



TALLINNA TEHNIKAÜLIKOOL

INSENERITEADUSKOND

Elektroenergeetika ja mehhatroonika instituut

ELEKTRITARBIJATE TUVASTAMINE TEHISNÄRVIVÕRGU ABIL

IDENTIFICATION OF ELECTRIC APPLIANCES WITH AN ARTIFICIAL NEURAL NETWORK

MAGISTRITÖÖ

Üliõpilane: Mart Saun

Üliõpilaskood: 211536AAAM

Juhendaja: Heigo Mölder, PhD

Tallinn 2023

(Tiitellehe pöördel)

AUTORIDEKLARATSIOON

Olen koostanud lõputöö iseseisvalt.

Lõputöö alusel ei ole varem kutse- või teaduskraadi või inseneridiplomit taotletud.

Kõik töö koostamisel kasutatud teiste autorite tööd, olulised seisukohad, kirjandusallikatest ja mujalt pärinevad andmed on viidatud.

“19” detsember 2023

Autor:

/ allkiri /

Töö vastab bakalaureusetöö/magistritööle esitatud nõuetele

“.....” 20.....

Juhendaja:

/ allkiri /

Kaitsmisele lubatud

“.....”20.....

Kaitsmiskomisjoni esimees

/ nimi ja allkiri /

Lihtlitsents lõputöö reprodutseerimiseks ja lõputöö üldsusele kättesaadavaks tegemiseks¹

Mina Mart Saun

1. Annan Tallinna Tehnikaülikoolile tasuta loa (lihtlitsentsi) enda loodud teose

Elektritarbijate tuvastamine tehisnärvivõrgu abil,

mille juhendaja on

Heigo Mölder,

1.1 reprodutseerimiseks lõputöö säilitamise ja elektroonse avaldamise eesmärgil, sh Tallinna Tehnikaülikooli raamatukogu digikogusse lisamise eesmärgil kuni autoriõiguse kehtivuse tähtaja lõppemiseni;

1.2 üldsusele kättesaadavaks tegemiseks Tallinna Tehnikaülikooli veebikeskkonna kaudu, sealhulgas Tallinna Tehnikaülikooli raamatukogu digikogu kaudu kuni autoriõiguse kehtivuse tähtaja lõppemiseni.

2. Olen teadlik, et käesoleva lihtlitsentsi punktis 1 nimetatud õigused jäävad alles ka autorile.

3. Kinnitan, et lihtlitsentsi andmisega ei rikuta teiste isikute intellektuaalomandi ega isikuandmete kaitse seadusest ning muudest õigusaktidest tulenevaid õigusi.

19.12.2023

¹ Lihtlitsents ei kehti juurdepääsupiirangu kehtivuse ajal vastavalt üliõpilase taotlusele lõputööle juurdepääsupiirangu kehtestamiseks, mis on allkirjastatud teaduskonna dekaani poolt, välja arvatud ülikooli õigus lõputööd reprodutseerida üksnes säilitamise eesmärgil. Kui lõputöö on loonud kaks või enam isikut oma ühise loomingulise tegevusega ning lõputöö kaas- või ühisautor(id) ei ole andnud lõputööd kaitsvale üliõpilasele kindlaksmääratud tähtajaks nõusolekut lõputöö reprodutseerimiseks ja avalikustamiseks vastavalt lihtlitsentsi punktidele 1.1. ja 1.2, siis lihtlitsents nimetatud tähtaja jooksul ei kehti.

LÕPUTÖÖ LÜHIKOKKUVÕTE

Autor: Mart Saun

Lõputöö liik: Magistritöö

Töö pealkiri: Elektritarbijate tuvastamine tehisnärvivõrgu abil

Kuupäev:
19.12.2023

82 lk (*lõputöö lehekülgede arv koos lisadega*)

Ülikool: Tallinna Tehnikaülikool

Teaduskond: Inseneriteaduskond

Instituut: Elektroenergeetika ja mehhatroonika instituut

Töö juhendaja(d): PhD Heigo Mõlder

Töö konsultant (konsultandid): -

Sisu kirjeldus:

Igakuiselt esitatakse lõpptarbijale elektriarve, milles esitatakse elektrienergia maksumus. Lisaks sellele, oleks tarbijal kasulik teada kui palju kulus majapidamises erinevate kodumasinate käitamiseks elektrienergiat ning kui suur oli seadmete kasutamise maksumus. Magistritöö eesmärk on koostada tehniline lahendus millega on võimalik kaudselt tuvastada töötavaid elektritarbijaid. Mõõtmiste tegemiseks paigaldatakse toiteahela juurde mõõteseade, mille järel on ühendatud kolm kodumasinat. Voolutrafoga mõõteseade mõõdab aktiivvõimsuse ja salvestab selle väärtuse sekundilise intervalliga faili. Peale seda liigutatakse failid MATLABi programmi, milles aegseeria andmed teisendatakse kahedimensiooniliseks RGB – mudeli põhiseks pildiks.

MATLABi programmis luuakse CNN tehisnärvivõrk, kasutades selleks varem koostatud GoogLeNet tehisnärvivõrku. Tehisnärvivõrku modifitseeritakse ja sellele lisatakse kiht, mis tuvastab RGB piltide põhjal toiteahelas töötanud elektrienergiatarbijad.

Tehisnärvivõrku kasutatakse igal tunnil töötanud seadmete leidmiseks ning selle põhjal arvutatakse tunni jooksul tarbija poolt kulutatud elektrienergia kogus. Tarbitud elektrienergia ja seadme talitlemise tunni põhjal arvutatakse seadmete kasutuse maksumus tunniks ja viiepäevaseks perioodiks. Perioodi maksumuse kohta koostatakse elektriarve.

Märksõnad: elektrienergia tarbija, disagreggeerimine, masinõpe, NILM

ABSTRACT

<i>Author:</i> Mart Saun	<i>Type of the work:</i> Master Thesis
<i>Title:</i> Identification of Electric Appliances with an Artificial Neural Network	
<i>Date:</i> 19.12.2023	<i>82 pages (the number of thesis pages including appendices)</i>
<i>University:</i> Tallinn University of Technology	
<i>School:</i> School of Engineering	
<i>Department:</i> Department of Electrical Power Engineering and Mechatronics	
<i>Supervisor(s) of the thesis:</i> PhD Heigo Mölder	
<i>Consultant(s):</i> -	
<i>Abstract:</i> <p>Every month, the consumer receives an electricity bill, which shows the total cost of the electricity. Additionally, it would be useful to know how much electricity was consumed in the household to run the various household appliances and the individual cost of using them. The aim of the thesis is to develop a technical solution that can indirectly identify the electricity appliances that are in operation. The measurements will be carried out by installing a metering device in the power supply circuit, to which three household appliances will be connected. The current clamp meter measures the active power and stores this value in a file with a period of one second. The files are then inserted to a MATLAB program, where this data is converted into a two-dimensional RGB image.</p> <p>In MATLAB, a CNN artificial neural network is created using the GoogLeNet artificial neural network created previously. The artificial neural network is augmented with a layer in order to identify the power consumers that have been operating in the power circuit based on the RGB images.</p> <p>The artificial neural network will then be used to find the appliances that were working each hour and calculate the amount of electricity consumed by those during the hour period. Based on this finding, the cost of using the appliances is calculated for periods of one hour and of five days. An electricity bill will be compiled for the cost per period.</p>	
<i>Keywords:</i> electricity appliance, disaggregation, machine learning, NILM.	

LÕPUTÖÖ ÜLESANNE

Lõputöö teema:	Elektritarbijate tuvastamine tehisnärvivõrgu abil
Lõputöö teema inglise keeles:	Identification of Electric Appliances with an Artificial Neural Network
Üliõpilane:	Mart Saun, 211536AAAM
Eriala:	Energiamuundus- ja juhtimissüsteemid
Lõputöö liik:	magistritöö
Lõputöö juhendaja:	Heigo Mölder
Lõputöö kaasjuhendaja: (ettevõtte, amet ja kontakt)	
Lõputöö ülesande kehtivusaeg:	kehtivusaja annab juhendaja Choose an item. Choose an item.
Lõputöö esitamise tähtaeg:	20.12.2023

Üliõpilane (allkiri)

Juhendaja (allkiri)

Õppekava juht (allkiri)

Kaasjuhendaja (allkiri)

1. Teema põhjendus

Iga kuu esitakse tarbijale või ettevõttele elektriarve, millest ei selgu millised elektriseadmed kui palju elektrit tarbisid. Täpselt teades, millele elekter kulub, on võimalus nendele kulutustele tähelepanu pöörata ja tarbimist muuta või elektritarbijat vahetada.

2. Töö eesmärk

Töö eesmärgiks on tuvastada ühest mõõtepunktist mõõtes erinevad seadmed, mis on samale toiteliinile ühendatud. Tuvastamine toimub seadmete iseloomuliku elektrienergia tarbimise tunnuse järgi.

3. Lahendamisele kuuluvate küsimuste loetelu:

Milliste seadmete ja meetoditega on võimalik elektritarbijaid tuvastada?

Millise seadmega mõõta seadmete elektrienergia tarbimist, et mõõdetud tulemus oleks piisavalt täpne?

Millised meetodid võimaldavad kogu agregeeritud elektrienergia tarbimisest vajalikud tarbijate tunnused üles leida?

4. Lähteandmed

Lähteandmed leitakse iseseisva mõõtmise teel.

5. Uurimismeetodid

Uurimismeetoditeks on katsemõõtmised seadmetega, vabavaralised tarkvarad, instituudis kasutusel olevad tarkvarad.

6. Graafiline osa

Töö graafiline osa esitatakse töö sees.

7. Töö struktuur

Sissejuhatus

1. Turul pakutavate lahenduste ülevaade
 - 1.1 Erinevate olemasolevate lahenduste võrdlus
 - 1.2 Teadusartiklid, raamatud
 - 1.3 Patendi kirjelduse ülevaade

2. Tehniline idee
 - 2.1 Riistvara
 - 2.2 Riistvaraga seadmete mõõtmine
 - 2.3 Masinõppe olemus
 - 2.4 Masinõppe mudeli koostamine

3. Tarbijate tuvastamine
 - 3.1 Tarbijate tuvastamine masinõppega
 - 3.2 Tarbijate seosed elektrienergia tarbimisega
 - 3.3 Elektriarve koostamine

4. Tootearenduse soovitusel idee edasiarenduseks

Kokkuvõte

8. Kasutatud kirjanduse allikad

Allikateks kasutatakse uuritavate teemade kohta käivaid teadusartikleid, erialakirjandust ja raamatuid.

9. Lõputöö konsultandid

Professor Lauri Kütt, Marek Jakovoi

10. Töö etapid ja ajakava

Lõputöö ülesande esitamine (november 2022)

Lõputöö ülesandes püstitatud probleemi uurimine (november 2022 – oktoober 2022)

Kirjanduse ülevaade (oktoober 2023)

Tehnilise idee lahendamine (oktoober 2023)

Tarbijate võimsuse mõõtmine (november 2023)

Mõõdetud tarbijate analüüs (november 2023)

Lõputöö esimene versioon (detsember 2023)

Lõputöö esitamine (detsember 2023)

SISUKORD

LÕPUTÖÖ LÜHIKOKKUVÕTE	4
ABSTRACT	5
LÕPUTÖÖ ÜLESANNE	6
EESSÕNA	9
Lühendite ja tähiste loetelu	10
SISSEJUHATUS	11
1 TURUL PAKUTAVATE LAHENDUSTE ÜLEVAADE	13
1.1 Olemasolevate lahenduste ülevaade	13
1.2 Turul tegutsevad lahenduste pakkujad	15
1.2.1 Sense	15
1.2.2 Shelly	16
1.2.3 Emporia	17
1.2.4 Bidegely	17
1.2.5 GridX	18
1.2.6 NET2GRID	19
1.2.7 Turul tegutsevate pakkujate vahekokkuvõte	19
1.3 Ülevaade teaduskirjandusest	22
1.4 Patentide ülevaade	24
2 TEHNILINE IDEE	26
2.1 Voolu ja pinge mõõtmine	27
2.1.1 Mõõtmisel kasutusel olevad seadmed ja komponendid	30
2.1.2 Mõõteskeem	31
2.1.3 RPICT4V3 kasutamine	32
2.1.4 Tarbijate mõõtmine	33
2.2 Masinõpe	35
2.2.1 Juhendatud õpe	36
2.2.2 Juhendamata õpe	37
2.2.3 Stiimulõpe	37
2.2.4 Tehisnärvivõrgud	38
2.3 Masinõppe tööriistad	39
2.3.1 PyTorch, TensorFlow, Keras	39
2.3.2 MATLAB®	40
2.4 Masinõppemudeli koostamine	41
2.4.1 Mõõteandmete teisendamine RGB piltideks	42
2.4.2 Tehisnärvivõrgu koostamine programmis MATLAB	46
2.4.3 Masinõppe mudeli treenimine	50
2.4.4 Masinõppe mudeli valideerimine	50
2.4.5 Masinõppe mudeli parendamine	51
3 TARBIJATE TUVASTAMINE MASINÕPPE ABIL	55
3.1 Energiatarbimise arvutamine	55
3.2 Tuvastatud seadmete energiatarve	57
3.3 Tuvastatud seadmete seosed majapidamise tarbimise andmetega	65
4 TOOTEARENDEUSE SOOVITUSED IDEE EDASIARENDEUSEKS	71
KOKKUVÕTE	73
5 Kasutatud kirjandus	75
LISAD	79
Lisa 1 Klassi ennustamise ja energiatarbe prognoosimise programmi kood	80

EESSÕNA

Lõputöö idee autor on töö juhendaja Heigo Mölder, kes pakkus välja idee elektriarvest, millel on eristatud eri tarbijatele kulunud elektrienergia hulk ning seeläbi seadmete kasutamise maksumus. Heigo Mölder pakkus välja idee mõõteseadmest, millega on võimalik elektrienergia tarbijat tuvastada.

Ülo Sepp abistas RaspberryPi ja Arduino UNO kontrolleriiga, kuna töö autoril varasem kokkupuude mikrokontrollerite ja RaspberryPi arvutiga puudus.

Elektritarbijate mõõtmised viidi läbi eramaja tüüpi majapidamises Harjumaal, milles jälgiti kolme kodumasina tööd viieteistkümne päeva jooksul.

Lühendite ja tähiste loetelu

- AMI – tark arvesti (ingl k *Advanced Metering Infrastructure*)
- AVP – andmevahetusplatvorm (andmeladu)
- CAD – kliendi energiatarbe mõõteriist (ingl k *Consumer Access Device*)
- CNN – konvolutsiooniline närvivõrk (ingl k *Convolutional neural network*)
- CSV – komadega eraldatud andmed (ingl k *comma-separated values*)
- DER – hajutatud energia ressursid (ingl k *Distributed Energy Resources*)
- DM – nõudepõhine tarbimine (ingl k *Demand Response*)
- GADF – grammi nurgavälja erinevus (ingl k *Gramian Angular Difference Field*)
- GAF - grammi nurgavälja (ingl k *Gramian Angular Field*)
- GASF – grammi nurgavälja summa (ingl k *Gramian Angular Summation Field*)
- GPIO - mitme otstarbeline sisend/väljund (ingl k *General-Purpose Input/Output*)
- HAN – koduvõrk (ingl k *Home Area Network*)
- HAT – peale paigaldatav riistvara (ingl k *hardware attached on top*)
- ILM – sekkuv energia mõõtmine (ingl k *Intrusive Load Monitoring*)
- NILM – mitte sekkuv energia mõõtmine (ingl k *Non-intrusive Load Monitoring*)
- ONNX – avatud tehisnärvivõrkude vahendus (*Open Neural Network Exchange*)
- RGB – värvimudel punasest, rohelisest ja sinisest värvist
- RP – rekurrentne joonis (ingl k *Recurrence Plot*)
- TOU – reaalaja tariifid (ingl k *Time-of-Use tariffs*)
- UART - universaalne asünkroonne vastuvõtja/saatja (ingl k *Universal Asynchronous Receiver/transmitter*)

SISSEJUHATUS

Tavatarbijale esitatakse igakuiselt elektriarve, milles on eraldi välja toodud päevane ja öine elektrienergia tarbimine. Detailsemat infot tarbimise kohta arvel ei avaldata. Veebisaidi Elektrihind.ee [1] selgitusel pakuvad elektrienergiat järgmised ettevõtted: Eesti Energia AS [2], 220 Energia OÜ [3], Elektrum Eesti OÜ [4], AS Eesti Gaas [5], VKG Elektrivõrgud OÜ [6], Alexela Energia AS [7]. Loetletud ettevõtete kodulehtede sisu põhjal selgub, et mõnede elektrimüüjate veebikeskkonnad ja võrguettevõtted võimaldavad kliendil tarbimise andmeid täpsemalt vaadata. Näiteks Eesti Energia kuvab Elektrilevi tunnipõhiseid tarbimise andmeid ja Elektrilevi võimaldab oma lepingulistel klientidel neid analüüsiks alla laadida [8]. Tarbimise andmed liitumispunktide kohta on samuti saadaval ettevõtte Elering AS Estfeed'i andmelaost [9]. Need andmed ei sisalda aga infot selle kohta, mis seadmed realselt töötasid. Kui elektriarve oleks tarbijate põhiselt jagatud, siis see võimaldaks:

- hinnata, kas mõnda seadet või seadmete gruppi kasutatakse liiga palju;
- hinnata, kas mõni seade kasutab liiga palju elektrienergiat oma funktsiooni täitmiseks ja vajaks välja vahetamist;
- hinnata, kas mõne seadme kasutamise aega saaks nihutada soodsama elektri hinnaga perioodile;
- hinnata, kas mõne elektriseadme juhtimist on vaja muuta, et elektriseade talitleks vaid soovitud ajal.
- tuvastades elektritarbijaid, samaaegselt tuvastada rikkeid elektriseadmetes ja madalpingevõrgus;
- tõsta tarbijate teadlikust elektrienergiast ja selle maksumusest.

Täiendava info alusel on võimalik vastu võtta teadlike otsuseid elektrienergia säästmiseks ja soodsamaks tarbimiseks. Lisaks muudab madalpinge võrgu analüüs elektri tarbimise turvalisemaks.

Lõputöös pakutav lahenduse idee põhineb sellele, et iga elektrienergia abil töötav kodumasin või seade tarbib oma talitlemisel kindla koguse elektrienergiat. Kui kodumasin võimust salvestada kõrge detailsusega, siis on võimalik kodumasin ja tema iseloomulik mõõdetud tarbimise tunnus omavahel siduda. Seekaudu on võimalik jagada kogu tarbitud elektrienergia iseloomulike tunnuste põhjal osadeks ehk kodumasinade vahel ära. Antud lahenduse teostuseks on vaja mõõteseadet elektrienergia mõõtmiseks ning tarkvara elektritarbijate eristamiseks.

Peatükis 1 on välja toodud valik olemasolevate lahendusi ja võimalusi kuidas tarbijaid hetkel tuvastatakse. Samuti antakse ülevaade teaduskirjandusest ja loetletakse patente, mis on olemasolevatele lahendustele registreeritud.

Peatükis 2 on kirjeldatud elektrienergia mõõtmisel kasutatava tehnilise lahenduse riistvara ja tarkvara ning kirjeldatakse kuidas elektritarbijate mõõtmisi läbi viiakse. Sellele järgneb ülevaade masinõppest ja selle meetoditest; ning ülevaade enim kasutatavatest tööriistadest, mille abil saab masinõppe võimalusi rakendada. Peatükis esitatakse lahenduses kasutatava CNN tehisnärvivõrgu mudeli koostamine ja mudeli analüüs.

Peatükis 3 on kirjeldatud tarbijate tuvastamine tarbitava elektrienergia põhjal kasutades riistavara mõõteandmeid ja CNN tehisnärvivõrku. Uuritakse kui palju kulub tuvastatud tarbijatele elektrienergiat ja selle põhjal koostatakse elektriarve.

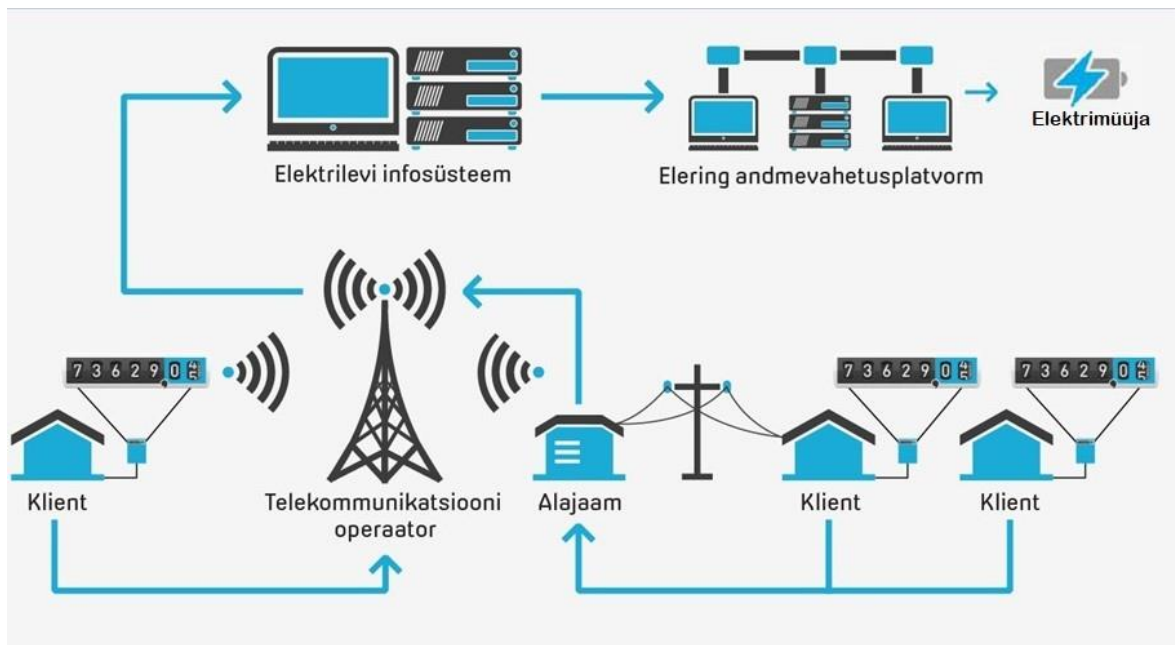
Peatükis 4 esitatakse soovitused tootearenduseks.

elektrienergia tarbija, disagreggeerimine, masinõpe, NILM, magistritöö

1 TURUL PAKUTAVATE LAHENDUSTE ÜLEVAADE

1.1 Olemasolevate lahenduste ülevaade

Turul pakutakse lõpptarbijale erineva suutlikusega seadmeid, millega energiat mõõta. Tööstuses on levinud peakilpidele paigutatud võrguanalüsaatorid pinge, voolu, energia ja teiste elektrienergiaga seotud parameetrite mõõtmiseks, näiteks Lovato DMG – seeria [10]. Tavakasutajale on mõeldud pistikupesadesse ühenduvad kompaktsed mõõteseadmed, mis on sageli paigutatud elektrivõrgus mõne suurema elektritarbija ette [11]. Elektrilevi võrguettevõtte liitumispunkti mõõtepunktis kasutatakse Eestis kaugloetavaid ELS andmesidet kasutavaid elektriarvesteid Landis+Gyr E450 [12]. Skeem kuidas mõõteandmed Elektrilevi võrgus liiguvad on esitatud joonisel 1.1.



Joonis 1.1 Mõõteandmete liikumine Elektrilevi võrgus

Käesolevas töös uuritakse energiamõõtmist lõppkliendi vaatest. Antud teema kohta on väga põhjaliku ülevaate ja aruande koostanud ülemaailmse ulatusega turuanalüüsi ja konsultatsiooniettevõtte Guidehouse [13]. Dokumendi *Guidehouse Insights Leaderboard: Customer Engagement and Experience Analytics*'i [14] andmetel on olulisi turuosalisi, kes kasutavad masinõppe põhist tarbija tuvastamist, erasektori toodete turul ca neliteist: Oracle, Uplight, Bidegely, Apogee Interactive, NET2GRID, Sense, GridX, Eliq, Powerley, Copper Labs, Voltaware, Elevation Energy Solutions, Emporia Energy ja Greenpocket. Nimetatud ettevõtted kasutavad majapidamiste energiatarve tuvastamiseks ja klientidele edastamiseks väga erinevaid meetodeid. Nende tootjate

tehtud energiamõõtmiste ja nende põhjal tehtud analüüsi kasulikkuse ja rakendatavuse kohta on raportis välja toodud järgmised võimalused:

- Tarbijate tuvastamine ja selle detailse info edastamine kliendile võimaldab saavutada suurema hulga klientide kaasamise, nende osalemise ja klientideks registreerimise.
- Nad pakuvad sisulisi järeldusi elektrienergia tarbimisest, mitte ainult energiatarbimise haldamise ja energia tarbimisharjumuste muutmise soovitusi.
- Targa kodu optimeerimine.
- Elektrisõidukite laadimise haldamine.
- Elektrihinna ja elektripaketi maksumuse analüüs.
- Agregeeritud elektrienergia elektritarbijateks jagamine.
- Reaalajas elektriturgudel osalemine.
- TOU (*Time-of-use*) reaalaja tariifid / tariifide analüüs.
- Kõnekeskuse optimeerimine, tarbijate energiatarbimise luure võrguettevõttele.
- DER (*Distributed energy Resources*) hajutatud energiaressursi ja DM (*Demand response*) nõudepõhise tarbimise juhtimine ja optimeerimine.

Loetletud punktide põhjal saab väita, et detailne teave elektritarbimise kohta võimaldab palju praktilisi rakendusi.

Eelnimetatud ettevõtted mõõdavad elektrienergia tarbimist ja tuvastavad tarbijaid erinevate meetoditega. Üheks võimaluseks on tarbijate tuvastamise rakendus lisada vahetult targa arvesti sisse. Antud võimalust pakub muude võimaluste kõrval Bidegely [15] ja Sense [16] koos Itroni [17] loodud arvestitega. Arvesti on võimalik liita andmesideprotokolliga tarbija tuvastamise rakenduse külge. Sellist meetodit pakub muude võimaluste kõrval GridX [18] ja NET2GRID [19]. Emporia Energy [20] kasutab tarbijate energiakulu mõõtmiseks voolutrafit iga tarbija toiteliini ees. Shelly [21] kasutab energia arvestamiseks eraldiseisvaid, seadmetoosi paigaldatavaid nutirelesid.

1.2 Turul tegutsevad lahenduste pakkujad

1.2.1 Sense

Sense [16] (joonis 2.2) annab võimaluse saada teada kui palju energiat majapidamine kasutab. Sense võimaldab reaalajas näha töötavaid elektritarbijaid ja elektritarbimise trende, süsteem kuvab hetke kogutarbimist, tuvastab elektritarbijad ja nende elektritarbimise. Lisaks võimaldab süsteemi tarkvara seadistada alarmid juhuks kui mõni seade lakkab töötamast või ununeb tööle. Eraldiseisvalt võimaldab seade hinnata elektrimootorite elutsüklit ja tarbimist ning anda võrguettevõttele teada esinevatest elektrikvaliteedi probleemidest hoiatades ühtlasi ujuva (katkenud) neutraali eest.



Joonis 1.2 Sense'i lahendus

Sense suunitleb oma toodet kolme sihtgruppi: eramajapidamised, võrguettevõtted ning tööstusettevõtted.

Võrguettevõtetele pakutavad võimalused:

- Anda kliendile infot tarbijad elektrikasutuse kohta, mis võimaldab kliendil energiat säästa, aitab lahendada kaebusi suurte kulude kohta ning muuta klientide kodud turvalisemaks.
- Võimaldab tarbijaid teavitada vajadusest mõne elektritarbija kasutamine lõpetada või vahetult juhtida kolmanda osapoole juhivat elektritarbijat, näiteks elektriauto laadijat.
- Võimaldab tuvastada rikkis elektriseadmeid ja klienti teavitada kui rikkis elektriseadet kasutatakse. Samuti võimaldab kindlustusele jagada infot elektririketest.


Eratarbijatele pakutavad võimalused:

- Võimaldab säästa energiat ja raha kuna tekib teadmine millistele seadmetele raha ja energia kulub. Keskmiselt on seeläbi säästetud 9% energiat.
- Võimaldab näha reaalajas, millised elektritarbijad hetkel töötavad või töötasid. Näiteks kas pesumasin on töötsükli lõpetanud.
- Võimaldab vältida õnnetusi. Võimalik on näha kas ahi või triikraud töötab või saada teavitus, kui külmkapp lõpetab töötamise.

Sense kasutab mõõtmiseks voolutrafot ja integratsioone arvestite tootjatega. Oluliseks puuduseks on kokkusobimatus kolmefaasilise elektrivõrguga. Lisaks pakutakse riistvara hetkel ainult Põhja-Ameerika klientidele.

1.2.2 Shelly

Shelly [21] toodab suurel hulgal erinevate võimalustega tooteid. Shelly energiamõõtmise seadmete lahendus seisneb selles, et iseseisvad mõõteseadmed on paigaldatud igale tarbijale või elektrienergia toiteliinile vahetult seadme juures. Lisavõimalusena on mõõteseadme elektri- jaotuskilbis kogu tarbitud energia mõõtmiseks ühest mõõtepunktist. Joonisel 1.3 on üks Shelly elektrienergia mõõtmise seade.



Joonis 1.3 Shelly Plus 1PM

Seadme iseloomulikud väärtused on:


- Mõõteseadmed on väikesed ning mahuvad suurematesse seinte sisestesse seadmetoosidesse pistikupesade ja tarbijate juures.
- Mõõteseadmed sisaldavad juhitavat releed, mis võimaldab väiksemaid tarbitavaid võimsusi eemalt juhtida.
- Võimaldab hinnata elektritarbija korrasolekut ning tuvastab kui seade hakkab rikki minema.
- Elektrikilpi paigaldatud mõõteseadme ja releed võimaldavad mõõta elektripaigaldise kogutarbimist ja juhtida mitut suurt koormust.
- Mõõteseadmed releedega võimaldavad graafikute alusel elektritarbijate juhtimist.
- Mõõteseadmed on avatud koodiga ning seadmeile on võimalik skriptimiskeelt kasutades funktsionaalsust lisada.
- Mõõteseadmetel on liidesed LAN, Wi-Fi, Z-Wave ja Bluetoothiga.
- Mõõteseadmed on integreeritud levinud nutikõlaritega ja seadmeid on võimalik häälkorraldustega juhtida.
- Mõõteseadme arvestab elektripaigaldise päikesepaneelide tootmisega.
- Vee lekke ja temperatuuriandurid, mis on võimalik integreerida mõõteseadmetega.
- Teiste seadmete juhtimine veebiüleste käskudega.

1.2.3 Emporia

Emporia [20] seade võimaldab mõõta elektripaigaldisse sissetulevatelt kaablilt voolu ja pinget väärtust. Lisaks on võimalik seadmega ühendada kuni kuusteist voolutrafo, millega on võimalik mõõta eraldiseisvalt tarbijatesse minevaid elektriühelaid. Joonisel 1.4 on Emporia mõõteseadet koos voolutrafoodega.

Seadme kohta on välja toodud:


- Seade ühendub elektripaigaldise elektrikiilpi.
- Seade võimaldab teada saada elektripaigaldise kogutarbimise ja kuni kuueteistkümmet ühefaasilise liini jälgimist.
- Võimaldab ühendada targad pistikupesad, mis võimaldab seadmetele kasutusaegu määrata.
- Võimaldab elektritarbijate tarbimist täpselt hinnata, kuna tarbijale on määratud mõõtmiste tegemiseks kindel voolutrafo.
- Võimaldab kliendil seadistada teavitusi kui mõni seade ununeb tööle või hoopiski ei käivitunud. Samuti on võimalikud teavitused seadme liiga suure elektritarbimise puhul.
- Teeb ülevaate tarbitud energiast ja annab soovitusi kuidas elektrienergiat kokku hoida.



Joonis 1.4 Emporia The Vue Energy Monitor

1.2.4 Bidegely

Bidegely [15] *Utility AI Disaggregation* esitleb end esimese ettevõttena, kes valmistab toote, mis suudab vooluarvesti mõõtetulemuste järgi tarbijaid eristada. Väite tunnustuseks on patent leiutise kohta kümne aasta eest ning lisaks on registreeritud sama leiutise täiendusena veel 12 patenti. Joonisel 1.5 on Bidegely *True Disaggregation* kontseptsioon. Ettevõtte kasutab tarbijate tuvastamiseks kolme võimalust.



Joonis 1.5 Bidegely *True Disaggregation*

- *True Disaggregation* – kasutab tarbijate tuvastamiseks tarka arvestit AMI (*Advanced Metering Infrastructure*).

- *Statistical Disaggregation* – kasutab tarbijate tuvastamiseks statistikat.
- *Hardware-based Disaggregation* – kasutab koduvõrgu HAN (*Home Area Network*) seadmeid.
- Kasutab tarbijate tuvastamiseks olemasolevate arvestite andmeid. Arvestid saavad olla targad pideva andmevooga või sellised, mis saadavad andmeid pikema intervalliga andmeserverisse.
- Kasutab tarbijate tuvastamiseks madala resolutsiooniga andmeid 15-30-60 minutilise mõõteintervalliga.
- 15 minutilise mõõteintervalliga arvesti andmete alusel jagatakse tarbimine 12 klassiks, millest osa klasse on tuvastatud tarbija klassid ning osad on hinnangulised klassid. Pikemaajalise intervalliga andmete põhjal on võimalik vähem tarbijate klasse tuvastada.
- Salvestab pikema aja jooksul tuvastatud seadmete energiatarbimise. Selle põhjal on võimalik hinnata seadme korrasolekut, kui energiatarbimine muutub.

Empowering Utilities with True, Behind-the-Meter Disaggregation: BIDGELY'S PROVEN APPROACH AND REAL-WORLD IMPACT [22]. Ettevõtte pakub tarkvaralahendusi tarbijate tuvastamiseks agregeeritud elektrienergia andmetest.

1.2.5 GridX

GridX [18] tuvastab elektritarbijad kasutades selleks elektriarvesti andmeid. Firma loodud lahenduses kasutatakse paljude võimalustega gridBox võrgulüüsi (joonis 1.6), mis on võimeline ühenduma kohapealsete seadmetega. Lisaks kasutatakse tuvastamiseks arvesti tarbimise andmeid andmeserverites. Võrgulüüs kasutab andmete saamiseks avatud EEBUS, Modbus ja OCPP protokolle. GridX on võimeline looma ühenduse 40 tootja seadmega. Võrgulüüsiga on võimalik ühendada vahelduvpinge laadijad, alalispinge laadijad, elektriarvesti, päikesepaneelide inverterid, soojuspumbad ja akupangad. Võrgulüüsi kasutamise võimalused:



Joonis 1.6 GridX gridBox

- Arvestiandmete põhjal on võimalik tuvastada majapidamises olevaid seadmeid.
- DER (Distributed Energy Resources) energia ressursi seadmete juhtimine kohapeal.
- Nõudepõhine tarbimise juhtimine.

GridXi *on-edge* riistvara võimaldab filtreerida välja olulised andmed kohapeal, enne kui need serverisse saadetakse. See vähendab andmesidega seotud probleeme ja vähendab andmevõrgus olevate andmete hulka. Kohapealse riistvara ja tarkvaraga on majapidamises olevate seadmete seire ja haldus võimalik kohapeal ilma serverivahelise andmesideta.

1.2.6 NET2GRID

NET2GRID [23] pakub tarkvara ja riistvara millega agregeeritud elektrienergia andmed tarbijateks jagada. Antud ettevõttel on väljatoodud tootjate arvestuses kõige suurem toodete valik. Tuvastamiseks kasutatakse nelja meetodit.

- Kasutab tarkade arvestite mõõdetud andmeid 15 - 30 - 60 minutilise mõõteintervalliga.
- Kasutab eraldiseisvat riistvara 1 - 10 sekundilise mõõteintervalliga. Eraldiseisev riistvara on ühendatud vahetult targa elektriarvesti külge olenevalt riigist LoRa PAN, IEC 62056-21 mode D, DLMS/COSEM, SML, Impulsi lugeja, IEC 62056-21 mode M, DSMR 2, 2.2, 3, 4 & 5, Modbus RTU, Dual Zigbee Smart Energy ja Zigbee Home Automation stacks'i abil.
- Kasutab arvestisse lisatud rakendust, mis mõõdab 1 - 10 sekundilise mõõteintervalliga.
- Kasutab volutrafot eraldiseisval riistvaral ja see võimaldab alla sekundilise mõõteintervalliga mõõtmist ja elektritarbija tuvastamist reaalsajas.



Joonis 1.7 NET2GRID SBWF4612 SmartBridge

DSMR liidest kasutatav seade on joonisel 1.7.

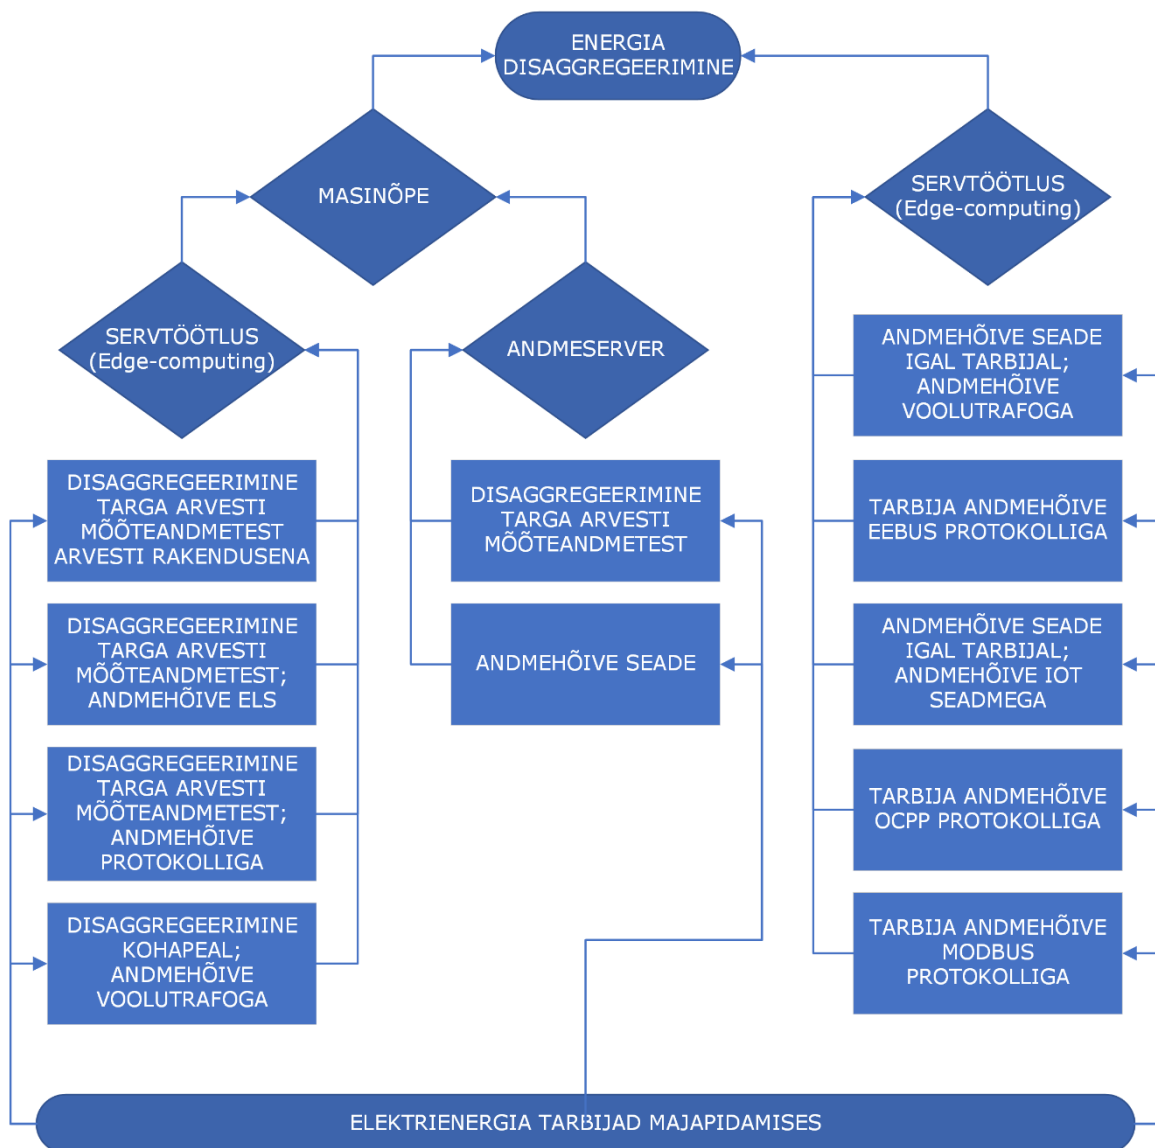
1.2.7 Turul tegutsevate pakkujate vahekokkuvõte

Kokkuvõtvalt kasutatakse kahte meetodit - vahetult elektritarbijaid tuvastavat ILM (*Intrusive Load Monitoring*) meetodit ja mitte vahetult tuvastavat NILM (*Non-Intrusive*

Load Monitoring) meetodit. Esimene kasutab riistvara iga seadme ees või suhtleb uuritava seadme liidestega. Meetodi eeliseks on suur täpsus, kuna igal uuritava tarbijal on oma mõõtesead. Kuid see tähendab ühtlasi suuremaid kulusid seadmetele ja seadmete paigaldusele. Samas on siis võimalik elektritarbijat juhtida mõõteseadme väljundiga. Teise meetodi korral kasutatakse algoritme mis disagregeerivad elektrienergia andmeid ja tuvastavad seadmed ühest mõõtepunktist või kasutavad olemasoleva elektriarvesti andmeid tarbijate tuvastamiseks. Antud lahendus on soodsam ja paigaldus lihtsam. Mõne lahenduse puhul tähendab paigaldus ainult tarkvara seadistamist. Selle meetodi korral aga ei ole võimalik täpselt teada, mis seade töötab ning elektritarbija tuvastamise täpsus sõltub algoritmi headusest ja mõõteandmete lugemise sagedusest. Lisaks ei ole võimalik elektritarbijaid vahetult juhtida. Kokkuvõtvalt on majapidamise elektritarbijad võimalik tuvastada:

- Tarkade arvestite andmetest, kui need on jõudnud andmeserveritesse.
- Tarkade arvestite sisse integreeritud rakenduste abil ning tuvastamine on kohapeal arvesti sees.
- Tarkade arvestite andmetest, kui need on kohapeal ühendatud andmevahetuseks mõne kasutajaliideselega.
- Kohapealse CAD (*Consumer Access Device*) seadmega, mis määrab elektrienergiat majapidamisse sissetulevalt kaablilt voolutrafo abil.
- Kohapealse CAD seadmega, mis määrab elektrienergia voolutrafode abil mitmete eraldiseisvate toiteliinide juhtmetelt.
- Kohapealse CAD seadmega, mis mõõdab elektrienergiat pistikupesade paigaldustoosidesse ühendatud ja paigaldatud mõõteseadmete abil.
- Kohapealse CAD seadmega, mis mõõdab elektrienergia pistikupesadesse paigaldatud pinnapealsetest nutipistiku seadmetest.

Joonisel 1.8 on voogdiagramm elektritarbijate tuvastamise meetoditest.



Joonis 1.8 Tarbijaid on võimalik tuvastada andmetest masinõppe abil ja ilma.

Eratarbijatele mõeldud seadmed on disainitud selliselt, et elektripaigaldise muutmist ei ole vaja teostada ning seadmed saab mõõtmisteks ühendada sellisel viisil, et juhtmeid elektripaigaldisel ei ole vaja lahti ühendada. Seadmed kasutavad pinge mõõtmiseks pistikupesadest saadud väärtust ja voolu mõõtmiseks kasutatakse voolutrafot, mille saab paigaldada juhtme ümber. Seadmeid peab elektriohutusseaduse ja seadme ohutuse seaduse alusel paigaldama kompetentne spetsialist [24] [25]. Selgitus on Tarbijakaitse ja Tehnilise Järelevalve Ameti leheküljel [26].

1.3 Ülevaade teaduskirjandusest

Olemasolevaid lahendusi uurides selgus, et tuvastamiseks kasutatakse peamiselt kahte lähenemist: ILM meetodit ja NILM meetodit. ILM meetodit puudutavaid artikleid käesolevas töös ei uuritud, sest lõputöö eesmärk oli tutvuda kaasaegse masinõppe meetodite rakendamisega praktilistes lahendustes. NILM meetodit käsitlevaid teadusartikleid energiatarbijate tuvastamise kohta leiab andmebaasidest suurel hulgal. Scopuse [27] andmebaasis on 1407 ja IEEE Explore andmebaasis 801 teadustööd. Suurim teadusartiklite otsingumootor Google Scholar [28] annab kokku 17300 NILM-i teemalist tulemust.

Esimesena tegi uurimistööd NILM rakendamise kohta George Hart 1992 aastal [29], kes mõõtis elektritarbijate voolutarbimist ja pinget. Hart uuris elektritarbijate üleminekut ühest püsiseisundist teise. Ta arvutas elektritarbija energiakasutuse ja tuvastas seekaudu elektritarbijaid. Elektritarbimise uurimine kaasaegsetel meetoditel muutus uuesti oluliseks alates 2010. a kui viidi läbi mitmeid uurimisi ja salvestati majapidamises erinevate tarbijate energiatarbimist. Näiteks UK-DALE [30], kus mõõdeti viie majapidamise tarbijaid 1/6Hz andmesalvestus sagedusega; AMPds2 uurimus Kanadas [31], kus uuriti majapidamise energiatarvet andmesalvestus 1/60 Hz sagedusega; REDD [32], kus mõõdeti elektritarbijaid 15 kHz andmesalvestus sagedusega; ja ENERTALK uurimus Lõuna-Koreas [33], milles mõõdeti 22 majapidamise tarbijaid 15 Hz andmesalvestus sagedusega. Viimasena nimetatud uurimus viidi läbi, et saada avalike andmeid suurema mõõtmisagedusega kui varem. Muu hulgas avastati, et igal tarbija tüübil on oma iseloomulik tarbimismuster, ning omakorda on tunnused erinevad ka konkreetse tarbija tootjate vahel.

Eelpool nimetatud uuringutel saadud kodumasinat tarbimise andmeid ei kasutanud akadeemilistes töödes ainult andmete mõõtjad, neid hakkasid analüüsima paljud teised uurimisasutused ning mõõteandmeid aluseks võttes katsetati uusi masinõppealgoritme. Näiteks UK-DALE mõõdetud andmete põhjal on hiljem kirjutatud 39 akadeemilist tööd [34].

Arvutite ja masinõppe arenedes hakati kasutama masinõppe võimalusi elektriseadmete tuvastamiseks. 2016 aastal uuriti Markovi mudeli kasutamist (Nandy), *FHMM Factorial hidden Markov models* (Wang). Peale seda uuriti süvaõppe kasutamist *Deep Learning Network, Sequens-to-sequence* – seq2seq koos LSTM *Long short-term memory*, DAE *denoising autoencoder*, CNN *Convolutional neural network*, LSTM, RNN *Recurrent neural network*. Antud kokkuvõtte tuuakse välja artiklis *IMG-NILM: A Deep learning NILM approach using energy heatmaps* [35]. Ülevaate kaasaegsetest tehisenärvivõrgu rakendustest saab artiklist *Explaining Deep Neural Networks and Beyond: A Review of Methods and Applications* [36].

Tarbijate tuvastamine põhineb mitmetes teadustöodes tarbija töö käivituse hetke ja seiskumise hetke tuvastamisel ning aegseeria analüüsil mille põhjal ennustatakse tarbija tüüp. Uudse lahendusena on kasutatud meetodit, kus aegseeria teisendatakse piltideks. Ühe teadusartiklis on seadme energiatarbimine teisendatud GASF/GADF (*Gramian Angular Summation Field/ Gramian Angular Difference Field*) algoritmidega kahe dimensiooniga pildiks ning hiljem on nendel piltide analüüsiks kasutatud varem valmis treenitud masinõppe mudelit VGG16, kohandades seda teisendatud kahedimensiooniliste piltide jaoks. Uuringus leiti, et piltideks teisendatuna üldistab mudel paremini uusi kodumasinat andmeid, isegi kui andmed on pärit varem tundmatust majapidamisest [37]. Sama meetodit on uuritud hiljemgi. Artiklis teisendatakse aegseeria andmed GAF (*Gramian Angular Field*), GADF ja RP (*Recurrence Plot*) meetodil. Uuringus leitakse, et meetoditest on parim GADF ning sellel meetodil on suur potentsiaal tarbijate tuvastamiseks. Uuringus keskendutakse aga ühele tarbijale ning teiste tarbijate tüübi tuvastamist ei käsitletud [38].

Uue meetodina kasutatakse aegseeria teisendamiseks *heatmap* värviskaalaga teisendusi. Artiklis *Using Heatmaps for Deep Learning based Disease Classification* [39] kasutati teisendust geneetilise info uurimiseks. Värviskaalat aegseeria teisendusena on kasutatud konverentsiettekandes *IMG-NILM: A Deep learning NILM approach using energy heatmaps* [35]. Antud ettekandes kirjeldatakse meetodit kuidas elektritarbimise aegseeria andmed teisendada *heatmap*'iga pildiks.

Ettekandes on kasutatud UK-DALE andmebaasi andmeid. Selle põhjal on mõõtmiste periood iga kuue sekundi järel ja ajaaken on üks ööpäev. Töös teisendatakse mõõtmiste periood ja ajaaken piksliteks, kus ajaaken on ühel teljel ja mõõtmiste periood teisel teljel. Piksli värv iseloomustab elektrienergia tarbimist. Kokku moodustus 720 x 24 piksliga pilt: 720 mõõtetulemust igal tunnil 24 tunni vältel.

IMG-NILM meetodi abil disagegeerimise eesmärk on tuvastada erinevad ajahetked, millal tarbija sisse- ja välja lülitati ning lisaks annab meetod infot tarbija energiatarbe kohta. UK-DALE andmebaas koosneb agregeeritud andmetest ja eraldi elektritarbijate andmetest. See võimaldas luua kaks klassi, milles ühes klassis on kogutarbimine koos kõikide tarbijatega ning teises klassis on kogutarbimine, millest on ühe tarbija tarbimisandmed välja võetud. Töö autorid lõi algoritmi, mis tuvastas kas päeva jooksul on tarbija töötanud või mitte. Kokku uuriti tarbijaid viies majapidamises ning andmed normaliseeriti, et standardiseerida andmed erinevate ajaakende ja hoonete vahel.

Kui elektritarbimine on teisendatud kahedimensiooniliseks pildiks, siis see võimaldab rakendada tänapäevaseid meetodeid piltide klassifitseerimiseks ehk masinnägemist.

1.4 Patentide ülevaade

Veebilehte patents.google.com [40] põhjal on elektritarbijate tuvastamise meetodeid registreeritud patentidena suurel hulgal. „NILM“, ja „Load disaggregation“ annavad tulemuseks vastavalt 3275 ja 52254 tulemust. Samsung Electronics Co võttis 22.05.2014 patendi US20140142724A1 [41] , *Apparatus and method for non-intrusive load monitoring*. Hetkel on patendi staatus *abandoned* ja patendist on loobutud. Võetud kirjeldab detailselt meetodeid ja seadmeid kuidas NILM meetodiga tarbijaid tuvastada. Süsteem koosneb sensorist, mis loeb energiatarbimise informatsiooni, kontrollerist, mis salvestab energiatarbimise mustri ja identifitseerib tarbija, kuvaekraanist, mis kuvab identifitseeritud seadme ning mille abil kasutaja saab kinnitada, et seade tuvastati korrektselt ning andmebaasist, kuhu salvestatakse korrektselt tuvastatud tarbijate tarbimise andmed. Tarbijate tuvastamise tehnikat täpselt ei kirjeldata, nimetatakse sündmuse tuvastamise loogikat, karakteristikute tuvastamise loogikat, seadmete tuvastamise loogikat ja võimsuse tuvastamise loogikat.

Oracle International Corp on võtnud oma lahendusele patendi WO2021108011A1 *Non-intrusive load monitoring using machine learning and processed training data* [42], mis on samuti registreeritud Jaapani, Hiina RV ja USA patentide registris. Patent kirjeldab, et süsteemi osised kasutavad mitte sekkuvat koormuse jälgimist (NILM) ja uudseid õppimise skeeme. Treenitud masinõppe mudel, mis on seadistatud eristama tarbija energiatarvet kogu majapidamise energiatarbest. Masinõppe mudel on treenitud ennustama tarbija energiatarvet kogu salvestatud majapidamise energiatarbest. Majapidamise energiatarbe saab esitada perioodide kaupa ning võimaldab perioodi kohta võtta kindla tarbija energiakasutuse või mitme valitud seadme energiakasutuse. Treenitud masinõppe mudeli abil on võimalik ennustada tarbija energiatarvet seadistatud perioodide kohta. Oracle International Corp on registreerinud veel patendid WO2021108008A1 [43] ja WO2021108010A1 [44], mis kirjeldavad seadmete tuvastamist masinõppe abil.

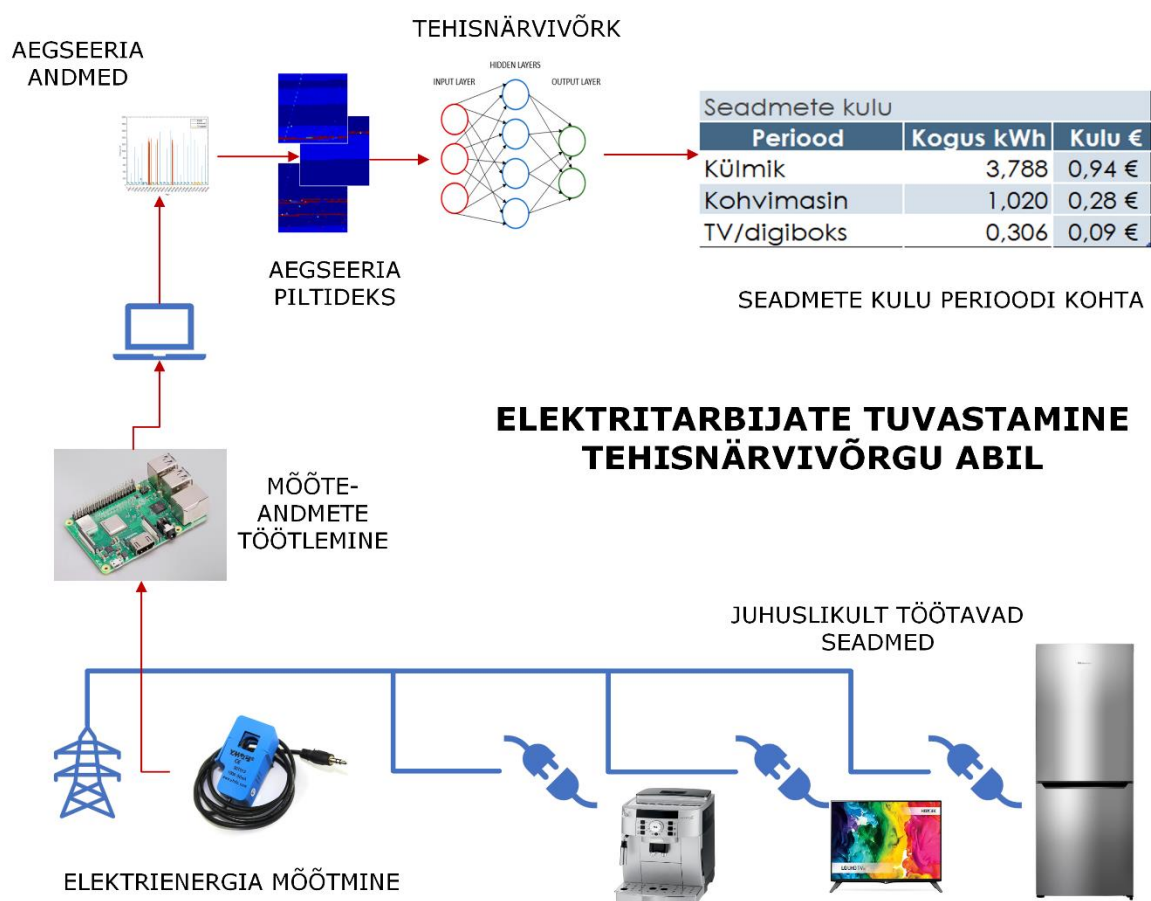
Bidegely on registreerinud patendi *Improvements in low frequency energy disaggregation techniques* WO2018109754A2 [45]. Leiutis võimaldab õpetada meetodid, mis tarbimise andmetele põhinedes jagab tarbijad esemeteks. Patendis loetletakse üles milliseid tarbijaid on võimalik tuvastada. Patent *Improvements in energy disaggregation techniques for whole-house energy consumption data* WO2015073997A2 [46]. Leiutis on suunatud süsteemidele ja meetoditele, mis võimaldab energia jagamist kogu hoone energia andmetest, baseerudes mingil viisil kogu maja energia profiilile, treenimise andmetele ja ette loodud mudelitele. Sisaldades mooduleid, mis seovad kogu maja energiatarbe impulsid konkreetse elektritarbija töötükliga, mis seovad tõusva nivoo impulsid ja langeva nivoo impulsid,

klassifitseerimise moodulid, mis grupeerivad sarnaste karakteristikutega impulsside kogumid. Leiutis võimaldab graafilist kasutajaliidest, mis võimaldab leitud elektrienergia tarbijate andmeid esitada.

Bidegely toob oma kodulehel välja, et nende ettevõtte on registreerinud tarbijate tuvastamisega seoses kokku 16 patenti.

2 TEHNILINE IDEE

Antud uurimustöö keskendub agregeeritud elektrienergia andmete tarbijateks lahutamisele ja selle läbiviimise analüüsile. Eelpool kirjeldatust selgub, et erinevaid masinõppe põhinevaid tarbijate tuvastamise lahendusi on turul mitmeid. Antud lõputöö raames soovib autor aga uurida masinõppe algoritmide rakendamist. Selleks kasutatakse võimalikult odavat kättesaadavat riistvara, mis on ostetud veebipoest LeChacal.com [47] ja hiljem uuritakse, kas seda meetodit on võimalik laiemalt kasutusele võtta, tuginedes Eesti elektrivõrgu ja arvesti andmetele. Lahenduse väljatöötamine annab *käed-küljes* meetodil tutvuda tarbija tuvastamise lahenduse süsteemi eri osadega, et mõista kuidas töötavad olemasolevad turul pakutavad lahendused. Lahenduse väljatöötamise printsiip on joonisel 2.1.




Joonis 2.1 Tehniline lahenduse idee voodiagrammina

Esiteks on vaja läbi viia mõõtmised ja leida elektritarbijate tunnused.

2.1 Voolu ja pinge mõõtmine

Tehnilise idee mõõteseadete on pärit veebilehelt LeChacal.com. Antud seade koosneb RaspberryPi [48] miniarvutist, sellele ühendatud mõõteseadmest ning mõõteseadme külge ühendatud voolutrafodest ja pingemuundurist. Mõõdetud andmete liikumine komponentide vahel on esitatud joonisel 2.2.



Joonis 2.2 Mõõdetud andmete liikumine

Sensoriteks on seadmel voolutrafo SCT013-100 [49] (joonis 2.3) ja vahelduvvoolu pingemuundur ZMPT 3X v3.0 [50] (joonis 2.4). Voolutrafo koosneb ferriitsüdamikust ja seda katvast plastikust. Voolutrafo on avatav ning seda on võimalik juhtme ümber paigaldada, midagi lahti ühendamata. Voolutrafo sisendiks on vool 0 kuni 100 A ja väljundiks vool 50 mA. Voolutrafol on teiste seadmetega ühendamiseks standardne 3,5 mm pulkpistik TRS, mille leiab sageli audio seadmetelt.



Joonis 2.3 Voolutrafo SCT013-100

Vahelduvvoolu pingemuundur ZMPT 3X v3.0 koosneb sisendklemmist, kuhu ühendatakse 230 V toiteahela neutraal ja faas. ZMPT 3X mõõteseadmel on kolm pinge sisendit. Seadme väljundiks on kolm madalamat vahelduvpinge signaali, mis edastatakse RPICT mõõteseadmele standardse 2,1 mm alalispinge pistikupesaga vahendusel.



Joonis 2.4 Vahelduvvoolu pingemuundur ZMPT 3X v3.0

RPICT seadme jaoks on vaja mõõdetud signaal sobitada, et mõõtevahemik oleks soovitud vahemikus. Antud seadmel on soovitud vahemik $\frac{V_{ref}}{2} = \pm 2,048 \text{ V}$. Voolutrafo sobitamiseks on seadmele lisatud sobiva suurusega takisti ehk šunt. Mudelil SCT013-100 on sobiv takisti väärtus 27Ω . RPICT voltmeetri mõõtevahemik on $0,15 \text{ V}$. Pinge väärtus on efektiivväärtusena. Selle vahemiku saamiseks võimendatakse pinget üles võimendiga.

RPICT seadmel on MCP3208 [51] analoog-digitaal konverter mis muudab mõõdetud analoog signaali diskreetseks digitaalseks väärtuseks. Konverter on 12 bitine. Antud digitaalsed algväärtuse edastatakse mikrokontrollerile töötlemiseks.

RPICT seadmel on andmete töötlemiseks ATmega328 [52] mikrokontroller. Sama tüüpi mikrokontroller on Arduino UNO [53] mikrokontrolleril. Mikrokontrolleri eesmärk on lugeda analoog-digitaal konverteri väljundi vahelduv signaal ning teisendada see antud signaali efektiivväärtuseks. Efektiivväärtust kasutatakse pinge ja voolu väärtuste iseloomustamisel. Mikrokontroller kasutab soovitud väärtuste arvutamisel valemeid (2.1)(2.2)(2.3) [54].

$$I_{ef} = \sqrt{\left(\frac{1}{N} \sum_{k=1}^N I_{[k]}^2\right)} \quad (2.1)$$

Kus I_{ef} – voolu efektiivväärtus, A
 N – ette antud hetkeväärtuste arv
 $I_{[k]}$ – voolu hetkeväärtus, A

$$U_{ef} = \sqrt{\left(\frac{1}{N} \sum_{k=1}^N U_{[k]}^2\right)} \quad (2.2)$$

Kus U_{ef} – pinge efektiivväärtus, V
 N – ette antud hetkeväärtuste arv

$U_{[k]}$ – pinge hetkeväärtus, V

Aktiivvõimsuse arvutamiseks kasutatakse valemit (2.3). Valem ei kasuta aktiivvõimsuse arvutamiseks voolu ja pinge efektiivväärtuseid. Võimsus arvutatakse, kui hetkeväärtuste keskmine aja jooksul.

$$P = \frac{1}{N} \sum_{k=1}^{k=N} U_{[k]} I_{[k]} \quad (2.3)$$


Kus P – aktiivvõimsus, W

N – ette antud hetkeväärtuste arv

$U_{[k]}$ – pinge hetkeväärtus, V

$I_{[k]}$ – voolu hetkeväärtus, A

Mikrokontroller saadab töödeldud mõõteandmed edasi RaspberryPI arvutisse, milles on võimalik andmeid viia lihtsalt arusaadavale kujule. RPICT mõõtesead (joonis 2.5) on RaspberryPi HAT(*Hardware Attached on Top*) ja seadme saab RaspberryPiga ühendada 40-ne kontaktiga GPIO (*General-Purpose Input/Output*) viigu abil.



Joonis 2.5 Mõõtesead RPICT4V3

Andmete ülekandmiseks RPICT seadmest RaspberryPi'sse kasutatakse jadaliidest UART (*universal asynchronous receiver/transmitter*). RaspberryPI arvutis on Pythoni rakendus, mis loeb jadaporti kirjutatud info ja kirjutab selle info CSV faili hilisemaks andmetöötluks .

2.1.1 Mõõtmisel kasutusel olevad seadmed ja komponendid

Mõõtmiste läbiviimiseks komplekteeriti seadmekomplekt oluliste komponentidega.

Joonisel 2.6 on numbri alusel tuvastatavad komponendid.

- 1) Mõõteseade RPICT4V3 1tk
- 2) Miniarvuti Raspberry Pi 3B+ ja toiteplokk 5,1 V / 2,5 A 1tk
- 3) Voolutrafo sct-013-000 3tk
- 4) Toitejuhtme komplekt, millel on eraldatud faas ja neutraal 3tk
- 5) Juhtmete komplekt pinge mõõtmiseks 1tk
- 6) Pinge mõõtmise seade ZMPT 3X v3.0 1tk
- 7) Juhtmed madaldatud vahelduvpingele 3tk
- 8) Seadmete paigaldusplaat 1tk
- 9) Andmeside kohtvõrgu ruuter ja toiteplokk 1tk
- 10) Pikendusjuhe 1tk
- 11) Pistikupesad 230 V / 16 A 3tk

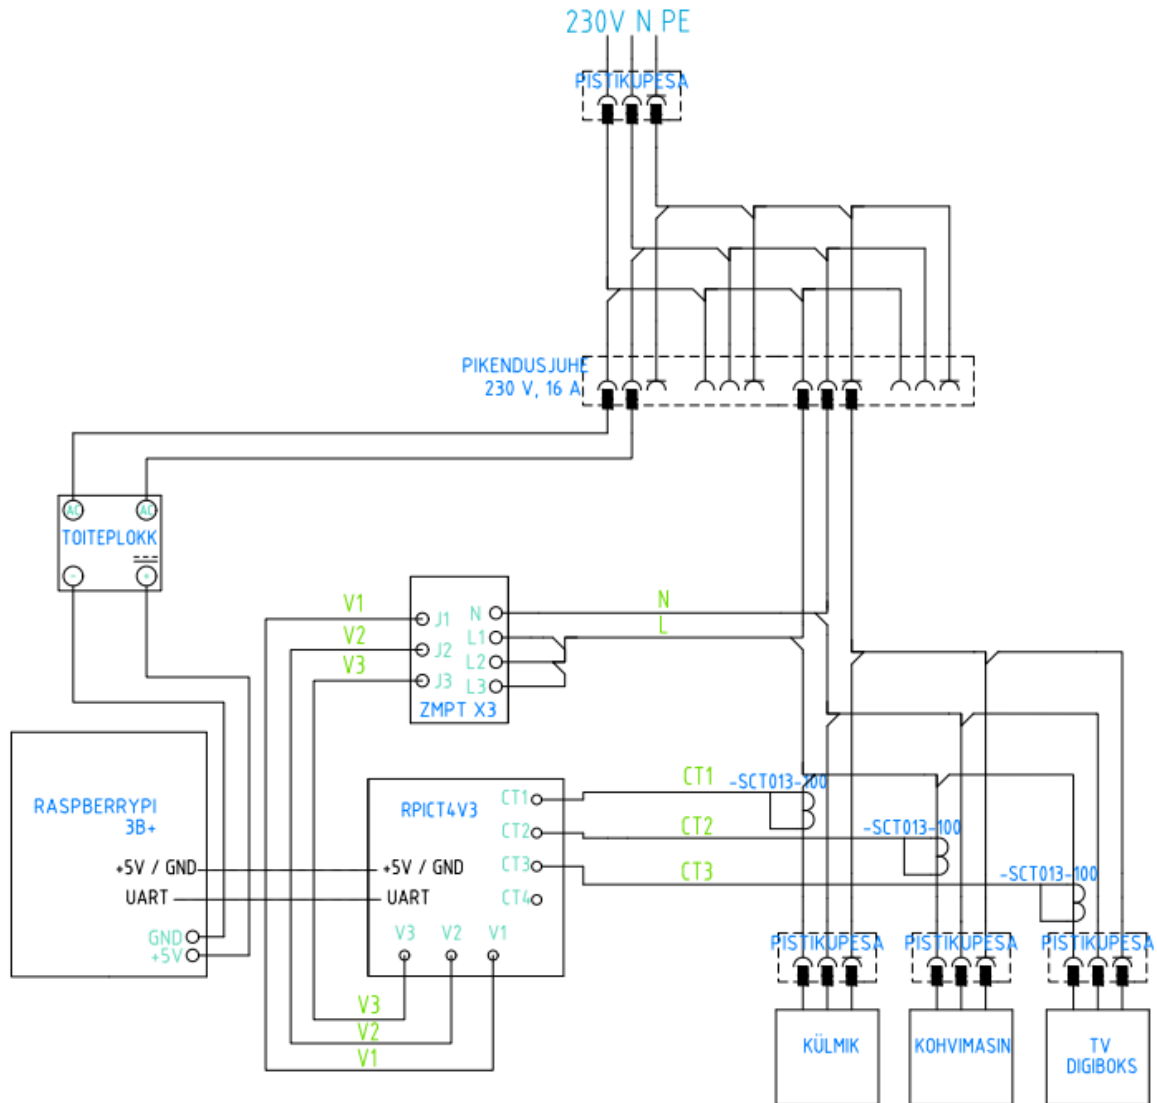
Joonisel 2.6 on seadmekomplektiga kolme elektritarbija mõõtmine. Külmik ja kohvimasin on mõõtekomplektile külge ühendatud pikendusjuhtmetega. Televiisor ja digiboks on vahetult mõõtekomplekti pistikupesasse ühendatud, kuna mõõtekomplekt oli mõõtmiste läbiviimisel televiisorilaua all.



Joonis 2.6 Mõõtmiste läbiviimine. [1] RPICT4V3, [2] raspberry Pi 3B+, [3] voolutrafo sct-013-000, [4] toitejuhtmed, [5] juhtmete komplekt pingemõõtmiseks, [6] ZMPT 3X v3.0, [7] madaldatud vahelduvpinge juhtmed, [8] paigaldusplaat, [9] kohtvõrgu ruuter, [10] pikendusjuhe, [11] pistikupesa 230 V / 16 A.

2.1.2 Mõõteskeem

Mõõtmiste läbiviimise skeem on joonisel 2.7. Voolutrafod on paigutatud vahetult kodumasinatete toitepistikute ette.



Joonis 2.7 Kolme seadme mõõtmine eraldi

2.1.3 RPICT4V3 kasutamine

RPICT mõõteseadet on võimalik ise seadistada ja modifitseerida. Seadistamise ja modifitseerimisel on abiks põhjalik veebileht lechacal.com/wiki/. RPICT4V3 kontrolleri algsetes seadistustes järgi lugema igal faasil voolu, pinget ja arvutama võimsust. Vaikimisi ei ole RPICT seadmega kaasas pinget mõõtmise seadet ZMPT ning vaikimisi seadete järgi on pinget väärtus defineeritud konfiguratsiooni failis `lcl-rpict-config.py`. Sellisel meetodil ei ole aga võimalik täpselt hinnata aktiivvõimsust.

Seadmest sobivate väärtuste saamiseks on vaja seadet konfigurida. Muuta seadet selliselt, et seade mõõdaks vaid ühe faasi voolu ja pinget selle faasi ja neutraali vahel ning seadistada mõõteseadet arvutama korrektset aktiivvõimsust.

Seade millega mõõtmisi läbi viidi oli vanema püsivaraga. Vanem püsivara lubas RPICT seadistamist RaspberryPi OS programmi käsurealt. See tähendas veebikeskkonnas sobiva konfiguratsiooni koostamist. Konfiguratsiooni salvestamist konfiguratsiooni faili, faili liigutamist RPICT4V3 seadmesse ning faili kirjutamist RPICT seadmesse käsuga *lcl-rpict-config.py -a -w my_file.conf*. Kuna RPICT4V3 seadmel puudus automaatne taaskäivitus, siis lisaks oli vaja seadmel kaks viigu PINi lühistada, et käsurealt käivitatud rakendus RPICT seadmesse uue seadistuse kirjutaks. Seetõttu on tegemist ajakuluka meetodiga.

Antud seadme tootjal on veebis põhjalikud juhendid. Juhendites on näide ka selle kohta kuidas on võimalik RPICT seadet kaasajastada ning teostada seadistamise protsess veebi keskkonnast. Veebikeskkonnast uuendamiseks oli vaja ühtlasi uuendada seadme püsivara. Püsivara uuendamiseks oli vaja Arduino UNO arendusplaati kuna Arduino ja RPICT4V3 seadmel on sama tüüpi mikrokontroller. Arduino UNO ja seadme programmeerimise tarkvara Arduino IDE võimaldab uusi Arduino programme mikrokontrolleri EEPROM mälusse kirjutada. Peale programmide loomist ja neile sobivate teekide lisamist, tekkis võimalus protsessor uuendada Arduino UNO arendusplaadil. Peale seda oli uuendatud mikrokontroller võimalik ümber tõsta RPICT seadmesse. Muudetuna oli seadet kiirelt võimalik seadistada. Peale *lcl-server.sh* käivitamist tekkis võimalus RPICT seadet seadistada vahetult veebirakenduse abil.

Mõõtmiste läbiviimiseks oli täiendavalt vaja alla laadida lcl-gateway tööriist, mis korrektselt seadistatuna kirjutab soovitud kohta RaspberryPi arvutisse CSV formaadis faili. CSV fail sisaldas ajatemplit ja mõõdetud aktiivvõimsust iga volutrafo kohta.

2.1.4 Tarbijate mõõtmine

Masinõppe mudeli loomiseks on vaja suurel hulgal lähteandmeid. Mida rohkem on algandmeid, seda põhjalikum ja täpsem mudel on võimalik koostada. Selle tõttu kasutavad paljud disagegeerimise kohta tehtud teadustööd vabalt kättesaadavaid algandmeid, näiteks UK-DALE ja REDD. Andmeid kasutatakse mudelite loomiseks ning nende andmete põhjal testitakse loodud algoritmi. Antud töös kasutatakse RPICT mõõteseadmega mõõdetud andmeid. Lähteandmete saamiseks võeti kolm levinud elektritarbijat. Külmik, kohvimasin ja televiisor koos digiboksiga ja mõõdeti nende seadmete aktiivvõimsused 10 päeva jooksul. Mõõtesagedus oli üks hertz. Elektriseadmete elektrilised parameetrid on tabelis 2.1.

Televiisor koos digiboksiga valiti, kuna antud seade on enamikes majapidamistes olemas ning seade tarbib vähe energiat. Selle tõttu on seadet keeruline tuvastada ja see võimaldab lihtsamalt hinnata masinõppe võimekust. Lisaks oli teadusartiklis *IMG-*

NILM: A Deep learning NILM approach using energy heatmaps [35] samuti televiisorit proovitud tuvastada.


Kohvimasin valiti, kuna seadme elektrienergia kasutuse profiil on omapärase kujuga. Lisaks on seadme kasutus ebaregulaarne ja päeva jooksul kasutatakse masinat suvalistel aegadel. Mitmed UK-DALE andmebaasi kasutavad teadustööd tuvastasid seadmeid peamiselt nende kasutusaegade järgi. Kohvimasina ebaregulaarne kasutamise muster on raskemini tuvastatav kui mõne teise seadme regulaarne kasutus.

Külmik valiti, kuna antud seade on pidevalt töös. Kui seade on pidevalt kasutusel, siis on samal ajal kasutusel mõni teine mõõdetavatest seadmetest ning disagregerimist on võimalik teostada.

Tabel 2.1 Elektritarbivate andmed

Seadmete elektrilised parameetrid					
					
Elektritarbija	Külmik	Kohvimasin	Televiisor	Digiboks	
Tootja	Hisense	DeLonghi	LG	Netgem	MOSO
Mudel	RB438N4EC2	ECAM 22.110.SB	40UH630V-ZA	N7800-T2C- 4-AB2	MSP- C1500IC12.0- 18F-DE
Võimsus W	*	1450	85	*	*
Energiakulu kWh	258	*	*	*	*
Toitepinge	*	220-240V 50- 60Hz	100-240V 50/60Hz 0,85A	12V 1500mA	100-240V 50/60Hz 0,6A max

Joonisel 2.8 on näidatud ühel joonisel kolme voolutrafo poolt mõõdetud aktiivvõimsuse tarbimised ühe päeva jooksul.



Joonis 2.8 Seadmete aktiivvõimsuse mõõteandmed sekundilise perioodiga.

Joonise 2.8 sinine graafik kujutab külmiku pidevalt tsükliliselt toimuvat elektrienergia tarbimist, millel on üksik pikem ja intensiivsem tsükkel. Punane graafik kujutab kohvimasina juhusliku ja ebaühtlast elektritarbimist. Kollane graafik kujutab Televisori/digiboksi ühtlast energiatarbimist töörežiimis.

2.2 Masinõpe

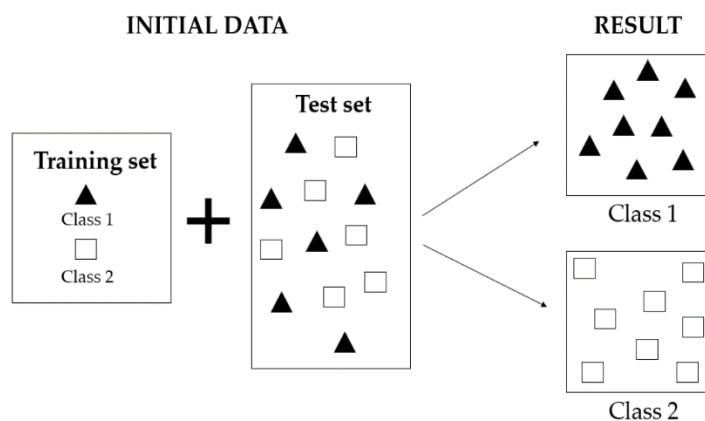
Masinõpe on tihedalt seotud arvutiteaduse, tehisintellektiga ja andmekaevega. Lühidalt tähendab see, et arvutid töötlevad andmeid ja otsivad neist andmetest mustreid ja kohandatavaid käitumisi. Mida rohkem ja detailsemad on andmed ning mida suurem on arvutusvõimsus, seda täpsemalt on võimalik andmete põhjal mingisuguseid järeldusi teha. [55] Masinõppe meetodite rakendamisel tehakse üldjuhul järgmist. Kui on olemas mingi algandmestik, siis sellest valitakse 60% andmeid, mille põhjal loob algoritm seosed andmete vahel. Järele jäänud 20% andmete alusel hinnatakse, kas masinõppe algoritmi poolt leitud seosed kehtivad ehk valideeritakse ning viimast osa 20% andmetest kasutatakse kui testandmeid tulemuste saamiseks.

Masinõppe meetodid jagatakse neljaks:

- Juhendatud õpe
- Juhendamata õpe
- Stiimulõpe
- Tehisnärvivõrgud

2.2.1 Juhendatud õpe

Juhendatud õpe seisneb selles et kui on olemas mingisugused andmed või keerulisema struktuuriga objekt, siis neid andmeid on võimalik töödelda ettemääratud meetoditega. Ette on võimalik anda andmete klassid ning siis on neid andmeid võimalik klassifitseerida mõne tunnuse järgi, kus mudel proovib sisendandmed jagada klassideks. [56] Joonisel 2.9 on diagramm, mis kirjeldab juhendatud õppe olemust. Esiteks õpib algoritm treenimise käigus olemasolevate andmete järgi andmeid klassideks jagama ning kui algoritmile antakse ette uued andmed, siis on võimalik ilma treenimata kohe andmetele klass määrata. Kui näiteks päeva keskmine elektrihind varieerub 50 eurost 350 euroni, siis need hinnad on võimalik klassideks jagada. Näiteks: väga madal, madal, kõrge, väga kõrge, siis andes ette väärtuse 250. Leiab algoritm, et tegemist on kõrge hinnaga.



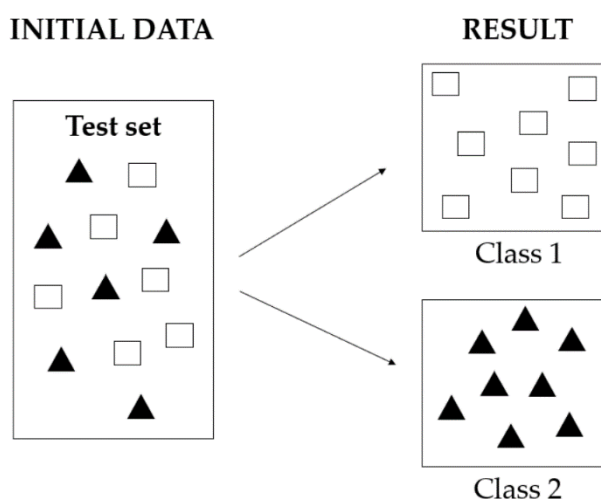
Joonis 2 . 9 Juhendatud õppimine [57].

Juhendatud õppe teiseks võimaluseks on regressioon, kus algandmete järgi proovitakse leida neid andmeid iseloomustavat funktsiooni. Peale mudeli treenimist on võimalik funktsioonile sisend andmeid ette anda ning funktsioon arvutab väljundi. Antud meetodit iseloomustab näiteks elektri tarbimise graafik nädala jooksul. Kui algoritm loob seosed mitmeid nädala tarbimisgraafikuid uurides, siis on võimalik teada saada tarbimine mõnel kindlal päeval.

Antud näited on lihtsad ning lahendatavad ka statistikat kasutades. Kui muutujaid on rohkem ja seosed on keerulisemad ja mitme muutuja vahel, siis tulevad välja masinõppe kasutamise eelised.

2.2.2 Juhendamata õpe

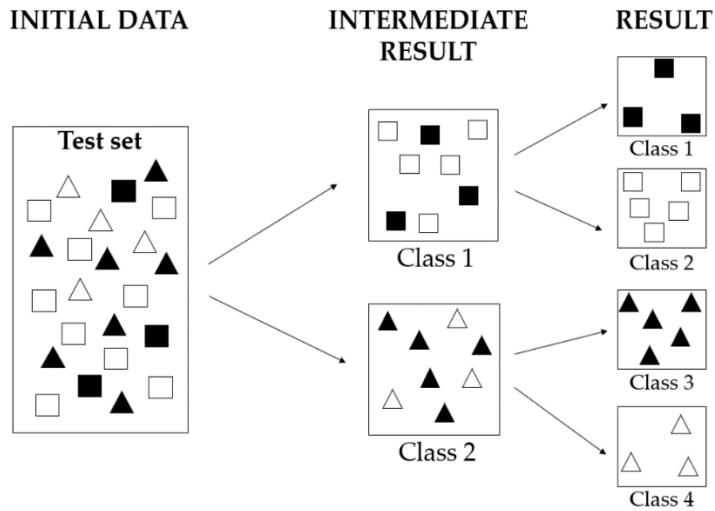
Juhendamata masinõppe puhul on ette antud vaid sisendandmed ilma vastavate väljunditeta ning eesmärgiks on nende seast leida võimalike seoseid. Idee on leida mõni struktuur või muster andmehulgast ja jagada see osadeks. Joonisel 2.10 on diagramm, mis kirjeldab juhendatud õppe olemust. Antud juhul on ülesanne vähem defineeritud, kuna ei ole ette antud, missuguseid mustreid otsida ja puudub ka selge suurus, mida kasutada veana. Kõige levinum näide juhendamata õppe kohta on klasterdamine ehk andmete grupeerimine tulenevalt „kaugusest“, „lähedusest“ või „sarnasusest“. Lisaks on võimalik andmehulgast erandeid leida ning suurandmetest tunnuste vahelisi seoseid õppida.



Joonis 2 . 10 Juhendamata õppimine [53].

2.2.3 Stiimulõpe


Stiimulõpe proovib aru saada korduvate sündmuste mustreid ja proovib neid üldistada. Joonisel 2.11 on kirjeldatud stiimulõpet. Eesmärk on minimeerida vigu ja suurendada täpsust. Algoritm õpib arvutades analüüsima iga oma sammu tulemust ning proovib leida suurimat preemiat. Stiimulõppes on agent, mis sobitub keskkonda. Stiimulõppe peamine idee on leida balanss tundmatu keskkonna ja teada väärtuste vahel.



Joonis 2 . 11 Stiimulõpe [53].

2.2.4 Tehisnärvivõrgud

Tehisnärvivõrgud on laialt kasutatav masinõppe meetod. Tehisnärvivõrk saab olla juhendatud, juhendamata ja stiimulõppe põhinev. Tehisnärvivõrk põhineb bioloogilisel närvisüsteemil ning koosneb neuronitest, mis koosneb sisendist, ühendusest ja väljundist. Diagramm joonisel 2.12 . Tehisnärvivõrgud ei ole programmeeritud vaid nad on õppivad. Õppimine on tehisnärvivõrgu peamine eelis teiste algoritmide ees. Tehniliselt õppimine on koefitsientide väärtuste leidmine neuronite vahel. Treenimise protsessis on tehisnärvivõrk võimeline tuvastama keerulisi sõltuvusi sisendite ja väljundite vahel ning on võimeline üldistama. See tähendab, et õigel treenimisel on närvivõrk võimeline andma korrektse tulemuse ka siis kui treenimise andmed on vigased või puudulikud. [57]



Joonis 2 . 12 Tehisnärvivõrk [53].

Siin tuleb välja ka masinõppe probleem, kui kasutatud andmestikud on keerukad ja seosed andmete vahel ei ole näha, siis on raske masina otsuseid usaldada ning kui masinõpe annab väär tulemust, ei ole võimalik aru saada mis väär arvutuse põhjustas. Lisaks kui keskkonnad muutuvad, siis väljatöötatud mudelid enam ei ole kasutatavad.

Masinõpe tähendab paljude varasemate andmete põhjal tarbijat iseloomustavate väärtuste kokku kogumist. Nende väärtuste põhjal on võimalik luua iga tarbijat iseloomustav mudel. Uute mõõteandmete mõõtmisel on võimalik tarbijat võrrelda mudeliga ning sarnasuse tuvastamisel masin tunnistab tarbijad mõnda kindlasse klassi kuuluvaks.

2.3 Masinõppe tööriistad

2.3.1 PyTorch, TensorFlow, Keras

Järgmine samm on rakendada masinõpet realselt probleemide lahendamisel. Masinõppe rakendamiseks on osa tööd ära tehtud ning ettevõtted Google ja Facebook on loonud kasutamiseks tarkvaralised tööriistakomplektid. Google on loonud Keras API. See on vabavaraline süvaõppevõrgu teekide kogum. Keras abil on võimalik kiirelt teha eksperimente. Google on samuti loonud vabavaralise süvaõppe raamistiku TensorFlow, mis on hea dokumentatsiooni ja treeningmaterjalidega. TensorFlow on *symbolic math*

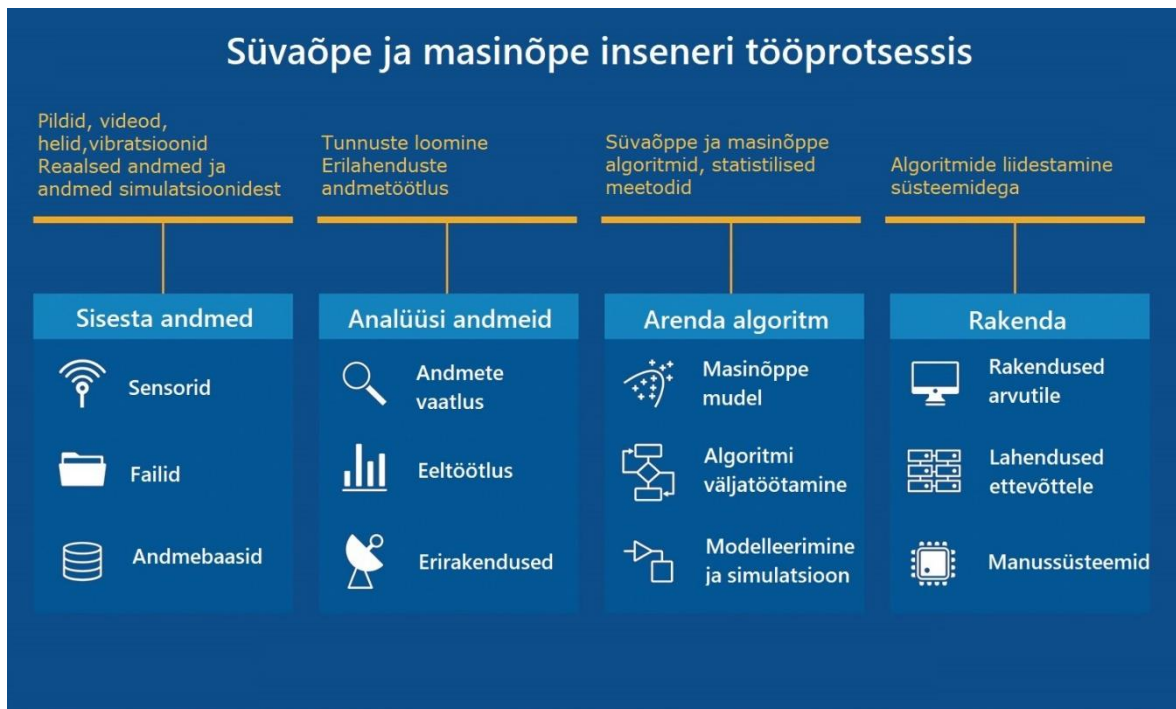
library, mida on kasutatud närvivõrkude programmeerimiseks ning sobib reaalaaja andmete töötamiseks.

PyTorch on Torchil baseeruv süvaõppe raamistik.. PyTorch'i on arendanud Facebook ja on samuti vaba-varaline. PyTorch on lihtne, lihtne kasutada, paindlik, efektiivse mälu kasutamisega ja *Dynamic Computation Graphs* [58] ja seda kasutatakse peamiselt tekstide töötlemisel.

Antud kolme rakenduse kohta on võimalik leida palju informatsiooni kuidas neid tööriistu oma probleemide lahendamiseks on võimalik kasutada. Tööriistade omavaheliseks suhtlemiseks saab kasutada ONNX (*Open Neural Network Exchange*) ning ühes eelnevalt nimetatud tööriistaga tehtud mudel on kasutatavad ka teistes tööriistades.

2.3.2 MATLAB®

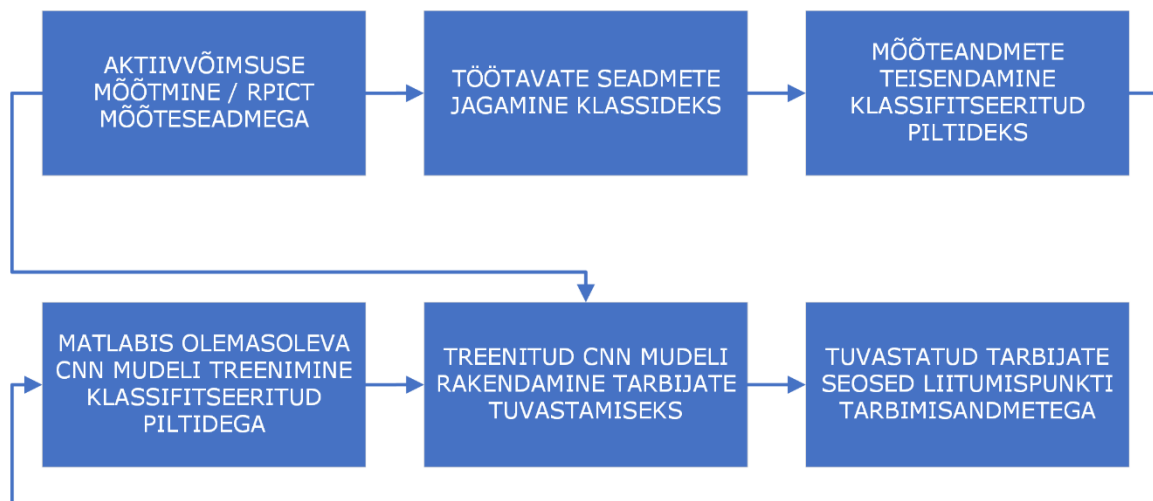
MathWorks'i MATLAB võimaldab samuti rakendada masinõppe meetodeid probleemide lahendamiseks. MATLABil on inseneriõppe tudengi jaoks see eelis, et programm on suunatud õppuritele ja inseneridele ning keel ja meetodid on lihtsamalt esitatud võrreldes mõne programmeerijatele suunatud lahendusega. Lisaks on MATLABiga seotud riistvaratõe moodulid, mis teeb loodud tarkvara rakenduste ühendamise riistvaraga lihtsamaks. MathWorks on loonud detailsed rakenduste loomise juhendid. Käesolev töö lahendus põhineb MathWorks'i Youtube'i keskkonna videoseerial *Deep Learning for Engineers*[39] ja MATLABi programmi juhendit *Classify Time Series Using Wavelet Analysis and Deep Learning* [59]. MATLAB loob eeldused kuidas tema tööriistu on võimalik rakendada erinevate reaalsete probleemide lahendamiseks ning on loodud ka raamistik kuidas prototüüpi luua (joonis 2.13). Selle tõttu töö valis autor programmi MATLAB masinõppealgoritmi tegemiseks.



Joonis 2.13 Joonis põhineb MathWorksi andmetel [60].

2.4 Masinõppemudeli koostamine


Masinõppe kasutamiseks viiakse läbi etapid (joonis 2.14). Esiteks viiakse läbi mõõtmised. Selle järel koostatakse seadmete klassid, mis kombinatsioonis kodumasinad olla saavad. Antud klasside põhjal koostatakse pildid ning piltidel olevate tunnustega treenitakse uus mudel. Peale treenimist kasutatakse mudelit tarbijate tuvastamiseks.



Joonis 2.14 Masinõppe kasutusega

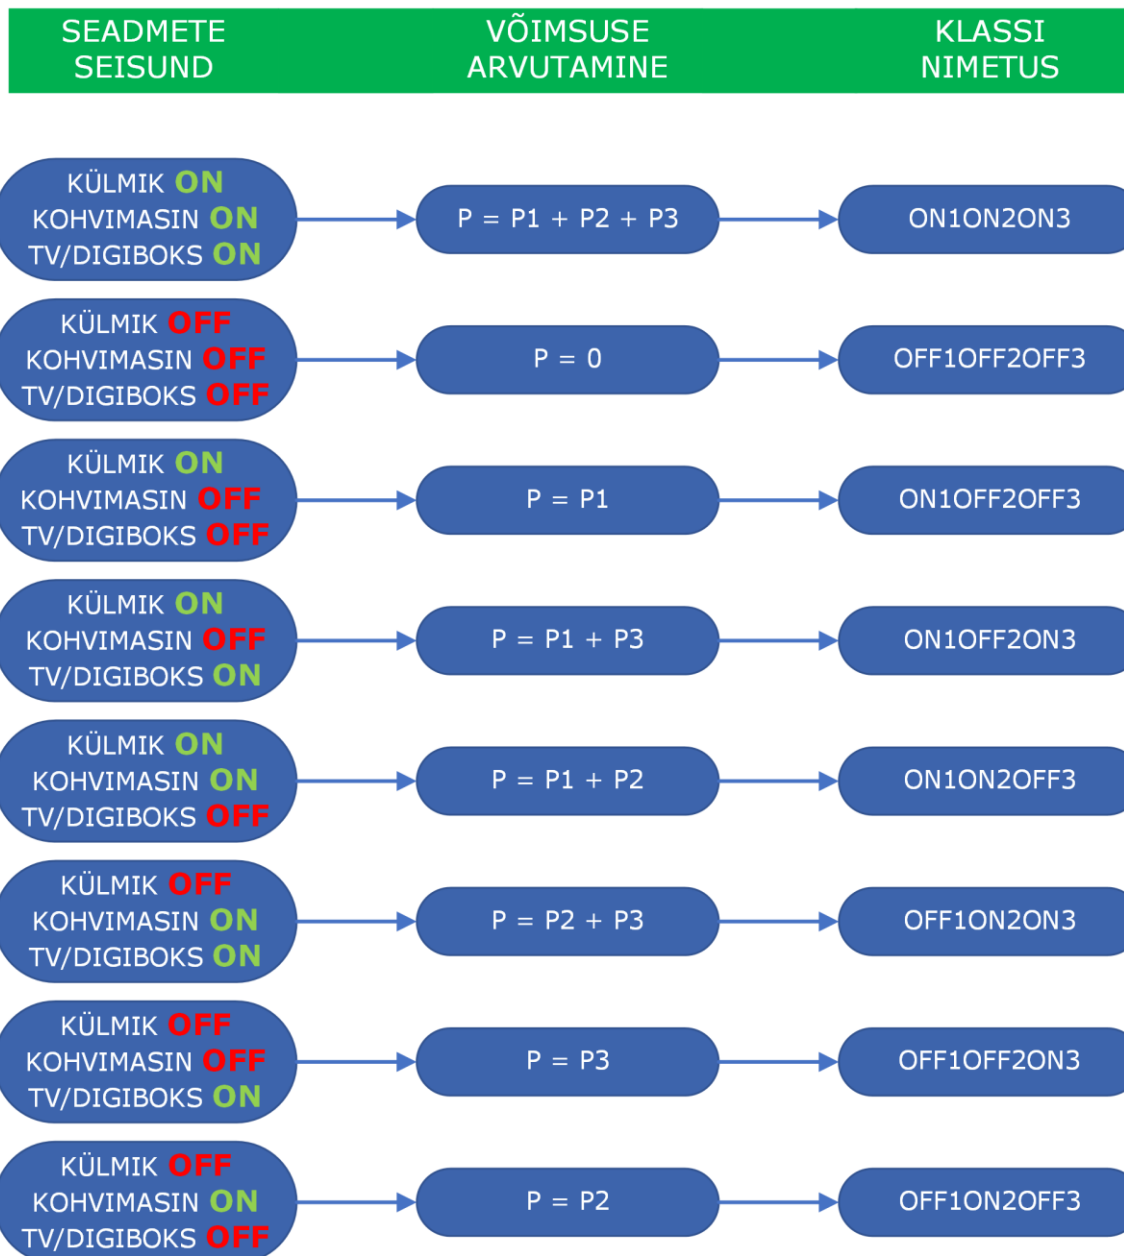
2.4.1 Mõõteandmete teisendamine RGB piltideks

Masinõppe mudeli loomiseks on vaja mõõteandmed analüüsida ja nende põhjal luua algoritm. Mudeli loomiseks tehti läbi joonisel 2.15 esitatud etapid.



Joonis 2.15 Masinõppe mudeli koostamine siirdeõppe meetodiga.

RPICT mõõteseadmest imporditi arvutisse CSV failid mõõteandmetega. Ühes CSV failis on terve päeva andmed mõõdetuna iga sekundi tagant. Failis on kolm võimsust P1, P2, P3. Mõõtmised viidi läbi kümnel päeval. CSV failid imporditi MATLABi programmi keskkonda ning moodustati tabel andmetega, mis sisaldas kolme võimsust P1, P2, P3. Eeldefineeriti klassid, mis olekus võivad RPICT mõõtekomplekti külge ühendatud elektritarbijad olla. Klassideks jaotamine otsustati selliselt, kuna tarbijate tuvastamist tehakse ühe tunni pikkuste ajavahemike kaupa ning individuaalsed tarbija tunnused on lühiajalise kestvusega. Klassid koostati joonisel 2.16 oleva reegli järgi.



Joonis 2.16 Mudeli klasside koostamise reeglid.

Tabeli esimeses veerus on esitatud võimalikud seadmete olekud. Teises veerus on arvutuskäik, kuidas arvutati agregeeritud tarbimise andmed. Kolmandas veerus on kirjas klassi nimetus.

Iga klassi kohta on vaja koostada klassi iseloomustavad andmed. Selleks on vaja teisendada MATLABi imporditud aegseeria andmed vastavalt klassi iseloomustava reegli järgi. Valem (2.4) kujutab klassi ON1ON2ON3 moodustamist.


$$P = P1 + P2 + P3 \quad (2.4)$$

Kus P – võimsuse agregeeritud väärtus

$P1, P2, P3$ – on elektritarbijate mõõdetud võimsus

Kui klassi defineerivad andmed on arvatatud, siis on võimalik suuruse P aegseeria andmed jagada tunni pikkusteks ajalõikudeks ning igast loodud tunnisest ajalõigust luua RGB (Red Green Blue värvimudeli) pilt. Antud pilt on tunnustega, mis iseloomustab antud klassi. Mõõtmised viidi läbi kümnel päeval ja iga tunni kohta on loodud iseloomulik RGB pilt. Kokku on alusandmeid klassi kohta 240. RGB pildid genereeritakse ja salvestatakse sobivasse kausta MATLABi programmi koodi abil. Iga klassi kohta on vaja koostada oma näidispiltide kaust ja antud kausta MATLABi koodiga genereerida pildid, mis iseloomustab kolme elektritarbija olekut ja olekute kombinatsioone. Joonis 2.17, joonis 2.18, joonis 2.19, joonis 2.20, joonis 2.21, joonis 2.22, joonis 2.23 ja joonis 2.24 iseloomustavad millistena piltideks teisendatud aegseeriad välja näevad. Tumesinine värv iseloomustab väga madalat aktiivvõimsust. Tumepunane iseloomustab väga kõrget aktiivvõimsust. Referents suuruseks on piltide juures 1500, millest suuremad võimsuse väärtused on sama tooni punasega.


Klass „OFF1OFF2OFF3“



Joonis 2.17 Klassi OFF1OFF2OFF3 iseloomustav pilt. Külmik ei tööta, kohvimasin ei tööta, televiisor ei tööta.

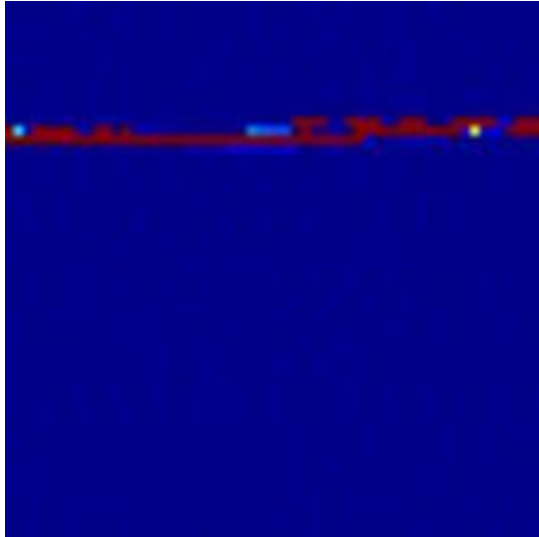
Klass „OFF1ON2OFF3“

Klass „OFF1OFF2ON3“




Joonis 2.18 Klassi OFF1OFF2ON3 iseloomustav pilt. Külmik ei tööta, kohvimasin ei tööta, televiisor töötab.

Klass „OFF1ON2ON3“




Joonis 2.19 Klassi OFF1ON2OFF3 iseloomustav pilt. Külmik ei tööta, kohvimasin töötab, televiisor ei tööta.

Klass „ON1OFF2OFF3“




Joonis 2.21 Klassi ON1OFF2OFF3 iseloomustav pilt. Külmik töötab, kohvimasin ei tööta, televiisor ei tööta.

Klass „ON1ON2OFF3“




Joonis 2.20 Klassi OFF1ON2ON3 iseloomustav pilt. Külmik ei tööta, kohvimasin töötab, televiisor töötab.

Klass „ON1OFF2ON3“




Joonis 2.22 Klassi ON1OFF2ON3 iseloomustav pilt. Külmik töötab, kohvimasin ei tööta, televiisor töötab.

Klass „ON1ON2ON3“



Joonis 2.23 Klassi ON1ON2OFF3 iseloomustav pilt. Külmik töötab, kohvimasin töötab, televiisor ei tööta.



Joonis 2.24 Klassi ON1ON2ON3 iseloomustav pilt. Külmik töötab, kohvimasin töötab, televiisor töötab.

Peale tunnustega piltide loomist on antud piltidega võimalik trennida CNN (*Convolutional neural network*) tehisnärvivõrk.

2.4.2 Tehisnärvivõrgu koostamine programmis MATLAB

Masinõppe mudeli koostamisel kasutatakse siirdeõppe meetodit. See tähendab et elektritarbijate tarbimist iseloomustavate piltide klassifitseerimiseks kasutatakse olemasolevat tehisnärvivõrgu mudelit. Siirdeõppe on vaja kasutada siis kui soovitud testandmeid ei ole piisavalt. Olemasoleva mudelina kasutatakse GoogLeNet'i [61] CNN mudelit, mis klassifitseerib esemeid tuhandeks esemeks aga antud juhul muudetakse olemasolevat mudeli selliselt, et mudel klassifitseerib sisend andmeteks olevad RGB pildid 1000 klassi asemel kaheksaks eelnevalt loodud seadmete klassiks.

GoogLeNet'i mudeli kasutab RGB pilte mille mõõdud on $224 \times 224 \times 3$ pikslit ja treenimiseks kasutatavad pildid on vaja konverteerida samasugusesse mõõtu. „ 224×224 “ iseloomustab pildi mõõte ja „ $\times 3$ “ iseloomustab kolme värvi skaalal 0 kuni 255. RGB pildi iga piksel on punasest, rohelisest ja sinisest värvist koosnev massiiv. Näiteks [0.8500 0.3250 0.0980].

Päevase kestvusega aegseeria teisendamisel tunniks, tekib 60×60 andmehulk, milles arvud väljendavad hulga dimensioone minutis ja sekundis. Andmehulk ise koosneb numbrilistest väärtustest, milles numbrid sümboliseerivad sekundis tarbitavat aktiivvõimsust. MATLABi programmi kood ühe päeva teisendamiseks klassi OFF1ON2OFF3 piltideks on joonisel 2.25.

```

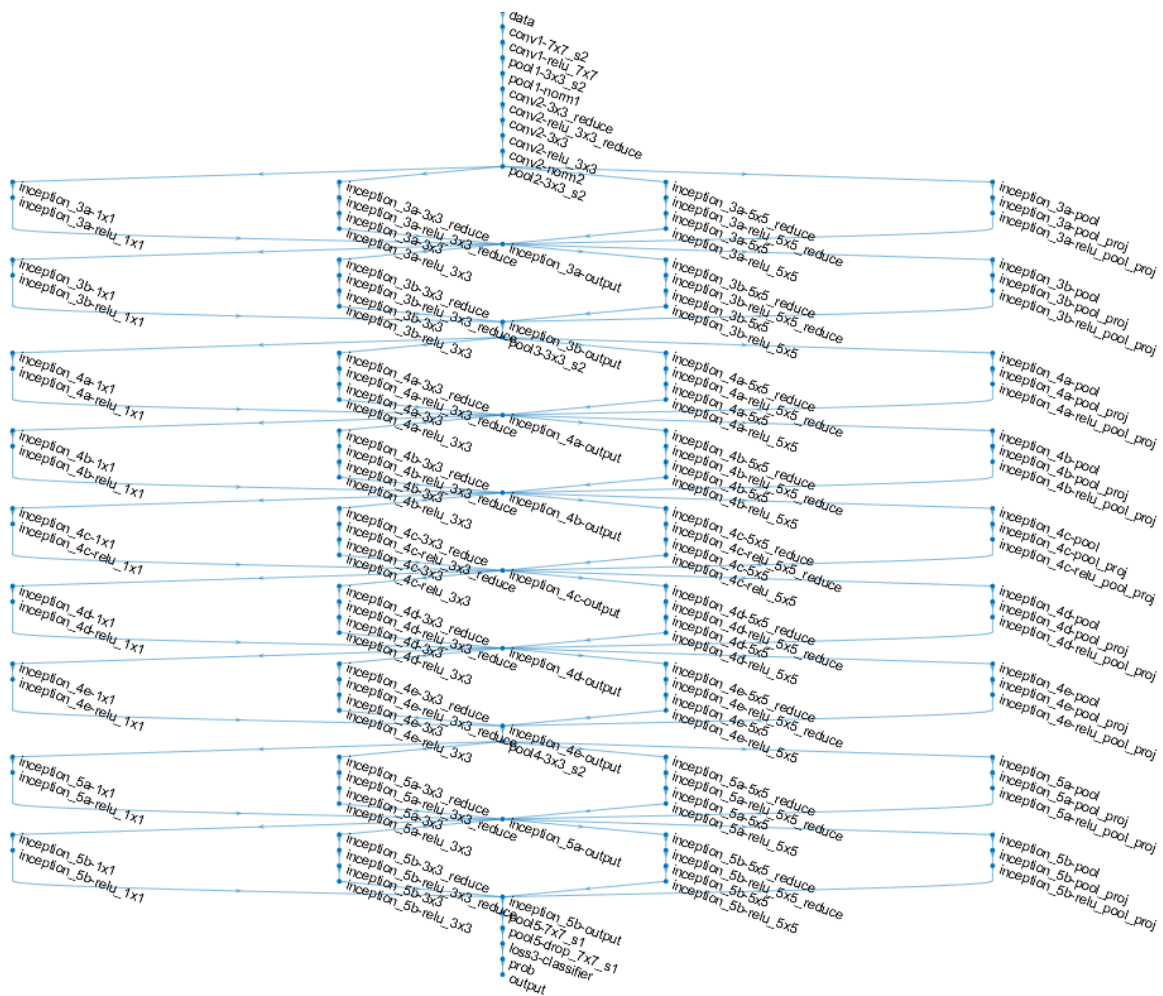
PAEV2 = PAEV2A; % Aegseeria andmete salvestamine tabelisse

PAEV2.P = PAEV2.P2; % Klassi OFF1ON2OFF3 reegel P-le P2
% omistamine
PAEV2.P1 = []; % P1 väärtuse kustutamine
PAEV2.P2 = []; % P2 väärtuse kustutamine
PAEV2.P3 = []; % P3 väärtuse kustutamine
Z2 = table2array(PAEV2)'; % Tabel massiiviks ja selle transponeerimine
FZ2 = paddata(Z2,86400); % Puuduvate sekundite lisamine massiivile
FZ2(1,86400) = SUURIM; % Referentssuuruse lisamine
FZN2 = normalize(FZ2); % Väärtuste normaliseerimine
FZNR2 = round(rescale(FZN2,0,255)); % Väärtuste skaleerimine 0 - 255
for jj = 1:24
    tunnid(jj,:) = FZNR2(1,(1 + 3600*(jj-1)):(3600*jj));
    for ii = 1:60
        ruut(ii,:) = tunnid(jj,(1 + 60*(ii-1)):(60*ii));
    end
    min = (1:60); % Minuti-telg
    sek = (1:60); % Sekundi-telg
    eng = ruut(min,sek); % Aktiivvõimsuse iseloomustus
    pilt = ind2rgb(eng,jet(128)); % Pilt 60 x 60 x 3
    pilt224x224 = imresize(pilt,[224 224]); % Pilt 224 x 224 x 3
    imwrite(pilt224x224,KAUST+num2str(jj)+"2.jpg","Comment","N");
    % Unikaalse nimega faili kirjutamine kassi kausta
end

```

Joonis 2.25 MATLABi kood aegseeria teisendamiseks.

GoogLeNet CNN tehisnärvivõrgu mudel koosneb 144 kihist. Mudelil on vaja muuta kolme närvivõrgu kihti, et seda oleks võimalik kasutada käesolevas rakenduses.



Joonis 2 . 26 GoogLeNet mudeli 144 kihti.

Igat kihti tehiskärgvõrgu arhitektuuris võib võtta kui filtrit. Eesmised kihid identifitseerivad tavalisemaid tunnuseid nagu plekid, servad ja värvid. Hilisemad kihid keskenduvad spetsiifilisematele väärtustele mis aitavad detaile kategoriseerida [59]. Kihide nimetuste inglise – eesti keele tõlked on veebilehelt *Data Science Estonia* | Eesti andmeteaduse koostöö [62]. Mudel koosneb järgnevatest tehiskärgvõrgu kihtidest.

- *Image Input* – pildi sisend. Antud kiht võtab sisendiks 224-224-3 RGB pildi.
- *2-D Convolution* – 2D konvolutsiooniline kiht ahendab kihi pikslid kindla suurusega matriksi abil teiseks kihiks, koos kaasnevate kaaludega.
- *ReLU* - mittenegatiivne lineaarfunktsioon – kiht mis muudab künnist mitte ületavad negatiivsed sisendid nulliks.
- *2-D Max Pooling* – 2D maksimumi ahenduskiht – kiht mis teeb alladiskreetmise, võttes sisendiks riskülikukujulise ahendi ja arvutab selle ahendi suurima väärtused.

- *Cross Channel Normalization* – kanaliülene normaliseerimine – arvutab ja asendab normaliseeritud väärtusega iga sisendi, võttes arvesse lähedal asuvate sisendite väärtused.
- *Depth concatenation* – sügavuse konkatenatsioon – kiht, mis võtab sama laiuse ja kõrgusega sisendid ja ühendab need.
- *2-D Global Average Pooling* – 2D globaalse keskmise ahenduskiht - kiht mis teeb alladiskreetmise, arvutades sisendi kõrguse ja sisendi laiuse keskmise.
- *Fully Connected* - täissidus kiht, täielikult ühendatud kiht – korrutab sisendi kaalude matriksiga ja lisab kallutatuse vektori.
- *Softmax* – softmax-kiht – ülekandefunktsiooni kiht, mis võtab sisend matriksi väärtused ja teisendab selle väljund matriksiks, mille väärtused annavad kokku tõenäosusliku ühe.
- *Classification Output* – klassifitseerimise väljund – kiht annab väljundiks klassi nimetuse.

GoogLeNet tehisnärvivõrgul muudetakse kolme kihti. Joonisel 2.27 on väljatoodud GoogLeNet tehisnärvivõrgu viis viimast kihti.



Joonis 2.27 Muudetud tehisnärvivõrgu kihid

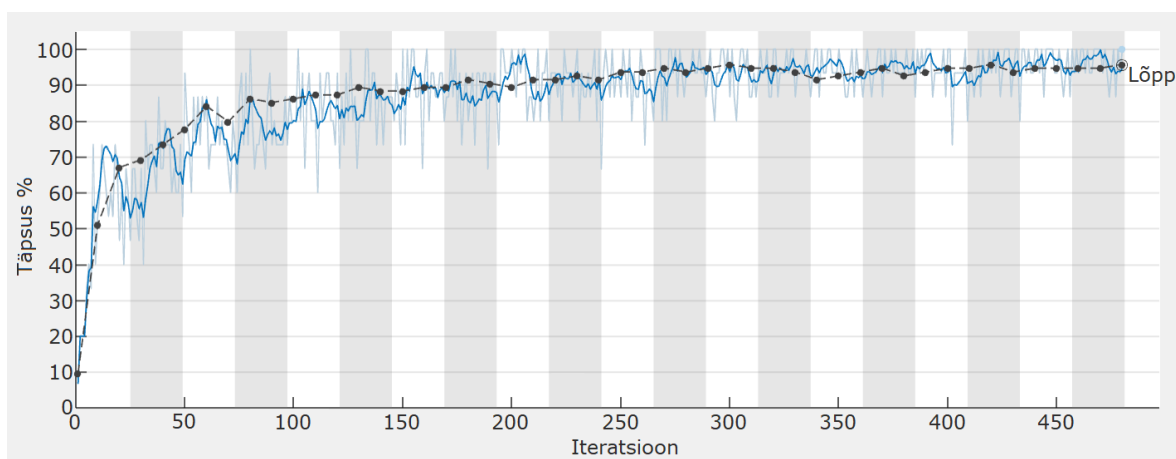
- *pool5-drop_7x7_s1* -> *new_Dropout*. Antud kiht vähendab ülesobitamist. Ülesobitamise kiht seab etteantud tõenäosusega sisendeid juhuslikult nulliks. Vaikimisi tõenäosuse väärtus 0,5 muudetakse 0,6.

Kihid *new_fc* ja *new_classoutput* sisaldavad infot kuidas teisendada eelnevates kihtides õpitud tunnused väljund klassi tõenäosuseks, kao väärtuseks ja ennustatavaks nimetuseks.

- *loss3 - classifier* -> *new_fc*. Uus konvolutsiooniline kiht, milles on klasside arvuga sarnane arv filtreid. Uute kihtide kiiremaks õppimiseks. Suurendatakse õppimise määra tegurit.
- *Output* -> *new_classoutput*. Antud kiht määrab millisteks klassideks tehisnärvivõrk sisendi klassifitseerib.

2.4.3 Masinõppe mudeli treenimine

Mudeli treenimiseks on vaja RGB pildid jagada kahte ossa. 80% piltidest kasutatakse andmete treenimiseks ja sellest ülejäänud 20% kasutatakse treenitud mudeli hindamiseks. Närvivõrgu treenimine on iteratiivne protsess, mis hõlmab kaofunktsiooni minimeerimist. Kaofunktsiooni minimeerimiseks kasutatakse gradientlaskumise algoritmi. Igas iteratsioonis hinnatakse kaofunktsiooni gradienti ja värskendatakse laskumisalgoritmi kaalusid [62].

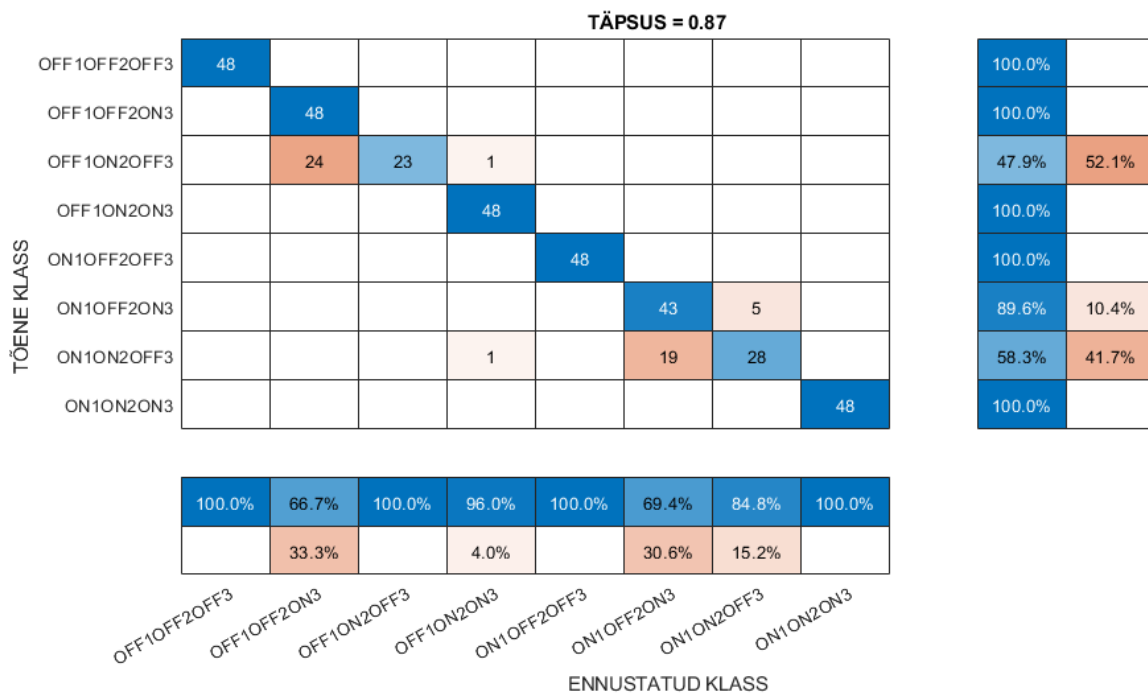


Joonis 2.28 Masinõppe mudeli treenimise väljavõte programmist MATLAB.

Joonis 2.28 kujutab treenimise kulgemist. Treenimisel kasutati Intel(R) Core(TM) i5-6500 CPU @ 3.20GHz protsessorit. Treenimiseks kulus 19 minutit ja 51 sekundit. Joonis 2.28 kujutab lõputöö käigus parendatud mudeli treenimist.

2.4.4 Masinõppe mudeli valideerimine

Mudeli valideerimiseks kasutatakse neid 20% andmetest mis eraldati eelnevalt treenimise andmetest. Valideerimisel hinnatakse RGB piltide klassidesse kuuluvust. Arusaadavuse parandamiseks on võimalik luua tabel, milles on valideerimise õnnestumine ja mitte õnnestumine välja toodud (joonis 2 . 29).



Joonis 2.29 Mudeli valideerimise veemaaatriks.

Tabelist on võimalik järeldada, et OFF1OFF2ON3 klass ja OFF1ON2OFF3 klass ei ole piisavalt eristatavad omavahel. Samuti ei ole eristatavad ON1OFF2ON3 ja ON1ON2OFF3 klassid. Treenitud mudeli täpsus on võimalik arvutada valemiga (2.5).

$$\text{õigsus} = \frac{\text{tõesed tulemused}}{\text{tõesed tulemused} + \text{väärad tulemused}} \quad (2.5)$$

Kus *õigsus* on mudeli hindamise täpsus

tõesed tulemused – on õigesti ennustatud klassid


väärad tulemused – on vääralt ennustatud klassid

$$\text{täpsus} = \frac{334}{334 + 50} = 0,87$$

2.4.5 Masinõppe mudeli parendamine

Antud mudelit on vaja proovida parendada, kuna lisaks mudeli valideerimisele ei suutnud mudel ennustada tarbijaid uute salvestatud testandmete korral. Mudeli paremaks saamiseks uuriti võimalust parandada algandmeid, mille põhjal algoritm oma otsuseid teeb. Algandmeteks olevatelt piltidelt (joonis 2.30) on näha, et olukordi kus

üks tarbija töötab ja samal ajal töötab mõni teine tarbija on vähem, kui on kogu klassi iseloomustava 240 pildi seas.




Joonis 2.30 Valik klassi OFF1ON2ON3 piltidest, millel osadel on klassi iseloomustavad tunnused ja osadel piltidel klassi iseloomustavad tunnused puuduvad.

Seega on võimalus andmed üle vaadata ja võtta klassi iseloomustamiseks sellised andmed, millel on kindlasti tarbijate talitlused näha ning algetest algandmetest on võimalik kustutada välja need algandmed, mis klassi ei iseloomusta. Algselt oli kokku 8 klassi ning igas klassis 240 pilti. Tabelis 2.2 on klassides olevate piltide arv peale parendamist.

Tabel 2.2 Piltide arv klassides peale parendamist.


Klassi nimetus ja selgitus	pilte
OFF1OFF2OFF3 - külmik ei tööta, kohvimasin ei tööta, TV ei tööta	27
OFF1OFF2ON3 - külmik ei tööta, kohvimasin ei tööta, TV töötab	38
OFF1ON2OFF3 - külmik ei tööta, kohvimasin töötab, TV ei tööta	48
OFF1ON2ON3 - külmik ei tööta, kohvimasin töötab, TV töötab	15
ON1OFF2OFF3 - külmik töötab, kohvimasin ei tööta, TV ei tööta	240
ON1OFF2ON3 - külmik töötab, kohvimasin ei tööta, TV töötab	38
ON1ON2OFF3 - külmik töötab, kohvimasin töötab, TV ei tööta	47
ON1ON2ON3 - külmik töötab, kohvimasin töötab, TV töötab	15

Muudetud algandmetega on võimalik mudel uuesti treenida. Uue mudeli veamaatriks on joonisel 2.31.




Joonis 2.31 Mudeli valideerimise veamaatriks.


Uuesti treenimisel on mudeli täpsus parem. Probleem on klassi OFF1ON2ON3 klassifitseerimisega ja valideerimise andmetes olnud kolm pilti klassifitseeriti valesti. Klassis OFF1ON2ON3 ei tööta külmik ja töötab kohvimasin ning televiisor. Täpsemal uurimisel selgub, et fail OFF1ON2ON376.jpg (joonisel 2.32) klassifitseeriti klassi OFF1ON2OFF3, kus töötab ainult kohvimasin. Fail OFF1ON2ON381.jpg (joonisel 2.33) klassifitseeriti klassi OFF1ON2OFF3, kus töötab ainult kohvimasin. Fail OFF1ON2ON382.jpg (joonisel 2.34) klassifitseeriti klassi ON1ON2OFF3, kus töötab külmik ja kohvimasin. Fail ON1ON2ON3104.jpg (joonisel 2.35) klassifitseeriti klassi ON1ON2OFF3, kus töötab külmik ja kohvimasin.




Joonis 2.32 Tegelik klass OFF1ON2ON3, ennustatud klass OFF1ON2OFF3 (fail OFF1ON2ON376.jpg)



Joonis 2.33 Tegelik klass OFF1ON2ON3, ennustatud klass OFF1ON2OFF3 (fail OFF1ON2ON381.jpg)



Joonis 2.34 Tegelik klass OFF1ON2ON3, ennustatud klass ON1ON2OFF3 (fail OFF1ON2ON382.jpg)



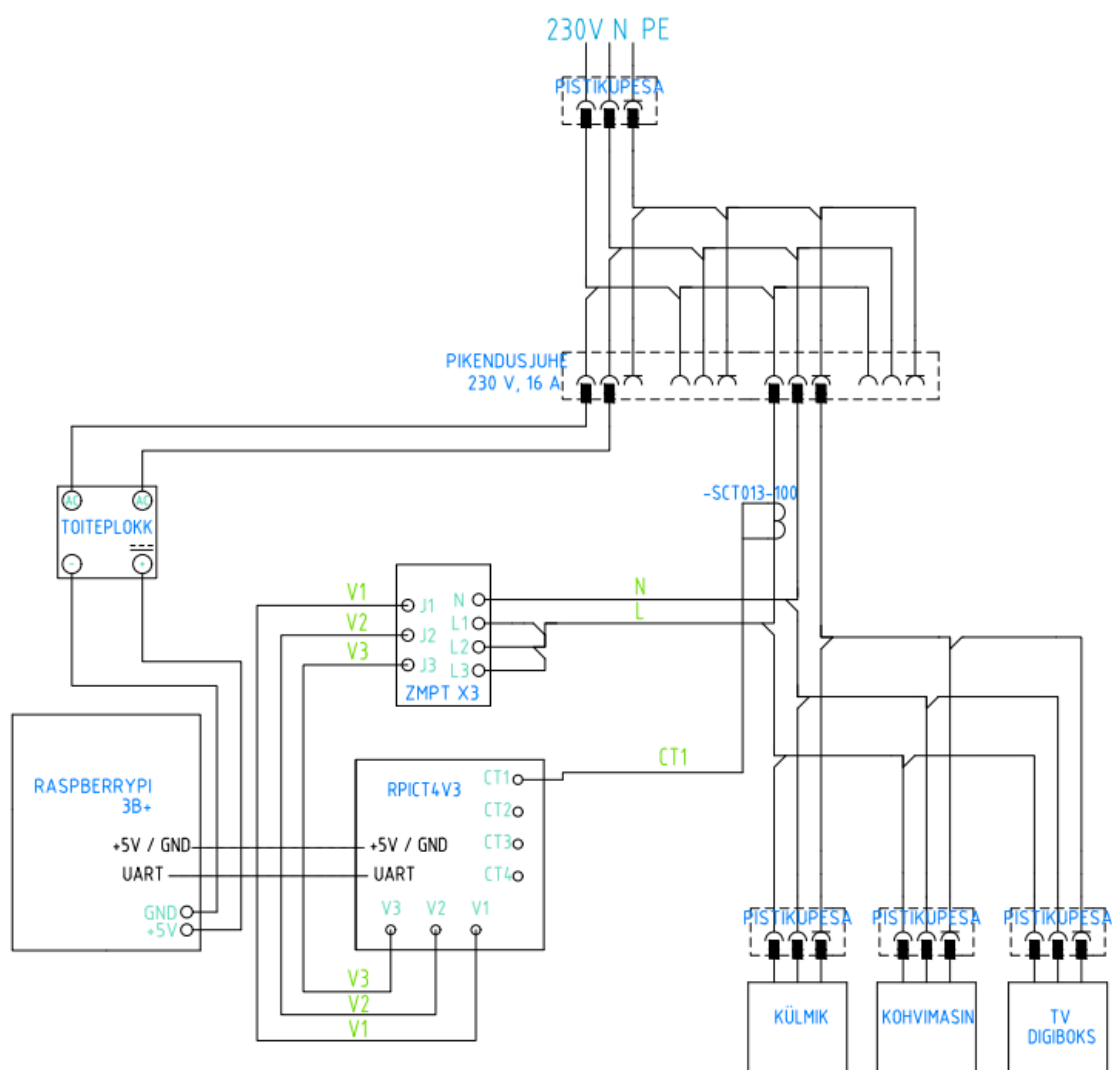
Joonis 2.35 Tegelik klass OFF1ON2ON3, ennustatud klass OFF1ON2OFF3 (fail ON1ON2ON3104.jpg)

Piltide vaatlusel (joonis 2.32), (joonis 2.33), (joonis 2.34) on väärtalt klassifitseerimine arusaadav, kuna nende klasside erinevus ei ole suur. Külmiiku ja televiisori energiatarbimine on väga sarnane ning erinevus on vaid tarbimise tsüklilisuses ning algoritm selle põhjal üldjuhul eristab televiisorit ja külmiikut.

3 TARBIJATE TUVASTAMINE MASINÕPPE ABIL

3.1 Energiatarbimise arvutamine

Tarbijate tuvastamise läbiviimiseks on vaja mõõteseadme skeem erinevalt kokku monteerida (joonis 3.1). Disagreggeerimise teostamiseks on vaja RPICT mõõteseadme volutrafad eemaldada eraldatud toiteliinide juhtmetelt ning üks volutrafo paigaldada tarbijate ühise toiteliini juhtmele. Selliselt paigaldatuna mõõdab volutrafo kõigi kolme tarbija volukõveraid korraga ning mõõdetud agregeeritud elektrienergia andmeid on võimalik kasutada tarbijate tuvastamiseks.



Joonis 3.1 Kolme seadme mõõtmine ühiselt

Masinõppe algoritmi koostamiseks jagati päev tundideks ja iga tunni kohta loodi pilt. Sarnaselt mudeli loomisele on võimalik päeva tarbimise andmed jagada tundideks. Kui

ööpäev on tundideks jagatud, siis on võimalik masinõppe mudeli abil ennustada, kas antud tunni jooksul mõni tarbija on sisse lülitatud. Kui on tuvastatud, mis seadmed tunni jooksul tarbisid elektrienergiat, millise klassi tehisnärvivõrk ennustab, siis on võimalik mõõdetud energiatarbimine jagada selle klassi tarbijate vahel. Kui masinõppe algoritm hindab 24 tunni jooksul töötanud elektritarbijad, siis on võimalik teada saada kõik terve päeva jooksul töötanud seadmed.

Energiatarbimise arvutamiseks hinnati seadmete keskmist elektrienergia kulu tunnis. Kasutades MATLABi programmi teisendati kümne päeva mõõteandmed sekundiliselt ajavahemikult tunnisele ajavahemikule, samaaegselt summeerides aktiivvõimsuse väärtused. Kuna mõõtmised on tehtud ühe sekundilise intervalliga, siis on võimalik lihtsalt leida tarbitav võimsus ajaühikus. Kuna ajavahe kestvus valemisse on võimalik võtta selliselt, et sekundi algus ja lõpp moodustavad ajavahe Δt ja $P_{i-1} = P_i$, siis valemi (3.1) järgi on elektrienergia.

$$E = \frac{\Delta t}{2} \times \sum_{i=1}^{i=N} (P_{i-1} + P_i) \quad (3.1)$$

Kus E – elektrienergia, kWh

Δt – on ajavahe mõõdetavate võimsuste vahel

P_i – on mõõdetavate elektritarbijate aktiivvõimsus

$$E = \frac{1}{2} \times (P_i + P_i) = P_i$$

Kui kasutada eelnevalt grupeeritud tundide andmeid, on võimalik leida tunnis tarbitud elektrienergia kilovatt tundides.

$$1 \text{ W} \cdot \text{s} = \frac{1}{60 \cdot \text{s} \times 60 \cdot \text{min} \times 1000} = k \cdot \text{W} \cdot \text{h}$$

Külmikut, kohvimasinat ja televiisor mõõtmised toimusid eraldi toiteliini abil ning iga tarbija kohta on energiatarbimise andmed kümne päeva kohta.

Külmik töötas püsivalt kümne päeva jooksul. Selle tõttu sai külmiku keskmine energiatarve arvatud kogu kümnapäevase perioodi kohta. Keskmiselt tarbis külmik 0,033 kWh energiat tunnis.

Kohvimasin ja televiisor ei töötanud kogu kümnapäevase perioodi jooksul ning seetõttu eraldati tunnid millal seade töötas, nendest tundidest millal seade ei töötanud. Kui tunnid on eraldatud on võimalik leida keskmine elektrienergia tarve neil tundidel, kui seade töötas. Kohvimasin ja televiisor töötasid mõlemad 49-tunnisel ajavahemikul kümne päeva jooksul. Kohvimasin tarbis keskmiselt 0,042 kWh energiat tunnis. TV ja digiboks koos tarbisid keskmiselt 0,024 kWh energiat tunnis.

Kuna leitud väärtused on keskmised energiatarbimise kulud, siis on vaja jagada reaalne mõõdetud elektrienergiakulu nende tarbijate vahel, mis tunni jooksul töötasid. Võttes sealjuures aluseks seadmete keskmised energia kulud tunnis. Joonisel 3.2 olev programmi kood arvutab iga tarbija osa klassi ON1ON2ON3 korral. Sarnasel viisil on leitud osad teiste klasside kohta, võttes aluseks antud klassis töötanud tarbijad.

```
% P = P1 + P2 + P3
```

```
% Klassi ON1ON2ON3 elektrienergia jaotus tunnis
```

```
ON1ON2ON3TARBIMINE = P1 + P2 + P3;           % Klassi kogutarbimine tunni jooksul  
ON1ON2ON3P1OSA = P1 / ON1ON2ON3TARBIMINE; % Külmiiku osa kogutarbimisest  
ON1ON2ON3P2OSA = P2 / ON1ON2ON3TARBIMINE; % Kohvimasina osa kogutarbimisest  
ON1ON2ON3P3OSA = P3 / ON1ON2ON3TARBIMINE; % TV/digiboksi osa kogutarbimisest
```

Joonis 3. 2 Seadmete elektrienergia tarbimise osa.

Kui on teada tarbijad mis töötasid tunni jooksul ja lisaks on teada tarbitav elektrienergia kogus, siis on võimalik arvutada tunni jooksul iga seadme poolt kulutatud elektrienergia kogus. Koostatud CNN tehisnärvivõrku kasutati tarbijate tuvastamiseks viiel päeval.


3.2 Tuvastatud seadmete energiatarve

Muudetud skeemiga seadmekomplekt salvestas RaspberryPi arvutisse CSV faili üheainsa aktiivvõimsuse aegseeriaga. Aegseeria koosnes umbkaudu 86400 aktiivvõimsuse kirjest. Mõõteandmeid oli realselt mõnevõrra vähem, kuna RPICT mõõteseadme sekund oli pikema kestvusega, kui defineeritud sekund. Mõõtmised viidi läbi viie päeva jooksu. Antud CSV faili laaditi MATLABi programmi ja seal koostatud programmi kood ennustas tunni jooksul töötanud seadmed ja prognoosis seadmete energiatarbimise. Ennustatud klassid ja prognoositud seadmete energiatarbimisest koostati tabelid (tabel 3.1), (tabel 3.2), (tabel 3.3), (tabel 3.4), (tabel 3.5). Arvutustes kasutati MATLABi programmi koodi Lisa 1. Lisaks loodi arusaadavuse suurendamiseks joonis iga päeva mõõtmise tulemuse kohta. Joonisel on mõõdetud päeva algandmed ja tarbijate elektrienergia kogus tunni pikkusel perioodil (joonis 3.3), (joonis 3.4), (joonis 3.5) , (joonis 3.6), (joonis 3.7).

Tabel 3.1 Mudeli tuvastatud klassid 26.11.2023.

26.11.2023					
Tund	Klass	Energia kWh	Külmik kWh	Kohvimasin kWh	TV / digiboks kWh
00:00	'ON1OFF2OFF3'	0,031	0,031	0,000	0,000
01:00	'ON1OFF2OFF3'	0,021	0,021	0,000	0,000
02:00	'ON1OFF2OFF3'	0,020	0,020	0,000	0,000
03:00	'ON1OFF2OFF3'	0,036	0,036	0,000	0,000
04:00	'ON1OFF2OFF3'	0,038	0,038	0,000	0,000
05:00	'ON1OFF2OFF3'	0,038	0,038	0,000	0,000
06:00	'ON1OFF2OFF3'	0,021	0,021	0,000	0,000
07:00	'ON1OFF2OFF3'	0,021	0,021	0,000	0,000
08:00	'ON1ON2OFF3'	0,096	0,043	0,054	0,000
09:00	'ON1OFF2OFF3'	0,030	0,030	0,000	0,000
10:00	'ON1OFF2OFF3'	0,037	0,037	0,000	0,000
11:00	'ON1OFF2OFF3'	0,033	0,033	0,000	0,000
12:00	'ON1OFF2OFF3'	0,019	0,019	0,000	0,000
13:00	'ON1ON2OFF3'	0,085	0,038	0,047	0,000
14:00	'ON1OFF2OFF3'	0,031	0,031	0,000	0,000
15:00	'ON1OFF2OFF3'	0,037	0,037	0,000	0,000
16:00	'ON1OFF2OFF3'	0,036	0,036	0,000	0,000
17:00	'ON1OFF2OFF3'	0,030	0,030	0,000	0,000
18:00	'ON1OFF2OFF3'	0,023	0,023	0,000	0,000
19:00	'ON1OFF2OFF3'	0,022	0,022	0,000	0,000
20:00	'ON1OFF2ON3'	0,054	0,031	0,000	0,022
21:00	'ON1OFF2ON3'	0,092	0,054	0,000	0,038
22:00	'ON1OFF2OFF3'	0,036	0,036	0,000	0,000
23:00	'ON1OFF2OFF3'	0,033	0,033	0,000	0,000

Tabeli 3.1 põhjal koostati joonis 3.3.



Joonis 3.3 Tuvastatud seadmete energiatarve 26.11.2023.

Kuupäeval 26.11.2023 (joonis 3.3) on ennustatud tarbijad õigesti. Sellise hinnangu võimaldab anda võrdlus sekundipõhise mõõtmisandmetega. 8. ja 14. tunnil on algoritm ennustanud külmiku ja kohvimasina töö ja 21. ja 22. tunnil on õigesti ennustatud külmik ja televiisor.


Tabel 3.2 Mudeli tuvastatud klassid 27.11.2023.

27.11.2023					
Tund	Klass	Energia kWh	Külmik kWh	Kohvimasin kWh	TV / digiboks kWh
00:00	'ON1OFF2OFF3'	0,034	0,034	0,000	0,000
01:00	'ON1OFF2OFF3'	0,030	0,030	0,000	0,000
02:00	'ON1OFF2OFF3'	0,027	0,027	0,000	0,000
03:00	'ON1OFF2OFF3'	0,027	0,027	0,000	0,000
04:00	'ON1OFF2OFF3'	0,026	0,026	0,000	0,000
05:00	'ON1OFF2OFF3'	0,037	0,037	0,000	0,000
06:00	'ON1ON2OFF3'	0,104	0,046	0,058	0,000
07:00	'ON1ON2OFF3'	0,115	0,051	0,064	0,000
08:00	'ON1OFF2OFF3'	0,041	0,041	0,000	0,000
09:00	'ON1ON2OFF3'	0,059	0,026	0,033	0,000
10:00	'ON1OFF2OFF3'	0,028	0,028	0,000	0,000
11:00	'ON1OFF2OFF3'	0,027	0,027	0,000	0,000
12:00	'ON1ON2OFF3'	0,073	0,032	0,041	0,000

Tabeli 3.2 järg

27.11.2023					
Tund	Klass	Energia kWh	Külmik kWh	Kohvimasin kWh	TV / digiboks kWh
13:00	'ON1OFF2OFF3'	0,030	0,030	0,000	0,000
14:00	'ON1OFF2OFF3'	0,092	0,092	0,000	0,000
15:00	'ON1ON2OFF3'	0,102	0,045	0,057	0,000
16:00	'ON1OFF2OFF3'	0,037	0,037	0,000	0,000
17:00	'ON1OFF2OFF3'	0,029	0,029	0,000	0,000
18:00	'ON1OFF2OFF3'	0,065	0,065	0,000	0,000
19:00	'ON1OFF2OFF3'	0,028	0,028	0,000	0,000
20:00	'ON1OFF2OFF3'	0,042	0,042	0,000	0,000
21:00	'ON1OFF2ON3'	0,053	0,031	0,000	0,022
22:00	'ON1OFF2OFF3'	0,040	0,040	0,000	0,000
23:00	'ON1OFF2OFF3'	0,020	0,020	0,000	0,000

Tabeli 3.3 põhjal koostati joonis 3.4. Joonisel 3.4 on näha aktiivvõimsuse graafiku muutus. Pinge ja voolu efektiivväärtuste arvutamiseks kasutati rohkem proove - kümme viie asemel, mille põhjal arvutati aktiivvõimsus.




Joonis 3.4 Tuvastatud seadmete energiatarve 27.11.2023.

Kuupäeval 27.11.2023 (joonis 3.4) on ennustatud väärt kaheksas tund ja 16. tund. Mõlemal tunnil on ennustatud klassi „Külmik töös – kohvimasin töös – televiisor väljas“. Reaalselt aga nendel tundidel töötas ka televiisor.

Tabel 3.3 Mudeli tuvastatud klassid 28.11.2023.

28.11.2023					
Tund	Klass	Energia kWh	Külmik kWh	Kohvimasin kWh	TV / digiboks kWh
00:00	'ON1OFF2OFF3'	0,023	0,023	0,000	0,000
01:00	'ON1OFF2OFF3'	0,032	0,032	0,000	0,000
02:00	'ON1OFF2OFF3'	0,037	0,037	0,000	0,000
03:00	'ON1OFF2OFF3'	0,035	0,035	0,000	0,000
04:00	'ON1OFF2OFF3'	0,023	0,023	0,000	0,000
05:00	'ON1OFF2OFF3'	0,022	0,022	0,000	0,000
06:00	'ON1OFF2OFF3'	0,032	0,032	0,000	0,000
07:00	'ON1ON2OFF3'	0,140	0,062	0,078	0,000
08:00	'ON1OFF2OFF3'	0,049	0,049	0,000	0,000
09:00	'ON1ON2OFF3'	0,054	0,024	0,030	0,000
10:00	'ON1OFF2OFF3'	0,024	0,024	0,000	0,000
11:00	'ON1OFF2OFF3'	0,037	0,037	0,000	0,000
12:00	'ON1OFF2OFF3'	0,037	0,037	0,000	0,000
13:00	'ON1OFF2OFF3'	0,029	0,029	0,000	0,000
14:00	'ON1OFF2OFF3'	0,024	0,024	0,000	0,000
15:00	'ON1OFF2OFF3'	0,021	0,021	0,000	0,000
16:00	'ON1ON2OFF3'	0,071	0,031	0,040	0,000
17:00	'ON1OFF2OFF3'	0,042	0,042	0,000	0,000
18:00	'ON1OFF2OFF3'	0,028	0,028	0,000	0,000
19:00	'ON1OFF2OFF3'	0,020	0,020	0,000	0,000
20:00	'ON1OFF2OFF3'	0,035	0,035	0,000	0,000
21:00	'ON1OFF2ON3'	0,044	0,026	0,000	0,018
22:00	'ON1OFF2OFF3'	0,038	0,038	0,000	0,000
23:00	'ON1OFF2OFF3'	0,023	0,023	0,000	0,000

Tabeli 3.3 alusel koostati joonis 3.5.



Joonis 3.5 Tuvastatud seadmete energiatarve 28.11.2023.

Kuupäeval 28.11.2023 (joonis 3.5) on ennustatud vääralt kaheksas tund ja algoritm ei leidnud TV jälge tarbimise andmetest. Ülejäänud klassid on õigesti ennustatud, sealhulgas 22. tunnil.


Tabel 3.4 Mudeli tuvastatud klassid 29.11.2023.

29.11.2023					
Tund	Klass	Energia kWh	Külmik kWh	Kohvimasin kWh	TV / digiboks kWh
00:00	'ON1OFF2OFF3'	0,018	0,018	0,000	0,000
01:00	'ON1OFF2OFF3'	0,033	0,033	0,000	0,000
02:00	'ON1OFF2OFF3'	0,037	0,037	0,000	0,000
03:00	'ON1OFF2OFF3'	0,033	0,033	0,000	0,000
04:00	'ON1OFF2OFF3'	0,019	0,019	0,000	0,000
05:00	'ON1OFF2OFF3'	0,025	0,025	0,000	0,000
06:00	'ON1OFF2OFF3'	0,036	0,036	0,000	0,000
07:00	'ON1ON2OFF3'	0,147	0,065	0,082	0,000
08:00	'OFF1ON2ON3'	0,124	0,000	0,079	0,045
09:00	'ON1OFF2OFF3'	0,031	0,031	0,000	0,000
10:00	'ON1OFF2OFF3'	0,025	0,025	0,000	0,000
11:00	'ON1OFF2OFF3'	0,025	0,025	0,000	0,000
12:00	'OFF1ON2OFF3'	0,062	0,000	0,062	0,000
13:00	'ON1OFF2OFF3'	0,031	0,031	0,000	0,000

Tabeli 3.4 järg

29.11.2023					
Tund	Klass	Energia kWh	Külmik kWh	Kohvimasin kWh	TV / digiboks kWh
14:00	'ON1ON2OFF3'	0,075	0,033	0,042	0,000
15:00	'ON1OFF2OFF3'	0,038	0,038	0,000	0,000
16:00	'ON1OFF2OFF3'	0,018	0,018	0,000	0,000
17:00	'ON1OFF2OFF3'	0,028	0,028	0,000	0,000
18:00	'ON1OFF2OFF3'	0,032	0,032	0,000	0,000
19:00	'ON1OFF2OFF3'	0,041	0,041	0,000	0,000
20:00	'OFF1OFF2ON3'	0,091	0,000	0,000	0,091
21:00	'ON1OFF2ON3'	0,060	0,035	0,000	0,025
22:00	'ON1OFF2OFF3'	0,026	0,026	0,000	0,000
23:00	'ON1OFF2OFF3'	0,030	0,030	0,000	0,000

Tabeli 3.4 põhjal koostati joonis 3.6.




Joonis 3. 6 Tuvastatud seadmete energiatarve 29.11.2023.

Kuupäeval 29.11.2023 (joonis 3.6) on ennustatud väärtalt 8., 9., 13. ja 21. tund. Algoritm ei suuda korralikult eristada kolme tarbijat korraga ja sellest eksimused kaheksandal ja üheksandal tunnil. 13. tunnil ja 21. tunnil ei tuvastanud algoritm külmiku tööd. Põhjus võib olla selles, et külmiku käivitamisel on suur voolu impulss. Kui impulss on pikema kestvusega tõlgendab tehisnärvivõrk seda kohvimasina tunnuseks.

Tabel 3.5 Mudeli tuvastatud klassid 30.11.2023.

30.11.2023					
Tund	Klass	Energia kWh	Külmik kWh	Kohvimasin kWh	TV / digiboks kWh
00:00	'ON1OFF2OFF3'	0,038	0,038	0,000	0,000
01:00	'ON1OFF2OFF3'	0,028	0,028	0,000	0,000
02:00	'ON1OFF2OFF3'	0,020	0,020	0,000	0,000
03:00	'ON1OFF2OFF3'	0,026	0,026	0,000	0,000
04:00	'ON1OFF2OFF3'	0,039	0,039	0,000	0,000
05:00	'ON1OFF2OFF3'	0,037	0,037	0,000	0,000
06:00	'ON1OFF2OFF3'	0,022	0,022	0,000	0,000
07:00	'ON1ON2OFF3'	0,131	0,058	0,073	0,000
08:00	'ON1OFF2OFF3'	0,038	0,038	0,000	0,000
09:00	'ON1OFF2OFF3'	0,033	0,033	0,000	0,000
10:00	'ON1OFF2OFF3'	0,037	0,037	0,000	0,000
11:00	'ON1ON2OFF3'	0,066	0,029	0,037	0,000
12:00	'OFF1ON2OFF3'	0,065	0,000	0,065	0,000
13:00	'ON1OFF2OFF3'	0,037	0,037	0,000	0,000
14:00	'ON1ON2OFF3'	0,075	0,033	0,042	0,000
15:00	'ON1OFF2OFF3'	0,037	0,037	0,000	0,000
16:00	'ON1OFF2OFF3'	0,036	0,036	0,000	0,000
17:00	'ON1OFF2OFF3'	0,036	0,036	0,000	0,000
18:00	'ON1OFF2OFF3'	0,032	0,032	0,000	0,000
19:00	'ON1OFF2OFF3'	0,039	0,039	0,000	0,000
20:00	'ON1OFF2OFF3'	0,038	0,038	0,000	0,000
21:00	'ON1OFF2OFF3'	0,037	0,037	0,000	0,000
22:00	'ON1OFF2OFF3'	0,035	0,035	0,000	0,000
23:00	'ON1OFF2OFF3'	0,031	0,031	0,000	0,000

Tabeli 3.5 põhjal koostati joonis 3.7.



Joonis 3.7 Tuvastatud seadmete energiatarve 30.11.2023.

Kuupäeval 30.11.2023 (joonis 3.7) ennustas mudel väärt 8., 9. ja 13. tunni. Kaheksandal tunnil ei tuvastanud algoritm televiisorit ja 13. tunnil ei tuvastanud mudel külmikut. Sarnaselt eelmise päevaga.

3.3 Tuvastatud seadmete seosed majapidamise tarbimise andmetega

Mõõdetud andmeid on võimalik võrrelda kogu majapidamise tarbimise andmetega. Tunnipõhised tarbimise andmed majapidamise kohta on võimalik alla laadida Eleringi serverist [9]. Seejärel saab neid andmeid võrrelda varem töö käigus arvatud tulemustega ja leida millise osa majapidamise elektrienergia tarbest moodustab külmik, kohvimasin ja televiisor. Ideaalis on mõõteandmeid vaja terve kuu kohta ja sellisel juhul oleks võimalik teha järeldused millise osa elektriarest moodustab külmiku, kohvimasina ja televiisori energiatarbimine kuus. Antud hetkel on võimalik teha kokkuvõtte viie päeva kohta. Suurema kirjelduse huvides lisati teada energiatarbimisega


seadmete hulka majapidamist küttev ja sooja vette tootev soojuspump, mille tarbitud elektrienergia oli võimalik seadmest välja lugeda.

Tabel 3.6 Tuvastatud tarbijate päevane energiatarve

Kuupäev	Külmik kWh	Kohvimasin kWh	TV/digiboks kWh	Muu kWh	Soojuspumba andmed kWh	Mõõtepunkti andmed kWh
26.11.2023	0,759	0,101	0,061	6,705	15,669	23,295
27.11.2023	0,821	0,290	0,066	4,302	16,000	21,478
28.11.2023	0,753	0,148	0,018	3,617	16,000	20,536
29.11.2023	0,660	0,265	0,161	2,919	17,000	21,005
30.11.2023	0,795	0,217	0,000	3,658	16,000	20,670


Tabeli 3.6 põhjal koostati joonis 3.8, milles on iga päeva kohta välja toodud seadmete energiatarbimise jagunemine.

Külmik, kohvimasin ja televiisor tarbivad kogu majapidamise elektrienergiat arvesse võttes väikese koguse elektrienergiat. Kolmveerand elektrienergiast tarbib soojuspump ja viiendiku tarbivad muud seadmed.



Joonis 3.8 Tuvastatud seadmete osa majapidamise energiatarbest.

Seadmete kasutuse maksumuse arvutamiseks saab võtta nende päevade elektrienergia hinna ja vastavalt sellele arvutada seadmete kasutamise kulu. Elektrienergiabörsihinnad perioodile 26.11 kuni 30.11 on võimalik leida Eleringi kodulehelt [64] (joonis 3.9).



Joonis 3.9 NPS Eesti elektribörsi hinnad ajavahemikul 26.11 kuni 30.11.

Täpsema hinna saamiseks on võimalik lisaks arvutada võrgutasu, taastuenergiatasu ja elektriaktsiis ning börsihinnale lisada marginaal. Kehtivad määrad on võetud Elektrilevi kodulehelt [65]. Võrgutasu on E – R ajavahemikul 07 – 22 0,0567 €/kWh. E - R ajavahemikul 22.00–7.00 ning laupäeval, pühapäeval ning riiklikul pühal kogu ööpäeva jooksul päeva hind 0.00328 €/kWh. Taastuenergiatasu on 0,0124 €/kWh ja elektriaktsiis on 0,001 €/kWh. Elektrimüüja marginaal on 0,0044 €/kWh. Teenuste kuumakse arvele ei lisatud. Kõikide hindade olemasolul on võimalik koostada näidisarve perioodile 26.11.2023 kuni 30.11.2023. Arvele ei lisatud eelmises näites olnud soojuspumpa ja muid seadmeid, kuna detailseid tunnipõhiseid tarbimise andmeid soojuspumbast ei olnud võimalik lugeda.

Võrgutasude leidmiseks võeti tunni jooksul töötanud elektritarbijate elektrienergia kogus ja korrutati vastavalt kellaajale ja päevale päevase või öise hinnaga. Taastuenergiatasu ja elektriaktsiisi leidmiseks korrutati tarbitud elektrienergia kogus taastuenergiatasu ja elektriaktsiisi määraga.

Elektrienergia maksumuse leidmiseks korrutati igal tunnil töötanud elektritarbijate elektrienergia kogus vastava tunni NPS Eesti hinna ja elektrimüüja marginaaliga ning

summeeriti kõikide elektritarbijate maksumused. Elektritarbijate hinnangulise maksumuse leidmiseks korrutati igal tunnil töötanud elektritarbijate elektrienergia kogus vastava tunni NPS Eesti hinna ja elektrimüüja marginaaliga. Elektritarbijate summeeriti elektritarbijate järgi ning igale tarbijale lisati vastavalt tarbimisajale võrgutasu. Hinnangulisele kulule liideti taastuenergiatasu, elektriaktsiis ja käibemaks. Arvutatud andmete alusel koostati elektriarve (joonis 3.10), kus on välja toodud kolme seadme elektrienergia kogus ja seadmete kogumaksumus. Viie päevasel perioodil kulus külmikule 3,788 kWh elektrienergiat ja selle seadme kulu on 0,94 eurot. Kohvimasinale kulus 1,020 kWh energiat ja seadme kasutuse maksumus on 0,28 eurot. Televiisorile kulus 0,306 kWh elektrienergiat ja seadme kasutuse maksumus on 0,09 eurot.



ELEKTRIARVE

ENERGIA MÜÜK

Kuupäev: 11. detsember 2023. a.

Arve nr: Nr 01

Kliendi ID: ID 01

Elektrienergia	0,78 €
Võrguteenus	0,24 €
Taastuenergia tasu ja elektriaktsiis	0,07 €
Vahesumma	1,09 €
Käibemaks	0,22 €
Kuulub tasumisele	1,31 €

Võrguteenus			
Periood 26.11.2023 - 30.11.2023	Ühiku hind €	Kogus kWh	Maksumus €
Elektri edastamine: päev	0,057	3,051	0,17 €
Elektri edastamine: öö	0,033	2,064	0,07 €
Taastuenergia tasu	0,012	5,115	0,06 €
Elektriaktsiis	0,001	5,115	0,01 €
		Vahesumma	0,31 €

Elektrienergia			
Periood 26.11.2023 - 30.11.2023		Kogus kWh	Maksumus €
Elektrienergia maksumus tunnipõhiste hindade alusel		5,115	0,78 €
		Vahesumma	0,78 €

Elektriseadmete energiakasutus ja kasutuse maksumus maksudega			
Periood 26.11.2023 - 30.11.2023		Kogus kWh	Hinnanguline kulu €
Külmik		3,788	0,94 €
Kohvimasin		1,020	0,28 €
TV/digiboks		0,306	0,09 €

Joonis 3.10 Elektriarve koos eristatud elektritarbijatega.

Seadmete kasutuse maksumused ei olnud suured. Pidevalt töötavale külmikule kulub nimetamisväärne summa. Sellest on võimalik järeldada, et praktilisem on tuvastada suure energiatarbimisega elektriseadmeid.

4 TOOTEARENDEUSE EDASIARENDEUSEKS

SOOVITUSED

IDEE

Tarbimise andmeid on kasulik teada elektrimüüjal ja elektritarbijal. Elektrimüüja saab jagada asjakohast teavet oma klientidele ning hoida klienti sellega enda juures. Kuna rahvusvahelisele kogemuse järgi konkurents elektrimüüjate vahel suureneb ja elektrimüüjad peavad lisaks elektrienergia müügile lisaväärtust pakkuma. Antud visiooni täitmiseks piisab sellistest andmetest, mis on saadaval tarkadest elektriarvestitest. Antud lahendust on soodne rakendada, kuna analüüsimiseks ei ole vaja lisa riistvara. Eleringi Estfeed AVP (andmeladu) läheb 01.06.2024 [66] üle 15-minutilisele perioodiga arvestusele ning võrgueeskirjaga määratud turuosalistel on kohustus hakata antud resolutsiooniga andmeid AVPsse esitama. Kõikide mõõtepunktide üleviimine 15-minutilise arvestuse peale peaks lõppema aastal 2031. Selliste arengute korral on Eleringi andmete aluse võimalik elektriseadmeid tuvastada. Bidgely kogemuse põhjal on 15 minuti andmete alusel võimalik ennustada suure täpsusega [22]. Tarbijate talitlemist tuvastab nende algoritm 75% kuni 100% täpsusega ning nende tarbitud elektrienergiat määratakse 75% kuni 92% täpsusega. Nende eelduste tõttu on suur potentsiaal antud lahendust Eestis samuti rakendada. Kahtlusi tekitavad aga probleemid, mis tuuakse välja Elektrilevi AS poolt tellitud uurimustööst ELEKTRILIINIANDMESIDE HÄIRINGUKINDLUSE ANALÜÜS ELEKTRILEVI OÜ MADALPINGE JAOTUSVÖRGUS [63]. Määramatust lisab teadmatus millise täpsusega on elekterliinside abil võimalik tulevikus andmeid saata arvesti ja kontsentraatori vahel. Tänapäeval on samuti oluline elektritarbimist juhtida, kuna elektritootmine ei ole alati nii lihtsalt juhitav ja tootmine võib toimuda siis kui tarbimine on väike ning vastupidi. Tänapäeval on elektrihind seotud sellega, kui palju elektrit hetkel toodetakse. Reeglina öösel, kui on tarbimine väiksem, on hind madalam ja päeval vastupidi. Elektrienergia kliendid saavad ise otsustada, millal elektrienergiat tarbida ja paljud seda ka teevad, aga mugavuse ja suurema võimaliku säästu saamiseks oleks hea, kui klientidel on selgem ülevaade sellest, kui palju mingi nende tarbija täpselt tarbib. Säästlikumaks tulevikuks on vaja süsteemi, mis saab aru, mis seadmed majapidamises töötavad ning vajadusel piirab nende tööd. Seda on võimalik saavutada paigaldades seadmete ette mõõteseadmega relee, mis mõõdab tarbimise ja vajadusel lülitab seadme välja. Probleemiks on releede paigaldamise tehniline keerukus ja vajadus olemasolev elektripaigaldis lahti võtta. Teine võimalus on luua majapidamises olevate seadmete vahele standardiseeritud andmesidevõrk ja seda võrku kasutades on teada, mis seadmed hetkel töötavad. Kui seadmetel on sellised võimalused, siis on nende funktsioone võimalik sisse-välja lülitada. Tulevikus on ilmselt üha rohkem IOT seadmeid

mis sellist tarka juhtimist võimaldavad. Tarbijad ja tootjad tuleb omavahel siduda läbi virtuaalse elektriijaama platvormi.

KOKKUVÕTE

Lõputöö algas ideest, et elektriseadmed tarbivad voolu kindla mustri järgi ning selle mustri järgi on võimalik elektriseade tuvastada. Antud meetodil on võimalik elektriseade tuvastada, aga sellisel juhul on vaja kvaliteetseid mõõteriistu, mis suudavad mõõta voolu ja pinget suure täpsuse ja sagedusega. Esialgu prooviti sellist lahendust olemasoleva mõõteseadmepool rakendada, aga tehniliselt ei olnud see võimalik ning algse idee lahenduseks otsiti alternatiivseid meetodeid.

Olemasolevad lahendused, mis turul on, jaotusid sisuliselt kaheks: esiteks riistvara, mis oli paigaldatud vahetult mõõdetavale seadmele või riistvara, mis mõõtis sekundilise perioodiga tarbitud energiat ning teiseks tarkvara, mis kasutas tarkade arvestite andmeid vahetult arvestist või arvesti andmeid andmebaasi serverist. Olemasolevad lahendused kasutasid madala resolutsiooniga andmeid energiatarbimise disageerimiseks. Sellel põhjusel muutus riistvara seadistus ja töös kasutusel olnud mõõteseade seadistati mõõdetud andmeid salvestama intervalliga üks sekund.

Mitmed teemakohased artiklid kasutasid erinevaid masinõppe algoritme elektriseadmete tuvastamiseks. Teadusartiklites kasutati sageli olemasolevaid tarbijate mõõtmiste andmeid ning tarbijate võimsuse, kasutuse kestvuse ja kasutuse aja järgi tehti kindlaks tarbija tüüp. Artiklite põhjal on tarbija liiga detailne määramine probleemne kuna erinevate tootjate valmistatud sama tüüpi tarbijad erinevad üksteisest ning neil ei ole sarnane tarbimise tunnus. Lisaks on probleemiks seadmete erinevad tööprogrammid ja töörežiimid, mille tõttu sama seadme energiatarbimise tunnused on erinevad.

Töös teisendati elektrienergia aegseeria RGB pildiks. Eraldi teisendati pildiks agregeeritud aegseeria kombinatsioonid ning iga tarbija enda elektrienergia RGB pilt. See võimaldas tuvastada seadme iga töörežiimi ja kestvuse.

Kui andmed olid piltide kujule teisendatud, tekkis võimalus kasutada olemasolevaid tehiskäivõrgu mudeleid, millega tuvastatakse piltidelt esemeid. Olemasoleval GoogLeNet mudeli juures kasutati siirdeõpet ja mudelil asendati kaks tehiskäivõrgu kihti. Asendati piltide klassifitseerimise kiht ning mudel klassifitseeris peale seda esemete asemel elektrienergia tarbijaid.

Töö lõpus kasutati tehiskäivõrku ja mõõteandmete alusel hinnati millised tarbijad töötasid iga tund viie päeva jooksul. Kui oli teada mis seadmed töötasid, siis selle põhjal arvestati igale seadmele osa mõõdetud elektrienergiast. Selliselt oli võimalik saada teada kui palju kulus energiat igale seadmele viie päeva jooksul. Töö lõpus võrreldi mõõdetud andmeid liitumispunktist mõõdetud andmetega. Uurimisel olnud seadmete energiatarbimise osaks kujunes mõni protsent.

Töö tulemusena selgus, et meetodid tarbijate tuvastamiseks on olemas ning võimalik on koos elektriarvega saada detailne info, kui palju maksis mõne toote kasutamine kuu jooksul. Töös selgus, et tehisnärvivõrk ennustab tunni jooksul töötanud tarbijaid, aga närvivõrk teeb vigu ning saadud tulemused ei ole kõrge usaldusväärsusega. Suur usaldusväärsus antud rakenduse juures ei ole aga väga oluline, sest elektriarvet saades on tõenäosuslik hinnang juba piisav, et seadmele kulunud raha hinnata. Mudelit saab arendada paremaks, kui koguda rohkem algandmeid, mille põhjal tehisnärvivõrgul oleks võimalik õppida. Kasulik on tuvastada tarbijaid, mis kasutavad rohkem elektrienergiat.

Tehisnärvivõrkude ja andmeanalüüsi kasutamine elektriseadmete tuvastamiseks ja tarbimise optimeerimiseks ei ole piiratud ainult selgete ja täpsete tulemuste saavutamise, vaid pakub ka võimalust mõista keerukamaid süsteeme ja käitumismustreid. See avab ka ukse aruteludele tehnoloogia eetilise kasutamise ja selle mõju üle ühiskonnale. Paljud kliendid võib-olla ei soovigi, et tarkvara analüüsib täpselt, mida nad kodus teevad. Samas on tehisintellekti rakendamine tarbimise analüüsimisel ei ole mitte ainult tehnoloogiline saavutus, vaid ka samm edasi teadlikuma ja vastutustundlikuma tarbimiskultuuri suunas.

Kokkuvõtteks, lõputöö tõstab esile tehisintellekti võimalused ja piirangud tarbijate tuvastamisel ja energiakasutuse optimeerimisel, andes ainet ka filosoofilisele mõtisklusele tehnoloogia rolli üle tarbimisharjumuste kujundamisel ja keskkonnasäästlikkuse edendamisel. See töö mitte ainult ei esita uusi tehnilisi lahendusi, vaid kutsub üles ka laiemalt mõtlema tehnoloogia mõjust meie eludele, ökoloogilisele jalajäljele ja planeedile.

5 Kasutatud kirjandus

- [1] Go OÜ, „Elektrihind - Elektrimüüjad,“ [Võrgumaterjal]. Saadaval: <https://elektrihind.ee/elektrimuujad/>. Kasutatud: 08.11.2023.
- [2] Eesti Energia, [Võrgumaterjal]. Saadaval: <https://www.energia.ee/et/avaleht>. Kasutatud: 08.11.2023.
- [3] 220 Energia OÜ, [Võrgumaterjal]. Saadaval: <https://www.220energia.ee/>. Kasutatud: 08.11.2023.
- [4] Elektrum Eesti OÜ, [Võrgumaterjal]. Saadaval: <https://www.elektrum.ee/ee/eraklient>. Kasutatud: 08.11.2023.
- [5] AS Eesti Gaas, [Võrgumaterjal]. Saadaval: <https://www.gaas.ee/>. Kasutatud: 08.11.2023.
- [6] VKG Elektrivõrgud OÜ, [Võrgumaterjal]. Saadaval: <https://vkgev.ee/>. Kasutatud: 08.11.2023.
- [7] Alexela Energia AS, [Võrgumaterjal]. Saadaval: <https://www.alexela.ee/et>. Kasutatud: 08.11.2023.
- [8] Elektrilevi OÜ, [Võrgumaterjal]. Saadaval: <https://www.elektrilevi.ee/et/eteenindus/tarbimisajalugu>. Kasutatud: 23.09.2023.
- [9] Elering AS, „Andmeladu Infosüsteem,“ [Võrgumaterjal]. Saadaval: <https://andmeladu.elering.ee/consumer/metering-points>. Kasutatud: 28.11.2023.
- [10] LOVATO Electric S.p.A., „Products > Metering instruments and current transformers,“ [Võrgumaterjal]. Saadaval: https://catalogue.lovatoelectric.com/gl_en/Products/Metering-instruments-and-current-transformers/CAP25/pc?LV10059=Flush+mounting&LV10062=CT+%2F5A+%2F1A&LV10064=15th+order. Kasutatud: 23.09.2023.
- [11] EMOS CZ group a.s., „Vattmeeter (digitaalne võimsusmõõtur) P5822,“ [Võrgumaterjal]. Saadaval: <https://www.emos.ee/vattmeeter-digitaalne-voimsusmootur-p5822>. Kasutatud: 15.11.2023.
- [12] Landis+Gyr AG, „Landis+Gyr E450,“ [Võrgumaterjal]. Saadaval: <https://www.landisgyr.eu/product/landisgyr-e450/>. Kasutatud: 23.09.2023.
- [13] Guidehouse Inc., „Guidehouse Insights,“ [Võrgumaterjal]. Saadaval: <https://guidehouseinsights.com/>. Kasutatud: 15.11.2023.
- [14] Guidehouse Insights, „Guidehouse Insights Leaderboard: Customer Engagement and Experience Analytics. 2023. Loetud aadressil: <https://www.bidgely.com/resources/bidgely-guidehouse-insights-leaderboard-ce-cx-2023-resources/>. Kasutatud: 01.11.2023”.
- [15] BIDGELY INC, „We Empower Smart Energy Decisions,“ [Võrgumaterjal]. Saadaval: <https://www.bidgely.com/>. Kasutatud: 07.11.2023.
- [16] Sense Labs, Inc, „Engage customers and manage to the grid edge,“ [Võrgumaterjal]. Saadaval: <https://sense.com/>. Kasutatud: 01.02.2023.
- [17] Itron Inc, „Itron enables utilities and cities to better manage energy and water,“ [Võrgumaterjal]. Saadaval: <https://www.itron.com/emea>. Kasutatud: 09.11.2023.
- [18] gridX GmbH, „Build custom digital energy solutions,“ [Võrgumaterjal]. Saadaval: <https://www.gridx.ai/>. Kasutatud: 15.11.2023.
- [19] NET2GRID, „Our mission is to accelerate the Energy Transition,“ [Võrgumaterjal]. Saadaval: <https://www.net2grid.com/>. Kasutatud: 15.11.2023.
- [20] Emporia, „The Vue Energy Monitor,“ [Võrgumaterjal]. Saadaval: <https://www.emporiaenergy.com/>. Kasutatud: 12.02.2023.

- [21] ALLTERCO ROBOTICS EOOD, „Easy Smart Home Automation,” [Võrgumaterjal]. Saadaval: <https://www.shelly.cloud/en-ee>. Kasutatud: 01.02.2023.
- [22] Bidgely Inc, „Empowering Utilities With True, Behind-the-Meter Disaggregation: Bidgely’s Proven Approach And Real-World Impact,” [Võrgumaterjal]. Saadaval: <https://www.bidgely.com/resources/behind-the-meter-disaggregation/>. Kasutatud: 16.11.2023.
- [23] NET2GRID B.V., „Our mission is to accelerate the Energy Transition,” [Võrgumaterjal]. Saadaval: <https://www.net2grid.com/>. Kasutatud: 28.11.2023.
- [24] *Elektriohutusseadus. Vastu võetud 24.01.2007. RT I 2007, 12, 64. Kasutatud: 05.12.2023.*
- [25] *Seadme ohutuse seadus. Vastu võetud 18.02.2015. RT I, 23.03.2015, 4. Kasutatud: 05.12.2023.*
- [26] Tarbijakaitse ja Tehnilise Järelevalve Amet, „Elektriohutus,” [Võrgumaterjal]. Saadaval: <https://ttja.ee/media/3502/download>. Kasutatud: 10.12.2023.
- [27] Elsevier B.V., „Scopus,” [Võrgumaterjal]. Saadaval: <https://www.scopus.com/search/form.uri?display=basic#basic>. Kasutatud: 02.12.2023.
- [28] Google Inc, „Google Scholar,” [Võrgumaterjal]. Saadaval: https://scholar.google.com/scholar?q=NILM&hl=en&as_sdt=0,5. Kasutatud: 02.12.2023.
- [29] G. W. Hart, „Nonintrusive appliance load monitoring,” *Proceedings of the IEEE*, vol. 80, no. 12, pp. 1870-1891, Dec. 1992, doi: 10.1109/5.192069. Kasutatud: 10.11.2023.
- [30] W. K. J. Kelly, „The UK-DALE dataset, domestic appliance-level electricity demand and whole-house demand from five UK homes. *Sci Data* 2, 150007 (2015), <https://doi.org/10.1038/sdata.2015.7>. Kasutatud: 26.10.2023”.
- [31] B. E. I. B. S. Makonin, „Electricity, water, and natural gas consumption of a residential house in Canada from 2012 to 2014,” *Scientific Data* 3, 160037, 2016, <https://doi.org/10.1038/sdata.2016.37>. Kasutatud: 12.11.2023.
- [32] M. J. J. Z. Kolter, „REDD: A public data set for energy disaggregation research,” Computer Science And Artificial Intelligence, Massachusetts Institute of Technology, Cambridge, MA, 2011. Loetud aadressilt: <https://people.csail.mit.edu/mattjj/papers/kddsust2011.pdf>.
- [33] E. L. J. H. C. Shin, „The ENERTALK dataset, 15 Hz electricity consumption data from 22 houses in Korea,” *Sci Data* 6, 193, 2019. <https://doi.org/10.1038/s41597-019-0212-5>. Kasutatud: 05.11.2023.
- [34] Papers with Code, „UK-DALE andmebaas,” [Võrgumaterjal]. Saadaval: <https://paperswithcode.com/dataset/uk-dale>. Kasutatud: 02.12.2023.
- [35] Z. S. A. Jonah Edmonds, „IMG-NILM: A Deep learning NILM approach using energy heatmaps,” %1 SAC '23: *Proceedings of the 38th ACM/SIGAPP Symposium on Applied Computing*, Pages 1151–1153, 2023.
- [36] G. M. S. L. C. J. A. a. K. -R. M. W. Samek, „"Explaining Deep Neural Networks and Beyond: A Review of Methods and Applications",” *Proceedings of the IEEE*, kd. 109, nr 3, pp. 247-278, 2021.
- [37] C. N. D. V. L. Kyrkou, „Imaging time-series for nilm,” %1 *International Conference on Engineering Applications of Neural Networks*, pages 188–196., 2019. Loetud aadressilt: <https://intelligence.csd.auth.gr/wp-content/uploads/2020/07/Imaging-Time-Series-for-NILM.pdf>. Kasutatud: 27.10.2023.
- [38] M. H. T. D. T. M. H. L. C. J. A. M. Senarathna, „An image based approach of energy signal disaggregation using artificial intelligence,” %1 *2021 IEEE 16th International Conference on Industrial and Information Systems (ICIIS)*, pages 98–103. doi: 10.1109/ICIIS53135.2021.9660638. Kasutatud: 28.10.2023.

- [39] F. C. P. Bruno, „Using heatmaps for deep learning based disease classification,” %1 *IEEE conference on computational intelligence in bioinformatics and computational biology (CIBCB)*, pages 1–7, doi: 10.1109/CIBCB.2019.8791493. Kasutatud: 28.10.2023, 2019.
- [40] Google LLC, „Google Patents,” [Võrgumaterjal]. Saadaval: <https://patents.google.com/>. Kasutatud: 31.10.2023.
- [41] M. R. S. M. S. J. H. S. (. Y. J. Park, „Apparatus and method for non-intrusive load monitoring (nilm)”. Patent US20140142724A1. Loetud aadressil: <https://patents.google.com/patent/US20140142724A1/en>. Kasutatud: 20.10.2023.
- [42] A. G. O. B. A. S. (. S. Mimaroglu, „Non-intrusive load monitoring using machine learning and processed training data”. Patent WO2021108011A1. Loetud aadressil: <https://patents.google.com/patent/WO2021108011A1/en?q=WO2021108011A1>. Kasutatud: 20.10.2023, 2021.
- [43] O. B. A. G. A. S. (. S. Mimaroglu, „Load monitoring using machine learning”. Patent WO2021108008A1. Loetud aadressil: <https://patents.google.com/patent/WO2021108008A1/en?q=WO2021108008A1>. Kasutatud: 20.10.2023.
- [44] A. S. A. G. O. B. (. S. Mimaroglu, „Non-intrusive load monitoring using ensemble machine learning techniques”. Patent WO2021108010A1. [Online]. <https://patents.google.com/patent/WO2021108010A1/en?q=WO2021108010A1> Kasutatud: 20.10.2023.
- [45] M. S. R. A. A. G. P. P. (. A. Shyr V. Garud, „Improvements in low frequency energy disaggregation techniques”. Patent WO2018109754A2. Loetud aadressilt: <https://patents.google.com/patent/CA3047073C/en>. Kasutatud: 20.10.2023.
- [46] A. G. H.-T. C. V. G. (. Y. HE, „Improvements in energy disaggregation techniques for whole-house energy consumption data”. Patent WO2015073997A2. <https://patents.google.com/patent/WO2015073997A3/un>. Kasutatud: 20.10.2023.
- [47] D. N, „Raspberrypi Current and Temperature Sensor Adaptor,” [Võrgumaterjal]. Saadaval: http://lechacal.com/wiki/index.php?title=Raspberrypi_Current_and_Temperature_Sensor_Adaptor. Kasutatud: 23.09.2023.
- [48] Raspberry Pi Foundation, „Raspberry Pi 3 Model B+,” [Võrgumaterjal]. Saadaval: <https://www.raspberrypi.com/products/raspberry-pi-3-model-b-plus/>. Kasutatud: 1.12.2023.
- [49] Dechang Electronic, „SCT013,” [Võrgumaterjal]. Saadaval: <http://en.yhdc.com/product/SCT013-401.html>. Kasutatud: 17.11.2023.
- [50] LeChacal.com, „LeChacal.com ZMPT 3X Voltage Sensor,” [Võrgumaterjal]. Saadaval: <https://lechacalshop.com/gb/sensors/93-2267-zmp-3x-voltage-sensor.html>. Kasutatud: 17.11.2023.
- [51] Microchip Technology Inc, „MCP3208,” [Võrgumaterjal]. Saadaval: <https://www.microchip.com/en-us/product/mcp3208#>. [Kasutatud 17 11 2023].
- [52] Microchip Technology Inc, „ATmega328,” [Võrgumaterjal]. Saadaval: <https://www.microchip.com/en-us/product/atmega328>. Kasutatud: 18.11.2023.
- [53] Arduino S.r.l., „Arduino Uno Rev3,” [Võrgumaterjal]. Saadaval: <https://store.arduino.cc/products/arduino-uno-rev3>. Kasutatud: 18.11.2023.
- [54] LeChacal.com, „RPICT Fundamentals,” [Võrgumaterjal]. Saadaval: https://lechacal.com/wiki/index.php?title=RPICT_Fundamentals. Kasutatud: 18.11.2023.
- [55] V. M. F. P. A. T. Häring, *Basic of Machine Learning for Electrical Engineering*, Tallinn, Estonia: Tallinn University of Technology, 2021.

- [56] M. Sarap, "Masinõppel põhineva koormuse hinnapõhise juhtimisalgoritmi uurimine ning väljatöötamine energiapaindlikkuse saavutamiseks", magistritöö, Tallinna Tehnikaülikool, 2021.
- [57] T. V. B. A. A. R. A. K. G. D. K. Kudelina, „Trends and Challenges in Intelligent Condition Monitoring of Electrical Machines Using Machine Learning.,” *Applied Sciences*. 2021; 11(6):2761. <https://doi.org/10.3390/app11062761>. Kasutatud: 10.11.2023.
- [58] J. Terra, „Keras vs Tensorflow vs Pytorch: Key Differences Among Deep Learning,” Simplilearn Solutions, [Võrgumaterjal]. Saadaval: <https://www.simplilearn.com/keras-vs-tensorflow-vs-pytorch-article>. Kasutatud: 21.11.2023.
- [59] The MathWorks, Inc., „Deep Learning Toolbox,” [Võrgumaterjal]. Saadaval: <https://se.mathworks.com/products/deep-learning.html>. Kasutatud: 07.12.2023.
- [60] B. Albright, „Deep Learning and Design Engineering,” Robotics24/7, [Võrgumaterjal]. Saadaval: <https://www.robotics247.com/article/deep-learning-and-design-engineering>. [Kasutatud 21 11 2023].
- [61] Papers With Code, „GoogLeNet,” [Võrgumaterjal]. Saadaval: <https://paperswithcode.com/method/googlenet>. Kasutatud: 03.12.2023.
- [62] Data Science Estonia, „Närvivõrkude ja masinõppe sõnastik,” [Võrgumaterjal]. Saadaval: <http://datasci.ee/masinõppe-sonastik/>. Kasutatud: 23.11.2023.
- [63] M. P. M. J. H. M. M. J. J. N. L. Kütt, „ELEKTRILIINIANDMESIDE HÄIRINGUKINDLUSE ANALÜÜS ELEKTRILEVI OÜ MADALPINGE JAOTUSVÕRGUS, Elektroenergeetika ja mehhatroonika instituut, Tallinna Tehnikaülikool, 2020.,” Loetud leheküljel:Loetud leheküljel: <https://www.elektrilevi.ee/-/doc/8644141/ettevottest/tutvustus/failid/EMÜ.pdf>. Kasutatud: 01.12.2023.
- [64] Elering AS, „Börsihinnad,” [Võrgumaterjal]. Saadaval: <https://dashboard.elering.ee/et/nps/price?interval=minute&period=search&start=2023-11-25T22:00:00.000Z&end=2023-11-30T21:59:59.000Z&show=graph>. Kasutatud: 05.12.2023.
- [65] Elektrilevi AS, „Abiinfo / Hinnakirjad,” [Võrgumaterjal]. Saadaval: https://www.elektrilevi.ee/documents/8644141/8658446/Elektrilevi_hinnakiri_vor_guteenuse_hinnad_alates_1_jaanuar_2023_EST.pdf. Kasutatud: 05.12.2023.
- [66] 廖. 邓. 韩信锐, „Time sequence based seq2point NILM method and device”. Hiina RV Patent CN111199014B, 25 11 2022.
- [67] D. B, „Deep Learning fo Engineers,” MathWorks Matlab, [Võrgumaterjal]. Saadaval: <https://www.youtube.com/playlist?list=PLn8PRpmsu08ol7qVBak-RUKrBNkn3H58R> Kasutatud: 21.11.2023.
- [68] Z. S. A. J. Edmonds, „IMG-NILM: A Deep learning NILM approach using energy heatmaps,” The 38th ACM/SIGAPP Symposium On Applied Computing. 2022. <https://doi.org/10.48550/arXiv.2207.05463>. Kasutatud: 23.10.2023.
- [69] Eesti Energia AS, [Võrgumaterjal]. Saadaval: <https://www.energia.ee/et/e-teenindus/arved>. Kasutatud: 23.09.2023.
- [70] World Intellectual Property Organization, [Võrgumaterjal]. Saadaval: <https://www.wipo.int/portal/en/index.html>. Kasutatud: 06.11.2023.
- [71] Elering, „Andmeladu Infosüsteem,” [Võrgumaterjal]. Saadaval: <https://andmeladu.elering.ee/consumer/home>. Kasutatud: 15.11.2023.
- [72] E. Mocanu, Machine learning applied to smart grids.doktoritöö, Research TU/e / Graduation TU/e, Electrical Engineering. Technische Universiteit Eindhoven, 2017. Loetud aadressil: https://research.tue.nl/files/77436888/20171009_Mocanu.pdf. Kasutatud: 11.11.2023.

LISAD

Lisa 1 Klassi ennustamise ja energiatarbe prognoosimise programmi kood

```

PAEVAKONTROLL = table2array(PAEVAKONTROLL)'; % Aegseeria massiiviks
                                                % ja andmete transponeerimine
PAEVAEKSPORT = PAEVAKONTROLL;                % Aegseeria eksport
                                                % graafiku genereerimiseks
PAEVAKONTROLL = paddata(PAEVAKONTROLL,86400); % Aegseeria täitmine
PAEVAKONTROLL(1,1) = SUURIM;                  % Referentssuuruse määramine
PAEVAKONTROLLLN = normalize(PAEVAKONTROLL);   % Andmete normaliseerimine
PAEVAKONTROLLNR = round(rescale(PAEVAKONTROLLLN,0,255)); % Väärtuste
                                                % skaleerimine 0 - 255

for jj = 1:24
    Ptunnid(jj,:) = PAEVAKONTROLLNR(1,(1 + 3600*(jj-1)):(3600*jj));
                                                % Piltide massiiv
    Etunnid(jj,:) = PAEVAKONTROLL(1,(1 + 3600*(jj-1)):(3600*jj));
                                                % Energia massiiv
        for ii = 1:60
            Pr uut(ii,:) = Ptunnid(jj,(1 + 60*(ii-1)):(60*ii));
                                                % Andmed pildi tegemiseks
            Eruut(ii,:) = Etunnid(jj,(1 + 60*(ii-1)):(60*ii));
                                                % Andmed energia arvutamiseks
        end
        Pmin = (1:60);                        % Minuti-telg
        Psek = (1:60);                        % Sekundi-telg
        Peng = Pr uut(Pmin,Psek);              % Aktiivvõimsuse iseloomustus
        Ppilt = ind2rgb(Peng,jet(128));       % Pilt 60 x 60 x 3
        Ppilt224x224 = imresize(Ppilt,[224 224]);
                                                % Pilt 224 x 224 x 3
        xKLASS.ENERGIA = (sum(Etunnid(jj,:)) / 3600) / 1000;
                                                % Tarbitud energia arvutamine
        ENNUSTUS = image(zeros(224, 224, 3)); % Tühja massiivi loomine
        ENNUSTUSP = Ppilt224x224;            % Andmete omistamine
        ENNUSTUS.CData = im2uint8(ENNUSTUSP); % Andmete konverteerimine
        [YPred,probs] = classify(trainedGNmod,ENNUSTUS.CData);
                                                % Klassi ennustamine
        if strcmp(string(YPred),'OFF1OFF2OFF3') % Tarbitud energia
                                                % klassis OFF1OFF2OFF3
            xKLASS.TUNDP1 = xKLASS.ENERGIA * 0;
            xKLASS.TUNDP2 = xKLASS.ENERGIA * 0;
            xKLASS.TUNDP3 = xKLASS.ENERGIA * 0;
        end
        if strcmp(string(YPred),'ON1ON2ON3')   % Tarbitud energia
                                                % klassis ON1ON2ON3
            xKLASS.TUNDP1 = xKLASS.ENERGIA * (P1 / ON1ON2ON3TARBIMINE);
            xKLASS.TUNDP2 = xKLASS.ENERGIA * (P2 / ON1ON2ON3TARBIMINE);
            xKLASS.TUNDP3 = xKLASS.ENERGIA * (P3 / ON1ON2ON3TARBIMINE);
        end
        if strcmp(string(YPred),'ON1OFF2OFF3') % Tarbitud energia
                                                % klassis ON1OFF2OFF3
            xKLASS.TUNDP1 = xKLASS.ENERGIA * (P1 / ON1OFF2OFF3TARBIMINE);
            xKLASS.TUNDP2 = xKLASS.ENERGIA * 0;
            xKLASS.TUNDP3 = xKLASS.ENERGIA * 0;
        end
        if strcmp(string(YPred),'ON1OFF2ON3') % Tarbitud energia
                                                % klassis ON1OFF2ON3
            xKLASS.TUNDP1 = xKLASS.ENERGIA * (P1 / ON1OFF2ON3TARBIMINE);
            xKLASS.TUNDP2 = xKLASS.ENERGIA * 0;

```

```

        xKLASS.TUNDP3 = xKLASS.ENERGIA * (P3 / ON1OFF2ON3TARBIMINE);
    end
    if strcmp(string(YPred), 'ON1ON2OFF3') % Tarbitud energia
        % klassis ON1ON2OFF3
        xKLASS.TUNDP1 = xKLASS.ENERGIA * (P1 / ON1ON2OFF3TARBIMINE);
        xKLASS.TUNDP2 = xKLASS.ENERGIA * (P2 / ON1ON2OFF3TARBIMINE);
        xKLASS.TUNDP3 = xKLASS.ENERGIA * 0;
    end
    if strcmp(string(YPred), 'OFF1ON2ON3') % Tarbitud energia
        % klassis OFF1ON2ON3
        xKLASS.TUNDP1 = xKLASS.ENERGIA * 0;
        xKLASS.TUNDP2 = xKLASS.ENERGIA * (P2 / OFF1ON2ON3TARBIMINE);
        xKLASS.TUNDP3 = xKLASS.ENERGIA * (P3 / OFF1ON2ON3TARBIMINE);
    end
    if strcmp(string(YPred), 'OFF1OFF2ON3') % Tarbitud energia
        % klassis OFF1OFF2ON3
        xKLASS.TUNDP1 = xKLASS.ENERGIA * 0;
        xKLASS.TUNDP2 = xKLASS.ENERGIA * 0;
        xKLASS.TUNDP3 = xKLASS.ENERGIA * (P3 / OFF1OFF2ON3TARBIMINE);
    end
    if strcmp(string(YPred), 'OFF1ON2OFF3') % Tarbitud energia
        % klassis OFF1ON2OFF3
        xKLASS.TUNDP1 = xKLASS.ENERGIA * 0;
        xKLASS.TUNDP2 = xKLASS.ENERGIA * (P2 / OFF1ON2OFF3TARBIMINE);
        xKLASS.TUNDP3 = xKLASS.ENERGIA * 0;
    end
    xKLASS.YPred = YPred; % Tabeli tulpa klassi ennustuse salvestamine
    KLASS = [KLASS;xKLASS]; % Tabelite liitmine
end

```