

Erik Mattsson

**DATA-ANALYTIKKA ENERGIANKULUTUKSEN  
OPTIMOINNISSA ÄLYKKÄISSÄ YMPÄRISTÖISSÄ**



JYVÄSKYLÄN YLIOPISTO  
INFORMAATIOTEKNOLOGIAN TIEDEKUNTA  
2023

# TIIVISTELMÄ

Mattsson, Erik

Data-analytiikka energiankulutuksen optimoinnissa älykkäissä ympäristöissä

Jyväskylä: Jyväskylän yliopisto, 2023, 34 s.

Tietojärjestelmätiede, kandidaatin tutkielma

Ohjaaja: Taipalus, Toni

Maa-ilmantilanteen muuttumisen seurauksena mediassa on ollut puhetta energiakriisistä sekä ympäristökriisin ehkäisemisestä. Data-analytiikalla voidaan löytää ratkaisuja näihin ongelmiin energiankulutuksen optimoinnin kautta. Tässä tutkielmassa tarkastellaan data-analytiikan hyödyntämistä energiankulutuksen optimoinnissa älykkäissä ympäristöissä. Tutkielman tavoitteena on kertoa, miten data-analytiikkaa hyödynnetään energiankulutuksen optimoinnissa älykkäissä ympäristöissä. Aihetta analysoidaan kolmesta eri näkökulmasta, jotka ovat energiankulutuksen, energiakustannusten sekä ympäristökuorman vähentäminen. Tutkielman aihe on erityisen ajankohtainen ja tärkeä, sillä teko hetkellä energiamarkkinoilla vallitsee epävarmuus ja kasvihuonepäästöjä on vähennettävä. Tutkimuksessa selviää, että data-analytiikkaa hyödynnetään monin tavoin energiankulutuksen optimoinnissa. Esimerkiksi energiankulutusta voidaan vähentää huomattavasti dataan pohjautuvalla laitteiden ohjauksella, energiakustannuksia puolestaan siirtämällä kulutus pois kalliin energian tunneilta ja ympäristökuormaa taas optimoimalla datan pohjalta uusiutuvien luonnonvarojen maksimaalista hyödyntämistä. Lisäksi dataan perustuvilla ratkaisuilla saadaan nostettua käyttäjien mukavuustasoa monissa erilaisissa ympäristöissä. Tämä tutkielma tarjoaa hyvän yleiskäsityksen data-analytiikasta energiankulutuksen optimoinnissa niin aiheesta kiinnostuneelle, kuin myös yrityksille, jotka ovat kiinnostuneita energiakustannusten vähentämisestä omassa työympäristössään.

Asiasanat: Data-analytiikka, IoT, Energiankulutuksen optimointi, Älykkäät ympäristöt

## ABSTRACT

Mattsson, Erik

Data analytics in optimizing energy consumption in smart environments.

Jyväskylä: University of Jyväskylä, 2023, 34 pp.

Information Systems Science, Bachelor's Thesis

Supervisor: Taipalus, Toni

As a result of the change in the world situation, the media have had headlines on the energy crisis and preventing the environmental crisis. Data analytics can be used to find solutions to these issues through optimization of energy consumption. This thesis examines data analytics in the optimization of energy consumption in smart environments. The aim of the thesis was to explain how data analytics is used to optimize energy consumption in smart environments. The subject was analyzed from three different perspectives: the reduction of energy consumption, energy cost, and environmental load. The subject of the thesis was relevant to study, as there is uncertainty in the energy market and greenhouse gas emissions needs to be reduced. The study finds that data analytics is used in many ways to optimize energy consumption. For example, energy consumption could be significantly reduced by data-based equipment control, energy costs by shifting consumption away from expensive energy hours, and environmental loads by optimizing the maximum use of renewable resources based on data. In addition, data-based solutions were used to raise user comfort levels in many different environments. This thesis provides a good overview of data analytics for optimizing energy consumption for those interested in the subject, as well as for companies interested in reducing energy costs in their own working environment.

Keywords: Data analytics, IoT, Energy consumption optimization, Smart environments

## KUVIOT

KUVIO 1 Data-analyysiprojektin vaiheet .....	8
KUVIO 2 Keskitetyn energianhallintajärjestelmän arkkitehtuuri .....	11
KUVIO 3 Kirjallisuuden hakuprosessi .....	14

## TAULUKOT

TAULUKKO 1 Hakulauseet ja tietokannat .....	13
TAULUKKO 2 Kelvollisuuskriteerit .....	14
TAULUKKO 3 Artikkelien määrä eri aihepiireissä .....	15

# SISÄLLYS

TIIVISTELMÄ

ABSTRACT

KUVIOT

TAULUKOT

1	JOHDANTO.....	6
2	TAUSTA .....	8
	2.1 Data-analytiikka.....	8
	2.2 Energiankulutuksen optimointi .....	9
	2.3 Älykkäät ympäristöt.....	10
3	TUTKIMUSMENETELMÄ .....	12
	3.1 Systemaattinen kirjallisuuskatsaus tutkimusmenetelmänä .....	12
	3.2 Tutkimuskysymys .....	12
	3.3 Systemaattinen valintaprosessi tutkielmassa .....	13
	3.3.1 Kirjallisuuden hakeminen.....	13
	3.3.2 Aineiston seulonta ja laadun arviointi .....	13
4	DATA-ANALYTIikka ENERGIANKULUTUKSEN OPTIMOINNISSA	15
	4.1 Data-analytiikka energiankulutuksen vähentämisen näkökulmasta	16
	4.2 Data-analytiikka energiakustannusten vähentämisen näkökulmasta	20
	4.3 Data-analytiikka ympäristökuorman vähentämisen näkökulmasta	23
5	POHDINTA .....	25
6	YHTEENVETO .....	28

LÄHTEET

# 1 JOHDANTO

Data-analytiikan käyttäminen yleistyy jatkuvasti uusien datan keräämismenetelmien sekä avoinna olevan datan myötä. Erilaisten mukavuutta tuottavien laitteiden, kuten ilmastoinnin tai valaistuksen, eteen valmistajat ovat tehneet paljon kehittämistä saadakseen laitteet toimimaan energiatehokkaasti. Älykkäät ympäristöt ovat jo arkipäivää ja niiden toimivuuden edellytyksenä on datan kerääminen ja sen analysointi. Energiaa kuluu jatkuvasti enemmän, kun kaikenlaisten elektronisten laitteiden käyttö ja käyttäjäkunta kasvavat. Myös Ukrainan kriisin myötä on tullut ilmi, että monet maat ovat erittäin riippuvaisia energiantuonnista Venäjältä, mikä on aiheuttanut ongelmia niin energian tarjonnassa kuin hinnassakin (Nasr ym., 2022). Data-analytiikalla voidaan ennustaa laitteiden energiankulutusta, energian hintaa sekä vaihtoehtoisten energialähteiden optimaalisempaa käyttöä (Benavente-Peces, 2019). Siksi data-analytiikka on vahvasti mukana energiatehokkaan tulevaisuuden rakentamisessa niin ympäristön kuin taloudenkin näkökulmasta.

Tutkielman tarkoitus on tuoda lukijalle yleiskuva siitä, miten data-analytiikalla sekä pienillä investoinneilla voidaan vähentää huomattavasti energiankulutusta, energiakustannuksia sekä ympäristövahinkoja. Tutkimus on erittäin merkityksellinen ja ajankohtainen siksi, että viime aikoina energian riittävyys ei ole enää ollut itsestäänselvyys. Tämä ei ole pelkästään vaikuttanut valtioiden tasolla, vaan energian tarjonnan ja kysynnän epätasapainosta johtuva energianhinnan nousu on aiheuttanut myös kansalaisille vaikeuksia (Council of the European Union, 2022). Lisäksi nyt ja tulevaisuudessa on yhä tärkeämpää ottaa käyttöön kaikki keinot ympäristökuorman vähentämiseksi. Tämä tutkielma vastaa tutkimuskysymykseen ”Miten data-analytiikkaa hyödynnetään energiankulutuksen optimoinnissa älykkäissä ympäristöissä?”.

Data-analytiikka lyhyesti tarkoittaa suurien datajoukkojen hyödyntämistä analyttisin menetelmin, josta saatuja tunnuslukuja käytetään päätösten tukena (Runkler, s.2, 2016). Energiankulutuksen optimointi voidaan ymmärtää kontekstin mukaan monella eri tavalla, mutta tässä tutkielmassa sillä tarkoitetaan keinoja, joilla voidaan säästää niin energiankulutuksen, energiakustannusten tai ympäristön puolesta. Älykkäät ympäristöt ovat puolestaan ympäristöjä, jotka

hyödyntävät sensoreilla kerättyä dataa saavuttaakseen saumattomamman kommunikaation ihmisen ja ympäristön välillä (Hajjaji, Boulila, Farah, Romdhani & Hussain, 2021). Älykkäisiin ympäristöihin liittyvät tunnetummat käsitteet, kuten älykkäät rakennukset tai älykkäät kodit.

Tutkielma on toteutettu systemaattisena kirjallisuuskatsauksena Okolin ja Schabramin (2010) ohjeiden pohjalta. Tietoa haettiin kolmesta eri tietokannasta, jotka olivat IEEE Xplore, ACM Digital Library ja ProQuest Computing Database. Tieteellisistä julkaisuista, joista artikkelit ovat valittu, suurin osa on Julkaisuforumin mukaan tasolla 1 ja osa tasolla 3, joista taso 1 tarkoittaa perustasoa ja taso 3 korkeinta tasoa.

Tutkimuksessa selviää, että data-analytiikkaa hyödynnetään monin tavoin energiankulutuksen optimoinnissa. Energiankulutusta voidaan vähentää huomattavasti dataan pohjautuvalla laitteiden ohjauksella, energiakustannuksia siirtämällä kulutus pois kalliin energian tunneilta ja ympäristökuormaa optimoimalla datan pohjalta uusiutuvien luonnonvarojen, kuten aurinkoenergian maksimaalista hyödyntämistä. Lisäksi dataan perustuvilla ratkaisulla saadaan nostettua käyttäjien mukavuustasoa monissa erilaisissa ympäristöissä.

Tutkielma on rakenteeltaan seuraavanlainen: johdannon jälkeen toisessa luvussa taustoitetaan tutkielman kannalta tärkeimmät termit. Kolmannessa luvussa käydään läpi, miten systemaattinen kirjallisuuskatsaus on toteutettu tässä tutkielmassa. Neljännessä luvussa vastataan tutkimuskysymykseen kolmesta eri näkökulmasta: energiankulutuksen, energiakustannusten sekä ympäristökuorman vähentämisen näkökulmasta. Viidennessä luvussa pohditaan tutkielman havaintoja ja löydöksiä sekä miten niitä voitaisiin jalostaa jatkossa. Kuu-dennessa eli viimeisessä luvussa kootaan tutkielman ydinasiat yhteen tiiviiksi tietopaketti.

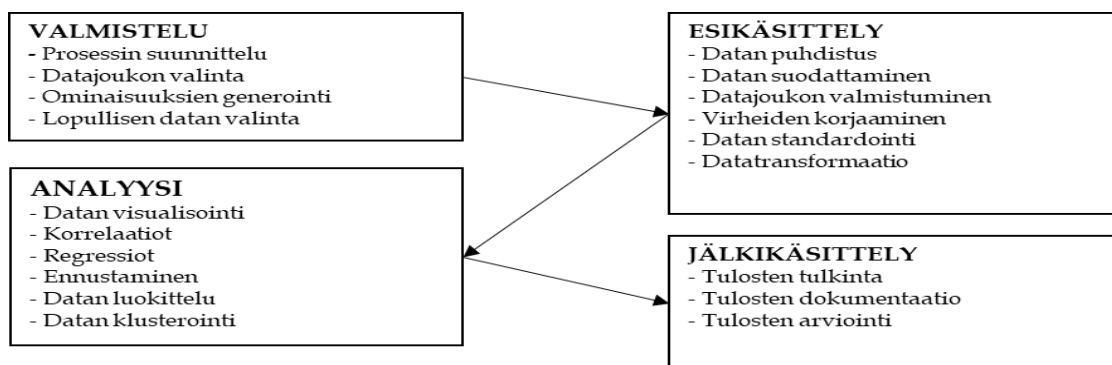
## 2 TAUSTA

Data-analytiikka on hyvin laaja-alainen käsite ja siihen liittyy monia eri tieteenaloja sekä alakäsitteitä. Myös energiankulutuksen optimointi voidaan ymmärtää monella eri tavalla riippuen kontekstista. Älykkäät ympäristöt tarvitsevat dataa ja elektronisia laitteita toimiakseen halutulla tavalla. Tämän luvun tarkoitus on taustoittaa lukijalle tärkeimmät termit tutkielman osalta.

### 2.1 Data-analytiikka

Data-analytiikka voidaan määritellä tietojärjestelmien soveltamisena datan analysoinnissa. Datasta voidaan analyysin avulla poimia konkreettista tietoa, jota taas voidaan käyttää päätöksenteon tukena. Data-analytiikka on luonteeltaan hyvin monimuotoista, koska se on ottanut vaikutteita monilta eri tieteenaloilta, kuten tilastotieteestä, koneoppimisesta, kuvion tunnistamisesta, systeemiteoriasta, operatiivisesta tutkimuksesta tai tekoälystä. (Runkler, 2016, s.2)

Runkler (2016, s. 2-3) jaottelee tyypillisen data-analyysiprojektin useampaan vaiheeseen, joita ovat datan valmistelu, esikäsitteleminen, analyysi ja jälkikäsitteleminen, kuten kuviosta 1 selviää.



KUVIO 1 Data-analyysiprojektin vaiheet



Data-analytiikkaa voidaan hyödyntää monilla eri aloilla, joista massadataa on saatavilla. Data-analytiikan hyödyntämisestä tuttuja aloja ovat muun muassa terveydenhuolto, tuotantoteollisuus ja maatalous (Duan & Da Xu, 2021). Tässä tutkielmassa keskitytään pääosin energia-alaan. Osa artikkeleista käsittelee energia-alan lisäksi myös rakennusteknistä näkökulmaa.

Modernit data-analytiikan tekniikat tarjoavat keinon ymmärtää paremmin rakennusten kokonaisenergiankulutusta, joka koostuu esimerkiksi energian hinnan ajanjaksoista, energiaa kuluttavista laitteistoista, ympäristöön kohdistuvasta kuormasta, laitteiston käytöstä ja niin edelleen (Benavente-Peces, 2019). Vargas-Solarin, Khalilin, Espinosa-Oviedon ja Zechinelli-Martinin (2022) mukaan data-analyysitekniikoiden kehitys mahdollistaa energiankulutuksen ja energiaverkon tehokkuuden parantamisen, sillä dataa voidaan hyödyntää monipuolisemmin. Benavente-Pecesin (2019) mukaan data-analytiikan keinoilla, kuten koneoppimisella, voidaan suuresta datajoukosta tuottaa ymmärrettävää tietoa, poimia piilossa olevia riippuvuuksia asioiden välillä ja tunnistaa näin myös uusia trendejä. Hänen mukaansa voidaan todeta, että dataan perustuvalla laitteiden ohjaamisella voidaankin vuositasolla saada huomattavat säästöt energiankulutuksessa sekä -kustannuksissa. Myös Chagantin ym. (2022) mukaan dataan perustuvat lähestymistavat ovat sopivimpia ratkaisuja energiankulutuksen optimointiin.

## 2.2 Energiankulutuksen optimointi

Perinteistä energiankulutuksen optimointia ohjaa käyttäjän valppaus, joka on esimerkiksi ylimääräisten valojen sammuttamista tai turhaa jääkaapin availun välttämistä. Energiankulutusta on hyvin vaikea optimoida perinteisillä keinoilla, sillä siitä voi syntyä myös haittavaikutuksia, jos tähtää vain maksimaalisiin säästöihin. Haittavaikutuksia voivat olla esimerkiksi asukkaiden epämukavuus, laitteiden rikkoutuminen ja rakennuksen liiallinen kosteus, jonka myötä rakennus voi homehtua. (Saba ym., 2022). Käyttäjän psykologinen profiili ohjaa käyttäjää toimimaan omalla totutulla tavallaan, mikä voi aiheuttaa ylimääräistä energiankulutusta tai -kustannuksia. Myös tuttujen tapojen muuttaminen voi olla käyttäjälle työlästä ja epämukavaa. Lisäksi energiankulutukseen vaikuttaa paljon käyttäjän ikä. Esimerkiksi lapsella ei ole välttämättä ensimmäisenä mielessä kuinka paljon tietty aktiviteetti kuluttaa energiaa. (Khamesi, Silvestri, Baker & Paola, 2020). Saba ym. (2022) ovat tutkimuksessaan listanneet asioita, jotka laskevat energiankulutusta. Näistä tärkeimmät on lueteltu alla.

- Optimoitu ilmastoinnin asetus
- Lämminvesikattilan ajastaminen
- Valojen sammuttaminen huoneesta poistuessa tai luonnonvalon aikaan

- Käyttämättömien elektronisten laitteiden kytkeminen irti pistorasiasta
- Uusiutuvien energianlähteiden käyttöönotto tai luonnonvarojen hyödyntäminen
- Jääkaapin ja pakastimen optimaalinen käyttö
- Uunin luukun turhan avaamisen välttämisen sen ollessa päällä ja jälkilämmön hyödyntäminen
- Ruoan laittaminen jääkaappiin jäähtyneenä
- Ajantasainen valaistus (LED-polttimot)
- Rakennuksen oikeaoppinen eristys

Listauksesta voidaan huomata useita asioita, jotka vaikuttavat energiankulutukseen enemmän tai vähemmän. Pienet teot voivat tuntua mitättömiltä yksilön mielestä, mutta on hyvä muistaa, että rakennukset kuluttavat suurimman osan sähkön kokonaiskulutuksesta. Avci, Erkoc, Rahmani ja Asfour (2013) arvioivat tutkimuksessaan, että rakennukset kuluttavat Yhdysvaltojen sähkönkulutuksesta jopa 73 % ja aiheuttavat myös 40 % kasvihuonekaasuista. Näiden tietojen valossa jokaisen ihmisen teoilla voi olla suuri vaikutus.

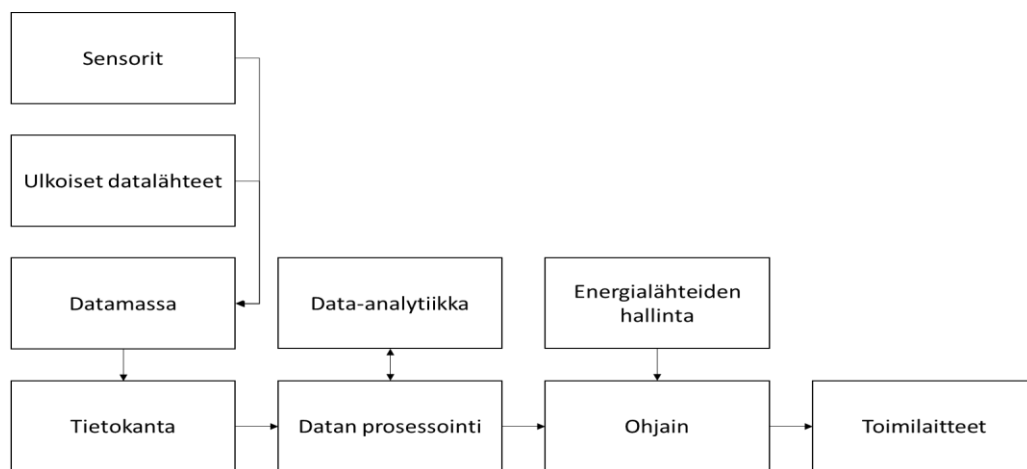
Energiankulutusta voidaan usein optimoida kolmesta eri näkökulmasta: energiankulutuksen, energiakustannusten ja ympäristökuorman vähentäminen. Energiankulutuksen vähentämisen näkökulmasta optimointia on muun muassa edellisessä kappaleessa listatut asiat. Näistä suurimpia energian kuluttajia ovat LVI-laitteet eli lämmitys-vesijohto-ilmanvaihto-laitteet (Auffenberg, Snow, Stein & Rogers, 2017). Energiankulutuksen vähentäminen vähentää luonnollisesti myös energiakustannuksia. Lisäksi kustannuksia voidaan alentaa aikatauluttamalla energiankulutus halvalla ajanjaksolle. Aikataulutus tarkoittaa sitä, että sähkön pörssihintaa seuraamalla käyttäjä tekee päätöksiä omasta energiankulutuksestaan (Lee, 2019). Esimerkiksi sähköautoa ei kannata ladata päivällä, kun sähkön hinta on korkeimmillaan, vaan yöllä, jolloin se on matalammalla. Energiankulutuksen vähentäminen vähentää samalla myös ympäristökuormaa. Ympäristökuormaa voidaan vähentää myös käyttämällä uusiutuvia luonnonvaroja, kuten aurinko- ja tuulivoimaa.

### 2.3 Älykkäät ympäristöt

Teknologian käyttöönoton ja ohjelmistopohjaisten palveluiden myötä on luotu älykkäitä ympäristöjä, joiden avulla käyttäjät voivat toimia saumattomammin vuorovaikutuksessa oman lähiympäristönsä kanssa. Älykkäisiin ympäristöihin voidaan usein yhdistää termi kotiautomaatio. Kotiautomaatiolla tarkoitetaan esimerkiksi valaistuksen, lämmityksen, ilmastoinnin, sähkön tai kodissa olevien muiden laitteiden ja automaation yhdistämistä. (Nugent, McClean, Cleland & Burns, 2014).

Benavente-Pecetin (2019) mukaan älykkäissä ympäristöissä usein käytetään älykkäitä sensoreja ja toimilaitteita, joilla voidaan monitoroida ja ohjata ympäristöissä erilaisia sovelluksia, kuten ilmastointia. Datan keräämisellä ja soveltamisella yhdessä älykkäiden toimilaitteiden kanssa pystytään toimimaan normaalia toimintaa tehokkaammin. Tällöin energiatehokkuus ja säästöt kustannuksissa nousevat

Älykkäillä sensoreilla tarkkaillaan ympäristön ominaisuuksia, kuten lämpötilaa, kosteutta, energiankulutusta, ilmanlaatua ja valaistustasoa. Ulkopuolista lähteistä saatavaa dataa, kuten sähkön hintasignaaleja tai sääennusteita, voidaan myös hyödyntää. Usein älykkäiseen ympäristöön yhdistetään myös omat energiavarannot, kuten aurinkoenergia ja tuulienergia sekä näiden optimaaliseen hyödyntämiseen liittyvät akkuvarastot. Koska dataa kerätään ympäristöstä paljon, on usein datan varastointiin älykkäissä ympäristöissä jokin keskitetty energianhallintajärjestelmä, jossa on tietokanta sekä datasta keskeisiä tunnuslukuja analysoivia ohjelmia. (Morteza, Zand, Eskandari, Padmanaban & Siano, 2021). Näitä energianhallintajärjestelmiä kutsutaan tutkielmassa ympäristöstä riippuen joko HEMS (home energy management system) tai BEMS (building energy management system) nimillä. Keskitetyn energianhallintajärjestelmän arkkitehtuuri, jossa hyödynnetään data-analytiikkaa, Benavente-Pecetin (2019) mukaan näyttää kuvion 2 mukaiselta.



KUVIO 2 Keskitetyn energianhallintajärjestelmän arkkitehtuuri

### **3 TUTKIMUSMENETELMÄ**

Tässä luvussa kuvataan systemaattisen kirjallisuuskatsauksen menetelmä. Menetelmä on sovellettu Okolin ja Schabramin (2010) ohjeiden pohjalta. Tämän luvun ensimmäisessä alaluvussa kuvataan lyhyesti systemaattinen kirjallisuuskatsaus tietojärjestelmätieteen osalta. Seuraavat alaluvut kertovat, miten systemaattista kirjallisuuskatsausta on sovellettu tässä tutkielmassa, kun esitellään tutkimuskysymys ja tämän tutkielman systemaattinen prosessi.

#### **3.1 Systemaattinen kirjallisuuskatsaus tutkimusmenetelmänä**

Okoli ja Schabram (2010) kuvailevat systemaattisen kirjallisuuskatsauksen tuottamisen tietojärjestelmätieteen alalla 8-vaiheiseksi ohjelmaksi. Vaiheet ovat tutkimuksen tarkoituksen kartoittaminen, protokollan noudattaminen, kirjallisuuden hakeminen, aineiston seulonnat, laadun arviointi, tiedonkeruu, tietojen analysointi ja katsauksen kirjoittaminen. Systemaattinen kirjallisuuskatsaus noudattaa hyvin selkeää vaiheittaista prosessia, ja menetelmää tulee seurata tarkasti, jotta lopputulos olisi mahdollisimman kattava.

Systemaattinen kirjallisuuskatsaus Okolin ja Schabramin (2010) mukaan eroaa muista kirjallisuuskatsauksista siten, että sille on määritelty tarkkaan suunnitelma sekä jokainen vaihe. Vaiheet on myös kirjattu virheiden minimoimiseksi ja toistettavuuden kattamiseksi.

#### **3.2 Tutkimuskysymys**

Tutkielmassa pyritään vastaamaan yhteen tutkimuskysymykseen, jonka avulla yritetään kartoittaa, miten data-analytiikkaa ja sen keinoja hyödynnetään energiankulutuksen optimoinnissa älykkäissä ympäristöissä. Tutkimuskysymys siis on:

TK1: "Miten data-analytiikkaa hyödynnetään energiankulutuksen optimoinnissa älykkäissä ympäristöissä?"

### 3.3 Systemaattinen valintaprosessi tutkielmassa

Tässä luvussa esitellään, miten systemaattinen valintaprosessi on toteutunut tätä kirjallisuuskatsausta tehdessä. Seuraavissa alaluvuissa kuvataan, miten kirjallisuuden valintaprosessi on edennyt tässä tutkielmassa.

#### 3.3.1 Kirjallisuuden hakeminen

Kirjallisuutta haettiin kolmesta eri tietokannasta samoin hakukriteerein. Tietokannat olivat ProQuest Computing Database, ACM: Digital Library sekä IEEE Xplore. Hakuja toistettiin myös joistakin muista tietokannoista, mutta haku ei tuottanut näissä tulosta tai osumat olivat duplikaatteja. Taulukossa 1 on käyty läpi tutkielmassa käytetyt hakulauseet.

TAULUKKO 1 Hakulauseet ja tietokannat

Tietokanta	Hakulause
IEEE Xplore	("data analytics" OR "big data" OR "machine learning" OR "predictive analytics" OR "ai" OR "artificial intelligence") AND ("energy consumption" OR "energy efficiency") AND ("smart building*" OR "smart home*" OR "smart environment*") AND ("optimization" OR "performance improvement" OR "cost reduction" OR "environmental sustainability")
ProQuest	noft(("data analytics" OR "big data" OR "machine learning" OR "predictive analytics" OR "AI" OR "artificial intelligence") AND ("energy consumption" OR "energy efficiency") AND ("smart building?" OR "smart home?" OR "smart environment?") AND ("optimization" OR "performance improvement" OR "cost reduction" OR "environmental sustainability"))
ACM digital library	("data analytics" OR "big data" OR "machine learning" OR "predictive analytics" OR "ai" OR "artificial intelligence") AND ("energy consumption" OR "energy efficiency") AND ("smart building*" OR "smart home*" OR "smart environment*") AND ("optimization" OR "performance improvement" OR "cost reduction" OR "environmental sustainability")

Hakulausekkeessa yritettiin ottaa kaikki tutkimuskysymykseen liittyvät aspektit mukaan mahdollisimman tarkasti, jotta kirjallisuus saatiin rajattua mahdollisimman tiiviiksi jo hakuvaiheessa.

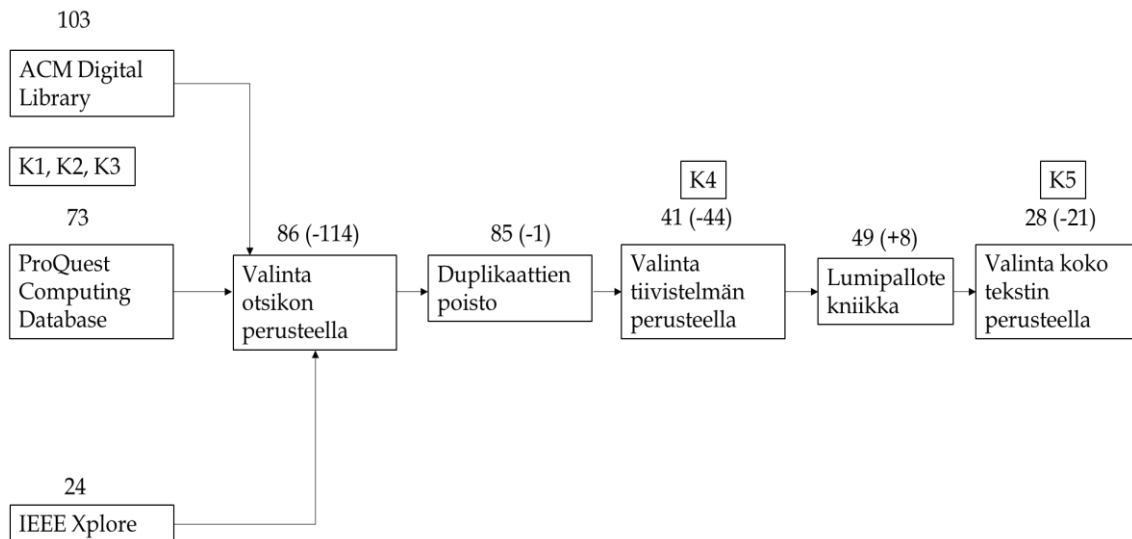
#### 3.3.2 Aineiston seulonta ja laadun arviointi

Hakulausekkeen oikean muotoilun jälkeen jäljelle jäänyt aineisto seulottiin käyttämällä kriteereitä, joilla aineistoa valittiin kirjallisuuskatsaukseen. Prosessissa aineistoa arvioitiin otsikkotason tarkastelulla, abstraktin tarkastelulla, lumipallotekniikalla sekä koko tekstin tarkastelulla seuraten ennalta asetettuja kelvollisuuskriteerejä. Taulukossa 2 on esitelty kelvollisuuskriteerit ja kuviossa 3 on esitelty kirjallisuuden hakeminen vaiheittain. Kelvollisuuskriteereiden

tunnukset ovat näkyvillä kuviossa 3, josta huomataan, missä vaiheessa kyseistä kriteeriä on käytetty. Kaikki artikkelit ovat vertaisarvioituja sekä valittu tieteellisistä lehdistä, jonka Julkaisufoorumin taso on joko 1 tai 3 (1: perustaso, 3: korkein taso).

TAULUKKO 2 Kelvollisuuskriteerit

Tunnus	Selitys
K1	Artikkeli on kirjoitettu englanniksi
K2	Artikkeli on kirjoitettu 01.2013 - 02.2023
K3	Artikkelin koko teksti on saatavilla
K4	Artikkeli kertoo data-analytiikasta, älykkäistä ympäristöistä sekä energiankulutuksesta
K5	Artikkeli kertoo data-analytiikan tekniikoista, joilla voidaan optimoida energiankulutusta älykkäissä ympäristöissä. Optimointi tarkoittaa tässä tapauksessa kaikkia keinoja, jolla voidaan säästää energiassa (hintaa, kulutus, ympäristö)



KUVIO 3 Kirjallisuuden hakuprosessi

## 4 DATA-ANALYTIikka ENERGIANKULUTUKSEN OPTIMOINNISSA

Tässä tutkielman pääluvussa vastataan tutkimuskysymykseen ”Miten data-analytiikkaa hyödynnetään energiankulutuksen optimoinnissa älykkäissä ympäristöissä?”. Luvussa esitellään data-analytiikan eri keinoja, joilla saadaan energiankulutusta optimoitua. Luku jaetaan alalukuihin energiankulutuksen optimoinnin eri aihealueisiin eli energiankulutuksen, energiakustannusten sekä ympäristökuorman vähentämiseen. Osa artikkeleista on laajempia, millä voidaan tuoda tietoa useampaan alalukuun. Taulukosta 3 voidaan nähdä artikkelien jakaantumisen eri aihepiirien ympärille.

TAULUKKO 3 Artikkelien määrä eri aihepiireissä

Aihe	Energiankulutuksen vähentäminen	Energiakustannusten vähentäminen	Ympäristökuorman vähentäminen
Määrä	16	12	6

Data-analytiikan avulla voidaan ennustaa monia eri tunnuslukuja energiankulutuksesta ja oivaltaa myös uusia ennestään tuntemattomia tapoja optimoida energiankulutusta (Benavente-Peces, 2019). Dataa tarvitsee kuitenkin kerätä ympäristöstä, josta analyysiä tehdään ja tällöin esimerkiksi IoT-laitteet (Internet of Things) ja -sensorit tulevat avuksi. IoT mahdollistaa datan reaaliaikaisen liikumisen eri kommunikaatiokeinoilla, useimmiten Wi-Fi:n tai esimerkiksi Zigbee-kommunikaation avulla. (Dhowmya, Danalakshmi, Hariharasudan, Marcin & Marlena, 2021). Tämä data liikkuu siitä pilvilaskentaan, joka analysoi datan ja tekee todennäköisyydeltäänärkevimmän päätöksen ajankohdalla. Tästä tieto liikkuu takaisin IoT-laitteelle tai releelle eli sähkömekaaniselle kytkimelle, joka säätää laitteen toimimaan data-analyysiin perustuvalla tiedolla (Benavente-Peces, 2019).

## 4.1 Data-analytiikka energiankulutuksen vähentämisen näkökulmasta

Data-analytiikkaa voidaan hyödyntää energiankulutuksen vähentämisessä usealla tavalla. Kokonaisuudessaan tuloksista voidaan huomata, että hyvin moni ratkaisu käyttää data-analytiikkaa myös käyttäjän mukavuuden optimointiin. Lisäksi mukavuustason optimointi on hyvin tärkeää ympäristössä, jossa käyttäjä nukkuu yönsä, eli esimerkiksi kotona. Useimmissa artikkeleissa keskitytään LVI-laitteiston energiankulutuksen optimointiin, sillä LVI-laitteet kuluttavat suurimman osan ympäristön sähkönkulutuksesta. Lisäksi tässä tutkimuksessa on mukana artikkeleja, jotka käsittelevät esimerkiksi valaistuksen optimointia tai erilaisia sovelluksia, jotka suosittelevat käyttäjälle eri tapoja toimia optimaalisesti. Automaattisilla data-analytiikan ratkaisuilla saavutetaan jopa noin 40 % säästöjä energiankulutuksessa.

Chou ja Ngo (2016) ovat toteuttaneet tutkimuksessaan kehyksen SDSS (Smart Decision Support System) sovellukseen, joka integroi tekoälyä ja dynaamisia monen objektin optimointimalleja. SDSS voi generoida käyttäjälle energiankulutuskaavoja ja vaihtoehtoisia energiaa säästäviä ratkaisuja laitetasolla. Data-analyysiä toteutetaan aikasarjamallien ja datan louhinnan avulla. Mallin idea on, että käyttäjä saa sovellukselta ehdotuksen, jolla energiaa voidaan säästää ja käyttäjä saa itse päättää tehdäänkö sovelluksen ehdottama ratkaisu. Myös Dhowmya ym. (2021) ovat pyrkineet energiankulutuksen vähentämiseen mutta toisin kuin Choun ja Ngon (2016) ratkaisussa, he käyttävät syväoppimisalgoritmia ennustamaan LVI-laitteiden energiankulutus erilaisissa sääolosuhteissa. Heidän mallinsa CRNN (Convolutional Recurrent Neural Network) perustuu kahden neuroverkon integrointiin luoden näin hybridiratkaisun. Myös Constantinou, Konstantinidis, Chrysanthis ja Zeinalipour-Yazti (2022) ovat luoneet laitetasolle tekoälyyn pohjautuvan GP-algoritmin (Green Planner), joka optimoi laitteiden energiankulutusta. Heidän ratkaisussaan luodaan balanssia mukavuuden, energiankulutuksen ja hiilidioksidipäästöjen välillä mahdollisimman tehokkaasti hyödyntäen samalla IMCF+ (IoT Meta-Control Firewall) mallia.

Chou ja Ngo (2016) eroavat ratkaisullaan Dhowmyan ym. (2021) ja Constantinoun ym. (2022) ratkaisusta siten, että heidän ratkaisunsa ei ole automaattinen, vaan ehdottaa käyttäjälle sovelluksen kautta, mitä voidaan tehdä energiankulutuksen osalta tehokkaammin. Dhowmyan ym. (2021) ja Constantinoun ym. (2022) ratkaisuisissa koko energianhallinta toteutetaan datan pohjalta automaattisesti. Toisaalta Choun ja Ngon (2016) ratkaisu on korvannut automatiikkaa siten, että käyttäjää informoidaan erilaisista tärkeistä tunnusluvusta sovelluksen kautta, joita ovat muun muassa reaaliaikainen energiankulutus, kulutushistoria ja vertailu, kulutusennusteet, optimaaliset suositukset ja säästöt sovelluksen ehdotuksilla. Konkreettisia energiankulutuksen säästöjä näistä tutkimuksista on vaikea verrata, sillä tulokset on raportoitu eri muodoissa. Kuitenkin GP-algoritmilli saadaan normaaliin energiankulutukseen verrattuna vä-



hennettyä laitteiden energiankulutusta jopa 40 % vain noin 3 % mukavuustason alenemisella (Constantinou ym., 2022). Myös CRNN-mallilla saadaan CNN (Convolutional Neural Network) ja RNN (Recurrent Neural Network) malleihin verrattuna laitteet toimimaan muutamia prosentteja tehokkaammin, kun CNN:ää käytetään löytämään datasta parannuksia energiatehokkuuteen ja RNN:ää käytetään laitteiden optimaalisempaan ohjaukseen (Dhowmya ym., 2021). Choun ja Ngon (2016) ratkaisulla saadaan puolestaan hyvin informoitua käyttäjää energiatehokkaammista ratkaisuisista, ja käyttäjä pystyy informaation perusteella tekemään itselleen oikeanlaisen ratkaisun.

Shafqat, Kyu-Tae ja Do-Hyeun (2023) ovat tehneet tutkimuksessaan laajan ennusteisiin perustuvan rakenteen optimaaliselle aikataulutukselle ja älykodin laitteille perustuen käyttäjien ja laitteiden luokitteluun. Energiankulutuksen ennustetta tehdään neuroverkkoihin perustuvalla LSTM (Long Short-Term Memory) algoritmilla yksilöllisesti käyttäjästä ja hänen preferensseistään, käytettävästä laitteesta sekä ulkoisista tekijöistä. Koska on vaikeaa yhdistää eri käyttäjiä laitteiden kulutukseen, he ovat ratkaisseet ongelman siten, että verkon välityksellä paikannetaan älypuhelimien paikkatieto esimerkiksi huoneen perusteella. Kun käyttäjä on paikannettu ja hänen preferenssinsä tietyssä huoneessa ennustettu, on aika asettaa käyttäjän ennustetut parametrit kullakin ajanhetkellä optimointiin ja ohjaukseen, millä saadaan ohjattua esimerkiksi oikea lämpötila ja valaistus huoneeseen.

Auffenberg ym. (2017) ovat myös pyrkineet data-analytiikalla ennustamaan käyttäjien preferenssit kullakin ajan hetkellä ja tällä tiedolla ohjaamaan ilmastointia ja lämmitystä optimaalisemmin. Toisin kuin Shafqatin ym. (2023) tutkimus hyödyntää neuroverkkoja käyttäjän preferenssien ennustamiseen, he ovat hyödyntäneet BCM (Bayesian Comfort Model) mallia. Data, jota tutkimuksessa hyödynnetään ei liity myöskään käyttäjien älylaitteiden paikantamiseen vaan enemmänkin yleisen tason muuttujien seurantaan, kuten lämpötila tai kosteus. Näin saadaan kaikille käyttäjille lähes optimaaliset olosuhteet elämiseen. Ullah ja Kim (2017) ovat keskittyneet myös tutkimuksessa energiankulutuksen vähentämiseen mukavuustason analysoinnin pohjalta. Heidän mallinsa perustuu Kalmanin filtlerin variaatioon, jolla toteutetaan ennusteet lämpötilasta, ilmanlaadusta sekä valomäärästä. Mukavuustasoa optimoidaan käyttäjän preferensseistä muodostetuilla raja-arvoilla, joita laitteiden ohjaus ei saa rikkoa. Laitteiden ohjaus heidän tutkimuksessansa toteutetaan soveltamalla Kalmanin filtteriä GA:han (Genetic Algorithm) ja PSO:hon (Particle Swarm Optimization), jotka laskevat optimaalisen asetuksen perustuen ennustettuihin arvoihin.

Tulosten kannalta Shafqatin ym. (2023), Auffenbergin ym. (2017) ja Ullahin ja Kimin (2017) tutkimukset eroavat toisistaan paljon. Esimerkiksi Shafqatin ym. (2023) tutkimuksessa todetaan, että käyttäjiä on niin paljon erilaisia, joten ainoa selkeä tulos on mukavuuden parantaminen. Myös tietyillä preferensseillä onnistutaan saamaan säästöä energiankulutuksessa. BCM mallilla säästetään energiankulutuksessa verrattuna referenssipisteeseen perustuvaan FSP (Fixed Set-Point) ja raja-arvoihin perustuvaan FCR (Fixed Comfort Range) malleihin jopa 6,4 % - 10,5 % lämmityksestä ja 15,1 % - 39,4 % ilmastoinnista (Auffenberg

ym., 2017). Ullah ja Kim (2017) ovat onnistuneet säästämään energiankulutuksessa ilmastoinnista, lämmityksestä sekä valaistuksesta GA:lla 31,42 % sekä PSO:lla 27,32 %. Heidän tuloksistaan voidaan myös huomata, että normaalitilassa lämmityksen ja ilmastoinnin energiankulutus pysyy hyvin tasaisena. Optimoituna energiankulutus vaihtelee siksakkimaisesti ylös ja alas, kuitenkin pitäen kulutuksen ylärajan lähellä vanhaa keskiarvoa.

Shah ja ym. (2020) esittelevät tutkimuksessaan mallin, jolla voidaan säätää dynaamiset käyttäjän preferenssit ja optimoida energiankulutusta käyttäen DELM:iä (Deep Extreme Learning Machine) ja Bat algoritmia. DELM:illä säädetään parametrit dynaamiseksi staattisten parametrien sijasta käyttämällä olosuhdedataa hyödyksi. Näin saadaan optimaalisemmat käyttäjäparametrit, kuten valo, hiilidioksidi sekä lämpötila, joilla saadaan Bat algoritmi tekemään energiankulutuksen optimointi tarkemmin. Heidän ratkaisunsa avulla mukavuustaso pysyy optimissa koko ajan, kun taas normaalitilassa se vaihtelee jatkuvasti 3–5 % optimista. DELM:illä saadaan myös suuri säästö energiankulutukseen, sillä pelkkään Bat-algoritmiin verrattuna DELM:in läsnäolo tuo noin 40 % suuremmat säästöt kulutuksen osalta.

Khamesi ym. (2020) tekevät energiankulutuksen optimointia tutkimuksessaan käyttäjän psykologista profiilia mallintamalla ja määrittävät käyttäjien energiankulutusbudjetin mallintamalla yksilöllistä energiankulutuksen dataa. Heidän malliaan kutsutaan tutkimuksessa CODY:ksi (COndensed DeBendency). Heidän ratkaisunsa ei ole automaattinen, kuten Shahin ym. (2020) ratkaisu, vaan he ehdottavat enemmänkin käyttäytymismalleja, joilla käyttäjä voi pysyä omassa energiankulutusbudjetissaan tinkimättä omasta mukavuustasostaan. CODY:ä verrattaessa muihin energiala säästäviin malleihin monet käyttäjät kyselyiden perusteella valitsevat CODY:n. Mallista selviää hyvin, miten täytyy käyttäytyä, jos haluaa selvittää budjetin rajoissa. Nagy ym. (2015) seuraavat toimistorakennuksen valaistustasoa ja käyttäjien palautetta voidakseen mallintaa optimaalisen valaistustason toimistoon. Erotten Shahin ym. (2020) ja Khamesin ym. (2020) tutkimuksista he ovat keränneet dataa pelkästään valosensoreilla liikkeentunnistimen triggereistä ja manuaalisista valokytkimen painalluksista. Malli säästää energiankulutusta tilanteessa, jossa valojen käyttö on järkevää, jopa 37,9 % ja tilanteessa, jossa valot palavat aina jopa 73,2 %.

Aguilar ym. (2019) tutkimuksessaan esittelevät ACODAT (Autonomous Cycle of Data Analysis Tasks) mallin, joka ehdottaa kullekin LVI-laitteelle parhaan mahdollisen toiminnon kullakin ajanhetkellä. Dataa kerätään sensoreilla esimerkiksi lämpötiloista, kosteudesta sekä hiilidioksidilukemasta. Mallin he ovat tehneet täysin itseohjautuvaksi, joten operointiin ei tarvitse puuttua fyysisesti. Malli toimii niin, että sille opetetaan suurilla datamassoilla se ympäristö, johon mallia sovelletaan. Tämän jälkeen sensorien reaaliaikainen data menee analysoitavaksi, josta malli lähettää parhaimman ratkaisun tiedot releelle, joka tekee komennon toimilaitteelle. Esimerkiksi jos sensori lähettää liian viileän lämpötilan ACODAT:ille, sille katsotaan ajanhetkellä sopivin lämmitysteho, jolla lämpötila saadaan oikealle tasolle. Myös Peña, Biscarri, Personal ja León (2022) ovat toteuttaneet lähes samanlaisen ratkaisun kuin Aguilar ym. (2019),

mutta eri menetelmillä. Heidän mallissaan käytetään DSS:ää (Decision Support System), joka on rakennettu koneoppimiseen perustuvasta päätöspuusta ja erilisistä klustereista. Päätöspuu toimii tutkimuksessa ennustemoduulina, jossa historiallinen data sekä reaaliaikainen data analysoidaan ja lähetetään eteenpäin luokittelumoduuliin, jossa ennusteet jaetaan klustereihin. Tämän jälkeen lähetetään ohjauskomennot ohjaimille. Aiemmin käsitellyt Peñan ym. (2022) sekä Aguilarin ym. (2019) ratkaisut ovat hyvin samanlaisia luonteeltaan, mutta Peñan ym. (2022) malli on toteutettu hieman laajemmin arkkitehtuurisesti. Molemmilla ratkaisuilla saadaan huomattava parannus ympäristön mukavuustason sekä energiatehokkuuteen. Peña ym. (2022) ovat raportoineet, että heidän mallillaan saadaan noin 75 % päivistä energiatehokkaiksi ja loput päivät ovat energiatehottomia. Energiatehottomat päivät voivat heidän mukaansa viitata poikkeavaan toimintaan, joka olisi pitänyt puhdistaa datasta paremmin.

Chaganti ym. (2022) ovat tutkimuksessaan optimoineet koneoppimisen tekniikalla uusien rakennusten suunnitteluun soveltuvaa lähestymistapaa. 3RF (3RandomForest) mallilla ennustetaan rakennuksen lämmitys- sekä jäähdytystarvetta. Malli eroaa muista tutkimuksen malleista siten, että parametreina on tällä kertaa rakennuksen ominaisuuksia, kuten pinta-aloja ja tilavuuksia tai lämpöarvoja. 3RF menestyi tarkkuudeltaan parhaiten muihin data-analytiikan keinoihin verrattuna. Myös Saba ym. (2022) ovat poikenneet muista tutkimuksista siten, että he ovat luoneet automaattisen muistutusjärjestelmän nimeltään IRRHEM (Intelligent Reasoning Rules for Home Energy Management), joka tarkkailee laitteiden energiankulutusdataa ja informoi käyttäjää energiahukkaa tuottavista toimista. IRRHEM:in kautta voidaan myös ohjata kodin verkossa olevia laitteita ilmastoinnista sälekaihtimiin.

Chagantin ym. (2022) ja Saban ym. (2022) tutkimukset muistuttavat toisiinsa siinä mielessä, että Chagantin ym. (2022) tutkimuksessa opetetaan rakennuksen suunnittelijoille lähtökohdat energiatehokkaaseen rakennukseen. Saban ym. (2022) tutkimuksessa puolestaan opetetaan rakennuksen käyttäjiä toimimaan mahdollisimman energiatehokkaasti. Koska hallinta on täysin käyttäjien käsissä, ratkaisulla saavutetaan vain 3,6 % energiansäästö (Saba ym., 2022). Chagantin ym. (2022) tutkimuksen tarkoituksena on tuoda tietoon koneoppimismetodeilla toteutettu rakennusten suunnitteluprosessi.

Park ym. (2020) ovat tutkimuksessaan hyödyntäneet olemassa olevaa BEMS-järjestelmää, jota parannellaan dynaamisella aikataulutuksella koneoppimisen metodeilla. Dynaamisen aikataulutuksen tarkoituksena on hyödyntää kerättyä sensoridataa, jotta käyttäjille saadaan optimaalinen mukavuustaso silloin, kun käyttäjät ovat tilassa. Kun käyttäjät poistuvat tilasta järjestelmät ajastetaan energiaa säästävälle asetukselle. Testiympäristönä heillä on suurehko hotelli ja dataa kerätään hotellin huoneista esimerkiksi lämpötilasta, kosteudesta, hiilidioksidilukemasta, liikkeistä sekä energiankulutuksesta. Näin saadaan kaikkien käyneiden asiakkaiden preferensseistä dataa. Ratkaisulla voidaan myös ennustaa suunnilleen koska asiakkaat tulevat takaisin, jotta huone ei esimerkiksi ole todella epämukava asiakkaan sinne saapuessaan. Avci ym. (2013) ovat muokanneet tutkimuksessaan energianhallintajärjestelmää, johon he liitti-

vät MPC (Model Predictive Control) ohjaimen. MPC eroaa Parkin ym. (2020) BEMS:stä siten, että se toimii aina samalla tavalla eikä vaihda esimerkiksi tehoaluetta, kun ympäristöstä poistutaan. Toisaalta taas MPC:llä analysoidaan lineaarisen regression avulla ulkolämpötilan suhdetta sisälämpötilaan, mitä ei BEMS:illä tehdä. Myös Vargas-Solar ym. (2022) toteavat sääennusteiden analysoinnin pohjalta, että ulkolämpötilan ja ulkoilman kosteuden analysointi ovat kaksi tärkeintä muuttujaa analyysin kannalta, jotka vaikuttavat energiankulutukseen. He myös tutkimuksessaan luovat GREENHOME-konseptin, jolla tuotetaan data-analytiikan työkaluja tutkijoille, millä voidaan paremmin ymmärtää muuttujien välistä suhdetta ja ennustaa energiankulutusta. GREENHOME käyttää kahta koneoppimiseen perustuvaa mallia, jotka ovat ARIMA (Auto-Regressive Integrated Moving Average) ja ARX (Auto-Regressive with Exogenous terms).

Avcı ym. (2013) pystyvät ratkaisullaan säästämään normaaliin raja-arvoihin perustuvaan termostaattiin verrattuna 8 % energiankulutuksesta, kun MPC operoi samoilla rajoilla. Jos rajojen toleranssia laajennettaisiin, säästöt voisivat olla vielä enemmän. Park ym. (2020) asukkaiden liikettä ja energiankulutusta analysoiden vähentävät energiankulutusta jopa 20 % aikaisemmasta, toisaalta ympäristö on erittäin optimaalinen sillä hotellin asukkaat eivät ole niin tarkkoja energiankulutuksesta, sillä siitä ei aiheudu heille erikseen lisäkustannuksia. Vargas-Solarin ym. (2022) ratkaisu on taas hyödyllinen, sillä tulevaisuudessa mallilla voidaan etsiä paremmin riippuvuuksia eri asioiden välillä. Näin esimerkiksi voidaan luoda automatiikkaa erilaisille energialaitteille ja suunnitella energiatehokkaampia ympäristöjä. He toteavat myös, että asuintaloille on hyvin hankalaa tehdä tarkkaa energiankulutuksen ympäri- vuotista ennustetta, sillä asukkaat voivat esimerkiksi lähteä reissuun, jota malli ei osaa odottaa. Näinä ajanjaksoina optimointi voisi olla tehokkaampaa, sillä mukavuustasosta ei tarvitsisi niinkään välittää.

## **4.2 Data-analytiikka energiakustannusten vähentämisen näkökulmasta**

Energiakustannuksia ihmiset ovat pyrkineet säästämään perinteisin keinoin, kuten esimerkiksi ajastimien avulla tai säätämällä termostaatteja alas päivisin, kun sähkön hinta on korkealla. IoT-laitteet tulevat myös energiakustannusten optimoinnissa esille, joiden avulla voidaan säätää esimerkiksi rakennuksen lämmitystä etäohjauksella. Kuitenkin kaikki tämä vaatii käyttäjältä jatkuvaa energian pörssihinnan seuraamista sekä tietämystä, mikä olisi se optimaalinen parametri laitteelle kullakin ajan hetkellä. Tässä data-analytiikka ajaa suurta roolia, koska sillä on mahdollista tehdä automaattisesti todennäköisimmin paras päätös kullakin ajanhetkellä.

Kaikki energiakustannusten optimointiin liittyvät tutkimukset hyödyntävät data-analytiikkaa ympäristön toimintojen optimaaliseen aikatauluttamiseen.

Lisäksi mukana on myös tutkimuksia, jotka hyödyntävät akkuvarastoja korvatakseen kalliin sähkön tunteja. Aikataulut on erittäin hyvä tapa säästää energiakustannuksissa, mutta se tuo samalla käyttäjälle epämukavuutta, kun jotain tiettyä asiaa ei voida tehdä haluamallaan ajanhetkellä. Tuloksista voidaan huomata, että energiakustannuksia on saatu säästettyä jopa 40–50 % riippuen siitä, onko ympäristössä käytetty akkuvarastoja.

Moni lähestymistapa energiakustannusten optimointiin on analysoida laitteiden tasolla energiankulutusta ja sähkön hintaa. Näin voidaan aikatauluttaa laitteiden toiminta taloudellisemmaksi sähkön hinnan puolesta. Shafqat ym. (2023) ottavat LSTM-algoritmillaan huomioon ennusteet kaikkien verkossa olevien laitteiden energiankulutuksesta ja energian hinnasta tuntitasolla. Myös Morteza ym. (2021) huomioivat samat ennusteet, mutta lisäävät ympäristöön akkuvarastot korvaamaan sähkön kysyntäpiikkejä. Khalid ym. (2018) ovat toteuttaneet ohjaukseltaan samankaltaisen järjestelmän, kuin Shafqat ym. (2023), mutta ovat ohjanneet tekemään ennusteet päivää ennen menetelmällä. Lisäksi heidän malliaan on mahdollista ohjata automaattisesti sekä manuaalisesti, jolloin käyttäjä voi halutessaan keskeyttää jonkin toiminnon tai aloittaa toiminnan haluamaan aikana, jolloin aikataulut uusitaan reaaliaikaisesti. Toisaalta tämä ratkaisu ei välttämättä ole se optimaalisin ratkaisu, sillä käyttäjä voi tehdä päätöksen kalliina ajankohtana. Morteza ym. (2021) taas käyttävät omaa energia-tuotantoa korvatakseen osittain kysyntäpiikit, mutta samalla ohjaten laitteita toimimaan automaattisesti sähkön hintasignaalin pohjalta optimaalisesti.

Shafqatin ym. (2023), Mortezan ym. (2021) ja Khalidin ym. (2018) mallit toimivat samalla tavalla siten, että tavoitteena on ohjata laitteita toimimaan vähemmällä energiankulutuksella kysyntäpiikin aikaan data-analytiikan avulla. Lisäksi vaikka automaattista ratkaisua ei haluaisi käyttää esimerkiksi sen vuoksi, että aikataulut olisivat epämukavia, data-analytiikalla voidaan informoida käyttäjiä tekemään energiaa kuluttavat aktiviteetit silloin, kuin julkinen sähköverkko ei ole suurella kuormituksella. Myös Rasheed ym. (2019) ovat MAS-järjestelmän avulla keränneet dataa ja analysoineet sitä sekä hyödyntäneet OSR:n (optimal stopping rule) toimintaa, jotta päätökset saataisiin tehtyä oikeaan aikaan. Heidän ratkaisunsa perustuu energiakustannuksia nostavien toimenpiteiden välttämiseen, jota toteutetaan laitteiden aikatauluttamista parantamalla datan pohjalta. Parhaimpaan tulokseen ylittää Mortezan ym. (2021) tutkimus, jossa saadaan uusiutuvia luonnonvaroja ja akkuvarastoja käyttämällä 45 % säästettyä energiakustannuksissa. Myös Khalid ym. (2018) onnistuvat karsimaan energiakustannuksia 40 % sekä PAR:ia (peak to average ratio) alennettua jopa 50 %, mikä on todella paljon siinä suhteessa, että heidän ratkaisunsa on myös manuaalisesti säädettävissä. Toisin kuin Rasheedin ym. (2019) ratkaisulla saadaan energiakustannuksia karsittua vain 16,76 %.

Lee (2019) sekä Avci ym. (2013) ovat tutkimuksissaan lähestyneet energiakustannusten vähentämistä pelkästään LVI-laitteiden osalta. Avcin ym. (2013) tutkimuksessa on hyödynnetty MPC-mallia, jolla voidaan sähkön pörssihinnan ja LVI-laitteiden energiankulutusdatan perusteella ennustaa oikea asetus ajanhetkelle. Heidän mallisansa käytetään ympäristön lämpötilalle raja-arvoja, jot-

ka käyttäjä asettaa. Lee (2019) on mallissaan taas dataa analysoimalla tehnyt käyttäjän lämpötilapreferenssien mukaan ohjauksen, jolla osataan löytää optimaalinen ilmastoinnin asetus kullekin ajanhetkelle. Hänen mallinsa on siis mukavuudeltaan todella optimaalinen, kun säätöjä ei tarvinnut tehdä ollenkaan käyttäjän osalta. Molempien osalta malli toimii kuitenkin niin, että kysyntäpiikin aikana laitteet toimivat juuri mukavuusalueen rajalla, kun taas muulloin kivutaan takaisin kohti optimaalista lämpötilaa. Avci ym. (2013) saavat laskettua kysyntäpiikin kulutusta jopa 24 % normaalista toiminnasta. Koska Lee (2019) käyttää tutkimuksessaan myös akkujen älykästä purkamista laitteiden aikataulutuksen lisäksi, data-analytiikan keinoilla saadaan säästettyä 50 % energiakustannuksissa.

Osa tutkimuksista keskittyy optimoimaan energiakustannuksia käyttäjän preferenssien kautta ensisijaisesti, sillä mukavuustason ylläpitäminen on erittäin tärkeää ihmisen hyvinvoinnin kannalta (Khamesi ym., 2020). Tundis, Ali ja Mühlhäuser (2019) tekevät mallin, jolla voidaan tunnistaa käyttäjä ja käytetyt laitteet, kun kerätään tietoa käyttäjän liikkeistä ja kulutuksesta Wi-Fi verkon avulla. Tällöin osataan yhdistää käyttäjän preferenssit ja sähkön hinta. Samanlaista menetelmää käyttää myös Huang, Xu, Cai, Khalid ja Yu (2018) ratkaisussaan. Toisaalta he ovat neuroverkkojen avulla analysoineet myös, mitä käyttäjä tulee seuraavaksi tekemään. Näin osataan käyttäjäpreferenssit huomioiden analyttisin metodein ohjata laitteita toimimaan energiatehokkaasti ja samalla säädellä myös energiaa kuluttavien laitteiden tehoja tiettyinä ajankohtina. Toisaalta Huangin ym. (2018) malli on laajempi siinä suhteessa, että ennusteita tehdään enemmän ja heidän tapauksessansa käytetään myös akkuvarastoja korvaamaan kysyntäpiikkien kulutus osittain.

Lee ja Choi (2020) ovat suunnitelleet käyttäjämukavuuden ohjaamaan kaksitasoista DRL-malliaan (deep reinforcement learning), jolla pyritään ensimmäisellä tasolla olevia suuren kulutuksen kodin laitteita ohjautumaan käyttäjän aikatauluihin ja toisella tasolla lataamaan akkuvarastoa sekä sähköautoa, kun sähkön hinta on optimaalinen. Heidän ratkaisunsa perustuu käyttäjän antamaan palautteeseen, jonka mukaan epämukavuuden lisääntyessä, koneoppimiseen perustuva algoritmi sisäistää asian ja säätää mukavuustasoa korkeammalle. Toisaalta laitteet taas kuluttavat enemmän kysyntäpiikkien päällä. He ovat myös hyödyntäneet ratkaisussaan akkujen älykästä purkamista niin sähköauton kuin akkuvarastojenkin osalta. Näin voidaan vähentää kysyntäpiikeiltä sähkön ostamista ja ylläpitää energiaa kuluttavia toimintoja akkujen avulla.

Hafeez ym. (2020) tutkimuksessaan ovat keskittyneet pelkästään energiakustannusten alentamiseen käyttäen energian hinnan ja energiankulutuksen ennustamiseen ANN:ia (Artificial Neural Network) eli neuroverkkoja ja optimointiin matemaattista algoritmia, joka käyttää ANN:in tuottamia ennustuksia parametreina. Tarkoituksena heillä on toteuttaa tehokasta energianhallintaa suunnittelemalla asuinrakennusten energiankäyttöprofiili ennakoitun energian hinnoittelun mukaisesti. Alduailij, Petri, Rana ja Aldawood (2021) tutkimuksessaan taas tekevät laajempaa tutkimusta viidestä eri data-analytiikan menetelmästä analysoimalla ympäristöä, josta ennustetaan seuraavan päivän energian-

kulutusta. Tarkoituksena heillä on tuottaa luotettavaa ennustetta korkean energiankulutuksen tunneista sekä erottaa ne tunnit kysyntäpiikkien tunneista.

Jo, Kim ja Joo (2013) ovat pyrkineet samaan tulokseen kuin Hafeez ym. (2020) sekä Alduailij ym. (2021), mutta he käyttävät parametreina rakennuksen historiallista dataa, kuten sisälämpötilan kapasiteettia ja lämpöenergian hävikkiä. Lisäksi he analysoivat sähkön hintadataa, jotta he saavat ilmaston ja lämmityksen toimimaan mahdollisimman optimaalisesti. Kaikilla ratkaisulla (Hafeez ym., 2020, Alduailij ym., 2021, Jo ym., 2013) on yhteisenä intressinä tuottaa ympäristön analysoimisella energiakustannuksissa säästöjä. Alduailij ym. (2021) ratkaisu eroaa Hafeezin ym. (2020) ja Jon ym. (2013) tutkimuksista siten, että he keskittyvät tarkimman mallin löytämiseen, joka on lopulta ARIMA, kun taas muut raportoivat energiakustannusten säästöistä. Hafeez ym. (2020) onnistuvat ANN:illa vähentämään PAR:ia jopa 47,05 % ja energiakustannuksia 23,9 % verrattuna muihin tutkimuksissa esiteltyihin tekoälypohjaisiin algoritmeihin. Jo ym. (2013) onnistuvat säästämään ilmaston ja lämmityksen energiakustannuksista asteittain 28–36 % laitteiston normaaliin toimintaan verrattuna.

### **4.3 Data-analytiikka ympäristökuorman vähentämisen näkökulmasta**

Ympäristökuorman näkökulmasta data-analytiikka voi tuoda myös uusia ulottuvuuksia energiatehokkuudelle esimerkiksi uusiutuvien luonnonvarojen käytämisen kautta. Aurinkopaneelien osalta valmistustekniikka on parantunut, ja siksi myös aurinkopaneelien hinnat ovat laskeneet ja kannattavuus on parantunut (Tekniikan Maailma, 2018). Kun yhdistetään data-analytiikkaa ja uusiutuvia luonnonvaroja, voidaan kulutusta ohjata kysyntäpiikeiltä esimerkiksi aurinkosähkön tunneille tai varastoida energiaa kysyntäpiikeille (Huang ym., 2018). Lisäksi data-analytiikan keinoilla voidaan suunnitella kestävämpiä ja energiatehokkaampia rakennuksia (Chaganti ym., 2022).

Chaganti ym. (2022) artikkelissaan pyrkivät energiankulutuksen optimoinnin lisäksi vähentämään myös uusien rakennusten ympäristökuormaa. 3RF mallia voidaan siis myös hyvin soveltaa kestävämpien rakennusten suunnitteluun. Constantinou ym. (2022) keskittyvät tutkimuksessaan hiilijalanjäljen vähentämiseen energiankulutuksen vähentämisen lisäksi. Chagantin ym. (2022) ja Constantinoun ym. (2022) tutkimuksissa analysoidaan data-analytiikan avulla laitteistoon liittyvää energiahukan hallintaa. Kun lämmitys- ja jäähdytystarvetta ennustetaan rakennusdatasta, voidaan huomattavasti vähentää energiankulutuksen lisäksi myös tarvetta tulevaisuudessa isommalle tai pienemmälle LVI-laitteistolle (Chaganti ym., 2022). Tekoälypohjaisella GP-algoritmillä voidaan ennustaa energian hävikkiä alueista ja laitteistosta. Sitä hyödyntämällä on jo saavutettu jopa 45–59 % alemmat hiilidioksidipäästöt rakennuksissa erilaisia tilanteita simuloimalla (Constantinou ym., 2022).

Morteza ym. (2021) sekä Huang ym. (2018) ovat dataa analysoimalla pyrkineet aikataulutamaan reaaliaikaisesti uusiutuvien luonnonvarojen käyttöä. Myös Alduailij ym. (2021) tutkimuksessaan ovat pyrkineet samaan mutta he loivat mallin toimimaan päivää etukäteen. Nämä kolme tutkimusta pyrkivät samaan lopputulokseen, eli uusiutuvien luonnonvarojen maksimaaliseen hyödyntämiseen ympäristöissä. Päivää ennen rakennettu malli on erittäin hyvä siitä, että jos asiat menevät sääennusteen puolesta onnistuneesti, saadaan myös todella hyvä malli uusiutuvien luonnonvarojen optimaaliselle hyödyntämiselle (Alduailij ym., 2021). Ilmatieteen laitoksen (2023) mukaan ennustetta on vaikea tuottaa tietyissä tilanteissa, kuten matalapaineen aikana, mutta silti vuodenajasta ja säätyypistä riippuen ennusteet ovat 80–95 % oikeassa 2,5 asteen tarkkuudella. Reaaliaikainen aikataulutaminen ei ole niin tehokasta, koska optimaalista asetusta rakennetaan samalla, kun energiaa käytetään, milloin on mahdollista, että osa uusiutuvasta energiasta valuu hukkaan (Huang ym., 2018; Morteza ym., 2021). Aurinkoenergian ongelma on luonnollisesti energiantuotannon riippuminen säätilasta. Tähän ongelmaan ratkaisua ovat kehittäneet Huang ym. (2018). Heidän ratkaisussaan neuroverkoilla analysoidaan saatavilla olevan hintadatan kanssa tilanteita. Esimerkiksi analysoidaan, onko kannattavampaa erittäin kuormittavana päivänä ladata akustoa aurinkoenergialla vai säästää aurinkoenergia kodin toimilaitteisiin ja ladata akusto yöllä halvalla sähköllä seuraavaa päivää varten. Morteza ym. (2021) ovat tutkimuksessaan hyödyntäneet aurinkoenergian lisäksi myös tuulienergiaa, jota käytetään ensisijaisesti ympäristön sähkönkulutuksen ylläpitoon.

Saba ym. (2022) puolestaan ovat tutkimuksessaan energiankulutuksen vähentämisen lisäksi onnistuneet vähentämään ympäristökuormaa. Tutkimuksessaan he käyttivät älykkäässä kodissa IRRHEM-järjestelmää, joka on manuaalisesti säädettävissä. Monessa muussa tutkimuksessa aurinkokennot ovat tuottaneet sähköä käyttäjälleen. Saban ym. (2022) tutkimuksessa ympäristön säästämistä tehdään datapohjaisella sälekaihtimien ohjauksella. Esimerkiksi, jos talossa on viileä ilma ja aurinko paistaa ulkona, sähköiset kaihtimet voidaan avata sovelluksen ehdotuksesta, jolloin auringonpaiste lämmittää sisätiloja ja sama toimii myös toisinpäin.



## 5 POHDINTA

Tutkimuksen aineiston haku- ja lajitteluprosessin perusteella voidaan todeta, että data-analytiikan hyödyntäminen energiankulutuksen optimoinnissa on vielä alkutekijöissään. Aihe on tullut ajankohtaiseksi vasta, kun ympäristö- ja kustannusasioihin on alettu etsimään ratkaisuja. Kirjallisuuden hakuprosessissa onkin huomattavissa nouseva trendi. Näin ollen suurin osa tutkimuksessani käytetystä kirjallisuudesta sijoittuu 2020-luvulle. Julkaisuissa esiintyy tieteellisen kontribuution osalta enimmäkseen työkaluja esitteleviä tutkimuksia, joissa käsitellään usein vain tietyn alueen optimointia, kuten LVI-laitteiston tai valaistuksen optimointia. Energiankulutuksen vähentäminen data-analytiikan keinoilla nousee valitsemassani kirjallisuudessa eniten esille. Energiankulutuksen vähentäminen onkin yksinkertaisin keino optimoida energiankulutusta verrattuna esimerkiksi muuttuvan sähkön hinnan kanssa pelailuun, mikä vaatisi syvempää analyysiä. Lisäksi data-analytiikan keinoilla saavutetaan energiankulutuksessa merkittäviä säästöjä jo vanhemmissakin tutkimuksissa ja aihe on ollut hyvin ajankohtainen viime vuosina, mitkä voivat vaikuttaa energiankulutuksen vähentämiseen keskittyneiden tutkimusten suosioon. Julkaisuista suurin osa käsittelee myös tiettyä data-analytiikan osa-aluetta ongelmien ratkaisemiseen. Näistä useimmin esiintyvät koneoppimisen menetelmät, joilla käsitellään useasta lähteestä tuleva data ja opetellaan esimerkiksi asuinrakennuksen energiankulutusta. Toisaalta käytettyä menetelmää useissa tutkimuksissa verrataan muihin älykkäisiin ratkaisuihin, jotta menetelmän edut ja haitat olisivat paremmin esillä. Lisäksi myös lähes jokaisessa tutkimuksessa hyödynnetään IoT-laitteita tai -sensoreita, jolla tieto saadaan sulavasti siirtymään.

Tutkielmassa kartoitetaan monia data-analytiikan metodeja ja niiden hyödyntämistä energiankulutuksen optimoinnissa älykkäissä ympäristöissä. Aihe on ajankohtainen ja tärkeä tulevaisuuden kannalta, joten tutkimuksen merkitys tieteelle voidaan nähdä aiheen tärkeyden esiin nostamisena. Toisena merkityksenä voidaan nähdä myös asian tuominen ihmisten tietoisuuteen hyvän yleiskuvan tarjoamisella aiheesta. Nämä merkitykset voidaan nähdä hyötynä niin kuluttajille kuin yrityksillekin, kun he pohtivat esimerkiksi omaa ekologista jalanjälkeään tai kulujen vähentämistä. Tietämyksen lisääminen aiheesta tietä-

mättömälle on suuri askel tulevaisuutta kohti, kun kohderyhmä alkaa pohtia oman ympäristönsä energijärjestelmien uusimista tai esimerkiksi uuden mahdollisen energiadirektiivin noudattamista, kuten Baptiste, Ojamo ja Saloranta (2023) tiedotteessaan mainitsevat. Ohjelmistoalan yrityksille tutkielma voi tuoda myös kiinnostuksen kehittää valmiita data-analytiikan paketteja energijärjestelmien lisäosiksi. Trendien tunnistaminen on myös tutkijoille hyödyksi, sillä niiden avulla voidaan kohdistaa omien tutkimusten aihealueet. Tuloksista selviää hyvin mitä tutkittiin ja millä menetelmillä. Näin voidaan tunnistaa esimerkiksi vähäiselle tutkimukselle jääneet aihealueet, joilla kuitenkin voisi olla potentiaalia tulevaisuuden tutkimuksessa.

Tutkimuksen laadun arvioimisen pohjana on käytetty Okolin ja Schabramin (2010) laatimaa systemaattisen kirjallisuuskatsauksen ohjenuoraa. Ohjenuora sisältää tutkimuksen vaiheet: tarkoituksen kartoittaminen, protokollan noudattaminen, kirjallisuuden hakeminen, seulonnat aineistolle, laadun arviointi, tiedonkeruu, tietojen analysointi ja katsauksen kirjoittaminen. Tarkoituksen kartoittaminen tutkimuksessa on onnistunut hyvin, koska aihe on erittäin ajankohtainen niin energiamarkkinoiden, ympäristöasioidenkin kuin data-analytiikankin osalta. Myös tietoa hakiessa ei vastaan tullut data-analytiikan hyödyntämistä energiankulutuksen optimoinnissa käsitteleviä kirjallisuuskatsauksia suomeksi kirjoitettuna. Lisäksi tutkimuskysymys vastaa hyvin tutkielman tavoitteeseen eli luoda hyvä yleiskuva data-analytiikasta energiankulutuksen optimoinnissa älykkäissä ympäristöissä. Tutkimuksen yksi vahvuuksista on hakulauseke, jolla on onnistuttu rajaamaan tutkimukset sopivan kokoiseksi otokseksi. Toisaalta haku olisi voinut olla osittain laajempi, jotta sopivia tutkimuksia olisi voinut löytyä vielä enemmän. Tulokset ovat kuitenkin riittäviä kandidaatin tutkielman laajuuteen nähden. Aineiston seulonnan osalta ongelma voi olla se, että tässä tutkimuksessa on vain yksi tutkija, mikä voi johtaa tiettyyn puolueellisuuteen julkaisujen valinnassa. Kuitenkin tutkimuksessa on pyritty vähentämään puolueellisuutta siten, että jos otsikkotasolla tai tiivistelmässä on ilmennyt jotain aiheeseen liittyvää, on tutkimus valittu seuraavaan tarkasteluun. Lisäksi tutkijan kokemattomuus on voinut vaikuttaa tutkimuksen laatuun niin aineiston seulonnassa kuin tulostenkin analysoinnissa.

Tulevaisuuden kannalta olisi mielenkiintoista nähdä tapauksia, joissa otetaan monesta tutkimuksesta parhaita menetelmiä ja yhdistetään niitä. Tämänkaltaiset kokonaisvaltaiset ratkaisut, joissa on esimerkiksi data-analytiikan keinoilla rakennettu mahdollisimman energiatehokas rakennus ja yhdistetty vielä energiankulutusta optimoivaa analytiikkaa, voisivat vähentää perinteisiin rakennuksiin verrattuna huomattavan paljon energiankulutusta. Baptiste ym. (2023) tiedotteessaan mainitsee, että vanhoja rakennuksia joudutaan mahdollisesti uuden energiadirektiivin mukaan muuttamaan energiatehokkaammiksi. Tällöin on mielenkiintoista nähdä, miten data-analytiikalla varustettu energiannahallinta voidaan tuoda osaksi vanhaa rakennustekniikkaa. Jatkotutkimusaiheena olisikin mielenkiintoista soveltaa data-analytiikkaa energiankulutuksessa vanhoissa rakennuksissa ja nähdä, saataisiinko data-analytiikan keinoilla parannettua energiatehokkuutta direktiivin mukaiselle tasolle. Lisäksi olisi mie-

lenkiintoista tutkia data-analytiikan soveltamista esimerkiksi Pohjoismaissa, joissa lämpötilan vaihtelut ovat suurempia kuin tutkimuksessani esiintyvät tapaukset, ja nähdä, miten ja kuinka paljon data-analytiikan keinoilla saadaan energiatehokkuutta parannettua.

## 6 YHTEENVETO

Maailmantilanteen muuttumisen seurauksena mediassa on ollut puhetta energiakriisistä ja ympäristökriisin ehkäisemisestä. Data-analytiikalla voidaan löytää ratkaisuja näihin ongelmiin energiankulutuksen optimoinnin kautta. Tämä tutkielma keskittyy tutkimaan data-analytiikan hyödyntämistä energiankulutuksen optimoinnissa älykkäissä ympäristöissä kolmesta eri näkökulmasta, jotka ovat energiankulutuksen, energiakustannusten ja ympäristökuorman vähentäminen. Tutkielman tarkoitus on tuoda lukijalle yleiskuva siitä, miten data-analytiikalla sekä pienillä investoinneilla voidaan vähentää huomattavasti energiankulutusta, energiakustannuksia sekä ympäristövahinkoja.

Tutkimus toteutettiin systemaattisena kirjallisuuskatsauksena Okolin ja Schabramin (2010) ohjeiden pohjalta. Systemaattinen prosessi aloitettiin kirjallisuuden hakemisesta, jonka jälkeen tehtiin aineiston seulonta ja laadun arviointi. Tutkimuksen yksi vahvuuksista onkin onnistunut hakulauseke, jolla saatiin rajattua kirjallisuus sopivan kokoiseksi otokseksi kandidaatintutkielman laajuuteen nähden. Toisaalta hakulauseketta muuttamalla olisi voinut löytyä aineistoa enemmän. Tutkielman merkitys tieteelle voidaan nähdä siten, että tämä ajankohtainen ja tärkeä aihe tuodaan esiin lukijoille ymmärrettävässä muodossa. Tämän pohjalta jokainen voi pohtia omaa energiankulutustaan ja ympäristökuormaa sekä niiden vähentämistä.

Tutkielmaan valikoiduissa tutkimuksissa data-analytiikan hyödyntämisessä suuressa roolissa olivat IoT-sensorit ja -laitteet, keskitetyt energianhallintajärjestelmät sekä tarpeeksi tehokkaat työkalut. Näiden avulla data saatiin liikkumaan eri kerrosten välillä ja analyysit tehtyä onnistuneesti. Tutkielmassa pyrittiin vastaamaan tutkimuskysymykseen ”Miten data-analytiikkaa hyödynnetään energiankulutuksen optimoinnissa älykkäissä ympäristöissä?”. Tuloksista ilmeni monta tapaa, miten data-analytiikkaa hyödynnetään energiankulutuksen optimoinnissa älykkäissä ympäristöissä energiankulutuksen, energiakustannusten ja ympäristökuorman vähentämisen näkökulmasta. Energiankulutusta optimoitiin usein LVI-laitteista, jotka kuluttavat suurimman osan ympäristön energiasta. Optimointi tapahtui usein

siten, että esimerkiksi ilmaston jatkuvan 1-vaiheisen puhaltamisen sijaan, vaihdeltiin tehoja ja sammuteltiin laitetta ympäristön datan pohjalta. Energiakustannusten optimointi tapahtui aikatauluttamalla datan pohjalta ympäristön laitteiden käyttäytymistä. Esimerkiksi tilanteissa, joissa sähkön hinta oli korkeimmillaan, pyrittiin vähentämään ja poistamaan automaattisesti energiaa kuluttavia toimintoja ajanhetkellä. Lisäksi kalleimmille tunneille voitiin automaattisesti hyödyntää akkuvarastojen varauksia laitteiden ylläpitoon. Ympäristökuorman optimointi taas toteutettiin uusiutuvien luonnonvarojen avulla. Data-analytiikkaa sovellettiin esimerkiksi aurinkoenergian hallintaan, jotta siitä saataisiin energiaa mahdollisimman paljon käyttöön mahdollisimman järkevästi.

Data-analytiikkaa sovellettiin usein koneoppimisen metodeilla, sillä niiden todettiin olevan tehokkaimpia massiivisen datamäärän analysoinnissa. Tutkimuksissa dataa kerättiin ympäristön muuttujista. Useimmiten muuttujat olivat sisä- ja ulkolämpötila, kosteus, energiankulutus, ilmanlaatu ja energian tuotto. Ulkoisista lähteistä dataa kerättiin useimmiten pörssisähkön hintasignaalista ja sääennusteista. Näitä muuttujia analysoimalla ja ennustamalla osattiin ennustaa todennäköisimmin energiaa säästävin, energiakustannustehokkain ja mahdollisimman paljon uusiutuvia luonnonvaroja käyttävä malli.

Otsikoissa on pyörinyt lähiaikoina EU:n julkaisema uusi rakennusten energiadirektiivi. Asetus uhkaa samalla monta suomalaista kotitaloutta muuttamaan oma asuntonsa ajan tasalle. Jatkotutkimusaiheena olisikin mielenkiintoista tutkia, saisiko data-analytiikan keinoilla nostettua energiatehokkuutta EU:n uuden direktiivin tasolle vanhemmissa rakennuksissa. Lisäksi lähes kaikkien tutkimuksen julkaisujen testiympäristöt olivat aika kaukana pohjoisista olosuhteista. Tästä syystä lämpötilanvaihtelut eivät olleet monessa tapauksessa niin suuria tai ne liittyivät pelkästään jäähdytystehon säätelyyn. Olisikin mielenkiintoista tutkia, kuinka hyvin data-analytiikan menetelmät soveltuvat esimerkiksi Suomen olosuhteisiin. Tällöin voitaisiin ottaa tarkemmin huomioon jyrkemmät lämpötilanvaihtelut ja metodeja hyödyntää myös lämmitystehon optimoimiseen.

## LÄHTEET

- Aguilar, J., Garcès-Jiménez, A., Gallego-Salvador, N., De Mesa, J. A. G., Gomez-Pulido, J. M. & García-Tejedor, À. J. (2019). Autonomic Management Architecture for Multi-HVAC Systems in Smart Buildings. *IEEE Access*, 7, 123402–123415. <https://doi.org/10.1109/ACCESS.2019.2937639>
- Alduailij, M. A., Petri, I., Rana, O. & Aldawood, A. S. (2021). Forecasting peak energy demand for smart buildings. *The Journal of Supercomputing*, 77(6), 6356–6380. ProQuest Central; SciTech Premium Collection. <https://doi.org/10.1007/s11227-020-03540-3>
- Auffenberg, F., Snow, S., Stein, S. & Rogers, A. (2017). A Comfort-Based Approach to Smart Heating and Air Conditioning. *ACM Trans. Intell. Syst. Technol.*, 9(3). <https://doi.org/10.1145/3057730>
- Avci, M., Erkoç, M., Rahmani, A. & Asfour, S. (2013). Model predictive HVAC load control in buildings using real-time electricity pricing. *Energy and Buildings*, 60, 199–209. <https://doi.org/10.1016/j.enbuild.2013.01.008>
- Baptiste, C., Ojamo, J., Saloranta, N. (2023, 14.maaliskuuta) Rakennusten energiatehokkuus: EU-parlamentti hyväksyi kantansa. Haettu 6.4.2023. <https://www.europarl.europa.eu/news/fi/press-room/20230310IPR77228/rakennusten-energiatehokkuus-eu-parlamentti-hyvaksyi-kantansa>
- Benavente-Peces, C. (2019). On the Energy Efficiency in the Next Generation of Smart Buildings—Supporting Technologies and Techniques. *Energies*, 12(22). ProQuest Central; Publicly Available Content Database; SciTech Premium Collection. <https://doi.org/10.3390/en12224399>
- Chaganti, R., Furqan Rustam, Daghri, T., Isabel de la Torre Díez, Vidal Mazón, J. L., Carmen Lili Rodríguez, & Imran Ashraf. (2022). Building Heating and Cooling Load Prediction Using Ensemble Machine Learning Model. *Sensors*, 22(19), 7692. ProQuest Central; Publicly Available Content Database; SciTech Premium Collection. <https://doi.org/10.3390/s22197692>
- Chou, J. S. & Ngo, N. T. (2016). Smart grid data analytics framework for increasing energy savings in residential buildings. *Automation in Construction*, 72, 247–257. <https://doi.org/10.1016/j.autcon.2016.01.002>

- Constantinou, S., Konstantinidis, A., Chrysanthis, P. K. & Zeinalipour-Yazti, D. (2022). Green Planning of IoT Home Automation Workflows in Smart Buildings. *ACM Trans. Internet Things*, 3(4). <https://doi.org/10.1145/3549549>
- Council of the European Union (2022). Infographic - Energy crisis: Three EU-coordinated measures to cut down bills. Haettu 26.04.2023. <https://www.consilium.europa.eu/en/infographics/eu-measures-to-cut-down-energy-bills/>
- Dhowmya, B., Danalakshmi, D., Hariharasudan, A., Marcin, L. & Marlana, G. (2021). Forecasting of Energy Demands for Smart Home Applications. *Energies*, 14(4), 1045. ProQuest Central; Publicly Available Content Database; SciTech Premium Collection. <https://doi.org/10.3390/en14041045>
- Duan, L. & Da Xu, L. (2021). Data Analytics in Industry 4.0: A Survey. *Information Systems Frontiers*. <https://doi.org/10.1007/s10796-021-10190-0>
- Hafeez, G., Alimgeer, K. S., Wadud, Z., Khan, I., Usman, M., Qazi, A. B. & Khan F. A. (2020). An Innovative Optimization Strategy for Efficient Energy Management With Day-Ahead Demand Response Signal and Energy Consumption Forecasting in Smart Grid Using Artificial Neural Network. *IEEE Access*, 8, 84415–84433. <https://doi.org/10.1109/ACCESS.2020.2989316>
- Hajjaji, Y., Boulila, W., Farah, I. R., Romdhani, I. & Hussain, A. (2021). Big data and IoT-based applications in smart environments: A systematic review. *Computer Science Review*, 39, 100318. <https://doi.org/10.1016/j.cosrev.2020.100318>
- Huang, H., Xu, H., Cai, Y., Khalid, R. S. & Yu, H. (2018). Distributed Machine Learning on Smart-Gateway Network toward Real-Time Smart-Grid Energy Management with Behavior Cognition. *ACM Trans. Des. Autom. Electron. Syst.*, 23(5). <https://doi.org/10.1145/3209888>
- Ilmatieteenlaitos (2023, 15. Huhtikuuta). Säätilan ennustettavuus seuraavan 5 vuorokauden aikana. Haettu 15.4.2023. <https://www.ilmatieteenlaitos.fi/saatilan-ennustettavuus>
- Jo, H. C., Kim, S. & Joo S. K. (2013). Smart heating and air conditioning scheduling method incorporating customer convenience for home energy management system. *IEEE Transactions on Consumer Electronics*, 59(2), 316–322. <https://doi.org/10.1109/TCE.2013.6531112>

- Khalid, A., Javaid, N., Guizani, M., Alhussein, M., Aurangzeb, K. & Ilahi, M. (2018). Towards Dynamic Coordination Among Home Appliances Using Multi-Objective Energy Optimization for Demand Side Management in Smart Buildings. *IEEE Access*, 6, 19509–19529. <https://doi.org/10.1109/ACCESS.2018.2791546>
- Khamesi, A. R., Silvestri, S., Baker, D. A. & Paola, A. D. (2020). Perceived-Value-Driven Optimization of Energy Consumption in Smart Homes. *ACM Trans. Internet Things*, 1(2). <https://doi.org/10.1145/3375801>
- Lee, S. (2019). Reinforcement Learning-Based Energy Management of Smart Home with Rooftop Solar Photovoltaic System, Energy Storage System, and Home Appliances. *Sensors*, 19(18), 3937. ProQuest Central; Publicly Available Content Database; SciTech Premium Collection. <https://doi.org/10.3390/s19183937>
- Lee, S. & Choi, D-H. (2020). Energy Management of Smart Home with Home Appliances, Energy Storage System and Electric Vehicle: A Hierarchical Deep Reinforcement Learning Approach. *Sensors*, 20(7), 2157. ProQuest Central; Publicly Available Content Database; SciTech Premium Collection. <https://doi.org/10.3390/s20072157>
- Morteza, A. N., Zand, M., Eskandari, M., Padmanaban, S. & Siano, P. (2021). Optimal Planning of Electrical Appliance of Residential Units in a Smart Home Network Using Cloud Services. *Smart Cities*, 4(3), 1173. ProQuest Central; Publicly Available Content Database; SciTech Premium Collection. <https://doi.org/10.3390/smartcities4030063>
- Nagy, Z., Yong, F. Y., Frei, M. & Schlueter, A. (2015). Occupant centered lighting control for comfort and energy efficient building operation. *Energy and Buildings*, 94, 100–108. <https://doi.org/10.1016/j.enbuild.2015.02.053>
- Nasr, J., Eckert, V., Escritt, T. & Hummel, T. (2022, 4. Huhtikuuta). Germany resists EU ban on Russia gas as bloc prepares new sanctions. Haettu 6.4.2023. <https://www.reuters.com/world/europe/germany-moving-step-by-step-toward-russian-energy-embargo-habeck-2022-04-04/>
- Nugent, C. D., McClean, S. I., Cleland, I. & Burns, W. (2014). Sensor Technology for a Safe and Smart Living Environment for the Aged and Infirm at Home. *Comprehensive Materials Processing* (s. 459–472). Elsevier. <https://doi.org/10.1016/B978-0-08-096532-1.01319-4>



- Okoli, C. & Schabram, K. (2010) A Guide to Conducting a Systematic Literature Review of Information Systems Research. <http://dx.doi.org/10.2139/ssrn.1954824>
- Park, S., Park, S., Choi, M., Lee, S., Lee, T., Kim, S., Cho, K. & Park, S. (2020). Reinforcement Learning-Based BEMS Architecture for Energy Usage Optimization. *Sensors*, 20(17), 4918. ProQuest Central; Publicly Available Content Database; SciTech Premium Collection. <https://doi.org/10.3390/s20174918>
- Peña, M., Biscarri, F., Personal, E. & León, C. (2022). Decision Support System to Classify and Optimize the Energy Efficiency in Smart Buildings: A Data Analytics Approach. *Sensors*, 22(4), 1380. ProQuest Central; Publicly Available Content Database; SciTech Premium Collection. <https://doi.org/10.3390/s22041380>
- Rasheed, M. B., Javaid, N., Malik, M. S. A., Asif, M., Hanif, M. K., & Chaudary, M. H. (2019). Intelligent Multi-Agent Based Multilayered Control System for Opportunistic Load Scheduling in Smart Buildings. *IEEE Access*, 7, 23990–24006. <https://doi.org/10.1109/ACCESS.2019.2900049>
- Runkler, T. A. (2016). *Data Analytics*. Springer Fachmedien Wiesbaden. <https://doi.org/10.1007/978-3-658-14075-5>
- Saba, D., Cheikhrouhou, O., Alhakami, W., Sahli, Y., Hadidi, A. & Hamam, H. (2022). Intelligent Reasoning Rules for Home Energy Management (IRRHEM): Algeria Case Study. *Applied Sciences*, 12(4), 1861. ProQuest Central; Publicly Available Content Database; SciTech Premium Collection. <https://doi.org/10.3390/app12041861>
- Shafqat, W., Kyu-Tae, L. & Do-Hyeun, K. (2023). A Comprehensive Predictive-Learning Framework for Optimal Scheduling and Control of Smart Home Appliances Based on User and Appliance Classification. *Sensors*, 23(1), 127. ProQuest Central; Publicly Available Content Database; SciTech Premium Collection. <https://doi.org/10.3390/s23010127>
- Shah, A. S., Nasir, H., Fayaz, M., Lajis, A., Ullah, I. & Shah A. (2020). Dynamic User Preference Parameters Selection and Energy Consumption Optimization for Smart Homes Using Deep Extreme Learning Machine and Bat Algorithm. *IEEE Access*, 8, 204744–204762. <https://doi.org/10.1109/ACCESS.2020.3037081>
- Tekniikan Maaailma, Rakennusmaailma (2018). Vertaile aurinkosähköjärjestelmiä: Säästöä jopa tuhansia euroja. Haettu 12.3.2023.

<https://rakennusmaailma.fi/vertaile-aurinkosahkojarjestelmia-saastojopa-tuhansia-euroja/>

- Tundis, A., Ali, F. & Mühlhäuser, M. (2019). A Feature-Based Model for the Identification of Electrical Devices in Smart Environments. *Sensors*, 19(11). ProQuest Central; Publicly Available Content Database; SciTech Premium Collection. <https://doi.org/10.3390/s19112611>
- Ullah, I. & Kim, D. (2017). An Improved Optimization Function for Maximizing User Comfort with Minimum Energy Consumption in Smart Homes. *Energies*, 10(11). <https://doi.org/10.3390/en10111818>
- Vargas-Solar, G., Khalil, M., Espinosa-Oviedo, J. A. & Zechinelli-Martini, J.-L. (2022). GREENHOME: A Household Energy Consumption and CO2 Footprint Metering Environment. *ACM Trans. Internet Technol.*, 22(3). <https://doi.org/10.1145/3505264>