

**Laitteiden tunnistus mittausdatasta**  
**Appliance identification from measurement data**

Jere Knuutinen

# TIIVISTELMÄ

Lappeenrannan-Lahden teknillinen yliopisto

LUT School of Energy Systems

Sähkötekniikka

Jere Knuutinen

## **Laitteiden tunnistus mittausdatasta**

2020

Kandidaatintyö.

31 s.

Tarkastaja: Tutkijaopettaja Antti Kosonen

Työ on kirjallisuuskatsaus siitä, kuinka laitteita voidaan tunnistaa sähkömittausdatasta. Työ keskittyy erityisesti NILM-järjestelmiin. NILM-järjestelmällä tarkoitetaan ei-intrusiivista laitteiden sähkökulutuksen seurantajärjestelmää eli järjestelmää, jossa sähkökulutusta mitataan vain yhdestä keskitetystä paikasta. Kiinnostus NILM-järjestelmiä kohtaan on viime aikoina noussut mittaustekniikan, tiedonsiirron ja tekoälyn kehityksen takia.

Työssä tuodaan esille tällaisen järjestelmän yleinen toimintaperiaate ja selvitetään erilaisia piirteitä, joiden avulla laitteet on mahdollista tunnistaa. Lisäksi luodaan pieni katsaus tulevaisuuden mahdollisuuksiin, joita NILM-järjestelmä voi tarjota sekä esitellään syitä siihen miksi ei-intrusiivinen laitteiden sähkökulutuksen seuranta ei ole yleistynyt kotitalouksissa.

## **ABSTRACT**

Lappeenranta-Lahti University of Technology  
LUT School of Energy Systems  
Electrical Engineering

Jere Knuutinen

### **Appliance identification from measurement data**

2020

Bachelor's Thesis.

31 p.

Examiner: Associate professor Antti Kosonen

This work is a literature review on how to identify appliances from aggregated electric data. Work focuses on NILM-systems. NILM-system refers to non-intrusive load monitoring system where the power consumption is only measured from a single point. Interest in NILM systems has recently risen due to the development of measurement technology, data transfer and artificial intelligence.

The work introduces the general principles of such a system and explores the various features by which the devices can be identified. In addition, brief insight into the future opportunities that the NILM-system has to offer and the reasons why non-intrusive load monitoring has not become common in households will be provided.

## SISÄLLYSLUETTELO

1.	Johdanto.....	6
2.	Tausta .....	7
3.	NILM.....	9
3.1	NILM kuormien erittelyongelmana.....	9
3.2	Laitekategoriat .....	10
3.2.1	Laiteluokittelu toimitilojen perusteella.....	10
3.2.2	Tehonkulutuksen perusteella luokittelu.....	12
3.3	Tiedonkeruu.....	14
3.3.1	Matalan taajuuden mittarit.....	14
3.3.2	Korkean taajuuden mittarit .....	14
3.4	Tapahtuman havaitseminen ja piirteiden erottaminen.....	15
3.4.1	Laitteiden jatkuvaa tilaa analysoivat menetelmät.....	15
3.4.2	Laitteen tilan muutosta analysoivat menetelmät .....	18
3.5	Päätely, oppiminen ja luokittelu .....	19
3.5.1	Ohjatun oppimisen lähestymistapa.....	20
4.	Haasteet laitteiden tunnistuksessa .....	22
5.	Mahdollisuudet .....	24
5.1	Eritellyt energialaskut ja yksilölliset energiansäästösuositukset.....	24
5.2	Kulutusjousto.....	24
5.3	Laitteiden seuranta.....	25
6.	yhteenveto.....	26
	Lähteet .....	27
	Liitteet	

## LYHENTEET

TWh	Terawattitunti
ILM	Intrusiivinen sähkökulutuksen seuranta ( <i>engl. Intrusive Load Monitoring</i> )
NILM	Ei-intrusiivinen sähkökulutuksen seuranta ( <i>engl. Nonintrusive Load Monitoring</i> )

## SYMBOLIT

$P(t)$	Kokonaisteho hetkellä $t$
$P_n(t)$	Tehon kulutus yksittäisessä laitteessa hetkellä $t$
$a_n(t)$	$\in \{0,1\}$
$\sigma(t)$	Mittauskohina tai virhetermi hetkellä $t$
$\bar{a}$	Piirrevektori
$x$	Satunnainen instanssi
$d(x_i, x_j)$	Euklidinen etäisyys

## 1. JOHDANTO

Energiansäästö on ollut suosittu tutkimuksen kohde viime vuosikymmeninä ilmastonmuutoksen ja vähentyvien fossiilisten energiavarojen takia. Asuinrakennukset näyttelevät suurta roolia energian kulutuksen vähentämisessä. Suomen kokonaissähkönkulutus vuonna 2018 oli 85,1 TWh ja asuinrakennuksien osuus tästä oli 23 TWh, joten niiden osuus sähkön käytöstä Suomessa oli noin 27% (Tilastokeskus 2018; Energiavirasto 2018). Tämän vuoksi kotitalouksien energiatehokkuuden parantamisella on suuri merkitys tulevaisuudessa energian kokonaiskulutuksen vähentämisessä. Vaikka kotitaloudet olisivat halukkaita vähentämään energian kulutustaan, on yleensä esteenä selvän suunnan ja menetelmien puuttuminen, kuinka energiatehokkuutta voisi parantaa. Tämä johtuu siitä, että tyyppilliset sähkömittarit ja -laskut ilmoittavat sähkön käytön tunnin tarkkuudella, eikä sähkönkulutusta näe reaaliajassa. Tästä syystä on niistä vain vähän hyötyä energiatehokkuutta parantavien menetelmien kehittämisessä. (Berges et al. 2009)

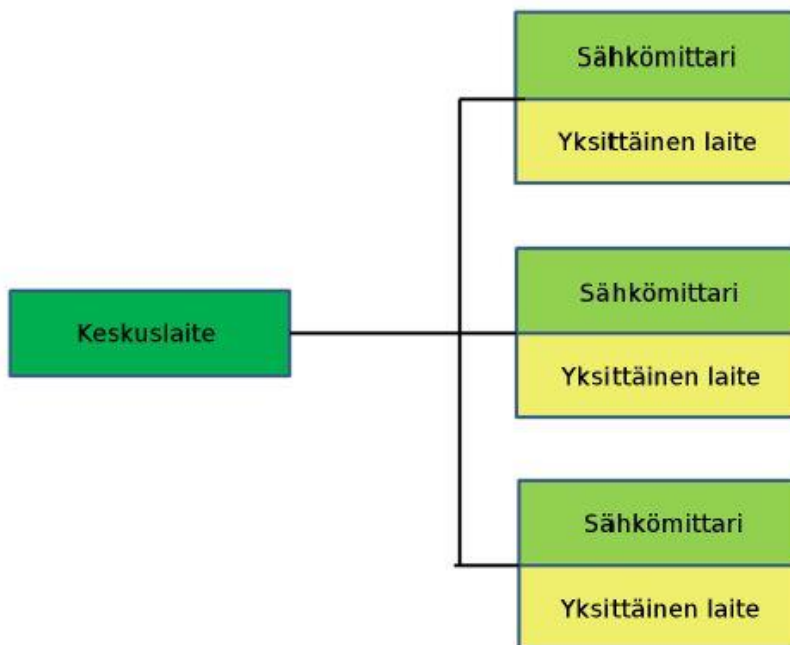
Tutkimuksien mukaan kotitalouksien sähköenergian kulutusta voidaan vähentää 5–15 % kotitalouksissa, jos kodin asukkaalle tarjotaan tietoa sähkönkulutuksesta (Darby 2006). Tilannetta voidaan entisestään parantaa, jos asukkaalle tarjotaan reaaliaikaista laitekohtaista sähkönkulutustietoa (Ford 2009). Ei-intrusiivinen sähkönkulutuksen seurantajärjestelmä (*engl. Non-intrusive load monitoring (NILM)*) on kehitetty tunnistamaan yksittäisten laitteiden sähkönkulutus kotitalouden yhdistetystä sähkönkulutuksesta. NILM-järjestelmässä taloon asennetaan yksi sähkömittari, jonka avulla mitataan asunnon kokonaissähkönkulutusta, ja josta järjestelmä pyrkii samaan selville laitteiden käynnistykset ja sammutukset.

Tämän työn tavoitteena on esitellä NILM-järjestelmän toiminta yleisellä tasolla. Tämän lisäksi työ esittelee NILM-järjestelmän tulevaisuuden mahdollisuuksia sekä tämän hetken haasteita, joita laitteiden tunnistuksessa kohdataan.

## 2. TAUSTA

Laitteiden sähkönkulutuksen seurantajärjestelmän tarkoituksena on tarjota reaaliaikaista sähkön kulutuksen seurantaan jokaisesta kotitalouden laitteesta. Järjestelmä sisältää yhden tai useamman älymittarin, joka mittaa, kerää ja analysoi sähköenergian kulutusta. Tällaisen systeemin idea on vuosikymmeniä vanha, mutta viimeaikainen kehitys mittaustekniikassa, tiedonsiirrossa ja tekoälyssä on saanut aikaan uutta kasvavaa kiinnostusta tällä tutkimusalalla (Zoha et al. 2012).

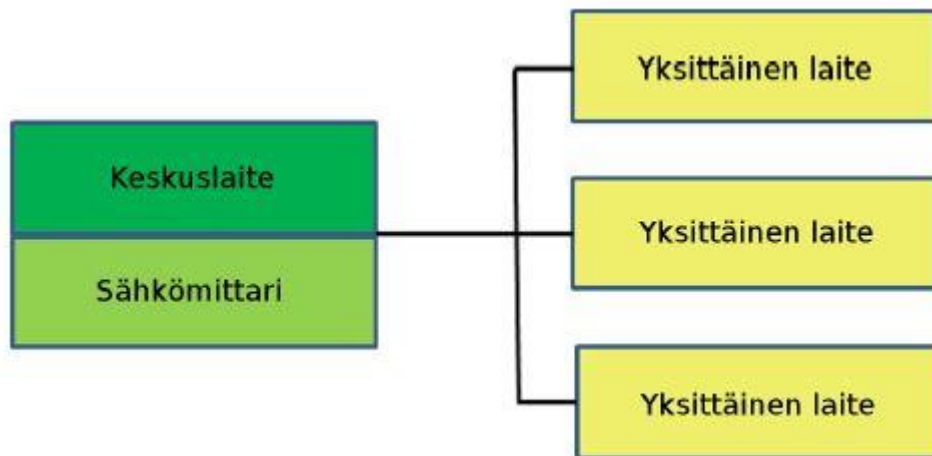
Laitteiden sähkönkulutuksen seurantajärjestelmä voidaan jakaa kahteen eri kategoriaan: intrusiiviseen sähkönkulutuksen seurantaan (*engl. Intrusive Load Monitoring (ILM)*) ja ei-intrusiiviseen sähkönkulutuksen seurantaan (*engl. Non-Intrusive Load Monitoring (NILM)*) (Zoha et al. 2012). Perinteisesti reaaliaikainen laitekohtainen sähkönkulutuksen seuranta on toteutettu ILM menetelmällä asentamalla analysaattoreita jokaiselle laitteelle erikseen (Abubakar et al. 2016). Tämä saa aikaan sen, että järjestelmästä tulee kallis, monimutkainen ja vaikeasti ylläpidettävä (Sharp 1994). Kuva 1 esittää yleisen ILM-järjestelmän rakenteen.



**Kuva 1.** Intrusiivinen kuormien tunnistusjärjestelmä (Pérez 2011)

Edellä mainittujen ongelmien takia yhdeksi vaihtoetoiseksi tavaksi tunnistaa laitteita on kehitetty NILM eli ei-intrusiivinen sähkönkulutuksen seuranta, jonka tavoitteena on arvioida laitekohtaista

sähkönkulutusta kotitaloudessa yhden mittalaitteen avulla. Ei-intrusiivinen NILM:n yhteydessä tarkoittaa sitä, että tunnistaminen ei tapahdu laitekohtaisilla analysointilaitteilla vaan keskitetysti yhdestä paikasta. NILM-järjestelmä vaatii yksikertaisemman laitteiston, mutta monimutkaisemman ohjelmiston verrattuna ILM-järjestelmään (Hart 1992). NILM-järjestelmä mahdollistaa kotitalouksille kustannustehokkaan ratkaisun laitekohtaiseen energiankulutuksen seurantaan (Rastogi 2018). Kuva 2 esittää yleisen NILM-järjestelmän rakenteen. (Makonin 2012)



**Kuva 2.** Ei-intrusiivinen kuormien tunnistusjärjestelmä (Pérez 2011)

Pioneerityö ei-intrusiivisessä kuorman tunnistuksessa tehtiin 1980- ja 1990-luvulla Massachusettsin teknillisessä korkeakoulussa George W. Hartin esitellessä ensimmäisenä NILM-järjestelmän konseptin. Hart huomasi, että rakennusten sähkönkulutukseen liittyvän tiedonkeruun yhteydessä olisi mahdollista saada yksittäisten laitteiden energiankulutus selville koko talon kuormitustiedoista. (Hart 1992)



### 3. NILM


NILM-järjestelmän eli ei-intrusiiiviseen sähkönkulutuksen seurantajärjestelmän tavoitteena on siis eritellä yhdestä älymittarista saatu yhdistetty kuormitusdata laitekohtaisiksi tiedoiksi. Tämä menetelmä on saavuttanut kiinnostusta johtuen viimeaikaisesta älymittareiden laajamittaisesta käyttöönotosta maailmalla (Lua 2015; He et al. 2019).

#### 3.1 NILM kuormien erittelyongelmana

Koska NILM-järjestelmän tavoitteena on eritellä kuormitusdata laitekohtaisiksi tiedoiksi, voidaan tehtävää pitää kuorman erittelyongelmana. Tämä voidaan matemaattisesti muotoilla seuraavalla tavalla: Määrälle  $N$  laitteita, kaikkien aktiivisten laitteiden kuluttama kokonaisteho hetkellä  $t$  voidaan ilmaista,

$$P(t) = \sum_{n=1}^N p_n(t) \cdot a_n + \sigma(t) \quad (1)$$

missä,  $p_n$  on tehon kulutus yksittäisessä laitteessa hetkellä  $t$  ja  $a_n \in \{0,1\}$  on ilmaisu jossa 1 edustaa ”laite on päällä” ja 0 edustaa ”laite on pois päältä”.  $\sigma(t)$  edustaa mittauskohinaa tai pientä virhetermiä. NILM-järjestelmän tehtävä on siis suorittaa  $P(t)$ :n hajotelma laitekohtaisiksi tiedoiksi (Zoha et al. 2012). Kuva 3 havainnollistaa kuinka NILM-järjestelmän tulisi kyetä erottelamaan laitteita mitaussignaalista. (Rastogi 2018)



**Kuva 3.** NILM kuorman erittelynä, (Esa et al. 2016)

Vaikka on olemassa lukuisia eri tapoja lähestyä ongelmaa, koostuvat kaikki NILM-algoritmit päävaiheista, jotka on esitetty kuvassa 4 (Zeifman & Roth 2011; Zoha et al.2011; Abubakar et al. 2017).

Päävaiheet ovat:

1. **Tiedonkeruu:** NILM-systeemin ensimmäinen vaihe on kerätä sähköistä mittaustietoa. Sähköinen mittaustieto, sisältäen virran, jännitteen sekä pätö- ja loistehon, on saatu älymittarilta tai spesifiseltä tähän tarkoitukseen suunnitellulta laitteistolta.
2. **Piirteiden erottaminen:** Erilaiset laitteet tuottavat erilaisia kuormituspiirteitä, joita voidaan käyttää laitteiden erottamiseen toisistaan. Se mitä ominaisuuksia kyetään erottamaan, on hyvin riippuvainen näytteenottotaajuudesta
3. **Luokittelu, päättely ja oppiminen:** Tässä vaiheessa käytetään edellisessä vaiheessa erotettuja ominaisuuksia. Erilaiset käytännön vaatimukset johtavat hyvin erilaisiin algoritmeihin ja tästä syystä NILM-algoritmit voidaan jakaa pääasiassa ohjattuihin ja ohjaamattomiin oppimälähestymistapoihin.



**Kuva 4.** NILM-järjestelmän yleinen toimintaperiaate

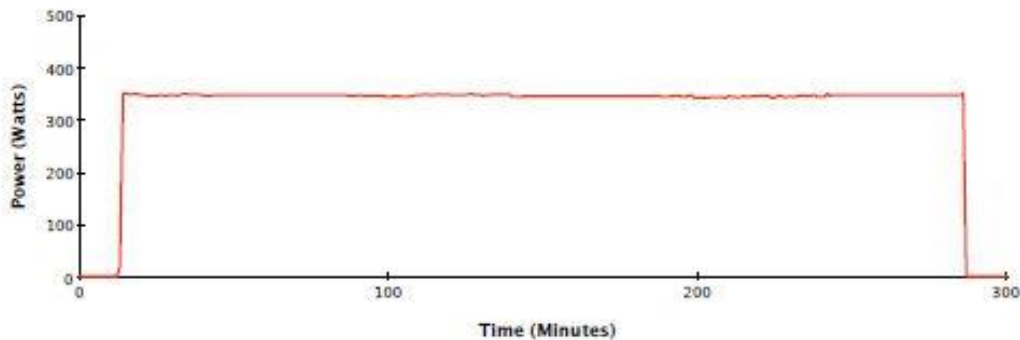
## 3.2 Laitekategoriat

Kotitalouksissa voi esiintyä lukuisia eri tyyllisiä laitteita, joita NILM-järjestelmän tulisi pystyä tunnistamaan. Kotitalouden laitteet voidaan jakaa muutamaankin ryhmään kahdella eri tavalla. Yksi yleinen tapa kategorisoida laitteita NILM:n yhteydessä perustuu laitteiden toimitiloihin (Zoha et al. 2012). Tämä lisäksi laitteet voidaan kategorisoida myös laitteen sähkönkulutuksen perusteella (Baker et al. 2013).

### 3.2.1 Laiteluokittelu toimitilojen perusteella


Laitteet voidaan toimitilojen perusteella luokitella neljään eri tyyppiin (Zeifman and Roth 2011). Neljä eri laitetyyppiä ovat päälle/kiinni laitteet, monessa tilassa toimivat laitteet, aina päällä olevat laitteet ja jatkuvasti muuttuvassa tilassa olevat laitteet. Seuraavaksi käsitellään nämä laitteet yksitellen:

1. **Päälle/kiinni laitteet:** Nämä ovat laitteita, joita on kaikista helpointa havaita ja, jotka toimivat vain kahdella eri toimitilalla. Tämä on hyvä malli isolle osalle kotitalouden laitteita (Makonin 2011; Hart 1992). Tällaisia laitteita ovat esimerkiksi hehkulamput, leivänpaahdin ja vedenkeitin. Kun laitteet ovat päällä tämän tyylliset laitteet kuluttavat vain kiinteän arvon verran pätö- tai loistehoa (Rastogi 2018). Kuva 5 antaa esimerkin päälle/kiinni tyyppisestä laitteesta.




**Kuva 5.** Esimerkki Päälle/pois tyyppisestä laitteesta (Makonin 2012).

2. **Monessa tilassa toimivat laitteet:** Nämä ovat laitteita, jotka kykenevät siirtymään lukuisien eri toimitilojen välillä. Tähän laitekategoriaan kuuluvia laitteita ovat esimerkiksi pesukone ja uuni. Jokaisella eri tilalla on spesifinen tehonkulutus ja toistettava siirtymämalli näiden tilojen välillä, joka helpottaa erittelyalgoritmia tunnistamaan niiden operaatioita. Kuvassa 6 on kuvattu jääkaapin käyttöjakso, joka sisältää kolme eri tilaa: kiinni, päälle ja sulatus (Makonin 2012). (Zoha et al. 2012)




**Kuva 6.** Esimerkki säädettävästä laitteesta (Makonin 2012)

- 3. Aina päällä:** Nämä laitteet ovat hankalia NILM-järjestelmille tunnistaa, koska tämän tyylliset laitteet ottavat koko ajan saman virran eikä muutoksia tapahdu. Esimerkki aina päällä olevasta laitteesta on esimerkiksi ilmastointilaite, jos sitä ei ole mitenkään ohjattu. Kuva 7 näyttää esimerkin aina päällä olevasta laitteesta.



**Kuva 7.** Esimerkki aina päällä olevasta laitteesta (Makonin 2012)

- 4. Jatkuvasti muuttuvassa tilassa olevat laitteet:** Näillä laitteilla ei ole kiinteää tilaa käytön aikana eli toisin sanoen näillä laitteilla on ääretön määrä eri tiloja, joilla ne voivat olla (Hart 1992). Muuttuvan kulutusprofiilin omaavat laitteet voivat vaihdella kuormaa käytön aikana. Esimerkki tästä on esimerkiksi pyykinpesukone. Kun pyykinpesukoneen on laittanut päälle, sen sähkön kulutus vaihtelee hyvinkin paljon ohjelman mukaan. Kuva 8 havainnollistaa jatkuvasti muuttuvassa tilassa olevaa laitetta.



**Kuva 8.** Esimerkki muuttuvasta laitteesta (Makonin 2012)

### 3.2.2 Tehonkulutuksen perusteella luokittelu

Jokainen kotitalouslaite käyttäytyy hieman toisistaan poikkeavalla tavalla, mutta kotitalouden laitteita voidaan silti ryhmitellä muutamaan eri ryhmään myös sen perusteella, mihin niiden tehonkulutus

perustuu. Laitteet voidaan tähän perustuvassa jaottelussa kategorisoida resistiivisiin laitteisiin, sähkömoottorilla toimiviin laitteisiin, muihin sähköllä toimiviin laitteisiin, säädettävällä teholla toimiviin laitteisiin ja loisteputkivalaisimiin. (Sultanem 1991)

- 1. Resistiiiviset laitteet:** Tähän ryhmään kuuluvia laitteita ovat muun muassa lämmityslaitteet kuten uuni ja hella sekä hehkulamput ja kahvinkeitinimet (Baker et al. 2013). Resistiiivisiä laitteita kuvaavia piirteitä on muun muassa loistehon puuttuminen tehonkulutuksessa sekä yliaaltojen puuttuminen virrankulutuksesta (Sultanem 1991).
- 2. Sähkömoottorilla toimivat laitteet:** Tämä ryhmä käsittää laitteet mitkä toimivat sähkömoottorilla. Näitä laitteita ovat esimerkiksi pyykinpesukoneet ja tuulettimet. Tyypillisiä piirteitä tähän ryhmään kuuluville laitteille on loistehon merkittävä osuus tehonkulutuksessa, huippu virrankulutuksessa käynnistyksen yhteydessä ja virrankulutusta parittomilla yliaalloilla. (Sultanem 1991)
- 3. Muut sähköllä toimivat laitteet:** Tämä kategoria sisältää laitteet, jotka kuluttavat vähän tehoa ja joita käytetään joka päivä kuten televisiot, tietokoneet ja stereot. Tyypillisiä piirteitä näille on lyhyt, mutta korkean amplitudin omaava, hetkellinen huippu virrankulutuksessa käynnistyksen yhteydessä ja laaja määrä havaittavia yliaaltoja virrankulutuksessa. (Sultanem 1991)
- 4. Säädettävällä teholla toimivat laitteet:** Nämä laitteet toimivat säädettävällä teholla ja niitä ovat esimerkiksi imurit ja lämpöpatterit. Näiden laitteiden tunnistaminen on kohtuu vaikeaa, koska niiden piirteet yleensä muuttuvat riippuen siitä millä teholla niitä käytetään. (Sultanem 1991)
- 5. Loisteputkivalaisimet:** Tyypillisiä piirteitä loisteputkivalaisimille on pitkä kaksi vaiheinen siirtymä nollakulutuksesta lopulliseen kulutukseen, korkea amplitudi kolmannen yliaallon taajuudella virrankulutuksessa ja merkittävä vaihesiirto virran ja jännitteen välillä. (Sultanem 1991)

### 3.3 Tiedonkeruu

Ensimmäinen vaihe NILM systeemissä on tiedonkeruu. Tiedonkeruu on NILM-järjestelmän kannalta olennaista ja ratkaisevaa, koska näytteenottotaajuus määrää hyvin vahvasti sen mitä sähköisiä piirteitä pystytään erottamaan yhdistetystä kuormitusdatasta (Rastogi 2018; Zhuang & Shahidehpour 2018). Kustannustehokkain lähestymistapa yhdistetyn kuormitusdatan hankkimiseen olisi älymittarit, joita aletaan vähitellen ottaa käyttöön älykkäiden sähköverkkojen yleistyessä (Faustine et al. 2017). Koska näytteenottotaajuus on niin merkittävässä osassa, voidaan mittarit jakaa näytteenottotaajuuden perusteella kahteen luokkaan: alhaista ja korkeaa näytteenottotaajuutta käyttäviin (Zoha et al. 2012). NILM aiheinen kirjallisuus ei selvästi määrittele mitä voidaan pitää alhaisena ja mitä korkeana näytteenottotaajuutena. Lyhyesti sanottuna mitä korkeampi näytteenottotaajuus on, sitä tarkemmin NILM-järjestelmä kykenee tunnistamaan ja luokittelemaan laitteita (Makonin 2012).

#### 3.3.1 Matalan taajuuden mittarit

Alhaisella taajuudella tarkoitetaan tässä työssä taajuutta, joka on alle 50 Hz. Mittarit, jotka kykenevät mittamaan tällä taajuudella ovat yleensä suhteellisen halpoja ja ne kykenevät mittamaan pätö- ja loistehoa, virtaa, jännitettä sekä tehokerrointa (Rastogi 2018). Koska Suomen sähköverkon taajuus on 50 Hz, pystyy algoritmi hyödyntämään vain ”makroskooppisia” piirteitä luokittelun ja tunnistamisen yhteydessä (Zeifman & Roth 2011). Makroskooppiset piirteet ovat siis piirteitä, joiden mittaamiseen riittää alhaisella näytteenottotaajuudella varustettu sähkömittari.

#### 3.3.2 Korkean taajuuden mittarit

Useimmat tutkijat ovat samaa mieltä siitä, että matalan taajuuden mittaustiedot ei yksinään voi taata tarkkaa laitteiden tunnistamista, vaan sähköisen signaalin ”mikroskooppisia” piirteitä pitäisi käyttää ”makroskooppisten” piirteiden tukena (Zeifman & Roth 2011). ”Mikroskooppinen” tässä yhteydessä tarkoittaa sähköisiä piirteitä kuten signaalin harmonisia yliaaltoja ja signaalin aaltomuotoja (Rastogi 2018). Nyquistin näytteenottoteoreeman mukaan signaalista tulee ottaa näytteitä taajuudella, joka vähintään kaksi kertaa suurempi kuin signaalissa esiintyvä suurin taajuus, jotta signaalin takaisin rekonstruointi olisi mahdollista ja, jotta pystyisimme tunnistamaan halutun taajuuden signaalista. Tämä tarkoittaa esimerkiksi sitä, jos haluamme mitata esimerkiksi 20. yliaaltoa tulee näytteenottotaajuuden olla vähintään 2 kHz.

### 3.4 Tapahtuman havaitseminen ja piirteiden erottaminen

Useimmat NILM menetelmät voidaan jakaa joko tapahtumapohjaisiksi tai ei-tapahtumapohjaisiksi (Wong et al. 2013; Lange 2016). NILM-järjestelmässä tapahtuma on määritelty signaalin muutoksena vanhasta jatkuvasta tilasta uuteen jatkuvaan tilaan (Zhuan & Shahidehpour 2018). Tapahtumien havaitsemisella tarkoitetaan kuinka havaita kuorman toimitilan vaihtuminen kuten esimerkiksi laitteen meneminen päälle tai pois päältä (Zhuan & Shahidehpour 2018). Katsaus NILM:ssä käytettyihin tapahtumien havaitsemisalgoritmeihin on esitetty muun muassa Anderson et al. (2012) raportissa. Kun tapahtuma on havaittu, luokitellaan erotetut seuraavissa kappaleissa esitellyt piirteet tapahtumapisteen läheltä hahmontunnistus/koneoppismenetelmillä (Wong et al. 2013). Hahmontunnistus/koneoppismenetelmät esitellään kappaleessa 3.5. Ei-tapahtumapohjaiset menetelmät eivät käytä tapahtumantunnistus algoritmeja vaan sen sijaan jokainen yhdistetyn kuormitusdatan näyte otetaan huomioon päättelyn yhteydessä (Abubakar et al. 2015; Wong et al. 2013). Tapahtumapohjaiset menetelmät ovat laskennallisesti tehokkaampia verrattuna ei-tapahtumapohjaisiin menetelmiin (Abubakar et al. 2015).

Jokaiselle toimivalle sähköiselle laitteelle on ominaista tietty joukko mitattavia piirteitä, jotka paljastavat tietoja laitteen kulutusmallista, luonteesta ja toiminnasta (Hart 1992). Laitteiden tunnistukseen käytetyt menetelmät voidaan jakaa jatkuvan tilan käyttäytymistä analysoiviin menetelmiin ja laitteiden muutosta analysoiviin menetelmiin (Zoha et al. 2012).


#### 3.4.1 Laitteiden jatkuvaa tilaa analysoivat menetelmät

Laitteiden jatkuvaa tilaa analysoivat menetelmät hyödyntävät piirteitä, jotka on saatu silloin kun laite toimii jatkuvassa tilassa (Zoha et al. 2012). Näitä piirteitä ovat esimerkiksi pätö- ja loistehon kulutus, virran harmoniset yliaallot ja virran aaltomuodot (Zoha et al. 2012). Seuraavaksi esitellään näitä piirteitä hieman tarkemmin.

##### 3.4.1.1 Pätö- ja loisteho (PQ)

Pätö- ja loisteho ovat tehon reaali- ja imaginäärikomponentit. Tutkijat ovat yrittäneet käyttää pelkkää pätötehoa yksinäisenä piirteenä kuormien erittelyn yhteydessä ja huomanneet, että laitteet kuten sähkölämmittimet ja vesipumput voidaan helposti huomata yhdistetystä mittausdatasta pelkän pätötehon avulla (Zoha et al. 2012). Pätötehon kulutus yksinään ei ole kuitenkaan sopiva piirre laitteiden laajamittaiseen tunnistukseen, koska on hyvinkin todennäköistä, että kahdella laitteella on sama pätötehon

kulutus (Rastogi 2018). Jotta pystytään välttämään saman suuruisesta pätötehosta aiheutunut tunnistusongelma, voidaan käyttää loistehoa toisena piirteenä, koska monilla laitteilla kokonaistehoon sisältyy merkittävä loistehokomponentti. Pätö- ja loistehon kulutus vaihtelee hieman käynnistyskertojen välillä, joka voidaan huomata kuvasta 10. Pätö- ja loistehomenetelmä sopii hyvin laitteille, jotka voivat olla joko päällä tai kiinni, mutta esimerkiksi monessa tilassa toimivien laitteiden tunnistukseen tämä menetelmä ei toimi.




Kuva 9. Pätö-/loisteho piirreavaruus ja laite klusterointi (Hart 1992)

### 3.4.1.2 Yliaallot

Yliaallot ovat signaalin perustaajuuden monikertoja. Käytännössä tämä tarkoittaa sitä, kun Suomen sähköverkon perustaajuus on 50 Hz, niin ensimmäisen yliaallon taajuus on 50 Hz, toisen yliaallon taajuus puolestaan 100 Hz, kolmannen 150 Hz ja niin edelleen. Yliaaltoja synnyttävät sähköverkkoon epälineaariset virtapiirin osat. Laitteet, jotka sisältävät tehoelektroniikkaa ovat harmonisten yliaaltojen pääaiheuttajia (Nassif 2009). Tehoelektroniikan määrä laitteissa kasvaa jatkuvasti, joten on kannattavaa tutkia harmonisia yliaaltoja laitteiden osalta, joilla on hyvin samanlaiset pätö-/loistehopiirteet (Fitta 2010).



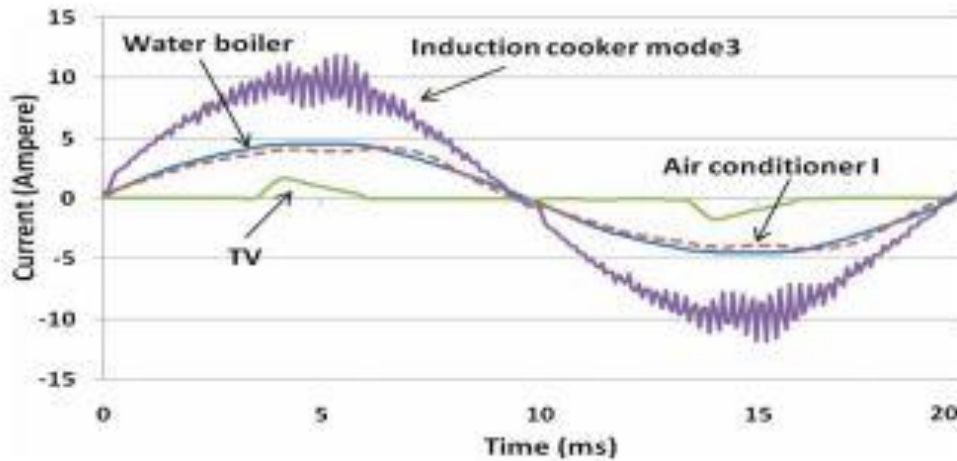
Signaalin harmoninen sisältö voidaan laskea käyttämällä nopeaa Fourier muunnosta (FFT) (Srinivasan et al. 2006; Liang et al. 2010). Kuvassa 10 on esitetty yhdessä tutkimuksessa mitattuja yliaaltojen amplitudeja vedenkeitin, ilmastointilaitteen, television ja induktiolieden osalta. Kuten kuvasta voidaan huomata, korkein virran yliaalto kuvaajassa on 91. yliaalto, joka on vielä suhteellisen merkittävä. Yliaaltoja voidaan käyttää pätö- ja loistehon lisänä laitteiden tunnistuksessa, suurin haittapuoli tässä on se, että yliaaltojen analysoiminen vaatii korkeaa näytteenottotaajuutta, joka lisää helposti NILM-järjestelmän laitteiston hintaa.



**Kuva 10.** Neljän eri laitteen yliaaltojen suhteelliset suuruudet (Liang et al. 2010).

### 3.4.1.3 Signaalin aaltomuodot

Signaalin aaltomuoto on mikroskooppinen piirre, jota voidaan käyttää laitetunnistuksessa (Zeifman and Roth 2011). Kuvassa 11 esitetty vedenkeitin, induktiolieden, television ja ilmastointilaitteen virran aaltomuodot yhden jakson aikana. Kuvasta huomataan, että puhtaasti resistiivisellä laitteella (vedenkeitin) virran aaltomuoto on puhdas siniaalto, kun taas television aaltomuoto ei puolestaan muistuta lainkaan siniaaltoa. Induktioliedellä on korkean kertaluokan harmonisia yliaaltoja ja ilmastointilaitteella (sähkömoottori käyttöinen) puolestaan on hiukan vääristynyt siniaalto. (Liang et al. 2010)



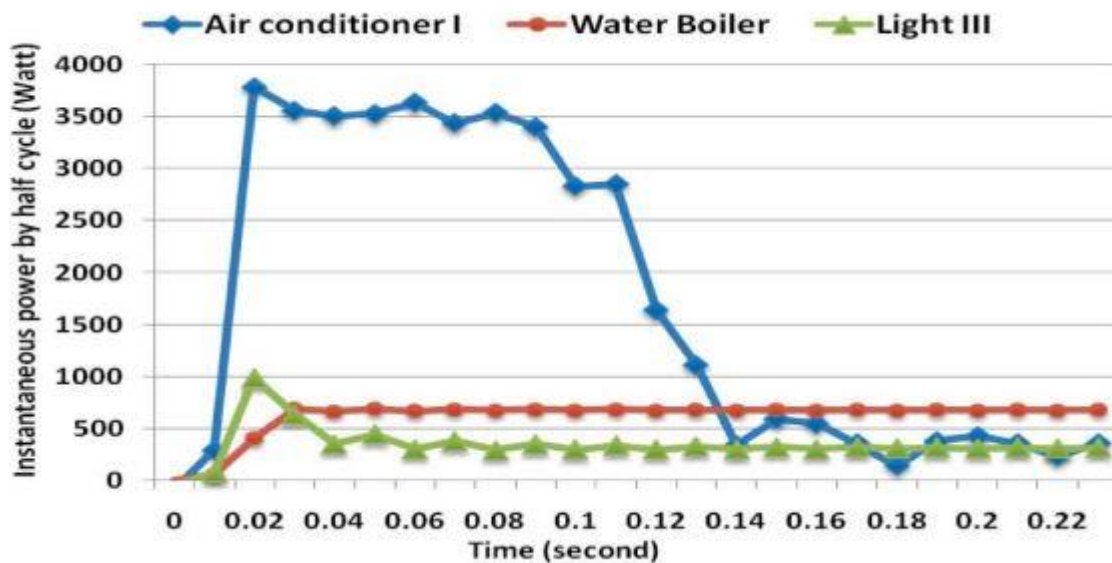
Kuva 11. Virran aaltomuoto muutamalla eri laitteella (Liang et al. 2010).

### 3.4.2 Laitteen tilan muutosta analysoivat menetelmät

Osalla laitteista jatkuvan tilan piirteet saattavat olla lähes identtiset esimerkiksi resistiivisillä laitteilla, joilla ei ilmene yliaaltoja virrankulutuksessa. Tunnistamistarkkuutta voidaan parantaa analysoimalla laitteiden tilan muutosta laitteen käynnistymisen jälkeen. Laitteiden muutostilan käyttäytyminen on todettu olevan selvästi erotettavaa ja laitteiden muutos tilanpiirteet ovat vähemmän toistensa päälle meneviä verrattuna jatkuvan tilan piirteisiin, suurin haittapuoli tässä on se, että näiden piirteiden havaitseminen vaatii suurta näytteenottotaajuutta, joka johtaa siihen, että joudutaan käsittelemään suurta määrää dataa (Figueiredo et al. 2011).

Kuvassa 12 on esitetty ilmastointilaitteen, vedenkeittimen ja hehkulampun tehonkulutus käynnistymisen yhteydessä. Kuvasta pystytään näkemään, että puhtaasti resistiivisellä vedenkeittimellä tehonkulutus kasvaa lineaarisesti. Ilmastointilaitteella ja hehkulampulla tehonkulutus puolestaan kasvaa nopeasti huippuarvoon, jonka jälkeen tehonkulutus laskee jatkuvan tilan tehonkulutuksen arvoon. (Liang et al. 2010)

Tilan muutosta havainnoivat menetelmät voivat analysoida tilan muutoksen yhteydessä virran- tai tehonkulutuksen aaltomuotoja (Chang 2008). Aaltomuodoista voidaan myös laskea mahdollisesti erilaisia tunnuslukuja kuten esimerkiksi asettumis- ja nousuaika, jotka voisivat helpottaa laitetunnistusta.



**Kuva 12.** Käynnistyksen aikana havaittava tehonkulutus (Liang et al. 2010).

Muuttuvan tilan piirteet voivat auttaa NILM-järjestelmää parantamaan tunnistustarkkuutta, kun niitä käytetään yhdessä jatkuvan tilan piirteiden kanssa. Ainoastaan muuttuvan tilan piirteistä ei voida kuitenkaan toteuttaa laitetunnistusta. Syy tähän on se, että laitteen käynnistyksen yhteydessä tehonkulutuksessa kyetään havaitsemaan yksilöllinen profiili, mutta laitteiden sammumisen yhteydessä tehonkulutuksessa ei useastikaan havaita tarpeeksi yksilöllisiä piirteitä, jotta laitetunnistus olisi mahdollista. (Chang et al. 2008)

### 3.5 Päättely, oppiminen ja luokittelu

Viimeinen vaihe NILM-järjestelmässä on luokitella laitteet erotettujen piirteiden avulla. Kirjallisuudessa on esitelty useita eri luokittelualgoritmeja ja järjestelmän opettamiseen perustuvassa kategorioidinnissa ne voidaan jakaa kahteen pääluokkaan: ohjatun oppimisen menetelmiin ja ohjaamattoman oppimisen menetelmiin. Ohjattua oppimista hyödyntävät algoritmit vaativat luokittelijan opettamisen piirreaineistolla, joka sisältää eri laitteiden ennalta määritellyt piirteet. Opetusdata voi esimerkiksi sisältää laitekohtaisilla mittauksilla saatuja laitteiden piirteitä tai sähköpiirustuksista saatuja tietoja siitä mitä laitteita missäkin vaiheessa on. Luokittelijan harjoittaminen on aikaa vievää ja kallista, joten tästä syystä tutkijoiden mielenkiinto on vähitellen siirtynyt kohti ohjaamatonta oppimista hyödyntävää algoritmia, jota ei kuitenkaan käsitellä tässä työssä sen tarkemmin. (Zoha et al. 2012)

### 3.5.1 Ohjatun oppimisen lähestymistapa

Ohjatun oppimisen menetelmät siis vaativat aineiston luokittelijan opettamiseen, jotta luokittelija pystyy tunnistamaan laitteita aggregoidusta kuormitusmittauksesta. Ohjatun oppimisen menetelmät voidaan edelleen jakaa optimointi- ja koneoppimis/hahmontunnistusmenetelmiin. Optimointimenetelmät käsittelevät kuorman erittelyä optimointiongelmana (Zoha et al. 2012). Optimointipohjaisissa menetelmissä mittausdatasta erotettuja piirteitä verrataan tietokantaan tallennettuihin laitekohtaisiin piirteisiin, jonka jälkeen yritetään minimoida virhe niiden välillä lähimmän osuman löytämiseksi (Zoha et al. 2012). Optimointimenetelmät voivat saavuttaa suuren laitteiden tunnistustarkkuuden, mutta niiden haittapuolena on se, että optimointimenetelmät ovat laskennallisesti raskaita (Zhuang & Shahidehpour 2018). Tutkijat ovat yrittäneet erilaisia optimointimenetelmiä kuten kokonaislukuohjelmointia (*engl. integer programming*) (Bhotto et al. 2017) ja geneettisiä algoritmeja (*engl. genetic algorithm*) (Baraski & Voss 2004).

Hahmontunnistusmenetelmät/koneoppiminen ovat olleet suosituimpia tutkijoiden keskuudessa kuorman tunnistuksessa (Zoha et al. 2012). Lukuisia eri menetelmiä on esitetty kirjallisuudessa kuten esimerkiksi tukivektorikone (Figueiredo et al. 2011), keinotekoiset neuroverkot (Srinivasan et al. 2006) ja  $K$ :n lähimmän naapurin menetelmä (Gupta et al. 2010). Käsitellään seuraavaksi  $K$ :n lähimmän naapurin menetelmä ja tukivektorikone lyhyesti.

#### 3.5.1.1 $K$ :n lähimmän naapurin menetelmä

$K$ :n lähimmän naapurinmenetelmä (*engl. k-Nearest Neighbor, k-NN*) on tunnettu instanssiperusteinen luokittelumenetelmä. Instanssiperusteinen tarkoittaa sitä, että instanssiperusteiset menetelmät eivät pyri kehittämään funktiota ongelman ratkaisemiseksi vaan sen sijaan opetusvaiheessa tallennetaan koko opetusaineisto eli instanssit. NN-algoritmi olettaa instanssien olevan pisteitä  $n$ -ulotteisessa avaruudessa. Lähin naapuri on yleensä määritelty euklidisen etäisyyden perusteella. Jos satunnainen instanssi  $x$  on määritelty piirrevektorilla

$$\bar{a} = \langle (a_1(x), a_2(x), \dots, a_n(x)) \rangle \quad (2)$$

missä  $a_r$  on instanssin  $x$   $r$ :nnen piirteen arvo. Kahden instanssin  $x_i$  ja  $x_j$  välinen etäisyys on määritelty euklidisena etäisyytenä seuraavasti

$$d(x_i, x_j) = \sqrt{\sum_{r=1}^n (a_r(x_i) - a_r(x_j))^2} \quad (3)$$

Kun lasketaan etäisyys tuntemattoman luokiteltavan ja kaikkien opetusaineiston instanssien välillä NN-menetelmä löytää  $k$  lähintä instanssia. Algoritmi antaa tuntemattoman luokiteltavan luokaksi yleisimmän arvon  $k$  lähimmän harjoitusesimerkin joukosta. Jos  $k = 1$ , kyseessä on silloin erikoistapaus 1-NN. 1-NN suorittaa luokittelun ainoastaan lähimmän naapurin perusteella ja asettaa näin tuntemattoman luokiteltavan luokaksi sen lähimmän naapurin luokan. NN-menetelmän suuri haittapuoli on se, että se on niin sanottu laiska oppija. Tämä tarkoittaa sitä laiskojen oppijoiden opetusvaihe tarkoittaa vain opetusaineiston tallentamista muistiin ja varsinainen laskenta tehdään luokitteluvaiheessa. (Mitchell 1997 s.230–232)

Figueiredo et al. (2011) käyttivät 5-NN luokittelijaa laitteiden erittelyyn korkealla tarkkuudella (~99%). Gupta et al. (2010) väittivät saavuttaneen 100% tarkkuuden käyttämällä K-NN tyylistä luokittelijaa, mutta eivät tarjonneet tarkempia perusteluja väitteelle.

### 3.5.1.2 Tukivektorikone

Tukivektorikoneen (*engl. support vector machine (SVM)*) idea on jakaa datapisteet mahdollisimman hyvin kahteen eri luokkaan. Tukivektorikone etsii hypertason siten, että kummallakin puolella hypertasoa on mahdollisimman paljon yhteen luokkaan kuuluvia datapisteitä (Pontil & Verri 1998). Hypertaso valitaan siten, että se maksimoi luokkien väliin jäävän marginaalin, siten että yksikään näyte ei jää marginaalitasojen väliin (Makonin 2012).


#### 4. HAASTEET LAITTEIDEN TUNNISTUKSESSA

NILM-järjestelmän toteutuksessa on edelleen lukuisia ongelmia, vaikka aihe on ollut tutkijoiden kiinnostuksen kohteena lähes kolme vuosikymmentä. On edelleen haaste kehittää järjestelmä, joka kykenee erottamaan laitteet niiden kategoriasta, koosta tai valmistajasta riippumatta (Zoha et al. 2012). Nykyiset NILM-menetelmät toimivat hyvin kahden toimitilan laiteille, mutta joidenkin monessa tilassa toimivien laitteiden tunnistaminen on edelleen vaikeaa, ja vielä haastavampaa on jatkuvasti muuttuvassa tilassa olevien laitteiden tunnistaminen (Ruano et al. 2019). Myös samaan aikaan käynnistyvät tai sammuvat laitteet ovat tällä hetkellä ongelma laitteiden tunnistuksessa (Bernard 2018). Tämä aiheuttaa ongelmia etenkin tapahtumapohjaisissa NILM-järjestelmissä (Bernard 2018).

Suuret rakennukset aiheuttavat myös haastetta laitteiden tunnistukselle, koska laitteiden määrä kasvaa. Tämä vaikeuttaa NILM-järjestelmän käyttöönottoa tulevaisuudessa esimerkiksi toimistorakennuksissa. Erityisesti toimistorakennuksille on ominaista se, että rakennuksessa on usein monia täsmälleen samoja laitteita ja samaan aikaan käynnistyy usein monta laitetta yhtä aikaa. Toimistorakennuksiin voisikin olla järkevää asentaa useampi NILM-järjestelmä, jotta laitetunnistus helpottuisi. Tässä tapauksessa NILM-järjestelmä olisi niin sanottu hybridijärjestelmä. (Bernard 2018)

NILM-järjestelmän analysoima data on hyvin henkilökohtaista. Tästä syystä tietoturva on tärkeä termi, kun puhutaan NILM-järjestelmästä. Bernard (2018) esittää omassa tohtorin työssään, että NILM-järjestelmä tulisi toteuttaa paikallisesti ilman, että tietoja siirretään internetin kautta. Tämä varmistaa sen, että kotitalouden asukkailla on kontrolli heidän omaan dataansa. Bernard (2018) myös ehdottaa, jos järjestelmässä käytetään pilvilaskentaa, tulisi silloin käyttää uusinta salaustekniikkaa. (Bernard 2018)

Tulevaisuudessa laitteiden tunnistusta tulee entisestään hankaloittamaan lisääntyvä omatuotanto. Kuva 13 sisältää kuormitusdataa kolmesta eri vaiheesta noin 42 000 s ajalta 1 Hz näytteenottotaajuu-  
della mitattuna. Kuvasta 13 huomataan, että noin 30 000 s kohdalla mukaan on tullut omatuotantoa. Tämä vaikeuttaa mahdollista laitteiden tunnistusta paljon. Omantuotannon osuus voidaan kuitenkin poistaa datasta, jos tuotantoa mitataan samalla aikaresoluutiolla kuin sähkönkulutusta. Resoluutiolla tarkoitetaan mittaustekniikassa mittausjärjestelmän erottelukykyä.



**Kuva 13.** Todellista mittausdataa kolmesta eri vaiheesta

Tämän lisäksi yksi ongelma on se, että suurin osa NILM-järjestelmää käsittelevistä tutkimuksista on tehty Yhdysvalloissa, jossa pääsyttö on usein yksi- tai kaksivaiheinen (Bernard 2018). Euroopassa taas suurin osa kotitalouksista on kytketty kolmivaihejärjestelmään. Mittaussysteemi siis tulee eroamaan Euroopassa siitä, mitä se tulee mahdollisesti olemaan Pohjois-Amerikassa. Tämä aiheuttaa konkreettisen käytännön ongelman yhtäläisen NILM-järjestelmän kehityksen suhteen.

## 5. MAHDOLLISUUDET

Huolimatta siitä, että NILM-järjestelmällä on useita hyödyllisiä sovelluksia energiansäästöön rakennuksissa, NILM-järjestelmän laajempia käyttöönottoja ei ole vielä toteutettu (Faustine et al. 2017; Bernard 2018).

### 5.1 Eriteltyt energialaskut ja yksilölliset energiansäästösuositukset

Sähkönkulutuksen vähentäminen tarjoamalla laitekohtaisiksi tiedoiksi eriteltyjä sähkölaskuja saattaa olla ei-intrusiivisen kuorman seuranta järjestelmän yleisimmin mainittu käyttösovellutus (Kelly 2016). Kempton ja Montgomery (1982) toteavat tutkimuksessaan, että kotitalouksien asukkaiden tietämys yksittäisten laitteiden vaikutuksesta kokonaiskulutukseen on kohtuullisen huono. Asukkaat yliarvioivat lyhyt aikaisen energiansäästön tehokkuuden kuten esimerkiksi valaistuksen vaikutuksen ja aliarvioivat pitkäaikaisia ratkaisuja kuten tehottomien laitteiden korvaamista tai kodin eristyksen parantamista (Kempton & Montgomery 1982). Parempi tietämys todellisesta sähkönkulutuksen jakautumisesta voisi auttaa ja motivoida kuluttajia tekemään merkityksellisempiä toimia energiansäästön toteuttamisessa. Tämän lisäksi NILM-järjestelmä voisi myös tarjota kotitalouden asukkaille tarkempia suoria energiansäästöehdotuksia.

### 5.2 Kulutusjousto

Kulutusjousto yleisesti tarkoittaa sähkön kuluttajien reagoimista sähkönhinnan ja -saatavuuden vaihteluun muuttamalla sähkönkulutuskäyttäytymistä. Toisella tapaa sanottuna kulutusjoustolla tarkoitetaan tilannetta, jossa loppukäyttäjä vaihtaa kulutuskäyttäytymistään vastauksena sähkön muuttuvaan hintaan tai muuhun kannustimeen siten, että kulutus poikkeaa loppukäyttäjän vakituisista kulutustottumuksista. Kuluttajalla on löyhästi jaoteltuna kolme eri mahdollisuutta toteuttaa kulutusjousto. Ensimmäinen vaihtoehto on, että kuluttaja vähentää sähkönkulutustaan kriittistenkulutuspiikkien aikana. Toinen vaihtoehto on, että sähkön kuluttaja siirtää kulutustaan toiseen ajankohtaan ja kolmas vaihtoehto on kulutusjouston toteuttamiseen verkosta kysytyn kuorman korvaaminen omalla tuotannolla. NILM-järjestelmä voisi käyttää aiempaa tietämystä laitteiden kuormitusprofiileista korkean kulutusjoustopotentiaalin omaavien laitteiden tunnistamiseksi (Zhuang & Shahidehpour 2018). (Harju 2013)



### **5.3 Laitteiden seuranta**

NILM-järjestelmää voitaisiin myös hyödyntää vikaantuneiden laitteiden tunnistamiseen tai jopa siihen, että pystyttäisiin ennustamaan laitteiden vikaantuminen ja näin ollen vaihtamaan tai korjaamaan vikaantumassa oleva laite ajoissa. Myös palveluasunnoissa NILM-järjestelmää voitaisiin hyödyntää esimerkiksi keittiölaitteiden seurannassa. Laitteiden seurannan avulla voidaan päätellä mitä keittiössä tehdään, onko asukas unohtanut esimerkiksi kahvinkeitin päälle tai muistanut syödä ruokansa. Tällä tavalla voitaisiin esimerkiksi vahtia muistisairasta henkilöä tai vanhusta, jotta hän ei aiheuta vahinkoa itselleen tai omaisuudelleen. (Pérez 2011)

## 6. YHTEENVETO

Työn lähtökohtana oli selvittää, kuinka laitteiden tunnistusta on toteutettu mittausdatasta. Työtä tehdessä huomattiin, että suurin osa aihepiiriin keskittyvästä kirjallisuudesta käsittelee NILM-järjestelmiä. NILM-järjestelmä sopiikin laitteiden tunnistukseen hyvin, jos tunnistustarkkuus vain saadaan riittävälle tasolle, koska se voidaan asentaa helposti ja ilman, että asukkaille aiheutuu häiriötä.

Tässä kandidaatin työssä on esitelty NILM-järjestelmän yleinen toimintaperiaate, eri laitetyypit ja eritelty jatkuvan tilan ja muutostilan piirteitä, joiden avulla laite on mahdollista tunnistaa mittausdatasta. Työssä on esitelty iso osa yleisimmistä menetelmistä, joita on käsitelty NILM-järjestelmiä koskevissa tutkimuksissa.

Tämän lisäksi työssä on tuotu esille tämän hetken haasteita, joita kohdataan laitteiden tunnistuksessa, sekä esitetty NILM-järjestelmän tulevaisuuden mahdollisuuksia. Tulevaisuudessa riittää vielä paljon tutkittavaa tunnistusalgoritmien kehittämisessä ja tunnistustarkkuuden saamisessa riittävälle tasolle. Mielestäni tulevaisuuden NILM-järjestelmän tutkimuksessa kannattaa keskittyä kehittämään algoritmeja, jotka hyödyntävät matalan taajuuden mittausdataa, koska älymittarit, joita maailmalla on alettu ottamaan kykenevät mittamaan yleensä ainoastaan alhaisella näytteenottotaajuudella.

**LÄHTEET**

Abubakar, I., Khalid, S., Mustafa, M., Shareef, H. & Mustapha, M. 2015. An overview of Non-intrusive load monitoring methodologies. Conf. Rec. IEEE CENCON, Johor Bahru, Malaysia. February 18. S.54–59. [Viitattu 17.11.2019]. Saatavissa: <https://doi.org/10.1109/CENCON.2015.7409513>

Anderson, K., Berges, M., Ocneanu, A., Benitez, D. & Moura, J. 2012. Event Detection for Non Intrusive Load Monitoring. Conf. Rec. IEEE IECON, Montreal, QC, Canada. December 24. S.3312–3317. [Viitattu 17.11.2019]. Saatavissa: <https://doi.org/10.1109/IECON.2012.6389367>

Barker, S., Karla, S., Irwin, D., Shenoy, P. 2013. Empirical Characterization and Modelling of Electrical Load in Smart homes. Conf. Rec. IEEE IGCC, Arlington, VA, USA. September 23. S.1–10. [Viitattu 17.11.2019]. Saatavissa: <https://doi.org/10.1109/IGCC.2013.6604512>

Baraski, M. & Voss, J. 2004. Genetic algorithm for pattern detection in NIALM systems. Conf. Rec. IEEE ICSMC, The Hague, Netherlands. March 7. S.3462–3468. [Viitattu 17.11.2019]. Saatavissa: <https://doi.org/10.1109/ICSMC.2004.1400878>

Berges, M., Goldman, E., Matthews, H. S. & Soibelman, L. 2009. Learning Systems for Electric Consumption of Buildings. Proceedings of the 2009 ASCE International Workshop on Computing in Civil Engineering, Austin, Texas. [Viitattu 24.11.2019]. Saatavissa: [https://doi.org/10.1061/41052\(346\)1](https://doi.org/10.1061/41052(346)1)

Bernard, T. 2018. Non-Intrusive Load Monitoring (NILM). combining multiple distinct electrical features and unsupervised machine learning techniques. [Viitattu 17.11.2019]. Saatavissa: <https://nbn-resolving.org/urn:nbn:de:hbz:464-20180717-141158-7>

Bhotto, Z. A., Makonin, S. & Bajic, I.V. 2017. Load Disaggregation Based on Aided Linear Integer Programming. IEEE Transactions on Circuits and Systems II: Express Briefs, vol.64, no 7, s. 792–769. [Viitattu 17.11.2019]. Saatavissa: <https://doi.org/10.1109/TCSII.2016.2603479>

Chang, H., Lin, C.L. & Yang, H.T. 2008 Load recognition for different loads with the same real power and reactive power in a non-intrusive load-monitoring system. 12th International Conference on Computer Supported Cooperative Work in Design, Xi'an, China. June 10. S. 1122–1127. [Viitattu 22.11.2019]. Saatavissa: <https://doi.org/10.1109/CSCWD.2008.4537137>

Darby, S. 2006. The effectiveness of feedback on energy consumption. A Review for DEFRA of the literature on metering, Billing and direct Displays. Environmental Change Institute, University of Oxford. [Viitattu 24.11.2019]. Saatavissa: <https://www.eci.ox.ac.uk/research/energy/downloads/smart-metering-report.pdf>

Energiavirasto. 2018. National Report 2018 to the Agency for the Cooperation of Energy Regulations and to the European Commission. [verkkodokumentti]. [viitattu 29.10.2019]. Saatavissa: <https://energiavirasto.fi/markkinoiden-julkaisut>

Esa, N. F., Abdullah, M. P., Hassan, M. Y. 2016. A review disaggregation methods in non-intrusive appliance load monitoring. vol.66, p.163–173. [Viitattu 24.11.2019]. Saatavissa: <https://doi.org/10.1016/j.rser.2016.07.009>

Faustine, A., Mvungi, N.H., Kaijage, S., Michael, K. 2017. A Survey on Non-Intrusive Load Monitoring Methodies and Techniques for Energy Disaggregation Problem. [viitattu 8.11.2019]. Saatavissa: <https://arxiv.org/abs/1703.00785>

Figueiredo, M. B., De Almeida, A. M., Ribeiro, B. 2011. An Experimental Study on Electrical Signature Identification of Non-Intrusive Load Monitoring (NILM) Systems. In Proceedings of the 10th ICANNGA, Ljubljana, Slovenia, April 14–16. s.31–40. Saatavissa: [https://doi.org/10.1007/978-3-642-20267-4\\_4](https://doi.org/10.1007/978-3-642-20267-4_4)

Fitta, M.T. 2010. Load classification and appliance fingerprinting for residential load monitoring system. Master's Thesis. Aalto University, Department of Electrical Engineering, Espoo. [Viitattu 17.11.2019]. Saatavissa: <http://urn.fi/URN:NBN:fi:aalto-201203151574>.

Ford, R. 2009. Reducing domestic energy consumption through behaviour modification. PhD thesis, University of Oxford. [Viitattu 24.11.2019]. Saatavissa: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.457.648&rep=rep1&type=pdf>

Gupta, S., Reynolds, M. S. & Patel, S. P. 2010. ElectriSense: single-point sensing using EMI for electrical event detection and classification in the home. In Proceedings of the 12th ACM international conference on Ubiquitous computing (UbiComp '10). ACM, New York, NY, USA, s.139–148. [viitattu 24.11.2019]. Saatavissa: <http://dx.doi.org/10.1145/1864349.1864375>

Harju, K. 2013. Reaaliaikainen hinnoittelu sähkömarkkinoilla. Master Thesis. Oulun yliopisto, taloustieteiden tiedekunta, kansantaloustieteen yksikkö, kansantaloustiede. [Viitattu 21.11.2019]. Saatavissa: <http://urn.fi/URN:NBN:fi:oulu-201312052021>

Hart, G.W. 1992. Non Intrusive Load Monitoring. Proceeding of the IEEE, vol.80, no 12, s. 1870–1891. [Viitattu 17.11.2019]. Saatavissa: <https://doi.org/10.1109/5.192069>

He, K., Jakovetic, D., Zhao, B., Stankovic, V., Stankovic, L. & Cheng, S. (2019). A Generic optimisation-based Approach for Improving Non-Intrusive Load monitoring. IEEE Transactions on Smart Grid, vol. 10, no 6, s. 6472–6480. [Viitattu 17.11.2019]. Saatavissa: <https://doi.org/10.1109/TSG.2019.2906012>

Kempton, W. & Montgomery, L. 1982. Folk quantification of energy. Energy, vol. 7, no 10, s. 817–827. [Viitattu 21.11.2019]. Saatavissa: [https://doi.org/10.1016/0360-5442\(82\)90030-5](https://doi.org/10.1016/0360-5442(82)90030-5)

Kelly, J. 2016. Disaggregation of domestic smart meter energy data. PhD Thesis, Imperial College London, Department of Computing, London. [viitattu 21.11.2019]. Saatavissa: <https://doi.org/10.25560/49452>

Lange, H. 2016. Disaggregation by state Inference A Probabilistic Framework For Non-Intrusive Load Monitoring. Master's Thesis. Aalto University, School of Science, Espoo. [Viitattu 17.11.2019]. Saatavissa: <http://urn.fi/URN:NBN:fi:aalto-201602161334>

Liang, J., Ng, S.K.K., Kendall, G., Cheng, J.W. M. 2011. Load Signature Study-Part I: Basic Concept, Structure, and Methodology. IEEE Transactions on Power Delivery, vol. 25, no 2, s.551–560. [Viitattu 17.11.2019]. Saatavissa: <https://doi.org/10.1109/TPWRD.2009.2033799>

Lua, A.R. 2015. Location-aware Energy Disaggregation in Smart Homes. [verkkodokumentti]. [viitattu 1.11.2019]. Saatavissa: <https://www.semanticscholar.org/paper/Location-aware-Energy-Disaggregation-in-Smart-Homes-Lua/05a6d5aafe5f46eac5a064feb96ec5af787aefbe>

Makonin, S. 2012. Approaches to Non-piIntrusive Load Monitoring (NILM) in the Home. PhD Thesis, Simon Fraser University, School of computing Science. [Viitattu 17.11.2019]. Saatavissa: <http://summit.sfu.ca/item/14475>

Mitchell, T. M. 1997. Machine Learning, Boston, WCB McGraw-Hill. 414 s. ISBN 0-07-042807-7

Nassif, A. 2009. Modeling, measurement and mitigation of power system harmonics. PhD thesis, University of Alberta. [Viitattu 24.11.2019]. Saatavissa: <https://doi.org/10.7939/R37X3G>

Pérez, M. N. V. 2011. A Non-Intrusive Appliance Load Monitoring System for Identifying Kitchen Activities. Universidad Autónoma de Madrid. Departamento de Ingeniería Informática. [Viitattu 24.11.2019]. Saatavissa: <http://hdl.handle.net/10486/7443>

Pointil, M. & Verri, A. 1998. Support Vector Machines for 3D Object recognition. IEEE Transaction on Pattern Analysis and Machine Intelligence. Vol. 20, no. 6, s. 637–646. [Viitattu 30.11.2019]. Saatavissa: <https://doi.org/10.1109/34.683777>

Rastogi, T. 2019. Load Identification from Aggregated Data using Generative Modeling. Master's Thesis. KTH Royal Institute of Technology. School of Electrical Engineering and Computer Science. [Viitattu 27.10.2019]. Saatavissa: <http://urn.kb.se/resolve?urn=urn:nbn:se:kth:diva-249599>

Ruano, A.; Hernandez, A.; Ureña, J.; Ruano, M.; Garcia, J. 2019. NILM Techniques for Intelligent Home Energy Management and Ambient Assisted Living: A Review. *Energies*, 12, 2203. [Viitattu 17.11.2019]. Saatavissa: <https://doi.org/10.3390/en12112203>

Sharp, T.R. 1994. Nonintrusive load monitoring system: Consideration for use and potential applications. US Department of Energy, Office of Scientific and Technical Information. [viitattu 27.10.2019]. Saatavissa: <https://www.osti.gov/biblio/10118074>

Srinivasan, D., Ng, W.S. & Liew, A.C. 2006. Neural-network-based signature recognition for harmonic source identification. *IEEE Transactions on Power Delivery*, vol.21, no 1, s.398–405. [Viitattu 17.11.2019]. Saatavissa: <https://doi.org/10.1109/TPWRD.2005.852370>

Sultanem, F. 1991. Using appliance signatures for monitoring residential loads at meter panel level. *IEEE Transactions on Power Delivery*, vol.6, no 4, s.1380–1385. [Viitattu 17.11.2019]. Saatavissa: <https://doi.org/10.1109/61.97667>

Tilastokeskus. 2018. Asumisen energiankulutus. [verkkodokumentti]. [viitattu 6.10.2019]. saatavissa: [https://www.stat.fi/til/asen/2017/asen\\_2017\\_2018-11-22\\_fi.pdf](https://www.stat.fi/til/asen/2017/asen_2017_2018-11-22_fi.pdf)

Wong, Y., Sekercioglu Y., Drummond, T. & Wong, V.S. 2013. Recent approaches to non-intrusive load monitoring techniques in residential settings. *Conf. Rec IEEE CIASG, Singapore, Singapore*. September 26. S.73–79. [Viitattu 17.11.2019]. Saatavissa: <https://doi.org/10.1109/CIASG.2013.6611501>

Zeifman, M. & Roth, K. 2011. Nonintrusive appliance load monitoring: Review and Outlook. *IEEE Transactions on Consumer Electronics*, vol. 57, no 1, s. 76–84. [Viitattu 17.11.2019]. Saatavissa: <https://doi.org/10.1109/TCE.2011.5735484>

Zhuang, M. & Shahidehpour, M. 2018. An Overview of Non-Intrusive Load Monitoring: Approaches, Business, Applications, And challenges. *Conf. Rec. IEEE POWERCON, Guangzhou, China*. January 7. S.4291–4299. [Viitattu 17.11.2019]. Saatavissa: <https://doi.org/10.1109/POWERCON.2018.8601534>

Zoha, A., Gluhak, A., Imran, M.A., Rajasegarar, S. 2012. Non-Intrusive Load Monitoring Approaches for Disaggregated Energy Sensing: A Survey. *Sensors*, vol. 12, no 12, s. 16838–16866. [Viitattu 17.11.2019]. Saatavissa: <https://doi.org/10.3390/s121216838>