

VILNIAUS UNIVERSITETO

KAUNO FAKULTETAS

**SOCIALINIŲ MOKSLŲ IR TAIKOMOSIOS INFORMATIKOS
INSTITUTAS**

Finansų technologijų studijų programa

Kodas 6211BX022

POVILAS BAČKIERIUS

MAGISTRO BAIGIAMASIS DARBAS

**ELEKTROS ENERGIJOS RINKOS ATEITIES SANDORIŲ PANAUDOJIMO
KAŠTŲ OPTIMIZAVIMO METODAS**

Kaunas 2024

VILNIAUS UNIVERSITETO
KAUNO FAKULTETAS

SOCIALINIŲ MOKSLŲ IR TAIKOMOSIOS INFORMATIKOS
INSTITUTAS

POVILAS BAČKIERIUS

MAGISTRO BAIGIAMASIS DARBAS

ELEKTROS ENERGIJOS RINKOS ATEITIES SANDORIŲ PANAUDOJIMO
KAŠTŲ OPTIMIZAVIMO METODAS

Magistrantas_____

(parašas)

Darbo vadovas_____

(parašas)

Dr. Martas Ambraziūnas

(darbo vadovo mokslo laipsnis, mokslo
pedagoginis vardas, vardas ir pavardė)

Darbo įteikimo data

Registracijos Nr.

Kaunas 2024

TURINYS

SANTRUMPŲ IR TERMINŲ SĄRAŠAS	4
PAVEIKSLŲ SĄRAŠAS.....	5
LENTELIŲ SĄRAŠAS.....	6
SUMMARY	7
ĮVADAS.....	8
1. ELEKTROS RINKOS IR KAŠTŲ OPTIMIZAVIMO ANALIZĖ	12
1.1. Elektros rinkos liberalizavimas	12
1.2. Elektros kainų prognozavimas.....	13
1.3. Elektros ateities sandoriai	17
1.4. Elektros ateities sandorių pritaikymas	19
1.4.1. Laistymo sistemų analizė	20
1.4.2. Elektromobilių krovimų stotelių analizė.....	23
1.5. Tinkamų elektros kaštų prognozavimui mašininio mokymosi algoritmų analizė	26
2. ELEKTROS KAŠTŲ OPTIMIZAVIMO PROTOTIPAS	31
2.1. Darbo metodai	31
2.2. Prototipo aprašymas	31
2.3. Duomenų išgavimas	32
2.4. Programinės įrangos analizė	36
2.5. Prototipo atliekami skaičiavimai	37
3. ELEKTROS KAŠTŲ OPTIMIZAVIMO PROTOTIPO ANALIZĖ	40
3.1. Duomenų apdorojimas.....	40
3.2. Mašininio mokymosi modelių treniravimas	42
3.2.1. Elektros kainų prognozavimas	43
3.2.2. Ateities sandorių pritaikymas elektromobilių krovimo stotelėse.....	45
3.2.3. Ateities sandorių pritaikymas laistymo sistemose	51
3.3. Elektros ateities sandorių sudarymo rezultatų vertinimas	57
IŠVADOS.....	59
LITERATŪROS SĄRAŠAS.....	61

SANTRUMPŲ IR TERMINŲ SĄRAŠAS

Tikslusis žemės ūkis (angl. precision agriculture) - tai ūkininkavimo strategija, paremta laiko ir erdvės stebėjimu bei reagavimu į pokyčius.

Agri-Fintech – tai žemės ūkio ir finansų technologijų rinkinys, kuriuo siekiama padidinti ūkininkams finansinių paslaugų efektyvumą, pasiekiamumą ir įperkamumą.

Prosumeris – tai asmuo ar organizacija, kuri vienu metu tiek gamina, tiek vartoja produktus ar paslaugas.

PAVEIKSLŲ SĄRAŠAS

1 pav. Energijos rinkos liberalizacija	13
2 pav. Elektros kainų prognozavimo metodų grupės.....	15
3 pav. Elektros kainos priklausomybė nuo anglies ir dujų kainų.....	16
4 pav. Elektros kainų priklausomybė nuo išorinių veiksnių	17
5 pav. Elektros rinkos kainų palyginimas su išvestinėmis kainomis	18
6 pav. Žemės ūkio nuostolių priežastys pasaulyje.....	21
7 pav. Energijos vartojimas laistymo sistemose	22
8 pav. Energijos suvartojimas JAV žemės ūkyje 2002-2016 metais	22
9 pav. Elektromobilių rinkos augimas.....	24
10 pav. Svarbiausi veiksniai perkant degalus.....	25
11 pav. Elektros sąnaudos elektromobilių krovimo stotelėse.....	26
12 pav. Mašininio mokymosi kategorijos (Lisa Umutoni, Vidya Samadi, 2024).....	27
13 pav. Atsakymo iš meteo.lt API pavyzdys	33
14 pav. Elektros dienos kainų Lietuvoje duomenų pavyzdys.....	33
15 pav. Elektros suvartojimo Lietuvoje duomenų pavyzdys.....	34
16 pav. Dujų istorinių kainų pavyzdys	34
17 pav. Elektromobilių krovimo stotelių duomenys	35
18 pav. Sugeneruotų elektros ateities sandorių kainų pavyzdys.....	35
19 pav. Drėgmės garavimo formulė.....	37
20 pav. Drėgmės skaičiavimo formulė.....	37
21 pav. Laistymo tvarkaraščio duomenų pavyzdys	38
22 pav. Laistymo sistemos energijos poreikio skaičiavimo formulė.....	39
23 pav. Kodo ištrauka orų prognozės duomenų išgavimui	41
24 pav. Elektros kainų iš Nordpool parsisiuntimo algoritmas.....	42
25 pav. Pavyzdinis elektros prognozės grafikas	44
26 pav. Elektros kainų prognozavimo parametrų reikšmingumas	45
27 pav. Krovimo stotelių elektros suvartojimo prognozavimas.....	47
28 pav. Krovimo stotelių elektros suvartojimo prognozavimo parametrų reikšmės.....	47
29 pav. Krovimo stotelių elektros ateities sandorių sudarymo parametrų reikšmės.....	49
30 pav. Krovimo stotelių elektros ateities sandorių sutaupymo/nuostolių kasdieninis palyginimas	50
31 pav. Laistymo poreikio litrais prognozė.....	52
32 pav. Parametrų svarba vandens poreikio prognozavimui laistymo sistemoje	53
33 pav. Parametrų svarba elektros ateities sandorių sudarymui laistymo sistemose.....	55
34 pav. Laistymo sistemos elektros ateities sandorių sutaupymo/nuostolių kasdieninis palyginimas	56
35 pav. Laistymo sistemos sudarytų elektros ateities sandorių kainų palyginimas su elektros dienos kainomis	57

LENTELIŲ SĄRAŠAS

1 lentelė. Elektros kainų prognozavimo reikšmė	14
2 lentelė. Agri-fintech reikšmė	20
3 lentelė. Mašininio mokymosi algoritmų pritaikymas elektros kainų prognozavimui	28
4 lentelė. Mašininio mokymosi algoritmų pritaikymas elektromobilių krovimų stotelių apkrovos prognozavimui	29
5 lentelė. Mašininio mokymosi algoritmų pritaikymas laistymo sistemose	29
6 lentelė. Python, MATLAB ir R kalbų palyginimas	36
7 lentelė. Elektros kainų prognozavimo mašininio mokymosi modelių rezultatų palyginimas	43
8 lentelė. Elektromobilių krovimo stotelių apkrovos prognozavimo mašininio mokymosi modelių rezultatų palyginimas	46
9 lentelė. Elektros ateities sandorių elektromobilių krovimo stotelėms modelių palyginimas	48
10 lentelė. Elektromobilių krovimo stotelių elektros suvartojimo simuliacijos rezultatai	50
11 lentelė. Vandens poreikio prognozavimo laistymo sistemoje mašininio mokymosi modelių palyginimas	51
12 lentelė. Elektros ateities sandorių sudarymo laistymo sistemose mašininio mokymosi modelių palyginimas	54
13 lentelė. Laistymo sistemos elektros kaštų palyginimas naudojant ateities sandorius	55

Povilas Bačkierius (2024). *A Method for Optimising the Cost of Electricity Market Future Contracts*. MBA Graduation Paper, Kaunas: Vilnius University, Kaunas Faculty, Institute of Social Sciences and Applied Informatics, Financial Technologies. 63 p.

SUMMARY

This paper examines the method of using electricity market futures for cost optimization and practical application in specific areas. The aim of the paper is to create a prototype that, using machine learning algorithms, would help predict electricity prices and demand and conclude electricity futures contracts, thus reducing the costs of electricity consumption.

The paper first analyzes the liberalized electricity market, its structure and new technologies which were developed in regards by liberalized market. The liberalized electricity market opens the way for a wider use of electricity futures contracts. It has been established that financial instruments allow reducing the risk of electricity price fluctuations and facilitate cost planning. It has also been established that supervised machine learning algorithms are most suitable for price forecasting and concluding futures contracts. After properly training these algorithms with historical data, it is possible to predict electricity prices and costs in the short term; the longer the period, the greater the error.

The developed prototype predicts electricity prices, estimates future electricity demand and creates future electricity contracts if they are predicted to bring profit. The functionality of the prototype is tested in two areas: electric vehicle charging station networks and irrigation systems. The study shows that the prototype is able to reduce electricity costs and improve resource planning.

The results of the work show that the prototype could be applied in other areas where it is important to properly manage electricity costs. The liberalized electricity market and the availability of futures contracts for a wider part of the market can help create more sustainable solutions in various areas, achieving energy efficiency and economic stability.

IVADAS

Temos aktualumas

Tobulėjant technologijoms, kartu atsiranda poreikis tobulinti esamas sistemas. Dažniausiai naujovės yra kuriamos tam, kad ne tik palengvintų žmonių gyvenimus, bet ir tam, kad optimizuotų procesus kaštų atžvilgiu ir padarytų sistemas tvaresnėmis. Tai tampa ypač svarbu šiomis dienomis, kuomet konkurencija tarp verslų yra didelė, o bendras rezultatas susideda iš mažų detalių, kurios gali lemti labai daug. Ne išimtimi gali tapti ir elektros ateities sandorių sudarymas verslams, kurie suvartoja didelį kiekį energijos.

Ateities elektros sandoriai yra svarbi priemonė, kuri leidžia valdyti riziką, apsisaugoti nuo didelių kainų svyravimų ir optimizuoti elektros kaštus. Tyrimas, kaip šis instrumentas gali būti panaudotas specifinėse srityse, tokiose kaip laistymo sistemos ar elektromobilių įkrovimo stotelės, yra svarbus ne tik verslams, bet ir bendram elektros energijos kiekio suvartojimui. Atsižvelgiant į klimato kaitos poveikį šiems sektoriams, kaštų optimizavimas gali turėti poveikį ne tik ekonominiu, bet ir ekologiniu aspektu.

Aktualumą lemia ir globalūs energijos pokyčiai, kuomet vis didesnis dėmesys skiriamas išmaniesiems sprendimams ir integruotoms sistemoms, kurios leidžia vis efektyviau naudoti energiją. Liberalizuotoje rinkoje elektros ateities sandoriai gali tapti integruotu kaštų valdymo įrankiu, kuris ne tik sumažins riziką, bet ir didins patrauklumą investuotojams.

Problemos ištyrimo lygis

Bendrai elektros rinka ir ateities sandoriai yra ištirti gan plačiai. Apie elektros liberalizaciją Lietuvoje informacijos galima rasti valstybės energetikos reguliavimo tarnybos puslapyje (www.regula.lt). Plačiau apie liberalizacijos įtaką nagrinėja Pepermans (2019) ir kiti autoriai. Įvairiuose internetiniuose šaltiniuose tokiuose kaip Next Kraftweke galima rasti elektros rinkos palyginimą prieš ir po liberalizacijos.

Šaltinių, kuriuose galima rasti informacijos apie elektros kainų prognozavimą, taip pat nemažai. Apie elektros kainų prognozavimą ir įtaką kalba Luo H. ir Shao Y. (2024). Dabuoh Mba A. ir kiti (2024) tyrinėja specifinius metodus, kuriais elektros ateities kainos gali būti prognozuojamos. Palygina skirtingus metodus ir išryškina pranašumus bei trūkumus. Taip pat galima rasti daug straipsnių apie tai, kas įtakoja elektros kainą ir kokie duomenys padeda ją prognozuoti.

Kalbant apie ateities sandorius, galima rasti tiek mokslinių straipsnių, tiek internetinių šaltinių, kurie pateikia elektros ateities sandorių naudą, kaip išvengti didelių kainų svyravimų. Euronext ir Nordpool (2024) puslapyje galima rasti informaciją, jog šios platformos jau nuo 2025 metų padarys elektros ateities sandorius labiau prieinamais didesnei rinkos daliai.

Tačiau sunkiau surasti tinkamų šaltinių būna tuomet, kai norima rasti straipsnių apie elektros ateities sandorių pritaikymą specifinėse srityse. Kadangi elektros ateities sandoriai vis dar nėra prieinami plačiai auditorijai, tokių tyrimų beveik nėra atlikta. Tačiau tai tampa aktualu, kai kalbama apie elektros rinkos liberalizaciją ir naujų platformų kūrimą, kurios padaro ateities sandorius labiau prieinamais.

Darbo problema

Kaip mašininio mokymosi algoritmai ir elektros kainų prognozavimas padeda sudaryti ateities sandorius ir sumažinti elektros kaštus?

Darbo objektas

Elektros energijos rinkos ateities sandorių panaudojimo kaštų optimizavimui metodas.

Darbo tikslas

Sukurti prototipą, padėsiantį optimizuoti elektros kaštus.

Darbo uždaviniai

Norint pasiekti darbo tikslą, buvo iškelti šie uždaviniai:

1. Apžvelgti dabartinę elektros rinką
2. Išnagrinėti elektros kainų prognozavimą
3. Įvertinti elektros ateities sandorių naudą
4. Išanalizuoti elektros ateities sandorių pritaikymo sritis
5. Išanalizuoti tinkamus mašininio mokymosi algoritmus prognozavimui
6. Sukurti prototipą, kuris padės optimizuoti elektros kaštus
7. Įvertinti sukurto prototipo pritaikymą ir naudą

Darbo struktūra

Pirmoje darbo dalyje „Elektros rinkos ir kaštų optimizavimo analizė“ nagrinėjama dabartinė elektros rinka Lietuvoje ir Europos Sąjungoje. Didžiausias dėmesys yra skiriamas elektros rinkos liberalizacijai. Toliau aptariama kaip ir kokiais būdais yra prognozuojamos elektros kainos ir kurie metodai yra veiksmingiausi. Kuomet kalbama apie liberalizaciją, dėmesys skiriamas ir išvestiniam finansiniam instrumentui – elektros ateities sandoriams. Analizuojama jų nauda ir kaip tai padeda valdyti riziką. Taip pat nagrinėjamos specifinės sritys, tokios kaip laistymo sistemos ir elektromobilių krovimo stotelės, ir aiškinamasi, kaip ateities sandoriai galėtų šiose sistemose optimizuoti elektros kainų kaštus. Optimizavo analizė atliekama tyrinėjant įvairius mašininio mokymosi prognozavimo algoritmus ir duomenis, kuriuos jie naudoja.

Antroje dalyje „Elektros kaštų optimizavimo prototipas“ aptariami darbe naudojami metodai. Taip pat aprašomas prototipas ir naudota programinė įranga. Pristatomi duomenų šaltiniai, kurie yra skirti mašininio mokymosi algoritmų treniravimui.

Trečioji dalis „Sukurto elektros kaštų optimizavimo prototipo analizė“ yra skirta parodyti, kaip buvo apdorojami duomenys ir kokie skaičiavimai su jais atliekami. Ir galiausiai atvaizduojami gauti rezultatai įvairiais aspektais.

Darbe naudoti literatūros šaltiniai

Pirmoje darbo dalyje buvo panaudoti moksliniai straipsniai iš įvairių duomenų bazių ir leidiniai, kurie padėjo suprasti niuansus elektros rinkoje ir ateities sandorių panaudojime. Taip pat dalis šaltinių yra iš internetinių puslapių, kurie dažniausiai suteikia įvairius duomenų atvaizdavimus bei suteikė informacijos apie ateities sandorių pritaikymą elektros rinkoje.

Darbo ir tyrimo metodai

Elektros rinkos ir ateities sandorių pritaikymo analizei naudojami tokie metodologiniai metodai kaip lyginamoji analizė, abstrahavimas, sintezė ir sisteminimas.

Empirinio tyrimo metu buvo atliekamas duomenų rinkimas, skaitinė analizė ir jų apdorojimas. Toliau buvo modeliuojamas ir kuriamas elektros kaštų optimizavimo prototipas.

Darbo rezultatų teorinė ir praktinė reikšmė

Teorinė reikšmė:

1. Išanalizuota liberalizuota elektros rinka Lietuvoje ir Europos Sąjungoje.
2. Atlikta elektros kainų prognozės analizė ir išskirti metodai, kurie yra tinkamiausi kainų prognozėms atlikti.
3. Išnagrinėta elektros ateities sandorių nauda ir reikšmė.
4. Apžvelgtos laistymo sistemų ir elektromobilių krovimų stotelių rinkos ir galima elektros kainų prognozių ir ateities sandorių nauda.
5. Išnagrinėti mašininio mokymosi algoritmai, kurie yra tinkamiausi prognozuoti elektros kainas ir sudaryti ateities sandorius.

Praktinė reikšmė:

1. Atlikti tyrimą ir sukurti elektros kaštų optimizavimo prototipą, kuris su nedideliais pakeitimais galėtų būti pritaikomas įvairiose rinkose. Šiuo atveju tiriamas laistymo sistemos ir elektromobilių krovimų stotelių kaštų optimizavimas.
2. Sukurto prototipo rezultatais pagrįsti elektros ateities sandorių naudą skirtingoms sritims.

Darbo sunkumai, taikymo apribojimai

Didžiausias sunkumas buvo rasti duomenis, kurie tiktų mašininio mokymosi algoritmo treniravimui. Taip pat elektros ateities sandorių istorinių duomenų trūkumas, dėl šio trūkumo šiuos duomenis teko generuoti, dėl to tyrimo rezultatai gali būti ne visai tikslūs.

Darbo struktūra ir apimtis

Darbas sudarytas iš įvado, 3 dalių ir išvadų. Darbo apimtis yra 60 puslapių neįskaičiuojant literatūros sąrašo. Darbe yra 35 paveikslai ir 13 lentelių. Literatūros sąrašas sudarytas iš 45 šaltinių.

1. ELEKTROS RINKOS IR KAŠTŲ OPTIMIZAVIMO ANALIZĖ

Elektros energijos rinka nuolatos kinta, ypač reikia atsižvelgti į liberalizacijos procesą ir besikeičiančias technologines galimybes. Svarbu ištirti tiek elektros rinkos liberalizacijos poveikį, tiek potencialias galimybes elektros kaštų optimizacijai. Reikia išnagrinėti elektros ateities sandorių koncepciją ir elektros kainų prognozių metodus, naudojant mašininio mokymosi algoritmus. Taip pat reikia susipažinti su rinkomis, kuriose šis kaštų optimizavimo metodas gali būti pritaikytas.

Pirmoje dalyje pateikiama išsami teorinė analizė, kuri sukuria pagrindą prototipo kūrimui, kurio tikslas sumažinti elektros kaštus laistymo sistemose bei elektromobilių krovimo stotelėse. Toks požiūris leidžia pažinti elektros vartojimo rinkas ir pritaikyti tokį metodą platesnėse rinkose.

1.1. Elektros rinkos liberalizavimas


Pradedant tyrinėti kaštų optimizavimą, pirmiausia būtina išsiaiškinti elektros rinką ir jos subtilybes.

Nuo 2021 metų Lietuvos gyventojai turėjo pasirinkti nepriklausomą elektros tiekėją ir elektrą pirkti iš jo. Tai reiškia, kad elektros rinka tapo laisva ir joje atsirado konkurencija. Tik apie pusę kainos yra reguliuojama valstybės, kita pusė priklauso nuo elektros biržos kainų bei tiekėjų ir konkurencijos tarp jų (Valstybės energetikos reguliavimo tarnyba, 2020).

Liberalizavus energijos rinką tikimasi sumažinti elektros kainas, pagerinti tiekiamų paslaugų kokybę ir suteikti vartotojui pasirinkimą. Nors pats liberalizavimo procesas Europos Sąjungoje prasidėjo daugiau nei prieš 20 metų, vis dar atsiranda kliūčių kaip tai pilnai įgyvendinti. Daugelyje ES valstybių, kaip ir Lietuvoje, yra integruota vidinė elektros rinka, tačiau norint pilnai tai įgyvendinti ir užtikrinti pilną mažmeninę konkurenciją reikia laiko ir pastangų. Viena iš pagrindinių kliūčių yra fizinės tinklų integracijos, kurios dar pilnai neužtikrina sklandaus paskirstymo ir tarpvalstybinio tinklo sujungimo. Taip pat trūksta elektros rinkos ir politikos suderinamumo tarp ES valstybių, kurios trukdo rinkai reaguoti į paklausos pakitimus (Pepermans, 2019).

1 pav. palygina kaip atrodo energijos rinka prieš ir po liberalizacijos. Prieš liberalizaciją elektros tiekimo grandinė, į kurią įeina gamyba, perdavimas, paskirstymas ir mažmeninė prekyba, yra valdoma vertikalčiai vieno subjekto, dažniausiai reguliuojamo valstybės monopolio. Šioje sistemoje visiškai nėra konkurencijos ir vartotojai neturi kitų pasirinkimų. Po liberalizacijos rinka yra

suskaidoma į atskiras dalis. Gamyba ir mažmeninė prekyba tampa konkurencingos ir leidžia atsirasti keliems paslaugos tiekėjams, kurie konkuruoja tarpusavyje, stengdamiesi suteikti palankesnes kainas ir geresnę kokybę. Tačiau perdavimo ir paskirstymo tinklai vis dar išlieka reguliuojami monopoliai, tam kad užtikrintų lygiavertę prieigą visiems rinkos dalyviams. Iš esmės liberalizacija skatina vartotojų laisvę rinktis ir tai turi sukurti mažesnes kainas klientams bei efektyvesnį resursų rinkoje paskirstymą.



Šaltinis: Next Kraftwerke

1 pav. Energijos rinkos liberalizacija

Taigi, liberalizuotoje rinkoje gali atsirasti didesni kainų svyravimai ir kaina labiau priklauso nuo paklausos bei pasiūlos. Esant tokioms sąlygoms, kainas galima bandyti prognozuoti ir kuomet yra didelis elektros suvartojimas – teisingos prognozės gali padėti sutaupyti.

1.2. Elektros kainų prognozavimas

Elektros kainų prognozavimas yra svarbus šiuolaikinėje energijos rinkoje, kuomet tai yra nepastovus ir nekaupiamas resursas. Tikslios prognozės yra svarbios visiems rinkos dalyviams, tiek gamintojams, mažmeninės prekybos dalyviams bei vartotojams.

Elektros kainų prognozavimo reikšmė


Nauda	Aprašymas
Kaštų minimizavimas	Tikslios prognozės rinkos dalyviams padeda sumažinti kaštus, patobulindamos sprendimus apie elektros pirkimus ir pardavimus.
Pelno didinimas	Suinteresuotos šalys kainų prognozes gali naudoti įvairioms verslo strategijoms tam, kad padidintų gaunamą pelną.
Rizikos valdymas	Būsimų kainų tendencijų žinojimas padeda planuoti ir valdyti finansus, nes nepastovios kainos gali kelti riziką valdomiems resursams
Prisitaikymas prie rinkos pokyčių	Teisingas prognozavimas leidžia efektyviai reaguoti į rinkos ir reguliacijos pokyčius, skirtingus kainų svyravimus.
Operacijų efektyvumo didinimas	Pagerina resursų planavimą ir paskirstymą, padidindama veiklos operacijų efektyvumą.

Šaltinis: Luo H., Shao Y. (2024)

Kadangi elektros kainų prognozavimas yra svarbus visiems energijos rinkos dalyviams, svarbu išsiaiškinti kokiais metodais kainas galima prognozuoti ir kurie yra veiksmingiausi.

Elektros kainų prognozavimui galima pasitelkti keletą skirtingų metodų. Dabuoh Mba A. ir kiti (2024) moksliniame leidinyje aptaria skirtingus metodus. Visų pirma kainas galima prognozuoti pasitelkiant statistinius modelius, tokius kaip autoregresiniai modeliai (ARIMA, ARIMAX ir panašūs) ar laiko eilučių analizė. Pasitelkiami istoriniai duomenys ir bandoma numatyti trumpalaikes tendencijas ar sezoniškumus. Taip pat kainas prognozuoti galima naudojant mašininio mokymosi algoritmus. Tam reikalingas didelis kiekis duomenų ir galima atpažinti skirtingas bei sudėtingas kainų tendencijas. Naudojami įvairūs neuroninių tinklų algoritmai, tokie kaip LSTM ar CNN. Tokiais atvejais naudojami ne tik kainų istoriniai duomenys, bet taip pat analizuojama nuo kokių kitokių veiksnių gali priklausyti kainos, pavyzdžiui nuo orų sąlygų ar dujų kainų.

2 pav. galima matyti skirtingas elektros kainų prognozavimo metodų grupes. Kainoms prognozuoti galima pasitelkti metodus atskirai, tačiau norint pasiekti geriausią rezultatą, skirtingus metodus galima apjungti į hibridinį modelį, tokiu būdu gauti rezultatai gali būti tikslesni.




Šaltinis: Pinhao M. ir kiti (2022).

2 pav. Elektros kainų prognozavimo metodų grupės

Norint kuo tiksliau prognozuoti elektros kainą, reikalinga išsiaiškinti veiksnius, kurie tai įtakoja. Visų pirma, tai yra elektros pasiūlos ir paklausos pokyčiai. Kuomet paklausa didėja, tada kyla elektros kainos ir atvirkščiai. Paklausa gali būti paveikta oro sąlygų ar verslų veiklos, kuomet yra keičiami vartojimo įpročiai (Maciejowska K. ir kiti, 2023).

Taip pat didelę įtaką elektros kainoms turi atsinaujinančios elektros gamyba. Kuomet yra pagaminama daug elektros, naudojant atsinaujinančius šaltinius, kainos yra linkusios mažėti. Pavyzdžiui, Ispanijoje nuo 2019 metų iki 2024 metų pagaminama saulės ir vėjo elektros dalis padidėjo nuo 26 % iki 40 % visos pagaminamos elektros. Dėl šio didelio pokyčio didmeninės elektros kaina tapo 40 % mažesnė, negu būtų buvusi, jeigu saulės ir vėjo pagaminamas elektros kiekis nebūtų pasikeitęs (Quintana J., 2024).

Elektros kainos priklauso ir nuo kitų išteklių kainų. Didžiausią įtaką turi anglies ir dujų kainos. 3 pav. pateikiamas pavyzdys, kaip Austrijos elektros kainos yra glaudžiai susijusios su dujų kainomis. Į beveik kiekvieną didesnę pilko stulpelio pakitimą reaguoja mėlyna kreivė. Tai rodo, jog Austrijos elektros rinka priklauso nuo dujų kainos. Nors Lietuvos elektros kainos neatvaizduojamos, tačiau apžvelgus kitas Europos Sąjungos šalis, galima pamatyti panašią priklausomybę. Nors Europos Sąjungoje siekiama, kad elektros priklausomybė nuo anglies ir dujų būtų mažesnė, tačiau pereinamuoju laikotarpiu šie šaltiniai vis dar daro didelę įtaką elektros kainoms.




Šaltinis: Ember

3 pav. Elektros kainos priklausomybė nuo anglies ir dujų kainų

Tačiau elektros kainos gali priklausyti ne tik nuo vidinių veiksnių ir resursų, kurie tiesiogiai daro įtaką kainoms, bet ir nuo išorinių įvykių. 4 pav. vaizduoja skirtingų valstybių elektros kainų reakciją į išorinius veiksnus. Pavyzdžiui, 2021 metų viduryje kainos pradėjo kilti dėl atsigavimo po COVID pandemijos, kadangi pasaulyje padidėjo energijos suvartojimas, todėl padidėjo ir energijos paklausa. Kuomet kainos pradėjo stabilizuotis po COVID pandemijos – Rusijos invazija Ukrainoje sukėlė didelę kainų šuolį, kadangi Europa turi didelę dujų priklausomybę nuo Rusijos. Šis įvykis sustiprino energijos krizę ir kainos pakilo į istorines aukštumas. Europa, reaguodama į kainų šuolius, ėmėsi veiksmų, jog sumažintų energijos krizę. Sukurti priemonių paketai tokie kaip REPowerEU, kuris skirtas sumažinti energijos priklausomybę nuo Rusijos bei spartinti atsinaujinančios energijos plėtrą ir efektyvumą.

Išorinius veiksnus, kurie galėtų paveikti elektros kainas, yra sunkiau prognozuoti nei vidinius veiksnus ar turimus resursų rezervus bei tų resursų panaudojimą. Išoriniai veiksniai tokie kaip pandemijos ar karai gali prasidėti labai staigiai ir turėti didelę įtaką elektros kainoms. Taip pat elektros kainas gali paveikti naujai išleisti įstatymai. Šie įstatymai gali būti susiję su elektros kainomis tiek tiesiogiai, pavyzdžiui, REPowerEU, tiek netiesiogiai, pavyzdžiui, tokie įstatymai, kurie yra susiję su klimato kaitos mažinimu, bet dėl jų verslai ar gyventojai gali pradėti rinktis atsinaujinančią energiją, kurios kainos skiriasi.

Evolution of monthly average day-ahead electricity wholesale prices in France, Germany and Spain – June 2021 to December 2022 (EUR/MWh)



Šaltinis: Acer

4 pav. Elektros kainų priklausomybė nuo išorinių veiksnių

Apibendrinant, elektros kainų prognozavimas yra svarbus šiuolaikinėje energijos rinkoje, kuri yra nepastovi. Tikslesnės prognozės leidžia rinkos dalyviams priimti sprendimus, kurie padeda sumažinti kaštus bei padidinti pelną. Prognozes gali paveikti daugelis faktorių, tokie kaip pasiūla ir paklausa, kitų išteklių kainos, kaip dujų ar anglies, taip pat išoriniai faktoriai, pandemijos, geopolitinės krizės ar politiniai sprendimai.

1.3. Elektros ateities sandoriai

Nepastovios elektros kainos gali tapti iššūkiu ne tik verslininkams ar ūkininkams, bet ir visiems kitiems vartotojams. Dėl įvairių veiksnių, tokių kaip pasiūla ir paklausa ar geopolitiniai įvykiai, yra sudėtinga numatyti savo išlaidas. Tokiuose scenarijuose išlaidų planavimui padeda ateities sandoriai. Ateities sandoriai apsaugoja nuo didelių kainų svyravimų ir užfiksuoja kainas ilgesniam laikotarpiui.

Nord Pool – viena didžiausių elektros biržų Europoje, paskelbė, jog jau 2025 metų kovo mėnesį testavimui paleis naują platformą, kuri bus orientuota į Šiaurės ir Baltijos šalis bei suteiks galimybę sudaryti ateities sandorius perkant elektrą (Euronext and Nord Pool announce Nordic and Baltic Power Futures market, 2024).

Elektros ateities sandoriai apsaugo nuo kainų svyravimo, kuomet yra užfiksuojamos kainos ir tokiu būdu sumažina riziką bei padeda tiksliau valdyti savo išlaidas. Tinkamai valdant savo krepšelį, galima sumažinti išlaidas ir taip sutaupyti. Taip pat ateities sandoriai padeda apsisaugoti nuo kainų svyravimų, kurie yra sukeliama besikeičiančių orų sąlygų, kurios įtakoja kainų šuolius (Markus Hess, 2013).



Šaltinis: Electricity deriv-a-tives markets (2022)

5 pav. Elektros rinkos kainų palyginimas su išvestinėmis kainomis

Diagramoje galima matyti kaip ateities sandoriai padeda išvengti didelių kainų šuolių. Nors kartais rinkos kaina ir buvo žemiau, nei sudaryti ateities sandoriai, tačiau už elektrą nebuvo permokėta, kuomet kaina staigiai išaugo.

Ateities sandoriai gali būti naudojami įvairių rinkos dalyvių tam, kad išvengtų kainų šuolių, sumažintų riziką ir palengvintų resursų planavimą. Vienu iš jų yra prosumeriai, kurie tiek gamina, tiek naudoja elektrą. Užima reikšmingą vietą vietinėse rinkose ir tiesioginėse (angl. peer-to-peer) sistemose, suteikdami galimybę lanksčiai mainytis elektra. Kita rinkos dalyvių grupė - agregatoriai. Tai tarpininkai, kurie jungia keletą prosumerių, jie padeda mažesniems rinkos dalyviams įsilieti į didesnes rinkas, derasi dėl sandorių ir organizuoja energijos tiekimą. Tuo tarpu virtualiosios elektrinės apjungia decentralizuotus energijos gamybos tinklus ir kartu juos valdo, siekdami optimizuoti elektros gamybą bei vartojimą. Šie tinklai dalyvauja įvairiuose prekybos modeliuose ir didina sistemos efektyvumą. Dar viena svarbi rolė - vietinių rinkų operatoriai, kurie užtikrina sklandžią prekybą, kad sandoriai vyktų efektyviai ir sąžiningai. (Khajeh H, Firoozi H ir kiti, 2022).

Įvairūs verslai gali pakliūti po keliomis kategorijomis, priklausomai nuo jų veikimo principo, gali būti tiek prosumeriai, tiek vietinių rinkų dalyviai, kurie tiesiogiai prekiauja energija su kitais rinkos dalyviais.

Technologiniai sprendimai yra svarbi dalis elektros ateities sandorių sudaryme. Jie suteikia galimybę rinkos dalyviams efektyviau ir tiksliau prognozuoti kainas. Tarp technologijų išsiskiria pažangūs prognozavimo modeliai, automatizuotos platformos, blokų grandinės ir dirbtinio intelekto pritaikymas.

Pažangūs prognozavimo modeliai leidžia numatyti kainų svyravimus, kurie gali būti nepalankūs vartotojui. Naudojant tokius duomenis, kaip orų sąlygos, elektros paklausa ir pasiūla bei geopolitiniai įvykiai, galima apmokyti mašininio mokymosi modelius ir tokias situacijas numatyti. Rinkos dalyviai, naudodami prognozavimo modelius gali pastebėti rinkos tendencijas ir priimti sprendimus dėl ateities sandorio sudarymo (Jedrezejwski A., Lago J. ir kiti, 2022).

Naudojant blokų grandinės technologiją galima užtikrinti skaidrumą ir saugumą elektros ateities sandoriams. Decentralizuotos platformos leidžia rinkos dalyviams sudaryti sandorius be tarpininkų, taip sumažindamos administracines išlaidas ir padidindamos sandorių sudarymo greitį. Taip pat, naudojantis blokų grandinės technologija, yra galimybė kurti išmaniuosius kontraktus, kurie automatiškai vykdo sandorius, kuomet yra tenkinamos pateiktos sąlygos (IEEE Blockchain Technical Community).

Šios technologijos ne tik padidina ateities sandorių sudarymo efektyvumą ir tikslumą, bet ir prisideda prie rinkos skaidrumo ir stabilumo kūrimo. Rinkos dalyviai įgauna daugiau pasitikėjimo ir galimybių, kaip teisingai valdyti savo portfelius.

Taigi, elektros ateities sandoriai ir teisingas kainų prognozavimas yra vienas iš pagrindinių įrankių, kai norima optimizuoti elektros kaštus ir valdyti riziką. Nepastovioje rinkoje gali atsirasti įvairių iššūkių, kurie kelia grėsmę verslo stabilumui. Ateities sandoriai yra naudingi įvairiems rinkos dalyviams, tiek individualiems prosumeriams, tiek didelėms įmonėms, kurios gamina ir vartoja elektrą.

1.4. Elektros ateities sandorių pritaikymas

Elektros sandorių taikymas įvairiose srityse, tokiose kaip laistymo sistemos ir elektromobilių krovimo stotelių tinklai, atskleidžia jų potencialą ne tik mažinant elektros kaštus, bet ir didinant

veiklos efektyvumą bei prisidedant prie tvarumo tikslų. Ateities sandoriai gali padėti stabilizuoti energijos kaštus, sumažinti riziką ir užtikrinti patikimą energijos tiekimą, kuomet susiduriama su energijos krizėmis. Taip pat elektros ateities sandoriai gali padėti išlikti lyderiu konkurencingoje rinkoje, kai galima pasiūlyti labiau prieinamas kainas klientams, lyginant su konkurentų kainomis. Šie pavyzdžiai parodo, kaip elektros ateities sandoriai padeda verslams kurti pridėtinę vertę skirtingiems sektoriams, prisitaikant prie specifinių poreikių ir iššūkių bei atskleidžia, kad toks metodas gali būti taikomas plačiau.

1.4.1. Laistymo sistemų analizė

Visame pasaulyje, tuo tarpu ir Lietuvoje, jaučiami globalinio atšilimo rezultatai. Ūkininkai dėl sausrų patiria didelius nuostolius. Per 2019 metus Lietuvoje ūkininkai patyrė 90 milijonų eurų nuostolių. Lietuva dėl savo padėties vidutinėse platumose yra klimato kaitos centre (LRT, 2019). Nors tokie nuostoliai šalies mastu gali atrodyti nedideli, tačiau kiekvienais metais, kai dėl sausrų yra prarandama keli procentai viso žemės ūkio kuriamos pridėtinės vertės, tai tampa aktualia problema.

Tokių problemų sprendimą apima agri-fintech sritis. Agri-Fintech – tai žemės ūkio ir finansų technologijų rinkinys, kuris leidžia ūkininkams padidinti finansinių paslaugų efektyvumą ir įperkamumą. Agri-Fintech yra sąvoka, apimanti daug sričių. 2 lentelėje yra apžvelgiamos kelios iš jų, kurios yra artimiausiai susijusios su laistymo sistemomis bei jų sprendžiamomis problemomis.

2 lentelė


Agri-fintech reikšmė

Sritis	Reikšmė ūkininkams
Finansinių paslaugų prieinamumas	Ūkininkai, gyvendami kaimuose, susiduria su sunkumais gauti finansines paslaugas. Todėl svarbu užtikrinti sklandų paslaugų tiekimą tiek miestuose, tiek kaimuose bei paslaugas perkelti į skaitmeninę erdvę.
Pasėlių draudimas ir rizikos valdymas	Agri-fintech sprendimai padeda įvertinti riziką, susijusią su pasėlių praradimu (pavyzdžiui rizikos vertinimui naudoja palydovų nuotraukas) bei tinkamai apdrausti savo turtą.
Tikslusis žemės ūkis ir duomenų analizė	Duomenų analizė padeda įvertinti laukų būklę bei atlikti tikslesnius sprendimus dėl laistymo, tręšimo ar kenkėjų naikinimo. Tai kuria taupesnę ir tvaresnę ūkį.
Išteklių valdymas ir tvarumas	Su fintech sprendimais mažinant energijos ir kuro sunaudojimą, ne tik sutaupoma, bet ir saugoma gamta.

Šaltinis: Pedro F. (2023). Fintech in Agriculture: How Digital Platforms are Empowering Farmers

Laistymo sistemos yra neatsiejama agri-fintech dalis. Norint patogiai ir saugiai valdyti laistymo sistemas, reikalingas finansinių paslaugų prieinamumas, jog būtų tvarkingai atsiskaitoma už sunaudotus resursus, bei draudimas ir rizikos valdymas, kuriems didelę įtaką turės išmanios ir optimizuotos laistymo sistemos. Tikslusis žemės ūkis – kone svarbiausia sritis, į kurią reikia susikonsoliduoti, norint optimizuoti laistymo sistemą, kadangi, tai apima ir duomenų analizę, reikalingą atlikti skaičiavimams, bei visos techninės įrangos paruošimą.


Agri-fintech kai kurios sritys gali atrodyti neaktualios, bet tik iki tol, kol nesusiduriama su nuostoliais. Pagal atliktą tyrimą nustatyta, jog net 17 % nuostolių patirta dėl globalinio atšilimo bei prognozuojama, jog globalinio atšilimo poveikis tik didės (Junaid, Gokce, 2024).



Šaltinis: Junaid, Gokce (2024). Global agricultural losses and their causes

6 pav. Žemės ūkio nuostolių priežastys pasaulyje


Energija laistymo sistemoms gali būti tiekama skirtingais būdais, tačiau didžiąją dalį sudaro elektra (7 pav.). Ši energija leidžia kurti drėkinamąjį žemės ūkį ir yra atsakinga už apie pusę visų JAV užauginamų ir parduodamų pasėlių (Sowby B. R., 2022).



Šaltinis: Sowby B. R. (2022). The energy footprint of U.S. irrigation: A first estimate from open data

7 pav. Energijos vartojimas laistymo sistemose

8 pav. galima matyti kiek JAV žemės ūkyje yra iš viso suvartojama energijos. Daugiausiai suvartojama dyzelino ir trąšų. Į trąšų energijos suvartojimą taip pat yra įskaičiuojama energija reikalinga jų gamybai, transportavimui ir panaudojimui. Trečioje vietoje yra elektra, kuri daugiausiai yra naudojama laistymo sistemose pumpuoti vandenį bei džiovininti derliui. Nors didelę dalį užima su laistymu nesusijusi energija, nereikia nuvertinti elektros sąnaudų, kurios bendrame kontekste sudaro nemažą dalį visos vartojimo energijos.



Šaltinis: Economic Research Service U.S. Department of Agriculture (2018)

8 pav. Energijos suvartojimas JAV žemės ūkyje 2002-2016 metais

Šiuo metu ūkininkai dažniausiai sudaro energijos pirkimo kontraktus, kurie nustato energijos pirkimo sąlygas tarp vartotojo ir gamintojo. Dažnai ūkininkai turi atsinaujinančios energijos šaltinius, kurie energijos perteklių parduoda gamintojui. Tokiu būdu galima užtikrinti pajamų srautą ir kompensuoti dalį energijos išlaidų (Farmers weekly, 2024).


Kadangi šiuo metu nėra pakankamai išvystyta infrastruktūra ir galimybės ūkininkams naudoti elektros ateities sandorius, tai pavyzdžių kaip tai naudojama nėra. Tačiau elektros rinkai vystantis ir vykstant liberalizacijai, atsiranda naujos galimybės. Nordpool paskelbus apie elektros ateities sandorių platformą, galima numanyti, kad atsiras galimybės ir mažesniems vartotojams sudaryti ateities sandorius bei taip kovoti su kainų svyravimais.

1.4.2. Elektromobilių krovimų stotelių analizė

Elektromobilių rinka yra gretai besivystanti ir auganti. Kiekvienais metais galime pastebėti vis daugiau elektromobilių. Tarp pačių populiariausių automobilių prekės ženklų yra ir Tesla. Tesla prekiauja elektra varomais automobiliais, kurie gali būti įvairių tipų, pavyzdžiui, visureigiai ar lengvieji automobiliai. Taip pat Tesla prekės ženklas gali būti laikomas netgi prabangos preke. Taigi, elektromobiliai gali būti perkami netgi dėl socialinio statuso. Kadangi jų paklausa auga, tai auga ir jų krovimo stotelių skaičius. Krovimo stotelių operatoriams labai svarbi elektros kaina, kadangi tai pagrindinė žaliava, ką jie parduoda klientui.

Elektromobiliai tampa vis populiarsnis pasirinkimas tarp vairuotojų. 2023 metų duomenimis buvo parduota beveik 14 milijonų elektromobilių. Iš jų apie 25 % buvo užregistruota Europoje, o apie 10 % Jungtinėse Amerikos Valstijose. Taip pat, pagal užregistruotų automobilių kiekį, vienas iš penkių automobilių Europoje yra elektromobilis (Trends in Electric Cars, 2024). Tai rodo, jog Europoje yra paklausa ir elektromobilių krovimo stotelėms.

9 pav. galima matyti elektromobilių rinkos augimo prognozes iki 2033 metų. Per 10 metų rinka padidėja daugiau nei 8 kartus. Tai priklauso nuo to, kad automobilių gamintojai vis labiau yra linkę investuoti į elektra varomus automobilius, o vartotojai yra linkę rinktis tvarius sprendimus ir saugoti gamtą.




Šaltinis: Precedence Research (2024)

9 pav. Elektromobilių rinkos augimas

Esant dideliui rinkos augimui, atsiranda ir konkurencija tarp skirtingų tiekėjų. Stotelių operatoriai sudarinėja įvairius kainodaros modelius, kuriais siekia padidinti gaunamą pelną. Dinaminiai modeliai atsižvelgia į konkurencines aplinkas ir leidžia reguliuoti kainas, kad pritrauktų vartotojus (EEE Transactions on Smart Grid, 2023). Pavyzdžiui, verslininkai gali sumažinti parduodamo projekto kainą vos keliais centais, taip pritraukiant daugiau klientų ir padidinant savo pelną.

2019 metų duomenimis 59 % degalų pirkėjų svarbiausias motyvas, renkantis degalinę, buvo degalų kaina. Tai galima pastebėti 10 pav. Antras didžiausias veiksnys, kuris daro įtaką degalų pirkėjams yra degalinės vieta, bet tai sudaro tik 22 %. Taigi nors ir fizinė degalinė gali būti toliau nei kitoje gatvės pusėje, tačiau vartotojas gali pasirinkti pirkti degalus toje degalinėje, kurioje kainos yra mažesnės, nors ir reikėtų važiuoti toliau. Kai kuriose Europos sąjungos valstybėse degalų kainos gali skirtis vos puse cento ir tai gali paskatinti klientus pasirinkti pigesnę degalinę (3 Ways to Learn About Retail Fuel Pricing Sensitivity, 2022).

Characteristics most important in purchase decisions




Šaltinis: Consumer Behavior at the Pump (2019)

10 pav. Svarbiausi veiksniai perkant degalus

Krovimo kaina tiesiogiai priklauso nuo elektros kainos. Didesnės elektros kainos gali privesti prie didesnių krovimo kainų arba mažesnio pelno. Norint optimizuoti pelną, verslininkams būtų naudinga pirkti elektrą kuo pigiau, o po to parduoti ją elektromobilių krovimo stotelėse pagal rinkos kainą. Nupirkus pigesnę elektrą, būtų galima šią elektrą krovimo stotelėse parduoti šiek tiek žemiau rinkos kainos, taip pritraukiant daugiau klientų. Integravus paklausos reagavimo strategiją, krovimo stotelės gali koreguoti savo operacijas atsižvelgiant į elektros kainas realiu laiku (Chen Q., Liu N. ir kiti, 2014).

11 pav. pavaizduoja, kiek energijos reikia elektromobilių stotelėms. Nors stotelių operatoriai nuolat investuoja į atsinaujinančią energiją, taip norėdami sutaupyti, tačiau vis dar didžiąją elektros dalį tenka pirkti. Vasarą, kuomet yra saulėta, saulės sugeneruota energija gali padėti padengti dalį išlaidų. Bet žiemą, kada saulės yra nedaug, gaunamo elektros kiekio iš saulės elektrinių įtaka bendram elektros suvartojimui nėra didelė. Taip pat gaunama saulės energija gali priklausyti nuo tuo metu esamų oro sąlygų, pavyzdžiui, jei atitinkamą dieną yra debesuota, tai tą dieną elektros iš saulės bus gaunama mažiau. Elektros kainos elektromobilių krovimų stotelių savininkams yra vis dar labai aktualios net tuo atveju, jei jie yra investavę į atsinaujinančią saulės energiją, iš kurios gali gauti dalį pigesnės elektros.



Šaltinis: Jing L., 2022

11 pav. Elektros sąnaudos elektromobilių krovimo stotelėse


Taigi, augant elektromobilių rinkai, didėja ir krovimų stotelių paklausa. Nors naudojamos įvairios strategijos, kurios siekia optimizuoti stotelių veikimą ir padidinti pelną, tačiau suvartojamos energijos kaštų optimizavimas vis dar išlieka iššūkiu. Atsinaujinančios energijos sprendimai padeda mažinti elektros kaštus, tačiau vis dar nėra labai efektyvūs, kadangi reikalauja didelių investicijų. Elektros ateities sandoriai tokiose situacijose elektros krovimo stotims galėtų suteikti pranašumo prieš konkurentus, kadangi pigiau nupirkta elektra gali leisti sumažinti krovimo kainą ir taip pritraukti daugiau klientų.

1.5. Tinkamų elektros kaštų prognozavimui mašininio mokymosi algoritmų analizė

Per ilgą laiką prognozių sistemos tobulėjo ir jų panaudojimo metodai keitėsi. Šiais laikais, kuomet yra surinkta daug duomenų, juos galima panaudoti optimizacijos tikslais. Didelį duomenų kiekį žmogui savo jėgomis apdoroti yra labai sudėtinga ir tai atlikti labai greitai – neįmanoma. Tai šiuos duomenis galima patikėti mašininio mokymosi algoritmams, kurie apsimokę, sprendimus gali atlikti ir greitai, ir dažniausiai su mažiau klaidų, nei žmogus. Toliau renkant ir analizuojant duomenis, algoritmus galima tobulinti ir išgauti geresnius rezultatus. Tačiau norint išgauti geriausią rezultatą,

būtina išsiaiškinti koks mašininio mokymosi tipas ir algoritmas kaštų optimizacijai ir ateities sandorių sudarymui yra tinkamiausias.

Mašininio mokymosi algoritmai skirstomi į 3 pagrindines grupes, kurios pavaizduotos 12 paveikslėlyje. Tai yra prižiūrimas mokymasis (angl. Supervised learning), neprižiūrimas mokymasis (angl. Unsupervised learning) ir sustiprintas mokymasis (angl. Reinforcement learning). Prižiūrimas mokymasis gali būti naudojamas nustatyti kategorines išvestis, tokiu atveju naudojami klasifikacijos algoritmai, jeigu išvestis skaitinė, tada regresiniai algoritmai. Šie algoritmai naudoja sužymėtus duomenis ir pagal treniravimosi rinkinį apsimoko. Atvirkščiai veikia neprižiūrimas mokymasis. Šie algoritmai naudoja nesužymėtus duomenis ir bando rasti duomenyse tam tikras sąsajas ir pagal tai susieti ar išskaidyti duomenis išvestyje. Sustiprintas mokymasis leidžia mašinoms ir agentams automatiškai įvertinti aplinkos veiksnius tam, kad būtų padidintas efektyvumas. Taip pat šie visi mašininio mokymosi tipai gali būti kombinuojami ir tokiu būdu išgaunami tikslesni bei efektyvesni rezultatai (Lisa Umutoni, Vidya Samadi, 2024).



Šaltinis: Umutoni Lisa, Samadi Vidya (2024). Application of machine learning approaches in supporting irrigation decision making: A review.

12 pav. Mašininio mokymosi kategorijos (Lisa Umutoni, Vidya Samadi, 2024)

Kadangi tyrime yra nagrinėjamos kelios sritys, tai yra elektros kainų prognozavimas ir ateities sandorių sudarymas, laistymo tvarkaraščių sudarymas ir elektromobilių krovimų stotelių apkrovos

prognozavimas, būtina išsiaiškinti kokie mašininio mokymosi algoritmai yra tinkamiausi šioms sritims.

3 lentelėje galima pamatyti, jog elektros kainų prognozavimui pagrinde naudojami prižiūrimi mašininio mokymosi algoritmai. Šiuo atveju yra pateikiami sužymėti duomenys, kurių pagalba algoritmai mokosi ir pagal tai ateityje gali atlikti prognozes. Dažniausiai naudojami yra istorinės kainos, atsinaujinančios energijos duomenys bei meteorologiniai duomenys.

3 lentelė

Mašininio mokymosi algoritmų pritaikymas elektros kainų prognozavimui

Nuoroda	Algoritmas	Aprašymas
Chughatta R. K., Haroon S. S., 2023	LSTM, GRU	Modeliai naudoja istorines elektros kainas ir meteorologinius duomenis tam, kad prognozuotų trumpalaikius kainų svyravimus
Zhao Z., Want C. ir kiti, 2018	ARIMA, GARCH	Naudoja istorinę elektros kainų seką ir sezoninius svyravimus. ARIMA prognozuoja kainų tendencijas, o GARCH įvertina kainų nepastovumą
Bara A., Oprea V. S., 2023	LSTM	Nagrinėja LSTM modelio struktūrą. Modelis apdoroja laiko eilutes, istorines kainas, paklausą ir meteorologinius duomenis.
Duke R., Mahajan J. ir kiti (2024)	Random Forest, SVM	Kainų prognozei naudojamos istorinės kainos, atsinaujinančios energijos duomenys, makro ekonomikos rodikliai bei paklausa ir pasiūla

Šaltinis: sudaryta autoriaus

Taip pat svarbu apžvelgti ir elektromobilių krovimo stotelių apkrovos prognozavimo metodus. 4 lentelėje galima pastebėti, kad naudojami prižiūrimieji mašininio mokymosi algoritmai. Svarbiausi duomenys yra pačių krovimo stotelių surinkta informacija apie klientus: kiek laiko kraunasi, kaip dažnai, kiek žmonių per dieną apsilanko ir panašūs duomenys. Reikia atkreipti dėmesį ir į aplinkinius veiksnius, tokie kaip orai, ar net miesto, kuriame yra stotelė, išsivystymo lygis.

**Mašininio mokymosi algoritmų pritaikymas elektromobilių krovimų stotelių apkrovos
prognozavimui**

Nuoroda	Algoritmas	Aprašymas
Ma. S., Jin. N. ir kiti (2024)	MLP ir LSTM	Naudojami krovimo parko duomenys, kaip žmonės naudojami krovimo stotelėmis. Prognozuojamos apkrovos atskiroms savaitės dienoms ir šventėms.
Gore S., Iqbal A. ir kiti (2024)	SVM, KNN	Prognozuojama krovimo paklausa, naudojant duomenis, surinktus Norvegijoje, tokie kaip orai ar krovimų sesijų ypatumai.
Zhu J., Yang Z. ir kiti (2019)	LSTM, GRU	Orų, atostogų, elektros kainų ir miesto išsivystymo lygio duomenys naudojami krovimų stočių apkrovai prognozuoti.

Šaltinis: sudaryta autoriaus

Kadangi ateities sandorių rinka gali būti plačiai pritaikoma įvairiose srityse, apžvelgsime ir mašininio mokymosi algoritmų pritaikymą laistymo sistemų tvarkaraščių sudarymuose.

Mašininio mokymosi algoritmų pritaikymas laistymo sistemose

Nuoroda	Algoritmas	Aprašymas
Weiqing Gu, Zhaocheng Yi (2020)	GMM, PCA, K-means (neprižiūrimi mašininio mokymosi algoritmai)	Iš API parsisiunčia orų prognozes ir SMS žinute žmogui nusiunčia rekomendacijas, kada ir kokių intensyvumu laistyti.
S. Ramya, A.M. Swetha ir Manivannan Doraipandian (2020)	SVR ir Bagging (prižiūrimi mašininio mokymosi algoritmai)	Apdoroja orų duomenis ir kontroliuoja vandens paleidimą, kai apskaičiuoja koks turėtų būti dirvos drėgnumas po laistymo ar lietaus.
S. Meivel, S. Maheswari (2020)	KNN (prižiūrimas mašininio mokymosi algoritmas)	Renka vaizdinius duomenis, gautus iš dronų, juos apdoroja ir pateikia laistymo rekomendacijas.
Pankaj Kashyap, Sushil Kumar, Ankita Jaiswal (2021)	LSTM (prižiūrimas ir neprižiūrimas mašininio mokymosi algoritmas)	Pagal dirvos drėgnumą ir oro sąlygas numato ateinančios dienos laistymo grafiką. Padeda sutaupyti iki 43 % vandens, lyginant su standartiniu drėkinimu.
Chen, Y., Hsieh, W (2021)	SVR, SVC, RF ir DT (prižiūrimi mašininio mokymosi algoritmai)	Oro drėgnumas, temperatūra, dirvos temperatūra, drėgnumas ir šviesos intensyvumas yra apdorojami ir gaunamas rezultatas, kaip intensyviai laistyti

Šaltinis: sudaryta autoriaus

Apžvelgus mašininio mokymosi algoritmus ir jų pritaikymą laistymo sistemose 5 lentelėje, galima matyti, jog skaičiavimams, kurie reikalauja paprastų duomenų, tokių kaip oro sąlygos ar dirvos drėgnumas, yra naudojami prižiūrimi algoritmai. Taip yra dėl to, jog modeliui yra paduodami

tikslūs duomenys ir žinomas tikslus norimas rezultatas. Kuomet norima gauti rezultatą iš duomenų, tarp kurių yra sunku rasti kokius nors ryšius, pavyzdžiui, vaizdinėje augalo informacijoje, tuomet naudojami neprižiūrimi algoritmai.

Bendrai išnagrinėjus mašininio mokymosi algoritmus, galima pastebėti, kad tiek elektros kainų prognozavimui, tiek atskirų sistemų (laistymo sistemų tvarkaraščiui ir elektromobilių krovimo stotelių apkrovos prognozavimui) vertinimui dažniausiai naudojami prižiūrimi algoritmai. Tai reiškia, kad yra labai svarbu, kaip pasirinkti duomenis ir kaip teisingai juos sužymėti, kad algoritmas kuo tiksliau galėtų priimti sprendimus. Pavyzdžiui, tokie algoritmai, kaip LSTM, SVR ar Random Forest, gerai susitvarko su laiko eilutėmis, kas šiose situacijose yra labai reikalinga. Be to, galima pastebėti tendenciją, jog vis dažniau naudojami hibridiniai modeliai, kurie padeda lengviau spręsti kompleksines užduotis.

Galiausiai, visi sprendimų rezultatai priklauso nuo duomenų kokybės, tikslumo ir teisingo paruošimo. Duomenų žymėjimas ir tinkamas interpretavimas yra vienas svarbiausių veiksnių, kuris įtakoja rezultato tikslumą. Mašininio mokymosi algoritmai veiksmingi tik tuomet, kai yra apmokomi tinkamais duomenimis.

2. ELEKTROS KAŠTŲ OPTIMIZAVIMO PROTOTIPAS

Antrojoje darbo dalyje aprašomas sukurtas elektros kaštų optimizavimo prototipas ir jo pagrindiniai komponentai - duomenų šaltinių analizė, mašininio mokymosi modelių taikymas bei simuliacijos aplinka. Prototipo tikslas yra kuo tiksliau numatyti elektros poreikius ir elektros ateities kainas bei, esant tinkamoms sąlygoms, sudaryti elektros ateities sandorius. Atlikta analizė parodo ne tik teorinę naudą, bet aptaria ir praktinius aspektus, kurie yra reikalingi prototipo pritaikymui specifinėse srityse.

2.1. Darbo metodai

Kadangi buvo siekiama sukurti prototipą, kuris optimizuoja elektros kainų kaštus tiek laistymo sistemose, tiek elektromobilių krovimo stotelėse, visų pirma reikėjo išanalizuoti šias sritis skirtingais aspektais. Pirmiausia, pritaikant teorinės analizės metodą, buvo nagrinėjama liberalizuota elektros rinka Lietuvoje, elektros ateities sandorių nauda, laistymo sistemų ir elektromobilių krovimo stotelių rinkos ir mašininio mokymosi modeliai, kurie gali padėti atlikti kainų ir rinkų apkrovos analizes. Literatūros analizėje naudoti sintezės, lyginamosios analizės, abstrahavimo ir sisteminimo metodologiniai tyrimo metodai.

Toliau buvo atliekamas empirinis tyrimas, kurio metu buvo renkami duomenys, kuriame mašininio mokymosi modeliai, jie treniruojami bei testuojami, ir galiausiai vertinamas sukurto prototipo našumas.

2.2. Prototipo aprašymas

Sukurtas prototipas, kuris skirtas optimizuoti elektros kaštus, naudojant elektros ateities sandorius. Prototipo funkcionalumas yra panaudojamas tirti laistymo sistemų ir elektromobilių krovimų stotelių sritis. Jis yra kuriamas su tikslu, jog taip pat galėtų būti pritaikomas ir kitose srityse, kuriose elektros kaštai sudaro reikšmingą išlaidų ir/arba sąnaudų dalį ir kur galima prognozuoti elektros poreikių dydį. Šiuo metu prototipas tik simuliuoja situacijas ir atlieka skaičiavimus, ar toks jo pritaikymas yra naudingas ir reikalingas. Tačiau atsiradus poreikiui ir pakeitus reikiamus srities duomenis kitais - jį būtų galima naudoti ir platesniais aspektais.

Pagrindiniai prototipo komponentai:

1. Duomenų šaltiniai ir apdorojimas:

Elektros kainų prognozėms yra naudojamos istorinės elektros kainos, ateities sandoriai, orų prognozės, atsinaujinančios energijos pagaminimo duomenys, dujų istorinės kainos. Papildomai prognozuojant elektromobilių krovimo stotelių apkrovą, naudojami istoriniai klientų krovimo duomenys, o laistymo tvarkaraščio sudarymui naudojamos orų prognozės ir augalų duomenys.

2. Mašininio mokymosi modeliai:

Prognozėms ir sprendimams priimti yra naudojami keli mašininio mokymosi modeliai. Algoritmų parinkimui naudojama analizė ir lyginami skirtingi variantai bei pasirenkamas pats tinkamiausias. Pagrindinis modelis yra skirtas prognozuoti elektros kainoms trumpajam periodui. Sekantys du modeliai yra skirti prognozuoti elektros poreikiams. Tai yra elektros kiekis, skirtas elektromobilių krovimui bei laistymo sistemai funkcionuoti. Paskutiniai du modeliai yra panašūs tuo, jog jie įvertina ateities sandorio reikalingumą. Jie palygina prognozuojamas elektros kainas, ateities sandorių kainas, elektros reikalingumą tomis dienomis ir įvertina riziką, ar sudarytas ateities sandoris suteiks naudą.

3. Simuliacija ir sąnaudų analizė:

Prototipo našumas vertinamas simuliacinėje aplinkoje, kuomet parinktame laikotarpyje atliekamos kainų ir sąnaudų prognozės. Tokiu būdu siekiama išsiaiškinti, ar elektros kainų prognozavimas ir ateities sandorių sudarymas atneša finansinę naudą.

2.3. Duomenų išgavimas

Kokybiški istoriniai duomenys yra reikalingi tinkamam prototipo veikimui. Jie buvo renkami iš įvairių duomenų bazių ir tinklapių, naudojant skirtingus išgavimo būdus. Taip pat dalis duomenų yra sugeneruoti, nes tinkamų duomenų šaltinių nepavyko rasti.

Orų prognozių duomenys gauti iš meteo.lt API (LHMT), naudojant „/v1/stations/kauno-ams/observations/{date}“ prieigos tašką. Pateikiant datą Y-m-d formatu, gaunamas atsakymas JSON formatu su tos dienos orų prognozėmis kiekvienai valandai. Atsakyme svarbiausi duomenys yra oro temperatūra, kritulių kiekis ir drėgmė.


```


1 {
2   "station": {
3     "code": "kauno-ams",
4     "name": "Kauno AMS",
5     "coordinates": {
6       "latitude": 54.88396,
7       "longitude": 23.83588
8     }
9   },
10  "observations": [
11    {
12      "observationTimeUtc": "2024-01-01 00:00:00",
13      "airTemperature": 0,
14      "feelsLikeTemperature": -3.2,
15      "windSpeed": 2.7,
16      "windGust": 4.8,
17      "windDirection": 99,
18      "cloudCover": 100,
19      "seaLevelPressure": 1014.1,
20      "relativeHumidity": 84,
21      "precipitation": 0,
22      "conditionCode": "cloudy"
23    },

```

Šaltinis: LHMT

13 pav. Atsakymo iš meteo.lt API pavyzdys

Elektros dienos kainos Lietuvoje gautos iš NordPool tinklapio. Istorines kainas galima pasiekti pasirinkus laiko periodus ir nustačius, jog duomenys būtų agreguojami dienomis. Kainos yra pateikiamos eurai už vieną megavatvalandę tam tikrą dieną. Tinklapis suteikia patogią vartotojo sąsają kainoms tikrinti, palyginti su kainomis, esančiomis kitose šalyse, bei analizuoti istorinius duomenis.



Šaltinis: NordPool

14 pav. Elektros dienos kainų Lietuvoje duomenų pavyzdys

Lietuvos elektros perdavimo sistemos operatorė Litgrid suteikia prieigą prie Lietuvos elektros suvartojimo duomenų. Duomenų atvaizdavimui tinklapio panelėje galima pasirinkti didžiausią 31 dienos periodą, tačiau, norint gauti didesnio laikotarpio istorinius duomenis, juos galima parsisiųsti .xls formatu. Litgrid pateikia tokius duomenis: šalies suvartojamas elektros kiekis, planuojamas suvartojimo kiekis, atsinaujinančios energijos prognozuojami pagaminimo kiekiai bei kiek iš tikro energijos buvo pagaminta. Duomenys tinklapyje yra pateikiami vienos valandos intervalu, atvaizduojama data ir kiekis elektros megavatais.

	Actual national Consumption
2024-09-30 00:00:00	1028.764
2024-09-30 01:00:00	989.18
2024-09-30 02:00:00	977.688
2024-09-30 03:00:00	971.93
2024-09-30 04:00:00	984.847
2024-09-30 05:00:00	1042.468
2024-09-30 06:00:00	1289.314
2024-09-30 07:00:00	1501.755
2024-09-30 08:00:00	1681.662
2024-09-30 09:00:00	1684.184
2024-09-30 10:00:00	1607.83

Šaltinis: Litgrid

15 pav. Elektros suvartojimo Lietuvoje duomenų pavyzdys

Anglies ir dujų kainos gautos iš investing.com tinklapio. Istorinius duomenis galima agreguoti dienomis, pasirinkti periodą bei pamatyti duomenis tinklapyje. Taip pat duomenis galima parsisiųsti .csv formatu.

Time Frame						
Daily						
Download 10/14/2024 - 11/14/2024						
Date	Price	Open	High	Low	Vol.	Change %
Nov 14, 2024	45.195	45.505	45.655	44.995	1.92K	+3.50%
Nov 13, 2024	43.666	43.625	44.105	42.200		-1.33%
Nov 12, 2024	44.255	43.820	44.435	43.000	7.78K	+1.21%
Nov 11, 2024	43.728	41.675	44.110	41.675	8.19K	+3.11%
Nov 08, 2024	42.409	42.325	43.055	41.975	7.86K	+2.74%

Šaltinis: Investing.com

16 pav. Dujų istorinių kainų pavyzdys

Elektromobilių krovimo stotelių duomenys gauti iš Kaggle duomenų bazės. Tai yra platus duomenų rinkinys su daug įvairių parametru, tačiau tyrime reikalingiausi parametrai yra data, savaitės diena ir suvartojamas elektros kiekis. Kiekviena atskira krovimo sesija turi atskirą įrašą, todėl ateityje šie duomenys turės būti agreguojami.

sessionId	kwhTotal	weekday	created	ended	startTime	endTime	chargeTimeHrs
1366563	7.78	Tue	0014-11-18 15:40:26	0014-11-18 17:11:04	15	17	1.510555556
3075723	9.74	Wed	0014-11-19 17:40:26	0014-11-19 19:51:04	17	19	2.177222222
4228788	6.76	Fri	0014-11-21 12:05:46	0014-11-21 16:46:04	12	16	4.671666667
3173284	6.17	Wed	0014-12-03 19:16:12	0014-12-03 21:02:18	19	21	1.768333333
3266500	0.93	Thu	0014-12-11 20:56:11	0014-12-11 21:14:06	20	21	0.298611111
4099366	2.14	Fri	0014-12-12 14:38:44	0014-12-12 15:04:04	14	15	0.422222222
5084244	0.3	Fri	0014-12-12 15:08:40	0014-12-12 15:47:04	15	15	0.64
2948436	1.82	Wed	0014-12-17 20:30:25	0014-12-17 21:31:04	20	21	1.010833333
3515913	0.81	Thu	0014-12-18 17:53:19	0014-12-18 18:04:04	17	18	0.179166667
8490014	1.98	Thu	0014-12-18 18:06:49	0014-12-18 18:30:05	18	18	0.387777778
7075912	4.56	Thu	0014-12-18 18:31:54	0014-12-18 20:57:04	18	20	2.419444444
5226095	2.05	Fri	0014-12-19 14:30:37	0014-12-19 15:12:04	14	15	0.690833333
9342496	5.3	Wed	0015-01-07 17:52:53	0015-01-07 20:54:03	17	20	3.019444444

Šaltinis: Kaggle

17 pav. Elektromobilių krovimo stotelių duomenys

Aktualių Lietuvos rinkai duomenų, susijusių su elektros ateities sandoriais, nepavyko rasti. Todėl šiuos duomenis teko generuoti. Duomenų generavimui padėjo generatyvinis dirbtinis intelektas ChatGPT. Buvo pateiktos elektros kainos ir išvesčiai gauti paprašyta, jog atitinkamai sugeneruotų ateities sandorių kainas. Peržvelgus sugeneruotus duomenis, buvo priimtas sprendimas, jog duomenys atitinka keliamus reikalavimus: ateities sandorių kainos svyravo įvairiai – kartais jos buvo mažesnės, kartais didesnės už tos dienos kainas.

Date	Future_Price
2022-01-03	89.545301983226
2022-01-04	159.50970346278
2022-01-05	128.33034740475
2022-01-06	175.944506972671
2022-01-07	154.896428130239
2022-01-10	231.598479430563
2022-01-11	223.245819156774
2022-01-12	225.089624610675
2022-01-13	156.767466540892
2022-01-14	103.901047927031

Šaltinis: autorius

18 pav. Sugeneruotų elektros ateities sandorių kainų pavyzdys

2.4. Programinės įrangos analizė

Prototipo kūrimui buvo pasirinkta Python programavimo kalba. Tačiau prieš pradedant kurti prototipą buvo atlikta palyginamoji analizė su kitais rinkoje egzistuojančiais sprendimais. Remiantis Ceyhun Ozgur, Taylor Colliu ir kitų (2017) bei Zulie Rane (2021) autorių įžvalgomis sudaryta 6 lentelė, kurioje yra palyginamos skirtingos programavimo kalbos.

6 lentelė

Python, MATLAB ir R kalbų palyginimas

Funkcionalumas	Python	MATLAB	R
Duomenų analizė	Turi pranašias bibliotekas tokias kaip Pandas ar NumPy. Gerai susitvarko su dideliais duomenų kiekiais	Tinkamas moksliniams skaičiavimams, tačiau ribtos galimybės su duomenų apdorojimu	Tinkamas statistinei analizei
Mašininis mokymasis	scikit-learn ir kitos bibliotekos leidžia lengvai kurti ir testuoti modelius	Tinkamas, tačiau gali reikalauti papildomų licencijų	Turi tam skirtas bibliotekas, tačiau jos yra mažiau lanksčios
Vizualizacija	Matplotlib ir kitos bibliotekos leidžia lanksčiai ir patogiai atvaizduoti įvairias vizualizacijas	Gerai vizualizuoja, tačiau ribotas funkcionalumas	Geros galimybės naudojant ggplot2
Greitis	Veikia greitai su optimizuotomis bibliotekomis	Greiti lygiagretūs skaičiavimai	Veikia greitai, tačiau gali sulėtėti, esant dideliame duomenų kiekiui
API užklausos	Lengva integruoti su papildomomis bibliotekomis	Reikalauja papildomų įrankių	Įmanoma integracija, tačiau yra labiau komplikauta

Šaltinis: sudaryta autoriaus

Įvertinus šiuos kriterijus, daroma išvada, jog kuriamo prototipo keliamus reikalavimus geriausiai išpildo Python programavimo kalba, kadangi platus bibliotekų pasirinkimas leidžia patogiai ir greitai apdoroti duomenis ir atlikti reikiamus skaičiavimus. Šios programavimo kalbos lankstumas leidžia duomenis pasiekti įvairiuose duomenų šaltiniuose ir jais lengvai manipuliuoti, o aktyvi bendruomenė ir gera dokumentacija palengvina darbą ir klaidų taisymą.

2.5. Prototipo atliekami skaičiavimai

Nors ir turimi duomenys yra surinkti iš įvairių šaltinių ir agreguojami, tačiau reikalinga atlikti ir papildomus skaičiavimus, norint pilnavertiškai juos panaudoti ir pritaikyti prognozėse.

Dirvos drėgmei skaičiuoti yra naudojamos dvi formulės. Pirmą iš jų yra Penman-Monteith formulė (Richard G. Allen, Luis S. Pereira ir kiti, 1998), kuri skaičiuoja potencialų drėgmės garavimą iš dirvos. Šioje formulėje naudojama temperatūra, prie kurios yra pridedama konstanta, kuri pakeičia temperatūros mastelį ir leidžia generuoti realesnius garavimo rezultatus. Ši reikšmė yra sudauginama su garavimo koeficientu, kuris yra 0.0023 ir su saulės radiacijos bei vėjo greičio suma.

```
def calculate_pet(temperature, wind_speed, solar_radiation):  
    return PET_COEFFICIENT * (temperature + 17.8) * (solar_radiation + wind_speed)
```

Šaltinis: sudaryta autoriaus

19 pav. Drėgmės garavimo formulė

Vėliau gautas drėgmės dydis yra pateikiamas funkcijai, kuri skaičiuoja dirvos drėgmę pagal turimus parametrus. Reikalinga pateikti prieš tai buvusią drėgmę, iš jos atimti išgaravusią drėgmę ir pridėti kritulių kiekį.

```
def calculate_humidity(previous_humidity, precipitation, pet):  
    soil_moisture = previous_humidity - pet + precipitation  
    return max(WILTING_POINT_PERCENT, min(FIELD_CAPACITY_PERCENT, soil_moisture))
```

Šaltinis: sudaryta autoriaus

20 pav. Drėgmės skaičiavimo formulė

Ir tokiu būdu galima sudaryti laistymo tvarkaraštį. Šiuo atveju skaičiavimai buvo atliekami daržovėms, kurių šaknys yra 3 centimetrų gylyje ir reikalingas drėgmės kiekis yra 50%, o laistomas plotas yra 10 hektarų. Taip pat buvo atlikta vandens litrų konversija į kritulių milimetrus ir gautas rezultatas, jog 10 tūkstančių litrų vandens 1 hektaro plote pakelia drėgmę 1 mm gylyje. Turimas laistymo tvarkaraštis padeda atlikti prognozes, kurios nustato reikiamo vandens kiekį laukų laistymui ir taip pat padeda įvertinti modelio tikslumą po atliktų prognozių.

Date	Soil_Moisture	Irrigation_Need_Liters	Evaporation_PE
2022-05-27	50.9170026232639	0	5.2063375
2022-05-28	50	201973.20121528	2.936734635
2022-05-29	55.5573661875	0	6.342633813
2022-05-30	50.8082663472222	0	6.24909984
2022-05-31	56.8044727847222	0	4.603793563
2022-06-01	51.1893608958333	0	5.915111889
2022-06-02	50	53904.0822916668	2.228401719
2022-06-03	50	658891.56388889	6.588915639
2022-06-04	50	183852.956076389	3.038529561
2022-06-05	50	328017.722222221	7.280177222
2022-06-06	67.3221229305556	0	7.377877069

Šaltinis: sudaryta autoriaus

21 pav. Laistymo tvarkaraščio duomenų pavyzdys

Taip pat kiekvienam modeliui reikia pateikti apdorotus parametrus, kurie yra naudojami tikslesniam prognozavimui.

Parametrų skaičiavimai elektros prognozavimo modelyje:

1. Atsiliekančiosios elektros kainos: atidėtos elektros kainos rodo faktines praityje užfiksuotas kainas ir padeda atpažinti tendencijas.
2. Saulės sugeneruotas energijos slenkantis vidurkis: skaičiuojamas tarp 7 ir 14 praities dienų ir perskaičiuojama kiekvieną dieną, skirtas sušvelninti saulės energijos gamybos svyravimus ir pamatyti įtaką elektros kainoms.
3. Anglies kainų slenkantis vidurkis: skaičiuojamas tarp 7 ir 14 praities dienų ir skirtas užfiksuoti mažesnes anglies kainų tendencijas, kurios paveikia elektros kainas.
4. Vėjo greičio slenkantis vidurkis: 7 dienų vėjo vidutinis greitis, padeda sušvelninti trumpalaikius vėjo svyravimus ir pastebėti vėjo įtaką elektros kainoms.

Parametrų skaičiavimai elektros sąnaudų prognozavimui elektromobilių krovimo stotelėse:

1. Atsiliekantis elektros suvartojimas: 7 ir 14 dienų atidėjimas suvartotos energijos padeda pastebėti savaitines tendencijas
2. Slenkantieji elektros suvartojimo vidurkiai: sušvelnina trumpalaikius suvartojimo svyravimus ir padeda atspindėti bendrą tendenciją.
3. Savaitės diena: savaitės diena yra užkoduoata reikšme nuo 1 iki 7. Savaitės diena gali padėti pastebėti pasikartojančius elektros suvartojimus tam tikromis dienomis.

Elektromobilių stotelių tinklo ateities sandorių sudarymams taip pat atliekami šie parametru skaičiavimai:

1. Kainų santykis: gaunamas, padalinus ateities sandorio kainą iš prognozuojamos kainos. Tokiu būdu galima įvertinti, ar sandoris būtų ekonomiškai naudingas.
2. 7 dienų vidutinės elektros sąnaudos: leidžia įvertinti ar prognozuojamos sąnaudos yra reikšmingos ir ar nėra rizikinga sudaryti ateities sandorį.

Laistymo sistemos laistymo tvarkaraščio sudarymo parametru skaičiavimai:

1. Dirvos drėgmė: skaičiuojama pagal dirvos drėgmės formulę, naudojant aplinkos lietaus, vėjo ir saulės kintamuosius. O modelyje naudojamas atsiliekančysis 7 dienų parametras, skirtas stebėti dirvos drėgmės kitimo priežastis.
2. Garavimo koeficientas: skaičiuojamas, naudojant orų prognozes ir naudojamas modelyje prognozuoti dirvos drėgmei.
3. Vidutinis laistymo poreikis: skaičiuojamas 7-14 praeities dienų periode. Sekama, kaip buvo laistoma dirva ir kaip tai paveikė jos drėgmę.

Laistymo sistemų ateities sandorių sudarymams atliekami šie parametru skaičiavimai:

1. Prognozuojamas vandens kiekis: jis gaunamas naudojant prieš tai apmokytą mašininio mokymosi modelį ir prognozuoja vandens poreikį litrais.
2. Kainų santykis: skaičiuojamas elektros ateities sandorio kainą padalinus iš prognozuojamos kainos, taip įvertinama, ar sandoris yra ekonomiškai naudingas. Kuo didesnis santykis, tuo tikėtiniau sudaryti ateities sandorį.
3. 7 dienų vidutinis laistymo poreikis: skaičiuojamas 7 laistymo vidurkis litrais ir tai leidžia įvertinti, ar dabartinis laistymo poreikis yra reikšmingas.

Taip pat naudinga formulė, kuri paverčia suvartojamo vandens kiekį litrais į suvartojamos elektros energijos kiekį kilovatvalandėmis. Tai padeda skaičiuoti bendrus elektros energijos kaštus. Pirmiausia suskaičiuojamas energijos kiekis džauliais ir vėliau jis paverčiamas į kilovatvalandes.

```
def calculate_energy_kwh(liters, pump_efficiency=0.8):  
    g = 9.81  
    density = 1000  
    energy_joules = liters * density * g / pump_efficiency  
    energy_kwh = energy_joules / (3.6 * 10**6)  
    return energy_kwh
```

Šaltinis: sudaryta autoriaus.

3. ELEKTROS KAŠTŲ OPTIMIZAVIMO PROTOTIPO ANALIZĖ

Trečiojoje darbo dalyje pateikiamas sukurto prototipo vertinimas, atskleidžiant jo veiksmingumą ir potencialią naudą realiomis sąlygomis. Analizuojamas duomenų apdorojimas, mašininio mokymosi modelių treniravimas bei jų pritaikymo rezultatai. Aptariami naudoti duomenys ir kaip jie daro įtaką gautiems rezultatams.

Atlikti testai ir simuliacijos parodo, kaip tinkamai parinkti duomenys bei mašininio mokymosi algoritmai padeda sutaupyti ir sumažinti elektros energijos kaštus laistymo sistemose bei elektromobilių krovimo stotelių tinkluose. Šios išvados sukuria pagrindą tolimesniam metodo tobulinimui ir potencialiam jo pritaikymui realiose situacijose.

3.1. Duomenų apdorojimas

Ne visi surinkti duomenys, kurie yra iš įvairių šaltinių, yra iš karto tinkami mašininio mokymosi modeliams apmokyti, todėl juos reikia apdoroti ir paruošti mašininio mokymosi modeliams.

Orų prognozės duomenų gavimui iš Meteo API teko parašyti mažą Python programą, kuri parsisiųstų duomenis ir juos įrašytų į failą. Šis API turi ribojimą, kadangi istorinius duomenis galima gauti tik vienos dienos ir per minutę galima atlikti iki 180 užklausų.

23 pav. yra pavaizduojama kodo iškarpa, kuriame aprašytas ciklas. Šiame cikle yra pereinama per visas periodo dienas ir, atlikus užklausą, būtų palaukiama apie pusę sekundės tam, kad Meteo API neužblokuotų dėl per didelio užklausų kiekio. Iš Meteo API gaunami duomenys apie oro temperatūrą, kritulius ir vėjo greitį.

Po kiekvienos užklauso, jei visi gauti duomenys yra geri, jie yra išvedami į failą. Vėliau tie duomenys yra naudojami mašininio mokymosi algoritmo apmokymui.


```

start_date = datetime(2023, 1, 1)
end_date = datetime(2023, 12, 31)
current_date = start_date
url_template = "https://api.meteo.lt/v1/stations/kauno-ams/observations/{date}"

while current_date <= end_date:
    date_str = current_date.strftime('%Y-%m-%d')
    url = url_template.format(date=date_str)

    response = requests.get(url)
    if response.status_code == 200:
        data = response.json()

        for observation in data.get("observations", []):
            air_temperature = observation.get("airTemperature")
            precipitation = observation.get("precipitation")
            windSpeed = observation.get("windSpeed")

            with open(output_file, mode='a', newline='') as file:
                writer = csv.writer(file)
                writer.writerow([
                    air_temperature, precipitation, windSpeed
                ])

    else:
        print("Failed to get data")
        time.sleep(0.4)

    current_date += timedelta(days=1)

print(f"Data has been saved to {output_file}")

```

Šaltinis: sudaryta autoriaus

23 pav. Kodo ištrauka orų prognozės duomenų išgavimui

Iš Meteo API yra gaunami 24 įrašai parai, t. y. po vieną įrašą kiekvienai valandai. Modelio apmokymui šiuos įrašus reikia suagreguoti į vieną, jog būtų vienas bendras įrašas vienai parai. Oro temperatūros ir vėjo greičio parametrams yra išvedamas vidurkis, o visas dienos kritulių kiekis yra sudedamas.

Elektros kainoms išgauti teko pasinaudoti Python biblioteka nordpool. Kadangi duomenis parsisiųsti iš Nordpool puslapio yra komplikuoja, ši biblioteka puikiai padėjo juos gauti. Reikia tik nurodyti datą ir vietą, kuriai norime gauti duomenis. Kodas pavaizduotas 24 paveikslėlyje parsienčia kainas iš Nordpool duomenų bazės ir jas išsaugo į kintamąjį. Vėliau naudojant ciklą yra pereinama per Lietuvos elektros kainas ir filtruojama pagal datą. Išfiltruoti duomenys yra išrikiuojami pagal datą didėjimo tvarka ir įrašomi į .csv formato failą.

```

from nordpool import elspot
from pprint import pprint
from datetime import datetime
import csv

prices_spot = elspot.Prices()

end_date = datetime(2022, 1, 1)

prices = prices_spot.daily(areas=['LT'], end_date=end_date)

prices_2022 = []

for price_info in prices['areas']['LT']['values']:
    start_date = price_info['start']
    price_value = price_info['value']

    if start_date.year == 2022:
        prices_2022.append((start_date.date(), price_value))

prices_2022.sort(key=lambda x: x[0])

csv_file_path = 'elspot_prices_2022.csv'

with open(csv_file_path, mode='w', newline='') as file:
    writer = csv.writer(file)
    writer.writerow(['Date', 'Price'])
    writer.writerows(prices_2022)

print("Finished")

```

Šaltinis: sudaryta autoriaus

24 pav. Elektros kainų iš Nordpool parsisiuntimo algoritmas

3.2. Mašininio mokymosi modelių treniravimas

Mašininio mokymosi modelius reikia apmokyti su mokymui paruoštais duomenimis ir vėliau juos ištestuoti su testavimo aibės duomenis. Šiam tikslui pasiekti kiekvienai sričiai reikalinga paruošti mokymo bei testavimo duomenis. Su mokymo duomenis apmokyti mašininio mokymosi modelius ir juos ištestuoti. Skirtingi mašininio mokymosi modeliai su skirtingais duomenimis ar skirtingomis duomenų struktūromis gali grąžinti skirtingus rezultatus. Toliau yra aprašoma, kaip vyko modelių treniravimas bei yra palyginami skirtingų modelių rezultatai, kurie buvo gauti su tais pačiais duomenimis.

3.2.1. Elektros kainų prognozavimas

Norint tinkamai optimizuoti elektros kaštus, visų pirma reikia kuo tiksliau prognozuoti ateities elektros kainas tam, kad įvykdyti ateities sandoriai padėtų sutaupyti kaštų.

Elektros prognozavimo modelio apmokymui ir optimizavimui naudojamas GridSearchCV metodas, kuris išbando visas pateiktas parametrų kombinacijas ir naudoja kryžminę validaciją modelio tikslumo vertinimui. Tokiu būdu išbandomi skirtingi mašininio mokymosi modeliai ir parenkamas tas, kuris atlieka prognozes tiksliausiai.

Prieš mokymąsi duomenys buvo suskirstyti į mokymo ir testavimo aibes, kur mokymosi aibės duomenys naudojami apmokyti modelį, o testavimo duomenys įvertinti rezultatus. Apmokymui naudojamos istorinės elektros ir anglies kainos, saulės sugeneruojama elektros energija, orų prognozės, savaitės dienos.

7 lentelė


Elektros kainų prognozavimo mašininio mokymosi modelių rezultatų palyginimas

Modelis	Geriausi parametrai	MAE	RMSE	R ²	Aprašymas
Random Forest	{'max_depth': 10, 'max_features': 'sqrt', 'min_samples_split': 5}	18.58	22.82	0.3762	Didžiausia vidutinė absoliutinė paklaida ir mažiausias R ²
Gradient Boosting	{'learning_rate': 0.05, 'max_depth': 3, 'n_estimators': 50}	16.07	18.90	0.57	Mažiausia vidutinė absoliutinė paklaida ir didžiausias R ²
Ridge	{'alpha': 1.0}	17.71	21.33	0.45	Vidutiniai rezultatai.

Šaltinis: sudarytas autoriaus

Geriausias rezultatas buvo pasiektas su Gradient Boosting modeliu. Gauta mažiausia vidutinė paklaida, reiškianti, jog prognozuojamos reikšmės yra arčiausiai tikrosios. Šakninė vidutinio kvadrato paklaida taip pat yra mažiausia. Ji rodo mažesnį nukrypimo dydį, nei kitų modelių. O didžiausias R² reiškia, kad modelis geriausiai paaiškina savo duomenų variaciją. Kryžminės validacijos rezultatas buvo gautas 49.69. Tai yra didesnė reikšmė, nei MAE rezultatas, gautas testavimo metu. Tai gali atsitikti dėl duomenų imties ir sudėtingesnio validacijos proceso. Nepaisant to Gradient Boosting pakankamai gerai atliko prognozę ir pasiekė geriausią rezultatą, lyginant su kitais modeliais.


25 pav. galima matyti kaip modelis prognozuoja elektros kainas ateinančiai savaitei. Mėlyna linija vaizduoja realias kainas, buvusias tame laikotarpyje, o oranžinė – prognozuotas modelio kainas. Modelis, nors ir nelabai tiksliai, tačiau sugeba numatyti bendras kainų tendencijas – kilimą ir kritimą. Ketvirtą dieną sugebėjo užfiksuoti staigų kainų šuolį, tačiau septintą dieną jau suklydo nustatydamas, jog kaina toliau nebekils.



Šaltinis: sudaryta autoriaus

25 pav. Pavyzdinis elektros prognozės grafikas

26 pav. matomi parametrų reikšmingumai elektros kainos prognozavimui. Svarbiausias yra vėjo greitis. Šis parametras yra tiesiogiai susijęs su vėjo sugeneruojama energija, didėjantis vėjo greitis didina atsinaujinančios energijos gamybą, taip didindamas energijos pasiūlą ir mažindamas elektros kainą. Savaitės diena taip pat labai svarbi elektros kainos prognozavimui, taip yra dėl to, jog elektros kainos darbo dienomis ir savaitgaliais yra skirtingos. Apie 15 % svarbos sudaro anglies kainos, kadangi brangstant anglims, brangsta ir elektra, kuri yra iš iškastinio kuro šaltinių. Temperatūra taip pat daro didelę įtaką elektros kainai, kadangi kintanti temperatūra gali paveikti elektros paklausą. Vidutinę reikšmę rezultatams turi istorinės elektros kainos ir atsiliekanieji rodikliai, tai parodo, jog elektros kaina nėra visiškai priklausoma nuo istorinių kainų, o didelę įtaką daro dabartiniai veiksniai. Debisuotumo reikšmė maža, tačiau jis gali paveikti energijos, gaunamos iš saulės, gamybą.



Šaltinis: sudaryta autoriaus

26 pav. Elektros kainų prognozavimo parametrų reikšmingumas

3.2.2. Ateities sandorių pritaikymas elektromobilių krovimo stotelėse

Norint prognozuoti elektros ateities sandorių sudarymą, reikalinga taip pat nustatyti elektros kiekį, kuris bus reikalingas būtent tam laikotarpiui elektromobilių krovimo stotelėse. Šiuo atveju prognozės yra atliekamos kiekvienai dienai atskirai, prognozuojant, kiek tą dieną bus suvartota elektros. Duomenų rinkinys nėra platus ir nėra paminėta duomenų rinkimo vieta, todėl šiuo atveju prognozėms naudojamos tik datos ir istoriniai elektros suvartojimo duomenys.

Prieš parenkant tinkamiausią mašininio mokymosi algoritmą, reikia palyginti kelis variantus ir išrinkti tą, kuris pateikia geriausius rezultatus.


**Elektromobilių krovimo stotelių apkrovos prognozavimo mašininio mokymosi modelių
rezultatų palyginimas**

Modelis	Geriausi parametrai	MAE	RMSE	R ²	Aprašymas
Random Forest	{'max_depth': 10, 'min_samples_leaf': 5, 'min_samples_split': 10, 'n_estimators': 50}	52.31	62.63	0.54	Vidutinio dydžio vidutinė absoliutinė paklaida ir mažiausias R ² , tinkamas tik, jei reikalingas greitas bazinis modelis.
Gradient Boosting	{'learning_rate': 0.05, 'max_depth': 3, 'n_estimators': 100}	31.36	33.84	0.86	Mažiausia vidutinė absoliutinė paklaida ir didžiausias R ² , tinkamas tiksloms prognozėms, bet reikalauja daugiau laiko.
Ridge	{'alpha': 0.01}	60.66	79.34	0.25	Gauti blogiausi rezultatai, greitas modelis, tačiau netinka sudėtingiems duomenims ar nenuoseklioms tendencijoms.
SVR	{'C': 1, 'gamma': 'scale', 'kernel': 'linear'}	55.47	70.76	0.4	Prastesni rezultatai nei Gradient Boosting, bet gali būti naudingas nedideliame duomenų rinkiniui.

Šaltinis: sudaryta autoriaus

Gradient boosting modelis pasirodė geriausiai tarp visų kitų analizuotų modelių, tačiau skaičiavimo laikas buvo didžiausias. Pasiekė mažiausią vidutinę absoliutinę paklaidą (MAE) - 31.36 bei didžiausią determinacijos koeficientą (R²). Šis modelis tiksliausiai prognozuoja elektros suvartojimo tendencijas ir sugeba paaiškinti didžiausią kiekį savo priimtų sprendimų. Kryžminės validacijos vidutinė absoliutinė paklaida buvo gauta 32.38, tai parodo, jog modelis sugeba išlaikyti stabilumą ir tikslumą skirtingose duomenų imtyse.


Random Forest ar SVR modeliai galėtų būti naudojami, jeigu reikėtų skaičiavimus atlikti greičiau arba duomenų struktūra ir/arba aibė būtų tinkamesnė šiems modeliams. Sutrumpinus skaičiavimo laiką, gaunama didesnė vidutinė absoliutinė paklaida, o determinacijos koeficientas sumažėja apie du kartus.



Šaltinis: sudaryta autoriaus

27 pav. Krovimo stotelių elektros suvartojimo prognozavimas

27 pav. matyti tikras ir prognozuojamas elektros suvartojimas. Modelis pakankamai gerai numato didesnius elektros suvartojimo svyravimus, tačiau nepastebi mažų pasikeitimų. Akivaizdu, jog birželio 20 dienos staigų pokytį pastebėjo ir į jį sureagavo, tačiau į prieš tai buvusius mažesnius – ne. Turint daugiau duomenų, pavyzdžiui, oro sąlygos (temperatūra, drėgnumas), būtų galima tiksliau prognozuoti elektros suvartojimą, tačiau nėra žinoma šių duomenų vietovė, todėl reikia pasikliauti tik laiko ir istoriniais suvartojimo duomenimis.



Šaltinis: sudaryta autoriaus

28 pav. Krovimo stotelių elektros suvartojimo prognozavimo parametrų reikšmės

28 pav. pateikiami parametų svarbumai, kurie skirti prognozuoti suvartojamą elektros kiekį. Savaitės diena turi didžiausią įtaką, kas reiškia, jog žmonės krauti savo elektromobilius yra linkę tam tikromis dienomis. Automobiliai yra kraunami dažniau darbo dienomis, nei savaitgaliais. Na ir likusią svarbą sudaro elektros suvartojimo atsiliekantieji parametrai. Iš jų svarbiausias yra 7 dienų atsiliekantysis parametras, kuris atspindi suvartojimo dėsningumą ir tendencijas, jis naudingas prognozuojant savaitinius duomenis. Vidurkis, suma ir standartinis nuokrypis modeliui suteikia ilgalaikių tendencijų informaciją ir leidžia aptikti bendrus energijos naudojimo pokyčius.

Paskutinis modelis, reikalingas ateities sandorių sudarymui, yra tas, kuris įvertina visus prognozuojamus veiksnius ir nusprendžia, ar apsimoka sudaryti ateities sandorį. Kaip ir visiems modeliams, šiam irgi buvo atliekama analizė, vertinant skirtingų modelių tikslumą.

9 lentelė


Elektros ateities sandorių elektromobilių krovimo stotelėms modelių palyginimas

Modelis	Geriausi parametrai	Tikslumas(CV)	Testavimo tikslumas	Aprašymas
Random Forest	{'max_depth': 5, 'min_samples_leaf': 10, 'min_samples_split': 10, 'n_estimators': 50}	0.65	0.62	Modelis gerai tvarkosi su sudėtingomis duomenų struktūromis ir tinkamai prioretizuoja jose esančius duomenis, tačiau šiuo atveju pasirodė blogiausiai
Gradient Boosting	{'learning_rate': 0.01, 'max_depth': 3, 'n_estimators': 50}	0.84	0.83	Gera subalansuotas tikslumas, gerai tvarkosi su sudėtingomis funkcijomis, nedaug atsiliko nuo Logistic Regression
Logistic Regression	{'C': 0.1, 'solver': 'liblinear'}	0.87	0.87	Greitas ir tiksliausiai prognozavo ateities sandorių sudarymą
SVC	{'C': 0.1, 'gamma': 'scale', 'kernel': 'linear'}	0.84	0.81	Gera pasirodė, nedaug atsiliko nuo LogisticRegression. Kainuoja daugiau resursų

Šaltinis: sudaryta autoriaus

Geriausiai pasirodė Logistic Regression modelis. Todėl tolimesniam ateities kontraktų nustatymui buvo pasirinktas būtent jis. 29 pav. matome parametų svarbą ateities sandorio sudaryme. Didžiausią įtaką sudarymui turi elektros kainos. Kai yra didelė elektros kaina, ateities sandorio sudarymas tampa tikėtinesnis. Ir taip didelį neigiamą poveikį turi ateities sandorių kaina, tai reiškia, kuo sandorio kaina yra mažesnė, tuo yra tikėtiniau pasirinkti sudaryti ateities sandorį. Bendras suvartojamas elektros kiekis taip pat padidina ateities sandorio sudarymą, kadangi prognozuojama, jog reikės daug elektros ir tam reikia palankių kainų. Mažiau, bet vis tik daro įtaką ir kainų santykiai,

santykis tarp būsimų kaštų ir prognozuojamų kaštų leidžia modeliui nustatyti rizikos lygį. Istorinis elektros suvartojimas daro neigiamą įtaką ateities sandorio sudarymui, jeigu dabartinis elektros suvartojimas yra mažesnis už 7 dienų vidurkį, tikimybė priimti sprendimą sumažėja, tai atspindi mažesnę poreikio riziką.



Šaltinis: sudaryta autoriaus

29 pav. Krovimo stotelių elektros ateities sandorių sudarymo parametrų reikšmės

Kuomet visi modeliai yra apmokyti: elektros kainų prognozavimo, krovimų stotelių suvartojamo elektros kiekio prognozavimo ir ateities sandorių sudarymu, galima atlikti simuliaciją ir pamatyti kaip šie visi trys modeliai sąveikauja ir ar pavyksta sutaupyti.


10 lentelėje pavaizduoti elektros suvartojimo simuliacijos rezultatai birželio mėnesį. Elektros ateities sandorių naudojimas šiomis sąlygomis padėjo sutaupyti 2.18 %. Prognozuojamam elektros kiekio suvartojimui buvo sudarytas ateities sandoris, kuris užfiksuoja kainą 80 % kiekio. 20 % buvo palikta paklaidai, kadangi modeliai neprognozuoja 100 % teisingai ir kad nebūtų nupirkta per didelis elektros kiekis.

Elektromobilių krovimo stotelių elektros suvartojimo simuliacijos rezultatai

Elektros kaštai be ateities sandorių	480.42 eurai
Elektros kaštai naudojant ateities sandorius	469.97 eurai
Sutaupyta	10.45 eurai (2.18%)

Šaltinis: sudaryta autoriaus

30 pav. pavaizduoti kasdieniai sutaupymai ir nuostoliai, kuomet buvo sudaryti ateities sandoriai. Nuostoliai gali būti patiriami tuomet, kai yra sudaromas ateities sandoris per dideliu kiekiui elektros arba kuomet ateities sandorio kaina būna aukštesnė nei dienos kaina. Daugeliu atvejų pavyko tinkamai atlikti prognozes ir sutaupyti, nors ir nedidelėmis sumomis. Didžiausias nuostolis patirtas birželio 6 dieną.



Šaltinis: sudaryta autoriaus

30 pav. Krovimo stotelių elektros ateities sandorių sutaupymo/nuostolių kasdieninis palyginimas

3.2.3. Ateities sandorių pritaikymas laistymo sistemose

Elektros kaštų optimizacijai laistymo sistemose visų pirmą reikalinga tinkamai prognozuoti elektros kainas. Šioje vietoje bus panaudotas tas pats modelis, kaip ir elektromobilių krovimų stotelių atveju. Taip pat svarbu išsiaiškinti reikiamą elektros kiekį. Laistymo sistemų atveju bus prognozuojamas reikiamo vandens kiekis ir vėliau šis kiekis bus konvertuojamas į elektros kiekį, kadangi laistymo sistemos siurbliams reikės tą vandenį išskirstyti po visą laistomą lauką.

Pasirinkti geriausiai tinkamą mašininio mokymosi modelį reikia atlikti palyginimą tarp skirtingų modelių ir kaip jie prognozuoja suvartojamo vandens kiekį.


11 lentelė

Vandens poreikio prognozavimo laistymo sistemoje mašininio mokymosi modelių palyginimas

Modelis	Geriausi parametrai	MAE	RMSE	R ²	Aprašymas
Random Forest	{ 'max_depth': 10, 'max_features': 'sqrt', 'min_samples_split': 10, 'min_samples_leaf': 5, 'n_estimators': 50 }	145869	183856	0.58	Gera susidoroja su nestruktūrizuotais duomenimis, tačiau tikslumas gautas mažesnis nei Gradient Boosting
Gradient Boosting	{ 'learning_rate': 0.1, 'max_depth': 3, 'n_estimators': 100 }	908645	110473	0.85	Tiksliausias modelis, tinkamas prognozėms, bet reikia tinkamai parinkti parametrus
Ridge	{ 'alpha': 10.0 }	108146	138781	0.76	Paprastas ir greitas modelis, bet blogai susitvarko su kompleksiniais duomenimis

Šaltinis: sudaryta autoriaus

Gradient Boosting buvo pasirinktas kaip tinkamiausias laistymo prognozavimo modelis. Šis modelis pasiekė mažiausią vidutinę absoliutinę paklaidą, bet didžiausią R², tai reiškia, jog jis taip pat geriausiai ir paaiškina savo atliktus sprendimus, užtikrindamas prognozių pagrįstumą. Kryžminės validacijos metu gauta MAE reikšmė - 81690, dar kartą parodo, kad modelis sugeba gerai generalizuoti ir nėra pertreniruotas. Šie rezultatai leidžia teigti, kad šiuo atveju Gradient Boosting yra tinkamiausias šioje situacijoje.




Šaltinis: sudaryta autoriaus

31 pav. Laistymo poreikio litrais prognozė

31 pav. pavaizduotas grafikas atspindi, kad modelis geba tinkamai prognozuoti laistymo poreikio dinamiką ir atspindi bendrą vandens poreikio didėjimo bei mažėjimo tendenciją. Modelis gana tiksliai prognozuoja visas žemumas, kuomet laistymo poreikis sumažėja, o aukštumas atpažįsta, tačiau ne visada tiksliai jas atvaizduoja. Taip pat galima pastebėti, jog modelio tikslumas sumažėja, kuomet prognozuojama ilgesniam laikotarpiui, šeštos ir septintos dienų prognozės nėra labai tikslios, nors galima pastebėti atitinkamą tendenciją, kada laistymo poreikis didėja ar mažėja.

Šio modelio paklaida buvo apie 90 tūkstančių litrų, tačiau didesnės paklaidos atsiranda prognozuojant didesnę laikotarpį į ateitį. Tai nėra labai didelė paklaida, kai palyginama su bendru laistymo kiekiu, nes kai kuriomis dienomis laistymui yra reikalinga virš 600 tūkstančių litrų vandens. Jeigu prognozuojamas vandens suvartojimo kiekis yra per didelis, jis ne visada yra perteklinis, nes šį vandenį galima vis tiek išnaudoti, taip padidinant dirvos drėgmę. Tokiu atveju gali būti sumažinamas laistymo poreikis kitomis dienomis.



Šaltinis: sudaryta autoriaus

32 pav. Parametrų svarba vandens poreikio prognozavimui laistymo sistemoje

Parametrų svarbos analizė parodo, kurie kintamieji labiausiai prisideda prie vandens poreikio prognozės tikslumo. Iš pateikto grafiko 32 paveiksle matyti, kad reikšmingiausias parametras yra prognozuojami krituliai būtent tą dieną. Tai yra logiška, kadangi iškritę krituliai didina dirvos drėgmę ir taip mažina laistymo poreikį. Antroje vietoje yra garavimo koeficientas, kuris atspindi drėgmės praradimą dėl garavimo, todėl tai svarbu skaičiuojant dirvožemio drėgmę. Trečioje vietoje yra istorinė dirvožemio drėgmė, kuriai turi įtaką visi aplinkos veiksnių per tam tikrą laiką. Šie trys parametrai sudaro apie 80 % viso bendro parametrų svarbumo.

Vienas iš mažiau svarbių veiksnių yra temperatūra, tačiau ji buvo naudojama skaičiuojant garavimo koeficientą, kuris tapo svarbesniu veiksnium. Istoriniai laistymo kiekiai taip pat mažai turi įtakos, kadangi svarbu žinoti laistymo poreikį šiai dienai, o istoriniai duomenys tampa nelabai aktualūs.

12 lentelėje yra pavaizduotas palyginimas tarp mašininio mokymosi modelių, kai yra priimami sprendimai sudaryti elektros ateities sandorius. Lentelėje yra pateikiami kiekvieno modelio parametrai, su kuriais buvo gauti geriausi tikslumo rezultatai. Visų keturių modelių testavimo tikslumas skyrėsi labai nedaug. Bendras tikslumas yra apie 0.8.


**Elektros ateities sandorių sudarymo laistymo sistemose mašininio mokymosi modelių
palyginimas**

Modelis	Geriausi parametrai	Tikslumas (CV)	Testavimo tikslumas	Aprašymas
Random Forest	{'max_depth': 6, 'class_weight': 'balanced', 'n_estimators': 100}	0.93	0.83	Gautas geriausias balansas tarp tikslumo ir stabilumo su parametru svarba.
Gradient Boosting	{'learning_rate': 0.1, 'max_depth': 3, 'n_estimators': 100}	0.9	0.8	Gera subalansuotas, nedidelis skirtumas tarp Random Forest gautų rezultatų
Logistic Regression	{'C': 1.0, 'solver': 'lbfgs'}	0.89	0.8	Greitas ir gan tikslus, tačiau atsiliko nuo kitų modelių
SVC	{'C': 1.0, 'gamma': 'scale', 'kernel': 'rbf'}	0.88	0.81	Gera pasirodė, reikalauja šiek tiek daugiau resursų, bet gautas tikslumas mažesnis nei kitų

Šaltinis: sudaryta autoriaus

Geriausiai prognozuoti ateities sandorių sudarymą sekėsi Random Forest algoritmui. Buvo pasiektas aukštas tikslumas tiek testavimo, tiek treniravimo duomenų imtyse. Nors Random Forest buvo tiksliausiai, kiti modeliai atsiliko labai nedaug.

Šiam modeliui svarbiausias parametras buvo kainos santykis, kuris parodo santykį tarp prognozuotos ir faktinės ateities sandorio kainos. Šis parametras yra pagrindinis indikatorius, ar ateities sandorio sudarymas yra ekonomiškai naudingas. Taip pat svarbus parametras yra prognozuojamas laistymui sunaudoto vandens kiekis litrais. Kai laistymui suvartojamo vandens kiekis yra nedidelis, arba laistyti nereikia, ateities sandorio sudarymas tampa nereikšmingu. Poreikio įvertinimui galima naudoti vidutinės laistymo sąnaudas. Ateities sandorių ir elektros kainos leidžia palyginti kainas ir nuspręsti ateities sandorio naudą.



Šaltinis: sudaryta autoriaus

33 pav. Parametrų svarba elektros ateities sandorių sudarymui laistymo sistemose

Turint visus apmokytus mašininio mokymosi modelius, galime atlikti simuliaciją ir patikrinti, ar ateities sandorių panaudojimas suteikia finansinę naudą laistymo sistemose. 13 lentelėje yra pateikiamas elektros kaštų palyginimas, kai yra naudojama laistymo sistema be ateities sandorių sudarymo ir, kai laistymo sistemos elektros kaštams yra pritaikomi ateities sandoriai.


13 lentelė

Laistymo sistemos elektros kaštų palyginimas naudojant ateities sandorius

Elektros kaštai be ateities sandorių	9134.56 eurai
Elektros kaštai naudojant ateities sandorius	8332.66 eurai
Sutaupyta	801.90 eurai (8.78%)

Šaltinis: sudaryta autoriaus

Simuliacija buvo atliekama vasaros laikotarpiui nuo liepos 15 dienos iki rugpjūčio 31 dienos, kuomet reikalinga laistyti augalus. Kaip ir elektromobilių krovimo stotelių elektros sąnaudų prognozėje, ateities sandoriai buvo sudaromi 80 % kiekiui, paliekant vietos paklaidai. Elektros sandorių sudarymas leido sutaupyti net 8.78 % bendrų elektros kaštų.




Šaltinis: sudaryta autoriaus

34 pav. Laistymo sistemos elektros ateities sandorių sutaupymo/nuostolių kasdieninis palyginimas

34 pav. pavaizduoti kasdieniai sutaupymai ir nuostoliai laistymo sistemoje, kai buvo sudaromi ateities sandoriai. Nuostoliai, kaip ir elektromobilių krovimo stotelių atveju, gali būti patiriami tuomet, kai yra sudaromas ateities sandoris per dideliu kiekiui elektros arba kuomet ateities sandorio kaina būna aukštesnė nei dienos kaina. Daugeliu atveju pavyko tinkamai atlikti prognozes ir sutaupyti. Kai sandoriai buvo sudaryti gerai, kai kuriais atvejais jie leido sutaupyti netgi virš 600 eurų per dieną. Blogiausia prognozė buvo atlikta liepos mėnesį, kai nuostoliai siekė beveik 400 eurų, tačiau kiti tinkamai sudaryti sandoriai leido kompensuoti nuostolį ir galutiniam rezultate elektros ateities sandoriai atnešė didesnę pelną.

35 pav. matomas sudarytų elektros ateities sandorių kainų palyginimas su tos dienos kainomis. Grafike galima pastebėti, jog tik dviejose vietose modelis nepataikė mažesnės elektros ateities sandorio kainos. Tose vietose modelis atspėjo, jog kaina kils, tačiau buvo apskaičiuotas per staigus kainos kilimas. Kitose vietose elektros ateities sandoris buvo sudarytas su mažesne kaina nei buvo tą dieną reali elektros kaina. Tai reiškia, jog kiti nuostoliai, kurie yra matomi 34 paveiksle, buvo dėl to, jog modelis prognozavo per didelį reikalingos elektros kiekį ir pagal sudarytą sandorį elektros kiekis buvo neišnaudotas.



Šaltinis: sudaryta autoriaus

35 pav. Laistymo sistemos sudarytų elektros ateities sandorių kainų palyginimas su elektros dienos kainomis

3.3. Elektros ateities sandorių sudarymo rezultatų vertinimas

Atlikus sukurtų modelių analizę ir elektros kaštų optimizavimo prototipo testavimą, gauti rezultatai patvirtino tokio metodo veiksmingumą specifinėse srityse. Prototipas geba prognozuoti elektros kainas, numatyti elektros poreikio svyravimus ir tinkamai valdyti elektros ateities sandorių sudarymą tiek elektromobilių krovimo stotelių tinkluose, tiek laistymo sistemose, tokiu būdu mažindamas riziką dėl staigių elektros kainų svyravimų, tiek dėl nenumatyto didelio elektros kiekio poreikio.

Elektromobilių krovimo stotelių tinklų atveju kaštus pavyko sumažinti 2.18 %. Nors tai nedidelis pokytis, tačiau tai verslams gali suteikti pranašumą prieš konkurentus. Teorinės analizės metu įrodyta, kad klientų degalinės pasirinkimą lemia net ir labai nedidelis kainų skirtumas. Taigi šiuo atveju keli procentai gali lemti didesnę klientų srautą ir tuo pačiu pelną. Gautą rezultatą būtų galima dar pagerinti, jeigu būtų galima tyrimą atlikti su didesniu ir tikslesniu duomenų kiekiu. Šiuo atveju duomenys nebuvo priskirti jokiai vietai, todėl įvertinti srautą gana sudėtinga. Turint vietovės duomenis būtų galima analizuoti tiek aplinkos veiksnius tokius, kaip orų sąlygos, ar miesto

infrastruktūra. Šie veiksniai padėtų dar tiksliau prognozuoti klientų poelgių kilmę, kodėl būtent specifinėmis dienomis yra didesni ar mažesni krovimo srautai.

Laistymo sistemos elektros energijos kaštus pavyko sumažinti 8.78 %. Gautas geresnis rezultatas todėl, kad buvo galima modelius apmokyti platesniu duomenų kiekiu, kuriais remiantis buvo atliekamos elektros ateities sandorių prognozės. Kadangi duomenys ir laistymo tvarkaraščiai buvo simuliuojami ir prognozės grindžiamos tik atliktais skaičiavimais pagal teorines funkcijas, tad norint atlikti tikslesnį tyrimą, kuris galėtų būti pritaikytas realiomis sąlygomis, modelius reikėtų apmokyti tikrais laistymų sistemų duomenimis. Tokiu atveju būtų galima pamatyti šio modelio naudą pritaikytą tam tikrai žemės ūkio kultūrai ir ūkiui, kadangi gali skirtis tiek dirvos sudėtis, tiek pačios laistymo sistemos sudėtis.

Nepaisant tyrime atsiradusių kliūčių, gautas teigiamas rezultatas, kuris ateityje gali būti tobulinamas. Sukurtas prototipas pasižymi lankstumu, nes gali būti pritaikytas ir kitose srityse atliekant nedidelius pakeitimus. Pakeitus ir papildžius duomenų rinkinius ir juos pateikus mašininio mokymosi algoritmams, šį metodą būtų galima pritaikyti įvairaus dydžio verslams, kuriems yra aktualu numatyti elektros energijos sąnaudas.

IŠVADOS

1. Atlikus liberalizuotos elektros rinkos analizę, pastebėta, kad tai atveria naujas rinkos galimybes ir leidžia kurtis naujiems technologiniams sprendimams. Rinkos praplėtimas padidina konkurenciją tarp elektros tiekėjų, tokiu būdu gali sumažėti kainos ir padidėti paslaugų tiekiamą kokybę vartotojams. Tačiau rinkos liberalizacija vis dar yra vystymosi stadijoje ir norint šį procesą efektyviai išnaudoti, būtina plėtoti infrastruktūrą ir užtikrinti sklandžią tarpvalstybinę integraciją Europos Sąjungoje.
2. Atliktas tyrimas parodė, kad prižiūrimi mašininio mokymosi modeliai yra efektyviausi elektros kainų prognozavimui. Algoritmų tikslumas priklauso nuo surinktų duomenų kokybės ir išsamumo. Elektros kainas lemia tokie veiksniai, kaip orų sąlygos, paklausa bei pasiūla, atsinaujinančios energijos gamyba, dujų bei anglies kainos ir sezoniškumas. Elektros kainų prognozavimas yra kompleksinis dalykas, apimantis didelį kiekį kainas paveikiančių faktorių. Net ir įvertinus turimus istorinius duomenis, gali įvykti įvykių, kurių nepavyks prognozuoti, kaip pavyzdys yra Covid-19 virusas ar karas Ukrainoje, kurie privertė elektros kainas staigiai išaugti.
3. Elektros ateities sandoriai suteikia galimybę mažinti riziką dėl elektros kainų svyravimų ir padeda lengviau planuoti išlaidas. Liberalizuojama elektros rinka skatina naujų finansinių instrumentų pritaikymą. Toks ateities sandorių pritaikymas gali būti panaudotas rinkose, kur išlaidų planavimas gali padėti sumažinti kaštus. Elektromobilių krovimo stotelių tinkluose elektra sudaro didžiausią išlaidų dalį, todėl tinkamas klientų srautų nustatymas ir pigesnių elektros ateities sandorių sudarymas gali reikšti didesnę pelną ir pranašumą prieš konkurentus. O elektros ateities sandorių panaudojimas žemės ūkyje laistymo sistemose gali padėti sumažinti elektrinių siurblių, skirtų vandens paskirstymui laukuose, suvartojamos elektros kaštus. Nepastovus klimatas ir globalinis atšilimas didina laistymo sistemų poreikį, o mažesni elektros kaštai daro įtaką auginamos produkcijos savikainai ir gali atnešti didesnę pelną verslininkams.
4. Išanalizavus mašininio mokymosi modelius, nustatyta, kad tokie prižiūrimi algoritmai kaip Random Forest ar Support Vector Machine, yra tinkami elektros poreikio ir kainų prognozėms. Kombinuojant skirtingus modelius ir lyginant jų rezultatus, galima padidinti prognozių tikslumą ir tokiu būdu gauti tikslesnius rezultatus.
5. Sukurtas prototipas leidžia prognozuoti elektros kainas, elektros poreikį ir sudaryti elektros ateities sandorius. Šis prototipas yra pritaikytas specifinėms sritims: laistymo sistemoms ir elektromobilių krovimo stotelių tinklams. Elektros kainų prognozėms yra naudojamos

istorinės elektros kainos, atsinaujinančios energijos duomenys, istorinės anglies kainos bei orų prognozės. Elektros suvartojimo prognozavimui elektromobilių krovimo stotelėse naudojami istoriniai klientų elektromobilių duomenys, o laistymo sistemose sudaryti laistymo tvarkaraščiui naudojami orų duomenys. Nors prototipas veikia specifinėse srityse, tačiau pats pritaikymo metodas gali būti pritaikomas platesnėse rinkose.

6. Elektros kaštų optimizavimo prototipo simuliacijos rezultatai parodė, kad toks metodo pritaikymas gali sumažinti elektros išlaidas ir padidinti veiklos efektyvumą. Prototipo pritaikymas elektromobilių krovimo rinkoje kaštus padėjo sumažinti 2.18 %, o laistymo sistemose 8.78 %. Net ir nedidelė kaštų sutaupymo dalis gali suteikti pranašumą konkurencingoje rinkoje, ar padėti lengviau planuoti išlaidas, tokiu būdu mažindama riziką. Vadovaujantis atlikta analize ir prototipu, tokį metodą galima vadinti lanksčiu ir pritaikomu platesnėse srityse. Dalies duomenų pakoregavimas ir jų pateikimas mašininio mokymosi algoritmams gali suteikti galimybę optimizuoti kaštus platesniu mastu. Metodo lankstumas ir pritaikomumas užtikrina jo potencialią vertę tiek ekonominiu, tiek ekologiniu atžvilgiu.

LITERATŪROS SĄRAŠAS

1. Acer (2023). Wholesale Electricity Market Monitoring 2022
2. Bara A., Oprea V. S. (2023), Forecasting the Spot Market Electricity Price with a Long Short-Term Memory Model Architecture in a Disruptive Economic and Geopolitical Context
3. Chen Q., Liu N. ir kiti (2014). Optimal power utilizing strategy for PV-based EV charging stations considering Real-time price
4. Chen, Y., Hsieh, W (2021). An ensemble learning model for agricultural irrigation prediction.
5. Chughatta R. K., Haroon S. S. (2023), Short-term electricity price forecasting using LSTM and GRU models
6. Dabuoh Mba A. ir kiti (2024). Enhancing Electricity Demand Forecasting Accuracy Through Hybrid Models and Deep Learning Techniques: A Systematic Literature Review
7. Duke R., Mahajan J. ir kiti (2024). “Enhancing Electricity Price Forecasting”: Integrating Macro-Economic Factors and Renewable Energy Dynamics in A Machine Learning Approach
8. Economic Research Service U.S. Department of Agriculture (2018). Energy consumption in agriculture increased in 2016, driven mainly by diesel and fertilizer use
9. Electricity derivatives markets (2022). Pasiokiama: <https://www.fortum.com/news-and-publications/fact-sheets/electricity-derivatives-markets>
10. Ember, (nenurodyta). European electricity prices and costs. Prieiga per internetą: <https://ember-energy.org/data/european-electricity-prices-and-costs/>, žiūrėta 2024-12-03.
11. Euronext and Nord Pool announce Nordic and Baltic Power Futures market (2024). Pasiokiama: <https://www.nordpoolgroup.com/en/message-center-container/newsroom/exchange-message-list/2024/q3/euronext-and-nord-pool-announce-nordic-and-baltic-power-futures-market/>
12. Farmers weekly (2024). Harnessing wind power: Power purchase agreements for farmers. Prieiga per internetą <https://www.fwi.co.uk/business/business-management/agricultural-transition/harnessing-wind-power-power-purchase-agreements-for-farmers>, žiūrėta 2024-12-04
13. Gore S., Iqbal A. ir kiti (2024). A Case Study of Electric Vehicles Load Forecasting in Residential Sector Using Machine Learning Techniques
14. IEEE Blockchain Technical Community (nenurodyta). Smart Contracts and Energy: How Blockchain Smart Contracts Can Improve the Energy Sector. Prieiga per internetą:

- <https://blockchain.ieee.org/verticals/transactive-energy/topics/smart-contracts-and-energy-how-blockchain-smart-contracts-can-improve-the-energy-sector>, žiūrėta 2024-12-03.
15. IEEE Transactions on Smart Grid (2023). Pricing for Electric Vehicle Charging Stations Based on the Responsiveness of Demand.
 16. Investing.com, Dutch TTF Natural Gas Futures Historical Data, <https://www.investing.com/commodities/dutch-ttf-gas-c1-futures-historical-data>. Prieiga 2024
 17. Jedrezejwski A., Lago J. ir kiti (2022). Electricity Price Forecasting: The Dawn of Machine Learning
 18. Jing L. (2022). Evolution of Electricity Rate Structures for EV Charging
 19. Kaggle, Electric Vehicle Charging Dataset. <https://www.kaggle.com/datasets/michaelbryantds/electric-vehicle-charging-dataset>., žiūrėta 2024-12-03.
 20. Kalibrate, 3 Ways to Learn About Retail Fuel Pricing Sensitivity. <https://kalibrate.com/insights/blog/fuel-pricing/fuel-pricing-sensitivity/>, žiūrėta 2024-12-03.
 21. Khajeh H, Firoozi H ir kiti (2022). Business Models for Different Future Electricity Market Players
 22. LHMT, Meteo.lt API, <https://api.meteo.lt/>. Prieiga 2024-11-15
 23. Lisa Umutoni, Vidya Samadi (2024). Application of machine learning approaches in supporting irrigation decision making: A review.
 24. Litgrid, Consumption, <https://www.litgrid.eu/index.php/dashboard/consumption/637>, Prieiga 2024
 25. LRT (2019). Lithuania ‘at the center of climate change’ – crop failures and extreme weather three years in a row. Prieiga per internetą: <https://www.lrt.lt/en/news-in-english/19/1059338/lithuania-at-the-center-of-climate-change-crop-failures-and-extreme-weather-three-years-in-a-row>, žiūrėta 2024-12-03
 26. Luo H., Shao Y (2024). Advanced Optimal System for Electricity Price Forecasting Based on Hybrid Techniques
 27. Ma. S., Jin. N. ir kiti (2024). Research on Machine Learning-Based Method for Predicting Industrial Park Electric Vehicle Charging Load
 28. Maciejowska K. ir kiti (2023). Forecasting Electricity Prices
 29. NACS, Consumer Behavior at the Pump. <https://www.convenience.org/topics/fuels/documents/how-consumers-react-to-gas-prices.pdf>, žiūrėta 2024-12-03.

30. Next Kraftwerke. (nenurodyta). Liberalization of Energy Markets. Prieiga per internetą: <https://www.next-kraftwerke.com/knowledge/liberalization-energy-markets>, žiūrėta 2024-12-03.
31. NoordPool, Prices, <https://data.nordpoolgroup.com/auction/day-ahead/prices?deliveryDate=2023-01-01¤cy=EUR&aggregation=DailyAggregate&deliveryAreas=LT>, Prieiga 2024
32. Pankaj Kashyap, Sushil Kumar, Ankita Jaiswal (2021). Towards Precision Agriculture: IoT-Enabled Intelligent Irrigation Systems Using Deep Learning Neural Network
33. Pedro F.(2023). Fintech in Agriculture: How Digital Platforms are Empowering Farmers
34. Pepermans G.,(2019). European energy market liberalization: experiences and challenges
35. Pinhao M. ir kiti (2022). Electricity Spot Price Forecast by Modelling Supply and Demand Curve
36. Precedence Research (2024). Electric Vehicle Market Size, Share, and Trends 2024 to 2034. Prieiga per internetą: <https://www.precedenceresearch.com/electric-vehicle-market>, žiūrėta 2024-12-04
37. Quintana J. (2024). The impact of renewable energies on wholesale electricity prices
38. Richard G. Allen, Luis S. Pereira ir kiti (1998). Crop evapotranspiration - Guidelines for computing crop water requirements - FAO Irrigation and drainage paper 56
39. S. Meivel, S. Maheswari (2020). Standard Agricultural Drone Data Analytics using KNN Algorithm
40. S. Ramya, A.M. Swetha ir Manivannan Doraipandian (2020). IoT Framework for Smart Irrigation using Machine Learning Technique.
41. Sowby B. R. (2022). The energy footprint of U.S. irrigation: A first estimate from open data
42. Weiqing Gu, Zhaocheng Yi (2020). Machine Learning on Minimizing Irrigation Water for Lawns
43. Zhao Z., Want C. ir kiti (2018). Improving Short-Term Electricity Price Forecasting Using Day-Ahead LMP with ARIMA Models
44. Zhu J., Yang Z. ir kiti (2019). Short-Term Load Forecasting for Electric Vehicle Charging Stations Based on Deep Learning Approaches
45. IEA (2024), Global EV Outlook 2024, Prieiga per internetą: <https://www.iea.org/reports/global-ev-outlook-2024>, žiūrėta: 2024-12-05.