

# IoT ja koneoppiminen älykotien energiankulutuksen hallinnassa

TURUN YLIOPISTO  
Tietotekniikan laitos  
TkK-tutkielma  
Tieto- ja viestintäteknikka  
Toukokuu 2024  
Aleksi Rokka

TURUN YLIOPISTO  
Tietotekniikan laitos

ALEKSI ROKKA: IoT ja koneoppiminen älykotien energiankulutuksen hallinnassa

TkK-tutkielma, 22 s.  
Tieto- ja viestintäteknikka  
Toukokuu 2024

---

Esineiden Internet on viime vuosina saanut jalansijaa tavallisten kuluttajien keskuudessa ja kehityskulun on ennustettavissa jatkuvan kohti vielä laajempaa integraatiota. Myös kiinnostus energiankulutusta kohtaan on kohonnut lähiaikoina, niin osana kestävästä kehitystä ja luonnonvarojen säästämistä kuin nousseiden energiahintojen toimesta. Moni onkin jo aloittanut kotiensa älyllistämistä IoT:ta hyödyntäen.

Tutkielma on kirjallisuuskatsaus esineiden internetin hyödyntämisestä älykodeissa energian seurantaan ja hallintaan. Katsauksen pohjana toimii IEEE Xplore-tietokantaan suoritettu haku aiheesta viime vuosina tehdyistä tieteellisistä julkaisuista. Tutkielmassa tarkastellaan myös koneoppimisen hyödyntämistä IoT pohjaisessa kotiautomaatiossa.

Energian seurantaan ehdotettujen mallien vertailussa esille nousee parhaiten toimivina hajautetun seurantatavan mallit. Energiankulutuksen hallinnassa artikkelit keskittyvät lämmitykseen ja ilmanvaihtoon kuluvan energian käytön optimointiin. Energiankulutusta optimoidaan energiankäytön vähentämisellä sekä kulutuksen siirtämisellä päivän edullisemmille tunneille. Koneoppiminen on edustettuna lähes jokaisessa läpi käydyssä artikkelissa joko osana itse mallia tai hyödynnettynä mallin kouluttamiseen.

Asiasanat: IoT, esineiden internet, koneoppiminen, neuroverkot, energianhallinta, energianseuranta, älykoti

# Sisällys

<b>1</b>	<b>Johdanto</b>	<b>1</b>
<b>2</b>	<b>IoT älykodeissa</b>	<b>5</b>
2.1	Esineiden Internet . . . . .	5
2.2	Älykoti ja kotiautomaatio . . . . .	6
2.3	Koneoppiminen . . . . .	7
2.4	Neuroverkot . . . . .	8
<b>3</b>	<b>IoT energiankulutuksen hallinnassa</b>	<b>11</b>
3.1	Energiankulutuksen seuranta . . . . .	11
3.1.1	NILM . . . . .	12
3.1.2	ILM . . . . .	14
3.1.3	Vertailu . . . . .	15
3.2	Energiankulutuksen hallinta . . . . .	16
3.2.1	Energiakustannuksen optimointi . . . . .	17
3.2.2	Energiatehokkuuden optimointi . . . . .	18
3.3	Yhteenveto . . . . .	19
<b>4</b>	<b>Pohdinta</b>	<b>21</b>
	<b>Lähdeluettelo</b>	<b>23</b>

# Kuvat

1.1	Hakuprosessi . . . . .	3
1.2	Lähteiden temaattinen jakautuminen . . . . .	4
2.1	Esineiden internetin kerrokset . . . . .	5
2.2	Neuroverkon rakenne . . . . .	9

# Taulukot

3.1	Kulutusseurannan algoritmien F1-arvot . . . . .	15
-----	---	----

# Termistö

**ABC** Artificial bee colony

**CNN** Convolutional neural network, Konvoluutioneuroverkko

**DDPG** Deep deterministic policy gradient

**FHMM** Factorial hidden Markov model

**FNN** Feedforward neural network, Eteenpäin kytketty neuroverkko

**LSTM** Long short-term memory

**SVM** Support vector machine, Tukivektorikone

**IoT** Internet of Things, Esineiden internet

**ILM** Intrusive load monitoring, hajautettu seuranta

**NILM** Nonintrusive load monitoring, keskitetty seuranta

**ADL** Activities of Daily Living, Päivittäiset toiminnot

**HEMS** Home energy monitoring system, Kodin energian kulutuksen seuranta

# 1 Johdanto

Tutkielman kirjoitushetkellä uutisia seuraamalla voidaan todeta sähkönkulutuksen olleen ajankohtainen aihe erityisesti muutamana viime vuotena. Uutisissa on mainittu energiapulan olevan mahdollinen talvena 2022–2023 ja energiansäännöstelyä tarvittavan [1]. Energian hinnan nousu on ollut myös otsikoissa, kuten 5.1.2024, jolloin sähkönkeskihinta oli 110 senttiä kilowattitunnilta [2]. Energian säästämällä on rahallisen ja yhteiskunnallisen hyödyn lisäksi myös positiivinen vaikutus ympäristölle muun muassa pienentyneiden päästöjen muodossa.

Pelkän määrällisen sähkönkulutuksen supistamisen lisäksi yhteiskunnallisesti merkittävää on energiankäytön ajankohta, sillä useiden kotitalouksien käyttäessä hetkellisesti paljon energiaa, syntyy sähköverkkoon virtapiikkejä. Nämä kulutuspiikit aiheuttavat sähköverkolle turhaa rasitusta, kun energiantuotantoa joudutaan sääntämään. Kuluttajalle nämä kulutuksen piikit näkyvät taas sähkölaskussa, eteenkin jos käytössä on pörssisähkö. Pörssisähkössä on tuntikohtainen hinnoittelu, jossa yksi hinnanvaihteluun vaikuttava tekijä on kulutus. Kun sähköverkossa on korkea tarve sähkölle, on tuntihinta korkeampi kuin tunteina, jolloin kulutus on matalaan. Mikäli energian tarpeen pystyy ajoittamaan pääsääntöisesti hetkiin, jolloin sähköverkon kulutus on muutoin alhaista, on sähkölaskua mahdollista pienentää.

Kotitalouksissa voidaan energiaa säästää manuaalisesti miettimällä esimerkiksi, milloin laittaa kodinkoneita päälle, miten usein käyttää sähkökiuasta ja kuinka lämpimänä sähkölämmitteisen asunnon pitää. Mikäli sähkönkulutusta halutaan

kotitaloudessa todella optimoida, kannattaa sitä hallinnoida vuorokauden ympäri. Tällöin on järkevää hyödyntää automaatiota eri laitteiden ohjauksessa käsin tehtävän säädön sijaan. Esimerkiksi talon lämmitys voidaan automatisoida tehtäväksi ajankohtana, jolloin muu energiankulutus on alhaista, millä saadaan minimoitua sähköverkonkuormitusta virtapiikkien pienentyessä.

Esineiden internet lyhennetään usein IoT:ksi, joka tulee englannin kielen sanoista Internet of Things. Se on ollut jo hetken nouseva teknologia, jolle on löytynyt käyttökohteita useilta aloilta kuten terveydenhoito, logistiikka ja energiantuotanto. Kodin energiankulutuksen automaatioon esineiden internet tuo uusia mahdollisuuksia, niin kulutuksen mittaamiseen kuin hallintaan. Tutkielman tarkoituksena on perehtyä, kuinka esineiden internetiä voidaan hyödyntää älykodeissa energian käytön näkökulmasta ja mitä etuja se tuo. Tavoitteena on myös selvittää koneälyn käyttämisen tuomia hyötyjä älykotien IoT pohjaiseen automaatioon.

Työn tutkimuskysymykset ovat:


1. IoT:n käyttö älykodeissa energian seurantaan
2. IoT:n käyttö energiankulutuksen hallintaan kodeissa
3. Koneälyn käyttö IoT pohjaisessa kotiautomaatiossa.

Tutkielma tehdään kirjallisuuskatsauksena pohjautuen tieteellisiin lähteisiin. Tiedonhaku suoritetaan käyttämällä pääasiallisesti IEEE Xplore-tietokantaa, jota voidaan pitää luotettavana sekä kattavana lähteenä informaatioteknologian alalla. Tutkimusosion tiedonhaku IEEE Xplore-tietokantaan rajataan englanninkielisiin julkaisuihin ja joita ei ole julkaistu konferensseissa. Tämän rajauksen tavoitteena on taata mahdollisimman laadukkaiden lähteiden käyttö.

Haku rajataan myös ajallisesti vuodesta 2020 vuoteen 2022 hakutuloksen suuren määrän takia. Hakulausekkeena toimii (*"IoT" OR "Internet of things"*) (*"home automation" OR "smart home"*) *NOT security*, jossa otetaan huomioon käytössä

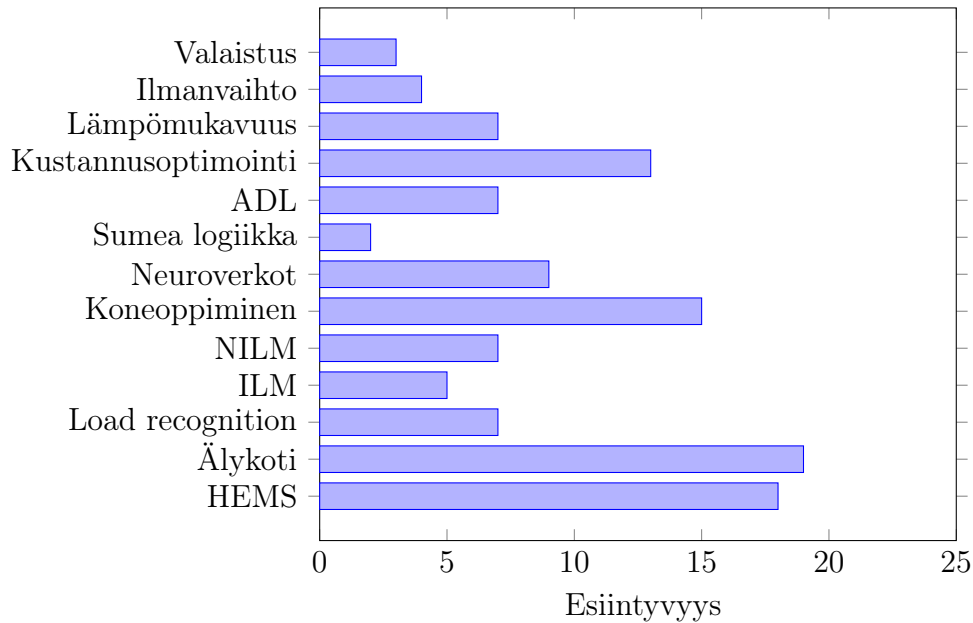


olevat lyhenteet sekä sisällytetään tutkimuksen kannalta tärkeät hakusanat. Turvalisuus on iso osa IoT:tä ja sitä tutkittu paljon, minkä takia se on erityisesti rajattu pois helpottamaan hakutulosten läpi käyntiä. Edellä esitellyllä hakulausekkeella tehtiin 28.9.2022 haku IEEE Xplore-tietokantaan. Haku tuotti 204 hakutulosta, joille suoritetaan kuvan 1.1 mukainen karsinta.



Kuva 1.1: Hakuprosessi

Otsikon ja abstraktin luennan perusteella voidaan hakutulosta rajata tarkemmin 42 artikkeliin, jotka käsittelevät energian seuranta ja energian hallintaa. Kun näiden artikkelien teemat taulukoidaan, saadaan artikkelien lukumäärä rajattua 28:n, joissa mainitaan älykoti tai kodin energianhallinta järjestelmä. Analyysivaiheessa vielä 3 artikkelia karsiutuu pois, kahden artikkelin ollessa portugalin kielelle ja yksi aiheen koskiessa enemmän yksityisyyttä kuin energianhallintaa. Karsinnan läpäisseet artikkelit luettiin kokonaan ja niissä esiintyvät teemat kerättiin kuvaan 1.2.



Kuva 1.2: Lähteiden temaattinen jakautuminen

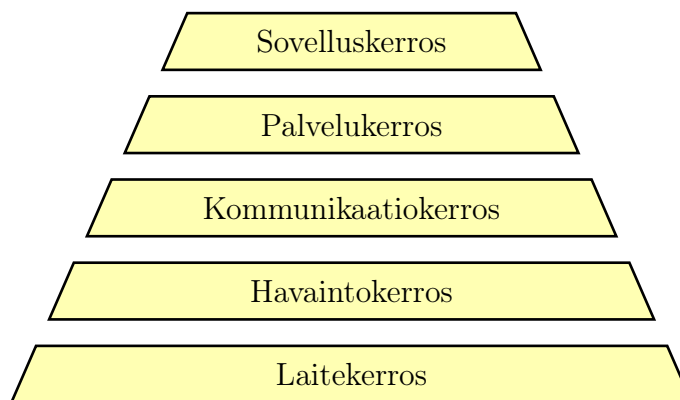
Taulukon perusteella voidaan huomata hakusanoihin vahvasti liittyvien termien älykoti ja kodin energianhallinta järjestelmä lisäksi monessa artikkelissa esiintyvän teemana myös koneoppiminen sekä kustannusoptimointi.

Toisessa luvussa käydään läpi esineiden internet käsitteenä ja sen rakennetta. Luvussa tarkastellaan myös älykodin ja kotiautomaation määritelmien keskinäisiä eroja sekä niiden toimintatapoja. Luvussa kolme käydään läpi ratkaisuja älykodin energian seurantaan ja hallintaan. Koneälyn hyödyntämisen eri vaihtoja tuodaan esille ja lopuksi havainnot kootaan yhteen ja näiden pohjalta esitetään vastaukset tutkimuskysymyksiin. Luvussa 4 tuodaan esille omaa pohdintaa työn aikana tehdyistä havainnoista.

## 2 IoT älykodeissa

### 2.1 Esineiden Internet

Esineiden internet on laaja käsite, joka määrittelee tämän verkoksi esineitä, jotka pystyvät kommunikoimaan ja jakamaan tietoa keskenään [3]. Koska edellä kuvattu määritelmä on erittäin laaja, usein termiä rajataan vastaamaan paremmin kyseisen kontekstin tarpeita [4]. Tässä tutkielmassa käsitteeseen IoT liittyvä esine rajataan tarkoittamaan Internettiin tai rakennuksen sisäiseen yhtenäiseen verkkoon kytkettyjä laitteita, joiden avulla voidaan asuinrakennuksen energiankulutusta seurata tai ohjata. Tällöin mukaan lukeutuu muun muassa älysähkömittari, älypistorasiat, etäohjattava valaistus ja verkon yli ohjattava ilmastointi. Esineiden Internet itsessään käsittää kokonaisuuden esineen anturoinnista loppukäyttäjän sovelluksiin sekä datan keräyksen, varastoinnin ja käsittelyn. Rakenteeltaan esineiden internet voidaan jakaa seuraavan kuvan 2.1 mukaisesti viiteen kerrokseen.



Kuva 2.1: Esineiden internetin kerrokset

Alimmainen kerroksista on laitekerros, johon kuuluu antureita sisältävä fyysinen laite. Seuraava kerros on havaintokerros, jossa anturien arvot kerätään dataksi. Tässä kerroksessa määrittyy myös, kuinka usein anturien tiedot luetaan. Kolmas kerros on kommunikaatiokerros, joka mahdollistaa tiedonvälityksen ja integraation laitteiden välillä. Laitteiden välinen yhteys voidaan luoda langattomasti, kuten WiFi ja Zigbee tai langallisesti esimerkiksi Ethernetin avulla. Neljäs kerros on palvelukerros, joka toimii rajapintana IoT laitteiden ja loppukäyttäjän sovellusten välillä. Tähän kerrokseen kuuluu kerätyn datan hallinta ja varastointi. Usein tämä kerros toteutetaan pilvipalveluina suuren kuormittavuuden takia. Ylimpänä kerroksena on sovel- luskerros, jossa datasta jatkojalostetaan informaatiota. Tällä kerroksella on käyttä- jäkohtaiset palvelut, joihin voi kotiautomaation piirissä kuulua kulutuksen seuranta, käyttäjän toiminnan seuraaminen ja laitehallinta datan perusteella. [5]

## 2.2 Älykoti ja kotiautomaatio

Kodintekniikkaan liittyvien sähköisten laitteiden määrä on viimeisten vuosikymme- nien aikana kasvanut moninkertaisesti. Nykyään on mahdollista ohjata valaistusta, ilmanvaihtoa ja lämmitystä muutenkin kuin pelkällä virtapiirin katkaisevalla kytki- mellä. Näille laitteille on tullut monipuolisia rajapintoja ohjaukseen, joita hyödyntä- mällä saadaan ohjattavista laitteista muodostettua kokonaisuus. Tämä yhtenäinen kokonaisuus määritellään kotiautomaatiojärjestelmäksi. [6]

Kodeissa yhä useamman laitteen ohjaus tapahtuu kodin langattoman verkon ylitse tai ne ovat yhteydessä verkkoon keskittimen välityksellä. Kun näihin laitteisiin voidaan ottaa yhteys mobiilisovelluksilla ja laitteita voidaan ohjata puheella, voidaan puhua älykodista. [7] Älykodissa laitteet reagoivat käyttäjän antamiin käskyihin [8], kun taas kotiautomaatiojärjestelmä toimii ennalta määriteltujen asetusten mukaan. Esimerkiksi ilmastoinnin ohjaus viikkokellon mukaan on kotiautomaatiota, kun taas valojen ohjaus puheella on älykodin toiminto.

## 2.3 Koneoppiminen

Vaikka koneoppiminen on viime vuosina noussut yleiseen tietoisuuteen uutena alana, on termi syntynyt jo vuonna 1959. [9] Koneoppiminen tarkoittaa koneellista ongelman ratkaisua ilman juuri kyseiseen tapaukseen ihmisen kehittämää algoritmia. Täten koneoppiminen on laaja käsite, joka kattaa sisälleen lukuisia ratkaisuja ja alaluokkia, kuten neuroverkot ja syväoppiminen.

Koneoppimisen menetelmät voidaan lajitella löysästi kolmeen luokkaan ongelman ja saatavilla olevan datan perusteella. Ohjatussa oppimisessa algoritmin opetus tapahtuu olemassa olevan tiedon perusteella, opetusdatalla. Opetusdatassa syötteen lisäksi tulos tiedetään mahdollistaen algoritmin tuloksen vertaamiseen oikeaan vastaukseen, minkä perusteella algoritmin säätöarvoja koneellisesti muutetaan virheen minimoimiseksi. Vahvistusoppimisessa tietoa kerätään toiminnan aikana palautteenä, jonka perusteella kone pyrkii muuttamaan toimintaa positiiviseen suuntaan. Kolmantena luokkana on ohjaamaton oppiminen, jossa tietoa datan rakenteesta ei ole etukäteen, vaan kategorisointi pyritään toteuttamaan syötteen perusteella. Tämän luokan etuna ohjattuun oppimiseen on opetussyötteen luokittelun eliminointi sekä siinä syntyvien luokitteluvirheiden vaikutus tarkkuuteen.

Vahvistusoppiminen asettuu ohjaamattoman ja ohjatun oppimisen väliin, ja on hyödynnettävissä käyttökohteissa, missä palautteen anto saadaan automatisoitua. Koska oppiminen tapahtuu palautteen perusteella, on oppiminen hidasta ja vaatii runsaasti palautetta. Vahvistusoppimista on hyödynnetty muun muassa peleissä, kuten Google DeepMindin AlphaGo-ohjelmassa. [10] Yksi suosituista vahvistusoppimismenetelmistä on Q-oppiminen, joka ympäristöä mallintamatta pyrkii oppimaan optimaalisen ratkaisun eri tiloissa edellisten tilojen palautteiden perusteella. Kokeilemalla eri toimia kaikissa tiloissa oppii algoritmi, mitkä näistä ovat yleisesti parhaita kokonaisuuden näkökulmasta. [11]

Useat vahvistusoppimismenetelmät toimivat ilman ympäristön mallintamista,

mutta myös mallintamiseen on kehitetty algoritmeja, kuten Q-oppimiseen pohjautuva SARSA, joka pyrkii oppimaan Markov-prosessin mallin (MDP)[12]. Markovin päätösprosessi antaa seuraavien tilojen todennäköisyydet perustuen nykytilassa vallittavaan toimintaan. Markovin päätösprosessi on laajennus Markovin ketjuille lisäten mahdollisuuden tehdä päätöksiä sekä näiden motivoinnin palkinnoilla. [13]


Ohjatun oppimisen yksi osa-alue on Structured prediction, jossa pyritään ennustamaan rakenteita luokkien tai arvojen sijaan. Tähän osa-alueeseen kuuluu energian kulutuksen seuranta käsittelevässä luvussa 3.1.1 mainittava HMM eli Markovin piilomalli. Mallin tavoitteena on oppia taustalla oleva tuntematon Markovin ketjun tila tarkkailemalla näkyvää prosessia, johon ketjun tila vaikuttaa [14]. Malli toimii siis hyvin systeemeille, joita ei voida täysin tarkkailla.

Ohjatun oppimisen toinen osa-alue on datan luokittelu. Tähän osa-alueeseen kuuluu muun muassa kNN-luokittelija ja tukivektorikone. kNN-luokittelija hakee jokaiselle luokitettavalle näytteelle lähimmät opetusnäytteet ja valitsee näissä useimmiten esiintyvän luokan näytteen luokaksi. [15] Tukivektorikone eli SVM on lineaarinen luokittelumalli. Tukivektorikone pyrkii löytämään opetusdatan kahden näytejoukon välille tason, jonka etäisyys on maksimaalinen näytejoukoista. Tämän tason perusteella voidaan luokitella tulevat näytteet joukkoihin. [16] Lineaarisen luokittelun lisäksi voidaan tukivektorikonetta käyttää epälineaariseen luokitteluun hyödyntämällä kernel-menetelmää eli kuvaamalla alkuperäinen tila moniulotteisempaan tilaan mahdollistaen jälleen lineaarisen luokittelun. Kernel funktioiden käyttö ulotteisuuden kasvattamisessa mahdollistaa helpon laskennan tilojen välillä. [17]

## 2.4 Neuroverkot

Keinotekoiset neuroverkot lyhennetään usein neuroverkoiksi ja ne ovat koneoppimisen haara, jonka mallit mukailevat rakenteeltaan aivojen biologisia neuroverkkoja. Neuroverkko koostuu tyypillisesti kuvan 2.2 mukaisesti neuroneista ja niitä yhdis-

tävistä viivoista, jotka vastaavat aivojen synapseja. Neuronit vastaanottavat signaaleja siihen kytketyistä neuroneista lähettämällä signaalin seuraaville neuroneille sisääntulojen summafunktion perusteella. Neuroneilla ja synapseilla on useimmiten signaalin voimakkuuteen vaikuttava painotus, jota säädetään oppimisen aikana.



Kuva 2.2: Neuroverkon rakenne

Neuronit tyypillisesti järjestetään kerroksiin, joista ensimmäinen on sisääntulokerros ja viimeinen ulostulokerros. Näiden kerrosten välissä on piilokerros. Neuroverkoista puhuttaessa syväoppimisella tarkoitetaan syvien neuroverkkojen hyödyntämistä, jotka eroavat perinteisistä neuroverkoista useamman piilotetun kerroksen käytöstä. Syvät neuroverkot mahdollistavat suurempien verkkojen rakentamisen, minkä takia niiden käyttö on hyvin yleistä verrattuna perinteiseen yhden piilokerroksen verkkoon.

Neuroverkot voidaan jakaa kahteen osaan verkossa siirtyvän tiedon kulkusuunnan perusteella. Mikäli tietoa siirretään vain yhteen suuntaan, sisääntulosta ulostuloon, on verkko eteenpäin syöttävä verkko, joka usein esiintyy kirjallisuudessa lyhenteenä FNN. Neuronin ulostulon vaikuttaessa tämän sisääntuloon kutsutaan neuroverkkoa takaisinkytketyksi neuroverkoksi, jonka lyhenne on RNN.

Katoavan gradientin ongelma on molemmissa neuroverkkotyypeissä havaittu haaste käytettäessä gradientti pohjaista opetustapaa, jossa neuroverkkojen painotuksia muutetaan suhteessa virhefunktion osittaiseen derivaattaan. Ongelmaksi tu-

---

lee iteraatiokertojen kasvaessa gradientin magnitudin lasku johtaen oppimisen hidastumiseen. FNN-verkkoihin kuuluvat konvoluutioneuroverkot eli CNN-verkot eivät kärsi tästä ongelmasta käyttämällä vakioituja painotuksia harvempien neuronien välisten liitosten kanssa. Takaisinkytketyissä verkoissa taas yksi ratkaisu on LSTM-verkon eli pitkäkestoisen lyhytkestomuistiverkon käyttö, joka nimensä mukaisesti pyrkii säilyttämään lyhytkestoisen muistin useiden tuhansien aika-askelien päähän. Tavoitteena LSTM-rakenteella on lisätä neuroverkolle kyky oppia milloin muistaa ja unohtaa olennaista tietoa. Koska LSTM-verkot voivat päästää lävitseen gradientin myös muuttumattomana, ratkaisee se osaltaan katoavan gradientin ongelman.



# 3 IoT energiankulutuksen hallinnassa

## 3.1 Energiankulutuksen seuranta

Jotta energiankulutusta voitaisiin hallita, on lähes välttämätöntä pystyä seuramaan sitä. Energiankulutuksen hallintaa automatisoidessa kulutuksen seurannasta saatavan datan merkitys nousee, jolloin raportti kuukausittaisesta kulutuksesta edes päiväkohtaisesti ei riitä vaan on tarve toteuttaa seuranta reaaliaikaisesti. Tiheään seurattua energiankulutuksesta voidaan muun muassa pyrkiä ymmärtämään käyttäjän päivittäisiä liikkeitä ja sen mukaan optimoimaan energian käyttöä. Esimerkiksi ilmanvaihdon kiertonopeutta voidaan optimoida käyttäjän läsnäolon mukaan, jolloin vältetään ilmassojen tarpeetonta kierrättämistä ja energian käyttöä.

Energiankulutuksen seuranta voidaan jakaa kahteen tyyppiin sähkökuorman mittauksen perusteella. Jos kuormaa mitataan vain yhdestä paikkaa, kutsutaan seurantatapaa keskitetyksi seurannaksi, josta käytetään usein lyhennettä NILM englanninkielisestä termistä non-intrusive load monitoring. Kun kuormaa seurataan useasta paikasta, usein laitekohtaisesti, kutsutaan menetelmää hajautetuksi seurannaksi, jolle on lyhenne ILM englanninkielisestä termistä intrusive load monitoring. [18]

### 3.1.1 NILM

Keskitetystä seurannassa mittauspisteenä voidaan käyttää etäluettavaa sähkömittari, jota kutsutaan myös älysähkömittariksi. Seurannan tavoitteena on pystyä erottelemaan sähkömittarilta tulevan datan perusteella mitä laiteita on päällä, joka mahdollistaa käyttäjän päivittäisen toiminnan seurannan energiankulutuksen optimoimiseksi. [19]

Keskitetyn seurannan vaiheet voidaan jakaa datan keräykseen, käsittelyyn sekä luokitteluun. Ensimmäiseksi data kerätään fyysisestä mittalaitteesta, jonka jälkeen käsittelyvaiheessa raakadatasta jalostetaan tarvittava data, kuten hetkellinen kulutus, virta ja jännite. Viimeisessä vaiheessa, luokittelussa kerätyn datan perusteella pyritään luokittelemaan ja tunnistamaan käytössä olevat laitteet. [18]

Laitteiden tunnistukseen käytetään pääsääntöisesti koneoppimista tai optimointitekniikoita. Koneoppimisessa voidaan käyttää joko ohjattua tai ohjaamatonta oppimista. [19] Tarkimpaan kuormantunnistukseen päästään ohjatulla koneoppimisella, mutta sen käyttö vaatii myös eniten laskentatehoa. Koneoppiminen tarvitsee myös laajan koulutusdatan oppiakseen, kun taas optimointialgoritmin parametrien säätöön riittää suppeampi koulutusdata.

Koneoppiseen voidaan hyödyntää tässä käyttökohteessa factorial hidden Markov model (FHMM)-mallia. Mallin opettamiseen voidaan käyttää valvottua opetusta. [20] Koska mallin opettamiseen vaadittavaa koulutusdataa voi olla haastavaa saada riittävä määrä, on Loughboroughin yliopistossa kehitetty CREST. CREST on koulutusdatan luomiseen kehitetty energian tarpeen mallintamisohjelma. [20] Artikkelissa [20] FHMM-mallin toimintaan ehdotetaan parannusta käyttämällä tietoa laitteen tilasta aktivoimaan laitteeseen liittyviä HMM-mallin ketjuja vain laitteen ollessa päällä. Mallia kutsutaan artikkelissa valikoivaksi FHMM-malliksi ja tällä mallilla tavoitellaan parannusta tarkkuuteen ja laskentanopeuteen verrattuna normaaliin FHMM-malliin. Ehdotettu mallia voidaan pitää hybridinä keskitetystä ja hajaute-

tusta tunnistuksesta, sillä yhden kuormanmittauspisteen lisäksi tarvitaan jokaiselta laitteelta erikseen päälläolotieto, joka eroaa keskityn tunnistuksen mallista.

Mallien toimintaa tutkittiin käyttämällä CREST-mallin luomaa tietoa-aineis-  
toa seitsemälle tarkkailtavalle laitteelle. Annetusta kuvaajasta saadaan normaalille  
FHMM-mallille eri laitteiden F1-arvojen keskiarvoksi 0.35 ja valikoivalle 0.82. Nor-  
maali FHMM-malli ei tunnistanut yhtä laitetta ollenkaan ja parhaimmalle laitteelle  
oli F1-arvo 0.58, kun taas valikoivan mallin paras tulos oli 0.99 ja heikoin 0.55.

Eri koneoppimismalleja voidaan vertailla F-arvon (F-score) avulla, joka kertoo  
algoritmin tarkkuudesta ja herkkyydestä. Mallin tarkkuus kertoo todellisten positiiv-  
visesti luokiteltujen datapisteiden osuuden kaikista positiiviseksi luokitelluista. Mal-  
lin herkkyys taas tarkoittaa oikein positiiviseksi luokiteltujen datapisteiden osuutta  
kaikista oikeasti positiivisista tapauksista. F1-arvo on tarkkuuden ja herkkyyden  
harmoninen keskiarvo ja saa arvon väliltä 0-1.

Keskitettyyn kuormantunnistukseen voidaan käyttää myös muokattua optimoin-  
tialgoritmia ABC (artificial bee colony), Tässä käyttökohteessa algoritmia käytetään  
yksittäisten laitteiden virran ja vaihe-eron arviointiin käyttäen lähtödatana anturil-  
ta saatavaa kokonaisvirran magnitudia ja vaihe-eroa. Algoritmille syötetään läh-  
töarvoiksi myös kaikkien mitattavien laitteiden päälläolotila tehden tästä mallista  
hybridin. ABC-algoritmi pyrkii laitteiden ennalta määritettyjen kulutusprofiileiden  
perusteella estimoimaan laitekombinaatiot, joiden kulutuskäyttäytyminen sopii par-  
haiten havainnoituun kulutukseen. Laitteiden päälläolotiedolla algoritmi voi sulkea  
mahdollisia kombinaatioketjua, mikä vähentää virheellisiä oletuksia ja nopeuttaa  
algoritmin toimintaa.

Mallin toimintaa tutkittiin 11 laitteen PLAID tietoa-aineistolla, josta F1-arvojen  
keskiarvoksi saatiin 0.9747, kun taas vertailussa olleen mallin keskiarvoksi saatiin  
0.7871. [19] Vertailtava malli on artikkelissa [21] esitetty aikasarjaan pohjautuva  
malli laitteiden luokitteluun. Artikkelissa voidaan huomata eroavaisuus taulun kolme

F1-arvojen keskiarvon ja kuvaa jassa 14 olevaan 11-laitteen F1-arvoon, joka vaikuttaa olevan 0.877 0.9747 sijaan, kun taas vertailussa olevan mallin 11-laitteen tulokseksi luetaan 0.786 0.7871 sijaan.

### 3.1.2 ILM

Keskitetyssä kuormanseurannassa kuormien erottelu toteutetaan suurelta osin ohjelmiston avulla, kun taas hajautetussa kuormanseurannassa erottelu toteutetaan laitteistotasolla. Aiemmissä tutkimuksissa on huomattu hajautetulla kuormanseurannalla päästävän tarkempaan kuorman tunnistukseen verrattuna keskitettyyn seurantaan, kun taas laitteiston yksinkertaisuus ja edullisuus ovat keskitetyn seurannan etuja hajautettuun verrattaessa. [5]

Hajautetun kuormanseurannan toteutus voidaan laitteistoltaan jakaa kahteen osaan, älykodinkoneisiin ja hajautettuun anturointiin. Älykodinkoneissa virrankulutuksen mittausta on sisäänrakennettu laitteen sisälle ja mittausdata jaetaan myös kodinkoneen ulkopuolelle. Hajautetussa anturoinnissa virrankulutuksen mittausta toteutetaan seurattavan kodinkoneen ulkopuolella. [18] Erillisanturointi voidaan sijoittaa esimerkiksi pistorasian ja laitteen väliin tai suoraan sähköpääkeskukseen mitatessa rakennukseen integroitua talotekniikkaa, kuten ilmanvaihtoa.

Laitteen tunnistusta tutkittiin artikkelissa [5] UK-DALE -tietoaaineistolla, jossa on viisi laitetta. Tutkinnan kohteena olivat kolme mallia FNN, LSTM ja SVM, joiden F1-arvot olivat 0.95385, 0.93846 ja 0.83077. Edellä mainitussa artikkelissa laitteilta saatava kulutustieto kerätään laitteilta tietokantaan, josta se luetaan erilliselle kuormantunnistus-sovellukselle, kun taas artikkeli [22] pyrkii siirtämään kuormantunnistuksen suoraan energiaa mittaavalle IoT-laitteelle. Artikkelissa IoT käyttöön ehdotettu algoritmi CompactNet on karsittu versio kirjoittajien aikaisemmin kehitämästä algoritmista EnsembleNet. EnsembleNet koostuu useasta erikseen koulutetusta konvoluutioneuroverkosta (CNN). CompactNet:ssä käytetään huomattavaa

määrä vähemmän CNN - filttäreitä kuin EnsembleNet:ssä, mikä samalla tavalla koulutettaessa johtaa heikoimpaan tunnistukseen. Artikkelissa ratkaisuksi ehdotetaan tiedon kiteytystä (KD) suuremmasta EnsembleNet:stä perustuen artikkeliin [23]. EnsembleNet:in F1-arvoksi saatiin 0.9075 ja CompactNet:in arvoksi 0.8756 ja algoritmien laskenta-ajat ESP32 mikrokontrollerilla olivat 3.89 ja 0.99 sekuntia. CompactNet:in kokoisen CNN mallin, CNN-16 tulos ilman optimointia ehdotettua koulutuksen optimointia oli F1-arvo 0.8558 ja huomattavasti isomman mallin, CNN-128, F1-arvo 0.8708.

### 3.1.3 Vertailu

Edellisissä aliluvuissa 3.1.1 ja 3.1.2 käytiin läpi eri tapoja ja malleja tunnistaa päällä olevia laitteita ja niiden energian kulutusta, jonka perusteella voidaan arvioida käyttäjän toimintaa. Toimintatavan perusteella jakautuvat mallit kolmeen kategoriiaan hajautettuun, keskitettyyn sekä hybridimalliin, jossa keskitettyyn malliin tuodaan lähtötiedoksi myös yksittäisten laitteiden päälläolotila. Eri algoritmeja voidaan vertailla F-arvon (F-score) avulla, joka kertoo algoritmin tarkkuudesta. Edellisissä luvuissa esitellyt kulutusseurantaan käytetyt algoritmit on kerätty taulukkoon 3.1 vertailua varten.

Taulukko 3.1: Kulutusseurannan algoritmien F1-arvot

Algoritmi	Tyyppi	F1-arvo
FNN	ILM	0,95385
LSTM	ILM	0,93846
SVM	ILM	0,83077
EnsembleNet	ILM	0,9075
CompactNet	ILM	0,8756
valikoiva FHMM	HNILM	0,82
alkuperäinen FHMM	NILM	0,35
ABC(taulukko)	HNILM	0,9747
ABC(kuvaaja)	HNILM	0,877
TimeSeries	NILM	0,7871

Tarkasteltaessa keskitettyjä malleja huomataan F1-arvojen tasapainottamattomien keskiarvojen olevan välillä 0.58–0.79, kun taas hybridimallien keskiarvon olevan välillä 0.82–0.97 tai 0.82–0.88 riippuen käytetäänkö artikkelin taulukon vai kuvaajan ilmoittamaa tulosta, joista taulukon tulos on huomattavasti positiivisempi.

Hajautettujen mallien F1-arvot ovat välillä 0.83–0.95. F1-arvojen perusteella tarkasteluvälillä ehdotetuista malleista hajautetut mallit ovat tarkimman tuloksen tuottava ryhmä, kun taas keskitetyt mallit ovat epätarkimpia laitteiden tunnistuksessa. Hybridimallit ovat tarkkuudeltaan ryhmänä hajautettujen ja keskitettyjen mallien välissä, mutta tulkinnasta riippuen mukautettu ABC-algoritmi saattaa olla tarkastelluista malleista tarkin.

Kahden viime vuoden tarkasteluvälillä on julkaisuiden ehdotettujen mittausalgoritmien perusteella havaittavissa keskitetyn kulutusmittauksen osalta trendi kohti hybridimallia, missä IoT:ta hyödynnytetään laitteiden tilatietoa. F1-arvojen perusteella voidaan ajatella lähtödatan määrän olevan yksi selittävä tekijä mallin tarkkuudelle. Suurimmassa osassa ehdotetuista malleista mitatusta kulutusdatasta ja lostetaan tieto kuluttavasta laitteesta keskitetysti riippumatta käytetäänkö datankeruuseen NILM- tai ILM-tekniikkaa. Poikkeus tästä trendistä on artikkelissa [22] ehdotettu CompactNet, jossa kulutuksen luokittelu tehtäisiin jo mittaavassa IoT-laitteessa. Tämä ratkaisu hyödyntää IoT-laitteiden kasvavaa laskentatehoa ja vähentää kuormitusta ulkoiselta hallintayksiköltä.

## 3.2 Energiankulutuksen hallinta

Kotitalouksien energiankulutuksesta suurin osa menee asuintilojen lämmittämiseen. Esimerkiksi Tilastokeskus arvioi vuonna 2021 lämmitykseen kuluneen 67 prosenttia kokonaisenergian kulutuksesta. [24] Näin ollen tämän osa-alueen optimoinnista on saatavissa merkittävä hyöty kokonaisuutta ajatellen, joka näkyy myös energiankulutuksen hallintaa käsittelevien tutkimusartikkelien fokuksessa.

### 3.2.1 Energiakustannuksen optimointi

Yksi optimoinnin kohteista on energiankustannusten minimointi. Edellä olevan artikkelin perusteella on lämmitys suurin kulutukseen vaikuttava tekijä. Lämmitykseen liittyy vahvasti myös ilmastointi ja ilmanvaihto ja näistä käytetään englannin kielestä tullutta lyhennettä HVAC. Optimoidessa HVAC-järjestelmän toimintaa tulee kuitenkin ottaa huomioon järjestelmän ensisijainen tarkoitus eli asukkaan lämpöviihtyvyys. Tämä asettaa rajat asuintilan minimi ja maksimilämpötilalle. Optimoinnin lähtökohtana on muuttavan sähköhinnan sekä mahdollisten akustojen ja uusiutuvan energian pientuotannon hyödyntäminen siirtämällä sähköverkon kuormitusta edullisimmille tunneille. Seuraavat ratkaisut on toteutettu ilman termodynamiikkamallia, joka mahdollistaisi matemaattisen lähestymisen lämmitystarpeen arviointiin. Todenmukaisen termodynamiikkamallin luominen on haastava sekä se on uniikki jokaiselle rakennukselle tuoden haasteita skaalautuvuuteen.

Artikkelissa [25] ehdotetaan DDPG-algoritmin käyttöä HVAC-järjestelmän energiakustannuksen optimointiin ottaen huomioon myös energian varastointi järjestelmän käyttö. Järjestelmä laaditaan Markovin päätösprosessina, johon kuvautuu ympäristö tila, toiminta ja palkintofunktio. Markovin päätösprosessin ratkaisuun hyödynnetään DDPG-algoritmia, josta saadaan halutut toimenpiteet annetulle ajankohdalle pohjautuen annettuun tilaan.

Algoritmin simulointiin käytetään artikkelissa Pecan Street -tietokantaa energiankulutuksesta Muellerin asuinalueella Austinissa, Texasissa, jossa koulukseen käytetään dataa kesä- ja heinäkuulta 2018 ja testaukseen elokuuta 2018. Simulaatiossa HVAC-järjestelmää käytettiin vain jäähdyttämiseen. Vertailukohtana käytettiin yksinkertaista mallia, joka kytkee HVAC:n pois alalämpötilarajan alittuessa ja päälle ylälämpötila ylittyessä. Vertailumalliin verrattuna energiakulu pieneni 15.2 prosenttia käytettäessä 3 kilowatin energiavarastoa ja 7.7 prosenttia ilman energiavarastointia.

Artikkelissa [26] ehdotetaan klusteroinnin hyödyntämistä käyttäen pohjana artikkelissa [25] käytettyä DDPG-algoritmia. Toisin kuin viitatussa artikkelissa huomioidaan tässä artikkelissa myös lämmitystilanteet. Artikkelissa klusterointi on toteutettu K-means -algoritmilla, jossa opetusdatan jako klustereihin tehdään päivän lämpötilaan ja energian hintaan perusteella. Tällä saadaan yksilöityä opetus eri tilanteisiin datan ollessa samalta lämpötila- ja energiakustannusalueelta. Tunnistamalla päivän tyyppi voidaan algoritmiin ladata tämän päivätyypin koulutuksessa kertynyt tieto. Artikkelissa todetaan, ettei äärimmäistä tarkkuutta päivätyypin tunnistuksessa tarvita ja tunnistukseen hyödynnetään LSTM-algoritmia.

Algoritmin toimintaa testattiin kuukauden aikana käyttäen opetusdatana kahta edellistä kuukautta. Syyskuussa klusterointi vähensi energian kulutusta 24.7 prosenttia lämpötila epämukavuuden ollessa 7.6 prosenttia pienempi. Marraskuussa klusterointi vähensi energian kulutusta 2.4 prosenttia lämpötila epämukavuuden ollessa 1914 prosenttia pienempi. Erojen arvioidaan aiheutuvan testikuukauden ja opetuskuukausien eroavaisuuksista. Syyskuu kuuluu pääosin korkean hinnan päiviin opetuskuukausien ollessa lähes kokonaan matalan hintaisia. Marraskuu toimii samalla tavalla lämpötilan suhteen. Opetusdatan klusteroinnilla saadaan opetusdata paremmin vastaamaan testattavaa dataa saavuttaen energia tehokkaamman energian hallintajärjestelmä.

### 3.2.2 Energiatehokkuuden optimointi

Artikkelissa [27] ehdotetaan energiantehokkuuden kasvattamista optimoimalla neuroverkon kanssa asunnon lämpötilaa. Lämpötilan laskemiseen otetaan huomioon asukkaan poissaolot ja nukkumisajat. Ehdotettua algoritmia on testattu Etelä-Koreassa 48 päivän kestäneellä koejaksolla 100 asunnossa käyttäen vertailukohteena 2281 asuntoa. Kokeeseen osallistuneista 91 prosenttia oli tyytyväisiä järjestelmän toimintaan. Järjestelmällä saatiin 14 prosentin säästö energiankulutukseen.



Artikkelissa [28] esitellään energiankulutuksen vähentämistä hyödyntäen Bat-algoritmia ja syvää äärimmäistä oppimiskonetta (DELM). Ehdotetussa mallissa säätötilan ympäristömuuttujina ovat lämpötila, valaistus sekä hiilidioksidipitoisuus, jotka suodatetaan Alpha Beta -suodattimella ennen DELM:lle syöttämistä. DELM ennustaa käyttäjän asettamia parametreja ja ympäristömuuttujia optimoidaan Bat-algoritmin kanssa, joiden kanssa sumean logiikan ohjaimet säätävät energiankulutusta ohjattavissa laitteissa.

Mallin toimintaa arvioitiin julkaisun [29] datalla, jota hyödynsivät myös vertailussa olevat muut mallit. Vertailumalleina toimivat artikkelin [30] geneettinen algoritmi (GA) ja hiukkasparvi optimointi (PSO). Ehdotetun mallin havaittiin laskevan energiankulutuksen huippuja merkittävästi kokonaiskulutuksen laskiessa myös. Ilman syvää oppimiskonetta on Bat-algoritmi 2.7 prosenttia energiatehokkaampi GA:n verrattuna ja 9.1 prosenttia PSO:n. Käytettäessä DELM:iä kasvaa ero energiatehokkuudessa 42.2 ja 46.1 prosenttiin.

### 3.3 Yhteenveto

IoT:n käyttö älykodeissa energian seurantaan jakautuu kahteen seurantatapaan, keskitettyyn ja hajautettuun. Keskitetyssä seurannassa kuluttavan laitteiden tunnistus toteutetaan lähes kokonaan IoT:n sovelluskerroksessa, kun taas hajautetussa hyödynnetään enemmän myös havainto- ja laitekerrosta. Esiteltyjen mallien perusteella hajautetuilla malleilla saavutetaan tarkempia tuloksia, joista tarkimmalla on saavutettu F1-arvo 0.95.

IoT:n käyttö energiankulutuksen hallintaan kodeissa painottuu tutkimusartikkeleissa ilmastointi ja ilmanvaihtojärjestelmien optimointiin, johon sisältyy myös lämmitys. Kodin kokonaisenergian kulutuksesta näihin järjestelmiin kuluu suurin osa energiasta. Suurimmassa osassa artikkeleja järjestelmää optimoitiin kuluttamaan energiaa ajankohtina, jolloin se on edullisinta vähentämään sähköverkon kuormi-

tusta ja energian käytöstä syntyviä kuluja. Ehdotetuilla malleilla energian käytöstä syntyviä kuluja voidaan laskea useampia kymmeniä prosentteja asumismukavuuden lämpötilan suhteen pysyessä hyväksyttävällä tasolla.

Koneälyä hyödynnetään IoT pohjaisessa kotiautomaatiossa lähes jokaisessa läpi käydyssä artikkelissa. Koneälyn käyttö sijoittuu IoT:n sovelluskerrokseen, jossa sitä hyödynnetään osana mallia tai mallin koulutukseen. Läpikäydyissä artikkeleissa koneäly sijaitsee erillisellä tietokoneella tai palvelimella lukuun ottamatta yhtä artikkelia, [23], jossa ajo tapahtuu suoraan mittavaan laitteen mikrokontrollerilla.

## 4 Pohdinta

Vertailu eri mallien välillä olisi helpompaa ja validimpaa, jos käytössä oli sama tietoaaineisto jokaiselle mallille. Eri tietoaaineistoja käyttäviä malleja vertaillessa on nimittäin syytä olla hieman kriittinen ja epäillä onko tietoaaineisto valittu julkaisuun, koska se tukee paremmin ehdotettua mallia verrokkimalliin verrattuna kuin muut tietoaaineistot.

Artikkeleja lukiessa on myös syytä tarkastella kaikkia taulukoita ja kuvaajia, vaikka osaa niistä mainitaan tekstissä ohimennen hyvin lyhyesti. Tästä esimerkkinä on ABC-optimointialgoritmia käsittelevä julkaisu [19], jossa isoa taulukkoa katso-malla näyttää 11 laiteen F1-arvojen olevan 0.9747 keskiarvoltaan, kun taas pienes-tä kuvaajasta F1-arvojen keskiarvo on 0.877. Tekstissä ei suoraan käydä läpi mo-lempien mittausten mittausmenetelmää, mutta kuvaajan kuvatekstin perusteella on ymmärrettävissä eron johtuvan yhden ja samanaikaisen kuormantunnistuksen tark-kuudesta. Taulukossa siis käydään läpi eri laitteiden tunnistustarkkuudet vain tämän laitteen ollessa kytketty ja kuvaaja kertoo tunnistustarkkuuden useamman laitteen ollessa kytkettyinä. Näin ollen kuvaaja vastaa paremmin todellista algoritmin käyt-töympäristöä, mutta näistä tuloksista ei harmillisesti ole mitään mainintaa tekstissä toisin kuin yksittäisten kuormien tunnistuksesta, joka tuotti parempia tuloksia.

Keskitetyn kulutuksenseurannan supistettu ja keskitetty anturointi on etu hin-nan ja huolettavuuden kannalta, mutta näkyy heikkoutena suorituskyvyssä verrat-tuna hajautettuun seurantaan mittausdata vähyyden rajoittaessa tulosten tarkkuut-

ta. Useamman laitteen yhdistetty magnitudi- ja vaihe-eroprofiili voi olla sama kuin kolmannen laitteen yksittäinen aiheuttaen virheellisiä tulkintoja NILM-seurannassa.

Keskitettyä kulutuksenseurantaa käsittelevissä artikkeleissa onkin havaittavissa trendinä siirtyminen hybridimalliin, jossa sisään tulevaa dataa kasvatetaan laitekohtaisilla päällä olo tiedoilla. Hybridimalli tuo kuitenkin keskitetyn mallin lähelle hajautetun seurannan monimutkaisuutta kaventaen etuja tähän nähden, suorituskyvyn jäädessä vielä vajaaksi hajautetun seurannan kärjestä. Hajautetussa seurannassa trendinä vaikuttaa olevan neuroverkkojen hyödyntäminen, jolla on saatu parannusta tunnistustarkkuuteen muihin koneällyn algoritmeihin verrattuna.

Artikkeleissa algoritmin suoritus tapahtuu keskitetyllä palvelimella lukuun ottamatta artikkelissa [22] esille tuotua CompactNet:iä, jossa suoritus tapahtuisi suoraan mittaavassa IoT-laitteessa. Tämä ratkaisu vähentää dataliikennettä ja kuormitusta hallintayksikölle ja hyödyntää IoT-laitteiden kasvaa laskentatehoa, siksi ajatellen tämäntyypisiä ratkaisuja tutkittavan tulevaisuudessa enemmänkin. On myös todennäköistä, että energiankulutusta seuraavan järjestelmän käyttämää energiaa saadaan pienennettyä siirtämällä sitä mahdollisimman lähelle jokaista seurattavaa kohdetta sen sijaan, että seurantaa suoritetaan päättelemällä yksittäisten laitteiden kulutus kootusta kulutuksesta raskaammilla algoritmeilla.

# Lähdeluettelo

- [1] A. Juusola. ”Sinunkin sähkösi saattavat katketa ensi talvena energiapulan takia – näin varaudut kiertäviin sähkökatkoihin”. (2022), url: <https://yle.fi/a/3-12566386> (viitattu 18. 04. 2024).
- [2] A. Heikinmatti, H. Forss ja A. Raimoaho. ”Tämän päivän sähkölasku voi nousta yli 200 euroon – katso koneesta, mitä sähköllä lämmittäminen nyt maksaa”. (2024), url: <https://yle.fi/a/74-20067932> (viitattu 18. 04. 2024).
- [3] ITU. ”Overview of the Internet of Things. ITU-T SERIES Y: Global information infrastructure Internet protocol aspects and next-generation networks, Recommendation Y.2060”. (2012), url: <https://www.itu.int/rec/T-REC-Y.2060-201206-I> (viitattu 18. 04. 2024).
- [4] A. Abusukhon, ”Toward Achieving a Balance Between the User Satisfaction and the Power Conservation in the Internet of Things”, *IEEE Internet of Things Journal*, vol. 8, nro 14, s. 10 998–11 015, heinäkuu 2021, ISSN: 2372-2541. DOI: 10.1109/jiot.2021.3051764.
- [5] P. Franco, J. M. Martinez, Y.-C. Kim ja M. A. Ahmed, ”IoT Based Approach for Load Monitoring and Activity Recognition in Smart Homes”, *IEEE Access*, vol. 9, s. 45 325–45 339, 2021, ISSN: 2169-3536. DOI: 10.1109/access.2021.3067029.
- [6] A. Vallati, S. Grignaffini, M. Romagna ja L. Mauri, ”Effects of different building automation systems on the energy consumption for three thermal insu-

- lation values of the building envelope”, teoksessa *2016 IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC)*, IEEE, kesäkuu 2016, s. 1–5. DOI: 10.1109/eeeic.2016.7555731.
- [7] J. Rosslin, R. Robles ja T.-H. Kim, ”A Review on Security in Smart Home Development”, *International Journal of Advanced Science and Technology*, vol. 15, maaliskuu 2010.
- [8] F. K. Aldrich, ”Smart Homes: Past, Present and Future”, teoksessa *Inside the Smart Home*, R. Harper, toim. London: Springer London, 2003, s. 17–39, ISBN: 978-1-85233-854-1. DOI: 10.1007/1-85233-854-7\_2.
- [9] A. L. Samuel, ”Some Studies in Machine Learning Using the Game of Checkers”, *IBM Journal of Research and Development*, vol. 3, nro 3, s. 210–229, heinäkuu 1959, ISSN: 0018-8646. DOI: 10.1147/rd.33.0210.
- [10] Google Inc. ”AlphaGo”. (2020), url: <https://deepmind.google/technologies/alphago/> (viitattu 12.02.2024).
- [11] C. J. C. H. Watkins ja P. Dayan, ”Q-learning”, *Machine Learning*, vol. 8, nro 3–4, s. 279–292, toukokuu 1992, ISSN: 1573-0565. DOI: 10.1007/bf00992698.
- [12] G. Rummery ja M. Niranjan, *On-Line Q-Learning Using Connectionist Systems*. Cambridge University, England: Cambridge University Engineering Department, marraskuu 1994.
- [13] R. Bellman, ”A Markovian Decision Process”, *Indiana Univ. Math. J.*, vol. 6, s. 679–684, 4 1957, ISSN: 0022-2518.
- [14] L. Rabiner ja B. Juang, ”An introduction to hidden Markov models”, *IEEE ASSP Magazine*, vol. 3, nro 1, s. 4–16, 1986, ISSN: 0740-7467. DOI: 10.1109/massp.1986.1165342.

- 
- [15] T. Cover ja P. Hart, "Nearest neighbor pattern classification", *IEEE Transactions on Information Theory*, vol. 13, nro 1, s. 21–27, tammikuu 1967, ISSN: 1557-9654. DOI: 10.1109/tit.1967.1053964.
- [16] C. Cortes ja V. Vapnik, "Support-vector networks", *Machine Learning*, vol. 20, nro 3, s. 273–297, syyskuu 1995, ISSN: 1573-0565. DOI: 10.1007/bf00994018.
- [17] B. E. Boser, I. M. Guyon ja V. N. Vapnik, "A training algorithm for optimal margin classifiers", teoksessa *Proceedings of the Fifth Annual Workshop on Computational Learning Theory*, sarja COLT '92, Association for Computing Machinery, 1992, s. 144–152, ISBN: 089791497X. DOI: 10.1145/130385.130401.
- [18] P. Franco, J. M. Martinez, Y.-C. Kim ja M. A. Ahmed, "A Framework for IoT Based Appliance Recognition in Smart Homes", *IEEE Access*, vol. 9, s. 133940–133960, 2021, ISSN: 2169-3536. DOI: 10.1109/access.2021.3116148.
- [19] S. Ghosh, D. Manna, A. Chatterjee ja D. Chatterjee, "Remote Appliance Load Monitoring and Identification in a Modern Residential System With Smart Meter Data", *IEEE Sensors Journal*, vol. 21, nro 4, s. 5082–5090, helmikuu 2021, ISSN: 2379-9153. DOI: 10.1109/jsen.2020.3035057.
- [20] G. A. Raiker, S. Reddy B., U. Loganathan et al., "Energy Disaggregation Using Energy Demand Model and IoT-Based Control", *IEEE Transactions on Industry Applications*, vol. 57, nro 2, s. 1746–1754, maaliskuu 2021, ISSN: 1939-9367. DOI: 10.1109/tia.2020.3047016.
- [21] H. Liu, H. Wu ja C. Yu, "A hybrid model for appliance classification based on time series features", *Energy and Buildings*, vol. 196, s. 112–123, elokuu 2019, ISSN: 0378-7788. DOI: 10.1016/j.enbuild.2019.05.028.

- [22] M. H. Phan, Q. Nguyen, S. L. Phung, W. E. Zhang, T. D. Vo ja Q. Z. Sheng, ”CompactNet: A Light-Weight Deep Learning Framework for Smart Intrusive Load Monitoring”, *IEEE Sensors Journal*, vol. 21, nro 22, s. 25 181–25 189, marraskuu 2021, ISSN: 2379-9153. DOI: 10.1109/jsen.2021.3088011.
- [23] G. Hinton, O. Vinyals ja J. Dean, *Distilling the Knowledge in a Neural Network*, 2015. DOI: 10.48550/arXiv.1503.02531. arXiv: 1503.02531 [stat.ML].
- [24] Tilastokeskus. ”Asumisen energiankulutus”. (2021), url: <https://stat.fi/julkaisu/ckfwmfrsg03h3015636dbwcpq> (viitattu 18.04.2024).
- [25] L. Yu, W. Xie, D. Xie et al., ”Deep Reinforcement Learning for Smart Home Energy Management”, *IEEE Internet of Things Journal*, vol. 7, nro 4, s. 2751–2762, huhtikuu 2020, ISSN: 2372-2541. DOI: 10.1109/jiot.2019.2957289.
- [26] I. Zengin, J. Vardakas, N. E. Koltsaklis ja C. Verikoukis, ”Smart Home’s Energy Management Through a Clustering-Based Reinforcement Learning Approach”, *IEEE Internet of Things Journal*, vol. 9, nro 17, s. 16 363–16 371, syyskuu 2022, ISSN: 2372-2541. DOI: 10.1109/jiot.2022.3152586.
- [27] K. Kwon, S. Lee ja S. Kim, ”AI-Based Home Energy Management System Considering Energy Efficiency and Resident Satisfaction”, *IEEE Internet of Things Journal*, vol. 9, nro 2, s. 1608–1621, tammikuu 2022, ISSN: 2372-2541. DOI: 10.1109/jiot.2021.3104830.
- [28] A. S. Shah, H. Nasir, M. Fayaz, A. Lajis, I. Ullah ja A. Shah, ”Dynamic User Preference Parameters Selection and Energy Consumption Optimization for Smart Homes Using Deep Extreme Learning Machine and Bat Algorithm”, *IEEE Access*, vol. 8, s. 204 744–204 762, 2020, ISSN: 2169-3536. DOI: 10.1109/access.2020.3037081.



- 
- [29] L. M. Candanedo, V. Feldheim ja D. Deramaix, ”Data driven prediction models of energy use of appliances in a low-energy house”, *Energy and Buildings*, vol. 140, s. 81–97, huhtikuu 2017, ISSN: 0378-7788. DOI: 10.1016/j.enbuild.2017.01.083.
- [30] S. Ali ja D.-H. Kim, ”Optimized Power Control Methodology Using Genetic Algorithm”, *Wireless Personal Communications*, vol. 83, nro 1, s. 493–505, helmikuu 2015, ISSN: 1572-834X. DOI: 10.1007/s11277-015-2405-3.