

TALLINNA TEHNIKAÜLIKOOL
Infotehnoloogia teaduskond

Egle Palk 192416IABM

Elektritarbimise modelleerimine eramaja näitel

Magistritöö

Juhendaja: Margarita Spitsšakova
PhD

Tallinn 2021

Autorideklaratsioon

Kinnitan, et olen koostanud antud lõputöö iseseisvalt ning seda ei ole kellegi teise poolt varem kaitsmisele esitatud. Kõik töö koostamisel kasutatud teiste autorite tööd, olulised seisukohad, kirjandusallikatest ja mujalt pärinevad andmed on töös viidatud.

Autor: Egle Palk

03.05.2021

Annotatsioon

Inimeste energiavajadus üha kasvab, mis tähendab et, on vaja suurendada energiatõhusust ja mõelda jätkusuutlikkusele, mille tagamiseks on oluline saavutada ka stabiilne elektrivõrk. See toob omakorda välja vajaduse parema energiahalduse ja prognoosimismudelite järele. Käesoleva magistritöö eesmärk on mõista, millised faktorid mõjutavad eramaja elektritarbimist. Lisaks koostatakse lühiajaline (1h) elektritarbimise prognoos ning selgitatakse välja, kas päikesepaneelide paigaldamine on otstarbekas.

Töö käigus uuriti elektritarbimist ühe eramaja näitel ning koostati erinevaid graafikuid mõistmaks elektritarbimise mustreid. Leiti, et elektritarbimine ei ole kunagi sama, kuna seda mõjutavad mitmed asjaolud nagu näiteks ilm ja elanike käitumismallid. Suured erinevused on nii aastaegade, nädalapäevade kui ka päevasisesese tarbimise osas. Seetõttu on ühe maja elektritarbimise prognoosimine ka väga keerukas.

Magistritöö üheks osaks oli teada saada, kuidas kujuneb päikesepaneelide tootlikkus ning kui suure osa nad kataks ära elektrivajadusest ja kui palju oleks võimalik elektrit tagasi müüa. Leiti, et antud näite puhul kataksid päikesepaneelid umbes 35% kogutarbimisest, päikeseenergia tagasimüümine ei ole eriti tasuv tegevus ja tasuvusperiood oleks umbes 19 aastat. Lisaks prognoositi elektritarbimist ning kõige paremad tulemused saavutas LSTM mudel, kus ruutjuur ruutkeskmiseks hälbeks (RMSE) saadi 0,85, ja SVR, kus keskmiseks absoluutprotsendi veaks (MAPE) saadi 33,19.

Lõputöö on kirjutatud eesti keeles ning sisaldab teksti 52 leheküljel, 7 peatükki, 51 joonist, 12 tabelit.

Abstract

Modelling of Electricity Consumption on the Example of a Household

People's energy needs are increasing, which means that it is necessary to increase energy efficiency and think about sustainability, for which it is also important to achieve a stable electricity grid. This in turn highlights the need for better energy management and forecasting models. The aim of this master's thesis is to understand the patterns of electricity consumption of the household. This is done on the example of one household. In addition, a short-term (1h) electricity load is forecasted. Also, it is determined whether the installation of solar panels is reasonable.

Firstly, the household electricity consumption was studied and various graphs were made to understand the patterns of electricity consumption. It has been found that electricity consumption is never the same, as it is influenced by several factors, such as the weather and the behaviour of the family members. There are big differences in terms of seasons, days of the week and intraday consumption. That is why electricity consumption prediction for one household, is complicated.

Secondly, an important part of the master's thesis was to find out how much solar energy you can get from solar panels, how much it covers actual need and how much energy could be sold back to the grid. Some solar panel companies were asked for an offer. Based on one offer, it was calculated how much of the energy produced by the solar panels would cover the family's electricity consumption needs. Also, the payback period was calculated. It was concluded that it in this case solar panels are not reasonable as the payback period would be close to 19 years, which is too long.

In addition, electricity load was forecasted and the best results were obtained with the LSTM model, where the root mean square error (RMSE) was 0.85, and the SVR, where the mean absolute percentage error (MAPE) was 33.19.

The thesis is in Estonian and contains 52 pages of text, 7 chapters, 51 figures, 12 tables.

Lühendite ja mõistete sõnastik

ACDE	<i>Adaptive Conditional Density Estimation</i> , adaptiivne tinglik tihedusehinnang
ARIMA	<i>Autoregressive Integrated Moving Average</i> , autoregressiivne integreeritud libiseva keskmise mudel
ARMA	<i>Autoregressive Moving Average</i> , autoregressiivne libiseva keskmise mudel
BPN	<i>Back-Propagation Neural Network</i> , tagasilevi närvivõrk
DT	<i>Decision Tree</i> , otsustuspuu
DNN	<i>Deep Neural Network</i> , sügav närvivõrk
ENN	<i>Elman Artificial Neural Network</i> , Elmani närvivõrk
ETR	<i>Extremely Randomized Trees Regressor</i> , Väga juhusliku puu regressor
FDN	<i>Feedforward Deep Networks</i> , pärilevivõrk
GB	<i>Gradient Boosting</i> , gradiendi võimendamine
GMM	<i>Gaussian Mixture Model</i> , Gaussi segumudel
GPR	<i>Gaussian Process Regression</i> , Gaussi protsessirgeressioon
KNN	<i>K-Nearest Neighbours</i> , k-lähimat naabrit
kWh	Kilovatt-tund
LASSO	<i>Lasso Regression</i> , lassoregressioon
LR	Lineaarne regressioon
LSTM	<i>Long short-term memory</i> , pikk lühiajaline mälu
LS-SVM	<i>Least-Square Support Vector Machine</i> , vähimruutude tugivektorklassifitseerija
MAE	<i>Mean Absolute Error</i> , keskmine absoluuthälve
MAPE	<i>Mean Absolute Percentage Error</i> , keskmine absoluutprotsendi viga
MARS	<i>Multivariate Adaptive Regression Splines</i> , mitmemõõtmeline adaptiivne regressiooniliin
MLP	<i>Multi-Layer Perceptron</i> , mitmekihiline pertseptron
NMAE	<i>Normalized Mean Absolute Error</i> , normaliseeritud keskmine absoluuthälve

NMRSE	<i>Normalized Root Mean Square Error</i> , normaliseeritud ruutjuur ruutkeskmisest hälbest
NN / ANN	<i>Neural Network, Artificial Neural Network</i> , närvivõrk
RMSE	<i>Root Mean Square Error</i> , ruutjuur ruutkeskmisest hälbest
RN	<i>Random Forest</i> , juhuslik mets
RNN	<i>Recurrent Neural Network</i> , rekurrentne närvivõrk
RR	<i>Ridge Regression</i> , kantregressioon
RW	<i>Random Walk</i> , juhuslik ekslemine
SVM	<i>Support Vector Machine</i> , tugivektorklassifitseerija
SVR	<i>Support Vector Regression</i> , tugivektoreiregressioon
XGBoost	<i>Extreme Gradient Boosting</i> , ekstreemne gradiendi võimendamine

Sisukord

1 Sissejuhatus	12
1.1 Taust ja probleem	12
1.2 Ülesandepüstitus	14
1.3 Töö struktuur	14
2 Elektritarbimine ja selle ennustamise võimalused.....	16
2.1 Elektritarbimine ja seda mõjutavad faktorid	16
2.2 Elektritarbimise prognoosimine ja selle tulemuste hindamine.....	19
2.3 Näited koostatud mudelitest	21
2.4 Energia-ja elektritarbimine Eestis	23
3 Metoodika.....	25
3.1 Uuritava hoone kirjeldus	25
3.2 Tööriistad.....	26
3.3 Andmete kogumine.....	27
3.4 Andmete eeltöötlus	28
4 Andmete ülevaade ja analüüs	30
4.1 Andmete kirjeldamine	30
4.2 Ilmastikunähtused, korrelatsioon ja olulised muutujad	38
4.3 Hoone elektritarbimine ja seda mõjutavad tegurid.....	44
5 Päikesepaneelid ja nende otstarbekus.....	45
6 Elektritarbimise prognoos	51
6.1 Prognoosimudel ja selle atribuudid	51
6.2 Prognoosi tulemused.....	53
6.2.1 Mudel LSTM.....	54
6.2.2 Mudel SVR.....	55
6.2.3 Mudel XGBoost.....	57
6.2.4 Mudel ETR	58
6.2.5 Lineaarne regressioon.....	59
6.3 Prognoos aasta 2019 andmete alusel	60
6.4 Mudelite prognoositulemuste kokkuvõte	61

7 Kokkuvõte ja edasine töö	62
Kasutatud kirjandus	64
Lisa 1 – Lihtlitsents lõputöö reprodutseerimiseks ja lõputöö üldsusele kättesaadavaks tegemiseks	69
Lisa 2 – Tunnipõhine tarbimine koos elektri hinnaga	70
Lisa 3 – Päikesepaneelide tootlikkus	71

Jooniste loetelu

Joonis 1. Energia-ja elektritarbimise osakaal kodumajapidamistes lõppkasutuse liigi järgi (2018)	24
Joonis 2. Katuste asukohad.....	26
Joonis 3. Elektritarbimise hajusgraafik aastatel 2013-2020	30
Joonis 4. Elektritarbimine aastate kaupa	31
Joonis 5. Keskmise elektritarbimine ühes tunnis aastaegade kaupa	31
Joonis 6. Päevane elektritarbimine koos nädala keskmisega aastate lõikes	32
Joonis 7. Elektritarbimine aastate kaupa päeva järgi.....	32
Joonis 8. Elektritarbimine aastate kaupa koos elektrihinnaga.....	33
Joonis 9. Elektritarbimise karpdiagramm kuude lõikes	33
Joonis 10. Argipäeva ja nädalavahetuse keskmise tunnitarbimise erinevus	34
Joonis 11. Argipäeva ja nädalavahetuse keskmise tarbimise erinevus tundide kaupa ...	34
Joonis 12. Keskmise tunnipõhine tarbimine nädalapäeva järgi 2017-2020.....	35
Joonis 13. Keskmise tunnipõhine tarbimine nädalapäeva järgi 2017–2019	35
Joonis 14. Keskmise tunnipõhine tarbimine nädalapäeva järgi 2020	35
Joonis 15. Keskmise tunnipõhine tarbimine päevas tundide kaupa 2017-2020.....	36
Joonis 16. Keskmise tunnipõhine tarbimine päevas tundide kaupa 2017	36
Joonis 17. Keskmise tunnipõhine elektritarbimine kuude kaupa.....	37
Joonis 18. Elektritarbimise histogramm	37
Joonis 19. Elektritarbimise jaotustiheduse histogramm logaritmilisel skaalal.....	38
Joonis 20. Päevavalguse seos elektritarbimisega logaritmiga	38
Joonis 21. Päevavalguse seos elektritarbimisega	38
Joonis 22. Elektritarbimine aastate lõikes koos temperatuuriga.....	39
Joonis 23. Temperatuuri jaotustiheduse histogramm	40
Joonis 24. ETR-i 5 tähtsamat muutujat	41
Joonis 25. <i>SelectKBest</i> viis tähtsamat muutujat.....	42
Joonis 26. Pearsoni korrelatsioonimaatriks	42
Joonis 27. Autokorrelatsioon 365-päevase nihkega	43
Joonis 28. Osaline autokorrelatsioon 30-päevase nihkega	43

Joonis 29. Osaline korrelatsioon 96-tunnise nihkega	43
Joonis 30. Päikesepaneelide tootlikkus ja keskmine tarbimine kuus	47
Joonis 31. Päikeseenergia üle-ja puudujääk	47
Joonis 32. LSTM mudeli kood	54
Joonis 33. LSTM-mudeli treenimine	54
Joonis 34. Aasta 2020 prognoos kasutades LSTM-mudelit	55
Joonis 35. Väljavõte jaanuarikuu prognoosist (LSTM).....	55
Joonis 36. Väljavõte juunikuu prognoosist (LSTM)	55
Joonis 37. Aasta 2020 elektritarbimise prognoos kasutades SVR-mudelit.....	56
Joonis 38. Väljavõte jaanuarikuu prognoosist (SVR)	56
Joonis 39. Väljavõte juunikuu prognoosist (SVR).....	56
Joonis 40. Aasta 2020 detsembri elektritarbimise prognoos kasutades SVR- mudelit ..	57
Joonis 41. Aasta 2020 elektritarbimise prognoos kasutades XGBoost mudelit.....	58
Joonis 42. Väljavõte jaanuarikuu prognoosist (XGBoost)	58
Joonis 43. Väljavõte juunikuu prognoosist (XGBoost).....	58
Joonis 44. Aasta 2020 elektritarbimise prognoos kasutades ETR-mudelit	59
Joonis 45. Väljavõte jaanuarikuu prognoosist (ETR).....	59
Joonis 46. Väljavõte juunikuu prognoosist (ETR)	59
Joonis 47. Aasta 2020 elektritarbimise prognoos kasutades LR-mudelit.....	60
Joonis 48. Väljavõte jaanuarikuu prognoosist (LR)	60
Joonis 49. Väljavõte juunikuu prognoosist (LR).....	60
Joonis 50. Keskmine tarbimine nädalavahetusel tundide kaupa 2017–2020	70
Joonis 51. Keskmine tarbimine argipäeval tundide kaupa 2017–2020	70

Tabelite loetelu

Tabel 1. Päikesepaneelide võimalikud asukohad katustel.....	26
Tabel 2. Eleringist saadud elektriandmed (väljavõte)	27
Tabel 3. Ilmastikunähtuste Pearsoni korrelatsioon elektritarbimisega	39
Tabel 4. Peamaja katus (päikesepaneelid).....	46
Tabel 5. Kuuri ja garaaži katus (päikesepaneelid).....	46
Tabel 6. Kokkuvõttev tabel (päikesepaneelid)	46
Tabel 7. Päikeseenergia tasuvus	49
Tabel 8. Viite lisamine andmetesse (väljavõte).....	52
Tabel 9. Mudelite tulemused ilma transformeerimata.....	53
Tabel 10. Mudelite tulemused transformeeritud logaritmilisele skaalale.....	53
Tabel 11. Mudelite tulemused aasta 2019 peal.....	60
Tabel 12. Päikesepaneelide tootlikkus.....	71

1 Sissejuhatus

1.1 Taust ja probleem

Ülemaailmne elektrivajadus suureneb rahvaarvu ja elatustaseme paranemisega. Samuti kasutatakse üha rohkem suure võimsusega elektriseadmeid ja arendatakse aruka võrgu tehnoloogiaid ja elektriautosid. Kõik need tegurid muudavad elektrisüsteemi haldamise keerulisemaks [1]. Suurenev vajadus suurendada energiatõhusust ja kasutada paremini taastuvaid energiaallikaid toovad välja vajaduse parema energiahalduse ja prognoosimismudelite järele [2]. Elektritarbimise ennustamine annab elektriteenusepakkujatele võimaluse aru saada nõudluse suuruselt ning sellest tulenevalt valida ka õige energiastrateegia [3]. Euroopa Liit on selles valdkonnas võtnud teerajaja rolli ning teinud investeeringuid elektriarvestitesse [2].

Elektrimõõtesüsteemi ülesehitamine annab võimaluse koguda andmeid ja algatada kahesuunaline suhtlus majapidamiste ja elektriteenusepakkujate vahel [4]. Elektrimõõdikud, mis mõõdavad ja edastavad kord tunnis automaatselt elektritarbimise teavet, on teinud kättesaadavaks tohutu hulga üksikasju elektritarbimise kohta. Võimalus neid elektriandmeid analüüsida on kasulik nii klientidele, elektriteenusepakkujatele kui ka keskkonnale [5] kiirendades automaatselt nõudlusele reageeriva isikupärastatud süsteemi rakendamist üksikmajapidamistes, mis võimaldab isikupärastatud elektrilepinguid ja tariife. See omakorda viib elektrienergia tõhusa juurutamiseni [4]. Kui kodutarbijatel oleks nende igakuise elektritarbimise prognoos, saaksid nad oma elektritarbimist tõhusamalt juhtida [5]. Seda eesmärki silmas pidades on kõigepealt vaja mõista üksikute leibkondade käitumist elektritarbijana, et selle alusel täpsemini ennustada elektritarvet [4]. Lisaks on näha, et Euroopa Liidus tervikuna kodumajapidamiste energiatarbimine suureneb [6]. Elektritarbimist on mõistlik vaadata üksikmajapidamiste lõikes, kuna agregeeritud tarbimine on sujuvam ning sõltub ka rohkem sesoonsusest ja ilmastikust kui individuaalne tarbimine [7].

Jätkusuutlik energiatarbimine on viimasel ajal tõusnud energiaallikate nappuse ja keskkonnateadlikkuse suurenemise tõttu kriitiliseks eesmärgiks. Kui elektrienergia nõudlus ja pakkumine pole tasakaalus, on võrk ebastabiilne ning selles esineb tõrkeid.

Elektrienergia nõudluse prognoosimine on energiasüsteemi ökonoomse, usaldusväärse ja turvalise töö planeerimise peamine eeldus [4]. Taastuvenergia tootmine on üha rohkem suurenenud ja industrialiseerinud, kuid nende väljund on väga juhuslik ja kontrollimatu. See suurendab aga süsteemi ebakindlust ja toimimist, mistõttu on pidevalt muutuva taastuvenergia efektiivne kasutamine muutmas elektrijaamade peamiseks probleemiks [8]. Ettevõtte GridIO peamiseks ideeks on läbi tehnoloogia suurendada elektrivõrgu paindlikust ja optimeerida elektritarbimist. Selleks nad pakuvad kasutajatele võimalust osa võtta „virtuaalsest elektrijaamast“, mille idee on müüa elektrit võrku tagasi, siis kui nad seda ise ei vaja. Näiteks kui üleüldine elektri nõudlus ületab pakkumist, kuna elektrijaamas on millegipärast rike või taastuvenergiat ei suudetud piisavalt toota, siis GridIO kohandab oma „virtuaalsete elektrijaamade“ tarbimist ja kasutajad saavad selle eest raha. Lisaks optimeerib GridIO seadmete elektritarbimist kõrgema hinnaga tundidel [9].

Kuna iga maja vastutab oma tarbimise eest, on ka nende omanikel huvi aru saada, mis faktorid mõjutavad tarbimist ja kuidas on võimalik ikkagi kulutustes kokku hoida. Kuigi ühe tarbimiskoha analüüs on hetkel väga aktuaalne teema, siis näiteks Eestis ei anta tarbijale piisavalt head võimalust saada teadlikumaks tarbijaks. On olemas küll mobiilirakendused nii Eesti Energia kui ka 220 Energia poolt, kuid nendesse jõuab info pika viitega ning on vähe võimalusi elektritarbimise analüüsimiseks.

Lisaks eelnevale, on jätkusuutlikkuse tagamiseks oluline saavutada ka stabiilne elektrivõrk, mille juures on väga oluline koht elektritarbimise prognoosil. Ennustuse alusel oleks võimalik vähendada elektritarbimist kui nõudlus on liiga suur ja seeläbi optimeerida tarbimist kõrgema elektrihinnaga tundidel. Kuna kasutada on ainult ühe maja andmed, siis antud magistr töö keskendub selle maja elektritarbimise modelleerimisele. Eesmärk on mõista, mis mõjutab elektritarbimist ja teada saada, kui täpselt on võimalik ennustada ühe maja elektritarbimist. Kuna info seadmete üksiktarbimiste kohta puudub, prognoositakse töös kogu maja elektritarbimist.

Praegu saab Eleringilt kergesti kätte järgmise päeva elektrihinna läbi liidese, kuid puudub liides erakliendile, mis võimaldaks näha elektritarbimise mahtu reaalselt. Eleringi sõnul see võimalus ilmselt siiski tekib. Selles töös on võetud arvesse ka tulevikuvõimalusi ning üritatakse prognoosida lühiajalist elektritarbimist eeldades, et läbi liidese on tulevikus võimalik reaalselt tarbimise infot pärida. Lisaks saab tulemusi tuleviks ära kasutada ka

näiteks GridIO, kes saaks antud tööst infot, missugused tegurid üksiktarbijat mõjutavad ja milliseid neist prognoosimudelitesse lisada.

1.2 Ülesandepüstitus

Magistritöös modelleeritakse ühe maja elektritarbimist, eesmärgiga mõista, millised faktorid mõjutavad elektritarbimist. Praegu leidub internetis palju kalkulaatoreid, mis arvutavad küll välja, kui palju päikesepaneeli on ühel majaomanikul vaja, et see kataks ära tema aastase elektritarbimise. Ent sellised kalkulaatorid on aga väga üldised ja ei anna head ülevaadet tarbijale. Seetõttu on töö üheks osaks välja selgitada, kuidas kujuneb päikesepaneelide tootlikkus ning kui suure osa nad kataks ära elektrivajadusest ja kui palju oleks võimalik elektrit tagasi müüa. Lisaks koostatakse lühiajaline (1h) elektritarbimise prognoos. Elektritarbimise ennustamine annab võimaluse aru saada, kui võrd prognoositav tarbimine on ja kas selle põhjal on võimalik tarbimist kõrgema elektri hinnaga tundidel optimeerida. Kuna sama päeva elektri hinna graafik on juba tunnipõhiselt saadaval, aitaks tarbimisprognoosi lisamine teadlikumaks tarbijaks saada.

Uurimisküsimused:

- Millised parameetrid mõjutavad elektritarbimist?
- Kui täpselt on võimalik ennustada ühe maja elektritarbimist?
- Milline töös kasutatud ennustusmudelitest annab kõige parema tulemuse?
- Kui suure osa tarbimisvajadusest katab päikesepaneelidest toodetud elektrienergia ja kui palju on võimalik elektrit tagasi müüa ja kas nende paigaldamine on otstarbekas?

1.3 Töö struktuur

Esimeses peatükis kirjeldatakse tausta ja probleemi, sõnastatakse eesmärk ning esitatakse uurimisküsimused. Teises peatükis tehakse ülevaade elektritarbimist mõjutavatest faktoritest, elektritarbimise prognoosimise võimalustest ning energia-ja elektritarbimisest Eestis. Kolmandas peatükis kirjeldatakse lähemalt uuritavat hoonet ja töös kasutatavaid

tööriistu ning antakse ülevaade, milliseid andmeid edaspidi kasutatakse ja kuidas neid koguti. Neljandas peatükis uuritakse andmeid ja nendes leiduvaid mustreid ning leitakse elektritarbimist mõjutavad olulised muutujad. Viiendas peatükis selgitatakse, kuidas kujuneb päiksepaneelide tootlikkus ning kui suure osa nad kataks ära elektrivajadusest ja kui palju oleks võimalik elektrit tagasi müüa. Kuuendas peatükis prognoositakse lühiajalist elektritarbimist ning viimases peatükis tehakse kokkuvõtte magistritöö tulemustest.

2 Elektritarbimine ja selle ennustamise võimalused

Peatükk annab ülevaate elektritarbimist mõjutada võivatest faktoritest ning elektritarbimise prognoosi- ja prognoositulemuste hindamise meetoditest. Üldisema ülevaate huvides kirjeldatakse ka energia- ja elektritarbimist Eestis.

2.1 Elektritarbimine ja seda mõjutavad faktorid

Elektrienergia tarbimist saab klassifitseerida eramajapidamise või äri-ja tööstuslikuks elektritarbimiseks. Eramajapidamise elektritarbimine on seotud inimeste kodu või eluruumiga. Äritarbivad on ettevõtted ja tööstusharud, mis vajavad ettevõtte töös hoidmiseks kodutarbijatest märkimisväärselt enam elektrit [10].

Elektritarbimise prognoosimine on seda mõjutavate tegurite mittelineaarsuse tõttu keeruline [11]. Enamik statistilisi mudeleid eeldab muutumatut nõudlust ega suuda seetõttu ennustada mittelineaarseid seoseid tarbimise ja seda mõjutavate faktorite vahel nagu näiteks päeva- ja nädalanerütm [4]. Süsteemis on palju määramatust, kuna elektritarbimist mõjutavad mitmed tegurid, näiteks ilmastikutingimused, päevavalgus, kalendrist tulenevad põhjused (nt riigipühad, nädalavahetused), aga ka inimeste erinevad käitumismustrid [3]. Hiljutised uuringud on vaadelnud, kuidas integreerida mudelitesse ajalisi faktoreid (näiteks kalendriteavet) ning ilmamuujuaid ja ilmatedetetest tulevat infot [12]. Kalendriinfo kasutamine tarbimist prognoosides hõlbustab tipptarbimise ennustamist [13]. Individuaalsete majapidamiste päevast elektritarbimist mõjutab igapäevane režiim. Päeva rütmi mõjutavad näiteks ilm, erisündmused ja päeva tüüp [4]. Majapidamiste individuaalsed elektritarbimised näitavad väga dünaamilisi ja kõikuvaid mustreid. Üksikmajapidamise tarbimist on raskem prognoosida kui üldist elektritarbimist, kuna käitumisharjumusi on keeruline ette näha [14]. Majapidamise üldine elustiil võib aastate jooksul muutuda, mistõttu võib olla keeruline elektritarbimist mitmeaastaste andmete põhjal ennustada. Ennustusvõimet võib aidata suurendada sotsiaal-demograafiliste tegurite lisamine [13].

Prognoosi pikkuse põhjal võib nõudluse ennustamise jagada neljaks tüübiks [4] [10] [15] [1]:

1. Väga lühiajaline tarbimise prognoosimine (mõnest minutist tunnini).
2. Lühiajaline tarbimise prognoosimine (1 tund kuni 1 nädal või kuni 1 kuu). Eeldatakse, et sellist ajaperioodi kasutatakse prognoosimisel kõige rohkem. Tund tunni kaupa prognoos eeldab, et viimane vaatlus on alati enne järgmise tunni prognoosi esitamist olemas [13].
3. Keskmise tähtajaga tarbimise prognoosimine (üks nädal kuni üks aasta).
4. Pikaajaline tarbimise prognoosimine (üle ühe aasta).

R. V. Jones, A. Fuertes ja K. J. Lomas annavad ülevaate elektritarbimist mõjutavatest faktoritest: 13 sotsioloogilist-majandusklikku faktorit, 12 majapidamistüübi faktorit ja 37 seadete faktorit [16]. Eri uuringutes on saadud eri faktorite mõjust elektritarbimisele erinevaid tulemusi. Selles magistritöös käsitletakse ainult neid faktoreid, mis on uuringutes näidanud kas ülekaalukalt positiivset või negatiivset mõju.

Sotsiaal-majanduslikud [17] [16]:

- Elanike arv majapidamises: mida rohkem elanikke, seda suurem on elektritarbimine. Samas on tehtud kindlaks, et elanike arvu suurenemine korterites elektritarbimist ei suurenda.
- Teismeliste arv majapidamises: mida rohkem teismelisi, seda suurem on elektritarbimine. Seda on põhjendatud tõsiasiaga, et teismelised vaatavad rohkem televisiooni või mängivad videomänge.
- Majapidamise eest vastutava inimese vanus. Majapidamise eest vastutav isik määrab või annab eeskuju, kuidas peaks majapidamises käituma ja mõjutab seetõttu elektritarbimist. Vanuse ja tarbimise vahel esineb mittelineaarne seos. Ühe uurimuse kohaselt on elektritarbimine on kõrgem, kui vastutava isiku vanus on 50-65 vahel ja väiksem, kui vanus on alla 50 või üle 65. Teise uurimuse kohaselt on elektritarbimine kõrgem, kui vastutava pereliikme vanus on 45-64 vahel, ja madalam, kui tema vanus on 35-44 või üle 64.
- Majapidamise sissetulek: mida suurem on majapidamise sissetulek, seda suurem on elektritarbimine. Ühe võimaliku põhjusena mainiti seda, et suurema sissetulekuga majapidamistel on suurem eluase ja rohkem kodumasinaid.

Eluasemetüübiga seotud faktorid [16]:

- Eluasemetüüp: Elektritarbimine suureneb koos eluruumi nn eraldumisega, st. ühepereelamutes tarbitakse rohkem elektrit kui paarismajades või korterites. Eestis jagunevad eluasemetüübid järgmiselt [18]:
 - korterelamu (Eestis 60,9%),
 - paarismaja (4,9),
 - ühepereelamu (33,7%),
 - muu (0,5%).
- Eluaseme vanus: mida vanem on maja, seda suurem on elektritarbimine. Elektritarbimine on väiksem uuemates majades, kuna need on paremini soojustatud ja neis on tõhusamad seadmed.
- Eluruumide arv: mida rohkem tube, seda suurem on elektritarbimine.
- Magamistubade arv: mida rohkem magamistube, seda suurem on elektritarbimine.
- Elamispinna suurus: mida suurem on elamispind, seda suurem on elektritarbimine.
- Elektrilise küttesüsteemi olemasolu: positiivne korrelatsioon elektritarbimisega.
- Konditsioneeride olemasolu: positiivne korrelatsioon elektritarbimisega.
- Elektriline veeküte: positiivne korrelatsioon elektritarbimisega.

Pikaajalised prognoosid on sageli seotud just sotsiaal-majanduslike muutujate ja hoone omadustega, sest nende muutujate ja pikaajalise elektritarbimise vahel on selge korrelatsioon [15].

Elektriseadmetega seotud faktorid [16]:

Elektriseadmete (nt arvutid, televiisor, pesumasinad, nõudepesumasin, külmikud) arv ja nende kasutamise tihedus mõjutab tugevalt elektritarbimist. Samas on elektrienergia uurimise juures seadmete arvust olulisem teada saada, kas majapidamises kasutatakse elektrilist veekütet [10].

Lisaks eelnevale võivad elektritarbimist mõjutada [19]:

- kognitiivsed tegurid: väärtussüsteemid, normid, veendumused, hoiakud, teadmised ja oskused, motivatsioon ja pühendumus;
- käitumistegurid: harjumused, rutiin, käitumismallid, varasem kogemus;

- kontekstfaktoriid: poliitika, kogukond, elektriinna muutused, reklaamikampaaniad, tehnoloogilised võimalused.

Eramajapidamiste elektritarbimise ennustamiseks on vaja tundma õppida elektritarbimise mustreid, alles seejärel saab ennustada tarbimist [4]. Kui kodutarbijatel oleks oma igakuise elektritarbimise prognoos, saaksid nad elektritarbimist tõhusamalt juhtida [5].

2.2 Elektritarbimise prognoosimine ja selle tulemuste hindamine

Hoone energiatarbimise ennustamismeetodid võib jagada kolme kategooriasse [20]:

1. Insenerimeetodid: kasutavad füüsikalisi printsiipe, et arvutada kogu maja või selle osade termodünaamika ja energiakäitumist. Selliste simulatsioonide tegemiseks on välja arendatud sadu tarkvaru. Nende meetodite puuduseks on nende teostuse kulukus (keerukas ja vajab ekspertteadmisi) ning väga detailse info vajadus hoone kohta.
2. Statistilised meetodid: statistilistes regressioonimudelites vaadeldakse korrelatsiooni energiatarbimise ja seda mõjutavate muutujate vahel. Statistiliste meetodite miinuseks on vajadus suure hulga sisendandmete järele. Statistilised meetodid kasutavad näiteks ARIMA, ARMA, Kalamani filtrid, eksponentsiaalne silumine [1].
3. Tehisintellekti meetodid: kõige levinumad hoone energiatarbimise ennustamise meetodid. Nende positiivseks küljeks on võime lahendada mittelineaarsusest tekkivaid probleeme, miinuseks aga see et need vajavad õppimiseks suurt hulka andmeid. Tehisintellektil põhinevad mudelid on näiteks närvivõrgud (NN), SVM, hägus loogika (*Fuzzy Logic*) [1].

Uurimused on näidanud, et elektritarbimise prognoosimise enimkasutatud mudeliteks on näiteks NN, SVM, ARIMA, juhuslik mets (RF), otsustuspuu (DT), LSTM, k-lähimat naabrit (KNN), hägus loogika ja XGboost, mis põhineb otsustuspuudel [10]. Kõige laialdasemat kasutust on leidnud närvivõrgud ja tugivektorklassifitseerija ehk SVM [20]. Närvivõrgu (NN) eeliseks on selle võime näiteandmetest õppida ja tunda pärast õppimisprotsessi lõppu mittelineaarseid sõltuvusi [21]. Närvivõrke on palju rakendatud erinevates energiamudelites [22] [23], neist enim on mudel rakendatud mitmekihiline pertseptroni mudelit (MLP), mis koosneb mitmest arvutusühikute kihist. Iga neuron

mingis kindlas neuronkihis on ühendatud järgneva kihi neuronitega. Kui närvivõrku rakendatakse muude probleemide lahendamiseks kui klassifitseerimine või mustrite äratundmine, siis parandab lühimälu kasutamine närvivõrgu jõudlust. Näiteks on seda implementeeritud rekurrentses närvivõrgus (RNN-is) [22], s.o NN tüübis, mida saab paremini rakendada järjestikuseid (nt aegridasid) andmeid töödeldes. [21]. RNN-i miinuseks aga on haihtuvad ja plahvatavad gradiendid [24]. Probleemi aitab lahendada pika lühiajalise mälu mudel (LSTM). Närvivõrkude miinuseks on see, et need vajavad treenimist ning suure närvivõrgu puhul on töötlemisaeg pikk [25].

Tugivektoregressioon (SVR) on hoone elektritarbimise prognoosimisel andud häid tulemusi [26]. Tugivektorklassifitseerijat (SVM) on edukalt rakendatud mittelineaarse regressiooni ja aegridade probleemide lahendamisel ning see ei ole erindite suhtes nii tundlik nagu närvivõrk [11]. SVM on juhendatud masinõppe mudel, mida kasutatakse klassifitseerimisprobleemide lahendamiseks. SVM-id koosnevad peamiselt valikulisest kernelist ja optimeerimisalgoritmist. Kernel muudab mittelineaarsed andmed kõrgdimensionaalseks ruumiks ja andmed lineaarselt eraldatavaks. Kuna SVM püüab minimeerida üldistusvea ülemist piiri, mis koosneb treeningvea summast ja usaldusnivoost, saavutab SVM tavaliselt kõrgema üldistusvõime kui teised masinõppe tehnikad [12]. Samas on SVM/SVR mudelid arvutuslikult ebaefektiivsed [23].

Kirjandusest selgub, et regressioonimudeleid kasutatakse tänu nende lihtsusele ja täpsusele tihti pikaajaliseks prognoosimiseks (aasta või kauem). Seevastu närvivõrke, SVM-i ja aegridade analüüsi (nt ARIMA, ARMA) kasutatakse peamiselt lühiajalise ennustuse tegemiseks. Lühiajalised prognoosid nõuavad keerukamaid mudeleid, kuna sellises ajaskaalas on muutujate omavaheline seos keerulisem ja tundlikum [15].

Viimasel ajal on rohkem huvi tuntud hübriidalgoritmide vastu, sest elektritarbimist on selle mittelineaarsuse, ajalise varieeruvuse ja määramatuse tõttu ainult ühe kindla algoritmiga on raske ennustada [27]. Hübriidmudelid võivad saavutada üksikmudelitest parema ennustustäpsuse, kuna nendes kombineeritakse üksikmudelite eelised. Sellest lähtudes on eri hübriidmudelite väljatöötamiseks saadaval arvukalt prognoosimeetodeid, optimeerimisalgoritme ja andmetöötlusvõtteid. Samas selle kohta häid viiteid pole, kuidas ja milliseid mudeleid hübriidmudelisse valida [1].

Üldiselt pole kindlat tehnikat või mudelit, mis lühiajaliste ennustuste tegemisel domineeriks ja oluline on mõista, et universaalset kõige paremat mudelit pole olemas [28].

Mudelite hindamine

Kirjanduses on prognoosimisalgoritmi täpsuse hindamiseks välja toodud kolm laialdaselt kasutatavat mõõdikut: MAPE, keskmine absoluuthälve (MAE) ja ruutjuur ruutkeskmisest hälbest (RMSE). MAPE puuduseks on suutmatus tulla toime nullile lähenevate väärtustega, paljude majapidamiste tarbimine aga on teatud aegadel nullilähedane. Lisaks on üsna tavalised väga väikeste tarbimisväärtustega leibkonnad, see teeb MAPE väärtuse väga suureks, lähenedes lõpmatuseni. Erinevalt MAPE-st ei mõjuta nullile lähenevad väärtused MAE ja RMSE meetodeid, mis on mõlemad ka skaala-sõltuvad mõõdikud. Normaliseeritud keskmine absoluuthälve (NMAE) ja normaliseeritud ruutjuur ruutkeskmisest hälbest (NRMSE) on aga skaalast sõltumatud ja tulevad nullilähedaste väärtustega toime [29]. Kirjanduse andmeil hinnatakse täpsust enim MAPE ja RMSE mudeliga [10].

2.3 Näited koostatud mudelitest

Järgnevalt kirjeldatakse konkreetsed näited eri töodes kasutatud mudelitest ja nende tulemustest.

Minutipõhise tarbimise ennustamine: Võrreldi omavahel välja pakutud mudelit ning tagasilevi närvivõrku (BPN), lineaarset regressiooni (LR), SVR-i, juhuslikku ekslemist (RW) ja adaptiivset tinglikku tihedusehinnangut (ARIMA). BPN, LR ja SVR saavutasid madalama prognoosimistäpsuse, kuna eirasid käitumismustri analüüsi olulisust. RW tulemus oli kehvem kui teistel. ARIMA andis keskmiseks absoluutprotsendi veaks (MAPE) 8.81%. Autorite arvates ei ole see mudel tarbimise prognoosimiseks piisav [4].

Tunnipõhise elektritarbimise ennustamine: Mudel põhineb adaptiivse tingimusliku tiheduse hinnangul (ACDE), mis eraldab elektritarbimisest temperatuurist sõltuva komponendi. Majade soojuspidavuse hindamiseks arvutatakse kadutegur. Selleks lahutati välistemperatuur sisetemperatuurist [3].

Tunnipõhise elektritarbimise ennustamine: Elektritarbimist ennustati mudeli põhjal, mis põhineb Elmani närvivõrgu (ENN) baasil. Testnädala jaoks arvutatud keskmine viga

oli 1,5%, maksimaalse vea korral 4,6%. Ennustustulemusi parandas niiskuseindeksi kasutuselevõtt [22].

Päeva ja tunnipõhise elektritarbimise ennustamine: Individuaalmajapidamise elektritarbimise ennustamiseks kasutati SVR meetodit. Analüüs näitab, et üksikute majapidamiste energiatarbimist on võimalik ennustada, kuid täpsus sõltub suuresti sellest, kui võrd leibkonna käitumine varieerub. Seetõttu andis päevane elektriennustus parema tulemuse kui tunnipõhine [12].

Päeva- ja tunnipõhise elektritarbimise ennustamine: Eramajapidamise elektritarbimise ennustamiseks kasutati närvivõrku, SVR-i, LS-SVM-i, Gaussi protsessiregressiooni (GNN) ja Gausi segumudelit (GSM) [23].

Igapäevase elektritarbimise ennustamine: Statistilise analüüsi abil tehti kindlaks, et regressioonipuude tehnika on teiste tehnikatega võrreldes oluliselt parem, kuid SVR mudel näitab paremat üldistusvõimet. Uurimuses leiti, et individuaalse majapidamise elektritarbimise mudeli väljatöötamiseks piisab üheaastastest andmetest, kuna andmete täiendav suurendamine on marginaalne [13].

Igakoise elektritarbimise ennustamine: Elektritarbimise andmete peal rakendatakse järgnevaid meetodeid: lineaarne regressioon, kantregressioon (RR), lassoregressioon (LASSO), mitmemõõtmeline adaptiivne regressiooniliin (MARS), gradiendi võimendamine (GB). Nende mudelite abil ennustati igale kliendile kuu koguelektritarbimine. Gradienti mudel andis kõige täpsema ennustuse: üle 95% klientidel oli MAPE skoor alla 4% [5].

Iga-aastase elektritarbimise ennustamine: Ühendati omavahel kokku XGboost ja pärilevivõrk (FDN) kasutades kantregressiooni. Ühendatud mudel annab ligi 30% parema tulemuse kui klassikalised regressioonimudelid [30].

Elektritarbimise prognoosimist on üritatud teha ka Eesti andmete alusel. Järgmisena on välja toodud mõned selle valdkonna lõputööd.

- Elektrienergia tarbimise lühiajaline ennustamine tehisnärvivõrkude abil (bakalaureusetöö) [31]. Töös üritati parendada AS-i Alexela jaoks välja töötatud elektritarbimise närvivõrgu ennustusmudelit.
- Elektritarbimise lühiajaline modelleerimine ja ennustamine: Eesti juhtumi analüüs (magistritöö) [32]. Töös üritati parendada AS-i Alexela jaoks välja töötatud elektritarbimise ennustusmudelit ilmastikuandmete lisamise abil.

- Eluruumide elektritarbimise prognoosimine masinõppealgoritmide abil (bakalaureusetöö) [33]. Töös üritati prognoosida ühe korteri elektritarbimist.
- Nordpooli elektri hinna analüüs ja ennustusmudeli arendamine (magistritöö) [34].

See magistritöö erineb eelmistest keskendudes ühe eramaja elektritarbimise analüüsile, sealhulgas uuritakse päikesepaneelide kasutussevõtu otstarbekust ning prognoositakse kõnealuse eramaja lühiajalist elektritarbimist.

2.4 Energia-ja elektritarbimine Eestis

Eestis paigaldati esimesed kaugloetavad elektriarvestid aastal 2012 [35]. Aastal 2016 teatas Elektrilevi, et kaugloetavana toimib üle 96% arvestitest [36]. Vastavalt Euroopa energiatõhususe direktiivile tuleb hiljemalt 2026. a lõpuks muuta kõik hoone- ja korteripõhised vee-, elektri-, gaasi- ja küttearvestid kaugloetavaks, et saavutada energiasäästu [37].


Eesti on pigem suurema energiatarbimisega (energia \neq elekter) riik [6]. Euroopa Liidu keskmine aastane energiatarbimine on sõltumata majatüübist 180 kWh/m², Eestis aga 285 kWh/m² [38]. 2018. aastal moodustas kodumajapidamiste tarbimine kogu energiatarbimisest Euroopas Liidus 26% [39]. Eestis aga oli see ligi 32% [40] [41] Eestis moodustab elektrienergia kogu kodumajapidamise energiatarbimisest 17% ning Eesti aastane koguelektritarbimine on ligikaudu 8,5 TWh aastas [42] [43].

Eurostat jaotab kodumajapidamise energiatarbimise kasutusotstarbe järgi järgmiselt [42]

- ruumikütmine,
- ruumijahutamine,
- vee soojendamine,
- toiduvalmistamine,
- valgustus ja seadmed,
- muu.

Eestis kasutatakse 72,7 % kodumajapidamise energiatarbimisest just ruumide kütmisele (Euroopa Liidus keskmiselt 63,6%), millest ainult 5,2% köetakse elektrienergiaga.

Veeküttele läheb 11,8 % ja toiduvalmistamisele 4,9% kodumajapidamise energiatarbimisest, millest elektrienergia moodustab vastavalt 5,5% ja 41,8% [42].



Joonis 1. Energia-ja elektritarbimise osakaal kodumajapidamistes lõppkasutuse liigi järgi (2018)

3 Metoodika

Käesoleva magistritöö eesmärk on mõista, millised faktorid mõjutavad eramaja elektritarbimist. Selleks uuritakse ühe maja elektriandmeid. Lisaks koostatakse lühiajaline (1h) elektritarbimise prognoos eesmärgiga võtta tulevikus kasutusele parim elektritarbimise optimeerimise mudel.

Peatükis kirjeldatakse uuritavat hoonet, elektritarbimise analüüsiks kasutatud tööriistu ning andmete kogumist ja nende eeltöötlust.

3.1 Uuritava hoone kirjeldus

Magistritöös antakse ülevaade ühe puithoone energiatarbimisest. Uuritav hoone on Tallinnas, Nõmme linnaosas asuv eramaja, mille ehitusaasta on teadmata, hoone renoveeriti aastal 2001. Hoone põranda kogupindala on 317,5 ruutmeetrit. Hoonet köetakse puidu ja elektriga, sellesse on paigaldatud kolm õhksoojuspumpa ning kolm elektriga köetavat veeboilerit, mis kokku mahutavad 450 liitrit. Umbes 27 ruutmeetrit põrandapinnast köetakse (vannitoad ja tualettruumid) elektrikõrreandaküttega. Kokku on hoones kaheksa tuba, sh neli magamistuba.

Ülevaade suurematest seadmetest:

- 3 külmikut ja 1 kirstsügavkülmik (elektrikulu ligi 300 kWh aastas külmiku kohta aastas)
- 5 televiisorit (ligi 200 kWh televiisori kohta aastas)
- 1 lauaarvuti ja 2 sülearvutit (ligi 200 kWh arvuti kohta aastas)
- 2 elektripliiti (ligi 350 kWh aastas)

Hoones elab viis täiskasvanut ja üks teismeline, perepea vanus on 53 aastat.

Kasutusel on bõrispakett 220 [44], aastas kulub elektri peale umbes 1700 eurot (käibemaksuta).

Päikesepaneele saab paigaldada kolme kohta: peamaja, kuuri ja garaaži katusele.

Tabel 1. Päikesepaneelide võimalikud asukohad katustel

	Peamaja katus	Kuuri katus	Garaaži katus
Katusepind (m²)	~ 64 (5 x 12.8)	~ 20 (5 x 4)	~ 32 (4.3 x 7.4)
Kaldenurk (kraadi)	~ 45	~ 15	~ 15
Katuse suund päikese suhtes (ilmakaar)	Lõuna	Lõuna	Lõuna

Kaardirakenduse [45] abil tehtud illustreerivale kuvatõmmisele on lisatud ilmakaared [46]. Punaste kastikestega on märgitud alad, kuhu päikesepaneelid oleks võimalik paigaldada.



Joonis 2. Katuste asukohad

3.2 Tööriistad

Andmete töötlemiseks kasutati programmeerimiskeelt *python*, peamiselt teeki *scikit-learn*, *pandas*, *numpy*, *tensorflow* ja *keras* API. Graafikute tegemiseks kasutati teeki *matplotlib* ja sellel põhinevat teeki *seaborn*. Kogu töö teostati keskkonnas Google Colab.

3.3 Andmete kogumine

Elektriandmed koguti manuaalselt elektri süsteemihalduri Eleringi andmelaost [47]. Elektritarbimise andmed saadi Microsoft Excel Worksheet (.xlsx) formaadis alates aastast 2011. Kahe esimese aasta (2011-2012) tarbimisinfo on päevapõhine, alates 2013 aga tunnipõhine. Seetõttu otsustati magistritöös kasutada andmeid alates aastast 2013. Tabelis on kaks veergu „tund“ ja „tarbimine“. Veerus „tund“ on info kuupäeva, nädalapäeva ja kellaaja kohta, veerus „tarbimine“ vaadeldavas tunnis tarbitud elekter kilovatt-tunni (kWh) kohta.

Tabel 2. Eleringist saadud elektriandmed (väljavõte)

Tund	Tarbimine
01.01.2013 T 00:00	4,196
01.01.2013 T 01:00	4,057
01.01.2013 T 02:00	3,776
01.01.2013 T 03:00	3,525

Ilmastikuandmed küsiti Riigi Ilmateenistusest [48]. Lisaks uuriti samalt kontaktilt ilmaennustuse täpsust (tegelik ilm võrreldes ennustatuga), kuna ka tulevikus tuleb elektritarbimise pikemal prognoosimiseks kasutada ilmaennustust. Selgus, et 24h prognoosi puhul on see tavaliselt 95%, 48h prognoosi puhul 90%, 72h prognoosi puhul 85% ning 96h prognoosi puhul 80%.

Harku ilmajaamast saadi aastate 2013-2020 kohta tunnipõhised andmed .xlsx formaadis. Andmetes olid järgmised veerud:

- aasta,
- kuu,
- päev,
- kell (UTC),
- tunni keskmine õhurõhk merepinna kõrgusel hPa,
- tunni sademete hulk mm,
- tunni keskmine suhteline õhuniiskus %,
- tunni keskmine õhutemperatuur °C,
- 10 minuti keskmine nähtavus m,

- tunni atmosfäärinähtus (iga nähtus, nt udu, sademed jms, on kodeeritud numbriks),
- tunni keskmine tuulesuund, °
- tunni keskmine tuulekiirus m/s,
- tunni maksimum tuulekiirus m/s.

Töös otsustati eemaldada veerg infoga tunni atmosfäärinähtuse. Atmosfäärinähtused eemaldati, kuna ilmastikunähtused on juba numbrilisel kujul olemas teiste muutujate näol.

Riigipühade info leiti Riigiteatajast [49]. Liikuvad pühad lisati andmetesse manuaalselt.

Päevavalguse info koguti kasutades rakendusliidest *Sunrise Sunset* (API). API sisenditeks on laius-ja pikkuskraad ning kuupäev. API väljund on *json*, mis sisaldab infot päevavalguse pikkuse kohta tundides. Andmete kogumiseks koostati *python*'is eraldi programm. Peale andmete pärimist konverteeriti päevapikkus minutiteks ja salvestati aastate 2013-2020 päevavalguse pikkuse andmed koos kuupäevaga eraldi *Comma-separated values (csv)* faili, et neid oleks hiljem võimalik elektriandmetega ühendada.

Parema ülevaate saamiseks vaadeldakse lisaks tarbimisele ka Nord Pooli hindu. Nord Pool on elektribörsi ettevõtte, mis korraldab elektri reguleeritud kaubandust Balti riikides, Soomes, Rootsis, Norras ja Taanis [50]. Elektri hinna andmed (*Elsport Prices*) saadi kätte Nord Pooli lehelt [51]. Sealt võeti tunnipõhised andmed Eesti kohta aastate 2017-2020 kohta. Iga aasta kohta oli eraldi *xlsx*-fail.

3.4 Andmete eeltöötlus

Töö käigus otsustati, et tarbimisandmete peal ei rakendata erindite (*outliers*) leidmise meetodikaid, kuna andmekogus puuduvad vead. Maksimaalseks väärtuseks oli 11,134 kWh, mis mõõdeti 4. jaanuaril 2017. Kuna peakaitse kannatab ideaalsetes tingimustes 17,25 kWh, on see väärtus ilmselt õige. Andmekogus oli ka neli rida 0 kWh tarbimist. Andmeid uurides selgus, et need on seotud elektrikatkestustega, väiksem tarbimine ka eelneval tunnil viitab sellele, et elektrikatkestus algas kõnealuse tunni ajal. Need

nullväärtused asendati eelmise tarbimisväärtusega, et oleks võimalik hiljem andmeid transformeerida logaritmilisele skaalale.

Eelmises alapeatükis kirjeldati tarbimisandmetes veergu „tund“, kus on info kuupäeva, nädalapäeva ja kellaaja kohta. Esimese sammuna eraldati sealt nädalapäeva info ning hakati indeksina kasutama kuupäeva ja kellaaja infot. Seejärel lisati info argipäeva ja nädalavahetuse kohta. Argipäev sai väärtuseks 0 ja nädalavahetus koos riigipühadega väärtuse 1. Samuti lisati info aastaaja (talv, kevad, suvi, sügis), päeva järjenumbri (aastas 365 või 366 päeva) ja nädala järjenumbri kohta. Edasi lisati andmetele info päevavalguse pikkuse ja ilmaandmete kohta.

Ilmaandmetes oli kokku 161 rida, mis sisaldasid NA väärtusi, mis asendati järgmise valiitse väärtusega

Elektrihinna andmete puhul pidi muutma ajatsooni ehk liigutama aega tunni võrra edasi ning hind EUR/kWh konverteeriti ümber senti/kWh-ks.


4 Andmete ülevaade ja analüüs

Peatükis kirjeldatakse andmeid ja näidatakse seoseid tarbimise ja eri muutujate (nt nädalapäeva-, tunni-, kuu-, aastaaja- ja ilmastikuinfo) vahel. .

4.1 Andmete kirjeldamine

Kirjeldav statistika annab ülevaate andmetest, võimaldab neid kirjeldada ning teha nende põhjal kokkuvõtteid ja järeldusi. Kogutud andmeid on visualiseeritud ning välja on selgitatud muutujate vaheline korrelatsioon.

Joonisel Joonis 3 on näha aastate lõikes andmepunkte, selgub, et aastast 2013 kuni 2016 keskpaigani ei ole mõõtmistulemused sama täpsed kui järgnevatel aastatel. Võimalik, et andmeid on kuidagi kopeeritud ja need ei kajasta reaalseid tulemusi. Seetõttu otsustati käesolevas magistritöös kasutada ainult andmeid aastatest 2017- 2020 .




Joonis 3. Elektritarbimise hajusgraafik aastatel 2013-2020

Pärast andmete eemaldamist jäi andmekogusse järgi 35064 rida. Tunni elektritarbimise keskvärtus on ligikaudu 2,4 kWh ja standardhälve 1,7 kWh. Seega on elektritarbimise kõikumine keskvärtuse ümber üpriski suur.

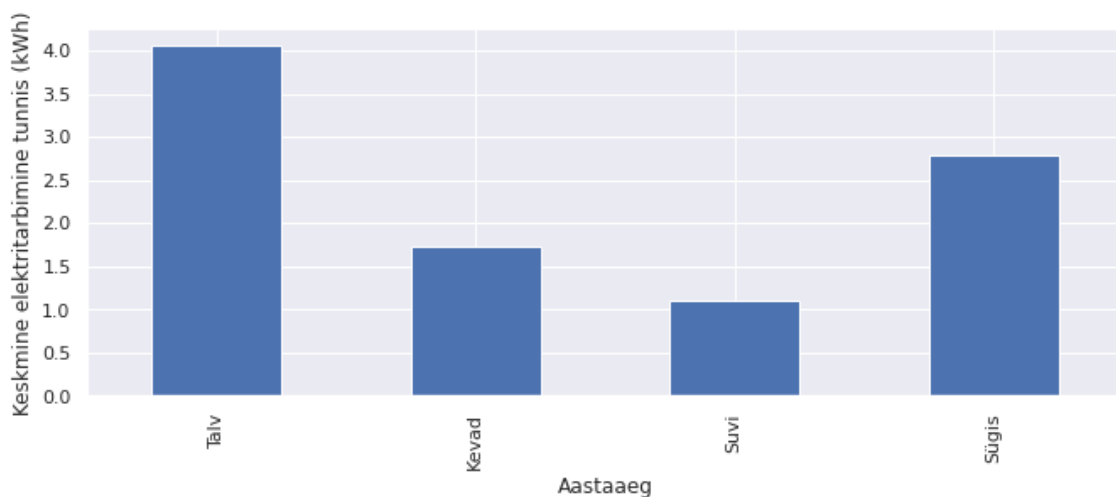
Uurimisobjekti aastast elektritarbimist mõjutab eelkõige see, kui külm on talv, kuna maja kõige suuremad elektritarbijad on elektrilised kütteseadmed. Aastal 2017 oli

elektritarbimine kõige suurem, kuid peamiselt on see püsinud 20 000 kWh ümber aastas (vt Joonis 4). Märkimist väärib ka see, et 2020. aastal kogutarbimine märgatavalt ei tõusnud, kuigi kolm täiskasvanut neljast jäi kevadel kodukontorisse ning ka teismelise õppetöö suunati kaugõppele.




Joonis 4. Elektritarbimine aastate kaupa

Aastaaegade keskmist tunnipõhist tarbimist kujutab järgmine graafik (vt joonis 5). Selgelt on näha, et talvisel perioodil on tarbimine kõrgeim (keskmine tunnipõhine tarbimine ligikaudu 4 kWh) ning suvisel madalaim (keskmine tunnipõhine tarbimine ligikaudu 1 kWh). Seega aastasisene kõikumine on üpriski suur.




Joonis 5. Keskmine elektritarbimine ühes tunnis aastaaegade kaupa

Sesoonsus tuleb välja ka joonisel 6, kus päevatarbimine on summeeritud ning sellele on lisatud nädala keskmine tarbimine, mis on palju laugem, kui üksikute päevade tarbimine.




Joonis 6. Päevane elektritarbimine koos nädala keskmisega aastate lõikes

Sesoonsust vaatleme lähemalt joonise 7 abiga. Tarbimine on iga-aastaselt justkui lauge U kujuline. Jooniselt on näha elektritarbimise varieeruvus ning aeg, mil tarbimine läheb väga üles või alla. Varieeruvus esimese 70 päeva jooksul on palju suurem kui ülejäänud aasta jooksul. Ja suuri tarbimise tippe on näha aastate 2017 ja 2018 talveperioodil. Ka jooniselt 4 tuli välja, et just neil aastail oli kogutarbimine kõige suurem. Samuti saab teha tähelepanekuid üksikute päevade kohta, näiteks 2020. aasta viimasel päeval on tarbimine läinud väga alla, kuna pereliikmed läksid aastavahetusel kodunt ära.




Joonis 7. Elektritarbimine aastate kaupa päeva järgi

Vaadates graafikut koos elektri hinnaga (joonis 8), on näha, et kevadel on elektri hind madalpunktis, seejärel hakkab tõusma ning saavutab tipu suve lõpus. Hüdoenergiast toodetud elektrienergia on kõige odavam elektri tootmise viis [52]. Kevadine madal hind võib olla seega põhjustatud sellest, kuna hüdrojaamades on sulavee tõttu rohkem vett, seevastu augustis on hind kõrgem.




Joonis 8. Elektritarbimine aastate kaupa koos elektrihinnaga

Varieerumisest paremaks mõistmiseks vaatame karpdiagrammi (joonis 9), kus on kujutatud tunnipõhist tarbimist kuude lõikes. Jaanuaris veebruaris ja märtsis on varieeruvus kõige suurem ning juulis kõige väiksem. Samuti on näha, et veebruaris tarbitakse elektrit kõige intensiivsemalt (mediaan on kõige kõrgem ja vahe esimese ja kolmanda kvartiili vahel kõige suurem) ning juunis, juulis ja augustis on tarbimismuster sarnane.



Joonis 9. Elektritarbimise karpdiagramm kuude lõikes

Argipäeva ja nädalavahetuse (sh riigipühad) keskmine tunnipõhine tarbimine erineb ligi 0,5 kWh võrra, st erinevus on st päeva peale kokku ligi 12 kWh (vt joonis 10).




Joonis 10. Argipäeva ja nädalavahetuse keskmise tunnitarbimise erinevus

Tunnipõhine tarbimine (vt joonis 11) annab parema ettekujutuse sellest, kuidas nädalavahetuse tarbimine argipäevast erineb. Nädalavahetusel ärgatakse hiljem ning päeval on tarbimine tunduvalt suurem .




Joonis 11. Argipäeva ja nädalavahetuse keskmise tarbimise erinevus tundide kaupa

Nädalapäeva joonis (joonis 12) näitab paremini erinevusi nädalapäevade osas. Esmaspäeval on tarbimine kõige madalam, neljapäevast alates liigub tarbimine lineaarselt üles.




Joonis 12. Keskmine tunnipõhine tarbimine nädalapäeva järgi 2017-2020

Järgmisena võrreldakse eraldi perioode 2017-2019 ja 2020 (vt joonised 13 ja 14). Näha on tarbimismustrite erinevust: 2020. aastal, mil pereliikmed koroonakriisi tõttu rohkem kodus viibisid, tõuseb tarbimine astmeliselt ja reedene tarbimine vastab vaba päeva omale, perioodil 2017–2019 aga on tõus sujuvam. Keskmise elektritarbimise erinevus on seotud sellega, et aastatel 2017 ja 2018 oli aastase tarbimise kogusumma suurem.

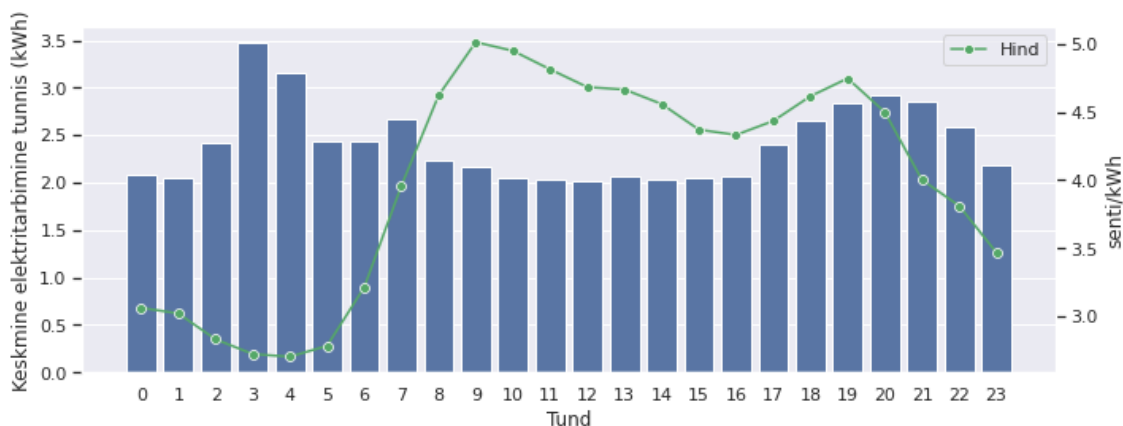


Joonis 13. Keskmine tunnipõhine tarbimine nädalapäeva järgi 2017–2019




Joonis 14. Keskmine tunnipõhine tarbimine nädalapäeva järgi 2020

Tarbimist tunnipõhiselt (joonis 15) vaadeldes, on näha, et päevas on kaks kõrgema tarbimisega perioodi: esimene neist kella kolme ja nelja vahel varahommikul ning teine õhtune tipptund, kui tarbimine hakkab tõusma kella 17st. Varahommikust elektritarbimist saab seletada sellega, et nutipistikute abil on veeboilerid pandud öösiti kütma ja aasta 2020 sügisest ka pörandakütted, kuna börsihind kaldub sellel perioodil olema kõige madalam. Seda mustrit on pere jälginud aastast 2018. Lisas 2 on välja toodud tunnipõhine tarbimine koos hinnaga eraldi argipäeva ja nädalavahetuse kohta.




Joonis 15. Keskmine tunnipõhine tarbimine päevas tundide kaupa 2017-2020

Näitamaks, kuidas tarbimine on muutunud, on joonisel 16 välja toodud aasta 2017 tunnipõhine tarbimine. Selgelt on näha, et kella kolme ja nelja vahel oli tarbimine madal ja hommikune tipptund algas alles kell kuus.




Joonis 16. Keskmine tunnipõhine tarbimine päevas tundide kaupa 2017

Järgmisena vaatleme tunnipõhist tarbimist ka kuude kaupa. Jooniselt 17 tuleb hästi välja, et inimese käitumismuster ei ole kunagi täpselt sama. Kuude lõikes on küll näha, kuidas tarbimine tõuseb hommikul ja õhtul, kuid tippudevaheline perioodi on erinev. Näiteks aprillis on näha tugevamat langust pärast hommikut, oktoobris on rohkem nõrkitamist, mais ja juunis aga on hommiku ja õhtu vahel sirge joon.



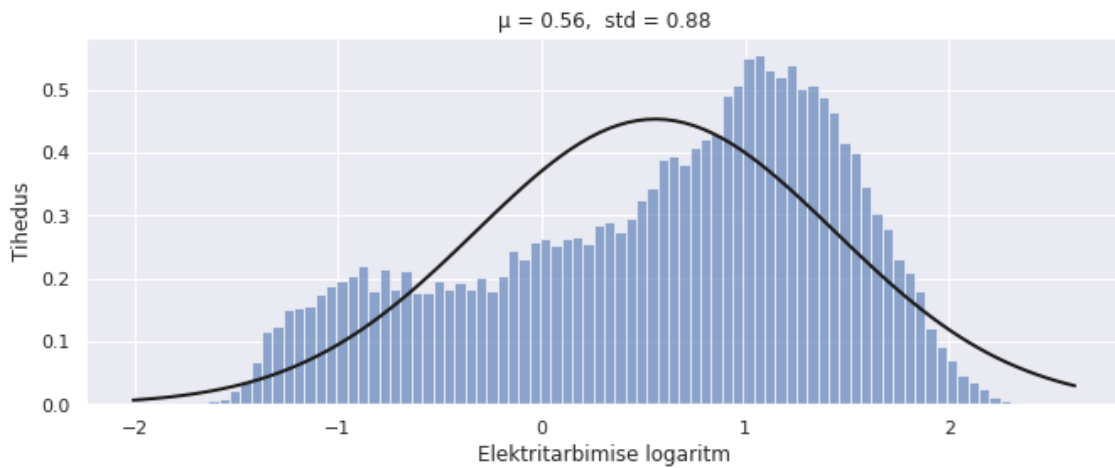
Joonis 17. Keskmine tunnipõhine elektritarbimine kuude kaupa

Mõistmaks elektritarbimise jaotuvust, uuritakse edasi elektritarbimise histogrammi (joonis 18). See on vasakule kaldu ja kõige rohkem andmepunkte on 0,5 kWh juures.



Joonis 18. Elektritarbimise histogramm

Kui muutujatel on ainult positiivsed väärtused, võib nende logaritmilisele skaalale viimine olla otstarbekas ning viia muutuja lähemale normaaljaotusele [53]. Rakendades seda elektritarbimise puhul (joonis 19), on näha, et elektritarbimine on ühtlasemalt jaotunud, kuid endiselt pole tegemist normaaljaotusega.

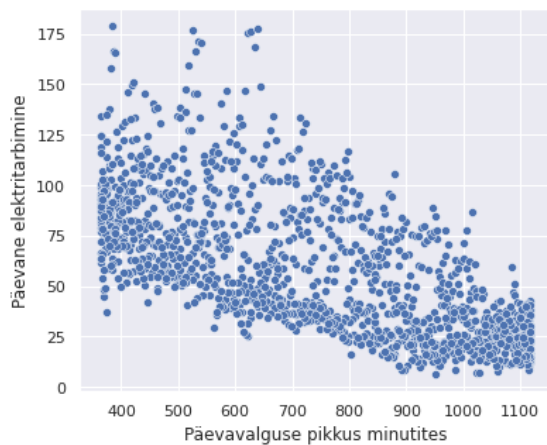


Joonis 19. Elektritarbimise jaotustiheduse histogramm logaritmilisel skaalal


4.2 Ilmastikunähtused, korrelatsioon ja olulised muutujad

Erialasest kirjandusest selgub (vt peatükk 2.1), eri ilmaparameetrid võivad elektritarbimist mõjutada.

Päevavalguse pikkus ei ole küll ilmastikunähtus, kuid ka see erineb päeviti ja võib mõjutada tarbimist. Joonisel 21 on summeeritud päeva kogutarbimine ja võrreldud seda päevavalguse pikkusega. Tarbimise viimine logaritmilisele skaalale (joonis 20) tõstis Pearsoni korrelatsioonikordaja -0,69 pealt -0,73 peale.



Joonis 21. Päevavalguse seos elektritarbimisega



Joonis 20. Päevavalguse seos elektritarbimisega logaritmiga


Lisades päevavalguse näitaja tunnipõhiste andmete külge, on Pearsoni korrelatsioonikordaja on -0,56, kui aga elektritarbimine viia logaritmilisele skaalale, siis -0,62. Seega on päevavalguse pikkusel selge seos elektritarbimisega.

Edasi on toodud välja Pearsoni korrelatsioonikordaja ilmastikunäitajate osas ja vaadeldud, kas andmete viimine teisele skaalale annab tulemust (vt tabel 3). Transformeerimise puhul viidi elektritarbimine logaritmilisele skaalale, sest nii jaotuvad andmepunktid ühtlasemalt (vt peatükk 4.1). Ilmastikunähtuste transformeerimisel arvestati, millisel muundamise viisil on histogramm normaaljaotusele kõige sarnasem. Lõpuks võeti sademetest ainult kuupruutjuur ja tuulest ruutjuur, teiste muutujate transformeerimine soovitud tulemusi ei andnud.

Tabel 3. Ilmastikunähtuste Pearsoni korrelatsioon elektritarbimisega


	Transformeerimata	Transformeeritud
Õhurõhk	-0,036	-0,055
Sademed	-0,024	0,056
Suhteline õhuniiskus	0,25	0,3
Temperatuur	-0,74	-0,76
Nähtavus	-0,16	-0,15
Tuulekiirus	0,076	0,079
Maksimaalne tuulekiirus	0,058	0,068
Tuulesuund	-0,027	-0,058

Eelnevast tuleb välja, et elektritarbimist mõjutavad kõige rohkem temperatuur (vt Joonis 22) ja õhuniiskus, kuigi viimase korrelatsioonikordaja on väike.



Joonis 22. Elektritarbimine aastate lõikes koos temperatuuriga

Temperatuuri jaotustiheduse histogrammi (vt joonis 23) näitab, kus pole tegemist normaaljaotusega, kuid visuaalselt jaotuvad andmepunktid keskvaertuse lähedale.



Joonis 23. Temperatuuri jaotustiheduse histogramm

Elektritarbimise seose uurimine lihtsustatud ilmaandmetega

Kuna elektritarbimise ja paljude ilmastikunähtuste vahel ei esinenud tugevat seost, otsustati lihtsustada ilmaandmeid, et näha, kas see mõjutab kuidagi korrelatsiooni, ja selle põhjal otsustada, mis kujul edasises töös andmeid edasi kasutada. Lihtsustuseks valitud väärtused on loodud lähtudes töö autori intuitsioonist.

- Sademed: kui sademete määr on üle nulli, saab muutuja väärtuseks 1.
- Suhteline õhuniiskus: kui suhteline õhuniiskus on üle 80, siis saab muutuja väärtuseks 1.
- Tuulekiirus: kui väärtus on üle 6, siis saab muutuja väärtuseks 1.
- Maksimaalne tuulekiirus: kui väärtus on üle 15, siis saab muutuja väärtuseks 1.

Lihtsustamisega oluliselt paremaid korrelatsiooninäitajaid ei saavutatud. Tulemused on järgmised

- sademete korrelatsioonikordaja sai väärtuse 0,061 ja kui tarbimine on viidud logaritmilisele skaalale, siis 0,088;
- suhtelise õhuniiskuse korrelatsioonikordaja sai väärtuse 0,22 ja kui tarbimine on viidud logaritmilisele skaalale, siis 0,26;
- tuulekiiruse korrelatsioonikordaja sai väärtuse 0,065 ja kui tarbimine on viidud logaritmilisele skaalale, siis 0,063;

- maksimaalse tuulekiiruse korrelatsioonikordaja sai väärtuse 0,026 ja kui tarbimine on viidud logaritmilisele skaalale, siis 0,028.


Lisaks kasutati oluliste muutujate leidmiseks logistilist regressiooni ja *scikit-learn* alla kuuluvat *SelectKBest* meetodit. Kolmandana meetodina vaadati väga juhusliku puu regressorit (*Extremely Randomized Tree Regressor* ehk ETR), mis on oma olemuselt sarnane juhuslikult metsale. Logistilisest regressioonist, mudelist ETR ega ka mudelist *SelectKBest* ei selgunud lihtsustatud muutujate olulisus. Seetõttu otsustati, et töös lihtsustatud andmeid ei kasutata ega edaspidi uurita.

Elektritarbimise seose edasine uurimine tavaandmetega

Kuna elektritarbimise logaritmilisele skaalale viimine oluliselt tulemusi ei muutnud, on järgnev korrelatsioonianalüüs tehtud ilma transformeerimata. Prognoosimisel seevastu katsetatakse mudeleid nii transformeerimata kui ka transformeeritud kujul.

Ilmastikuandmetest otsustati alles jätta temperatuur ja suhteline õhuniiskus, kuigi korrelatsiooninäitaja oli viimasel alla 0,5.


Korrelatsioonile lisaks viidi läbi logistiline regressioon. Ilmastikunäitajates on olulised just temperatuur ja õhuniiskus (p väärtuse 0,05 juures). Kuna väga juhusliku puu regressorist (ETR) tõusis esile ka õhurõhk (Joonis 24), katsetatakse prognoosi mudeleid nii ilma õhurõhuta kui ka koos sellega.




Joonis 24. ETR-i 5 tähtsamat muutujat

Korrelatsioonimaatriksilt (Joonis 26) selgub, et tarbimisega omavad suuremat korrelatsiooni veel aastaajad ja päevavalgus. Kuigi andmeid kirjeldades oli näha, et tarbimine erineb tunniti ja nädalapäeviti, siis see seos korrelatsioonimaatriksis välja ei tule. Rohkem seoseid korrelatsioonimaatriksist rõhutada ei ole. Logistiline regressioon

andis oluliseks muutujaks veel nädalavahetuse. ETR ja *SelectKBest* andsid oluliseks muutujateks lisaks talve. Mudelist *SelectKBest* (vt Joonis 25) tuli välja ka see, et kuud jaanuar ja veebruar on küll olulised, ent aastaaeg talv on olulisem.



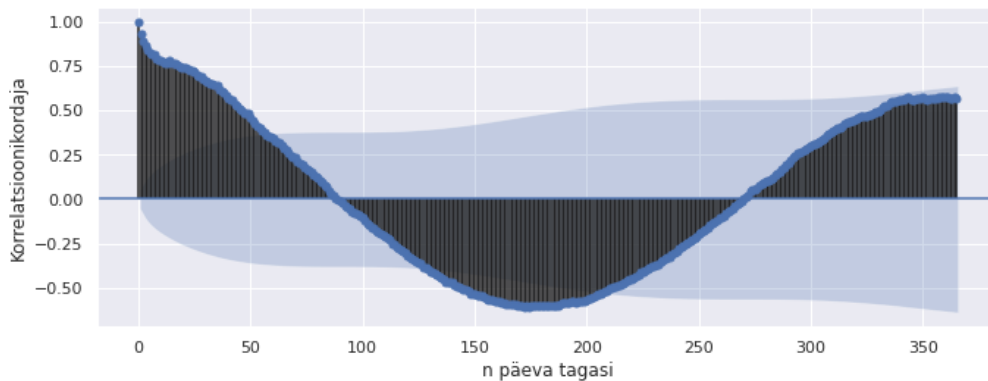
Joonis 25. *SelectKBest* viis tähtsamat muutujat



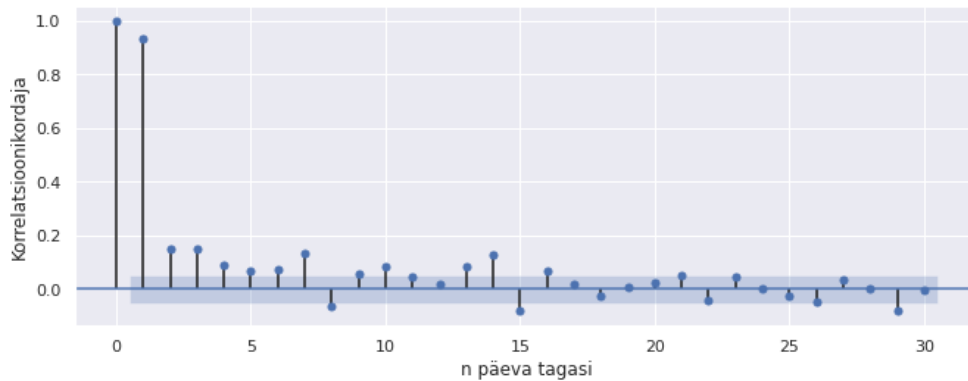
Joonis 26. Pearsoni korrelatsioonimaatriks

Autokorrelatsioon

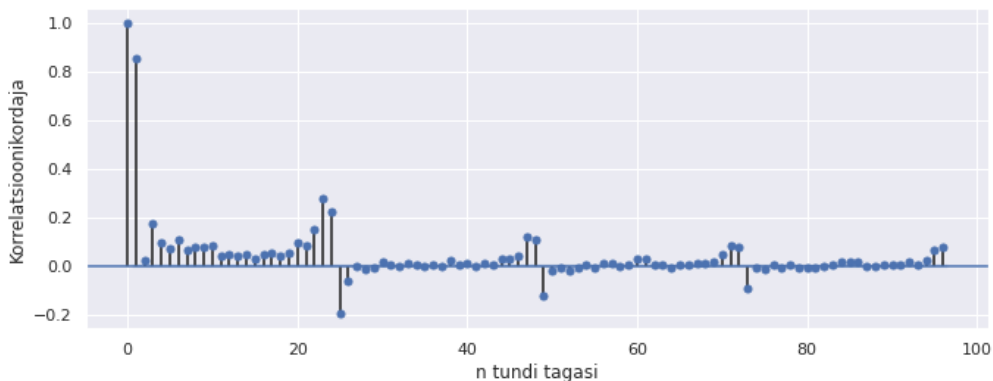
Autokorrelatsiooni jooniselt Joonis 27 on näha hooajalisust. Vaadates autokorrelatsiooni osaliselt graafikult (Joonis 28) selgub, et 95% usaldusnivoo juures on olulised 7 päeva. Samuti saab sealt välja lugeda, et näiteks 8. ja 15. päeva juures on korrelatsioon kõrgem ehk näha on nädalatevahelist korrelatsiooni. Samamoodi on päevadevahelist korrelatsiooni näha jooniselt Joonis 29.



Joonis 27. Autokorrelatsioon 365-päevase nihkega



Joonis 28. Osaline autokorrelatsioon 30-päevase nihkega



Joonis 29. Osaline korrelatsioon 96-tunnise nihkega

4.3 Hoone elektritarbimine ja seda mõjutavad tegurid

Elektritarbimine on kogu aeg erinev, kuna seda mõjutavad mitmed asjaolud nagu näiteks ilm ja elanike käitumismallid. Juba ühe maja näitel on näha, kui kiiresti võib elektritarbimise mustrid muutuda (COVID, nutipistikute kasutamine). Eelpool selgus, et talveperioodil on tarbimine kõige kõrgem, suvel aga madalaim (vt peatükk 4.1). See on seotud peamiselt välistemperatuuriga ehk see annab kinnitust, et peamised tarbijad on kütteseadmed. Andmeid uurides tuli ka välja, et päevavalguse pikkusel on kõrge korrelatsioon elektritarbimisega. Seejuures on päevavalguse pikkusel ja temperatuuril omavaheline suur korrelatsioon (Pearoni korrelatsioonikordaja on 0,7): suviti on Eestis kõige soojem, aga ka kõige pikemad päevad. Ilmastikunähtuste osas võib elektritarbimist mõjutada veel suhteline õhuniiskus, kuna kõrgema õhuniiskuse korral võib inimene tajuda talvel ilma külmemana, suvel aga soojemana. Lisaks tuli mõnest mudelist välja, et ka õhurõhk võib tarbimise juures olla oluliseks faktoriks (vt Joonis 24), mistõttu katsetatakse prognoosida nii ilma selle näitajata kui ka koos sellega.

Peatükis 4.1 selgus, et argipäeva ja nädalavahetuse tarbimisprofiilid on erinevad, kuna pereliikmed veedavad nädalalõputi rohkem aega kodus, seega on elektrikulu suurem ja elektritarbimise jaotuvus teistsugune kui argipäeviti. Selline päevapõhine tarbimiserinevus tuli välja ka aastal 2020, kui pereliikmed viibisid COVID-19 kriisi tõttu rohkem kodus ja elektritarbimine suurenes juba reedel.

Kui tarbijad otsivad võimalusi kulude vähendamiseks, siis tuleb mõista ka kuidas need tekivad. Väga hea alguspunkt ongi uurida, milline on statistiliselt elektrihind ja tulemusi arvestades teha oma tarbimises muudatusi. Näiteks siis nutipistikute või termostaatide abil reguleerida tarbimist. Siit tööst tuli välja, et elektrihind on keskmiselt kõige madalam kella kolme ja nelja vahel öösel ning kõige kõrgem hommikul kella üheksast üheteistkümneni. Nädalavahetusel aga on elektrihind keskmiselt kõige madalam nelja ja viie vahel öösel. Samuti tuli välja, et elektrihind on talve asemel hoopis kõige kõrgem suve lõpul ja sügise algul.

5 Päikesepaneelid ja nende otstarbekus

Peatükis antakse ülevaade päikesepaneelide peamistest tehnoloogiatest, küsitakse päikesepaneelide ja nende paigalduse pakkumist ning arvestatakse lõpuks välja, kui palju suudab päikeseenergia katta tarbimisvajadusest ja kui palju jääb päikeseenergiat üle, et seda oleks võimalik elektrivõrku tagasi müüa.

Päikesepaneelide tehnoloogiad jagunevad peamiselt kaheks [54] [55]:

1. Monokristalsed: päikesepaneelielemendid on valmistatud puhtast ränist (siliitsium), need on toodetud suurte kristallidena, mistõttu nende tootmine on kulukam kui polükristalsete elementide tootmine.
2. Polükristalsed: päikesepaneelielemendid sisaldavad suurt hulka väikeseid sinakaid ränikristalle. Nende paneelide efektiivsus on väiksem, võimsus tavaliselt madalam ning neid on odavam toota kui monokristalseid elemente.

Eestis loetakse päikesepaneelide optimaalseimaks paigaldusnurgaks maapinna suhtes 35-40 kraadi. Suurema nurga all paigaldatud paneelide tootlikkus talveperioodil on suurem, seevastu kui paneelid on paigaldatud 10-20-kraadise nurga all, suurendatakse peamiselt suvist tootlikkust [55].

Päikesepaneelide eluiga on umbes 25-30 aastat ning nende kasutegur on ajas vähenev. Tavaliselt öeldakse, et esimesel aastal kaotavad päikesepaneelid kuni 3% oma aastasest tootlikkusest ja järgnevatel aastatel 0,5% [56].

Päikesepaneelide pakkumist küsiti ettevõtetelt Energogen [57] ja Solar4you [58]. Mõnel ettevõttel on hinna ja võimsuse arvutamiseks kodulehel kalkulaator, neid kasutati Areva Solari [59] ja Eesti Energia [60] puhul. Pakkumiste koostamise juures on arvestatud sellega, et kõikidel katustel olevatest päikesepaneelidest moodustuks üks süsteem ehk need on koondunud ühe inverteri alla. Päikesepaneelidega katuste aastane energiatootlus

on arvatud Euroopa Komisjoni lehel oleva kalkulaatori abiga [61]. Pakkumise hinnale on lisatud ka paigaldustasu.

Päikesepaneelide pakkumistest annavad ülevaate tabelid 4-6, esitades andmed eraldi peamajakatuse (Tabel 4), garaaži- ja kuurikatuse kohta ning kokkuvõtlikult kõigi katuste kohta (Tabel 6).

Tabel 4. Peamajakatus (päikesepaneelid)

	Energogen	Areva Solar	Eesti Energia	Solar4you
Süsteemi võimsus (kW)	9,2	10	9,6	13,2
Energiatootlikkus (kWh)	8261	9400	9256	11 853
Päikesepaneelide arv	28	39	30	29

Tabel 5. Kuuri- ja garaažikatuse (päikesepaneelid)

	Energogen	Areva Solar	Eesti Energia	Solar4you
Süsteemi võimsus (kW)	7,9	5	4,8	10,9
Energiatootlikkus (kWh)	5599	4432	4283	7738
Päikesepaneelide arv	24	19	15	24

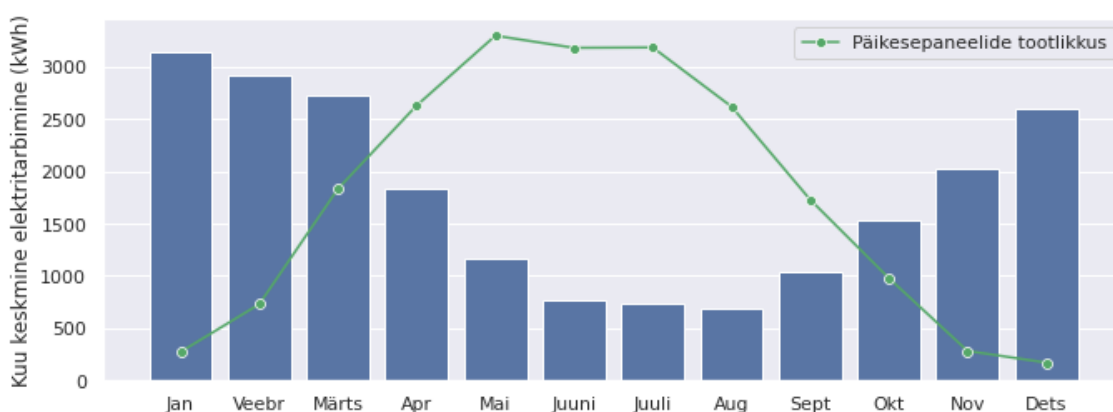
Tabel 6. Kokkuvõttev tabel (päikesepaneelid)

	Energogen	Areva Solar	Eesti Energia	Solar4you
Süsteemi võimsus (kW)	17,1	18	17,28	24,1
Aasta tootlikkus (kWh)	~13 860	~16 631	~16 109	~19 591
Päikesepaneelide arv	52	70	54	53
Päikesepaneeli võimsus (W)	330	~260	~320	455
Tehnoloogia	Monokristall	Puudub info	Puudub info	Monokristall
Süsteemi maksumus (€)	14 008	29 030	21 356	19 586

Järgmisena on arvestatud Solar4You pakkumise andmeid, kuna neil on ühe päikesepaneeli võimsus kõige suurem ja arvestatud on ka optimeerijatega. Tänu optimeerijatele langeb ainult selle paneeli tootlikkus, millele langeb vari, erinevalt standardlahendusest, mille puhul kahjustub kogu paneeligrupi tootlikkus. Kuupõhise tootlikkuse arvutamisel on jälle


kasutatud Euroopa Komisjoni lehel olevat kalkulaatorit [61]. Tootlikkuse välja arvutamiseks lisati kalkulaatorisse peamaja ning kuuri/garaaži andmed eraldi, kuna nende katused on erineva kaldenurgaga, mistõttu neil on erinev tootlikkus. Lisas 3 on välja toodud päikesepaneelide tootlikkus kuude kaupa.

Joonis 30 kujutab keskmist tarbimist ja päikesepaneelide tootlikkust kuude kaupa. Aprillist septembrini peaksid päikesepaneelid katma kogu elektritarbimise vajaduse, ent talve- ja sügiskuudel päikesepaneelid suurt osa elektrivajadusest ei kata. Päikesepaneelide kogu aasta tootlikkus on 20 907 kWh.



Joonis 30. Päikesepaneelide tootlikkus ja keskmine tarbimine kuus

Jooniselt Joonis 31 on aga näha nii päikeseenergia ülejääki (märgitud rohelisega), mida oleks võimalik elektrivõrku tagasi müüa, kui ka päikeseenergia puudujääki (ehk elektritarbimist, mida ei ole võimalik päikeseenergia abil katta).



Joonis 31. Päikeseenergia üle- ja puudujääk

Selgitamaks välja igakuine rahakulu elektrile, tuleb mõista, millest see koosneb. Elektriarve koosneb Nord Pooli hinnast ja võrgutasudest. Võrgutasud koosnevad elektri

edastamise ja taastuenergiatasust ning elektriaktsiisist. Aktsiisile ja teistele tasudele lisandub käibemaks [62]. Hoonel on järgmine leping:

- elektri edastamise hind päeval 0,0274 €/kWh,
- elektri edastamise hind öösel 0,0158 €/kWh,
- kuutasu 14,46 €,
- taastuenergiatasu 0,0113 €/kWh,
- elektriaktsiis 0,001 €/kWh.

Elektrilevi hinnakirjast saab selgituse päeva- ja ööhindadele [63].

- „Päevahind (elektri edastamine: päev) kehtib esmaspäevast reedeni: suvel kell 8.00–24.00 ning talvel kell 7.00–23.00.“
- „Ööhind (elektri edastamine: öö) kehtib esmaspäevast reedeni: suvel kell 24.00–8.00 ja talvel kell 23.00–7.00 ning kõigil laupäevadel ja pühapäevadel.“
- „Argipäevadele langevatel riiklikel pühadel kehtivad samad hinnad, mis tavalistel argipäevadel“

Suve all on mõeldud suveaega ja talve all talveaega. Talveaeg vahetub suveaja vastu märtsi viimasel pühapäeval ja suveaeg talveaja vastu oktoobri viimasel pühapäeval. Töös arvestati lihtsustatult suveajaks aprill, mai, juuni, juuli, august, september ja oktoober ning talveajaks november, detsember, jaanuar, veebruar ja märts. Lisaks otsustati jätta arvutustele lisamata kuutasu ja käibemaks, kuna need ei sõltu tarbimisest.

Selgitamaks välja päikesepaneelide tasuvus tehti järgmised arvutused

- Arvutati välja iga tunni elektritarbimise hind eurodes koos võrguteenustasuga.
- Seejärel arvutati välja iga kuu keskmine elektriarve eurodes (aastate 2017–2020 põhjal). Arvutustest tuli ka välja, et võrgutasud moodustavad veidi üle poole elektrihinnast.
- Selgitamaks välja rahaline sääst arvutati, mitu protsenti moodustab päikeseenergia elektritarbimisest ja korrutati see elektriarvega.
- Eesti Energia sõnul põhineb elektri ostuhind Nord Pool elektribörsihindadel, millest lahutatakse lepingus kokku lepitud marginaal [64]. Elektrienergia müügitulu teadasaamiseks arvutati Nord Pooli kuu keskmine tunnihind (aastate 2017–2020 põhjal), mis korrutati päikeseenergiast saadud elektrienergia ülejäägiga. Kuna täpne marginaal pole teada, otsiti seda internetist ja leiti

Äripäeva artikkel, mille väitel marginaal on 0,18–0,25 senti [65]. Müügitulu arvutamiseks võeti vahemiku keskmine ehk 0,215 senti.

Tabel 7. Päikeseenergia tasuvus

Kuu	Keskmine elektri-arve (€)	Keskmine tarbimine (kWh)	Keskmine tunni-hind (senti/kWh)	Päikese-paneelide tootlikkus (kWh)	Päikese-energia ülejääk (kWh)	Rahaline sääst (€)	Tulu müügist (€)
1	230	3134	3,92	274	-2861	20	0
2	210	2910	3,84	730	-2180	53	0
3	188	2728	3,50	1834	-895	126	0
4	119	1837	3,42	2629	793	119	25
5	75	1173	3,42	3296	2123	75	68
6	52	765	3,99	3180	2415	52	91
7	54	732	4,18	3183	2452	54	97
8	53	689	4,54	2619	1930	53	84
9	77	1035	4,42	1729	694	77	29
10	112	1537	4,12	979	-558	71	0
11	151	2027	4,32	283	-1744	21	0
12	193	2594	4,24	171	-2422	13	0
Kokku	1514	21161	-	20907	-253	734	394

Tasuvusperiood = Süsteemi maksumus / (rahaline sääst + tulu müügist + käibemaks) =
 $19\,586 / (734 * 1,2 + 394 * 1,2) = 19\,586 / 1353,6 = \mathbf{14,5}$ aastat

Praegu tuli arvutuste järgi tasuvusperioodiks 14,5 aastat, tegelikult on see number suurem, kuna tabeli Tabel 7 koostamisel kasutati väga palju miinuseid/lihtsustusi: seega on tegelikud numbrid erinevad.

- Tabelis on arvestatud tootmise ideaaltingimustega, nt pole võetud arvesse tootlikkuse vähenemist varjude tõttu.
- Tasuvusperioodi arvutamisel pole arvestatud päikesepaneelide tootlikkuse langusega.

- Elektri tagasimüümiseks peab tegema lepingu, millel on oma tasud, ka ei teata täpset marginaali.
- Päikeseenergia täpne tunnitoodang pole teada (eelnevat oleme toodangut vaadanud kuude lõikes), seega ei pruugi toodang katta ühe tunni vajadust.
- Öösel tootmist ei ole, päikeseenergiaga saab elektrienergiat toota ainult päeval, seega pole olemas nullkuluga kuid. Kuna öösel ei toodeta elektrit, siis jääb päeval toodetud energiat jääb rohkem üle, kui enne arvestatud, ja seega tuleb seda ka rohkem tagasi müüa.

Päikesepaneelid kataks seega lihtsustatuna kogutarbimisest: $274 + 730 + 1833 + 1837 + 1173 + 765 + 732 + 689 + 1035 + 979 + 282 + 171 = \mathbf{10\ 500\ kWh}$. See on ligikaudu **50%** aastasest kogutarbimisest

Kuna varjud võivad tootlikkust oluliselt vähendada, tehti arvutused ka tingimusel, et päikesepaneelid suudaksid toota umbes 70%. Sel juhul saadi tasuvusperioodiks 19,2 aastat ja päikeseenergia kataks ligi 35% kogutarbimisest. Selle kohta, kui palju varjud konkreetse hoone puhul tootlikkust mõjutada võivad pole ilma katseteta võimalik usaldusväärseid andmeid saada.

Tasuvusperiood (70% tootlikkuse juures) = Süsteemi maksumus / (rahaline sääst + tulu müügist + käibemaks) = $19\ 586 / (644 * 1,2 + 207 * 1,2) = 19\ 586 / 1021,2 = \mathbf{19,2\ aastat}$

Päikesepaneeli ostes tasuks mõelda ka eri toetustele. 2019. aasta septembrini oli võimalik saada Kredexilt päikesepaneelide investeeringutoetust [66] (taotluste vastuvõtt lõppes 18.09.2019) ja läbi Eleringi taastuenergia toetust 5,37 s/kWh kohta [67] (toetus lõppes 31.12.2020). Nüüd on Kredexilt võimalik taotleda ainult väikeelamute rekonstrueerimistoetust (sealhulgas taastuenergia seadmete paigaldamine), ent taotluste vastuvõtt on rahaliste vahendite ammendumise tõttu peatatud [68]. Seega pole praegu ühtegi toetust, mida saaks päikesepaneelide paigaldamiseks taotleda.

Tasuvusperiood tuli mõlema arvutusvariandi puhul pikk, lisaks oli nende juures tehtud ka lihtsustusi, seega on tegelik tasuvusperiood veelgi pikem. Niisiis ei pea autor praeguses olukorras näiteks mõistlikuks antud majale päikesepaneeli soetada. Tuleks oodata vähemalt senikaua, kuni on võimalik taotleda paigaldustoetust, ühtlasi tasuks kaaluda päikesepaneelidele varje tekitavate puude langetamist.

6 Elektritarbimise prognoos

Peatükis kirjeldatakse elektritarbimise prognoosi mudeleid, põhjendatakse neis kasutatud faktorite valikut ning antakse ülevaade prognoositulemustest.

6.1 Prognoosimudel ja selle atribuudid

Prognoosiks otsustati kasutada järgmisi mudeleid:

- LSTM – Mudel valiti, kuna see on närvivõrk, mida kasutatakse eelkõige aegridade peal ning seda tüüpi mudelite rakendamist kirjeldatakse ka vaadeldud kirjanduses (vt peatükk 2.2)
- SVR – Mudel valiti, kuna see on üks enimkasutatavaid meetodeid elektritarbimise prognoosimiseks (vt peatükk 2.2).
- XGBoost – Mudel valiti, kuna see on levinud elektritarbimise prognoosi mudel
- ETR – ETR ja juhusliku metsa mudelid on omavahel sarnased [69]. Töös otsustati proovida ETR-mudelit, kuna ETR mudel kasutab treenimisel kogu treeningandmete hulka iga puu treenimiseks, mistõttu võib mudeli nihe (*bias*) väheneda [70].
- Lineaarne regressioon – Mudel valiti eelkõige võrdluse eesmärgil, et aru saada, kuidas lihtne mudel elektritarbimise prognoosiga toime tuleb.

Mudelite atribuutide valikul võeti aluseks andmekirjelduse, korrelatsioonanalüüsi ja oluliste muutujate leidmise tulemused. Esialgu katesetati mudeleid ilma tunni, nädalapäeva ja kuu andmeteta, sest korrelatsioonanalüüsist nende puhul tugevat seost välja ei tulnud. Pärast katsetusi otsustati välja jätta kuu info, kuna see tulemust ei parandanud või isegi tegi neid halvemaks. Seevastu nädalapäeva info otsustati sisse jätta, ka joonistelt (vt näiteks joonis 12) tuli välja, kuivõrd erinev on nädalasisene tarbimine. Andmetele otsustati lisada eelneva 24 tunni (24 tunnine viide) tarbimisandmed, kuna autokorrelatsiooni jooniselt (Joonis 29. Osaline korrelatsioon 96-tunnise nihkega) selgus oluline seos sellega ja prognoosimise hetkel on eelneva tarbimise info teada. Eemaldati

ainult tarbimine viitega üks ja kaks (tabelis Tabel 8 märgitud punase taustavärviga), kuna järgmise tunni prognoosimise hetkel ei ole veel teada, milliseks käesoleva tunni tarbimine kujuneb, ning tarbimine viitega kaks, kuna info ei pruugi süsteemis piisavalt kiiresti uueneda. Eleringi lehelt saab alla laadida andmed, mis on 8 tunni vanused. Tulevikus saab eratarbija arvatavasti võimaluse tarbimise andmed kätte saada läbi liidese. Kuna töö on suunatud eelkõige tulevikku, eeldatakse, et tarbimisandmed uuenevad kiiremini kui praegu.

Tabel 8. Viite lisamine andmetesse (väljavõte)

Kuupäev	Tarbimine	t-1	t-2	t-3	t-4	t-5
01.01.2017 0:00	3,19	NaN	NaN	NaN	NaN	NaN
01.01.2017 1:00	2,196	3,19	NaN	NaN	NaN	NaN
01.01.2017 2:00	2,679	2,196	3,19	NaN	NaN	NaN
01.01.2017 3:00	2,269	2,679	2,196	3,19	NaN	NaN
01.01.2017 4:00	2,267	2,269	2,679	2,196	3,19	NaN
01.01.2017 5:00	2,453	2,267	2,269	2,679	2,196	3,19
01.01.2017 6:00	2,675	2,453	2,267	2,269	2,679	2,196
01.01.2017 7:00	3,301	2,675	2,453	2,267	2,269	2,679
01.01.2017 8:00	2,958	3,301	2,675	2,453	2,267	2,269
01.01.2017 9:00	4,145	2,958	3,301	2,675	2,453	2,267
01.01.2017 10:00	4,624	4,145	2,958	3,301	2,675	2,453

Ilmastikuandmetest valiti mudelisse ainult temperatuur ja suhteline õhuniiskus. Mudeleid katsetati ka koos õhurõhuandmetega, kuid see mudeleid RMSE/MAPE seisukohalt ei muutnud.

Lõppmudelitesse valiti seega järgmised atribuudid:

- nädalavahetuse info,
- päevavalguse pikkus,
- suhteline õhuniiskus,
- temperatuur,
- aastaajad,
- tund,

- nädalapäev,
- eelmise 24 tunni tarbimine, v.a tarbimine viitega üks ja kaks.

Aastaajad, nädalapäevad ja tunnid muudeti fiktiivseteks muutujateks (*dummy variables*). Enne mudelisse andmist andmed normaliseeriti: kui andmed ei vasta normaaljaotusele, siis soovitatakse standardiseerimise asemel kasutada normaliseerimist [71] [72].

Mudeli treenimiseks kasutati aastate 2017–2019 andmeid ning testimiseks aastat 2020. Terve aasta valiti testperioodiks, et oleks näha, kuidas mudelid hooajalisusega toime tulevad .

Mudelite hindamiseks kasutati näitajaid RMSE ja MAPE: neid hindamismõõdikuid kasutatakse elektritarbimise prognoosimisel enim (vt peatükk 2.2).

6.2 Prognoosi tulemused

Tabelites 9 ja 10 on näha, kuidas mudelid erinevad vastavalt sellele, kas elektritarbimine on transformeeritud logaritmilisele skaalale või mitte. RMSE tulemused on transformeerimata skaalal natukene paremad, MAPE omad seevastu halvemad.

Tabel 9. Mudelite tulemused ilma transformeerimata

	LSTM	SVR	XGBoost	ETR	LR
RMSE	0,85	0,87	0,88	0,87	0,89
MAPE	44,97	36,37	39,79	39,91	42,25

Tabel 10. Mudelite tulemused transformeeritud logaritmilisele skaalale

	LSTM	SVR	XGBoost	ETR	LR
RMSE	0,92	0,88	0,91	0,9	0,92
MAPE	40,27	33,19	34,22	34,34	35,8

Mudeli LSTM puhul otsustati kasutada transformeerimata andmeid, kuna RMSE 0,85 pealt tulemuse liikumine RMSE 0,92 peale annab ligi 8%, aga MAPE 44.97 pealt liikumine MAPE 40.27 peale annab ligi 5%. Teiste mudelite puhul otsustati kasutada

transformeeritud kuju, kuna MAPE-näitajad on väiksemad võrreldes transformeerimata kujuga.

6.2.1 Mudel LSTM

Mudeli LSTM koostamiseks ja hüperparameetrite tuunimiseks kasutati Keras API-d. Tuuniti kahte hüperparameetrit, kusjuures igal hüperparameetril on oma väärtuste hulk.

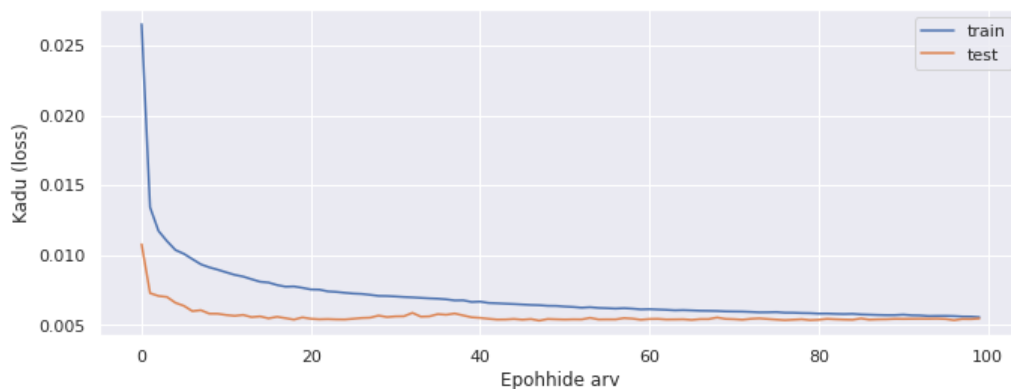
- Ühikud (*units*): minimaalne väärtus 32, maksimaalne väärtus 512, samm 32
- Õpisamm (*learning rate*): [0,01; 0,001; 0,0001]

Parimaks osutus kombinatsioon, kus ühikute arv on 256 ja õpisamm on 0.0001. Mudelit LSTM prooviti täiendada ka ühe RNN-(Keras API-s on see *SimpleRNN*) kihiga, kuid see tegi mudeli halvemaks. Samuti prooviti mudelit täiendada ühe ja kahe LSTM-lisakihiga, kuid kuna mudel jäi samaväärseks, otsustati jätkata ühekihilise LSTM-iga.

```
model = keras.Sequential()
model.add(
    keras.layers.Bidirectional(
        keras.layers.LSTM(
            units=256,
            input_shape=(X_train_LSTM.shape[1], X_train_LSTM.shape[2])
        )
    )
)
model.add(keras.layers.Dropout(rate=0.2))
model.add(keras.layers.Dense(units=1))
model.compile(loss='mean_squared_error', optimizer=keras.optimizers.Adam(learning_rate=0.0001))
```


Joonis 32. LSTM mudeli kood

Treenimisel otsustati epohhide arvuks võtta 100, kuna suurema arvu juures võib mudel üle treenida. Ploki suuruseks (*batch size*) valiti 64.




Joonis 33. LSTM-mudeli treenimine


Jooniselt Joonis 34 on näha kogu aasta prognoos võrreldes tegeliku tarbimisega. Selgub, et ennustatud tarbimine ületab tihti tegelikku elektritarbimist, seda eelkõige suveperioodil. Talviseid tippe on mudelil raskem ennustada. Selleks, et mudelist paremini aru saada, on välja toodud suvaliselt valitud perioodid. Esimesel joonisel (Joonis 35) on näha väljavõtet jaanuari algusest ja teisel joonisel (Joonis 36) juuni algusest. Joonistel 35 ja 36 on näha, et prognoositud tarbimine on laugema joonega ega suuda tarbimist täpselt jäljendada.



Joonis 34. Aasta 2020 prognoos kasutades LSTM-mudelit



Joonis 35. Väljavõte jaanuarikuu prognoosist (LSTM)




Joonis 36. Väljavõte juunikuu prognoosist (LSTM)

6.2.2 Mudel SVR


Mudeli SVR koostamiseks kasutati teeki *scikit-learn* ja hüperparameeride tuunimiseks *scikit-learn*'i alla kuuluvat mudelit *GridSearchCV*. Kuna algselt valitud juhuslikud parameetrid andsid parema RMSE/MAPE tulemuse kui *GridSearchCV* saadud parameetrid, siis seetõttu otsustati jääda kasutama juhuslikult valitud parameetreid:

- kernel: rbf
- C (regulariseerimise parameeter): 1
- gamma: auto
- epsilon: 0,01


Joonistelt 37–39 selgub, et suuremat tarbimist ei suudeta prognoosida ja väärtused koonduvad võrreldes LSTMi joonistega allapoole. Joonistelt järeldub, et prognoositud tarbimine jääb alati alla tegeliku väärtuse.



Joonis 37. Aasta 2020 elektritarbimise prognoos kasutades SVR-mudelit




Joonis 38. Väljavõte jaanuarikuu prognoosist (SVR)



Joonis 39. Väljavõte juunikuu prognoosist (SVR)

Kuna SVR-mudelil on kõige paremad tulemused MAPE osas, siis selle puhul testiti ka seda, kuidas mudel käitub, kui prognoositakse ainult aasta 2020 detsembri tarbimist ja ülejäänud andmepunkte kasutatakse treenimiseks.

RMSE tulemuseks saadi 1, MAPE puhul aga tunduvalt madalam 25,67.



Joonis 40. Aasta 2020 detsembri elektritarbimise prognoos kasutades SVR- mudelit

6.2.3 Mudel XGBoost


Mudeli XGBoost koostamiseks kasutati teeki *XGBoost* ja hüperparameerite tuunimiseks *scikit-learn*'i alla kuuluvat mudelit *GridSearchCV*.

Esimesena valiti välja parim võimendaja (*booster*), milleks osutus *gbtree*. Seejärel otsiti parimaid hüperparameetreid:


- maksimaalne puu sügavus (*max_depth*): [5, 6, 7, 10, 15],
- minimaalne lehe kaal (*min_child_weight*): [1,4],
- õpisamm: [0,03; 0,05; 0,07]
- puude arv (*n_estimator*): [100, 500].

Parimaks osutus kombinatsioon, kus puu maksimaalne sügavus on 5, lehe minimaalne kaal on 4, õpisamm 0,03 ja puude arv 100.


Aastaprognoozi jooniselt (vt Joonis 41) on näha, et see on sarnasem LSTM-iga (vt Joonis 34) ehk väärtused ei ole koondunud nii alla nagu SVR-mudeli puhul ja suviseid väärtusi ennustatakse paremini. Prognoositud tarbimine jääb tavaliselt alla tegeliku väärtuse.



Joonis 41. Aasta 2020 elektritarbimise prognoos kasutades XGBoost mudelit



Joonis 42. Väljavõte jaanuarikuu prognoosist (XGBoost)



Joonis 43. Väljavõte juunikuu prognoosist (XGBoost)


6.2.4 Mudel ETR

Mudeli ETR koostamiseks kasutati teeki *scikit-learn*, hüperparameeride otsiti käsitsi.


- Puude arv ($n_estimator$): [100, 1000]
- Maksimaalne puu sügavus (max_depth): [5, 10, 15, 20]

Parim tulemus saadi, kui puude arv on 1000 ja puu maksimaalne sügavus 20.


Visuaalselt sarnaneb terve aasta prognoos kõige rohkem mudelile XGBoost.



Joonis 44. Aasta 2020 elektritarbimise prognoos kasutades ETR-mudelit



Joonis 45. Väljavõte jaanuarikuu prognoosist (ETR)




Joonis 46. Väljavõte juunikuu prognoosist (ETR)


6.2.5 Lineaarne regressioon

Lineaarse regressiooni mudeli koostamiseks kasutati teeki *scikit-learn*, hüperparameetreid ei tuunitud, kuna mudelil ei ole parameetreid, mida tuunida.

Joonistelt 47–49 on näha, et lineaarse regressiooni mudel ei suuda ennustada suuremat tarbimist ja väärtused on koondunud pigem alla. Kui võrrelda lineaarse regressiooni mudelit eelpool käsitletutega, siis see ennustab talviseid (jaanuar - aprill) väärtusi paremini. Vaadates RMSE- ja MAPE-näitajaid selgub, et see lihtne mudel saavutab eelkäsitletutega võrdväärse tulemuse.



Joonis 47. Aasta 2020 elektritarbimise prognoos kasutades LR-mudelit



Joonis 48. Väljavõte jaanuarikuu prognoosist (LR) Joonis 49. Väljavõte juunikuu prognoosist (LR)

6.3 Prognoos aasta 2019 andmete alusel

Tuunitud mudelitega prognoositi eraldi aastat 2019 eesmärgiga saada aru, kas sellel aasta ennustus on parem võrreldes aastaga 2020. Seda katsetati, kuna COVID-19 tõttu muutus tarbimismuster, sest pereliikmed viibisid nädala sees rohkem kodus, lisaks oli aasta 2020 temperatuuri mõttes soojem.

Tabel 11. Mudelite tulemused aasta 2019 alusel

	LSTM	SVR	XGBoost	ETR	LR
RMSE	0,89	0,95	0,98	0,98	1
MAPE	48,22	35,81	37,38	37,79	39,74

Tulemused on võrreldes aasta 2020 prognoosiga veidi halvemad, mis viitab sellele, et mudelid vajavad rohkem treenimist.

6.4 Mudelite prognoositulemuste kokkuvõte

Tarbimise viimine logaritmilisele skaalale parandas üldiselt mudelite tulemusi. Mudelite prognooside tulemused on MAPE ja RMSE osas väga sarnased, kuid visualiseerimise abiga on näha erinevusi ning on võimalik mõista, millal mudel suuremaid vigu teeb.

- Mõned mudelid suudavad nõ tipp-tarbimist ennustada paremini kui teised.
- Talvekuudel on ennustusvõime halvem.
- Prognoosijooned on palju laugemad kui tegelik tarbimine.
- Autori arvates annab visuaalselt kõige täpsemad tulemused LSTM, kuna ennustuse kattuvust reaalse tarbimisega on rohkem. Lisaks ei jää prognoositud väärtused nii madalale nagu teiste mudelite puhul.

SVR-mudelil oli kõige paremad tulemused MAPE osas ($MAPE = 33,19$, $RMSE = 0,88$) ja LSTM-mudelil RMSE ($RMSE = 0,85$, $MAPE = 44,97$) osas, kuid RMSE erinevus on eri mudelite vahel väga väike. SVR- ja LSTM- mudelite MAPE erinevus on 11,78.

Autori arvates on MAPE ja RMSE tulemused aastaprognosi osas halvad, mudelid ei suuda reaalselt tarbimist jäljendada, ei suudeta ennustada elanike käitumist. Seevastu SVR-mudel näitas, et kui ennustada ainult 2020. aasta detsembrikuud, siis MAPE vähenes 7,52 võrra jõudes 25,67 peale. Mudelid muudaks täpsemaks ka tarbimisinfo viitega kaks, sel juhul oleks LSTM-i puhul RMSE 0,83 ja MAPE 41,92, SVR-i puhul aga vastavalt 0,84 ja 31,49.

Samuti uuriti, kuidas mudelid tarbimismustri muudatusega (2020 muutus tarbimine rohkem, kuna antud maja pereliikmed olid kriis ajal rohkem kodus) toime tulevad. Katsetati ennustamist ainult aasta 2019 andmete alusel. Selgus, et aasta 2019 aasta tulemused olid vähem täpsed, mis viitab sellele, et mudelid vajavad ilmselt rohkem treenimist. Samas, see näitas seda, et mudelid toime tarbimisprofili muutusega. Seda saab seletada sellega, et eelneva 24h tarbimine toimib siin olulise indikaatorina.

7 Kokkuvõte ja edasine töö

Magistritöös keskendutakse ühe maja elektritarbimise modelleerimisele eesmärgiga mõista, millised faktorid elektritarbimist mõjutavad. Lisaks koostatakse lühiajaline (1h) elektritarbimise prognoos.

Kuna inimeste energiavajadus üha suureneb, siis selle efektiivsemaks kasutamiseks, tuleb ka üksiktarbijal mõista, milline on tema tarbimine ja mis seda mõjutavad. Parem tarbimise juhtimine aitab ka rahalist kokkuhoidu saavutada. Andmete analüüs näitas, et elektritarbimine ei ole kunagi sama, kuna seda mõjutavad mitmed asjaolud nagu näiteks ilm ja elanike käitumismallid. Suured erinevused on nii aastaegade, nädalapäevade kui ka päevasisesese tarbimise osas. Seetõttu on üksiktarbija elektritarbimist väga keeruline prognoosida, sest me justkui prooviks ennustada elanike käitumist. Selgus, et töös vaadeldud ilmastikunäitajatest on olulised ainult temperatuur ja suhteline õhuniiskus. Kuna temperatuuril on oluline roll kogutarbimises, siis joonistus välja näiteks ka see, et talviti on tarbimine kõige suurem ja suvel kõige madalam. Nord Pooli hinna lisamine tarbimisele andis mõistmise, milline on statistiliselt elektrihind: kuidas elektrihind kõigub aastasiseselt, millal on päevasiseselt hind kõige madalamal ja millal kõige kõrgemal.

Nagu sissejuhatuses sai mainitud, siis jätkusuutlikkuse tagamiseks oluline saavutada stabiilne elektrivõrk, mille juures on väga oluline koht elektritarbimise prognoosil. Ennustuse alusel oleks võimalik vähendada elektritarbimist kui nõudlus on liiga suur ja seeläbi optimeerida tarbimist kõrgema elektri hinnaga tundidel. Antud töös andsid prognoosimudelitest kõige parema tulemuse SVR (MAPE = 33,19, RMSE = 0,88) ja LSTM (RMSE = 0,85, MAPE = 44,97). Olulisteks muutujateks olid nädalavahetus info, päevavalguse pikkus, suhteline õhuniiskus, temperatuur, aastaajad, tund, nädalapäeva ja eelmise 24 tunni tarbimine. SVR ja närvivõrgul põhinevad mudelid olid ka kirjanduses enim kasutatud. MAPE- ja RMSE- näitaja ei olnud autori arvates siiski piisavalt täpsed, seega tuleks otsida võimalusi, kuidas prognoosi täpsemaks muuta. COVID-19 ajal muutus pere elulaad, mistõttu veedeti rohkem aega kodus, mille tõttu muutus ka nädalasisene tarbimisprofiil. Prognoosimudeleid aga tarbimisprofiili muutus ei mõjutanud.

Jätkusuutlikkuse ja keskkonna seisukohalt on väga oluline kasutada taastuenergiat. Eratarbijad saavad suurendada oma panust näiteks kattes osa oma tarbimisest päikeseenergiaga ja seejuures vähendades ka elektrikulusi. Kuidas kujuneb aga päikesepaneelide tootlikkus ja kui otstarbekas nende soetamine on, ei ole kuigivõrd intuiitiivne (näiteks päikesepaneelide kalkulaatorid on väga üldised ja ei anna täit ülevaadet) ja seega vajab paremat analüüsi. Analüüsitulemused näitavad, et aprillist septembrini katavad päikesepaneelid pea täielikult kogu elektritarbimisevajaduse; talve- ja sügiskuudel aga ületab tegelik elektritarbimise vajadus oluliselt päikesepaneelide abil toodetud elektri hulka. Päikesepaneelid kataks ideaaltingimustest 50% elektrivajadusest ning tasuvusperioodiks saadi 14,5 aastat, kui aga võeti arvesse päikesepaneelide väiksemat tootlikkust neile langevate varjude tõttu (päikesepaneelide tootlikkuseks arvestati sel puhul 70% ideaaltingimuste omast), saadi tasuvusperioodiks 19,2 aastat ning päikeseenergia kataks sel juhul 35% kogutarbimise vajadusest. Lisaks tuli välja, et päikeseenergia tagasimüümine ei ole eriti tasuv kui võrrelda seda, mis kulu läheb tarbimisele (NordPool hinnale lisandub võrgutasu).

Töö edasiarendusvõimalused

Antud töös kasutatavad meetodeid saab kasutada edaspidi ka teiste majade peal ning leitud olulisi tegureid saab nende elektritarbimise prognoosimise juures arvestada. Kindlasti tuleb proovida prognoosimudelit parandada ning katsetada mitmesuguseid hübriidmudeleid, et kombineerida kokku mudelite parimaid omadusi. Samuti kuna kodud muutuvad ajaga üha nutikamaks on ehk võimalik täpsust suurendada ka sellega, et ennustada hoopis seadmete, mitte maja, tarbimist. Antud majal puudub täpne reaalaajaline info seadmete elektritarbimise kohta.

Tulevikus oleks mõistlik mõelda rakenduse tegemisele, mis näitaks infot elektritarbimise kohta, tarbimisprognoosi järgmiseks tunniks, kogu päeva tunnipõhist elektrihinda ning näiteks ka ilma infot. See annaks tarbijatele võimaluse visuaalselt ja seega hoomatavalt näha, milline on tarbimine ja milliseks see võib lähiajal kujuneda. Sellist lahendust võiks näiteks integreerida Eesti Energia või 220 Energia mobiilirakendusse, mille abil jõuaks parem elektritarbimise analüüsivahend rohkemate inimesteni. Praegu saab Eleringilt läbi API kätte Nord Pooli hinnad [73], kuid infot eraisiku reaalaaja tarbimise kohta pole võimalik läbi liidese saada. Eleringi sõnul on era- ja juriidiliste isikute tarbeks mõeldud API üle arutelu olnud ning tõenäoliselt see pikemas perspektiivis ka luuakse, kuid ilmselt mitte lähima aasta-kahe jooksul.

Kasutatud kirjandus

- [1] M. A. Hammad, B. Jereb, B. Rosi, ja D. Dragan, „Methods and Models for Electric Load Forecasting: A Comprehensive Review“, *Logist. Sustain. Transp.*, kd 11, nr 1, lk 51–76, veebr 2020, doi: 10.2478/jlst-2020-0004.
- [2] A. Jozi, T. Pinto, G. Marreiros, ja Z. Vale, „Electricity consumption forecasting in office buildings: an artificial intelligence approach“, *2019 IEEE Milan PowerTech*, juuni 2019, lk 1–6. doi: 10.1109/PTC.2019.8810503.
- [3] F. Amara, K. Agbossou, Y. Dubé, S. Kelouwani, A. Cardenas, ja J. Bouchard, „Household electricity demand forecasting using adaptive conditional density estimation“, *Energy Build.*, kd 156, lk 271–280, dets 2017, doi: 10.1016/j.enbuild.2017.09.082.
- [4] Y.-H. Hsiao, „Household Electricity Demand Forecast Based on Context Information and User Daily Schedule Analysis From Meter Data“, *IEEE Trans. Ind. Inform.*, kd 11, nr 1, lk 33–43, veebr 2015, doi: 10.1109/TII.2014.2363584.
- [5] D. Ignatiadis, G. Henri, ja R. Rajagopal, „Forecasting Residential Monthly Electricity Consumption using Smart Meter Data“, *2019 North American Power Symposium (NAPS)*, okt 2019, lk 1–6. doi: 10.1109/NAPS46351.2019.9000285.
- [6] R. Raudjärv ja L. Kuskova, „Energiatarbimine kodumajapidamistes“, *Eesti Stat.*, lk 15, 2013.
- [7] M. Jacob, C. Neves, ja D. Vukadinović Greetham, „Short Term Load Forecasting“, *Forecasting and Assessing Risk of Individual Electricity Peaks*, M. Jacob, C. Neves, ja D. Vukadinović Greetham, Toim Cham: Springer International Publishing, 2020, lk 15–37. doi: 10.1007/978-3-030-28669-9_2.
- [8] G. Weichun, M. Tingting, Z. Yu, W. Shunjiang, G. Kai, ja L. Jiajue, „Research on Joint Planning of the Source-Grid-Load with New Energy System Energy Balance and Economy“, *2018 International Conference on Engineering Simulation and Intelligent Control (ESAIC)*, aug 2018, lk 73–77. doi: 10.1109/ESAIC.2018.00024.
- [9] „GridIO“. <https://gridio.io/en> (vaadatud apr 02, 2021).
- [10] I. K. Nti, M. Teimeh, O. Nyarko-Boateng, ja A. F. Adekoya, „Electricity load forecasting: a systematic review“, *J. Electr. Syst. Inf. Technol.*, kd 7, nr 1, lk 13, sept 2020, doi: 10.1186/s43067-020-00021-8.
- [11] Y. Guo, D. Niu, ja Y. Chen, „Support Vector Machine Model in Electricity Load Forecasting“, *2006 International Conference on Machine Learning and Cybernetics*, aug 2006, lk 2892–2896. doi: 10.1109/ICMLC.2006.259076.
- [12] X. M. Zhang, K. Grolinger, M. A. M. Capretz, ja L. Seewald, „Forecasting Residential Energy Consumption: Single Household Perspective“, *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)*, dets 2018, lk 110–117. doi: 10.1109/ICMLA.2018.00024.
- [13] P. Lusic, K. R. Khalilpour, L. Andrew, ja A. Liebman, „Short-term residential load forecasting: Impact of calendar effects and forecast granularity“, *Appl. Energy*, kd 205, lk 654–669, nov 2017, doi: 10.1016/j.apenergy.2017.07.114.
- [14] B. Yildiz, J. I. Bilbao, J. Dore, ja A. Sproul, „Household electricity load forecasting using historical smart meter data with clustering and classification

- techniques“, *2018 IEEE Innovative Smart Grid Technologies - Asia (ISGT Asia)*, mai 2018, lk 873–879. doi: 10.1109/ISGT-Asia.2018.8467837.
- [15] C. Kuster, Y. Rezgui, ja M. Mourshed, „Electrical load forecasting models: A critical systematic review“, *Sustain. Cities Soc.*, kd 35, lk 257–270, nov 2017, doi: 10.1016/j.scs.2017.08.009.
- [16] R. V. Jones, A. Fuertes, ja K. J. Lomas, „The socio-economic, dwelling and appliance related factors affecting electricity consumption in domestic buildings“, *Renew. Sustain. Energy Rev.*, kd 43, lk 901–917, märts 2015, doi: 10.1016/j.rser.2014.11.084.
- [17] Z. Guo, K. Zhou, C. Zhang, X. Lu, W. Chen, ja S. Yang, „Residential electricity consumption behavior: Influencing factors, related theories and intervention strategies“, *Renew. Sustain. Energy Rev.*, kd 81, lk 399–412, jaan 2018, doi: 10.1016/j.rser.2017.07.046.
- [18] „Distribution of population by degree of urbanisation, dwelling type and income group - EU-SILC survey“, *Statistics / Eurostat*. https://ec.europa.eu/eurostat/databrowser/view/ILC_LVHO01__custom_592816/default/table?lang=en (vaadatud veebr 21, 2021).
- [19] J. Krstić, M. Reljić, ja S. Filipović, „Factors influencing electricity consumption: a review of research methods“, *Manag. Sustain. Bus. Manag. Solut. Emerg. Econ.*, kd 24, nr 2, Art. nr 2, sept 2019, doi: 10.7595/management.fon.2018.0021.
- [20] H. Zhao ja F. Magoulès, „A review on the prediction of building energy consumption“, *Renew. Sustain. Energy Rev.*, kd 16, nr 6, lk 3586–3592, aug 2012, doi: 10.1016/j.rser.2012.02.049.
- [21] W. Chandramitasari, B. Kurniawan, ja S. Fujimura, „Building Deep Neural Network Model for Short Term Electricity Consumption Forecasting“, *2018 International Symposium on Advanced Intelligent Informatics (SAIN)*, aug 2018, lk 43–48. doi: 10.1109/SAIN.2018.8673340.
- [22] A. Marvuglia ja A. Messineo, „Using Recurrent Artificial Neural Networks to Forecast Household Electricity Consumption“, *Energy Procedia*, kd 14, lk 45–55, jaan 2012, doi: 10.1016/j.egypro.2011.12.895.
- [23] B. Dong, Z. Li, S. M. M. Rahman, ja R. Vega, „A hybrid model approach for forecasting future residential electricity consumption“, *Energy Build.*, kd 117, lk 341–351, apr 2016, doi: 10.1016/j.enbuild.2015.09.033.
- [24] purnasai gudikandula, „Recurrent Neural Networks and LSTM explained“, *Medium*, märts 27, 2019. <https://medium.com/@purnasaigudikandula/recurrent-neural-networks-and-lstm-explained-7f51c7f6bbb9> (vaadatud veebr 24, 2021).
- [25] A. S. Ahmad *et al.*, „A review on applications of ANN and SVM for building electrical energy consumption forecasting“, *Renew. Sustain. Energy Rev.*, kd 33, lk 102–109, mai 2014, doi: 10.1016/j.rser.2014.01.069.
- [26] M. Amina, V. S. Kodogiannis, I. Petrounias, ja D. Tomtsis, „A hybrid intelligent approach for the prediction of electricity consumption“, *Int. J. Electr. Power Energy Syst.*, kd 43, nr 1, lk 99–108, dets 2012, doi: 10.1016/j.ijepes.2012.05.027.
- [27] D. Jiandong, W. Peng, M. Wentao, T. Xuan, ja Q. Xinyu, „Daily electricity consumption combined forecast based on variational mode decomposition and sample entropy“, *2019 IEEE Sustainable Power and Energy Conference (iSPEC)*, nov 2019, lk 762–767. doi: 10.1109/iSPEC48194.2019.8975040.
- [28] T. Hong ja S. Fan, „Probabilistic electric load forecasting: A tutorial review“, *Int. J. Forecast.*, kd 32, nr 3, lk 914–938, juuli 2016, doi: 10.1016/j.ijforecast.2015.11.011.

- [29] T. K. Wijaya, M. Vasirani, S. Humeau, ja K. Aberer, „Cluster-based aggregate forecasting for residential electricity demand using smart meter data“, *2015 IEEE International Conference on Big Data (Big Data)*, okt 2015, lk 879–887. doi: 10.1109/BigData.2015.7363836.
- [30] K. Chen, J. Jiang, F. Zheng, ja K. Chen, „A novel data-driven approach for residential electricity consumption prediction based on ensemble learning“, *Energy*, kd 150, lk 49–60, mai 2018, doi: 10.1016/j.energy.2018.02.028.
- [31] V. Tšetšnev, „Elektrienergia tarbimise lühiajaline ennustamine tehisnärvivõrkude abil“, Tallinna Tehnikaülikool, 2019. Vaadatud: veebr 24, 2021. [Online]. Available at: <https://digikogu.taltech.ee/et/Item/9f92aab-d5bd-4d9b-9525-5bfee3bd4727>
- [32] M. Sinimaa, „Elektritarbimise lühiajaline modelleerimine ja ennustamine: eesti juhtumi analüüs“, Tallinna Tehnikaülikool, 2020.
- [33] M. Maliarov, „Eluruumide elektritarbimise prognoosimine masinõppe algoritmide abil“, Tallinna Tehnikaülikool, 2020. Vaadatud: veebr 24, 2021. [Online]. Available at: <https://digikogu.taltech.ee/et/Item/738be4fe-5776-4cd1-97bb-159273420e57>
- [34] K. T. Kama, „Nordpooli elektrihinna analüüs ja ennustusmudeli arendamine“, Tallinna Tehnikaülikool, 2020. Vaadatud: veebr 24, 2021. [Online]. Available at: <https://digikogu.taltech.ee/et/Item/4c299a0f-e850-4961-98d8-0319405dd156>
- [35] „Algab kaugloetavate elektriavetite paigaldamine“, *ERR*, nov 26, 2012. <https://www.err.ee/356922/algab-kaugloetavate-elektriavetite-paigaldamine> (vaadatud veebr 21, 2021).
- [36] H. Rudi, „Alates uuest aastast peavad kõik elektriavetid olema kaugloetavad“, *Postimees*, nov 07, 2016. <https://majandus24.postimees.ee/3900247/alates-uuest-aastast-peavad-koik-elektriavetid-olema-kaugloetavad> (vaadatud veebr 21, 2021).
- [37] „Arvetite kauglugemine muutub kohustuslikuks igas korteris“, *City24*. <https://www.city24.ee/et/kinnisvarauudised/14720/arvetite-kauglugemine-muutub-kohustuslikuks-igas-korteris> (vaadatud veebr 21, 2021).
- [38] „Energy consumption per m²“, *European Commission*, okt 17, 2016. https://ec.europa.eu/energy/content/energy-consumption-m%C2%B2_en (vaadatud veebr 21, 2021).
- [39] „Energy consumption and use by households“, *Eurostat*. <https://ec.europa.eu/eurostat/web/products-eurostat-news/-/DDN-20190620-1> (vaadatud veebr 21, 2021).
- [40] „Final energy consumption“, *Statistics / Eurostat*. https://ec.europa.eu/eurostat/databrowser/view/t2020_34/default/table?lang=en (vaadatud veebr 22, 2021).
- [41] „Final energy consumption in households“, *Statistics / Eurostat*. https://ec.europa.eu/eurostat/databrowser/view/t2020_rk200/default/table?lang=en (vaadatud veebr 22, 2021).
- [42] „Energy consumption in households - Statistics Explained“, *Eurostat*. https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Energy_consumption_in_households#Energy_products_used_in_the_residential_sector (vaadatud veebr 21, 2021).
- [43] „Kuum teema: elekter“, *Eesti Energia*. <https://www.energia.ee/uudised/avaleht> (vaadatud veebr 21, 2021).
- [44] „Elekter kodukliendile“, *220 energia*. <https://www.220energia.ee/et/elekter-kodukliendile> (vaadatud märts 09, 2021).

- [45] „Maa-amet geoportaal“. index.php?lang_id=1&page_id=36 (vaadatud märts 10, 2021).
- [46] „Ilmakaared“, *Vikipeedia*, veebr 10, 2021. <https://et.wikipedia.org/w/index.php?title=Ilmakaared&oldid=5819714> (vaadatud märts 10, 2021).
- [47] „Elering - Andmeladu“. <https://andmeladu.elering.ee/consumer/home> (vaadatud veebr 04, 2021).
- [48] „Riigi Ilmateenistus“, *Riigi Ilmateenistus*. <http://www.ilmateenistus.ee/> (vaadatud märts 03, 2021).
- [49] „Pühade ja tähtpäevade seadus – Riigi Teataja“. <https://www.riigiteataja.ee/akt/109032011007> (vaadatud veebr 05, 2021).
- [50] „Elektribörs“, *Elering*. <https://elering.ee/elektribors> (vaadatud apr 06, 2021).
- [51] „Historical Market Data“, *Nord Pool*. <https://www.nordpoolgroup.com/historical-market-data/> (vaadatud märts 11, 2021).
- [52] J. Vetsvanags, „Elektrihinna muutlikkuse mõjutavate tegurite analüüs“, Tallinna Tehnikaülikool, 2015. Vaadatud: apr 12, 2021. [Online]. Available at: <https://digikogu.taltech.ee/et/Item/7bc338dc-98fd-4ffb-b652-f5655392893e>
- [53] T. Päll ja Ü. Maiväli, *Bayesi statistika kasutades R keelt*. Vaadatud: märts 25, 2021. [Online]. Available at: <https://rstats-tartu.github.io/bayesiraamat/andmete-transformimine.html>
- [54] „Päikesepaneelid“, *Solar4you*. <https://solar4you.ee/paikesepaneelid/> (vaadatud märts 24, 2021).
- [55] „Päikesepaneelid (PV-paneelid)“, *Energogen*. <https://energogen.ee/paikesepaneelid/paikesepaneelid/> (vaadatud märts 24, 2021).
- [56] M. Rehepapp, „Päikesepaneelide kasutamise majandusliku otstarbekuse võrdlus erinevatele tarbijatele Eestis“, Tallinna Tehnikaülikool, Tallinn, 2018. Vaadatud: apr 11, 2021. [Online]. Available at: <https://digikogu.taltech.ee/et/Item/f38ac853-dd85-4371-ad96-06e885909ed4>
- [57] „Energogen“. <https://energogen.ee/> (vaadatud märts 24, 2021).
- [58] „Solar4you“, *Solar4you*. <https://solar4you.ee/> (vaadatud märts 24, 2021).
- [59] „Päikesepaneelide hinna- ja efektiivsuse kalkulaator“, *Sinu Energia. Areva Solar*. <https://paikesepaneel.ee/> (vaadatud märts 12, 2021).
- [60] „Päikesepaneelid - Eesti Energia“. <https://www.energia.ee/era/taastuenergia/paikesepaneelid> (vaadatud märts 12, 2021).
- [61] „JRC Photovoltaic Geographical Information System (PVGIS)“, *European Commission*. https://re.jrc.ec.europa.eu/pvg_tools/en/tools.html (vaadatud märts 24, 2021).
- [62] „Hinnad ja paketid“, *Eesti Energia*. <https://www.energia.ee/abi/hinnad-ja-paketid> (vaadatud märts 27, 2021).
- [63] „Elektrilevi OÜ hinnakirjad alates 1. jaanuarist 2019“.
- [64] „Väiketootja leping“, *Eesti Energia*. <https://www.energia.ee/era/taastuenergia/tooda-ise> (vaadatud märts 27, 2021).
- [65] M. Pinn, „Elektrijaama saab püsti lihtsalt“, *Äripäev*. <https://www.aripaev.ee/uudised/2015/04/22/elektrijaama-saab-pusti-lihtsalt-paberimajandusega-pisut-pusimist> (vaadatud apr 03, 2021).
- [66] „Päikesepaneelide investeringutoetus“, *KredEx*. <https://kredex.ee/et/teenused/kuja-kov/paikesepaneelide-investeringutoetus> (vaadatud apr 03, 2021).
- [67] „Taastuenergia toetus“, *Elering*. <https://elering.ee/taastuenergia-toetus> (vaadatud apr 03, 2021).

- [68] „Väikeelamute rekonstrueerimistoetus“, *KredEx*.
<https://www.kredex.ee/et/majaduueks> (vaadatud apr 03, 2021).
- [69] „What is the difference between Extra Trees and Random Forest?“, *Quantdare*.
<https://quantdare.com/what-is-the-difference-between-extra-trees-and-random-forest/> (vaadatud apr 13, 2021).
- [70] S. Papadopoulos, E. Azar, W. Woon, ja C. Kontokosta, „Evaluation of tree-based ensemble learning algorithms for building energy performance estimation“, *J. Build. Perform. Simul.*, lk 1–11, juuli 2017, doi: 10.1080/19401493.2017.1354919.
- [71] Z. A. Almaliki, „Standardization VS Normalization“, *Medium*, okt 01, 2020.
<https://medium.com/@dataakkadian/standardization-vs-normalization-da7a3a308c64> (vaadatud märts 14, 2021).
- [72] S. Lakshmanan, „How, When, and Why Should You Normalize / Standardize / Rescale Your Data?“, *Towards Ai*. <https://towardsai.net/p/data-science/how-when-and-why-should-you-normalize-standardize-rescale-your-data-3f083def38ff>,
<https://towardsai.net/p/data-science/how-when-and-why-should-you-normalize-standardize-rescale-your-data-3f083def38ff> (vaadatud märts 14, 2021).
- [73] „Elering Dashboard API docs“, *Elering*. <https://dashboard.elering.ee/assets/api-doc.html#/> (vaadatud märts 25, 2021).

Lisa 1 – Lihtlitsents lõputöö reprodutseerimiseks ja lõputöö üldsusele kättesaadavaks tegemiseks¹


Mina, Egle Palk

1. Annan Tallinna Tehnikaülikoolile tasuta loa (lihtlitsentsi) enda loodud teose „Elektritarbimise modelleerimine eramaja näitel“, mille juhendaja on Margarita Spitsakova.
 - 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.


16.05.2021

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 loomingu tegevusega ning lõputöö kaas- või ühisautor(id) ei ole andnud lõputööd kaitsvale üliõpilasele kindlaksmääratud tähtajaks nõusolekut lõputöö reprodutseerimiseks ja avalikustamiseks vastavalt lihtlitsentsi punktile 1.1. ja 1.2, siis lihtlitsents nimetatud tähtaja jooksul ei kehti.

Lisa 2 – Tunnipõhine tarbimine koos elektri hinnaga



Joonis 50. Keskmine tarbimine nädalavahetusel tundide kaupa 2017–2020



Joonis 51. Keskmine tarbimine argipäeval tundide kaupa 2017–2020

Lisa 3 – Päikesepaneelide tootlikkus

Tabel 12. Päikesepaneelide tootlikkus

Kuu	Peamaja	Kuur ja garaaž	Kokku
1	186,26	87,62	273,88
2	466,68	263,06	729,74
3	1099,81	733,16	1832,97
4	1491,92	1137,25	2629,17
5	1803,29	1493,09	3296,38
6	1703,52	1476,55	3180,07
7	1719,93	1463,62	3183,55
8	1458,19	1160,91	2619,10
9	1007,58	721,58	1729,16
10	608,43	370,49	978,92
11	185,76	97,08	282,84
12	121,24	50,17	171,41
Kokku	11852,61	9054,58	20907,19