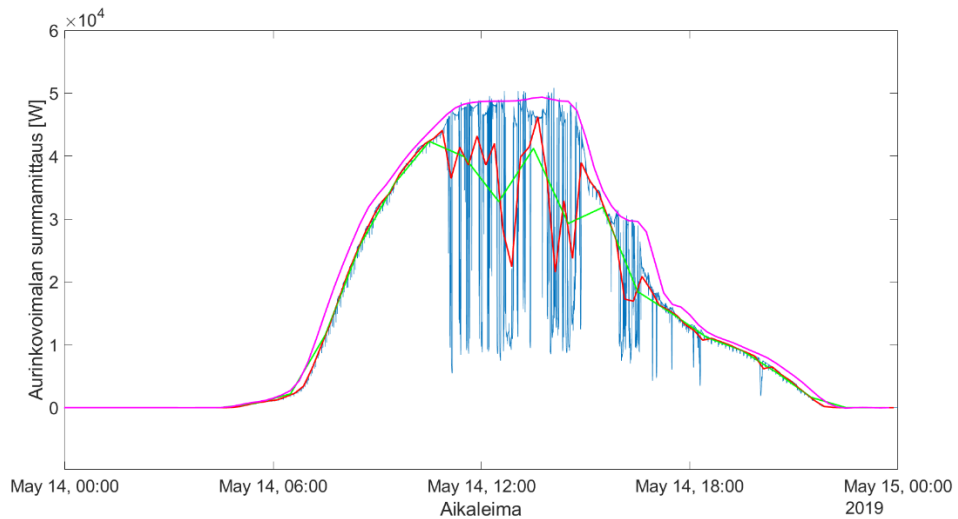


**Kuva 32. Tunti- ja varttikeshajonnat 21.4.2019.**

21. huhtikuuta (kuva 32) on kuitenkin keskihajontakuvien varttikeshajontojen perusteella hyvin samanlainen kuin huhtikuun 11. päivä, sillä varttikeshajonnat painottuvat alle 2000 W:n lukuun ottamatta yksittäisiä tapauksia, jotka ovat aiheutuneet lyhytaikaisista piikeistä iltapäivällä. Tuntikeshajontakuvissa kuvan 32 mukainen jakauman muoto poikkeaa kuvassa 29 olevan tuntikeshajontajakauman muodon kanssa. Tällä on vaikutusta ennustusmenetelmiin, jotka käyttävät jakauman tilastollisia ominaisuuksia ennusteen lähtötietona. Kuvasta 30 on nähtävissä varttikeshajonnan ja tuntikeshajonnan suuriakin poikkeamia (lähes 10 kW) iltapäivällä, kun aurinkovoiman tuotanto laskee selvästi lyhyen ajanjakson aikana.


Saman verhoikäyrän käyttö jokaisen kesäkuukauden kohdalla ei ole perusteltua johtuen siitä, että aurinko ei nouse ja laske Suomessa samanaikaisesti joka kuukauden aikana. Kuvaan 33 on luotu uusi verhoikäyrä toukokuun 14. päivästä 2019.





**Kuva 33. Aurinkovoiman pätöteho 14.5.2019**


Kuvassa 34 on kuvan 33 päivästä piirrettyjen tuotantokeskiarvojen ja ideaalituotannon väliset suhteelliset poikkeamat.



**Kuva 34. Suhteelliset poikkeamat ideaalituotannosta 14.5.2019.**

Kuvassa 34 esitetyt poikkeamat paljastavat selvästi, että molemmat päivät ovat olleet puolipilvisiä. Varttipoikkeamat ideaalituotantoon verrattuna ovat 14.5. suurimmillaan 40-50 %:n välillä ja tuntipoikkeamatkin suurimmillaan 30-40 %:n välillä.


Selkeisiin päiviin verrattuna prosentuaaliset poikkeamat ovat kasvaneet paljon, mikä viittaa siihen, että myös ennustaminen tällaisena päivänä tulee olemaan vaikeampaa ja ennusteet epäluotettavampia. Varttikeskiarvojen poikkeamat tuntikeskiarvoista voivat vaihdella paljon, Kampusareenan tuotannon tapauksessa jopa 15 kW eli noin 30 % maksimituotannosta.



**Kuva 35. Tunti- ja varttikeshajonnat 14.5.2019.**


14. toukokuuta keskihajonnat ovat jakautuneet kuvassa 35 0-18 kW:in välille. Varttikeshajonnat ovat tarkasteltavana olevan puolipilvisen päivän aikana painottuneet joko hyvin pieniksi tai yli 10 kW:n suuruiseksi ja tällä välillä niitä esiintyy vain yksittäisinä tapauksina. Tuntikeshajonnat jakautuvat hajonta-alueen koko leveydelle tasaisesti.

14. huhtikuuta kaltaisen päivän tarkka ennustaminen on hyvin vaikeaa, kun tuotanto vaihtelee lyhyellä ajanjaksolla 10 kW:n ja 50 kW:n välillä. Erityisesti varttitason tuotannon ennustaminen on vaikeaa, sillä joidenkin varttien aikana tuotanto voi olla lähellä ideaalia, kun joidenkin varttien kohdalla se on vain 10 kW:n tasolla.




**Kuva 36.** Aurinkovoiman pätöteho 9.5.2019.

Toukokuun 9. päivää kuvaavassa käyrässä kuvassa 36 on selkeä ja aurinkoinen päivä, jolloin tuotanto jää kuitenkin verhokäyrän alapuolelle. Tämän oletetaan johtuvan siitä, että aurinkopaneelien hyötysuhde laskee, kun ne lämpenevät. Tästä syystä tuotanto ei nouse ideaalituotannon tasolle, vaikka pilviä ei kuvan 36 mukaan olisikaan peittämässä auringonsäteilyä. Siksi myös kuvan 37 prosentuaaliset poikkeamat ovat suurempia, koska verhokäyrä on luotu puolipilvisestä päivästä, jolloin maksimiarvot ovat korkeita. Jos verhokäyrä olisi luotu päivästä, jolloin on ollut selkeää, olisi kuvan 37 poikkeamat todennäköisesti pienempiä. Kuvassa 38 olevat keskihajonnat kuvaavat kuitenkin hyvin selkeän päivän käyttäytymistä.




**Kuva 37.** Tuotantokeskiarvojen- ja ideaalituotannon väliset suhteelliset poikkeamat 9.5.2019.




**Kuva 38. Tunti- ja varttikeshajonnat 9.5.2019.**

Kuvan 38 suuret varttikeshajonnat aiheutuvat noin klo 14 aikaisesta tuotannon vaihtelusta.




**Kuva 39. Aurinkovoiman pätöteho 29.8.2019.**

Kuvassa 39 on piirretty elokuun 29. päivän tuotantokäyrä ja sille oma verhoikäyrä. Suhteelliset poikkeamat tuotantokeskiarvojen ja ideaalituotannon välille on esitetty kuvassa 40 ja keskihajonnat kuvassa 41.




**Kuva 40. Tuotantokeskiarvojen ja ideaalituotannon väliset suhteelliset poikkeamat 29.8.2019.**




**Kuva 41. Tunti- ja vartikeskihajonnat 29.8.2019.**

Kuvassa 42 on Kampusareenan aurinkovoimalan tuotantodataa 27. elokuuta 2019.




**Kuva 42.** Aurinkovoiman pätöteho 27.8.2019.



**Kuva 43.** Tuotantokeskiarvojen ja ideaalituotannon väliset suhteelliset poikkeamat 27.8.2019.


Kuvan 42 päivänä kuvassa 43 määritetyt suhteelliset poikkeamat ovat suuria ideaalituotantoon nähden. Vartikeskiarvotetun datan osalta noin 50 % ja tuntikeskiarvotetun datan osalta 40 %.

Eri aikavälillä keskiarvotettujen keskihajontajakaumien muodossa alkaa näkyä eroavaisuuksia, kun pienten vartikeskihajontojen suhteellinen osa on suurempi kuin tuntikeskihajontojen osalta. Keskihajonnat ovat kuvassa 44.




**Kuva 44.** Tunti- ja vartikeskihajonnat 27.8.2019.

Kuvassa 45 on esitetty tuotantodata 19. heinäkuuta 2019. Samassa kuvassa on myös kyseisestä päivästä muodostettu verhokäyrä.




**Kuva 45.** Aurinkovoiman pätöteho 19.7.2019.



**Kuva 46.** Tuotantokeskiarvojen poikkeamat ideaalituotannosta 19.7.2019.

Tuotantokeskiarvojen suurimmat poikkeamat kuvassa 46 aiheutuvat alkuiltapäivän puolipilvisyydestä, jolloin varsinkin varttikeskisarvo putoaa lähes puoleen ideaalituotannosta. Suurimmillaan varttikeskisarvo poikkeaa tuntikeskarvosta yli 10 kW:n verran, joka Kampusareenan tasolla tarkoittaa noin 20 %:n osuutta tuotantokapasiteetista. Megawatin kokoisella tuotantolaitoksella tämä ero tuotannossa olisi 200 kW, joka on merkittävä määrä sähköenergiaa.




**Kuva 47.** Tunti- ja varttikeskiahajonnat 19.7.2019.


Kuvan 47 keskihajonnat havainnollistavat sitä, miten vaihtelulle altista sääriippuva tuotanto on. Varttikeskiahajontoja on selkeämmän aamupäivän osalta paljon alle 200 W:n kohdalla, mutta iltapäivän puolipilvisyyden takia myös paljon 800-1600 W:n alueella.



Tästä voidaan päätellä, että jakauman tilastolliset ominaisuudet muuttuvat, kun tarkasteltava aikaväli muuttuu.




**Kuva 48.** Aurinkovoiman pätöteho 21.7.2019.




**Kuva 49.** Tuotantokeskiarvojen prosentuaalinen poikkeama ideaalista 21.7.2019.

Kuvan 48 selkeää päivää verrattaessa 19.7. verhoikäyrään pysyvät poikkeamat alle 20 %:n alueella kuvassa 49. Kuvan 50 keskihajonnat ovat varttitasolla pääosin alle 1000 W:n luokkaa, joka heijastuu siihen, että tuntitasolla keskihajonnat ovat noin nelinkertaisia varttitasoon nähden.




**Kuva 50. Tunti- ja vartikeskihajonnat 21.7.2019.**


Kuvassa 51 on esitetty pilvinen päivä, jotta voidaan tarkastella sitä, miltä pilvisen päivän jakaumat näyttävät.



**Kuva 51. Aurinkovoiman pätöteho 5.7.2019.**



**Kuva 52. Tuotantokeskiarvojen suhteellinen poikkeama ideaalituotannosta 5.7.2019.**



**Kuva 53. Vartti- ja tuntikeskihajonnat 5.7.2019.**


Kuvassa 52 on pilvisenä päivänä varttikieskiarvon ja tuntikeskiarvon suhteelliset poikkeamat ideaalituotantoon. Pilvisenä päivänä tuotantokeskiarvot ovat pääasiassa 20 % tai vähemmän ideaalituotannosta. Keskihajonnoista kuvassa 53 nähdään, että jakaumien muodossa on eroja. Tämä kuitenkin johtuu todennäköisesti tuntikeskiarvojen pienestä otannasta eikä ero ole suuruudeltaan merkittävä.

Yleisesti aurinkotuotantoa voidaan ennustaa ennalta arvattavasti, jos on olemassa historiadataa tuotannon käyttäytymisestä. Ennustaessa historiadataan yhteyteen täytyy kuitenkin integroida sääennusteita, jotta pystytään määrittämään tuotantotaso, johon tulevan vuorokauden aikana on mahdollista päästä. Tuotannon voidaan olettaa olevan


pienhajontaista päivänä, kun pilviä ei ole, mutta suurihajontaista, kun pilviä on kohtalainen määrä, mutta aurinkokin pääsee paistamaan.

## 5.4.2 Tuulidata

Tuulidataa saatiin tutkimuksen pohjaksi eräästä tuulipuistosta vuoden 2019 mittaiselta jaksolta. Tuulivoimapuiston nimellisteho on useita kymmeniä megawatteja. Dataa oli saatavilla minuutin aikavälein tuulivoimapuiston hetkellisestä kokonaistehosta. Tehodata tämän opinnäytetyön puitteissa muunnettiin prosenttiosuudeksi tuulivoimapuiston tuotantokapasiteetista. Talvikuukausien tuotantodataa on kuvissa 54 ja 55. Kuvien punaiset käyrät kuvaavat vartikeskiarvotettua tuotantoa ja vihreät tuntikeskiarvotettua tuotantoa.




**Kuva 54.** Tuulituotanto 14.1.2019.




**Kuva 55. Tuulituotanto 1.12.2019.**

Kuvista 54 ja 55 voidaan nähdä, että päivittäisen tuulituotannon vartti- ja tuntikeskiarvojen välillä on paljon vaihtelevuutta. Keskiarvojen väliset poikkeamat ovat esitettyinä kuvassa 56. Poikkeama on ilmoitettu negatiivisena kun varttikeskisarvo on tuntikeskiarvoa suurempi.




**Kuva 56.** Tuntikeskiarvon ja varttikkeskiarvon poikkeamat. Päivämäärät järjestyksessä ylhäältä alas: 14.1. ja 1.12.

Tammikuun 14. päivä ja joulukuun 1. päivä ovat olleet tuulisuudeltaan erilaisia. Tuotanto 14. tammikuuta on vaihdellut pääosin 20-70 %:n alueella tuulivoimapuiston tuotantokapasiteetista ja keskiarvot ovat poikenneet toisistaan noin 5 %. Joulukuun 1. päivänä tuotanto on ollut selvästi vaihtelevampaa ja suurimmat tunti- ja varttikkeskiarvon väliset poikkeamat ovat olleet 20 %:n luokkaa.




**Kuva 57.** Vartti- ja tuntikeshajonnat tuulituotannolle 14.1.2019.




**Kuva 58.** Vartti- ja tuntikeskihajonnat tuulituotannolle 1.12.2019.

Kuvissa 57 ja 58 on tuotetun tehon keskihajontoja 15 minuutin ja tunnin keskiarvotusjaksoilla talvikuukausien tuulivoimatuotannolle. Joulukuun 1. päivän havaitaan olleen selvästi vaihtelevampi myös keskihajontakuvien perusteella, sillä tuntikeskihajonnan osumia on jopa 16-18 %:n kohdalla. Vaihtelevampien päivien kohdalla keskihajonnat jakautuvat suuremmalle alueelle ja vartti- ja tuntikeskihajonnat poikkeavat jakauman muodoltaan toisistaan.


Kuvissa 59-62 on kuvia tuulituotannosta heinäkuun alusta sekä lokakuulta.



**Kuva 59.** Tuulituotanto 4.7.2019.

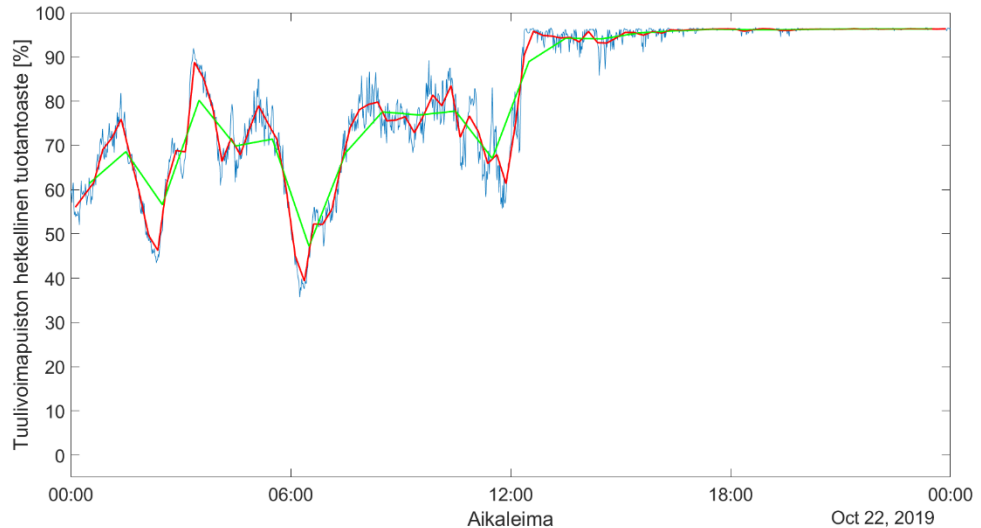


**Kuva 60.** Tuulituotanto 8.7.2019.




**Kuva 61.** Tuulituotanto 1.10.2019.






**Kuva 62. Tuulituotanto 22.10.2019.**

Heinäkuun 4. ja 8. päivä tuotanto on vaihdellut tuotantokapasiteetin suhteen runsaasti. Kuvasta 63 nähdään, että vartikeskiarvo ja tuntikeskiarvo ovat kuitenkin pidempikestoisesti pysyneet suhteellisen lähellä toisiaan lukuun ottamatta 22.10. aamupäivää, jolloin poikkeamat ovat paljon suurempia. Lokakuun 1. päivän tuotanto on ollut tasaisesti kasvavaa, jolloin poikkeamat ovat pysyneet todella pieninä, alle 5 prosentin ja illaksi vakiintunut alle prosentin tasolle. Lokakuun 22. päivänä aamupäivän poikkeamat keskiarvojen välillä ovat suuria puuskittaisuuden takia, mutta tuotanto tasoittuu illaksi hyvin lähelle maksimituotantokapasiteettia. Tämän takia kuvan 63 alimman käyrän poikkeama tasoittuu lähes lineaariseksi nollan seudulle.

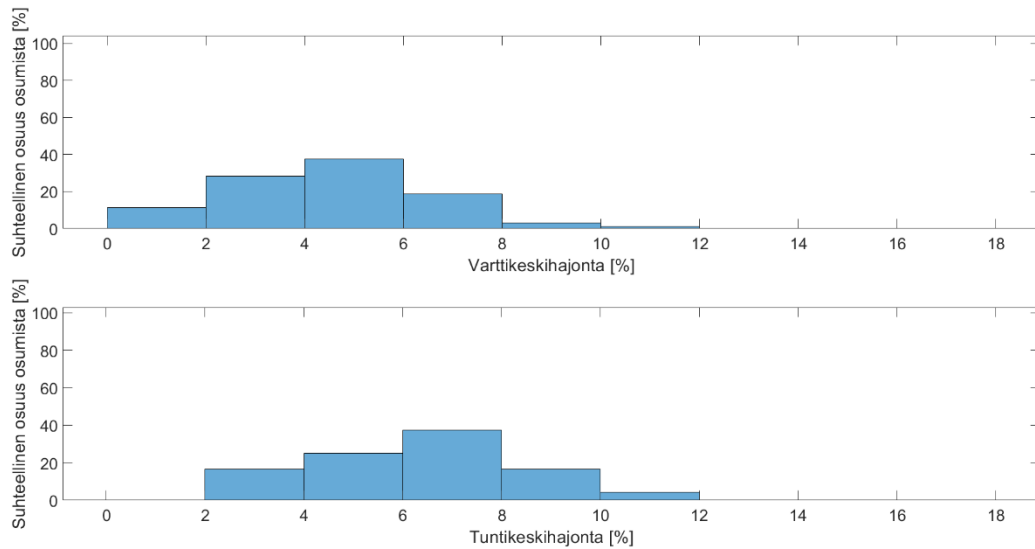


**Kuva 63.** Tuntikeskiarvon ja vartikeskiarvon poikkeamat. Päivämäärät ylhäältä alaspäin: 4.7., 8.7., 1.10. ja 22.10.


Kuvissa 64-67 ovat vartti- ja tuntikeskiarvotetun tuotannon keskihajonnat kuvan 63 päville. Keskihajontakuvista on nähtävissä varttikeskijajontojen painottuvan alle 6 prosenttiin, kun tuntikeskihajonnat jakautuvat tasaisemmin 0-10 %:in.




**Kuva 64.** Tuulituotannon vartti- ja tuntikeskihajonnat tuulivoimapuiston nimellistehosta 4.7.2019.



**Kuva 65.** Tuulituotannon vartti- ja tuntikeskihajonnat tuulivoimapuiston nimellistehosta 8.7.2019.



**Kuva 66.** Tuulituotannon vartti- ja tuntikeskihajonnat tuulivoimapuiston nimellistehosta 1.10.2019.



**Kuva 67.** Tuulituotannon vartti- ja tuntikeskihajonnat tuulivoimapuiston nimellistehosta 22.10.2019.

Tuulituotannon keskihajonnat käyttäytyvät eri vuodenaikoina hyvin samalla tavoin. Kuvien 57 ja 58 keskihajonnat muistuttavat tilastollisesti kuvien 64-67 keskihajontoja. Talvikuukausien tuotantokeskiarvojen poikkeamat ovat hieman suurempia kuin kesäkuukausien, mikä johtunee siitä, että talviaikaan sekä myöhään syksyllä tilastoidaan enemmän päiviä, jotka luokitellaan myrskyisiksi [41].

## 5.5 Tuloksien tulkintaa

Tässä luvussa tutkittujen aurinkovoiman ja tuulivoiman tuotantodatoista sai hyvän kuvan siitä, miten ennusteaikavälin muuttaminen vaikuttaa tuotantodatan tilastollisiin ominaisuuksiin. Tarkasteltavia suureita olivat aurinkovoiman osalta eri aikavälillä keskiarvotetun tuotannon suhteellinen poikkeama ideaalituotannosta sekä 15 minuutin ja tuntikeskiarvotetun tuotannon laskettu keskihajonta. Tuulivoiman osalta tarkasteltiin 15 minuutin ja tuntikeskiarvon välistä poikkeamaa sekä aurinkovoiman tavoin eri aikakeskiarvotettuja keskihajontoja.

Aurinkovoiman osalta selkeiden päivien suhteelliset poikkeamat käyttäytyivät samoin tavoin sekä tunnin että 15 minuutin keskiarvoilla. Myös keskihajonnat käyttäytyivät samalla tavalla. Selkeiden päivien osalta jakaumien tilastollisessa käyttäytymisessä ei ole ennustusmenetelmien kannalta huolestuttavia merkkejä. Puolipilvisinä päivinä jakaumat olivat vaikeammin tulkittavia. 15 minuutin keskiarvojen ja tuntikeskiarvojen väliset poikkeamat olivat merkittäviä ja ne aiheuttivat vaihtelevuutta myös eri aikavälillä keskiarvotettujen keskihajontajakaumien muotojen välille. Se voi aiheuttaa erityisesti aikasarjamenetelmiä käyttävien ennustusmenetelmien joukossa ongelmia ennusteen luotettavuuden kannalta, kun ennuste vielä tällä hetkellä perustuu tunneittaiseen historiadataan. Pilvisten päivien osalta poikkeamat ovat suuria eikä 15 minuutin ja tunnin mukaan keskiarvotettujen datojen välillä ole suuria tilastollisia eroavaisuuksia.

Tuulivoiman osalta vartti- ja tuntikeskiarvon poikkeamat vaihtelivat paljon, kuten kuvista 56 ja 63 voitiin nähdä. Jakaumien muodosta on vaikeaa tehdä mitään selkeitä johtopäätöksiä, koska keskiarvotetut keskihajontajoukot ovat niin pieniä. Tarkkojen lyhytaikaisten ennusteiden tekeminen tuulituotannon osalta tulee olemaan vaikeaa, ja tunti- ja varttikkeskiarvoihin perustuvat ennusteet ja erityisesti ennustevirhe tulee vaihtelemaan paljon.

## 6. YHTEENVETO

Sähkömarkkinat ovat pohjoismaissa murrosvaiheessa. 15 minuutin taseen käyttöönotolla tulee olemaan monimuotoisia vaikutuksia kunkin pohjoismaan sähköenergiajärjestelmässä sekä sen hallinnassa. 15 minuutin tase tulee uudistamaan mittauslaitteistoja ja tietokantoja, kun tarvittavan datan määrä kasvaa merkittävästi. Suomessa tullaan ottamaan käyttöön Datahub-tietokanta, jonne kerätään tiedot monesta miljoonasta sähkönkäyttöpaikasta.

Tuotannon ja kulutuksen ennustamisessa käytettyjä menetelmiä ovat mm. neuroverkot, tukivektorikoneet, sumea logiikka, hiukkasparvioptimointi, aikasarjamenetelmät ja Kalman-suotimeen pohjautuvat mallipohjaiset menetelmät. Varsinkin koneoppimiseen pohjautuvat menetelmät, kuten neuroverkot ja tukivektorikoneet ovat nykypäivän kehityskohteita ja jatkuvan tutkimuksen alaisena.

Tarkkojen ennusteiden rooli tuotannossa kasvaa. Ennustemenetelmien tulee mukautua 15 minuutin aikaresoluutioon eli niiden täytyy pystyä muodostamaan tarkat ennusteet 15 minuutin jaksoin seuraavalle vuorokaudelle. Tämä tarkoittaa, että ainakin pidemmän aikavälin päähän tehtävien ennusteiden tarkkuus tulee laskemaan. Esimerkiksi aurinkovoiman kohdalla pilvimassojen tarkkaa liikettä ja muodostumista on vaikea ennustaa jo vuorokaudenkin päähän. Luvussa 5.4.1 esitettyjen Kampusareenan aurinkovoimalan tuotantokuvista on nähtävissä, että tuotanto voi vaihdella todella paljon lyhyessä ajassa, kun on puolipilvinen päivä. Tällaisina päivinä tunti- ja varttikeskisarvotettu tuotanto voivat poiketa toisistaan merkittävästi, jolloin sähkönmyyjän tehtävä tuotettavan sähkön määrän ennustamiseksi seuraavaksi päiväksi monimutkaistuu.

Luvussa 5.4.2 esitetyn tuulidatan havaittiin olevan luonteeltaan hyvin vaihtelevaa, ja erityisesti tuulivoiman tuottajille varttitaseeseen siirtyminen tulee aiheuttamaan haasteita. Tuntikeskiarvojen havaittiin vaihtelevan suhteessa varttikeskisarvoon paljon pienellä aikavälillä varsinkin silloin, kun tuotanto kasvaa tai laskee nopeasti.

Sääriippuvan tuotannon ennustamisen voidaan siis olettaa kokevan pienen takaiskun ennustevirheiden tarkkuuden kohdalla. Tulevaisuudessa on kuitenkin oletettavaa, että sääennusteiden tarkkuus kasvaa entisestään, kun teknologia kehittyy ja tarkempia mittausjärjestelmiä kehitetään. Tällöin tuotantoennusteiden tarkkuus tulee kasvamaan ja 15 minuutin selvitysjakson hyödyt saadaan vielä entistä paremmin esille.

# LÄHTEET

- [1] A. Abdulkarim, S. M. Abdelkader, D. J. Morrow, Statistical Analyses of Wind and Solar energy Resources for the Development of Hybrid Microgrid, 2014. 10.1007/978-3-319-16901-9\_2.
- [2] V. Alagbe, S.I. Popoola, A. A. Atayero, B. Adebisi, R. O. Abolade, S. Misra, Artificial Intelligence Techniques for Electrical Load Forecasting in Smart and Connected Communities. In: S. Misra et al. (eds) Computational Science and Its Applications – ICCSA 2019. ICCSA 2019. Lecture Notes in Computer Science, vol 11623. Springer, Cham. [https://doi.org/10.1007/978-3-030-24308-1\\_18](https://doi.org/10.1007/978-3-030-24308-1_18)
- [3] S.M. Al-Alawi, S. M. Islam, Principles of electricity demand forecasting – Part 1 Methodologies, Power Engineering Journal, Vol. 10, Iss. 3, 1996, pp. 139-143.
- [4] F. N. Al Farsi, M. H. Albadi, N. Hosseinzadeh, A. H. Al Badi, Economic Dispatch in power systems, Proceedings of the 8<sup>th</sup> IEEE GCC Conference and Exhibition, Muscat, Oman, February 1-4, 2015.
- [5] A. Azadeh, S. F. Ghaderi, S. Sohrabkhani, Forecasting electrical consumption by integration of Neural Network, time series and ANOVA. Applied Mathematics and Computation, Vol. 18, 2007, pp. 1753-1761.
- [6] S. Ben Amor, H. Boubaker, L. Belkacem, Forecasting electricity spot price for Nord Pool market with a hybrid k-factor GARMA-LLWNN model, Journal of forecasting, Vol. 37, 2018, pp. 832-851.
- [7] A. Bhardwaj, V. K. Kamboj, V. K. Shukla, B. Singh, P. Khurana, Unit Commitment in Electrical Power System - A Literature Review, IEEE International Power Engineering and Optimization Conference, Melaka, Malaysia, 6-7 June, 2012, pp. 275-280.
- [8] E. Ceperic, V. Ceperic, A. Baric, A Strategy for Short-Term Load Forecasting by Support Vector Regression Machines, IEEE Transactions on Power Systems, Vol. 28, Iss. 4, 2013, 9 p.
- [9] Commission Regulation (EU), 23.11. 2017/2195, 2017. Saatavissa: <https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:32017R2195&from=EN>
- [10] L. P. C. Do, Š. Lyócsa, P. Molnár, Residual electricity demand: An empirical investigation, Applied Energy, Vol. 283, 2021.
- [11] M. E. El-Hawary, Advances in electric power and energy systems: load and price forecasting, Hoboken, New Jersey : Wiley, 2017, 310 p.
- [12] Energiategollisuus ry, Fingrid, Hyvä tietää sähkömarkkinoista, verkkosivu, Saatavissa (viitattu 1.12.2020): [https://www.fingrid.fi/globalassets/dokumentit/fi/julkaisut/uusi\\_versio\\_sahkomarkk.pdf](https://www.fingrid.fi/globalassets/dokumentit/fi/julkaisut/uusi_versio_sahkomarkk.pdf).
- [13] Entso-E, Statistical Factsheet 2018, verkkodokumentti. Saatavissa (viitattu 3.3.2021): [https://eepublicdownloads.entsoe.eu/clean-documents/Publications/Statistics/Factsheet/entsoe\\_sfs2018\\_web.pdf](https://eepublicdownloads.entsoe.eu/clean-documents/Publications/Statistics/Factsheet/entsoe_sfs2018_web.pdf).

- [14] eSett, Handbook, 2020, Saatavissa (viitattu 14.12.2020): <https://www.esett.com/handbook/>.
- [15] P. M. Ferreira, I. D. Cuambe, A. E. Ruano, R. Pestana, Forecasting the Portuguese Electricity Consumption using Least-Squares Support Vector Machines, IFAC Proceedings Volumes, Vol. 46, 2013, pp. 411-416.
- [16] Fingrid Datahub Oy, verkkosivu. Saatavissa (viitattu 19.5.2021): <https://www.fingrid.fi/sivut/yhtio/datahub-oy/>.
- [17] Fingrid: Esittely, Fingrid, verkkosivu. Saatavissa (viitattu 20.11.2020): <https://www.fingrid.fi/sivut/yhtio/esittely/>.
- [18] Fingrid, Kaksi- ja yksihinta-järjestelmä, Fingrid, verkkosivu. Saatavissa (viitattu 4.3.2021): <https://www.fingrid.fi/sahkomarkkinat/tasepalvelut/tasemallin-kuvaus/kaksi-ja-yksihinta-jarjestelma/>.
- [19] Fingrid, Kuluttajatietoa, Fingrid, verkkosivu. Saatavissa (viitattu 20.11.2020): <https://www.fingrid.fi/asiakkaille/kuluttajatietoa/>.
- [20] Fingrid, Nopea taajuusreservi, Fingrid, verkkosivu. Saatavissa (viitattu 13.1.2021): <https://www.fingrid.fi/sahkomarkkinat/reservit-ja-saatosahko/nopea-taajuusreservi/#hankinta>.
- [21] Fingrid, Nopean taajuusreservin (FFR) teknisten vaatimusten todentaminen ja hyväksyttämisen prosessi, verkkosivu. Saatavissa (viitattu 12.5.2021): <https://www.fingrid.fi/globalassets/dokumentit/fi/sahkomarkkinat/reservit/liite2---nopean-taajuusreservin-ffr-teknisten-vaatimusten-todentaminen-ja-hyvaksyttamisprosessi.pdf>.
- [22] Fingrid, Sähköjärjestelmän tila, Fingrid, verkkosivu. Saatavissa (viitattu 3.3.2021): <https://www.fingrid.fi/sahkomarkkinat/sahkojarjestelman-tila/>.
- [23] Fingrid, Sähkön kulutus Suomessa, avoin data, verkkosivu. Saatavissa (viitattu 10.3.2021): <https://data.fingrid.fi/fi/dataset/electricity-consumption-in-finland>.
- [24] Fingrid, Säätosähkö- ja säätökapasiteettimarkkinat, Fingrid, verkkosivu. Saatavissa (viitattu 13.1.2021): <https://www.fingrid.fi/sahkomarkkinat/reservit-ja-saatosahko/saatosahko-ja-saatokapasiteettimarkkinat/#saatosahkon-hinnoittelu>.
- [25] Fingrid, Tasemallin kuvaus, Fingrid, verkkosivu. Saatavissa (viitattu: 4.3.2021): <https://www.fingrid.fi/sahkomarkkinat/tasepalvelut/tasemallin-kuvaus/>.
- [26] Fingrid, Tasepalvelut, Fingrid, verkkosivu. Saatavissa (viitattu 14.12.2020): <https://www.fingrid.fi/sahkomarkkinat/tasepalvelut/#tasehallinta>.
- [27] Fingrid, Taseselvitysmallin muutos, Fingrid, verkkosivu. Saatavissa (viitattu 22.3.2021): <https://www.fingrid.fi/sahkomarkkinat/markkinoiden-yhtenaisyyss/pohjoismainen-tasehallinta/taseselvitysmallin-muutos/>.
- [28] Fingrid, Varttitase eli 15 minuutin taseselvitysjakso, Fingrid, verkkosivu. Saatavissa (viitattu 29.4.2021): <https://www.fingrid.fi/sahkomarkkinat/markkinoiden-yhtenaisyyss/pohjoismainen-tasehallinta/varttitase/#taustaa>
- [29] Fingrid: Yhtenäiset sähkömarkkinat, Fingrid, verkkosivu. Saatavissa (viitattu 11.12.2020): <https://www.fingrid.fi/sahkomarkkinat/markkinoiden-yhtenaisyyss/>.



- [30] P. Finn, C. Fitzpatrick, Demand side management of industrial electricity consumption: Promoting the use of renewable energy through real-time pricing, *Applied Energy*, Vol. 113, 2014, pp. 11-21.
- [31] J. Gylén, Datahubin vaikutukset tasevastaavalle, Diplomityö, Lappeenrannan teknillinen yliopisto (LUT), 2020, 59 s.
- [32] G. Hafeez, K. S. Alimgeer, I. Khan, Electric load forecasting based on deep learning and optimized by heuristic algorithm in smart grid, *Applied Energy*, Vol. 269, 2020.
- [33] A. Heikura, Ennusteiden laadun vaikutukset sähköjärjestelmän käyttötoimintaan, Diplomityö, Aalto-Yliopisto, 2020, 69+4 s.
- [34] Helsingin yliopisto, Elements of AI, verkkokurssi.
- [35] A. Hilden, Power Quality and Power Monitoring in a Modern Office Building Utilizing Diverse Metering, Master of Science Thesis, Tampere University of Technology, 2018, 88 p.
- [36] S. Hochreiter, J. Schmidhuber, Long Short-Term Memory, *Neural Computation*, vol. 9, no. 8, 1997, pp. 1735-1780.
- [37] N. Hodžić, T. Konjić, V. Miranda, Artificial Neural Networks Applied To Short Term Load Diagram Prediction, (th Seminar on Neural Network Application in Electrical Engineering, NEUREL-2006, October, 2006.
- [38] H. Holttinen, J. Miettinen, S. Sillanpää, Wind power forecasting accuracy and uncertainty in Finland, VTT, Espoo, Finland, 2013.
- [39] Y. Huang, P. M. Pardalos, Q. P. Zheng, *Electrical Power Unit Commitment*, Springer, Boston Massachusetts, USA, 2017, 93 p.
- [40] IBM, Deep Learning, verkkosivu. Saatavissa (viitattu 5.1.2021): <https://www.ibm.com/cloud/learn/deep-learning>.
- [41] Ilmatieteen Laitos, verkkosivu. Saatavissa (viitattu 18.5.2021): <https://www.ilmatieteenlaitos.fi/tuulitilastot>.
- [42] R. H. Inman, H. T. C. Pedro, C. F. M. Coimbra, Solar forecasting methods for renewable energy integration, *Progress in Energy and Combustion Science*, Vol. 39, 2013, pp. 535-579.
- [43] N. Jaakamo, Impact of the 15-Minute Imbalance Settlement Period and Electricity Storage on an Independent Wind Power Producer, Master of Science Thesis, Aalto University, 2020, 68+9 p.
- [44] G. James, D. Witten, R. Tibshirani, T. Hastie, An Introduction to Statistical Learning, verkkodokumentti. Saatavissa (viitattu 23.4.2021): <https://static1.squarespace.com/static/5ff2adbe3fe4fe33db902812/t/6062a083ac-bfe82c7195b27d/1617076404560/ISLR%2BSeventh%2BPrinting.pdf>, 2013, 431 p.
- [45] S. Jovanović, S. Savić, M. Bojić, Z. Djordjević, D. Nikolić, The impact of the mean daily air temperature change on electricity consumption, *Energy*, Vol. 88, 2015, pp. 604-609.

- [46] O. Karabiber, G. Xydis, electricity Price Forecasting in the Danish Day-Ahead Market Using the TBATS, ANN and ARIMA Methods, *Energies*, Vol. 12, Iss. 5, 2019.
- [47] G. Kariniotakis, *Renewable Energy Forecasting: From Models to Applications*, Elsevier Science & Technology, June, 2014, 375 p.
- [48] R. G. Kavasseri, K. Seetharaman, Day-ahead wind speed forecasting using f-ARIMA models, *Renewable Energy*, Vol. 34, Iss. 5, 2009, pp. 1388-1393.
- [49] Y. Kim, K. H. Lee, Y. Yoon, Visualizing the search process of particle swarm optimization, *Proc. of the 11th Annual Conference on Genetic and Evolutionary Computation*, July, 2009, pp. 49-55.
- [50] E. Kokkonen, *Kaukolämpöverkon kuorman ennustus ja käytön optimointi*, diplomityö, Lappeenranta-Lahden teknillinen yliopisto LUT, 2020, 69 p.
- [51] D. Kumar, H. D. Mathur, S. Bhanot, R. C. Bansal, Frequency regulation in islanded microgrid considering stochastic model of wind and PV, *International transactions on electrical energy systems*, Vol. 29, 2019, 17 p.
- [52] H. Le Cadre, I. Aravena, A. Papavasiliou, Solar PV Power Forecasting Using Extreme Learning Machine and Information Fusion, *European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*, April 2015, Bruges, Belgium.
- [53] P. Leinonen, Fingrid, What is inertia?, verkkosivu. Saatavissa (viitattu 9.3.2021): <https://www.fingridlehti.fi/en/what-is-inertia/>.
- [54] M. Leivo, *Effects of Demand Response Products in the Interface of Electricity Supplier and Customer*, Master of Science Thesis, Tampere University of Technology, 2015, 86 p.
- [55] Y. Li, Y. Su, L. Shu, An ARMAX model for forecasting the power output of a grid connected photovoltaic system, *Renewable Energy*, Vol. 66, 2014, pp. 78-89.
- [56] B. Lu, M. Shahidehpour, Unit Commitment With Flexible Generating Units, *IEEE Transactions on Power Systems*, Vol. 20, Iss. 2, 2005, pp. 1022-1034.
- [57] S. Mehta, P. Basak, Solar irradiance forecasting using fuzzy logic and multilinear regression approach: a case study of Punjab, India, *International Journal of Advances in Applied Sciences*, Vol. 8, 2019, pp. 125-135.
- [58] I. Mellin, *Todennäköisyyslaskenta: Todennäköisyysjakaumia*, Oppikirja. Saatavissa (viitattu 24.2.2021): <http://math.aalto.fi/opetus/sovtoda/oppikirja/TodLaskJakaumat.pdf>.
- [59] R. Merikoski, Fortum, Pohjoismainen energiantuotanto 2020-30, Paikallisvoiman vuosiseminaari, 12.2.2020. Saatavissa (viitattu 3.3.2021): <http://www.paikallisvoima.fi/tiedostot/Pohjoismainenenergiantuotanto202030.pdf>.
- [60] M. Määttä, Pohjoismainen tasehallintahanke vie kohti reaaliaikamarkkinoita, verkkosivu. Saatavissa (viitattu 15.2.2021): <https://www.fingridlehti.fi/pohjoismainen-tasehallintahanke-vie-kohti-reaaliaikamarkkinoita/>.

- [61] D. H. Nguyen, A. T. Nguyen, An Approach for The Electricity Consumption Prediction based on Artificial Neural Network, 2019 SICE International Symposium on Control Systems (SICE ISCS), Kumamoto, Japan, 2019, pp. 78-83.
- [62] F. J. Nogales, J. Contreras, A. J. Conejo, R. Espinola, Forecasting Next-Day Electricity Prices by Time Series Models, IEEE Transactions on Power Systems, Vol. 17, 2002, pp. 342-348.
- [63] Nord Pool, verkkosivu. Saatavissa (viitattu 11.12.2020): <https://www.nordpoolgroup.com/>.
- [64] Nord Pool: Block order, Nord Pool, verkkosivu. Saatavissa (viitattu 11.12.2020): <https://www.nordpoolgroup.com/trading/Day-ahead-trading/Order-types/Block-bid/>.
- [65] Nord Pool: Intraday Trading – Order types, Nord Pool, verkkosivu. Saatavissa (viitattu 11.12.2020): <https://www.nordpoolgroup.com/trading/intraday-trading/order-types/>.
- [66] Nord Pool: Price calculation, Nord Pool, verkkosivu. Saatavissa (viitattu 11.12.2020): <https://www.nordpoolgroup.com/trading/Day-ahead-trading/Price-calculation/>.
- [67] Nord Pool: Single hourly order, Nord Pool, verkkosivu. Saatavissa (viitattu 11.12.2020): <https://www.nordpoolgroup.com/trading/Day-ahead-trading/Order-types/Hourly-bid/>.
- [68] Nordic Green Energy: Kannattaako pörssisähkö?, Nordic Green Energy, verkkosivu. Saatavissa (viitattu 20.11.2020): <https://www.nordicgreen.fi/blogi-kannattaako-porssisahko/>.
- [69] Nordic Green Energy: Sähkömarkkinat, Nordic Green Energy, verkkosivu. Saatavissa (viitattu 19.11.2020): <https://www.nordicgreen.fi/asiakaspalvelu/energia-tietoa/sahkomarkkinat/>.
- [70] Nordic TSOs, Report: Challenges and opportunities for the Nordic power system, 2016.
- [71] G. Oğcu, O. F. Demirel, S. Zaim, Forecasting Electricity Consumption with Neural Networks and Support Vector Regression. Procedia - Social and Behavioral Sciences, Vol. 58, 2012, pp. 1576-1585.
- [72] O. Ozerdem, E. Olaniyi, O. Oyedotun, Short term load forecasting using particle swarm optimization neural network, Procedia Computer Science, Vol. 120, 2017, pp. 382-392.
- [73] D. Pajunen, Fingrid, Sähköjärjestelmän tasapaino vaatii paljon ennustedataa, verkkosivu. Saatavissa (viitattu 4.2.2021): <https://www.fingridlehti.fi/ennustedataa/>.
- [74] J. Partanen, S. Viljainen, J. Lassila, S. Honkapuro, K. Salovaara, S. Annala, M. Makkonen, Sähkömarkkinat – Opintomoniste, Lapeenrannan teknillinen yliopisto, 2015.

- [75] R. Porteiro, S. Nesmachnow, L. Hernandez-Callejo, Short Term Load Forecasting of Industrial Electricity Using Machine Learning. In: S. Nesmachnow, L. Hernandez-Callejo, (eds) Smart Cities. ICSC-CITIES 2019. Communications in Computer and Information Science, Vol. 1152, Springer, Cham.
- [76] H. Saadat, Power system analysis, WCB/McGraw-Hill, 1999.
- [77] B. Saravanan, S. Das, S. Sikri, D. P. Kothari, A Solution to the unit commitment problem a review, *Frontiers in Energy*, Vol. 7, 2013, pp. 223-236.
- [78] A. Solovian, Impact of quarter hourly imbalance settlement period on the Nordic physical electricity market, Master of Science Thesis, Aalto University, 2019, 53 p.
- [79] Suomen tuuliatlas, WAsP-malli, verkkosivu. Saatavissa (viitattu 23.2.2021): [http://www.tuuliatlas.fi/mallinnus/mallinnus\\_2.html](http://www.tuuliatlas.fi/mallinnus/mallinnus_2.html).
- [80] Suomen tuuliatlas, Weibull, verkkosivu. Saatavissa (viitattu 23.2.2021): [http://www.tuuliatlas.fi/mallinnus/mallinnus\\_2\\_1.html](http://www.tuuliatlas.fi/mallinnus/mallinnus_2_1.html).
- [81] Suomen virallinen tilasto (SVT): Energian hankinta ja kulutus [verkkójulkaisu]. ISSN=1799-795X. 4. Vuosineljännes 2019, Liitekuvio 20. Sähkön kulutus sektoreittain 2019\* . Helsinki: Tilastokeskus [viitattu: 1.12.2020].  
Saantitapa: [http://www.stat.fi/til/ehk/2019/04/ehk\\_2019\\_04\\_2020-04-17\\_kuv\\_020\\_fi.html](http://www.stat.fi/til/ehk/2019/04/ehk_2019_04_2020-04-17_kuv_020_fi.html).
- [82] H. Takeda, Y. Tamura, S. Sato, Using the ensemble Kalman filter for electricity load forecasting and analysis, *Energy*, Vol. 104, 2016, pp. 184-198.
- [83] F. Tseng, G. Tzeng, A fuzzy seasonal ARIMA model for forecasting, *Fuzzy Sets and Systems*, Vol. 126, Iss. 3, 2002, pp. 367-376.
- [84] Työ- ja elinkeinoministeriö, Uusiutuva energia Suomessa, verkkosivu. Saatavissa (viitattu 18.1.2021): <https://tem.fi/uusiutuva-energia>.
- [85] E. Vallinheimo, Säämalli – nykypäivän ennustetehdas, Atmos, verkkosivu. Saatavissa (viitattu 27.1.2021): <https://atmoslehti.fi/teema/saamalli-nykypaivan-ennustetehdas-2/>.
- [86] V. Vapnik, S. Golowich, A. Smola, Support Vector Method for Function Approximation, Regression Estimation and Signal Processing, *Advances in Neural Information Processing Systems 9*, Cambridge, MA, USA, MIT Press, 1996, pp. 281-287.
- [87] C. Wan, Z. Xu, P. Pinson, Z. Y. Dong, K. P. Wong, Probabilistic forecasting of wind power generation using extreme learning machine, *IEEE Transactions on Power Systems*, Vol. 29, Iss. 3, 2014, pp. 1033-1044.
- [88] H. Wang, Z. Lei, X. Zhang, B. Zhou, J. Peng, A review of deep learning for renewable energy forecasting, *Energy Conversion and Management*, Vol. 198, October, 2019.
- [89] Wikimedia Commons, verkkosivu. Saatavissa (viitattu 20.4.2021): [https://commons.wikimedia.org/wiki/File:TUT\\_-\\_Kampusareena.jpg](https://commons.wikimedia.org/wiki/File:TUT_-_Kampusareena.jpg).

- [90] B. M. Williams, Multivariate Vehicular Traffic Flow Prediction: Evaluation of ARIMA Modeling, Transportation Research Record Journal of the Transportation Research Board, Vol. 1, 2001.
- [91] G. Wynn, Power-Industry Transition, Here and Now: Wind and Solar Won't Break the Grid: Nine Case Studies, 2018. Saatavissa (viitattu 29.3.2021): [http://ieefa.org/wp-content/uploads/2018/02/Power-Industry-Transition-Here-and-Now\\_February-2018.pdf](http://ieefa.org/wp-content/uploads/2018/02/Power-Industry-Transition-Here-and-Now_February-2018.pdf).
- [92] Yritys X, yritysvierailu.
- [93] J. Yusuf, R. Faruque, A. Hasan, S. Ula, Statistical and Deep Learning Methods for Electric Load Forecasting in Multiple Water Utility Sites, 2019 IEEE Green Energy and Smart Systems Conference (IGESSC), 2019.
- [94] H. Zareipour, Short-term Electricity Market Prices: A Review of Characteristics and Forecasting Methods, Handbook of Networks in Power Systems, Springer, Berlin, Heidelberg, 2012, pp. 89-121.