

Aurinkovoimalalla ja akulla varustetun  
kotitalouden energianhallinnan  
neuroverkkopohjainen optimointi

Pro Gradu  
Turun yliopisto  
Fysiikka  
2024  
LuK Lauri Karttunen  
Tarkastajat:  
Dos. Johannes Niskanen  
TkT Sami Jouttijärvi

Turun yliopiston laatujärjestelmän mukaisesti tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck-järjestelmällä

TURUN YLIOPISTO

Fysiikan laitos

**Karttunen, Lauri** Aurinkovoimalalla ja akulla varustetun kotitalouden energianhallinnan neuroverkkopohjainen optimointi

Pro Gradu, 64 s.

Fysiikka

Tammikuu 2024

---

Kotitalouksien mielenkiinto aurinkovoimaloihin on lisääntynyt muun muassa aurinkopaneelien hintojen laskun sekä energiakriisin aiheuttaman sähkönhinnan nousun takia. Koska aurinkoenergiaa saadaan nimensä mukaisesti vain silloin, kun aurinko paistaa, ovat myös kotitalouksien akkusysteemit alkaneet kasvattaa suosiotaan. Akun avulla ylimääräinen aurinkoenergiatuotanto voidaan varastoida myöhempää käyttöä varten. Verkkoon kytkettynä akku mahdollistaa myös kotitalouden joustavan verkkosähkön kulutuksen, sillä akkuun voidaan varastoida verkkosähköä, kun se on halpaa (eli kun kansallisella tasolla tuotantoa on paljon), ja akun latausta voidaan käyttää, kun verkkosähkö on kallista (kun tuotannosta on pulaa). Tällöin kotitalouksien akunkäytöstä voi olla hyötyä myös yhteiskunnan tasolla.

Kun kotitalouden energiajärjestelmä koostuu energiavarastosta ja vaihtelevasta tuotantokapasiteetista, sen toiminnan optimointi on haastavaa. Kirjallisuudessa on esitetty lukuisia strategioita kotitalouksien energianhallintaan, jonka tarkoitus on tyypillisesti maksimoida energiajärjestelmän taloudellinen hyöty. Ne pohjautuvat joko yksinkertaisiin sääntöihin, matemaattiseen optimointiin tai koneoppimislähestymistapoihin. Erityisesti vahvistusoppimismallit ovat osoittautuneet energianhallintaongelmaan toimiviksi, sillä ne pystyvät parantamaan toimintaansa käytön aikana.

Tässä työssä tutkin neuroverkkopohjaisen vahvistusoppimismallin käyttökelpoisuutta aurinkovoimalalla ja akulla varustetun kotitalouden energianhallintaan eri skenaarioissa varioiden akun kytkentää energiajärjestelmässä. Mallin tavoitteena on minimoida vuosittainen sähkölasku, ja vertaan neuroverkkomallin tuloksia sääntöpohjaiseen referenssiin strategiaan. Työn tutkimuskysymykset ovat: (1) saavutetaanko neuroverkkomallilla suurempi taloudellinen hyöty kuin yksinkertaisella sääntöpohjaisella mallilla ja (2) millainen taloudellinen hyöty eri aurinkovoimala-akku-skenaarioilla saavutetaan Suomen olosuhteissa. Tulokseni viittaavat siihen, että vaikka neuroverkkomalli oppii päätöksenteossaan huomioimaan seuraavan päivän sähkönhinnat, se ei vuositasolla tuo taloudellista lisäarvoa sääntöpohjaiseen malliin nähden. Kun akkua voidaan ladata verkkosähköllä, saadaan vuosittaista sähkölaskua pienennettyä merkittävästi varastoimalla akkuun yön halpaa sähköä. Kun sähkölaskun lisäksi huomioidaan akun ikääntymiseen liittyvä akunkäytön hinta, akku on tämän työn perusteella kuitenkin taloudellisesti kannattamaton verrattuna pelkkään aurinkovoimalalla varustettuun kotitalouteen.

Asiasanat: HEMS, aurinkoenergia, koneoppiminen, vahvistusoppiminen, energiajärjestelmä

# Sisällys

<b>Johdanto</b>	<b>1</b>
<b>1 Työn tausta</b>	<b>2</b>
1.1 Pientuottajien aurinkovoimalat, akut ja sähkösovimukset . . . . .	2
1.2 Neuroverkko . . . . .	9
1.3 Energianhallintastrategiat . . . . .	15
1.4 Tutkimuskysymykset . . . . .	21
<b>2 Menetelmät</b>	<b>22</b>
2.1 Tutkitut skenaariot ja suorituskykymittarit . . . . .	22
2.2 Työssä käytetty data ja sähkösovimus . . . . .	25
2.3 Komponenttien mallinnus ja mitoitus . . . . .	28
2.4 Työn neuroverkkomalli . . . . .	31
<b>3 Tulokset</b>	<b>39</b>
3.1 Mallinvalinta . . . . .	40
3.2 Vuosittaiset ja kuukausittaiset sähkölaskut . . . . .	41
3.3 Mallien toimintojen tarkastelu . . . . .	45
3.4 Akunkäytön hinta ja neuroverkkostrategian kokonaishyöty . . . . .	51
<b>4 Jatkotutkimusaiheita</b>	<b>56</b>
<b>5 Yhteenveto</b>	<b>59</b>
<b>6 Kiitokset</b>	<b>60</b>

## Johdanto

Energiakriisi, vihreä siirtymä sekä laskevat aurinkopaneelien hinnat ovat lisänneet kotitalouksien mielenkiintoa aurinkovoimaloihin. Yksi aurinkoenergian merkittävimmistä ongelmista on kuitenkin sen täysi riippuvuus auringon säteilystä, joka vaihtelee niin vuorokausi- kuin vuositasolla, erityisesti pohjoisilla leveysasteilla. Tämän auringonsäteilyn vaihtelun takia aurinkovoimatuotannon hyödyntäminen kotitalouden omaan käyttöön saattaa olla vaillinaista. Yksi ratkaisu tuotannon hyödyn maksimoimiseen lyhyellä aikavälillä (korkeintaan muutama vuorokausi) on akku. Ylimääräinen aurinkoenergia voidaan varastoida akkuun ja käyttää myöhemmin. Mutta milloin akkuun varastoitua energiaa kannattaa itse käyttää? Kysymykseen ei ole yksiselitteistä eikä yksinkertaista vastausta, vaan se riippuu vallitsevista olosuhteista ja tavoiteltavasta hyödystä, kuten sähkölaskun mimimoinnista. Akunkäytön strategisointi on yksi kotitalouden energianhallintajärjestelmän (engl. *home energy management system*, HEMS) tehtävä, ja kotitalouksien älyjärjestelmien, aurinkovoimaloiden ja akkujen yleistyessä HEMS-strategioista on tullut tärkeä tutkimuskohde [1, 2].

Tässä työssä tavoitteenani on tutkia neuroverkkopohjaisen HEMS-mallin käyttökelpoisuutta aurinkovoimalalla ja akulla varustetun kotitalouden energianhallintaan. Tutkin neuroverkkomallin toimintaa erilaisissa skenaarioissa, joissa varioin akun kytkentää energiajärjestelmässä, ja vertaan sitä yksinkertaiseen ja yleisesti käytettyyn sääntöpohjaiseen HEMS-strategiaan. Kirjallisuudessa esitettyjen koneoppimiseen perustuvien HEMS-mallien mukaisesti [3] myös tässä työssä esiteltyyn neuroverkkomallin etu on sen kyky adaptoitua vaihtuviin olosuhteisiin, mutta se on kuitenkin arkkitehtuuriltaan yksinkertaisempi kuin nämä muut koneoppimiseen pohjautuvat lähestymistavat.

# 1 Työn tausta

## 1.1 Pientuottajien aurinkovoimalat, akut ja sähkösopimukset

### Aurinkovoimalat

Viitataan tässä työssä aurinkoenergiaan lyhenteellä PV, joka tulee englanninkielen termistä *photovoltaic*. Kirjallisuudessa tällä yleisellä termillä viitataan valosähköistä ilmiötä hyödyntäviin teknologioihin, eli aurinkokennoihin ja niistä koostuviin aurinkopaneelisiin ja -voimaloihin. Lisäksi yksiköllä "wattipiikki" Wp (ja sen eri suuruusluokat, kuten MWp) tarkoitan PV-systeemin nimellistehoa.

Aurinkopaneelien hinnan pienentyessä aurinkopaneeleista on tullut suosittu energiatuotantomuoto globaalisti sekä myös Suomessa. Suomessa on tällä hetkellä (tammikuu 2024) 140 kapasiteetiltaan yhden MWp:n ylittäviä aurinkosähkövoimaloita joko toiminnassa (16), rakenteilla (8) tai suunnittelussa (116) [4], joista Lappeenrannan Huuhansuon-Suurisuon aurinkovoimahankkessa on tarkoitus rakentaa yli 1000 MWp:n aurinkovoimala, jonka vuosituotantoennuste 1200 GWh [5] olisi yli kolminkertainen Suomen 400 GWh:n aurinkosähkön kokonaistuotantoon -ja tuontiin vuonna 2022 [6]. Aurinkosähköjärjestelmien erinomaisen skaalautuvuuden ansiosta taloyhtiöiden ja kotitalouksien aurinkosähköjärjestelmät ovat myös yleistyneet hintojen pienentyessä. Kotitalouksia, jotka voivat myydä aurinkovoimaloillaan tuottamaa sähköä verkkoon, kutsutaan pientuottajiksi. Aurinkovoimala tässä yhteydessä tarkoittaa mitä tahansa vähintään yhdestä aurinkopaneelistä koostuvaa energiasysteemiä, joka tuottaa sähköä. Koska aurinkovoimaloiden tuotantohinta (engl. *levelized cost of electricity*, LCOE) on nykyään usein pienempi kuin verkkosähkön ostohinta, on taloudellisesti kannattavaa tuottaa aurinkosähköä omaan käyttöön. Väisänen ym. laskivat 10 kWp:n PV-systeemille Lappeenrannassa LCOE-arvoksi noin 6 c/kWh [7]. Rodríguez-Gallegos ym. taas laskivat LCOE-arvoja PV-systeemeille eri lokaatioissa, ja heidän tuloksiansa perusteella yli 60 asteen leveyspiireillä LCOE on keskimäärin

noin 10 c/kWh [8]. Nämä LCOE-arvot ovat pienempiä kuin myöhemmin työssä esittäminäni keskimääräiset spot-sopimukseen perustuvat sähkön ostohinnat Suomessa vuosina 2019-2022.

En löytänyt julkisia tilastoja pientuottajien määrästä tai pientuottajien aurinkovoiman kokonaiskapasiteetista Suomessa. Inderberg ym. tutkivat työssään [9] Saksan, Norjan ja Yhdistyneen kuningaskunnan (UK) pientuottajakehitystä vuodesta 1990 vuoteen 2016. Kaikissa kolmessa maassa pientuottajien lukumäärä on ollut suuressa kasvussa tutkimusjakson aikana [9], ja tämä kasvutrendi on mitä todennäköisimmin jatkunut vuodesta 2016 eteenpäin. Vuonna 2021 alkaneen energiakriisin aiheuttaman sähkönhintojen suuren nousun jälkeen kotitalouksien kiinnostus aurinkovoimaan on lisääntynyt; kotitalouksien kysyntä aurinkovoimaloille onkin Suomessa ollut viime vuosina tasaisessa kasvussa [10]. Tyypillinen pientuottajan aurinkovoimalan koko Saksassa, UK:ssa ja Suomessa on 4-10 kWp [9–11].

Käytännössä kaikki kotitalouksiin asennettavat aurinkopaneelit ovat yksipuolisia piipaneeleita, joka on tällä hetkellä aurinkopaneelimarkkinoita dominoiva teknologia. Kaksipuoleiset piipaneelit ovat kuitenkin osoittautuneet potentiaalisiksi teknologiksi pohjoisissa olosuhteissa, erityisesti kun paneelit asennetaan pystyyn itä-länsi-suuntaisesti [12, 13]. Tällöin aurinkoisena päivänä tuotannolla on kaksi huippua: yksi aamulla ja toinen illalla. Tämä tuotantoprofiili vastaa paremmin tyypillistä kotitalouden kulutusprofiilia kuin perinteisen etelään suunnatun yksipuoleisen paneelin tuotantoprofiili, jossa on yksi huippu keskipäivän aikaan. Lisäksi pohjoisissa lokaatioissa pystyyn asennetun itä-länsi-suuntaisen kaksipuolisen aurinkopaneelin kokonaistuotanto saattaa olla jopa melkein 10 % suurempi kuin yksipuoleisen etelään suunnatun paneelin [14] ja LCOE pienempi kuin yksipuoleisen etelään suunnatun paneelin [8]. Pystyyn asennettuja paneeleita on kuitenkin vaikea sijoittaa kotitalouden yhteyteen [12], mikä hidastaa niiden laajamittaista yleistymistä.

## Akut kotitalouksissa ja akun mallinnus

Akut eivät ole globaalissa mittakaavassa saavuttaneet vielä samanlaista suosiota kotitalouskäytössä kuin aurinkopaneelit, sillä niiden korkeiden hintojen takia ne eivät usein ole taloudellisesti kannattavia [15–17], vaikka ne selvästi lisäävät kotitalouksien aurinkovoiman tuotannon oman käytön osuutta sekä omavaraisuusosuutta [15–19]. Lisäksi akut auttavat aurinkovoimaloiden kanssa lisäämään kotitalouksien energiasilienssiä: sähkökatkoksen yllättäessä kuluttaja voi käyttää varastoimaansa PV-tuotantoa. Akkujen hinnat ovat viimeisen vuosikymmenen aikana kuitenkin pienentyneet merkittävästi ja tämän laskutrendin ennustetaan jatkuvan [20], jolloin lähivuosikymmenien aikana akuista tulisi taloudellisesti kannattavia kotitalouksien energiajärjestelmiin.

Akullisten kotitalouksien energiajärjestelmien simuloinnissa keskeisimmässä osassa on akun toiminta, joten sen riittävän tarkka mallintaminen on tärkeää todenmukaisten tulosten saamiseksi. Energiajärjestelmien simulaatioissa tärkeimpänä muuttuvana parametrinä on akun lataustila SOC (engl. *state-of-charge*), joka kuvaa akun suhteellista energiavarausta  $E_A$  (kWh) sen maksimikapasiteettiin  $E_A^{\text{MAX}}$  (kWh) nähden

$$\text{SOC} = \frac{E_A}{E_A^{\text{MAX}}}. \quad (1)$$

Kun akkuun varastoidaan tai sieltä puretaan energiaa, SOC:n arvo muuttuu. Kun akkua tarkastellaan osana energiasysteemiä, on akun hyötysuhde huomioitava. Hyötysuhteen takia akkuun varastoitu energia on aina pienempi kuin akun lataukseen käytetty energia, ja samoin akusta purettu energia on pienempi kuin akun latauksen muutos:

$$\text{SOC}_{h+1} = \text{SOC}_h + \eta_{\text{CH}} \frac{P_{\text{CH},h} \Delta t}{E_A^{\text{MAX}}} - \frac{1}{\eta_{\text{DCH}}} \frac{P_{\text{DCH},h} \Delta t}{E_A^{\text{MAX}}}, \quad (2)$$

jossa  $h$  kuvaa ajanhetkeä,  $\Delta t$  hetkien  $h$  ja  $h+1$  välistä aikaa,  $\eta_{\text{CH}}$  ja  $\eta_{\text{DCH}}$  akun lataus- ja purkaushyötysuhdetta sekä  $P_{\text{CH}}$  ja  $P_{\text{DCH}}$  akun lataus- ja purkaustehoa. Joskus



akulle ilmoitetaan vain sen lataus-purkaus-syklin hyötysuhde  $\eta_{RT}$  (engl. *round-trip efficiency*), jolloin laskennallisesti oletetaan  $\eta_{CH} = \eta_{DCH} = \sqrt{\eta_{RT}}$ . Usein simulaatioissa akun hyötysuhteet oletetaan vakioiksi [1]. Todellisuudessa akun ja sen invertterin hyötysuhteet muuttuvat muun muassa lämpötilan sekä hetkittäisten tehojen  $P_{CH}$  ja  $P_{DCH}$  mukaan, mikä saattaa johtaa ylioptimisiin simulaatiotuloksiin käytettäessä yksinkertaistettua akkumallia [1, 21, 22].

Tärkeä seikka simulaatioihin ja akun taloudelliseen arviointiin liittyen on sen ikääntymisen huomioiminen. Akku ikääntyy käytön seurauksena sekä ajan kanssa vaikkei sitä käytettäisi [1]. Energianhallintasimulaatioissa akun ikääntyminen huomioidaan harvoin, vaikka akun käyttöstrategia vaikuttaa suuresti sen käyttöikään ja tätä kautta energiajärjestelmän käytön hintaan [1, 23–25], jolloin simulaatiotulokset saattavat olla taloudellisesti epärealistia. Usein akuille ilmoitetaan niiden käyttöikä lataus-purkaus-sykleinä johonkin (yleensä 20 %:n) kapasiteetin menetykseen (esim. [26]). Tätä käyttöikää kutsutaan käyttökertaiäksi  $N_{\text{life}}$  (engl. *cycle life*). Käyttökertaike riippuu kuitenkin purkaussyvyydestä (engl. *depth of discharge*, DOD) [25, 27, 28]: mitä suurempi DOD, sitä nopeammin akku ikääntyy. Purkaussyvyys DOD tarkoittaa akusta purettavaa suhteellista osuutta täyteen ladattuun akkuun nähden, ja se voidaan esittää SOC:n avulla [25]:

$$\text{DOD} = 1 - \text{SOC}. \quad (3)$$

Käyttökertaike määritellään kirjallisuudessa syklien lukumääränä täydestä kapasiteetistä kyseiseen DOD:iin ja takaisin [25]. Tämä käyttökertaiän ja DOD:n suhde riippuu akusta, eikä sitä usein esitetä akun dokumentaatioissa (engl. *datasheet*). Bocca ym. esittivät työssä [27] yleistetyn mallin eri akkuteknologioiden käyttökertaiälle  $N_{\text{life}}$  ja DOD:lle:

$$N_{\text{life}}(\text{DOD}) = R \frac{r_{\text{EOL}}}{\text{DOD}^\alpha} = R \frac{r_{\text{EOL}}}{(1 - E_A/E_A^{\text{MAX}})^\alpha}, \quad (4)$$

missä  $R$  ja  $\alpha$  ovat riippuvuutta kuvaavia sovitusparametrejä ja  $r_{\text{EOL}}$  prosentuaalinen kapasiteettihäviö (alaviite EOL viittaa termiin käyttöiän loppuun, engl. *end-of-*

*life*). Työssä [27] nämä sovituspäätimet määritettiin akkujen dokumentoinneista. Edelleen yhtälöä (4) käyttäen voidaan kullekin purkaustunnille laskea vastaava akun terveydentilan (engl. *state of health*, SOH) muutos [28]:

$$\Delta\text{SOH}(h) = \frac{1}{N_{\text{life}}(E_{A,h})} - \frac{1}{N_{\text{life}}(E_{A,h-1})}, \quad (5)$$

jossa akku purkaantuu tunnilta  $h - 1$  tunnille  $h$ .

Taulukossa I on esitetty kolmen eri valmistajan kotitalouksiin suunniteltujen akkujen parametreja. Esitettyjen akkujen valmistajista LG ja Tesla ovat suuria kansainvälisiä elektroniikkavalmistajia, kun taas Nelinor on vuonna 2020 Suomessa perustettu pienyritys. Näistä esitellyistä akuista LG:n RESU16H Primeä [29] markkinoidaan akkumarkkinoiden suurimpana kotitalouksiin tarkoitettuna litiumioniakkuna. Powerwall [30] on Teslan kotitalouskäyttöön suunnattu litiumioniakku, jonka uusimmat mallit Powerwall 3 ja Powerwall+ on suunniteltu integroitaviksi aurinkopaneelien kanssa niiden sisäänrakennettujen aurinkopaneeli-invertterien avulla. Nelinorin Grid Battery [31] ajoittaa akunkäytön automaattisesti spot-hintojen perusteella. Nelinorin nettisivuilta ei kuitenkaan selviä tarkemmin, mihin akun toimintastrategia perustuu.

Akkujen kapasiteeteissa ja tehoissa on jonkin verran eroja, erityisesti Nelinorin ja kahden muun esitetyn akun välillä. Yleisesti kotitalouksien akkujen kapasiteetit kuitenkin vaihtelevat välillä 6–16 kWh (6,5 kWh LG:n pienin akku). Tyypillinen suomalainen omakotitalo ilman sähkölämmitystä kuluttaa vuodessa noin 5 MWh sähköä [32], joka vastaa keskimääräisesti 14 kWh:n päivittäistä kulutusta. Tällaisella kulutuksella tyypillinen akku kattaa noin 0,5–1 vuorokauden sähkön tarpeen. Taulukossa I esitetyille akuille ei ole ilmoitettu  $N_{\text{life}}$ :n riippuvuutta DOD:stä, minkä takia oletan, että  $N_{\text{life}}$  kuvaa täysien syklien lukumäärää.

Taulukko I. Kolmen kotitalouskäyttöön tarkoitettujen akujen parametrit.  $E_A^{\text{MAX}}$ : käytettävä kapasiteetti;  $P_{\text{DCH}}^{\text{MAX}}$ : maksimipurkuteho;  $P_{\text{CH}}^{\text{MAX}}$ : maksimilatausteho;  $\eta_{\text{RT}}$ : kokonaishyötysuhde;  $\eta_{\text{DCH}}$ : purkuhyötysuhde;  $\eta_{\text{CH}}$ : lataushyötysuhde;  $C_{\text{AKKU}}$ : akun hinta;  $N_{\text{life}}$ : elinikä.

Akku	$E_A^{\text{MAX}}$ (kWh)	$P_{\text{DCH}}^{\text{MAX}}$ (kW)	$P_{\text{CH}}^{\text{MAX}}$ (kW)	$\eta_{\text{RT}}$ (-)	$\eta_{\text{DCH}}$ (-)	$\eta_{\text{CH}}$ (-)	$C_{\text{AKKU}}$ (EUR)	$N_{\text{life}}$ (kierto)
LG RESU16H Prime	16	7	7	>0,9	0,975 <sup>1</sup>	0,975 <sup>1</sup>	-	-
Tesla Powerwall	13,5	5	5	0,9	-	-	9000 <sup>3</sup>	3000 <sup>4</sup>
Nelinor Grid battery	7	1,8	2,1	-	0,93 <sup>2</sup>	0,93 <sup>2</sup>	4699	6000

<sup>1</sup> DC/DC-muuntajan hyötysuhde

<sup>2</sup> AC/DC-hyötysuhde

<sup>3</sup> Sisältää akun ja asennuksen [33]

<sup>4</sup> Arvioitu 10 vuoden ja 37,8 MWh:n kokonaisvarauksen takuehdoista [34]

## Sähkösopimukset

Suomi on osana Pohjoismaiden ja Baltian maiden yhteisiä tukkusähkömarkkinoita, joiden kaupasta noin 70 % käydään Nord Pool -sähköpörssin kautta [35]. Vuonna 2022 Suomessa ostettiin 55 TWh ja myytiin 48 TWh tuotantoa Nord Poolin kautta [36], kun vastaavasti Suomen kokonaiskulutus oli 82 TWh ja -tuontanto 70 TWh [6]. Tällöin ostetun sähkön kaupasta 67 % ja myydyin sähkön kaupasta 69 % käytiin Nord Poolin kautta. Näillä markkinoilla sähkön pörssihinta (ns. spot-hinta) määräytyy seuraavalle päivälle tehdyistä tunnittaisista tarjouksista (osto ja myynti), jotka julkaistaan kello 13.45 Suomen aikaa [36]. Täten seuraavan vuorokauden tunnittaiset sähkön spot-hinnat julkaistaan jo iltapäivällä.

Suomessa kuluttajat ostavat sähköä sähköyhtiöltä, jotka voivat tarjota eri tyyppisiä sähkösopimuksia. Yleinen sähkösopimusmuoto Suomessa on kiinteähintainen sopimus, jolloin sähköyhtiö veloittaa sähköstä kiinteän hinnan energiayksikköä kohden (c/kWh). Sopimus voi olla toistaiseksi voimassa oleva tai määräaikainen. Lisäksi jot-

kut yhtiöt tarjoavat kiinteähintaisia sopimuksia, joissa yösähkölle on oma matalampi hintansa. Kiinteähintaisen sopimuksen lisäksi sähköyhtiöt tarjoavat pörssisidonnaisia sopimuksia, jolloin asiakas maksaa sähkön spot-hinnan lisäksi sähköyhtiölle sen määräämän välityspalkkion. Sähkösopimustyyppistä riippumatta sähkölasku koostuu sähköenergian lisäksi sähköjakeluyhtiön veloittamasta sähkön siirtopalvelun hinnasta (kiinteä hinta kilowattituntia kohden), huoltovarmuusmaksusta, sähköverosta ja arvonlisäveroista. Huoltovarmuusmaksu ja sähkövero tyypillisesti maksetaan siirtomaksun yhteydessä. Näiden hintakomponenttien lisäksi sähköyhtiö perii asiakkaalta kiinteän kuukausittaisen perusmaksun. [37]

Myydäkseen aurinkopaneeleilla tuotetun ylimääräisen sähkön (ylituotannon) verkkoon täytyy pientuottajan tehdä erillinen myyntisopimus sähköyhtiön kanssa. Myyntisopimus perustuu sähkön spot-hintaan siten, että myydystä sähköstä maksetaan verottoman spot-hinnan ja välityspalkkion erotus. Esimerkiksi sähköyhtiöt Helen [38] ja Vattenfall [39] tarjoavat tällaisia sopimuksia, joissa välityspalkkot ovat 0,2 c/kWh ja 0,3 c/kWh. Molemmat yhtiöt vaativat myyntisopimuksen tekemiseksi asiakkaan aurinkovoimalan nimellistehon olevan enintään 100 kWp ja sähkön ostosopimusta samoilta yhtiöiltä.

Pientuottajan sähkön osto- ja myyntihinnat ovat siis

$$p_{\text{osto}} = \begin{cases} p_{\text{spot}} \cdot (1 + \text{ALV}) + p_{\text{välitys}} + p_{\text{siirto}}, & \text{spot-sopimuksille} \\ p_{\text{sähkö}} + p_{\text{siirto}}, & \text{kiinteille sopimuksille} \end{cases} \quad (6)$$

$$p_{\text{myynti}} = p_{\text{spot}} - p_{\text{välitys}}, \quad (7)$$

missä  $p_{\text{spot}}$  on sähkön spot-hinta, ALV on 24 %:n arvonlisävero,  $p_{\text{välitys}}$  on sähköyhtiön veloittama välityspalkkio,  $p_{\text{siirto}}$  on siirtomaksu, joka sisältää myös huoltovarmuusmaksun sekä sähköveron ja  $p_{\text{sähkö}}$  on kiinteä sähköhintaa (sisältää ALV:n).

Eri valtioissa sekä eri kuluttajaryhmille kotitalouksien lisäksi (esim. teollisuus) on edellä kuvattujen lisäksi myös muita malleja sähkön osto- ja myyntihinnoille, joita kutsutaan yleisesti tariffeiksi [40]. Tällaisia ovat esimerkiksi yösähkön kaltainen

käyttöaikaan (engl. *time-of-use*, ToU) perustuva tariffi ja kulutuksen mukana kasvava tariffi [41]. Monissa valtioissa on pientuottajien myymälle aurinkoenergiatuotannolle myös erilaisia ns. syöttötariffeja, joilla pyritään tekemään pientuotannosta kannattavaa. Tyypillisesti syöttötariffi on kiinteähintainen ja perustuu esimerkiksi aurinkovoiman tuotantohintaan (LCOE) [42]. Tällöin ylituotanto ei teoriassa tuota pientuottajalle tappioita toisin kuin pörssisähköön sidottu myyntihinta, jolloin sähkön spot-hinnan ollessa pieni saattaa ylituotannon myyntihinta olla pienempi kuin aurinkovoimalan tuotantohinta. Syöttötariffi voi myös perustua sähkön markkinahintaan, jolloin spot-hintaan lisätään preemiohinta, joka voi olla kiinteä tai muuttuva [42]. Tällaista markkinahintaan perustuvaa syöttötariffia kutsutaan markkinapreemioksi. Suomessa aurinkovoimatuotannolle ei kuitenkaan ole minkäänlaisia syöttötariffeja, vaan myyntihinta on yhtälön (7) mukaisesti sidottu markkinahintaan ja aina pienempi kuin sähkön ostohinta.

## 1.2 Neuroverkko

Neuroverkolla tarkoitetaan koneoppimiskontekstissa mallia, joka jäljittelee biologisen neuroverkon toimintaa. Neuroverkko koostuu biologisen neuroverkon tapaan yhteenkytketyistä neuroneista, ja sen koulutus perustuu neuronien välisten kytkentöjen vahvistamiseen tai heikentämiseen. Neuroverkkojen arkkitehtuuri, eli neuronien ja kytkentöjen määrä sekä kytkentöjen suunta, vaihtelee riippuen sovellusongelmasta. Ensimmäistä kertaa neuroverkon konseptin esitteli neuropsykologi Warren McCulloch vuonna 1943 [43]. Tämän jälkeen neuroverkkojen suosio on vaihdellut kausittain, ja tällä hetkellä se on ollut suuressa kasvussa laskentayksiköiden muistin ja laskentatehon suuren kasvun tarjoamien resurssien ansiosta [44]. Neuroverkot ovat käyttökelpoisia monissa sovelluskohteissa, sillä ne voivat teoriassa approksimoida mitä tahansa funktiota. Neuroverkkomalleja käytetäänkin laajalti eri sovelluksissa niin regressio- kuin luokitteluongelmissa. Seuraavat neuroverkkoja käsittelevät lu-

vut perustuvat pääasiassa Aurélen Géronin kirjaan *Hands-On Machine Learning with Scikit-Learn, Keras & TensorFlow* [45].

### Monikerroksinen perseptroniverkko

Yksi yleisimmistä ja yksinkertaisimmista neuroverkkoarkkitehtuureista on monikerroksinen perseptroniverkko (engl. *multilayer perceptron*, MLP), joka koostuu useasta yhteenkytketystä perseptronikerroksista. Perseptroni tarkoittaa yksinkertaista neuroverkkoarkkitehtuuria, joka koostuu yhdestä neuronista, useasta syötteestä ja yhdestä tulosteesta. Perseptronikerroksella tarkoitetaan useaa rinnakkaista perseptronia, jossa syötteet ovat yhteydessä kuhunkin neuroniin ja neuroneilla on oma tulosteensa. Kuvassa 1 on esitetty MLP:n havainnekuva. Sen (ja yleisesti neuroverkon) tehtävä on kuvata syöte tulosteeksi. Syöte on moniulotteinen vektori  $\mathbf{x}$ , joka koostuu useasta muuttujasta  $x_i$ , ja tuloste on joko skalaari  $y$  tai moniulotteinen vektori  $\mathbf{y}$ . Syöte- ja tulostekerroksien välissä on vähintään yksi piilokerros. Piilokerroksen leveys tarkoittaa neuronien määrää kerroksessa, ja se voi vaihdella eri kerroksien välillä. Kaikki kerrokset ovat MLP:ssä täydellisesti kytkettyjä, eli jokaisen kerroksen jokainen neuroni on yhteydessä jokaiseen seuraavan kerroksen neuroniin. Jokaista neuronien  $j$  ja  $k$  välistä yhteyttä vastaa paino  $w_{jk}$ , joka indikoi näiden neuronien kytkennän vahvuutta. Lisäksi jokaiseen neuroniin (pl. syötekerros) liittyy vakiotermi  $b$  (engl. *bias neuron*). Nämä painot  $w_{jk}$  ja vakiotermit  $b_j$  ovat neuroverkon parametreja, ja niihin viitataan kootusti symbolilla  $\boldsymbol{\theta}$ . Kussakin neuronissa lasketaan siihen saapuvien syötteiden painotettu summa

$$z_j = w_{j1}a_1 + w_{j2}a_2 + \dots + w_{jn}a_n + b_j = \mathbf{w}_j^T \cdot \mathbf{a} + b_j, \quad (8)$$

missä  $a_i$  ja  $w_{ji}$  ovat neuroniin  $j$  saapuvat  $i$ :nnes syöte ja vastaava painokerroin ja  $b_j$  vakiotermi. Tässä työssä käytän kerrosten välisille lähdeille ja syötteille symbolia  $a$  ja koko neuroverkon syötteelle ja tulosteelle symboleita  $x$  ja  $y$ . Tämän jälkeen neuronin lähtö saadaan ajamalla summa jonkin aktivaatiofunktion  $g$  läpi. Täten

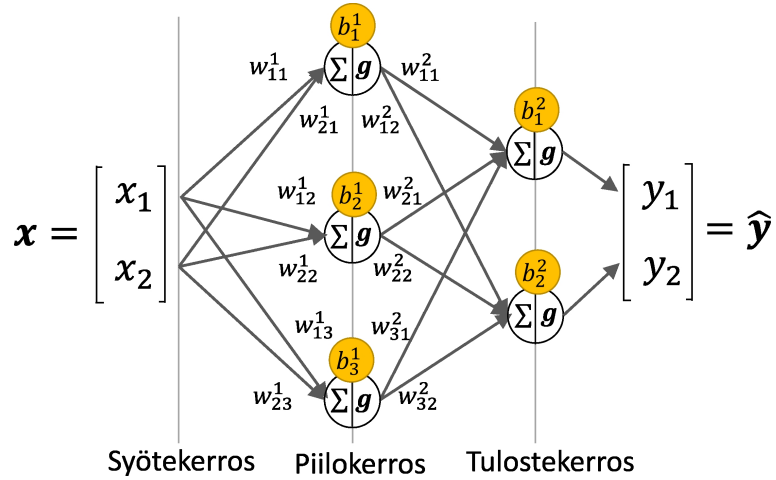
kerroksen  $l$  neuronin  $j$  lähtö  $a_j$  saadaan vektorimuodossa:

$$a_j^{[l]} = g^{[l]} \left( \mathbf{w}_j^{[l]} \cdot \mathbf{a}^{[l-1]} + b_j^{[l]} \right) = g^{[l]} \left( z_j^{[l]} \right), \quad (9)$$

missä  $\mathbf{a}^{[l-1]}$  kuvaa edellisen kerroksen lähtövektoria. Kun  $L$  kuvaa painollisten kerrosten lukumäärää (piilokerroksien lukumäärä on tällöin  $L - 1$ ), on  $\mathbf{a}^{[L]} = \hat{\mathbf{y}}$ . Yhtälö (9) voidaan yleistää matriisimuotoon

$$\mathbf{a}^{[l]} = g^{[l]} \left( \mathbf{W}^{[l]} \mathbf{a}^{[l-1]} + \mathbf{b}^{[l]} \right), \quad (10)$$

missä  $\mathbf{W}^l$  on piilokerroksen painomatriisi, joka sisältää kaikki kerroksen  $l$  painovektorit  $\mathbf{w}_j^{[l]}$ . Tuloste  $\hat{\mathbf{y}}$  muodostuu siis useista peräkkäisistä vektorioperaatioista; tätä tulosteen muodostumista syötteestä kutsutaan läpisyötöksi (engl. *forward pass*).



Kuva 1. Havainnekuva MLP:stä.

Usein MLP:ssä käytetään epälineaarisia aktivaatiofunktioita, jolloin sillä voidaan approksimoida epälineaarisia funktioita. Yksi käytetyimmistä aktivaatiofunktioista on leikattu lineaarifunktio (engl. *rectifier linear unit*, ReLU), joka on muotoa

$$\text{ReLU}(z) = \max(0, z), \quad (11)$$

missä  $z$  on neuroniin saapuvien edellisen kerroksen lähtöjen ja vakiotermin painotettu summa (yhtälö (8)). Toinen yleisesti käytetty aktivaatiofunktio on logistinen

funktio  $S$ , joka muuntaa neuronin tulosteen välille  $[0, 1]$ :

$$S(z) = \frac{1}{1 + e^{-z}}. \quad (12)$$

### Neuroverkon koulutus

Neuroverkon koulutuksen tarkoitus on löytää sellaiset verkon parametrit  $\theta$ , joilla saadaan approksimoitua tavoitesuuretta mahdollisimman hyvin käyttäen koulutusdatajoukkoa  $\{\mathbf{x}_i\}_{i=1}^n$  ja valittua neuroverkkomallia. Datajoukko voidaan esittää matriisina  $\mathbf{X}$ , joka sisältää  $n$  kappaletta syötevektoreita  $\mathbf{x}_i$  eli datapisteitä, jotka vastaavat matriisin vaakavektoreita. Tyypillisesti data jaetaan koulutus- ja testijoukkoon esimerkiksi 80/20-jakosuhteella. Neuroverkko koulutetaan koulutusdatajoukolla ja koulutetun mallin suorituskyky mitataan testijoukolla. Datan jako erillisiin joukkoihin on välttämätön osa neuroverkon koulutusta. Mallin suorituskykyä ei nimittäin voi arvioida riippumattomasti sen koulutukseen käytetyn datan avulla, koska tulokset on optimoitu juuri tälle datajoukolle. Tämän takia mallin lopullinen suorituskyky tulee mitata erillisellä testijoukolla, jota ei ole käytetty mallin koulutukseen.

Mallin koulutus perustuu jonkin sakkofunktion minimointiin verkon parametrien  $\theta$  suhteen. Sakkofunktion tarkoitus on kuvata neuroverkon suorituskykyä sille tarkoitettussa tehtävässä. Yksi yleisesti käytetty sakkofunktio regressio-ongelmissa on keskimääräinen prosentuaalinen virhe (engl. *mean absolute percentage error*, MAPE)

$$\text{MAPE} = \frac{1}{n} \sum_{i=0}^n |(\mathbf{y}_i - \hat{\mathbf{y}}_i) \oslash \mathbf{y}_i|, \quad (13)$$

missä  $n$  on dataerän koko,  $\hat{\mathbf{y}}$  on ennustettu tuloste,  $\mathbf{y}$  vastaava oikea tunnettu tuloste ja  $\oslash$  tarkoittaa vektorien jakolaskua alkioittain.

Neuroverkon koulutuksessa hyödynnetään usein vastavirta-algoritmia (engl. *back-propagation*). Se alkaa edellä kuvatulla läpisyötöllä, jolloin joko yhdelle datapisteelle tai dataerälle (engl. *batch*) lasketaan tulosteet. Tämän jälkeen määritetään tulosteen ennustevirhe  $J$  laskemalla sakkofunktion arvo. Tämän virheen avulla lasketaan kun-



kin neuroverkon parametrin (painon ja syötteen) vaikutus tähän virheeseen. Parametrien kontribuutio virheeseen voidaan laskea virheen gradientin  $\nabla_{\theta} J$  avulla käyttäen derivaatan ketjusääntöä, jolloin

$$\frac{\partial J}{\partial \theta_{jk}^{[l]}} = \frac{\partial J}{\partial a_k^{[l]}} \frac{\partial a_k^{[l]}}{\partial \theta_{jk}^{[l]}} \quad (14)$$

missä  $J$  on ennustusvirhe (sakko),  $\theta_{jk}^{[l]}$  kerroksen  $l$  parametri (paino tai vakiotermi) ja  $a_k^{[l]}$  kerroksen  $l$  neuronin  $k$  lähtö. Tällä ketjusäännöllä lasketaan kaikkien verkon parametrien vaikutus sakkoon  $J$  rekursiivisesti lähtien tulostekerroksesta  $L$ . Koska lähtö kerrokselle  $l$  saadaan ajamalla yhtälön (8) mukainen summa aktivaatiofunktion läpi, tulee aktivaatiofunktion olla derivoituva (huom. ReLU ei ole differentioituva kohdassa 0, mutta se on silti yksi yleisimmistä aktivaatiofunktioista).

Kun neuroverkon parametrien kontribuutio virheeseen on laskettu, parametrejä  $\theta$  muutetaan virheen gradientin suuntaan siten, että virhe pienenee. Tätä vaihetta kutsutaan optimointiaskeleeksi, ja tällä hetkellä yleisimmin käytetty algoritmi siihen on Adam-optimoija (engl. *adaptive moment estimation*) [46]. Adam-menetelmässä lasketaan edellisten vastavirtaiteraatioiden gradienttien ja gradienttien neliöiden, ns. ensimmäisen ja toisen momentin, painotetut keskiarvot  $\hat{m}^1$  ja  $\hat{m}^2$ , joiden tarkoitus on tehdä verkon koulutuksesta stabiili. Neuroverkon parametrit  $\theta$  päivitetään käyttäen näitä momentteja

$$\theta_i \leftarrow \theta_{i-1} - \gamma \hat{m}^1 \oslash \left( \sqrt{\hat{m}^2 + \epsilon} \right), \quad (15)$$

missä  $\gamma$ -parametri on optimointiaskeleen askelpituus ja kuvastaa, kuinka nopeasti parametrit muuttuvat. Nollalla jaon estämiseksi nimittäjään lisätään pieni vakioterminvektori  $\epsilon$ . Adam-algoritmiin voidaan lisätä regularisaatiovaihe (kuten esimerkiksi tässä työssä käyttämässäni Pythonin PyTorch-kirjaston Adam-funktiossa), jolloin momenttien gradientteihin lisätään neuroverkkojen parametrit skaalattuna regularisaatiokertoimella  $\lambda$ :

$$\mathbf{g}_i = \nabla_{\theta} J_i(\theta_{i-1}) + \lambda \theta_{i-1}, \quad (16)$$

missä  $\mathbf{g}_i$  on momenteissa käytettävä regularisoitu gradientti. Regularisaation lisäämisen rajoittaa parametrien suuruutta (optimointiaskel otetaan gradientista vastakkaiseen suuntaan (yhtälö (15))), mikä auttaa estämään verkon ylisovitusta koulutusdataan.

Koska syötedatan muuttujilla on usein erilaiset kokoluokat (esimerkiksi akun SOC on välillä  $[0,1]$  ja kotitalouden sähkönkulutus yksikössä kWh), on usein tarpeellista skaalata muuttujat samaan suuruusluokkaan. Muutoin neuroverkon koulutuksessa saatetaan tarpeettomasti painottaa lukuarvoltaan suuria muuttujia. Kaksi tyypillistä syötedatan skaalausta on minimi-maksimi-skaalaus ja standardointi. Minimimaksimi-skaalauksessa muuttuja  $\mathbf{X}^{(i)}$  (esim. sähkönhinta) skaalataan välille  $[0,1]$ :

$$\tilde{\mathbf{X}}^{(i)} = \frac{\mathbf{X}^{(i)} - \min(\mathbf{X}^{(i)})}{\max(\mathbf{X}^{(i)}) - \min(\mathbf{X}^{(i)})}, \quad (17)$$

missä  $\tilde{\mathbf{X}}^{(i)}$  on skaalattu muuttujavektori. Standardoinnissa muuttuja skaalataan siten, että muuttujavektorin  $\mathbf{X}^{(i)}$  elementtien keskiarvo on 0 ja keskihajonta 1:

$$\tilde{\mathbf{X}}^{(i)} = \frac{\mathbf{X}^{(i)} - \mu_i}{\sigma_i}, \quad (18)$$

missä  $\mu_i$  ja  $\sigma_i$  ovat sarakevektorin  $\mathbf{X}^{(i)}$  keskiarvo ja keskihajonta. Jotta mallin koulutuksen päätteeksi laskettava testivirhe ei olisi vinoutunut, muuttujien skaalaus tulee tehdä käyttäen vain koulutusdatajoukkoa. Testijoukko skaalataan käyttäen koulutusdatajoukon skaalauksia, jolloin esimerkiksi testijoukon muuttujan standardoinnissa käytetään vastaavaa koulutusjoukon keskiarvoa ja -hajontaa.

Edellä kuvattua vastavirta-algoritmia toistetaan iteroimalla koulutusdatajoukkoa läpi dataerissä. Yhtä iteraatiota koko koulutusjoukon läpi kutsutaan epokiksi. Koulutusjoukko voidaan jakaa edelleen koulutukseen käytettävään osaan ja validaatioosaan, jolloin vain koulutusosaa käytetään mallin koulutukseen. Validaatio-osaa voidaan käyttää mallin koulutuksen aikaiseen suorituskyvyn mittaamiseen laskemalla

epokkien välissä ennustevirhe validaatiojoukolle. Tämä virhe kuvaa mallin yleistyvyttä. Koulutuksen aikana koulutusdatasta laskettu koulutusvirhe ja validaatiovirhe laskevat, kun malli oppii approksimoimaan syötteen ja tulosteen välistä funktiota. Joskus koulutuksesta saattaa seurata kuitenkin mallin ylisovitus, jolloin malli tuottaa matalan koulutusvirheen, mutta ei yleisty muihin instansseihin koulutusjokouksen ulkopuolella, jolloin validaatiovirhe kasvaa. Tämän ylisovituksen estämiseksi mallin koulutus voidaan lopettaa siihen pisteeseen, jolla saadaan matalin validaatiovirhe. Tätä menettelyä kutsutaan aikastetuksi lopetukseksi (engl. *early stopping*).

Koska muokattavia neuroverkkomallin hyperparametrejä on lukuisia (neuroverkon syvyys, leveys, aktivaatiofunktiot yms.), usein parhaiden hyperparametrien löytämiseksi tehdään mallinvalinta. Yksinkertaisuudessaan mallinvalinnassa kullekin säädettävälle hyperparametrille kokeillaan useaa vaihtoehtoa, jolloin ne muodostavat hyperparametriavaruuden. Tämän joukon kaikki pisteet (eli eri hyperparametrikombinaatiot) voidaan käydä erikseen läpi, jolloin puhutaan ruudukkohausta (engl. *grid search*). Tällä tavoin löydetään hakuavaruuden rajoissa paras malli. Alhaisinta validaatiovirhettä voidaan käyttää parhaan mallin kriteerinä. Tällaisessa mallinvalinnassa huomattavaa on kuitenkin se, että parhaan mallin validaatiotulos on vinoutunut, jolloin mallin lopulliseen suorituskäyvyn arviointiin tulee käyttää koulutus- ja validaatiojoukoista riippumatonta testijoukkoa, jota ei ole käytetty koulutuksessa millään tavoin.

### 1.3 Energianhallintastrategiat

Kodin energiajärjestelmät koostuvat useasta eri komponentista kuten kontrolloitavista ja kontrolloimattomista kuormista sekä mahdollisesta akusta, aurinkovoimalasta ja sähköautosta. Näiden komponenttien hallintaa kutsutaan kodin energianhallinaksi (engl. *home energy management*, HEM), jonka ohjaavaa päätöksentekoa kutsutaan kodin energianhallintajärjestelmäksi (HEMS). Energiajärjestelmän dynaamisten kom-

ponenttien takia HEMS:n strategisointi ei ole triviaalia. Han ym. käyvät katsausartikkelissaan [2] läpi lukuisia HEMS-strategioita, jotka voidaan jakaa pääpiirteissään kolmeen kategoriaan, kuten Azuatalam ym. työssään [1] esittävät:

### Sääntöpohjaiset strategiat

Yleisimpiä HEMS-strategioita ovat yksinkertaiset sääntöpohjaiset (engl. *rule-based*) heuristiset mallit. Niissä energianhallinta perustuu ennalta määrättyihin sääntöihin. Tällaisia strategioita ovat esimerkiksi itse käytetyn energian osuuden maksimointi (engl. *self-consumption maximization*, SCM) ja sähkönhintatariffeihin perustuvat strategiat, kuten ToU tariffiin perustuva aikatariffiarbitraasi (engl. *time-of-use arbitrate*, ToUA) [1], jossa akkua ladataan halvan sähkönhinnan aikana ja puretaan kalliin sähkönhinnan aikaan.

SCM:n toimintaperiaate on seuraavanlainen: PV-tuotanto käytetään ensisijaisesti oman kulutuksen kattamiseen ja toissijaisesti akun lataukseen. Jos akku on ladattu täyteen, ylituotanto myydään verkkoon. Vastaavasti kulutus pyritään kattamaan ensin PV-tuotannolla, sitten akkuun varastoidulla sähköllä ja lopuksi ostamalla sähköä verkosta. Tarkempi SCM:n toiminnan kuvaus on esitetty myöhemmin osiossa 2.1. Sähkön hintaa ei siis huomioida SCM-strategiassa, jolloin energianhallinta saattaa olla taloudellisesti epäoptimaalista, erityisesti jos sähköhinnoissa on suurta vaihtelua vuorokausitasolla, kun akkua ladataan (tyypillisesti päivällä) ja puretaan (yöllä). Tästä huolimatta simuloidussa vuosittaisessa sähkölaskussa ei välttämättä ole suurta eroa SCM-strategialla ja edistyksekkäämmillä sähkönhinnan huomioivilla strategioilla [1, 23]. Azuatalam ym. toteavat [1], että heidän työssään SCM ei taloudellisesti eroa juurikaan muista strategioista, sillä tulokset perustuvat yksinkertaiseen akkumalliin ja muut strategiat hyödyntävät mahdollisesti epätarkkoja tuotanto- ja kulutusennusteita. Lisäksi heidän työssään syöttötariffi on kiinteä ja aina pienempi kuin ToU-tariffiin perustuva ostohinta, jolloin taloudellisesti kan-

nattavinta on käyttää tuotanto itse. Akun DOD on kuitenkin SCM-strategialla keskimäärin suurempi kuin muilla strategioilla, jolloin akun elinikä on myös lyhyempi [1, 24] ja edelleen akunkäytön hinta korkeampi [23]. Zou ym. vertasivat työssään [23] SCM:llä ja optimointimenetelmällä saatuja sähkölaskuja, joista SCM:n sähkölasku oli itse asiassa pienempi. He eivät esittäneet selitystä tulokselle. Akunkäytön hinnan takia kokonaishinta oli SCM:llä kuitenkin suurempi kuin optimointistrategialla [23]. Yksinkertaisuutensa ja yleisyytensä takia SCM on käyttökelpoinen referenssi-strategia, johon monimutkaisempia strategioita voidaan verrata [23, 24, 47]. Usein myös energiasysteemien mitoitukseen käytetään SCM:ää [48].

### Optimointistrategiat

Optimointistrategiat ovat suosittuja HEMS:n ohjaukseen. Ne perustuvat yhden tai usean suureen matemaattiseen optimointiin, yleensä sähkölaskun minimointiin tietyn optimointihorisontin, esimerkiksi kahden vuorokauden ajalta. Tunnittaisella toimintaresoluutiolla tämä tarkoittaa kahden vuorokauden horisontilla sitä, että tuntia  $h$  vastaavat toiminnot päätetään optimoimalla sakko välillä  $[h, h + 48]$ . Toimintojen seurauksena saadaan akun tila seuraavalle tunnille  $h + 1$ , ja optimointi suoritetaan jälleen käyttäen uutta horisontin määräämää väliä. Koska optimointi suoritetaan lähitulevaisuuden datalla, kulutuksen ja tuotannon ennustaminen ovat oleellinen osa optimointistrategioita [1]. Optimointi on laskennallisesti raskasta ja tulosteiden saaminen vie enemmän aikaa kuin sääntöpohjaisilla strategioilla [1]. Yleisesti käytettyjä optimointimenetelmiä HEMS-ongelmiin ovat lineaariset ohjelmointimenetelmät, kuten MILP (engl. *mixed integer linear programming*), Markovin päätösprosesseihin (engl. *Markov decision process*) perustuva dynaaminen ohjelmointi (engl. *dynamic programming*) sekä erilaiset luonnon inspiroimat heuristiset optimointimenetelmät, kuten geneettiset algoritmit [1, 2].

## Koneoppimiseen pohjautuvat strategiat

HEMS-strategioissa voidaan hyödyntää koneoppimiseen pohjautuvia menetelmiä, jotka tässä kirjallisuusselvityksessä olen jakanut vahvistusoppimismenetelmiin sekä muihin neuroverkkomalleihin. Kirjallisuusselvitykseni relevanteimmat työt on koottu taulukkoon II.

**Vahvistusoppimismallit** (engl. *reinforcement learning*, RL) ovat suuressa suosiossa koneoppimista hyödyntävissä HEMS-strategioissa. Vahvistusoppiminen on koneoppimisen alakategoria, jossa mallin koulutuksessa ei käytetä merkittäviä tulosteita ennusteen virheen laskemiseen. Sen sijaan mallin päätöksiä tekevä niin sanottu agentti (HEMS:n tapauksessa esimerkiksi akku) oppii toimintamallin kokeilemalla erilaisia toimintoja erilaisissa ympäristöissä (joka koostuu esim. hetkittäisestä kulu- tuksesta, tuotannosta ja sähkönhinnasta). Toiminnon seurauksena systeemi siirtyy seuraavaan tilaan (uusi SOC) sekä ympäristöön, ja toiminnasta saadaan jokin palk- kio [45]. Palkkio yleensä perustuu sähkölaskuun, mutta voi tämän lisäksi sisältää muita suureita, kuten kotitalouden käyttäjämukavuuden [3, 49] ja akun ikääntymi- sen [50]. Vahvistusoppimismallin tavoitteena on estimoida tiloille toimintatavat, jolla odotettu tulevaisuuden palkkio maksimoidaan. Usein siirtymät tilasta toiseen mal- linnetaan stokastisina prosesseina, jolloin mallin tulosteet kuvaavat todennäköisyyk- siä. Tämä koneoppimisen paradigma soveltuu hyvin HEMS-ongelmaan, sillä siinä ei ennestään tunneta tavoitetulosteita eri toiminnoille. Lisäksi vahvistusoppimisen vah- vuus HEMS-strategiana on se, että se voi adaptoitua ajon aikana tekemään päätök- set siten, että se maksimoi tulevaisuuden odotetun palkkion [49, 51]. Kun ympäristö on moniulotteinen ja sen muuttujat sekä toiminnot jatkuvia, vahvistusoppimismallit hyödyntävät yhtä tai useampaa neuroverkkoa. Tällöin ne saattavat kuitenkin olla epästabiileja [52], jolloin malli ei opi järkeviä toimintatapoja. Eräs ratkaisu tähän on ympäristön diskretisointi [3, 49], jolloin esimerkiksi akun SOC jaetaan diskreetteihin arvioihin.

Vahvistusoppimismalleja on käytetty niin yksittäisten kotitalouksien akkujen toimintojen ajoittamiseen [53, 54], kuin myös kotitalouksien kulutuksen hallintaan [3, 49, 50]. Kotitalouksien älyjärjestelmien ja sähköajoneuvojen lisääntyessä kulutuksen hallinta ja kodin eri laitteiden kuormien koordinointi on noussut tärkeäksi tutkimuskohteeksi. Kun laitteiden toiminta on toisistaan riippumatonta, voidaan kullekin laitteelle määrätä oma agentti, jolloin energiajärjestelmä mallinnetaan moniagenttiongelmanä [49]. Tällöin kulutuksen hallinta optimoidaan siten, että kukin agentti löytää itselleen parhaan toimintamallin, jolla kokonaispalkkio maksimoidaan. Moniagenttilähestymistapaa voidaan hyödyntää myös useasta kotitaloudesta koostuvien energiakomunien [55] ja mikroverkkojen [56] optimointiin.

**Neuroverkkomalleja** käytetään usein myös osana HEMS-strategiaa. Zhang ym. käyttivät työssään [57] MLP:tä asuintalon ilmastointilaitteen toiminnan approksimointiin, ja tätä approksimaatiota käytettiin edelleen kulutuksen hallintaan optimointistrategialla. Lee ym. hyödynsivät [3] neuroverkkoa talon sisälämpötilan approksimointiin ulkolämpötilasta ja ilmastointilaitteen tilasta, ja tätä approksimaatiota he hyödynsivät edelleen kulutuksen hallinnan optimointiin vahvistusoppimismallilla. Lisäksi neuroverkkoja käytetään usein eri energianhallintaan liittyvien suureiden lähitulevaisuuden arvojen ennustamiseen (tyypillisesti seuraavalle vuorokaudelle), jolloin näitä ennusteita voidaan käyttää syötteenä HEMS-strategian algoritmissa. Tällaisia suureita ovat PV-tuotanto [49, 54], kulutus [54, 58] ja sähkönhinta [49, 53]. Neuroverkkomalleja on myös sovellettu HEMS-strategiana yhdessä optimointistrategioiden kanssa siten, että neuroverkko koulutetaan käyttäen optimointistrategialla saatuja toimintoja [1, 59]. Tällä tavoin saatu approksimatiivinen malli on nopeampi sekä mahdollisesti vähemmän altis ennustusvirheille kuin pelkkään optimointiin perustuva malli [1].

Taulukko II. Koneoppimiseen pohjautuvien strategioiden kuvauksia. Lyhenne *RL* viittaa englannin kielen termiin *reinforcement learning*, joka tarkoittaa vahvistusoppimista. Lyhenne *ANN* tarkoittaa neuroverkkoa.

Vahvistusoppimismallit							
Malli	Tehtävä	Tariffi	PV	Akku	Sakko/palkkio	Referenssi	Lähde
Moniagentti	Kulutuksen hallinta, sähköauton lataamisen ajoitus	Dynaaminen	Kyllä	Ei	Sähkölasku ja kuluttajatytyväisyys	Globaali optimi ja Geneettinen optimointialgoritmi (RL parempi)	[49]
Yksi agentti	Kulutuksen ajoitus ja akun ajoittaminen	ToU	Kyllä	Kyllä	Sähkölasku, kuluttajatytyväisyys ja akun yli- ja alilataus	MILP (RL:llä 14 % pienempi sähkölasku)	[3]
Yksi agentti	Kulutuksen ajoitus ja akun ajoittaminen	Dynaaminen	Kyllä	Kyllä	Sähkölasku, akun ikääntyminen ja sisälämpötilan muutos	Globaali optimi (RL:llä 40 % suurempi keskimääräinen sähkölasku)	[50]
Moniagentti	Energiakommuunin energianhallinta	Dynaaminen/ToU	Kyllä	Kyllä	Sähkölasku	Eri skenaariot	[55]
Neuroverkkomallit							
Malli	Tehtävä	Arkkitehtuuri (syöte x piilot x tuloste)	Optimoija	Aktivaatio	Suorituskyky	Referenssi	Lähde
MLP	Sähköhinnan ennustaminen seuraavalle vuorokaudelle	24x40x24	Ei tietoa	Ei tietoa	Seuraavan tunnin MAPE (9,34 %)	-	[49]
MLP	Tuotannon ennustaminen seuraavalle vuorokaudelle	24x20x24	Ei tietoa	Ei tietoa	Seuraavan tunnin MAPE (8,82 %)	-	[49]
MLP	asunnon sisälämpötilan approksimointi	5x17x17x17x1	Adam	ReLU	Ei tietoa	-	[3]
Takaisinkytketty ANN	Kotitalouskulutuksen ennustaminen	?x20x20x1	Adam	Logistinen/Tanh	MAPE (44 %, 3 %-yksikköä parempi kuin paras referenssi)	Empiirisiä ja kirjallisuudessa esitettyjä ANN malleja	[58]



## 1.4 Tutkimuskysymykset

Tässä työssä keskityn akun toiminnan ajoittamiseen aurinkovoimalan kanssa, jolloin HEMS-strategialla tarkoitan tuotannon ja varastoinnin hallintastrategiaa. Keskityn kahteen HEMS-tutkimuksen ongelmaan. Ensiksi esitän neuroverkkoon pohjautuvan vahvistusoppimismallin kotitalouden energianhallintaan. Malli muistuttaa yksinkertaisia toimintagradietti-menetelmiä (engl. *policy gradient*) [60], mutta on toiminnaltaan yksinkertaisempi ja intuitiivisempi. Kirjallisuusselvitykseni perusteella toimintagradietti-menetelmiä on käytetty HEMS-ongelmissa hyvin vähän [51] ja aurinkovoimala-akku-kontekstissa ei lainkaan. Havainnollistan mallin toimintaa vertaamalla sitä yleisesti käytettyyn sääntöpohjaiseen SCM-strategiaan.

Kirjallisuusselvitykseni mukaan aurinkovoimala-akku-systeemien energianhallinnasta ei Suomessa ole tehty julkista tutkimusta. Maamme sääolosuhteiden sekä dynaamisen sähköhinnoittelun takia muualla maailmalla tehtyjen tutkimusten tuloksia ei voida suoraan hyödyntää, vaan energianhallintaskenaariot pitää tutkia käyttäen paikallista dataa. Esitän työssäni erilaisia skenaariota, joissa varioin akun toimintaa. Nämä skenaariot havainnollistavat akun ja aurinkovoimalan taloudellisia vaikutuksia kotitalousjärjestelmässä Suomen olosuhteissa. Tämä teknoekonominen energianhallinnan tutkimus on tärkeää, jotta pientuottajien aurinkovoiman ja akun käytön kannattavuus saadaan maksimoitua. Kotitalouksien taloudellisella akunkäytöllä voidaan hyötyä myös yhteiskunnan tasolla, sillä energian varastoinnin ansiosta kotitaloudet voivat olla käyttämättä verkkosähköä tuotantopulan aikana (tuotantopulan aikana turvaudutaan säätövoimaan, jonka tuotantohinta on usein kallista, mikä johtaa korkeaan sähkönhintaan).

## 2 Menetelmät

### 2.1 Tutkitut skenaariot ja suorituskykymittarit


Tässä työssä tarkastelen kolmea eri energiajärjestelmäskenaariota, jotka on havainnollistettu kuvassa 2.

**Skenaario A** sisältää vain aurinkovoimalan, jolloin PV-tuotanto voidaan joko käyttää itse tai myydä verkkoon. Tämä skenaario vastaa suurinta osaa kotitalouksien aurinkoenergiajärjestelmistä, sillä akkujen käyttö ei ole yleistynyt samaan tahtiin aurinkovoimaloiden kanssa. Spot-sopimuksella taloudellisin HEMS-strategia on käyttää kaikki mahdollinen tuotanto itse ja myydä ylimääräinen tuotanto verkkoon.

**Skenaario B** vastaa yksinkertaista akullista tilannetta, jossa PV-tuotanto voidaan käyttää itse, varastoida akkuun tai myydä verkkoon, mutta akun toiminnot on rajattu vain aurinkoenergian varastointiin ja oman kulutuksen kattamiseen. SCM-strategia pohjautuu tähän skenaarioon.

**Skenaario C** sisältää skenaarion B toimintojen lisäksi akun lataamisen suoraan verkkosähköllä ja sähkön myynnin akusta verkkoon. Tämä skenaario on tutkimistani monimutkaisin ja se kattaa kaikki mahdolliset toiminnot, joita PV-akkuenergiajärjestelmällä voidaan toteuttaa. Käytännössä tämä skenaario saattaa olla tänä päivänä vaikea toteuttaa yhdellä akulla, sillä yleensä pientuottajasopimukset vaativat, että verkkoon myytävä sähkö on uusiutuvaa. Akkua ladattaessa verkosta akun varastoima sähkö ei ole välttämättä uusiutuvaa, jolloin akusta myytävän sähkön tuotantotapa voi olla vaikea todentaa. Kahdella akulla tämän skenaarion voisi kuitenkin yleistää siten, että toinen akku varastoi vain PV-tuotantoa, jolloin tämän akun latausta voi myydä verkkoon. Tämä skenaario voisi olla toimiva myös esimerkiksi energiakommuunissa (esim. [55]), jossa kotitalouden akusta voisi vapaasti siirtää energiaa keskitettyyn energiavarastoon muiden käyttöön. Lisäksi lisääntyvä vaihteleva uusiutuva energia ja sähköautojen enenevä käyttö energiavarastoina saat-

taa tulevaisuudessa muuttaa kodin energiajärjestelmiä tämän skenaarion suuntaan. Kirjallisuusselvitykseni lähteissä ei missään tarkemmin eritelty akun ja sähköverkon kytkentää.



Kuva 2. Tässä työssä tutkitut skenaariot. A: Skenaario sisältää aurinkovoimalan, josta energiaa voidaan käyttää itse ja myydä verkkoon. B: Aurinkovoimalan lisäksi tämä skenaario sisältää akun, johon voidaan varastoida PV-tuotantoa ja josta voidaan purkaa energiaa taloon. C: Tässä skenaariossa akkuun voidaan skenaarion B lisäksi varastoida verkkosähköä ja akusta voidaan myydä energiaa suoraan verkkoon.

Neuroverkkomallin toimintaa voi olla vaikea arvioida skenaariossa B ja C näiden skenaarioiden kompleksisuuden takia, minkä takia määrittelen kolme referenssiskenaariota KV,  $A_{\text{optimi}}$  ja SCM:

**KV** (kaikki verkosta) vastaa tilannetta, jossa kaikki sähkö ostetaan verkosta. Tämä skenaario ei siis sisällä PV-tuotantoa tai akkua.

$A_{\text{optimi}}$  vastaa skenaarion A optimiratkaisua. Koska spot-sopimuksella sähkön ostohinta on aina myyntihintaa suurempi, on skenaariolla A triviaali optimistrategia: kaikki mahdollinen tuotanto käytetään itse ja ylituotanto myydään verkkoon. Tämä referenssiskenaario tarjoaa vertailukohtan neuroverkkomallin toiminnalle skenaariossa A.

**SCM** vastaa skenaariota B SCM-strategialla. Käytän SCM-strategiaa referenssinä, sillä se on usein käytetty referenssimalli ja yksinkertainen implementoida. Tämä referenssiskenaario toimii vertailupohjana neuroverkkomallille skenaariossa B sekä

C. Alla on kuvattu SCM:n toiminta vaiheittain:

1. Kaikki mahdollinen PV-tuotanto  $E_{PV}$  käytetään itse ( $E_{PV \rightarrow T} = \min(E_{PV}, E_T)$ , jossa  $E_T$  tarkoittaa kulutusta)
2. Ylimääräinen tuotanto varastoidaan akkuun ( $E_{PV \rightarrow A}$ )
3. Jos akku on täynnä, myydään ylituotanto verkkoon ( $E_{PV \rightarrow V}$ )
4. Jos PV-tuotantoa ei ole tarpeeksi kulutuksen kattamiseen, puretaan tarvittava energia akusta ( $E_{A \rightarrow T}$ )
5. Jos akkussa ei ole tarpeeksi latausta, ostetaan loppu energia verkosta ( $E_{V \rightarrow T}$ )

Nämä vaiheet suoritetaan iteratiivisesti jokaiselle tunnille  $h$  käyttäen syötteenä tunnin  $h$  tuotantoa, kulutusta ja akun latausta, jonka jälkeen akulle lasketaan päivitetty lataus, jota käytetään seuraavan tunnin iteraatiossa:

$$E_{A,h+1} = E_{A,h} + \eta_{CH} E_{PV \rightarrow A,h} - \frac{E_{A \rightarrow T,h}}{\eta_{DCH}}, \quad (19)$$

jossa  $\eta_{CH}$  ja  $\eta_{DCH}$  ovat akun lataus- ja purkuhyötysuhteet ja  $E_A$  tarkoittaa akkuun varastoitua energiaa.

Arvioin neuroverkomallin toimintaa vertaamalla erilaisia suorituskykymittoja vastaaviin referenssiarvoihin. Alla esittelen käyttämäni suorituskykymitat.

**Vuosittainen sähkölasku**  $C_{\text{lasku}}$  on tämän työn pääasiallinen suorituskykymita. Se tarkoittaa ostetun ja myydyn sähkön hintojen erotusta. En sisällytä kiinteää kuukausihintaa sähkölaskuun, sillä se on kaikille skenaarioille sama eikä täten vaikuta tuloksiin. Sähkölasku kuvaa konkreettista rahallista sähkön arvoa ja se on erityisen käyttökelpoinen suorituskykymitta erityisesti skenaariossa A, jossa akkua ei ole.

**Vuosittainen akun suhteellinen käyttöiän muutos**  $\Delta\text{SOH}$  (yhtälö (5)) ja vastaava vuosittainen **akunkäytön hinta**  $C_{\text{SOH}}$  ovat skenaarioissa B ja C tärkeitä


suorituskykymittoja sähkölaskun lisäksi.  $\Delta\text{SOH}$  lasketaan yhtälöllä (5) laskemalla yhteen tunnitteiset  $\Delta\text{SOH}(h)$ -arvot koko vuoden yli. Akunkäytön hinta voidaan yksinkertaisesti laskea akun kustannuksien ja  $\Delta\text{SOH}$ :n tulona

$$C_{\text{SOH}} = C_{\text{AKKU}}\Delta\text{SOH}, \quad (20)$$

jossa  $C_{\text{AKKU}}$  tarkoittaa akun investointikustannuksia ja  $\Delta\text{SOH}$  vuosittaista käyttöiän muutosta.

## 2.2 Työssä käytetty data ja sähkö sopimus

Tässä työssä käytän mitattua PV-tuotantodataa, joka on peräisin Turun ammattikorkeakoulun (TuAMK) Kupittaaan kampuksen mittausasemalta, ja se on saatavilla TuAMK:n Uuden energian tutkimuskeskuksen dataportaalista [61]. Mittausasema sisältää neljä pystyyn asennettua itä-länsisuuntaista kaksipuolista aurinkopaneelia (Prism Solar Bi60-375BSTC) sekä kaksi näiden päällä olevaa referenssikennoa, jotka mittaavat auringon säteilyn intensiteettiä aurinkopaneelien pinnan tasossa. Paneelien pintalämpötilan mittaamiseksi jokaiseen paneeliin on kiinnitetty termopari. Aurinkopaneelisysteemi on esitetty kuvassa 3. Samalla mittausasemalla sijaitsee sääasema, joka on varustettu lämpö-, sade-, kosteus- ja tuulimittarilla sekä kahdella auringon säteilyä mittaavalla pyranometrillä. Tässä työssä käytän kuitenkin vain aurinkopaneelien tehodataa. Mittasdataa on vuoden 2019 alusta vuoden 2022 loppuun (joulukuun 6. päivä asti), joten käytän analyysissäni näitä neljää vuotta. Koska joulukuussa PV-tuotanto on vähäistä, oletan vuoden 2022 joulukuun tuotannon 6. päivän jälkeen nollassi, jolloin sähkölaskut voidaan laskea koko vuodelle 2022. Koska työssä käytetty kulutusdata (tarkempi kuvaus alla) on tunnitteisella resoluutiolla, keskiarvoistin tuotantodatan tunnitteiseksi arvoiksi.



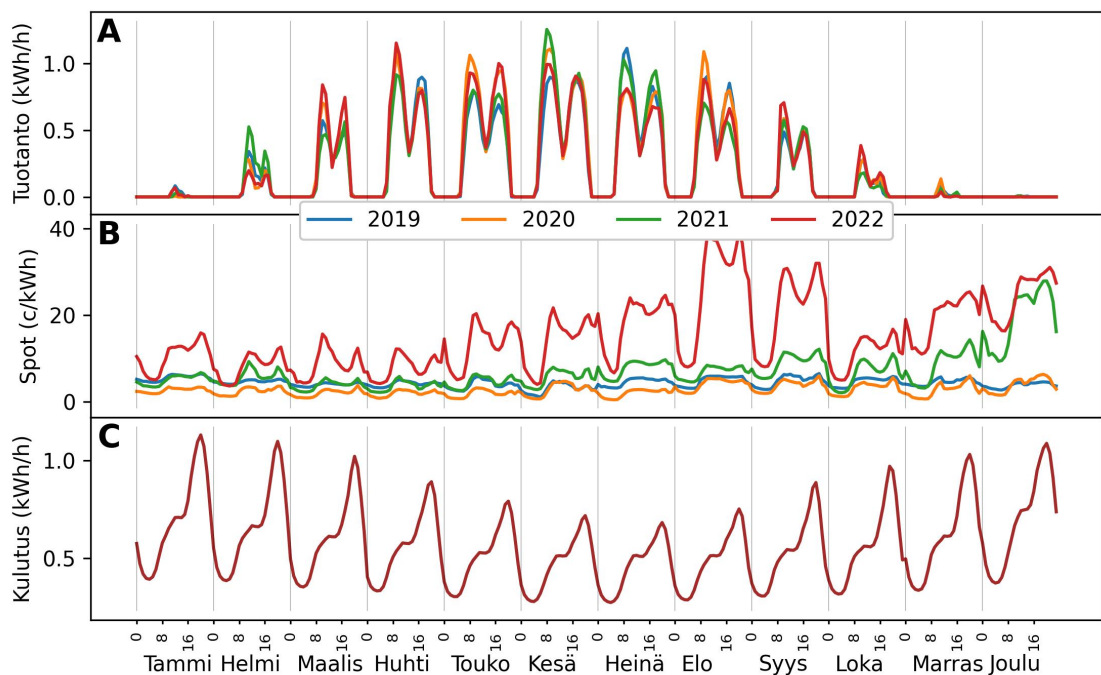
Kuva 3. Aurinkovoimala, josta tässä työssä käytetty tuotantodata on peräisin. Muokattu lähteestä [62].

Kuvassa 4A on esitetty kuukausittaiset keskimääräiset PV-tuotannon vuorokausiprofililit vuosille 2019-2022. Profilit on saatu laskemalla kullekin vuorokauden tunnille kuukausittainen keskiarvo. Kuvasta nähdään itä-länsisuuntaiselle kaksipuoleiselle paneelille tyypillinen tuotantoprofiili: yksi aamuhuippu ja yksi iltahuippu. Aamuhuippu on keskimääräisesti hieman iltahuippua korkeampi, sillä se vastaa paneelin etupuolta, jonka hyötysuhde on paneelin takapuolen hyötysuhdetta suurempi. Selkeästi nolasta poikkeavaa tuotantoa on maaliskuusta syyskuuhun ja talvikuu-kausina tuotantoa on hyvin vähän.

Sähkön spot-hinnat ovat peräisin Nord Poolista. Kuvassa 4B on esitetty verotomat spot-hinnat vuosille 2019-2022. Kuvaajasta nähdään Euroopan energiakriisin aiheuttama hintojen huomattava nousu vuoden 2021 lopusta vuodelle 2022. Lisäksi kuvaajasta nähdään hintojen keskimääräinen vuorokausiprofiili: hinnalla on tyypillisesti kaksi huippua, aamupäivällä sekä illalla. Iltapäivisin sähkönhinta on keskimäärin pienempi ja öisin se saavuttaa minimiarvonsa.

Työssä käyttämäni kulutusdata perustuu Tampereen yliopiston Energiavirastolle laatimiin suomalaisiin tyypillisiin kulutusprofiiliklustereihin [32]. Tässä työssä käytän tyypikklasteria 4, joka vastaa omakotitaloa ilman sähkölämmitystä 5 MWh:n

vuosikulutuksella. Kulutusprofiili on keskiarvoistettu useasta yksittäisestä kulutusprofiilista usean vuoden mittausdatasta, ja se on lämpötilanormalisoitu käyttäen usean vuoden kuukausikeskiarvoja, jolloin profiili edustaa tyypillistä vuosikulutusta. Kuvassa 4C on esitetty kulutusprofiilin kuukausittaiset keskimääräiset vuorokausiprofiilit. Vuorokauden sisällä kulutus saavuttaa huippuarvonsa iltaisin, jonka jälkeen se nopeasti laskee yöksi saavuttaen miniarvon. Kesällä kulutus on keskimääräisesti hieman alhaisempaa kuin talvella.



Kuva 4. Kuukausikeskiarvoistetut tuntikohtaiset profiilit A: tuotannolle, B: sähkön spot-hinnalle (ei sisällä ALV:ää), C: kulutukselle.

## Sähkösopimus

Tässä työssä käytän pörssisähkään perustuvaa sähkösopimusta, jolloin sähkön ostojen ja myyntihinnat ovat yhtälöiden (6) ja (7) mukaiset. Käytän hintakomponentille  $p_{\text{välitys}}$  arvoa 0,4 c/kWh. Taulukossa III on esitetty tässä työssä käytetyt siirtohinnat  $p_{\text{siirto}}$ . Nämä arvot ovat Turun alueen sähköverkkoyhtiö Turku Energia Sähköverkot Oy:n keskiarvohintoja ei-sähkölämmitteisille pientaloille (joiden vuosikulutus on 5 MWh) ja ovat peräisin Energiaviraston tilastoista [63]. Siirtohintojen lisäksi ar-

voon sisältyy sähkövero ja huoltovarmuusmaksu. Taulukossa IV on esitetty työssä käytettyjen spot-hintojen sekä sähkön osto- ja myyntihintojen vuosittaiset keskiarvot. Vuonna 2020 spot-hinta on keskimääräisesti selvästi muita vuosia alhaisempi, kun taas vuonna 2022 keskimääräinen spot-hinta on yli kaksi kertaa kalliimpi kuin edeltävänä vuonna 2021. Koska sähkön ostohintaan lisätään siirtomaksu, verot sekä välitysmaksu, on se huomattavasti suurempi kuin sähkön myyntihinta.

Taulukko III. Eri vuosien siirtomaksut sisältäen sähköveron ja huoltovarmuusmaksun.

	2019	2020	2021	2022
$p_{\text{siirto}}$ (c/kWh)	6,93	6,65	6,65	6,22

Taulukko IV. Sähkön spot-hinnan, ostohinnan sekä myyntihinnan vuosittaisen keskiarvot. Kaikki luvut yksikössä c/kWh.

Vuosi	$p_{\text{spot}}$	$p_{\text{osto}}$	$p_{\text{myynti}}$
2019	4,4	12,8	4,0
2020	2,8	10,5	2,4
2021	7,2	16,0	6,8
2022	14,8	25,0	14,4

## 2.3 Komponenttien mallinnus ja mitoitus

### Akun mallinnus

Tässä työssä käytän yhtälön (1) mukaista yksinkertaistettua akkumallia, joka olettaa vakiohyötysuhteen olosuhteista riippumatta. Tämän työn tarkoitus on keskittyä uudenlaisen neuroverkkoon pohjautuvan HEMS-menetelmän tutkimiseen, minkä takia pidän akun mallinnuksen yksinkertaisena. Yksinkertainen akkumalli saattaa kuitenkin vaikuttaa tuloksiin. Koska akun hyötysuhde pienenee sen purkaus-/lautaustehon kasvaessa [1], tulokset saattavat olla hieman ylioptimistisia. Erityisesti tämä approk-



simaatio vaikuttaa kuitenkin SCM:n tuloksiin, sillä SCM:llä keskimääräinen purkaussyvyys on suurempi kuin muilla strategioilla [1], jolloin myös akun operaatioteho ja edelleen approksimaatiosta aiheutuva virhe on suurempi kuin muilla strategioilla.

Jotta työn tulokset vastaisivat realistista kotitalouden energiasysteemiä, käytän Teslan Powerwallin parametrejä simulaatiossa. Powerwall on yksi yleisesti HEMS-kirjallisuudessa käytetyistä akuista [1, 55], ja sen parametrit on esitetty aiemmin taulukossa I.

Estimoin akun käyttöön liittyvää ikääntymistä käyttäen yhtälöitä (4) ja (5). Ilman tarkempia Powerwall:n arvoja parametreille  $\alpha$  ja  $R$  käytän analyysissäni  $\alpha$ :lle arvoa 1,3, joka vastaa työssä [27] esitettyjen litiumioniakkujen keskiarvoa (vaihteluväli 0,23-2,00). Parametrin  $R$  arvon arvioin käyttämällä Powerwallin takuuehtojen mukaista 30 % kapasiteettihäviötä ja minimikäyttökertaikää 3000 [34], joka vastaa syvintä mahdollista sykliä (DOD=1). Tällöin yhtälön (4) avulla saadaan

$$R = \frac{N_{\text{life}}(\text{DOD} = 1)\text{DOD}^\alpha}{r_{\text{EOL}}} = \frac{3000 \cdot 1^{1,3}}{0,3} = 10000 = 10^4, \quad (21)$$

Tämä arvo on samaa suuruusluokkaa kuin työssä [27] esitettyjen litiumioniakkujen  $R$ -arvot (suuruusluokkavaihteluväli  $10^3 - 10^6$ ). Näillä parametrien arvoilla estimoitu  $N_{\text{life}}$ -DOD-riippuvuus todennäköisesti eroaa Powerwallin oikeasta ikääntymiskäyttäytymisestä, mutta tämän työn kannalta oleellista on vain se, että  $N_{\text{life}}$ -DOD-riippuvuus on muodoltaan ja suuruusluokaltaan litiumioniakuille tyypillisellä aluella.

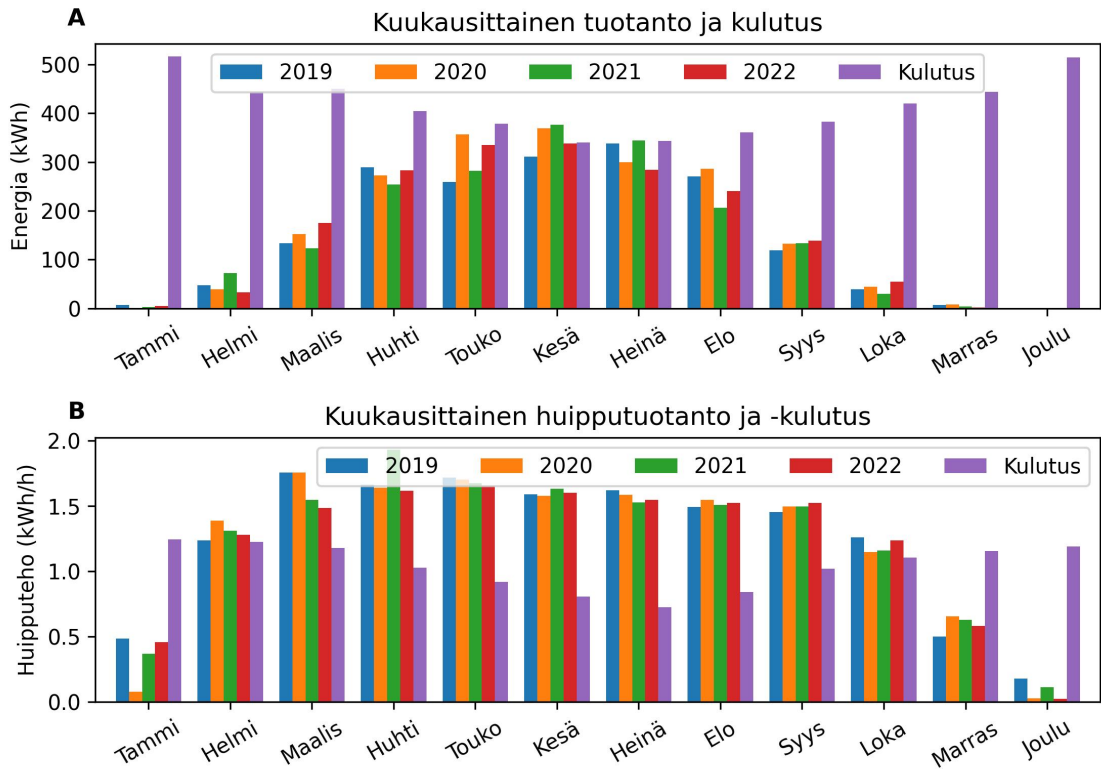
## Mitoitus

Tässä työssä tutkin ainoastaan energianhallintaa enkä energiajärjestelmän komponenttien (akku ja aurinkovoimala) mitoitusta, vaikka nämä kaksi optimointiaspektia riippuvat toisistaan. Tämän rajauksen teen keskittyäkseni uudelleen neuroverkkojäestymistävän esittelyyn sekä sen perusteelliseen analysointiin.

Akun parametrit asetin vastaamaan Teslan Powerwallia, jolloin käytettävä kapa-

siteetti  $E_A^{\text{MAX}}$  on 13,5 kWh ja maksimilataus- ja purkuteho 5 kW. Tällä kapasiteetilla akkuun voi varastoida likimain yhtä keskimääräistä päivää vastaavan energian ( $5000 \text{ kWh}/365 = 13,7 \text{ kWh}$ ).

Mitoitin aurinkovoimalan kapasiteetin intuitiivisesti siten, että tuotanto vastaa likimain kulutusta niiltä kuukausilta, kun PV-tuotantoa on merkittävästi. Työssä käytettyjen TuAMK:n testiaseman kaksipuoleisten paneelien kokonaiskapasiteetti on 1180 Wp. Tämä kapasiteetti vastaa paneelien etupuolien nimellistehoa. Käytän tätä kokonaiskapasiteettina, sillä se on kaksipuoleisten paneelien tapauksessa tyypillistä [62]. Skaalasin tuotannon kaskinkertaiseksi, jolloin PV-systeemin kapasiteetti on 2360 Wp. Tämä kapasiteetti on pienempi kuin tyypillinen 4–10 kWp:n pientuotajan aurinkovoimalan vastaava [9–11], mutta toisaalta myös omakotitalojen energiankulutus on tyypillisesti suurempaa kuin työssä käytetty 5 MWh:n vuosittainen kulutus. Kuvassa 5A on esitetty skaalattu kuukausittainen kokonaistuotanto vuosille 2019-2022 sekä vastaava kuukausittainen kokonaiskulutus. Kesällä kuukausittainen kokonaistuotanto vastaa keskimäärin vastaavaa kuukausikulutusta. Tämä ei välttämättä kuitenkaan tarkoita, että kesäkuukausina omakotitalo olisi omavarainen, sillä kuukauden sisällä PV-tuotanto voi olla jakautunut epätasaisesti. Kuvassa 5B on esitetty kuukausittaiset huipputehot tuotannolle sekä kulutukselle. Kesäkuukausina tuotannon huipputeho on keskimäärin kaksinkertainen kulutushuippuun, joten hetkittäinen ylituotanto on paikoin suurta. Huomattavaa on kuitenkin se, että esitetyt tehot ovat tunnittaisia keskitehoja ja täten pienempiä kuin hetkittäiset todelliset huipputehot. Vuosittaiset kokonaistuotannot on esitetty taulukossa V. Vuosi- ja kuukausituotannoissa on selvää vaihtelua, mikä johtuu pääasiassa auringonsäteilyn vaihtelevuudesta.



Kuva 5. A: kuukausittaiset kokonaistuotannot sekä kokonaiskulutus, B: kuukausikohtainen huipputeho ja -kulutus (keskiarvoistettu tunnin jakovälin yli).

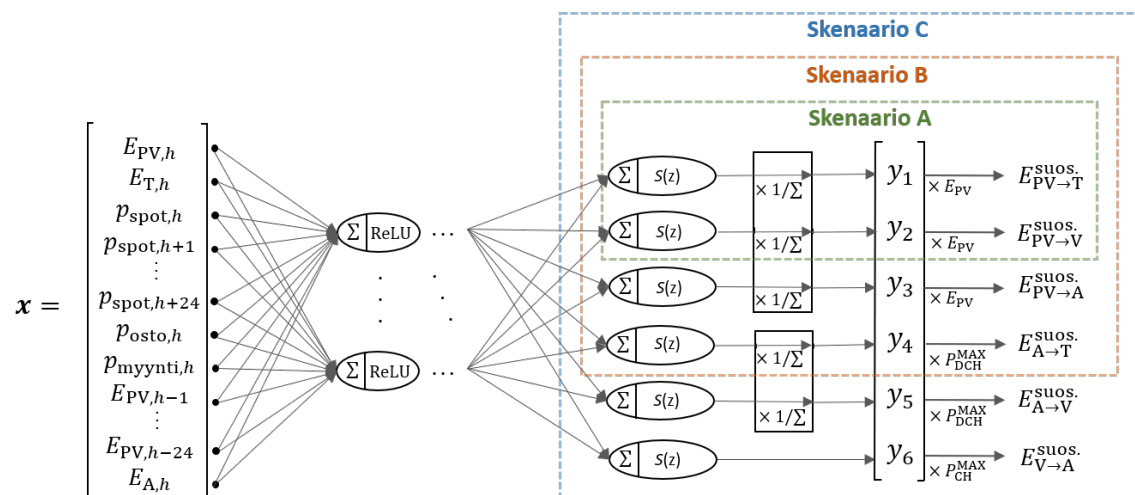
Taulukko V. Vuosittaiset PV-tuotannot.

	2019	2020	2021	2022
$E_{PV}$ (MWh)	1,77	1,90	1,77	1,83

## 2.4 Työn neuroverkkomalli

Käytin neuroverkon ohjelmointiin Pythonin PyTorch-ohjelmointikirjastoa. Neuroverkkomallin rungon oli kirjoittanut ohjaajani dosentti Niskanen. Kuvassa 6 on esitetty tämän neuroverkkomallin periaatekaavio. Neuroverkon koulutus perustuu iteraatiiviseen lähestymistapaan ja poikkeaa tyypillisestä osiossa 1.2 kuvatusta neuroverkon koulutuksesta. Työn neuroverkon peruseriaate on lyhyesti seuraava: syöte  $\mathbf{x}$  koostuu tunnin  $h$  ympäristömuuttujista kuten tuotannosta, kulutuksesta ja sähkön-

hinnasta ja tulosteena  $\hat{\mathbf{y}}$  saadaan ehdotetut energianhallinnan toiminnot kyseiselle tunnille. Ehdotettujen toimintojen sekä toteutuvien tuotannon ja kulutuksen avulla lasketaan realisoituneet energiamäärät kullekin toiminnolle. Tuntia vastaava sähkölasku voidaan laskea ostetun ja myydyin sähkön avulla. Alla kuvailen tarkemmin mallin koulutuksen ja toiminnan.



Kuva 6. Kaaviokuva työssä käytetystä neuroverkosta ja tulosten muodostumisesta eri skenaarioissa. Tuntia  $h$  vastaava syötevektori ajetaan piilokerrosten läpi, joissa aktivaationafunktiona on ReLU. Tulostekerroksessa lähdöt ajetaan logistisen funktion läpi ja edelleen normalisoidaan skenaariosta riippuen siten, että tuotantoa ja akun purkausta vastaavien toimintojen summa on yksi. Tämän jälkeen realisoituneet suositukset saadaan kertomalla tulosteet tuotannolla tai akun teholla.

### Mallin iteratiivinen koulutus

Tämän työn neuroverkkomallin koulutus perustuu viikon keskimääräisen päivittäisen sähkölaskun minimointiin. Tämä koulutus poikkeaa tyypillisestä neuroverkon koulutuksesta siinä, että ennustetuille tulosteille  $\hat{\mathbf{y}}$  ei ole vastaavia oikeita arvoja  $\mathbf{y}$ , joiden avulla voisi laskea ennustevirheen. Sen sijaan sähkölasku edustaa mini-voitavaa sakkoa. Tämä koulutuslähestymistapa ilman oikeita  $\mathbf{y}$ -arvoja tekee tästä neuroverkkomallista vahvistusoppimismallin.

Mallin koulutus tapahtui seuraavasti: kullekin datapisteelle (tunnille) harjoitusdatajoukossa ajettiin ennusteet iteratiivisesti seuraavan 7 vuorokauden jokaiselle tunnille (tyypillisesti tällaista iteratiivista ajoa kutsutaan vahvistusoppimiskontek-

tissa episodiksi). Jokaisen iteraation aikana realisoituneiden toimintojen avulla laskettiin vastaavan tunnin sähkölasku ja päivitettiin akun lataus seuraavalle tunnille sekä seuraavan tunnin syötteeseen  $\mathbf{x}$ . Tunnittaiset 7 vuorokauden sähkölaskut keskiarvoistettiin vastaamaan päivittäistä sähkölaskua, ja tämä keskiarvo osittain edustaa minimoitavaa sakkoa. Sakon toinen osa liittyy akkuun varastoidun sähkön arvoon. Jos huomioidaan vain 7 vuorokauden episodi, suurin taloudellinen hyöty saadaan, kun akku puretaan tämän episodin lopussa tyhjäksi. Tämä toimintamalli ei kuitenkaan käytössä ole kannattava, sillä akun käytöllä ei tosielämässä ole mitään aikaikkunaa, jonka aikana se pitäisi saada tyhjennettyä. Tämän takia mallin koulutusvaiheessa annoin akkuun varastoidulle sähkölle arvon  $V_{\text{akku}}$ , joka vastasi seuraavan 9 tunnin sähkön ostohinnan mediaania. Näin 7 vuorokauden episodin lopuksi laskin akkuun varastoidun energian arvon muutoksen

$$P_{\text{akku}} = (E_{A,7\cdot 24} - E_{A,0}) V_{\text{akku},7\cdot 24}, \quad (22)$$

jossa  $E_{A,7\cdot 24}$  on akun lataus episodin lopussa ja  $E_{A,0}$  episodin alussa. Kun akun lataus yhden 7 vuorokauden episodin lopussa on pienempi kuin episodin alussa, on  $P_{\text{akku}}$ :n arvo negatiivinen, ja vastaavasti se on positiivinen, jos episodin lopussa varaus on suurempi kuin alussa. Tällöin minimoitava sakko on muotoa

$$J_{\text{sakko}} = \frac{1}{7} \sum_{h=0}^{7\cdot 24} [(E_{V\rightarrow T,h} + E_{V\rightarrow A,h}^{\text{ulk.}}) p_{\text{osto},h} - (E_{PV\rightarrow V,h} + E_{A\rightarrow V,h}^{\text{ulk.}}) p_{\text{myynti},h}] - \frac{1}{7} P_{\text{akku}}, \quad (23)$$

Tämän iteratiivisen lähetymistavan tarkoitus on mahdollistaa mallin löytävän toimintatapoja, jossa huomioidaan lähitulevaisuuden olosuhteet.

Koulutin mallin 200 erissä, jolloin optimointiaskel suoritettiin keskiarvoistettuun 200 datapisteen yhtälön (23) mukaiseen sakkoon. Optimointiin käytin Adam-funktiota. Mallia koulutettiin maksimissaan 2000 epokin verran, ja joka epokin päätteeksi laskettiin harjoitus- ja validaatiotulos, jotka saatiin laskemalla sähkölaskut koko harjoitus- ja validaatiojoukon yli. Tällöin harjoitus- ja validaatiotulos vastaavat

keskiarvoistettuja harjoitus- ja validaatiojoukkoon kuuluvien datapisteiden viikon yli laskettuja päivittäisiä sähkölaskuja. Näihin tuloksiin en lisännyt akun sähkön arvoa  $P_{\text{akku}}$ , jotta tulokset vastaisivat mahdollisimman hyvin tosielämän sähkölaskua. Sisällytin koulutukseen aikaistetun lopetuksen, jolloin koulutus lopetettiin, jos 10 peräkkäistä epokkia tuotti huonomman harjoitus- tai validaatiotuloksen kuin sen hetkinen paras vastaava tulos. Koulutusjakson parhaan validaatiotuloksen saanut malli tallennettiin. Lopullisina raportoituina tuloksina laskin sähkölaskun vuoden mittaisen ajon yli, jossa lopussa olevan akun latauksen arvo on vähäinen tekijä.

### **Koulutusdata ja syötemuuttujat**

Skenaarioilla A ja B käytin koulutukseen vuoden 2020 kesäkuukausia (huhtikuu-elokuu), sillä näinä kuukausina tuotantoa on merkittävästi (kuva 5A), ja kyseiset skenaariot perustuvat nimenomaan PV-tuotannon hallintaan. Skenaarion C harjoitukseen käytin koko vuoden 2020 dataa, sillä tässä skenaariossa akun lataus ei perustu pelkkään PV-tuotantoon, vaan myös verkosta ostettuun sähköön, jolloin myös talvi-kuukausina akusta voidaan hyötyä sopivalla HEMS-strategialla. Vuotta 2020 käytin koulutukseen siksi, koska vuoden 2019 kesäkuussa aurinkovoiman mittausdatassa on pitkä katkos, ja koska vuosi 2020 edustaa sähkönhinnan kannalta "normaalia" vuotta (vuonna 2021 sähkönhinta nousee loppuvuonna voimakkaasti). Laajensin vuoden 2020 datajoukon kymmenkertaiseksi monistamalla jokaisen datapisteen kymmenen kertaa, jolloin skenaariolle A ja B datapisteitä oli yli 51000 ja skenaariolle C yli 87000. Syötteenä käytin tuotettua tehoa, kulutusta, spot-hintaa ( $p_{\text{spot}}$ ), 24 seuraavan tunnin spot-hintaa, sähkön osto- ja myyntihintaa sekä 24 edellisen tunnin tuotantotehoa. Lisäksi generoin syötedataan akun varausta kuvaavan muuttujan, jonka alustin satunnaisesti välille  $[0, E_A^{\text{MAX}}]$ . Moninkertaistin koulutusdatan nimenomaan siksi, että koulutukseen saataisi laaja otanta eri akun ja ympäristön lähtötiloja. Muuttujia oli yhteensä 54 eli syötevektorin  $\mathbf{x}$  pituus oli 54. Ajatukseni

oli, että informaatio lähitulevaisuuden spot-hinnoista syötevektorissa auttaa mallia löytämään toimintamalleja, jotka ottavat lähitulevaisuuden sähkönhinnan muutokset huomioon. Lisäksi toivoin menneiden lähituntien tuotantotehon sisällyttämisen syötteeseen auttavan mallia ennustamaan lähituntien tehon. Motivaationi oli, että vaikka mallia ei kouluteta ennustamaan tehoa, mallin parametreihin teoriassa pitäisi impliseettisesti koodautua lähitulevaisuuden tuotannon ennustaminen, mikä näkyy mallin tekemissä energianhallinnan ratkaisuisissa. Jaoin koulusdatan koulutusjoukkoon ja validointijoukkoon 80/20 jakosuhteella satunnaisjaolla. Skaalasin koulutus- ja validointijoukon muuttujat käyttäen koulutusjoukon dataa. Akulle käytin minimi-maksimi-skaalausta (yhtälö (17)) ja muille muuttujille standardointia (yhtälö (18)).

### Neuroverkon arkkitehtuuri

Käytin MLP-verkkoa, jonka piilokerroksien lukumäärän ja leveyden valitsin mallinvalinnalla (mallinvalinnassa käytetyt parametrit esitetty myöhemmin taulukossa VI). Kaikki kerrokset olivat täysin kytkettyjä, eli jokainen neuroni on yhteydessä jokaiseen edeltävän ja seuraavan kerroksen neuroniin. Piilokerroksien aktivaatiofunktiona käytin ReLUa, sillä se on yleisesti käytetty oletusaktivaatiofunktio.

### Tulostevektori

Esitän alla tulostevektorien  $\hat{\mathbf{y}}$  elementtejä vastaavat toiminnot ja tulostekerroksen aktivaatiofunktiot eri skenaarioiden neuroverkoille. Tulostevektorin sisältö enkoodaa suositeltavat HEMS-toiminnot, jotka riippuvat tutkitusta skenaariosta.

**Skenaariossa A** toimintoja on kaksi: itse käytetty tuotanto ( $E_{P \rightarrow T}$ ) ja verkoon myyty tuotanto ( $E_{P \rightarrow V}$ ). Verkosta taloon ostetun sähkön määrä voidaan johdattaa kulutuksen ja itse käytetyn tuotannon osuuden erotuksena  $E_{V \rightarrow T} = \min(0, E_T - E_{P \rightarrow T})$ , eikä sitä täten tarvitse ennustaa. Käytin logistista aktivaatiota (yhtälö (12)) kumpaankin tulosteneuroniin, jolloin tulostearvot ovat välillä  $[0, 1]$ . Tämän

jälkeen laskin normitetun tulostevektorin  $\hat{\mathbf{y}}_n$  tulostevektorista  $\hat{\mathbf{y}}$  siten, että sen elementtien summa on yksi:

$$\hat{\mathbf{y}}_n = \frac{\hat{\mathbf{y}}}{\|\hat{\mathbf{y}}\|_2}. \quad (24)$$

Vektorin  $\hat{\mathbf{y}}_n$  komponenteista toinen vastaa itse käytetyn tuotannon osuutta ja toinen verkkoon myydyyn tuotannon osuutta. Normituksen takia skenaarion A tapauksessa tulosteeksi riittäisi periaatteessa vain yksi skalaariarvo, sillä toinen arvo voidaan johtaa tästä. Realisoituneet mallin suosittamat energiamäärät  $E_{\text{PV} \rightarrow \text{T}}^{\text{suos.}}$  ja  $E_{\text{PV} \rightarrow \text{V}}^{\text{suos.}}$  saadaan kertomalla tulostevektori  $\hat{\mathbf{y}}_n$  tuotannolla.

**Skenaarion B** tapauksessa tulostevektorissa on neljä elementtiä, jotka vastaavat itse käytettyä tuotantoa ( $E_{\text{PV} \rightarrow \text{T}}$ ), verkkoon myytyä tuotantoa ( $E_{\text{PV} \rightarrow \text{V}}$ ), akkuun varastoitua tuotantoa ( $E_{\text{PV} \rightarrow \text{A}}$ ) sekä akusta taloon purettua energiaa ( $E_{\text{A} \rightarrow \text{T}}$ ). Taloon verkosta ostettu sähkö voidaan johtaa kulutuksesta ( $E_{\text{T}}$ )  $E_{\text{PV} \rightarrow \text{T}}$ :n ja  $E_{\text{A} \rightarrow \text{T}}$ :n avulla

$$E_{\text{V} \rightarrow \text{T}} = \max(0, E_{\text{T}} - E_{\text{PV} \rightarrow \text{T}} - E_{\text{A} \rightarrow \text{T}}). \quad (25)$$

Käytin jälleen kaikkiin tulosteneuroneihin logistista aktivaatiofunktioita (yhtälö (12)), jonka jälkeen normitin kaikki kolme tuotantoon liittyvää toimintoa yhtälön (24) mukaisesti kertoen ne sitten tuotannolla saadakseni realisoituneet ehdotukset energioille  $E_{\text{PV} \rightarrow \text{T}}^{\text{suos.}}$ ,  $E_{\text{PV} \rightarrow \text{A}}^{\text{suos.}}$  ja  $E_{\text{PV} \rightarrow \text{V}}^{\text{suos.}}$ . Toimintoa  $E_{\text{A} \rightarrow \text{T}}$  vastaavan tulosteen kerroin maksimipurkausteholla  $P_{\text{DCH}}^{\text{MAX}}$  saadakseni kyseisen toiminnon realisoituneen energian  $E_{\text{A} \rightarrow \text{T}}^{\text{suos.}}$ .

**Skenaariorissa C** toimintoja on kuusi. Skenaarion B toimintojen lisäksi akku on kaksisuuntaisessa yhteydessä verkkoon, eli sitä voi ladata verkosta tai purkaa verkkoon. Vastaavasti kaikki tulosteet ajettiin logistisen aktivaatiofunktion läpi (yhtälö (12)) ja kolme tuotantoon liittyvää toimintoa normitettiin kuten skenaarion B tapauksessa (yhtälö (24)). Lisäksi normitin akun purkautumiseen  $E_{\text{A} \rightarrow \text{T}}$  ja  $E_{\text{A} \rightarrow \text{V}}$  liittyvää kaksi toimintoa keskenään, jonka jälkeen kerroin ne  $P_{\text{DCH}}^{\text{MAX}}$ :llä. Tällöin maksimipurkausteho ei ylitä. Viimeinen toiminto edustaa verkosta akkuun ostettua ener-



giaa  $E_{V \rightarrow A}$ , ja sen realisoitunut arvo saadaan kertomalla vastaava tuloste  $P_{CH}^{MAX}$ :llä.

### Toimintojen reunaehdot

Realisoituneiden tulosteiden jälkeen tulee huolehtia ettei alla esitettyjä simulaation reunaehtoja rikota. Yhtälöiden ylämerkintä "suos." tarkoittaa mallin realisoitunutta tulostetta, "ulk." akkuun syötettyä tai sieltä saatua käytettävää energiaa ja "sis." akun sisäistä latauksen muutosta.

Akkuun ei voi varastoida energiaa sen kapasiteetin yli, eikä kokonaislatausteho saa ylittää tehoa  $P_{CH}^{MAX}$ :

$$E_{PV \rightarrow A}^{ulk.} = \min \left( [E_A^{MAX} - E_A] / \eta_{CH}, P_{CH}^{MAX} \Delta t, E_{PV \rightarrow A}^{suos.} \right) \quad (26)$$

$$E_{V \rightarrow A}^{ulk.} = \min \left( [E_A^{MAX} - E_A] / \eta_{CH}, P_{CH}^{MAX} \Delta t - E_{PV \rightarrow A}^{ulk.}, E_{V \rightarrow A}^{suos.} \right), \quad (27)$$

missä  $\Delta t$  tarkoittaa kahden datapisteen välistä aikaa (tässä työssä yksi tunti). Vastaavasti akusta ei saa purkaa enempää energiaa kuin mitä siihen on varastoitu. Suomen sähkösopimusten mukaisesti akusta ei voi myöskään myydä verkkoon samanaikaisesti kun sähköä ostetaan:

$$E_{A \rightarrow T}^{ulk.} = \min (E_A \eta_{DCH}, E_{A \rightarrow T}^{suos.}) \quad (28)$$

$$E_{A \rightarrow V}^{ulk.} = \begin{cases} 0, & \text{jos } (E_{V \rightarrow T} > 0 \text{ tai } E_{V \rightarrow A}^{ulk.} > 0) \\ \min (E_A \eta_{DCH}, E_{A \rightarrow V}^{suos.}) & , \text{ muutoin.} \end{cases} \quad (29)$$

Yhtälöissä (28) ja (29) ei ole erikseen rajoitusta maksimipurkuteholle, sillä se tulee huolehdittua tulosteiden normituksessa. Verkkoon ei voi myydä tuotantoa silloin kun taloon tai akkuun ostetaan sähköä:

$$E_{PV \rightarrow V} = \begin{cases} 0 & , \text{ jos } (E_{V \rightarrow T} > 0 \text{ tai } E_{V \rightarrow A}^{ulk.} > 0) \\ E_{PV \rightarrow V}^{suos.} & , \text{ muutoin.} \end{cases} \quad (30)$$

Akkuun sisäisesti varastoitu energia on pienempi kuin lataukseen käytetty energia, ja vastaavasti akusta purettu energia on pienempi kuin akun varauksen muutos:

$$E_{PV \rightarrow A}^{\text{sis.}} = E_{PV \rightarrow A}^{\text{ulk.}} \eta_{CH} \quad (31)$$

$$E_{A \rightarrow T}^{\text{sis.}} = E_{A \rightarrow T}^{\text{ulk.}} / \eta_{DCH} \quad (32)$$

$$E_{A \rightarrow V}^{\text{sis.}} = E_{A \rightarrow V}^{\text{ulk.}} / \eta_{DCH} \quad (33)$$

$$E_{V \rightarrow A}^{\text{sis.}} = E_{V \rightarrow A}^{\text{ulk.}} \eta_{CH}. \quad (34)$$

Malli huomioi nämä ehdot ja häviöt toiminnassaan.

### Mallinvalinta

Suoritin malleille kussakin skenaariossa mallinvalinnan ruudukkohaulla varioiden neuroverkon syvyyttä, leveyttä sekä Adam-optimoijan askelpituutta  $\gamma$  ja regularisaatioparametriä  $\lambda$ . Taulukossa VI on esitetty mallinvalintaan sisällytetyt hyperparametrien arvot, jotka on erotettu vakioiduista hyperparametreistä taulukon sarakkeen "Tila" arvolla "Muuttuva".

Taulukko VI. Neuroverkkomallissa käytetyt muuttumattomat ja muuttuvat (mallinvalinnassa varioitavat) hyperparametrit. Skenaarioissa A, B ja C eroavat parametrit erotettu kenoviivalla. Mallinvalinnassa käytetyt eri arvot erotettu toisistaan pilkulla.

Parametri	Arvo	Tila
Syötekerroksen leveys	54	Muuttumaton
Tulostekerroksen leveys	2/4/6	Muuttumaton
Piilokerroksien leveys	20, 50, 100, 200	Muuttuva
Piilokerroksien lukumäärä	1, 2, 4, 5	Muuttuva
Piilokerroksien aktivaatiofunktio	ReLU	Muuttumaton
Optimointialgoritmi	Adam	Muuttumaton
$\lambda$ (Adam)	$10^{-3}, 10^{-6}$	Muuttuva
$\gamma$ (Adam)	$10^{-2}, 10^{-3}, 10^{-4}, 10^{-5}, 10^{-6}$	Muuttuva
Koulutuserän koko	200	Muuttumaton

## Dynaaminen ajonaikainen koulutus

Koska HEMS-strategiaa toteutetaan tosielämän tilanteessa reaaliaikaisesti, ja koska HEMS:n ympäristötekijät (esimerkiksi tuotanto, kulutus ja sähkönhinta) saattavat muuttua suuresti ajan kuluessa (kuten sähkönhinta vuosina 2019-2022, kuva 4), implementoin edellä kuvatun mallinvalinnan ja mallin lopullisen koulutuksen jälkeen ajonaikaisen dynaamisen mallin koulutuksen. Tämän tarkoituksena on päivittää mallia ajonaikaisesti, jotta se kykenisi tuottamaan hyviä ratkaisuja muuttuvissa olosuhteissa.

Dynaamisen koulutuksen suoritin ajamalla mallia kronologisesti tunneittain vuoden 2019 alusta vuoden 2022 loppuun aloittaen vuodella 2020 koulutetulla mallilla. Koska mallin koulutusepisodi vaatii dataa viikon ajalta, koulutus tunnille  $h$  voidaan suorittaa aikaisintaan viikko  $h$ :n jälkeen, eli tunnilla  $h + 7 \cdot 24$ . Käytännössä suoritin koulutuksen joka toinen viikko sisällyttäen koulutukseen kaikki mahdolliset datapisteet eli kahden viikon ensimmäisen viikon (ensimmäisen viikon jälkeen ei ole vielä tarpeeksi realisoituneita datapisteitä viikon episodiin). Näille datapisteille laskin yhtälön (23) mukaiset sakot, jotka laskettiin yhteen ja keskiarvoistettiin jälleen vastaamaan keskimääräistä päivän sähkölaskua, jonka jälkeen optimointiaskel suoritettiin tällä sakolla. Käytin optimointiin Adam-optimoijaa askelpituudella  $\gamma = 10^{-4}$  ja regulaatiokertoimella  $\lambda = 10^{-6}$ . Tämä koulutusaskel suoritettiin viisi kertaa peräkkäin (viisi epokkia), jonka jälkeen simulaatioajoa jatkettiin päivitetyllä mallilla.

## 3 Tulokset

Esitän aluksi neuroverkkomallien mallinvalinnan tulokset. Tämän jälkeen esitän työn päätulokset eli eri skenaariolla saadut vuosittaiset sähkölaskut, jonka jälkeen käsitelen tarkemmin skenaarioiden A, B ja C toimintaa kvalitatiivisesti. Lopuksi tarkastelen mallien kokonaishyötyä laskemalla simulaatioajojen akunkäytön hinnan ja

neuroverkkomallin hukkaaman energian arvon.

### 3.1 Mallinvalinta

Mallinvalinnan parhaat tulokset kaikissa skenaarioissa saatiin systemaattisesti suurimmalla askelpituudella  $10^{-2}$  ja melko leveällä 100 neuronin verkolla, eikä muilla hyperparametreillä ollut vastaavanlaista selvää vaikutusta tuloksiin. Vaikka pyrin vakioimaan kaikki koodin satunnaisuutta sisältävät operaatiot, sain lopullisessa koulutuksessa selvästi huonommat tulokset verrattuna mallinvalinnassa saatuihin parhaimpiin tuloksiin. Olin vakioinut akun varauksen alustuksen sekä datan osituksen koulutus- ja validaatiojoukkoon, joten satunnaisuus saattaa johtua neuroverkon parametrien  $\theta$  alustuksesta. Luulen, että suuren askelpituuden mahdollistama laaja parametriavaruuden läpikäynti auttoi mallia löytämään satunnaisesti erityisen hyvät parametrit joillakin mallinvalinnan ajoilla, joilla sakkofunktio saavutti minimiarvonsa. Pienemmällä askelpituudella malli todennäköisesti konvergoituu lokaliin minimiin eikä täten löydä parasta toimintamallia. Tällöin mallinvalinnan parhaat tulokset edustavat hyvällä tuurilla löytyneitä malleja, eivätkä niiden tulokset ole välttämättä toistettavissa. Tämä mallin tuloksien suuri satunnaisuus on epäkohta, jota voisi yrittää parantaa kokeilemalla muun muassa koulutuksen aikana pienenevää askelpituutta.

Taulukossa VII on esitetty työssä käytetyt hyperparametrit. Tein lopulliset koulutukset eri skenaarioiden malleille kokeilemalla useita mallinvalinnan perusteella hyviä hyperparametrejä. Edellä kuvatun satunnaisuuden takia mallinvalinnan parhaat hyperparametrit eivät nimittäin tuottaneet hyviä tuloksia koulutettaessa malli niillä uudelleen. Taulukossa esitetyt hyperparametrit edustavat siis niitä malleja, joilla sain parhaat validaatiotulokset mallinvalinnan jälkeen kokeilemalla satunnaisesti hyviä hyperparametriedokkaita. Nämä mallit ovat melko leveitä ja syviä.

Taulukko VII. Työssä käytetyt mallien hyperparametrit.

	Leveys	Syvyys	$\gamma$	$\lambda$
A	100	3	$10^{-3}$	$10^{-6}$
B	100	3	$10^{-2}$	$10^{-3}$
C	100	3	$10^{-3}$	$10^{-6}$

### 3.2 Vuosittaiset ja kuukausittaiset sähkölaskut

Taulukossa VIII on esitetty vuosittaiset sähkölaskut kaikille malleille kaikissa skenaarioissa. Kuvassa 7 on esitetty kuukausittaiset sähkölaskut skenaarioille B ja C eri vuosille. Käyn nämä taulukossa ja kuvassa esitetyt tulokset läpi skenaario kerrallaan.

#### Referenssit

Taulukon referenssituloksista nähdään spot-hintojen vaihtelun vaikutus sähkölaskuun: energiakriisin alkaessa vuoden 2021 lopussa spot-hinnat äkillisesti kasvoivat (kuva 4C), jolloin vuoden 2022 vuosittainen sähkölasku tapauksessa KV (kaikki verkosta) on jopa kaksinkertainen sähkönhinnan kannalta "normaaliin" vuoteen 2020 verrattuna. Kun kotitalouden hyödynnettävissä on tässä työssä esitetty 2,4 kWp:n aurinkovoimala, vuosittainen sähkölasku pienenee merkittävästi, tutkituilla vuosilla vähintään yli 150 euroa (vuonna 2020). Vuonna 2022 saadaan suurin säästö 460 euroa, kun sähkönhinta on suurin. Kun energiasysteemiin lisätään Powerwallin kaltainen akku, vähenee vuosittainen sähkölasku SCM-strategialla edelleen 38-50 euroa.

#### Skenaario A

Skenaarion A tuloksista (taulukon sarakkeen "A") nähdään, että neuroverkkomalli pääsee lähelle optimituloksia vuosina 2019-2021. Vuonna 2022 sähkölasku taas poikkeaa selvästi optimista. Tulokset viittaavat siihen, että neuroverkko pystyy löy-

tämään optimaalisen toimintatavan tässä yksinkertaisessa skenaariossa, kun ympäristön muuttajat (kulutus, tuontanto ja sähkönhintaa) ovat samaa suuruusluokkaa kuin mallin koulutuksessa käytetyssä koulutusjoukossa. Kun vuonna 2022 sähkön hinta on selkeästi korkeampi kuin koulutusdatajoukossa, neuroverkon pitää ekstrapoloida ennusteet syötteelle, jota se ei ole ennen nähnyt, ja täten epäonnistuu energianhallinnassa. Tämä tulos implikoi, että neuroverkko ei tässä skenaariossa pysty erottamaan oleellisia syötemuuttujia (kulutus ja tuotanto) optimaalisen tulosteen generoimiseen. Dynaamisella koulutuksella (sarake "A<sub>d</sub>") tulokset hieman paranevat erityisesti vuonna 2022, mutta todennäköisesti dynaamisen koulutuksen optimointiaskeleen askelpituus ja epokkien lukumäärä eivät ole tarpeeksi suuria, jotta malli pääsisi lähemmäs optimiratkaisua. Vuonna 2020 dynaamisen koulutus hieman suurentaa sähkölaskua. Tämä johtuu siitä, että dynaaminen koulutus suoritetaan ensin vuodelle 2019, jolloin alunperin vuodelle 2020 koulutetun mallin parametrit  $\theta$  hieman muuttuvat, eikä dynaaminen tulos vuodelle 2020 enää edusta nimenomaan sille vuodelle optimoitua mallia.

### **Skenaario B**

Skenaariossa B neuroverkkomallilla saadut vuosittaiset sähkölaskut (taulukon sarake "B") ovat vuosina 2019-2021 hyvin lähellä SCM:n tuloksia ja vuonna 2020 tämä referenssilasku jopa alitetaan. Tämä johtuu siitä, että mallin koulutukseen käytettiin vuotta 2020, jolloin tulos kuvastaa koulutusdatalle optimoitua tulosta ja on täten vinoutunut. Dynaaminen koulutus jälleen parantaa erityisesti vuoden 2022 sähkölaskua (taulukon sarake "B<sub>d</sub>"), jolloin neuroverkkomallin sähkölasku alittaa SCM:llä saadun sähkölaskun. Kuvasta 7 huomataan, että neuroverkkomalli pääsee alhaisempiin sähkölaskuihin erityisesti keväällä ja syksyllä, mutta kesäkuukausina sähkölaskut ovat suurempia kuin SCM:llä saadut laskut. Kuten seuraavassa osiossa 3.3 havainnollistetaan, neuroverkkomalli ei hyödynnä kesän ylituotantoa myymällä

tuotantoa verkkoon vaan hukkaa sen, minkä takia neuroverkkomalli ei pääse yhtä alhaisiin sähkölaskuihin kesällä. Tämä tuotannon hukkaus johtuu todennäköisimmin siitä, että koulutusdatassa on vain vähän instansseja, joissa tuotannon myyminen olisi hyvä ratkaisu, jolloin malli ei opi toimintatapaa. Pääsääntöisesti tulokset ovat kuitenkin hyvin lähellä SCM:llä saatuja tuloksia, mikä viittaa joko siihen, että SCM:n tulokset ovat lähellä globaalia optimia, tai siihen, että neuroverkkomalli ei kykene hyödyntämään informaatiota tulevaisuuden sähköhinnoista.

### **Skenaario C**

Skenaariossa C vuosittaiset sähkölaskut (taulukon sarake "C") ovat selvästi pienempiä kuin SCM:llä saadut laskut. Dynaamisella koulutuksella (sarake "C<sub>d</sub>") sähkölaskua saadaan pienennettyä vielä huomattavasti lisää, jolloin sähkölasku on jopa alle puolet SCM:llä saadusta sähkölaskusta (vuonna 2021). Kuten kuvasta 7 nähdään, pienemmät sähkölaskut johtuvat erityisesti akun hyödyntämisestä talvisin. Koska tässä skenaariossa akkuun voidaan ladata sähköä suoraan verkosta, akulla saadaan taloudellista hyötyä lataamalla sitä alhaisen sähköhinnan aikaan vaikkei PV-tuotantoa olisikaan. Dynaamisen ajon aikana malli pyrkii mukautumaan aina vallitseviin olosuhteisiin ja täten oppii hyödyntämään paremmin akkua talvella. Alkuvuonna 2019 talven kuukausittaiset sähkölaskut ovat lähellä skenaarion B sähkölaskuja, sillä tällöin koko vuoden 2020 datalla koulutetulla mallilla ei ole ollut vielä aikaa adaptoitua talven toimintaympäristöön. Loppuvuonna talven sähkölaskut ovat jo selvästi pienempiä. Tämä tulos havainnollistaa dynaamisen ajonaikaisen koulutuksen tärkeyttä: koska ympäristön olosuhteet vaihtuvat, täytyy HEMS-strategian pystyä mukautumaan näihin muutoksiin. Toisaalta kuvasta 7 huomataan, että ke-  
säkuukausina sähkölaskut ovat suurempia kuin skenaarion B tapauksessa, ja ne itseasiassa kasvavat suhteessa skenaarioon B vuosien kuluessa. Tämä tulos on odotamaton, sillä skenaarion C tapauksessa säästöä pitäisi kahden akun lisätoiminnon

takia pystyä tekemään enemmän skenaarioon B nähden myös kesällä. On mahdollista, että dynaamisen ajon aikana talven datapisteillä on suuren säästöpotentiaalin takia enemmän painoarvoa neuroverkon koulutuksessa, jolloin kesän toimintamallit jäävät huonoiksi ja jopa huononevat entisestään. Tätä ilmiötä voisi jatkossa tutkia varioimalla dynaamisen koulutuksen askelpituutta ja epokkien lukumäärää.

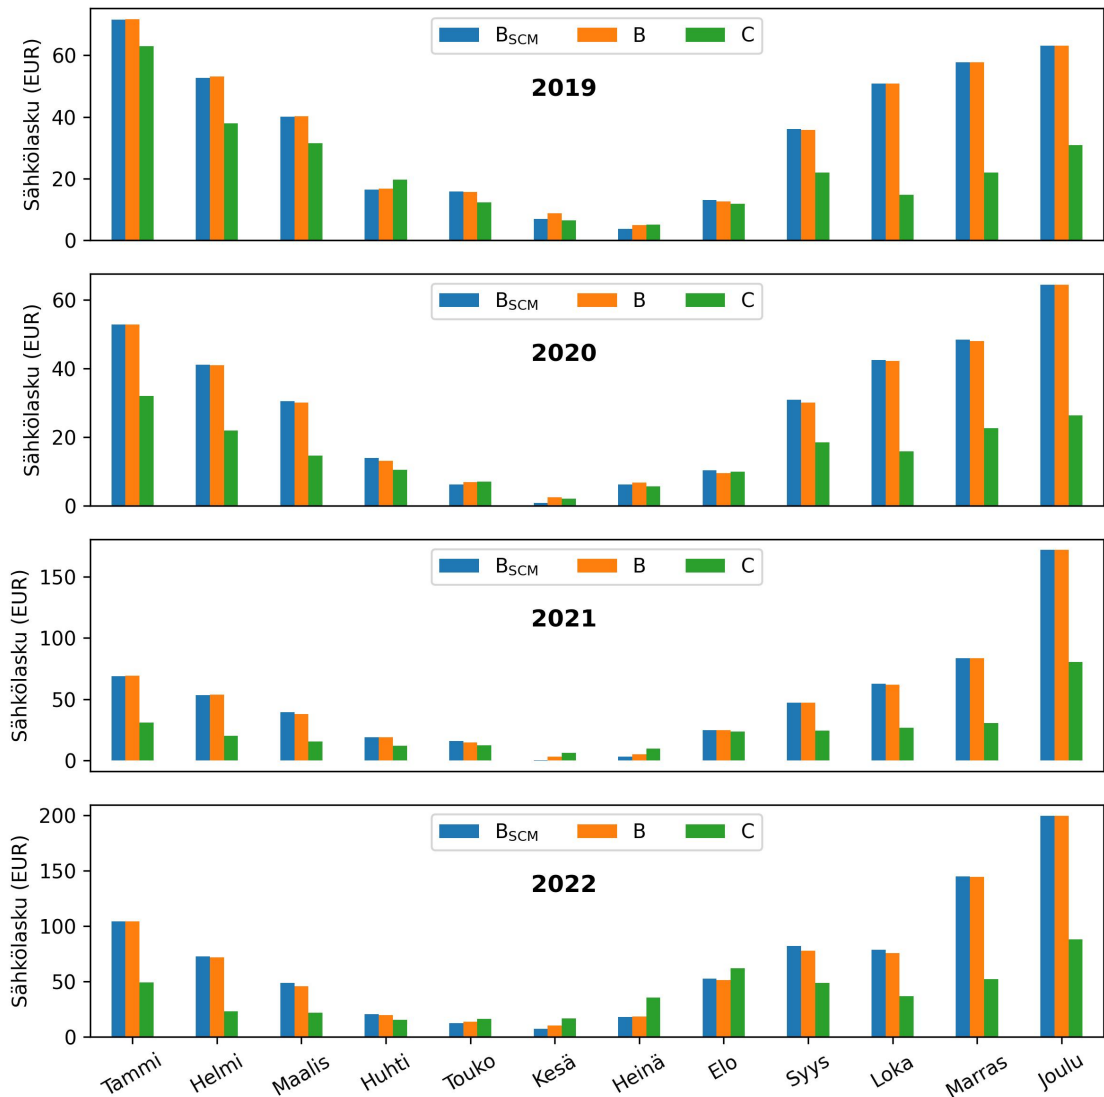
Jatkossa tuloksilla viitataan nimenomaan dynaamisen koulutuksen tuloksiin, ellen erikseen toisin mainitse.

Taulukko VIII. Vuosittaiset sähkölaskut eri skenaarioille. KV: Kaikki sähkö ostetaan verkosta;  $A_{\text{optimi}}$ : PV ilman akkua, ylimääräinen tuotanto myydään (skenaario A:n optimiratkaisu);  $B_{\text{SCM}}$ : Skenaario B SCM-strategialla. Skenaarion A, B ja C tulokset esitetty vuoden 2020 datalla koulutetulla mallilla (ilman alaindeksiä) sekä dynaamisen koulutusajon jälkeen (alaindeksi d). Kaikki arvot yksikössä EUR.

Vuosi	KV	$A_{\text{optimi}}$	A	$A_d$	$B_{\text{SCM}}$	B	$B_d$	C	$C_d$
2019	649,6	470,0	471,0	471,0	428,7	432,2	431,6	419,9	277,5
2020	542,4	390,2	390,3*	390,4	347,9	347,0*	347,2	304,3*	187,4
2021	849,6	628,0	630,4	629,7	589,2	591,2	591,0	494,8	290,8
2022	1350,2	890,7	923,4	894,3	840,9	854,4	832,5	602,1	465,2

\* Tulokset laskettu koulutusjoukolle ja ovat täten vinoutuneita





Kuva 7. Kuukausittaiset sähkölaskut skenaarioille B ja C eri vuosina. Neuroverkko-mallien tulokset ovat dynaamisen koulutusajon tuloksia.


### 3.3 Mallien toimintojen tarkastelu

#### Skenaario B

Kuvassa 8 on havainnollistettu SCM:n toimintaa kolmen päivän jaksolta 10.-12.7.2019. Kuva on jaettu kahteen osaan: kuvassa 8A havainnollistetaan PV-tuotannon jakaantuminen taloon ( $PV \rightarrow T$ ), akkuun ( $PV \rightarrow A$ ) sekä verkkoon ( $PV \rightarrow V$ ) ja kuvassa 8B havainnollistetaan, mistä lähteistä kulutus katetaan. Käytettäessä SCM:ää kaik-

ki mahdollinen kulutus katetaan tuotannosta, minkä takia kuvan  $PV \rightarrow T$  -käyrä jää  $PV$ - ja kulutuskäyrien alle käytännössä kokonaan. Kuun 10. päivänä ylituotanto varastoidaan akkuun, ja tämä varaus käytetään seuraavan yön ja aamupäivän aikana kokonaan. Kuun 11. päivän aamun ja illan sekä seuraavan yön kulutus katetaan verkosta ostetulla sähköllä. Kuvaaajasta huomataan, että sähkönhinta on 11. päivänä korkea, mutta SCM ei hyödynnä tätä informaatiota, vaikka sähköhinnat julkaistaan jo edellisenä päivänä. Kuun 12. päivänä ylituotantoa on sen verran, että kulutus katetaan suoraan tuotetulla sähköllä tai sen päivän aikana akkuun varastoidulla sähköllä, eikä täten sähköä tarvitse ostaa verkosta.

### SCM, Skenaario B, 10.-12.07.2019

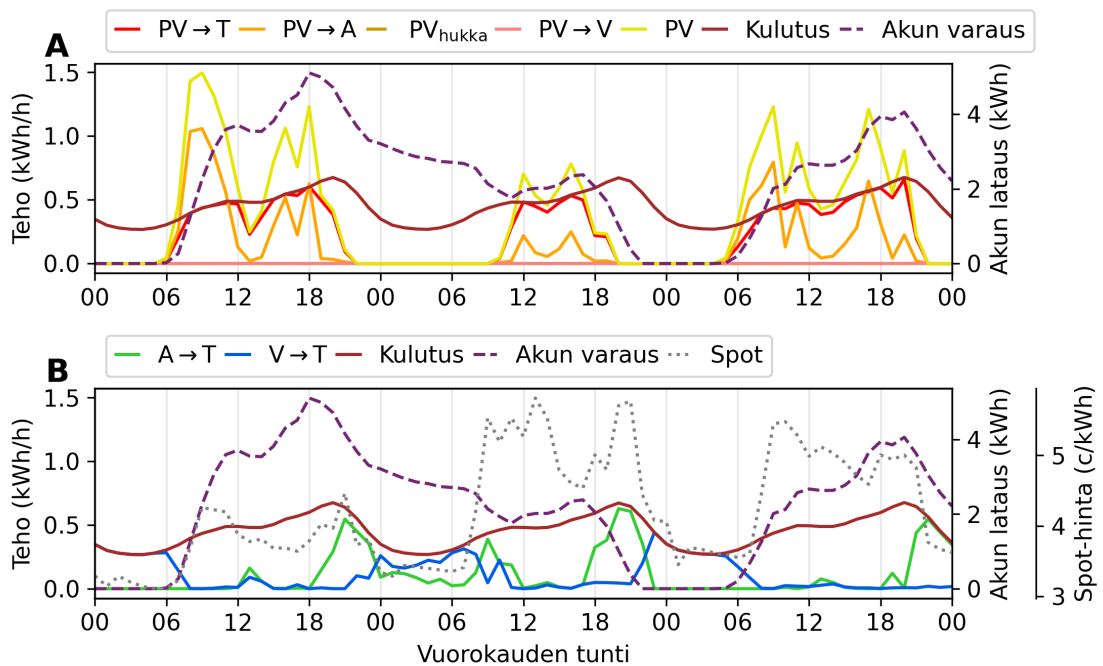


Kuva 8. SCM-strategian toiminta kolmen päivän ajalta.  $PV \rightarrow T$ : itse käytetty tuotanto;  $PV \rightarrow A$ : akkuun varastoitu tuotanto;  $PV \rightarrow V$ : verkkoon myyty tuotanto;  $PV$ : kokonaistuotanto;  $A \rightarrow T$ : akusta taloon purettu varaus;  $V \rightarrow T$ : verkosta ostettu sähkö.

Kuvassa 9 on esitetty neuroverkkomallin toiminta samalle kolmelle vuorokaudelle. Pääsääntöisesti jälleen kaikki mahdollinen tuotanto käytetään itse ja ylituotanto varastoidaan akkuun. Ero SCM:n kanssa ilmenee akun purkamisen ajoittamisessa:

nyt yön aikana akkua ei pureta tyhjäksi vaan säästetään 11. päivälle, jolloin tuotantoa on vähän ja sähkönhintaa saa kolmen vuorokauden huippuarvonsa. Akkuun säästetty lataus käytetään illalla 11. päivänä korkean sähkönhinnan aikaan. Tästä havainnosta voidaan todeta, että neuroverkkomalli pystyy ainakin jossakin määrin tekemään intuitiivisesti järkeviä ratkaisuja. Tästä huolimatta ja hyvin yllättävästi SCM:n sähkölasku näiden kolmen päivän yli (0,94 EUR) on pienempi kuin neuroverkkomallilla saatu sähkölasku (0,96 EUR). Tämä ero johtuu siitä, että neuroverkkomalli hukkaa näiden kolmen vuorokauden aikana noin 12 Wh energiaa todennäköisesti yrittämällä myydä tuotantoa verkkoon samanaikaisesti kun sieltä ostetaan sähköä, mikä estetään yhtälön (30) mukaisesti. Olettaen, että tämän hukatun energian hinta on sama kuin hetkittäinen sähkön myyntihinta, on hukatun sähkön arvo 0,05 EUR.

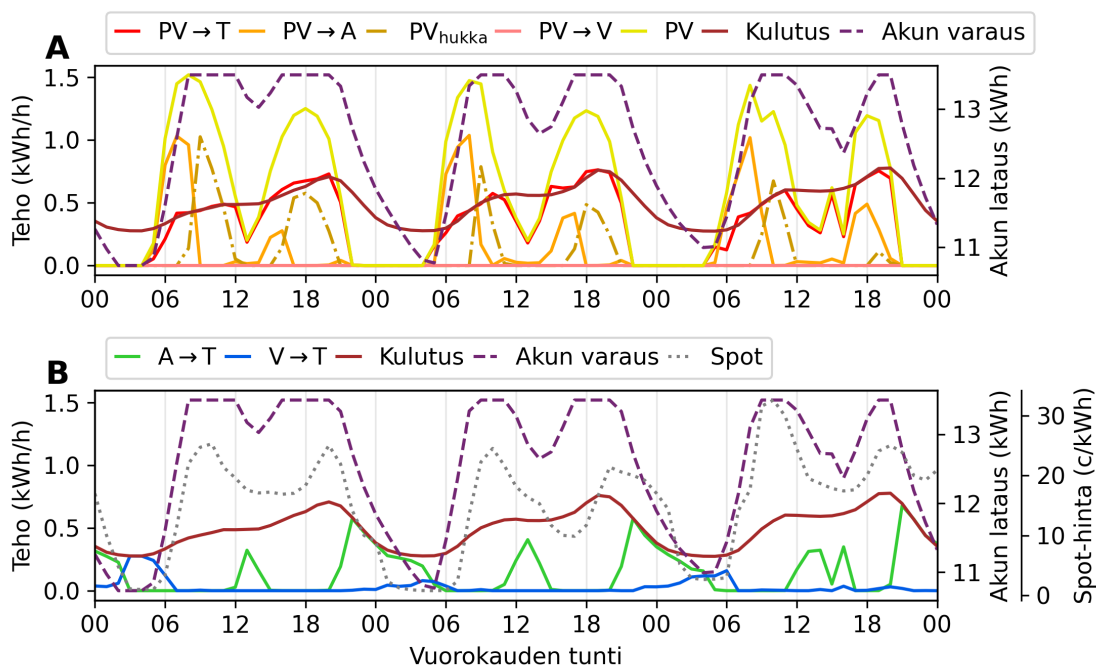
### Skenaario B, 10.-12.07.2019



Kuva 9. Neuroverkkomallin toiminta kolmen päivän ajalta. PV → T: itse käytetty tuotanto; PV → A: akkuun varastoitu tuotanto; PV<sub>hukka</sub>: hukattu tuotanto; PV → V: verkkoon myyty tuotanto; PV: kokonaistuotanto; A → T: akusta taloon purettu varaus; V → T: verkosta ostettu sähkö.

Tämän työn neuroverkkomallin suurin ongelma on se, että se on taipuvainen hukkaamaan energiaa. Kuvassa 10 on esitetty kolmen päivän aurinkoinen periodi, jonka aikana päivisin akku täyttyy ja tuotantoa hukataan. Hukattu energia johtuu siitä, että tämä tuotanto koitetaan ladata akkuun eikä myydä verkkoon. Koska akun kapasiteetti on suuri suhteessa aurinkovoimalan kapasiteettiin, tulee koulutusdatassa vain vähän instansseja, joissa tuotannon myyminen verkkoon on kannattavaa, eikä täten malli opi toimintamallia näihin tilanteisiin.

### Skenaario B, 15.-17.06.2022




Kuva 10. Neuroverkkomallin toiminta kolmen päivän ajalta.  $PV \rightarrow T$ : itse käytetty tuotanto;  $PV \rightarrow A$ : akkuun varastoitu tuotanto;  $PV_{\text{hukka}}$ : hukattu tuotanto;  $PV \rightarrow V$ : verkkoon myyty tuotanto;  $PV$ : kokonaistuotanto;  $A \rightarrow T$ : akusta taloon purettu varaus;  $V \rightarrow T$ : verkosta ostettu sähkö.

### Skenaario C

Kuvassa 11 on esitetty sama kolmen päivän periodi heinäkuulta 2019 skenaarion C mukaiselle neuroverkkomallille. Skenaarion B tavoin akun varausta säästellään 10. päivään asti, mutta akun lataus ei riitä illan sähkönhintahuippuun asti, jolloin osa kalliista sähköstä joudutaan ostamaan verkosta. Kolmen päivän kokonaishin-

ta on 0,98 EUR. Lisäksi kuvasta 11A voidaan huomata, että kaikkea mahdollista tuotantoa ei hyödynnetä kulutuksen kattamiseen, sillä  $PV \rightarrow T$  -viiva ei asetu ai-  
van päällekkäin esimerkiksi 10. päivän kulutus-viivan kanssa. Tämän epäoptimaali-  
suuden aiheuttama lisä sähkölaskuun tältä kolmelta päivältä on 0,10 EUR. Ilman  
dynaamista koulutusta käyttäen vuodella 2020 koulutettua tämän kolmen päivän  
sähkölasku on 0,86 EUR (kuvaa ei esitetty), joka on selvästi pienempi kuin SCM:llä  
saatu 0,94 euron sähkölasku. Tämä tulos tukee aiemmin esitettyä hypoteesia siitä,  
että dynaaminen koulutus heikentää mallin toimintaa kesäisin.

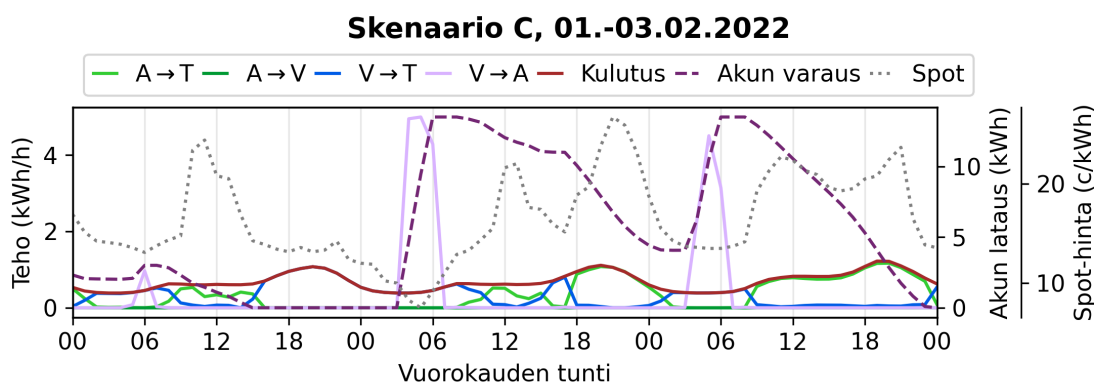
### Skenaario C, 10.-12.07.2019



Kuva 11. Neuroverkkomallin toiminta kolmen päivän ajalta.  $PV \rightarrow T$ : itse käytetty tuotanto;  $PV \rightarrow A$ : akkuun varastoitu tuotanto;  $PV_{hukka}$ : hukattu tuotanto;  $PV \rightarrow V$ : verkkoon myyty tuotanto;  $PV$ : kokonaistuotanto;  $A \rightarrow T$ : akusta taloon purettu varaus;  $A \rightarrow V$ : akusta verkkoon purettu varaus;  $V \rightarrow T$ : verkosta taloon ostettu sähkö;  $V \rightarrow A$ : verkosta akkuun ostettu sähkö.

Kuvassa 12 on havainnollistettu neuroverkkomallin toimintaa kolmelta päivältä talvella 2022. Yön halpa sähkö hyödynnetään lataamalla akku täyteen ja käyttämällä tämä varaus päivän aikana. Malli hyödyntää myös päivisin sähkönhinnan


päivänsisäistä vaihtelua. Päivisin sähkönhinnan ollessa matala akun latausta säädetään ostamalla sähköä verkosta, kuten esimerkiksi 2. päivän iltapäivällä. Aamulla 1. päivänä akun lataus ja sähkönhinta ovat matalia, jolloin akkua ladataan sen verran verkosta, että päivän hintahuippu voidaan kattaa pääsääntöisesti tällä akkuun varastoidulla sähköllä. Talvisin malli näyttää siis tekevän taloudellisesti hyviä toimintoja.



Kuva 12. Neuroverkkomallin toiminta kolmen päivän ajalta.  $A \rightarrow T$ : akusta taloon purettu varaus,  $A \rightarrow V$ : akusta verkkoon purettu varaus,  $V \rightarrow T$ : verkosta taloon ostettu sähkö,  $V \rightarrow A$ : verkosta akkuun ostettu sähkö.

Äskettäin 5.1.2024 mitattiin Suomen historian korkein sähkönhinta [64]. Tässä työssä käytetyllä kulutusdatalla tämän päivän sähkölasku olisi noin 23 euroa ilman akkua, joten säästöpotentiaalia tälle yhdelle päivälle on paljon. Tämän vuorokauden kokonaiskulutus on 17 kWh, joten täydellä akulla pitäisi pystyä kattamaan melkein koko vuorokauden kulutus. Kuvassa 13 on esitetty mallin toiminta 4.-6. päivänä tammikuuta. Kuvasta voidaan huomata, että vaikka akku ladataan yön aikana täyteen, suurin osa 5. päivän kulutuksesta ostetaan verkosta, jolloin päivän sähkölasku on 18 euroa. Tulos on mielenkiintoinen, sillä 4. päivän aamupäivällä ja 6. päivänä malli näyttäisi toimivan hyvin, sillä tällöin se käyttää akun latausta pääasiallisena energian lähteenä päivisin. Kun 5. päivän spot-hinnat realisoituvat 4. päivän iltapäivänä, malli äkillisesti vaihtaa akkuenergian verkkoenergiaan. Historiallisen korkeat hinnat saavat mallin tekemään taloudellisesti järkeviin toimintoihin nähden päinvas-

taisa toimintoja. Koska malli toimii yleisesti talvisin hyvin, on tässäkin tapauksessa todennäköisesti kyse siitä, että koulutusdatassa ei tällaisia datapisteitä ole ollut, jolloin malli joutuu ekstrapoloimaan tulosteita huonoin tuloksin (kuten kesän suuren ylituotannon hukkaamisessa, kuva 10).



Kuva 13. Neuroverkkomallin toiminta kolmen päivän ajalta.  $A \rightarrow T$ : akusta taloon purettu varaus;  $A \rightarrow V$ : akusta verkkoon purettu varaus;  $V \rightarrow T$ : verkosta taloon ostettu sähkö;  $V \rightarrow A$ : verkosta akkuun ostettu sähkö.

### 3.4 Akunkäytön hinta ja neuroverkkostrategian kokonaishyöty

Tässä osiossa tarkastelen skenaarion B ja C kokonaishyötyä ja -hintaa, kun sähkölaskun lisäksi huomioidaan akunkäytön hinta ja hukattu energia. Määritän hukatun energian kahteen kategoriaan:

- (1)  $PV_{\text{hukka}}$ , joka sisältää PV-tuotannon, jota koitettiin myydä verkkoon tai ladata akkuun, mutta estettiin osittain tai kokonaan yhtälöiden (26) ja (30) ehtojen takia.
- (2)  $T_{\text{hukka}}$ , joka sisältää PV:stä ja akusta taloon syötetyn ylimääräisen energian, kun talon kulutus on jo katettu.

Taulukossa IX on esitetty nämä dynaamisen koulutusajon aikana saadut hukatut energiat vuosille 2019-2022 skenaariolla B ja C. Arvioin näiden hukattujen energioiden rahallisia arvoja  $C_{PV,\text{hukka}}$  ja  $C_{T,\text{hukka}}$  kertomalla vuosittaiset hukatut energiat sen vuoden myyntihinnan  $p_{\text{myynti}}$  keskiarvolla (taulukko IV). Taulukosta nähdään,

että  $PV_{\text{hukka}}$  ja  $T_{\text{hukka}}$  ovat suuruudeltaan samaa suuruusluokkaa vuosina 2019-2021. Vuonna 2022 hukatun energian määrä on molemmissa kategorioissa selvästi suurempi, mikä todennäköisesti johtuu juurikin mallin herkkyydestä muuttuville sähkönhinnoille. Kokonaisuudessaan hukatun sähkön arvo korkeimmillaan vastaa vuosina 2019-2021 noin muutamaa euroa ja vuonna 2022 korkeimmillaan taas noin 30 euroa.

Taulukossa IX on myös esitetty vuosittaiset arvot akun kapasiteetin menetykselle  $\Delta\text{SOH}$  ja vastaavalle akunkäytön hinnalle  $C_{\text{SOH}}$ . Skenaariossa B SCM:n ja neuroverkkomallin akunkäyttö on ikääntymisen kannalta hyvin samanlaista.  $\Delta\text{SOH}$  vaihtelee hieman vuosittain, mutta on keskimäärin noin 1,5 %-yks./vuosi, jonka arvo noin 140 euroa (taulukossa  $\Delta\text{SOH}$  on esitetty kahden merkitsevän numeron tarkkuudella, minkä takia arvot  $C_{\text{SOH}}$  eroavat vaikka  $\Delta\text{SOH}$  olisi sama). Yleisesti ottaen neuroverkkomallilla ikääntyminen on pienempää, mikä on odotettua, sillä SCM-strategian on todettu olevan eri HEMS-startegioista akkua nopeiten ikäännyttävä [1]. Ero on kuitenkin hyvin pieni, ja itse asiassa vuonna 2021 akun ikääntyminen neuroverkkomallilla on suurempaa kuin SCM:llä. Olettaen akun eliniän vastaavan 30 %:n kapasiteetin menetystä (vastaten Powerwallin takuuehtoja) vuosittainen 1,5 %-yksikön ikääntyminen vastaisi noin 67 käyttövuotta ( $100\% / 1,5\% \text{-yks.} / \text{v} \approx 67 \text{ v}$ , huom. 1,5 %-yks. edustaa ikääntymistä suhteessa 30 %:n kapasiteetin menetykseen). Tämä käyttöikä on todella pitkä, sillä työssä [1] laskettiin SCM-strategialla Australiassa sijaitseville PV-akku-järjestelmille käyttöikäksi noin 13 vuotta. Vertailu kahden eri systeemin ja eri lokaation välillä on kuitenkin vaikeaa. Australiassa akkua käytetään aurinkoisen sään takia enemmän kuin Suomessa, jolloin akun ikääntymisen voisi odottaa olevan nopeampaa kuin Suomessa. Lisäksi työssä [1] akun ja PV:n kWh/kWp suhdeluvut (1,4–2,2) olivat pienempiä kuin tässä työssä (noin 7), jolloin PV-tuotantoa on enemmän suhteessa akun kokoon ja täten myös akkua käytetään enemmän.

Skenaariolla C akkua käytetään vuoden ympäri, jolloin ikääntyminen on selväs-



ti suurempaa kuin skenaariossa B. Vuonna 2022 ikääntyminen on 9,3 %-yks., joka vastaisi noin 11 vuoden käyttöikä. Tesla takaa Powerwall-akuille 10 vuoden käyttöiän, joten tulos on kuitenkin järkevää suuruusluokkaa. Jokaisena vuonna akunkäytön hinta on suurempi kuin skenaarion B sähkölaskut, jolloin skenaarion C kokonaissäätöpotentiaali ei olekaan niin suuri kuin pelkkien sähkölaskujen perusteella ymmärtäisi.

Kirjallisuudessa vain harvassa työssä määritetään akunkäytölle erikseen hintaa. Työssä [24] SCM:n kokonaishinta oli 12 % suurempi muihin HEMS-strategioihin verrattuna, mikä johtui käytännössä pelkästään akun nopeammasta ikääntymisestä. Työssä [25] akunkäytön hinnaksi arvioitiin noin 10 % 165 MWp:n tuulipuiston kokonaiskustannuksista, jossa muut kustannukset tulevat seuraavan päivän ennustusvirheen sakosta (jos tuulipuisto ei pysty tuottamaan seuraavalle päivälle ennustettua energiaa joko tuulituotannolla tai akulla, sen täytyy maksaa sakkoa). Suuruusluokaltaan nämä akunkäytön hinnat ovat hieman pienempiä kuin tässä työssä esitetyt skenaarion B akunkäytön hinnat. Skenaariossa C akunkäytön hinnan osuus kokonaishinnasta on edelleen vielä suurempi.


Tässä työssä estimoidut ikääntymisnopeuden ovat suuntaa antavia eivätkä tarkkoja yksinkertaisen akkumallin ja ikääntymismallin suurpiirteisten parametrien estimointien takia. Koska tämän työn tarkoitus on esittää neuroverkkomallin toimintaa, nämä akunkäytön hintojen suuntaa antavat arviot ovat riittäviä tähän analyysiin havainnollistamaan skenaarioiden välisiä eroja.

Summaamalla sähkölaskuun akunkäytön hinnan ja vähentämällä siitä hukattujen energioiden arvot saadaan vuosittainen kokonaishinta  $C_{\text{kokonais}}$  eri HEMS-strategioille. Nämä vuosittaiset kokonaishinnat on esitetty taulukossa IX sekä kuvassa 14. Yleisesti ottaen skenaariossa B neuroverkkomallilla saadut kokonaishinnat ovat hieman pienempiä kuin SCM:llä saadut kokonaishinnat poislukien vuosi 2021. Skenaarion C kokonaishinnat ovat taas huomattavasti suurempia skenaarion

B neuroverkkomallin ja SCM-strategiaan verrattuna, mikä johtuu korkeasta akunkäytön hinnasta. Hukatun energian suuruus on häviävän pieni verrattuna sähkölaskuun ja akunkäytön hintaan. Vaikka akunkäytön hinta ei välttämättä olisi täysin todenmukainen, tulokset havainnollistavat sen ja sähkölaskun suhdetta. Vertaillen skenaarion B tuloksia skenaarion C tuloksiin on ilmeistä, että akunkäytön hinta tulee huomioida HEMS-strategioinnissa, jos halutaan maksimoida taloudellinen hyöty akun kanssa. Vaikka skenaariossa C neuroverkkomalli saavuttaa jopa yli puolet pienemmän vuosittaisen sähkölaskun, akunkäytön hinnan takia skenaario B on taloudellisesti kannattavampi. Kuvassa on esitetty myös skenaarion A sähkölaskut, jotka ovat selvästi pienempiä kuin skenaarioiden B ja C kokonaishinnat. Koska skenaariossa A ei ole akkua, tulos viittaa siihen, että akku ei ole tämän työn tapauksessa taloudellisesti kannattava osa energiasysteemiä.

Taulukko IX. Vuosittainen hukatun tuotannon määrä  $PV_{\text{hukka}}$  ja sen arvo  $C_{PV,\text{hukka}}$ , kulutuksen kattamiseen hukattu energia  $T_{\text{hukka}}$  ja sen arvo  $C_{T,\text{hukka}}$ , akun ikääntymisen  $\Delta\text{SOH}$ , akunkäytön hinta  $C_{\text{SOH}}$  sekä energiajärjestelmän kokonaishinta  $C_{\text{kokonais}}$ .

		$PV_{\text{hukka}}$	$C_{PV,\text{hukka}}$	$T_{\text{hukka}}$	$C_{T,\text{hukka}}$	$\Delta\text{SOH}$	$C_{\text{SOH}}$	$C_{\text{kokonais}}$
	Skenaario	(kWh)	(EUR)	(kWh)	(EUR)	(-)	(EUR)	(EUR)
2019	SCM	0	0	0	0	0,015	137,0	565,7
	B	41,9	1,7	10,0	0,4	0,015	130,5	560,0
	C	14,6	0,6	21,0	0,8	0,049	439,8	715,9
2020	SCM	0	0	0	0	0,016	146,1	494,0
	B	68,9	1,7	17,8	0,4	0,016	143,0	488,1
	C	12,8	0,3	26,1	0,6	0,056	503,5	689,9
2021	SCM	0	0	0	0	0,014	129,2	718,4
	B	44,1	3,0	25,1	1,7	0,015	134,5	720,7
	C	25,1	1,7	25,4	1,7	0,072	646,6	933,9
2022	SCM	0	0	0	0	0,017	149,2	990,1
	B	72,0	10,4	43,7	6,3	0,016	147,4	963,2
	C	132,9	19,2	74,4	10,7	0,093	836,8	1272,1



Kuva 14. Eri skenaarioiden kokonaishinnan komponentit. Skenaariion A tulokset edustavat optimiratkaisua eivätkä neuroverkkomallin tuloksia.  $C_{\text{lasku}}$ : sähkölasku;  $C_{\text{SOH}}$ : akunkäytön hinta;  $C_{\text{PV, hukka}}$ : hukatun tuotannon hinta;  $C_{\text{T, hukka}}$ : taloon hukatun energian hinta.

## 4 Jatkotutkimusaiheita

Tässä työssä olen tarkastellut neuroverkkopohjaista lähestymistapaa HEMS-ongelmaan eri skenaarioissa. Tuloksien merkittävyyttä rajoittaa kuitenkin se, että globaaleja optimiratkaisuja ei ole vertailukohteeksi. Koska akun tila riippuu aikaisemmista valinnoista, on HEMS:n optimointi haastavaa, erityisesti kun skenaario monimutkaistuu ja optimointimuuttujien lukumäärä kasvaa. Ilman luotettavaa optimointitulosta on vaikea sanoa, kuinka kaukana SCM:n ja neuroverkkomallin tulokset ovat pienimmästä mahdollisesta sähkölaskusta. Tämän lisäksi työssä käytetty kulutusprofiili oli keskiarvoistettu tyyppikäyttäjäprofiili, eikä täten edusta todennukaista kulutusprofiilia. Todenmukainen kulutusprofiili on sähköä käyttävien kodinkoneiden käytön taakia kohinaista, jolloin taloudellinen energianhallinta on haastavampaa. Jo 10 kW:n sähkökiukaan lämmityksestä aiheutuva kulutus melkein kymmenkertaistaisi tässä työssä käytetyn tyyppikäyttäjäprofiilin maksimikulutuksen (kuva 5). Neuroverkkomallin implementointi tosielämän HEMS:iin vaatii kuitenkin sen, että malli toimii

hyvin oikealla kulutusdatalla.

Lisäksi tulosten tarkentaminen todenmukaisemmiksi vaatii tarkempaa akkumallia. Erityisesti akun hyötysuhteen tarkempi mallintaminen sekä akun ikääntymisen huomioiminen simulaatiossa ovat seikkoja, jotka jatkotutkimuksessa pitää huomioida. Neuroverkkomallin parantaminen huomioimalla akun ikääntymisen aiheuttaman akunkäytön hinnan sakkofunktiossa tarvitsee myös jatkotutkimusta. Akunkäytön huomioimisella sakkofunktiossa malli oppisi tekemään ratkaisuja, jotka minimoisivat energiajärjestelmän kokonaishinnan.

Tämän työn tulokset viittaavat siihen, että esitetyllä neuroverkkolähestymistavalla on potentiaalia tehdä taloudellisesti järkeviä ratkaisuja. Lähestymistapa vaatii kuitenkin jatkotutkimusta. Seuraava vaihe mallin tutkimuksessa olisi ratkaista edellä esitetyt kaksi rajoittavaa tekijää käyttämällä oikeaa kulutusdataa ja estimoimalla vertailukohteeksi globaalin optimituloksen. Näiden lisäksi neuroverkkolähestymistapaa tulisi vertailla muihin yleisesti käytettyihin HEMS-strategioihin, kuten optimointi- tai vahvistusoppimisstrategioihin. Helpoiten tämä onnistuisi etsimällä kirjallisuuslähteen, jossa vertaillaan eri HEMS-strategioita, ja joka tarjoaisi siinä työssä käytetyn datan. Tällöin neuroverkkomallin tuloksia voisi vertailla suoraan työssä esitettyihin tuloksiin.

Neuroverkkomallia voisi edelleen parantaa kokeilemalla toisenlaista syötedatan kuvailijaa ja varioida syötedatan muuttujia. Syötedata ja sen kuvailu on neuroverkon toiminnan kannalta yksi oleellisimmista seikoista. Sen sijaan, että tunnittaiset ympäristön muuttujat kuvataan syötevektorissa yksittäisinä datapisteinä, voi ne kuvata todennäköisyysjakauman kaltaisena jakaumana (jolloin esimerkiksi tunnin  $h$  tuotanto kuvataan diskreettinä jakaumana käyttäen useampaa syötevektorin neuronina). Erityisesti jos mallin syöteenä hyödynnettäisi ennusteita lähitulevaisuuden tuotannosta ja kulutuksesta, voisi ennusteiden epävarmuuden sisällyttää syötteeseen jakauman avulla. Vaikka teoriassa tämän työn malli voisi implisiittisesti jol-

lakin tasolla oppia ennustumaan lähitulevaisuuden tuotanto- ja kulutusennusteet, tulevaisuuden työssä kannattaisi ketjuttaa erillisten ennustemallien tulosteet tämän neuroverkkomallin syötteeksi. Lisäksi koulutusdatan määrää tulisi kasvattaa. Tässä työssä mallin koulutukseen (pl. dynaaminen koulutus) käytettiin vain vuoden 2020 dataa, joka monistettiin kymmenkertaiseksi erilaisten akun alkulatauksien kattamiseksi. Vuonna 2022 mallin toiminta oli huonoa. Koulutukseen voisi käyttää dataa usealta vuodelta ja huolehtia siitä, että koulutusdatajoukossa on riittävästi datapisteitä eri sähkönhinnan ja tuotannon alueilta. Jotta malli oppisi myymään tuotantoa verkkoon, tulisi koulutusdatassa olla riittävästi sellaisia korkean tuotannon ajanjaksoja, joissa akku ladataan täyteen.

Lisäksi mallinvalintaa voisi kasvattaa kattamaan esimerkiksi useampia episodipituuksia yhden viikon lisäksi. Kokeiluni mukaan pidempi kahden viikon episodi paransi tuloksia hieman viikkoon verrattuna, mutta kahden viikon episodin vaatiman pitkän koulutusajan takia päädyin käyttämään vain viikon episodina. Dynaamista koulutusta pitää edelleen parantaa, sillä tässä työssä dynaaminen koulutus ei skenaarion C tapauksessa parantanut mallin toimintaa kesäkuukausina. Dynaamiselle koulutukselle voisi tehdä oman mallinvalinnan, johon sisältyisi mallin päivitysväli, epokkien määrä sekä Adam-optimoijan askelpituus ja muut mahdolliset hyperparametrit.

Neuroverkkolähestymistävän vahvuus on se, että se on adaptoituva ja sitä voi muokata eri skenaarioille sopivaksi esimerkiksi muokkaamalla sakkofunktiota. Jos tästä mallista saisi jatkotutkimuksen avulla hyvin toimivan, voisi sen kouluttaa suurella määrällä dataa vaihtelevista olosuhteista ja vaihtelevalla kulutus- ja tuotanto-profileilla. Tämän jälkeen mallin voisi implementoida eri systeemeihin lyhyemmällä siirtokoulutuksella, jolloin malli räätälöityisi systeemikohtaisesti. Hyvin toimivaa neuroverkkomallia voisi käyttää myös akullisten energiasysteemien teknoekonomiseen skenaarioanalyysiin mitoituksen ja taloudellisen kannattavuuden tutkimiseen.

Lisäksi neuroverkkolähestymistapaa voisi hyödyntää myös muilla tuotantoteknologioilla kuten tuulivoimalla. Mallia mahdollisesti pitäisi kuitenkin muokata eri varastointiteknologioille sopiviksi. Esimerkiksi pumppuvoimalaitokselle tulisi huomioida sen vasteaika, sillä toiminnon päättämisestä kestää minuutteja ennenkuin siitä saadaan haluttu energia. Jos vasteajan olettaisi olevan litiumioniakun tavoin merkityksettömän pieni, jo tunnin simulaatioresoluutiolla voisi saada epärealistisia tuloksia.

## 5 Yhteenveto

Tässä työssä tutkin uudenlaisen neuroverkkopohjaisen HEMS-mallin käyttökelpoisuutta aurinkovoimalalla ja akulla varustetun kotitalouden energianhallintaan erilaisissa skenaarioissa. Vertailin sen tuloksia ja toimintaa yksinkertaiseen sääntöpohjaiseen referenssistrategiaan. Tutkimuskysymykseni olivat: (1) saavutetaanko neuroverkkomallilla suurempi taloudellinen hyöty kuin yksinkertaisella sääntöpohjaisella mallilla ja (2) millainen taloudellinen hyöty eri aurinkovoimala-akku-skenaarioilla saavutetaan Suomen olosuhteissa.

Neuroverkkomallilla saavutettiin käytännössä samat tulokset kuin sääntöpohjaisella mallilla, eikä neuroverkkomalli täten tuonut taloudellista lisäarvoa. Skenaariossa, jossa akkua voitiin ladata suoraan verkosta, neuroverkkomallilla vuosittainen sähkölasku pieneni merkittävästi (tässä skenaariossa ei ollut referenssistrategiaa). Suuri säästö johtui siitä, että talvella halpaa yösähköä hyödynnettiin varastoimalla sitä akkuun. Tällöin kuitenkin akku ikääntyi selvästi nopeammin. Kun akunkäytön hinta huomioitiin kokonaiskustannuksissa sähkölaskun lisäksi, olivat akulliset skenaariot taloudellisesti kannattamattomia.

Vaikka neuroverkkomallilla ei saavutettu selviä taloudellisia hyötyjä sääntöpohjaiseen strategiaan verrattuna, se osasi hyödyntää seuraavan vuorokauden sähkönhintoja päätöksenteossaan. Tämä havainto osoittaa, että neuroverkkomallilla on kyky tehdä taloudellisesti järkeviä ratkaisuja dynaamisilla sähkönhinnoilla. Mallin hie-

nosäädöllä ja perusteellisemmalla koulutuksella siitä voisi saada tehokkaan HEMS-strategian, jota voisi hyödyntää HEMS:n lisäksi energiajärjestelmätutkimuksessa muun muassa komponenttien mitoitukseen.

## 6 Kiitokset

Kiitän ohjaajiani dosentti Johannes Niskasta ja TkT Sami Jouttijärveä kaikesta heiltä saamastani tuesta, avusta ja ideoista. Olen kiitollinen professori Kati Miettuselle mahdollisuudesta työskennellä ja tehdä tämä opinnäytetyö hänen tutkimusryhmässään sekä myös tätä työtä koskevista ideoista ja ajatuksista. Kiitän Suomen Akatemian Strategisen tutkimuksen neuvostoa (*RealSolar*-projekti, 358542) sekä Salon kaupunkia ja Turun yliopistoa (*HEMS*-projekti) rahoituksesta. Lisäksi kiitän Turun ammattikorkeakoulun Uuden energian tutkimuskeskuksen Samuli Rantaa ja Hugo Huertaa heidän tarjoamastaan mittausdatasta sekä avuliaisuudesta kaikkiin dataan liittyvissä asioissa. Lopuksi haluan kiittää perhettäni ja läheisiäni sekä kollegoitani tuesta ja kannustuksesta.



## Viitteet

- [1] D. Azuatalam, K. Paridari, Y. Ma, M. Förstl, A. C. Chapman ja G. Verbič, *Renewable and Sustainable Energy Reviews* **112**, 555 (2019).
- [2] B. Han, Y. Zahraoui, M. Mubin, S. Mekhilef, M. Seyedmahmoudian ja A. Stojcevski, *IEEE Access* **11**, 19999 (2023).
- [3] S. Lee ja D. H. Choi, *Sensors* 2019, Vol. 19, Page 3937 **19**, 3937 (2019).
- [4] Motiva Oy, Aurinkosähkövoimalat, <https://aurinkosahkovoimalat.fi> (Haettu: 17.1.2024).
- [5] Ympäristöhallinto, Huuhansuon-Suurisuon aurinkovoimahanke, Lappeenranta, <https://www.ymparisto.fi/fi/osallistu-ja-vaikuta/ymparistovaikutusten-arviointi/huuhansuon-suurusuon-aurinkovoimahanke-lappeenranta> (Haettu: 9.11.2023).
- [6] Energiategollisuus, Tilastot, <https://energia.fi/tilastot> (Haettu: 9.11.2023).
- [7] J. Väisänen, A. Kosonen, J. Ahola, T. Sallinen ja T. Hannula, *Solar Energy* **185**, 350 (2019).
- [8] C. D. Rodríguez-Gallegos, M. Bieri, O. Gandhi, J. P. Singh, T. Reindl ja S. K. Panda, *Solar Energy* **176**, 412 (2018).
- [9] T. H. J. Inderberg, K. Tews ja B. Turner, *Energy Research Social Science* **42**, 258 (2018).
- [10] Yle, Kiinnostus pieniä aurinkovoimakoita kohtaan on rajussa kasvussa Kaakkois-Suomessa, <https://yle.fi/a/74-20039893> (Haettu: 17.1.2024).
- [11] K. Tews, Mapping the Regulatory Features Underpinning Prosumer Activities in Germany: The case of residential photovoltaics, DOI: 10.13140/RG.2.1.1525.1445, 2016.
- [12] S. Jouttijärvi, G. Lobaccaro, A. Kamppinen ja K. Miettunen, *Renewable and Sustainable Energy Reviews* **161**, 112354 (2022).
- [13] S. Guo, T. M. Walsh ja M. Peters, *Energy* **61**, 447 (2013).
- [14] D. Chudinzow, S. Nagel, J. Güsewell ja L. Eltrop, *Applied Energy* **264**, 114782 (2020).
- [15] P. Puranen, A. Kosonen ja J. Ahola, *Applied Energy* **298**, 117199 (2021).
- [16] A. Chaianong, A. Bangviwat, C. Menke, B. Breitschopf ja W. Eichhammer, *Renewable Energy* **146**, 297 (2020).
- [17] L. Pereira, J. Cavaleiro ja L. Barros, *Applied Sciences* 2020, Vol. 10, Page 7366 **10**, 7366 (2020).

- [18] R. Luthander, J. Widén, D. Nilsson ja J. Palm, *Applied Energy* **142**, 80 (2015).
- [19] E. Nyholm, J. Goop, M. Odenberger ja F. Johnsson, *Applied Energy* **183**, 148 (2016).
- [20] L. Mauler, F. Duffner, W. G. Zeier ja J. Leker, *Energy Environmental Science* **14**, 4712 (2021).
- [21] E. Raszmann, K. Baker, Y. Shi ja D. Christensen, 2017 IEEE Power and Energy Conference at Illinois, PECE 2017 (2017).
- [22] H. Pandžić ja V. Bobanac, *IEEE Transactions on Power Systems* **34**, 1416 (2019).
- [23] B. Zou, J. Peng, R. Yin, Z. Luo, J. Song, T. Ma, S. Li ja H. Yang, *Energy and Buildings* **279**, 112712 (2023).
- [24] G. Angenendt, S. Zurmühlen, H. Axelsen ja D. U. Sauer, *Applied Energy* **229**, 884 (2018).
- [25] Y. Zhou, H. Su, Q. Gui, L. Gan, D. Feng, Z. Yan ja Y. Fan, *IET Renewable Power Generation* **14**, 3079 (2020).
- [26] Saft, Evolion® Li-ion battery, Technical Manual, [https://www.saft.com/emailing/evolion/doc/Evolion\\_TM\\_en\\_0115.pdf](https://www.saft.com/emailing/evolion/doc/Evolion_TM_en_0115.pdf) (Haettu: 7.1.2024).
- [27] A. Bocca, A. Sassone, D. Shin, A. Macii, E. Macii ja M. Poncino, *IEEE/IFIP International Conference on VLSI and System-on-Chip, VLSI-SoC 57* (2015).
- [28] A. Ahsan, Q. Zhao, A. M. Khambadkone ja M. H. Chia, *ECCE 2016 - IEEE Energy Conversion Congress and Exposition, Proceedings* (2016).
- [29] L. E. Solution, RESU16H Prime, <https://www.lghomebattery.com.au/resu16hprime> (Haettu: 1.11.2023).
- [30] Tesla, Powerwall, <https://www.tesla.com/powerwall> (Haettu: 1.11.2023).
- [31] Nelinor, Grid battery, <https://nelinor.com> (Haettu: 1.11.2023).
- [32] A. Mutanen, K. Lummi ja P. Järventausta, *Valtakunnallisten tyyppikäyttäjämäärittelyiden päivittäminen ja hyödyntämisen periaatteet verkkopalvelumaihin liittyvissä tarkasteluissa*, 2019.
- [33] *Tekniikan Maailma*, Ikea alkaa myydä aurinkokennoja ja kotiakkuja – Asennetun akun hinta yli 2,5-kertainen Teslaan verrattuna, <https://tekniikanmaailma.fi/ikea-alkaa-myyda-aurinkokennoja-ja-kotiakkuja-asennetun-akun-hinta-yli-25-kertainen-teslan-verrattuna> (Haettu: 28.1.24).

- [34] Solarquotes, Powerwall 2 Full Spec Released: Low cost but ‘unlimited cycles’ warranty has limits, <https://www.solarquotes.com.au/blog/powerwall-2-warranty> (Haettu: 16.11.2023).
- [35] T. ja elinkeinoministeriö, Sähkömarkkinat, <https://tem.fi/sahkomarkkinat> (Haettu: 6.1.2024).
- [36] Nord Pool, <https://www.nordpoolgroup.com/en> (Haettu: 6.1.2024).
- [37] Energiavirasto, Sähkönhinta.fi, <https://www.sahkonhinta.fi> (Haettu: 6.1.2024).
- [38] Helen, Aurinkosähkön myynti, <https://www.helen.fi/aurinkopaneelit/aurinkopaneelipaketit> osto (Haettu 6.1.2024).
- [39] Vattenfall, Sähkön myynti verkkoon - myy meille ylijäämäsähkösi, <https://www.vattenfall.fi/aurinkopaneeli/omatuotanto-sopimus> (Haettu: 6.1.2024).
- [40] V. Foster ja S. Witte, Falling Short: A Global Survey of Electricity Tariff Design, 2020.
- [41] M. Ansarin, Y. Ghiassi-Farrokhfal, W. Ketter ja J. Collins, *Applied Energy* **275**, 115317 (2020).
- [42] T. D. Couture, K. Cory, C. Kreycik ja E. Williams, (2010).
- [43] W. S. McCulloch ja W. Pitts, *The Bulletin of Mathematical Biophysics* **5**, 115 (1943).
- [44] A. Toosi, A. G. Bottino, B. Saboury, E. Siegel ja A. Rahmim, *PET Clinics* **16**, 449 (2021).
- [45] A. Géron, *Hands-On Machine Learning with Scikit-Learn, Keras and TensorFlow*, 3rd ed. (O’Reilly Media, Inc, 2022).
- [46] D. P. Kingma ja J. L. Ba, 3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings (2014).
- [47] H. Tischer ja G. Verbic, 2011 IEEE PES Innovative Smart Grid Technologies, ISGT Asia 2011 Conference: Smarter Grid for Sustainable and Affordable Energy Future (2011).
- [48] R. Khezri, A. Mahmoudi ja M. H. Haque, *IEEE Transactions on Industry Applications* **56**, 5319 (2020).
- [49] X. Xu, Y. Jia, Y. Xu, Z. Xu, S. Chai ja C. S. Lai, *IEEE Transactions on Smart Grid* **11**, 3201 (2020).
- [50] L. Yu, W. Xie, D. Xie, Y. Zou, D. Zhang, Z. Sun, L. Zhang, Y. Zhang ja T. Jiang, *IEEE Internet of Things Journal* **7**, 2751 (2020).

- [51] E. Mocanu, D. C. Mocanu, P. H. Nguyen, A. Liotta, M. E. Webber, M. Gibescu ja J. G. Slootweg, *IEEE Transactions on Smart Grid* **10**, 3698 (2019).
- [52] V. Mnih, K. Kavukcuoglu, D. Silver, A. A. Rusu, J. Veness, M. G. Bellemare, A. Graves, M. Riedmiller, A. K. Fidjeland, G. Ostrovski, S. Petersen, C. Beattie, A. Sadik, I. Antonoglou, H. King, D. Kumaran, D. Wierstra, S. Legg ja D. Hassabis, *Nature* 2015 518:7540 **518**, 529 (2015).
- [53] J. Cao, D. Harrold, Z. Fan, T. Morstyn, D. Healey ja K. Li, *IEEE Transactions on Smart Grid* **11**, 4513 (2020).
- [54] K. Shivam, J. C. Tzou ja S. C. Wu, *Energy Conversion and Management* **237**, 114103 (2021).
- [55] S. Zhou, Z. Hu, W. Gu, M. Jiang ja X.-P. Zhang, *CSEE Journal of Power and Energy Systems* (2019).
- [56] L. Xiong, P. Li, Z. Wang ja J. Wang, *Applied Energy* **259**, 114140 (2020).
- [57] D. Zhang, S. Li, M. Sun ja Z. O'Neill, *IEEE Transactions on Smart Grid* **7**, 1790 (2016).
- [58] W. Kong, Z. Y. Dong, Y. Jia, D. J. Hill, Y. Xu ja Y. Zhang, *IEEE Transactions on Smart Grid* **10**, 841 (2019).
- [59] B. Liu, X. Wei, C. Sun, B. Wang ja W. Huo, *International Journal of Hydrogen Energy* (2023).
- [60] R. J. Williams, *Machine Learning* 1992 8:3 **8**, 229 (1992).
- [61] New Energy Research Center Turku, NERC's Data sharing and Document Library, <https://nerc.turkuamk.fi/data-portal> (Haettu: 24.1.2024).
- [62] L. Karttunen, S. Jouttijärvi, A. Poskela, H. Palonen, H. Huerta, M. Todorović, S. Ranta ja K. Miettunen, *Renewable Energy* **219**, 119473 (2023).
- [63] Energiavirasto, Sähkön hintatilastot, <https://energiavirasto.fi/sahkon-hintatilastot> (Haettu: 9.1.2024).
- [64] Yle, Ennätyskallista sähköä huomenna: jopa yli 2 euroa kilowattitunnilta – Fingrid: Välttääkö sähkön käyttöä, <https://yle.fi/a/74-20067808> (Haettu: 15.1.2023).