

VILNIAUS GEDIMINO TECHNIKOS UNIVERSITETAS

Jonas BIELSKUS

MAŠININIO MOKYMOSI MODELIO
TAIKYMAS PASTATO VĖDINIMO
SISTEMOS VALDYMO EFEKTYVUMUI
DIDINTI

DAKTARO DISERTACIJA

TECHNOLOGIJOS MOKSLAI,
STATYBOS INŽINERIJA (T 002)

Vilnius, 2024

Disertacija rengta 2018–2024 metais Vilniaus Gedimino technikos universitete.

Vilniaus Gedimino technikos universiteto Statybos mokslo krypties disertacijos gynimo taryba:

Vadovas

doc. dr. Violeta MOTUZIENĖ (Vilniaus Gedimino technikos universitetas, Statybos inžinerija – T 002).

Pirmininkas

prof. dr. Zenonas TURSKIS (Vilniaus Gedimino technikos universitetas, Statybos inžinerija – T 002).

Nariai:

dr. Anatolijs BORODINECS (Rygos technikos universitetas, Latvija, Statybos inžinerija – T 002),

dr. Rolandas JONYNAS (Kauno technologijos universitetas, Energetika ir termoinžinerija – T 006),

prof. habil. dr. Artūras KAKLAUSKAS (Vilniaus Gedimino technikos universitetas, Statybos inžinerija – T 002),

doc. dr. Giedrė STRECKIENĖ (Vilniaus Gedimino technikos universitetas, Energetika ir termoinžinerija – T 006).

Disertacija bus ginama viešame Statybos inžinerijos mokslo krypties disertacijos gynimo tarybos posėdyje **2024 m. birželio 14 d. 13 val.** Vilniaus Gedimino technikos universiteto SRA-I posėdžių salėje.

Adresas: Saulėtekio al. 11, LT-10223 Vilnius, Lietuva.

Tel.: (8 5) 274 4956; faksas (8 5) 270 0112; el. paštas doktor@vilniustech.lt

Pranešimai apie numatomą ginti disertaciją išsiųsti 2024 m. gegužės 13 d.

Disertaciją galima peržiūrėti Vilniaus Gedimino technikos universiteto talpykloje <https://etalpykla.vilniustech.lt> ir Vilniaus Gedimino technikos universiteto bibliotekoje (Saulėtekio al. 14, LT-10223 Vilnius, Lietuva).

Vilniaus Gedimino technikos universiteto 2024-033-M mokslo literatūros knyga

<https://doi.org/10.20334/2024-033-M>

© Vilniaus Gedimino technikos universitetas, 2024

© Jonas Bielskus, 2024

jonas.bielskus@gmail.com

VILNIUS GEDIMINAS TECHNICAL UNIVERSITY

Jonas BIELSKUS

APPLICATION OF A MACHINE LEARNING
MODEL TO IMPROVE THE EFFICIENCY OF
THE VENTILATION CONTROL SYSTEM IN
A BUILDING

DOCTORAL DISSERTATION

TECHNOLOGICAL SCIENCES,
CIVIL ENGINEERING (T 002)

Vilnius, 2024

The doctoral dissertation was prepared at Vilnius Gediminas Technical University in 2018–2024.

Supervisor:

Assoc. Prof. Dr Violeta MOTUZIENĖ (Vilnius Gediminas Technical University, Civil Engineering – T 002).

The Dissertation Defense Council of the Scientific Field of Civil Engineering of Vilnius Gediminas Technical University:

Chairman:

Prof. Dr Zenonas TURSKIS (Vilnius Gediminas Technical University, Civil Engineering – T 002).

Members:

Dr Anatolijs BORODINECS (Riga Technical University, Latvia, Civil Engineering – T 002),

Dr Rolandas JONYNAS (Kaunas University of Technology, Energetics and Power Engineering – T 006),

Prof. Dr Habil. Artūras KAKLAUSKAS (Vilnius Gediminas Technical University, Civil Engineering – T 002),

Assoc. Prof. Dr Giedrė STRECKIENĖ (Vilnius Gediminas Technical University, Energetics and Power Engineering – T 006).

The dissertation will be defended at the public meeting of the Dissertation Defense Council of the Scientific Field of Civil Engineering in the SRA -I Meeting Hall of Vilnius Gediminas Technical University at **1 p.m. on 14 June 2024.**

Address: Saulėtekio al. 11, LT-10223 Vilnius, Lithuania.

Tel.: +370 5 274 4956; fax +370 5 270 0112; e-mail: doktor@vilniustech.lt

A notification on the intended defence of the dissertation was sent on 13 May 2024. A copy of the doctoral dissertation is available for review at the Vilnius Gediminas Technical University repository <https://etalpykla.vilniustech.lt> and the Library of Vilnius Gediminas Technical University (Saulėtekio al. 14, LT-10223 Vilnius, Lithuania).

Reziumė

Disertacijoje nagrinėjamos vėdinimo sistemos energijos suvartojimo problemos, kurios tiesiogiai susijusios su vartotojų elgsena.

Pagrindiniai tyrimo objektai – atvirojo tipo biurai ir jų vėdinimo sistemos.

Disertacijos tikslas – sukurti dirbtiniu intelektu grįstą vėdinimo sistemos valdymo modelį vadovaujantis vartotojų elgsenos prognozavimu.

Darbe sprendžiami šie pagrindiniai uždaviniai:

Pirmasis uždavinys – vartotojų elgsenos parametrų identifikavimas ir jų įtakos pastato energijos suvartojimui vertinimas.

Antrasis uždavinys – atlikti realių pastatų ilgalaikę stebėseną, išanalizuoti pastatų užimtumo ir mikroklimato parametrų duomenis ir paruošti duomenų imtį, reikalingą matematiniam prognozavimo modeliui kurti.

Trečiasis uždavinys – adaptuoti mašininio mokymusi grįstų modelių taikymo galimybes pagal patalpų vartotojų užimtumą ir atlikti modelio validavimą.

Disertaciją sudaro įvadas, trys skyriai, bendrosios išvados, naudotos literatūros ir autoriaus publikacijų disertacijos tema sąrašai.

Įvadiniamе skyriuje aptariama tiriamoji problema, darbo aktualumas, aprašomas tyrimų objektas, formuluojamas darbo tikslas bei uždaviniai, aprašoma tyrimų metodika, darbo temos naujumas, darbo rezultatų praktinė reikšmė, ginamieji teiginiai. Įvado pabaigoje pristatomos disertacijos tema autoriaus paskelbtos publikacijos ir pranešimai konferencijose bei disertacijos struktūra.

Pirmasis skyrius skirtas literatūros apžvalgai. Jame aptariami veiksniai, darantys įtaką vartotojų elgsenai, ir vartotojų elgsenos prognozavimo modeliai.

Antrajame skyriuje aptariami tyrimo objektai ir jų dalyvių elgsena, taip pat pasyviosios vartotojų elgsenos prognozavimo modeliai ir jų integravimo į pastato vėdinimo sistemą veikimo koncepcija.

Trečiajame skyriuje atliekama mašininio mokymosi modelių prognozavimo jautrumo analizė. Pasiūlytas atvirojo tipo biurų vėdinimo sistemos modeliuojantis algoritmas, parodantis sistemos veikimo efektyvumą prognozuojant pasyviąją vartotojų elgseną. Kiekvieno skyriaus pabaigoje ir atlikus galutinius tyrimus pateikiamos bendros darbo išvados. Disertacijos pabaigoje yra atskiras skyrius, kuriame pateikiamos bendrosios tyrimo išvados.

Disertacijos tema paskelbti šeši straipsniai: du recenzuojamuose mokslo žurnaluose, turinčiuose cituojamumo rodiklį *Clarivate Analytics Web of Science* duomenų bazėje; vienas tarptautinių konferencijų leidiniuose, referuojamuose *Clarivate Analytics Web of Science* duomenų bazėje *Conference Proceedings*, trys kituose recenzuojamuose mokslo žurnaluose. Disertacijoje atliktų tyrimų rezultatai buvo paskelbti dviejose mokslinėse konferencijose Lietuvoje ir užsienyje.

Abstract

This dissertation addresses the energy consumption problems of ventilation systems, which are directly related to user behaviour.

The main objects of the research are open-plan office spaces and their ventilation systems

This dissertation aims to develop an artificial intelligence-based model for ventilation system control based on the prediction of user behaviour.

The dissertation addresses several main challenges: first, to identify user behaviour parameters and assess their impact on building energy consumption; second, to carry out long-term monitoring of real buildings, to analyse data on occupancy and microclimate parameters and to prepare a data sample for the development of a mathematical prediction model; and finally, to adapt to machine learning-based models based on occupancy rates of premises and to validate the model.

The dissertation consists of an introduction, three chapters, general conclusions, a list of literature, and a list of publications on the dissertation's subject.

The introduction discusses the research problem and the relevance of the work, describes the research object, formulates the aim and objectives of the dissertation, describes the research methodology, the novelty of the topic, the practical significance of the results, and the defended statements. The introduction closes with lists of the author's publications and conference presentations on the subject of the dissertation and the presented structure of the dissertation.

The First Chapter is devoted to a literature review. It discusses the factors influencing user behaviour and models for predicting user behaviour.

The Second Chapter discusses the research objects and the behaviour of their participants, as well as the methods for predicting passive user behaviour and the concept of how to integrate them into the building ventilation system.

The Third Chapter provides a sensitivity analysis of the prediction of machine learning models. A modelling algorithm for an open-type office ventilation system is proposed to show the performance of the system in predicting passive user behaviour. Each chapter closes with an outline of the general conclusions for the work covered in it. There is a separate chapter, of general conclusions of the research at the end of the dissertation.

Six articles were published on the topic of the dissertation: two in peer-reviewed scientific journals with a citation index in *Clarivate Analytics Web of Science* databases, one in international conference publications referenced in the *Clarivate Analytics Web of Science* database *Conference Proceedings*, and three in other peer-reviewed journals. The results of the research were published in two scientific conferences in Lithuania and abroad.

Žymėjimai

Santrumpos

AI-VAV – kintamojo oro srauto vėdinimo sistema su mašininio mokymosi algoritmo valdymu (angl. *Artificial Intelligence and Variable Air Volume*);

ANN – dirbtiniai neuroniniai tinklai (angl. *Artificial Neural Networks*);

ANNM – dirbtiniais neuroniniais tinklais pagrįstas modelis (angl. *Artificial Neural Network-Based Model*);

B, A, A+ ir A++ – pastatų energetinis vertinimo koeficientas (angl. *Building Energy Performance Rating Coefficient*);

BMS – pastato valdymo sistema (angl. *Building Management System*);

CART – klasifikavimo ir regresijos medžiai (angl. *Classification and Regression Trees*);

CAV – pastovaus oro srauto vėdinimo sistema (angl. *Constant Air Volume*);

clo – žmonių apsirengimo lygis (1 = kelnės, marškiniai ir švarkas) (angl. *Clothing Insulation*);

CO₂ – anglies dioksido koncentracija, ppm (angl. *Carbon Dioxide*);

DE – diferencialinės evoliucijos algoritmas (angl. *Differential Evolution*);

DI – dirbtinis intelektas (angl. *Artificial intelligence*);

ELM – ekstremalaus mašininio mokymosi modelis (angl. *Extreme Learning Machine*);

ES – Europos Sąjunga (angl. *The European Union*);

FFNs – perdavimo tinklams (angl. *For Feedforward Networks*);

GA – genetinis algoritmas (angl. *Genetic Algorithm*);
 GA-ELM – ekstremalaus mokymosi mašininis modelis su genetinio algoritmo optimizacija (angl. *Extreme Learning Machine Model with Genetic Algorithm Optimisation*);
 KNNs – K artimiausioji kaimynystė (angl. *K-Nearest Neighbors*);
 LDA – tiesinė diskriminacinė analizė (angl. *Linear Discriminant Analysis*);
 RF – radijo dažnis (angl. *Radio Frequency*);
 RH – santykinė drėgmė (angl. *Relative Humidity*);
 SA – imituoto atkaitinimo algoritmas (angl. *Simulated Annealing Algorithm*);
 SA-ELM – ekstremalaus mokymosi mašininis modelis su imituoto atkaitinimo optimizacija (angl. *Extreme Learning Machine Model with Simulated Annealing Algorithm Optimisation*);
 SLFNN – vieno paslėpto sluoksnio tiekimo į priekį neuroninis tinklas (angl. *Single Hidden Layer Feed forward Neural Network*);
 SVM – atraminių vektorių mašininis modelis (angl. *Support Vector Machines*);
 TVOC – bendras lakiųjų organinių junginių kiekis (angl. *Total Volatile Organic Compounds*);
 VAV – kintamojo oro srauto vėdinimo sistema (angl. *Variable Air Volume*);
 VE – vartotojų elgsena (angl. *User Behaviour*).

Simboliai

Ekstremalaus mašininio mokymosi modelio (ELM) simboliai:

$G(x)$ – aktyvacijos funkcija (angl. *Activation Function*);
 b_i – įverčio poslinkio svorių vektorius (angl. *Bias Weight Vector*);
 H – paslėptųjų sluoksnių išvesties matrica (angl. *Hidden Layer Output Matrix*);
 H^+ – Moore–Penrose generalizuota atvirkštinė matrica (angl. *Moore-Penrose Generalised Inverse Of Matrix*);
 L – paslėptųjų neuronų sluoksnių skaičius (angl. *Number Of Hidden Layer Nodes*);
 N – neuronų skaičius (angl. *Number Neurons*);
 O_j – prognozuota išvesties funkcija (angl. *Predicted Output Value*);
 R – realusis skaičius (angl. *Real Numbers*);
 T – vienos bendros tiesinės sistemos mažiausio kvadrato sprendinys (angl. *One of the Least-Squares Solutions of a General Linear System*);
 w_i – įvesties svorių vektorius (angl. *Input Weight Vector*);
 x_i, t_i – įvesties neuronai (angl. *Input Neurons*);
 β – išvesties svoriai (angl. *Output Weights*).

Genetinio algoritmo (GA) simboliai:

$f(y)$ – populiacijos funkcija (angl. *Population Function*);
 $Fit(y_i)$ – tinkamumo funkcija (angl. *Fitness Function*);

$Y(0)$ – pradinė populiacija (angl. *Initial Population*);
 $Y(t)$ – populiacijos karta (angl. *Generation of Population*);
 L – chromosomų tėvai (angl. *Chromosome Parents*);
 M – populiacijos dydis (angl. *Population Size*);
 N – nutraukta evoliucijos algebra (angl. *Terminate Evolution Algebra*);
 P_c – kryžminimo tikimybė (angl. *Crossover Probability*);
 P_m – mutacijos tikimybė (angl. *Mutation Probabilities*);
 T_j – faktinė išvesties vertė (angl. *Actual Output Value*).

Imituoto atkaitinimo algoritmo (SA) simboliai:

$f(y)$ – kandidatų funkcija (angl. *Candidate Function*);
 $f(x)$ – sprendimo funkcija (angl. *Decision Function*);
 y – kandidatų sprendinys (angl. *Candidate Solution*);
 p – tikimybių lygtis (angl. *Probability Equation*);
 r – atsitiktinis skaičius (angl. *Random Number*);
 t – išmatuoti duomenys (angl. *Measured Data*);
 x – pradinis sprendinys (angl. *Initial Solution*).

Turinys

IVADAS	1
Problemos formulavimas.....	1
Darbo aktualumas.....	2
Tyrimų objektas.....	2
Darbo tikslas.....	3
Darbo uždaviniai	3
Tyrimų metodika	3
Darbo mokslinis naujumas	4
Darbo rezultatų praktinė reikšmė	4
Ginamieji teiginiai	5
Darbo rezultatų aprobavimas.....	5
Disertacijos struktūra.....	5
1. VARTOTOJŲ ELGSENA IR JOS PROGNOZAVIMO MODELIAI.....	7
1.1. Vartotojų elgsenos įtaka pastatų energijos suvartojimui	7
1.2. Pastatų vartotojų elgsenos ypatumai.....	9
1.3. Vartotojų veiklos profiliai skirtinguose energijos modeliavimo įrankiuose	13
1.4. Vartotojų elgsenos prognozavimo modeliai	16
1.5. Dirbtinio intelekto taikymas pastatų projektavimo ir eksploatavimo etapais	24
1.6. Pirmojo skyriaus išvados ir disertacijos uždavinių formulavimas.....	27
2. DUOMENYS IR TYRIMO METODIKA	29
2.1. Tiriamieji objektai	31

2.2. Tiriamųjų objektų patalpos.....	37
2.3. Ekstremalaus mokymosi mašininis modelis su integruotais optimizacijų algoritmais	38
2.4. Anglies dioksido koncentracijos patalpoje modeliavimas	46
2.5. Antrojo skyriaus išvados	49
 3. MAŠININIO MOKYMOSI SU OPTIMIZACIJOMIS MODELIAI IR VĖDINIMO SISTEMOS VALDYMO MODELIO ANALIZĖ BEI PATIKRINIMAS	51
3.1. Tiriamųjų objektų empirinių duomenų analizė.....	52
3.2. Prognozavimo modelio jautrumo ir patikimumo analizė	59
3.3. Vėdinimo sistemos valdymo taikant mašininio mokymosi modelį skaičiavimų rezultatai	69
3.4. Vėdinimo sistemos energetinis efektyvumas taikant mašininio mokymosi modelį	77
3.5. Trečiojo skyriaus išvados	79
 BENDROSIOS IŠVADOS	81
 LITERATŪRA IR ŠALTINIAI.....	83
 AUTORIAUS MOKSLINIŲ PUBLIKACIJŲ DISERTACIJOS TEMA SĄRAŠAS ...	93
 SUMMARY IN ENGLISH.....	95

Contents

INTRODUCTION	1
Formulation of the problem.....	1
Relevance of the dissertation.....	2
Object of the research.....	2
Aim of the dissertation	3
Tasks of the dissertation	3
Research methodology	3
Scientific novelty of the dissertation	4
Practical significance of achieved results	4
Defended statements	5
Approval of the research results	5
The structure of the dissertation	5
1. USER BEHAVIOUR AND PREDICTION MODELS	7
1.1. Influence of user behaviour on the energy consumption in buildings	7
1.2. Specifics of building user behaviour	9
1.3. Occupancy profiles in different energy modelling tools	13
1.4. Models for predicting occupancy behaviour	16
1.5. Application of artificial intelligence in building design and operation stages...	24
1.6. Conclusions of the First Chapter and formulation of the dissertation objectives	27

2. DATA AND RESEARCH METHODOLOGY	29
2.1. Research subject	31
2.2. Premises of research objects.....	37
2.3. Extreme learning machine model with integrated optimisation algorithms	38
2.4. Modelling of indoor carbon dioxide concentrations.....	46
2.5. Conclusions of the Second Chapter.....	49
3. ANALYSIS AND VERIFICATION OF MACHINE LEARNING MODELS WITH OPTIMISATIONS FOR VENTILATION SYSTEM CONTROL	51
3.1. Analysis of empirical data of research objects	52
3.2. Sensitivity and reliability analysis of the forecasting model	59
3.3. Results of ventilation system control with machine learning model calculations	<u>69</u>
3.4. Energy efficiency of a ventilation system using a machine learning model.....	77
3.5. Conclusions of the Third Chapter.....	79
GENERAL CONCLUSIONS	81
REFERENCES	83
LIST OF SCIENTIFIC PUBLICATIONS BY THE AUTHOR ON THE TOPIC OF THE DISSERTATION	93
SUMMARY IN ENGLISH.....	95

Įvadas

Problemos formulavimas

Energijos suvartojimas pastatų sektoriuje didėja nepaisant to, kad šiuolaikiniai pastatai statomi vis energetiškai efektyvesni. Augantis energijos suvartojimas pastatų sektoriuje tiesiogiai priklauso nuo vartotojų ir jų poreikių tenkinimo. Nauji pastatai projektuojami vis labiau atsižvelgiant ne į pastato energijos taupymą, bet į vartotojų ergonomiką ir siekiant pastato darnumo sertifikatų (BREEAM, LEED, *Well* ir pan.). 2022 m. dėl susiklosčiusios politinės situacijos Europoje energijos kainos padidėjo 2–3 kartus – energijos taupymas tampa dar aktualesnis, tiesiogiai priklausantis nuo išlaidų pastatų eksploatacijai.

Vartotojų elgsena (toliau ir VE) – pagrindinis veiksnys, kurį privalu pažinti ir pritaikyti siekiant taupyti energiją pastatuose.

Vartotojų elgsenos tyrimuose vis dažniau yra taikomi mašininio mokymosi metodai arba bendrąja prasme – dirbtinis intelektas. Dirbtinio intelekto taikymo tyrimų rezultatai turi didelį potencialą energijos poreikiui mažinti. Vis dėlto taikant dirbtinį intelektą vis dar susiduriama su iššūkiais, nes efektyviam jo taikymui reikalinga sukaupti didelį duomenų kiekį. Taigi, nors VE poveikio energijos sąnaudoms ir jų prognozavimo tobulinimo tyrimai sparčiai vystosi, tačiau esminių sprendimų vis dar nėra pasiūlyta.

Darbo aktualumas

Energijos vartojimo mažinimas tampa vis svarbesnis siekiant Europos Sąjungos (toliau ir ES) tvaraus vystymosi tikslų. 2021 m. Europos Komisija pasiūlė dokumentų rinkinį ir tikslą – iki 2030 m. Europos Sąjungoje šiltnamio efektą sukeliančių dujų emisiją sumažinti 55 proc. (lyginant su 1990 m.) ir iki 2050 m. visiškai neutralizuoti poveikį klimatui. Energijos vartojimo efektyvumo didinimas pastatuose vis dar išlieka viena iš aktualiausių problemų, nes pastatai vis dar suvartoja apie 40 proc. visos ES suvartojamos energijos.

Praktika rodo, kad realūs pastatų energijos poreikiai dažnai labai skiriasi nuo projektinių ir šie skirtumai (angl. *Performance Gap*) siekia daugiau nei 1,5 karto (Harper, 2017). Atliekant skaičiavimus pagal pastatų energetinio naudingumo sertifikavimo metodiką pastatų vartotojų įtaka vertinama tik taikant fiksuotą standartinį jų elgsenos modelį, todėl klaidos projektuose yra kartojamos.

Detaliau gilintis į žmonių elgesį pastatuose ir į jų įtaką energijos suvartojimui pradėta nuo 2008 m., kai pastebėta, kad nors pastatai yra energetiškai efektyvūs, bet energijos vartojimas tarp vienodų pastatų labai skirtingas (Harptulugi et al. 2021).

Vartotojų elgsenos įtakos energijos suvartojimui mažinimas gali būti vykdomas keliuose pastato gyvavimo etapuose: projektavimo, įgyvendinimo ir eksploatacijos. Visų minėtų trijų etapų stadijose galima taikyti vartotojų elgsenos prognozavimą.

Šis prognozavimas atliekamas taikant įvairius modelius, kuriuose dažniausiai taikomi mašininio mokymosi modeliai. Jų prognozavimo tikslumas ir patikimumas siekia iki 90 %.

Daugiausia energijos šildymo, vėdinimo ir oro kondicionavimo (toliau – ŠVOK) sistemose galima sutaupyti modernizuojant vėdinimo sistemas. Erickson et al. (2015) ir Brandemuehl et al. (1999) atliktų tyrimų metu nustatyta, kad sumažinus vidutinį tiekiamo oro kiekį pastatuose, kuriuose oro kiekis apskaičiuojamas pagal didžiausią galimą vartotojų skaičių, energijos suvartojimas sumažėja 10–15 proc., išlaikant priimtina patalpų kokybę.

Šiame darbe vertinamas pastato vėdinimo sistemos energijos sutaupymo potencialas.

Tyrimų objektas

Darbo tyrimų objektas – atvirojo tipo biurai ir jų vėdinimo sistemos.

Darbo tikslas

Ištyrus pasyviają vartotojų elgseną administracinės paskirties biurų pastatuose, taikant mašininio mokymosi modelius (AI-VAV) darbe siekiama parengti teorinį kintamo oro srauto sistemos valdymo modelį, skirtą suvartojamos energijos kiekiui mažinti.

Darbo uždaviniai

Darbo tikslui pasiekti darbe keliami šie uždaviniai:

1. Atlikti mokslinės ir kitos literatūros, susijusios su vartotojų elgsenos prognozavimo ir mašininio mokymosi taikymo pastato informaciniame modelyje tema, analizę.
2. Atlikti ilgalaikę realių pastatų vartotojų elgsenos stebėseną, išanalizuoti pastatų užimtumo ir mikroklimato parametrų duomenis bei paruošti duomenų imtį, reikalingą matematiniam prognozavimo modeliui kurti.
3. Išanalizuoti mašininio mokymusi grįstų metodų taikymo galimybes patalpų užimtumui prognozuoti, sukurti modelį, atlikti jo pritaikymą ir validavimą, įvertinant:
 - įvesties duomenų kiekio svarbą modeliui ir minimalaus duomenų kiekio poreikį prognozavimui;
 - modelio jautrumą keičiant mašininio mokymosi parametrus ir patikrinti skaičiavimo patikimumą esant mažam darbo vietų užimtumui.
4. Validuoti sukurtą AI-VAV sistemos matematinį modelį *Matlab* aplinkoje ir nustatyti šio modelio:
 - kokybinį patikimumą prognozuojant vartotojų užimtumą ir skaičiuojant CO₂ koncentraciją modeliuojamoje patalpoje;
 - reikiamus AI-IVAV modeliui pradinis duomenų įvesties kiekius;
5. Pateikti sukurto modelio taikymo rekomendacijas.

Tyrimų metodika

Atvirojo tipo biurų pastatų patalpose buvo atlikti eksperimentiniai tyrimai, kurių metu sukaupti vidaus ir lauko mikroklimato parametrai, taip pat vartotojų darbo

vietos užimtumo duomenys. Atlikta duomenų analizė ir apdorojimas paruošiant panaudoti empirinius duomenis mašininio mokymosi modelyje.

VE prognozavimas atliktas kompiuterinėje programoje *Matlab*, kurioje buvo parašytas ekstremalaus mašininio mokymosi (ELM – angl. *Extreme Learning Machine*, toliau vadinamas ir ELM) modelis integruojant du optimizacijos algoritmus, tai yra genetinį (angl. *Genetic Algorithm*, toliau vadinamas ir GA) ir imituoto atkaitinimo algoritmus (angl. *Simulated Annealing*, toliau vadinamas ir SA).

Šiame darbe nagrinėjama vėdinimo sistema, o jos valdymas pagrįstas sukurtu mašininio mokymosi modeliu, kuris yra imituojamas *Matlab* aplinkoje keičiant valdymo sistemą į sukurtąjį AI-VAV modelį. Šios sistemos privalumas – greitis, gautų duomenų apdorojimas ir prisitaikymas prognozuojant žmonių skaičių patalpoje.

Darbo mokslinis naujumas

Rengiant disertaciją buvo gauti šie statybos inžinerijos mokslui nauji rezultatai:

1. Atlikta vartotojų elgsenos analizė ir sukaupiti duomenys apie pasyviąją vartotojų elgseną įvairiomis sąlygomis įtraukiant ir COVID-19 pandemijos griežto režimo ir jo švelninimo laikotarpius.
2. Vartotojų elgsenai prognozuoti pritaikytas mašininio mokymosi modelis su skirtingais optimizavimo algoritmais. Atlikta jautrumo analizė nustatant optimaliausius parametrus, siekiant aukšto prognozavimo patikimumo ir trumpiausios skaičiavimo trukmės.
3. Eksperimentinių tyrimų pagrindu sukurtas vėdinimo sistemos AI-VAV modelis, leidžiantis imituoti atvirojo tipo biuro patalpą, prognozuojantis vartotojų elgseną bei pagal prognozę atliekantis vėdinimo sistemos valdymą.

Darbo rezultatų praktinė reikšmė

Šiame darbe pateiktas mašininio mokymosi modelis su optimizavimo algoritmais, jį taikant atliekama vartotojų elgsenos prognozė pagal lauko ir patalpų fizinius parametrus. Modelis leidžia prognozuoti vartotojų elgseną bei atitinkamai valdyti vėdinimo sistemą, tiekiant šviežią orą į patalpas pagal realų numatomą poreikį. Tyrimų rezultatai gali būti naudojami ne vien atvirojo tipo, bet ir kitos paskirties pastatų patalpose (pvz., prekybos centrų salėse, teatruose ir pan.) ŠVOK sistemų valdymui programuoti, numatant veiksmus pagal pasikartojančius įvykius, reikalingus eksploataavimo metu.

Ginamieji teiginiai

1. Mašininio mokymosi modelis ELM su optimizacijomis vartotojų užimtumą prognozuoja iki 0,9 tikslumo (pagal determinacijos koeficientą R^2), kai vartotojų darbo vietų užimtumas yra ne mažesnis nei 0,033 žm./m².
2. Mašininio mokymosi modeliui pakanka 4 savaitių CO₂ ir vartotojų darbo vietos užimtumo stebėsenos duomenų (5 minučių laiko žingsniu) patikimam užimtumo prognozavimui.
3. AI-VAV modelis leidžia padidinti vėdinimo sistemos energijos suvartojimo efektyvumą, kai prognozuojamas vartotojų užimtumas patalpoje.

Darbo rezultatų aprobavimas

Disertacijos tema paskelbti šeši straipsniai: du recenzuojamuose mokslo žurnaluose, turinčiuose cituojamumo rodiklį *Clarivate Analytics Web of Science* duomenų bazėje (Bielskus et al. 2020; Motuzienė et al. 2021); vienas tarptautinių konferencijų leidiniuose, referuojamuose *Clarivate Analytics Web of Science* duomenų bazėje *Conference Proceedings* (Bielskus et al. 2020); trys kituose recenzuojamuose mokslo žurnaluose (Bielskus et al. 2019, Motuzienė et al. 2021, Motuzienė et al. 2021).

Disertacijoje atliktų tyrimų rezultatai buvo paskelbti dviejose mokslinėse konferencijose Lietuvoje ir užsienyje:

- tarptautinėje konferencijoje *11th International Conference Environmental Engineerings* 2020 m. Vilniuje Lietuvoje;
- tarptautinėje konferencijoje *The Conference of Environmental and Climate Technologies (CONNECT)* 2021 m. Rygoje, Latvijoje.

Disertacijos struktūra

Disertaciją sudaro šios dalys: įvadas, trys skyriai ir rezultatų apibendrinimas bei trys priedai.

Darbo apimtį sudaro 113 puslapių, tekste panaudota 20 numeruotų formulių, 43 paveikslai ir 17 lentelių. Rašant disertaciją buvo nagrinėta 100 literatūros šaltinių.

Vartotojų elgsena ir jos prognozavimo modeliai

Šiame skyriuje apžvelgiama, kokią įtaką vartotojų elgsena daro pastatų energijos poreikiams, bei atskleidžiami vartotojų elgsenos ypatumai. Taip pat apžvelgiami metodai, taikytini vartotojų elgsenai prognozuoti, prognozavimo efektyvumas ir patikimumas, galiausiai, kaip prognozavimo rezultatai gali būti pritaikomi projektuojant pastatą ir jį naudojant. Be to, aptariama ŠVOK sistemų reguliavimo metodika naudojant BMS (angl. *Building Management System*) pastato valdymo sistemą. Šio skyriaus tematika yra paskelbtos dvi publikacijos (Bielskus et al. 2020; Motuzienė et al. 2021).

1.1. Vartotojų elgsenos įtaka pastatų energijos suvartojimui

Skaičiuojama, kad Europos Sąjungoje pastatai energijos suvartojimo sektoriuje generuoja 40 proc. CO₂ emisijų. Į tai atsižvelgdami ES valstybių vadovai net keltą kartų kaip strateginį tikslą kėlė siekį sumažinti energijos suvartojimą ir CO₂ emisiją. Pirmąkart toks tikslas iškeltas 2007 m. (siekiant sumažinti CO₂ emisiją 20 proc. iki 2020 m.), tuomet pakartotas 2018 m. (siekiant sumažinti CO₂ emisiją

32,5 proc. iki 2030 m.) ir galiausiai vėl iškeltas 2021 m. (siekiant sumažinti CO₂ emisiją 55 proc. iki 2030 m.) kartu su siekiu visiškai neutralizuoti pastatų poveikį klimatui iki 2050 m., lyginant su 1990 m. CO₂ emisija.

Pastarąjį dešimtmetį stengiamasi projektuoti ir statyti energetiškai efektyvius ar beveik energijos nevartojančius pastatus. Nepaisant to, pastatai vis tiek energijos suvartoja ne tiek, kiek buvo numatyta planavimo ir projektavimo etapuose. Pastatai paprastai sunaudoja 1,5–2,5 karto daugiau energijos, nei buvo prognozuota (Harper, 2017). Atlikti teoriniai energijos suvartojimo prognozavimo skaičiavimai parodė, kad nuo 2010 m. iki 2040 m. energijos suvartojimas didės 56 proc. (SUSRIS, 2013), nepaisant pastatų energetinio efektyvumo.

JAV aplinkos apsaugos agentūros ir Europos Komisijos atliktų tyrimų metu nustatyta, kad amerikiečiai ir europiečiai vidutiniškai 85 proc. ir 90 proc. laiko praleidžia patalpose. Tai rodo, kad didžioji žmogaus gyvenimo trukmės dalis yra praleidžiama uždaroje patalpoje, todėl vartotojai daro ypač didelę įtaką pastato eikvojamai energijai. Peper ir Feist (2016) atlikto tyrimo metu nustatyta, kad vartotojų poveikis pastatui gali siekti apie 50 proc. suvartojamo energijos kiekio (Peper et al. 2016). Pagal Kanadoje biuruose atliktą tyrimą biuruose pastebėta, kad ŠVOK sistemų energijos suvartojimas sudarė 66 proc. visos sunaudojamos energijos, o pagal Jungtinėse Amerikos Valstijose (JAV) atliktus tyrimus – ŠVOK sistemos suvartoja apie 50 proc. visos pagamintos energijos (Erickson et al. (2010). Todėl daugiausiai energijos biuruose galima sutaupyti ŠVOK sistemomose. Dėl šių sistemų dėka galima sutaupymą pasiekti iki 60 proc. energijos sutaupymo (Cheng et al., 2019).

Motuzienė atliko energetinius tyrimus įvairios paskirties pastatuose ir pagal sukauptus duomenis palygino energetiškai efektyvių pastatų A, A+ ir A++ teorinius ir faktinius suvartojamos energijos kiekius Lietuvos Respublikos teritorijoje (Motuzienė et al. 2021). Tyrimų metu buvo nustatyta, kad A klasės pastatuose energijos suvartojimas svyruoja nuo –101 proc. iki 77 proc., t. y. iš visų tirtųjų pastatų net 32 proc. jų energijos suvartojimas yra mažesnis arba lygus prognozuotajam ir, atvirkščiai, tačiau net 68 proc. pastatų energijos buvo suvartojama daugiau, nei planuota. A+ ir A++ pastatų klasėms šiluminės energijos suvartojimo kiekiai skiriasi ne taip žymiai: atitinkamai nuo 18 proc. iki 76 proc. ir nuo 23 proc. iki 77 proc. Toks didelis skirtumas tarp realaus (faktinio) energijos suvartojimo ir planuoto būdingas daugelyje pastatų visoje Europos Sąjungoje. Tai vadinama efektyvumo neatitikimu (angl. *Performance Gap*) tarp prognozuotų ir realių rodiklių. Todėl vartotojų elgsena pastatuose, jos supratimas ir kuo tikslesnis pastato įvertinimas projektiniame ir naudojimo etapuose tampa itin reikšmingais energijos taupymo potencialą sudarančiais veiksniais ypač energiškai efektyviuose ir darniuose pastatuose.

VE – vienas iš pagrindinių veiksnių vertinant energiją taupančius sprendimus. Ar energiją taupanti įranga veikia taip, kaip tikėtasi, itin priklauso nuo to, ar

virtutiniai geba naudotis technologijomis, kol pastatas yra naudojimo fazėje. Tai patvirtina ir 2019 m. atvirojo tipo biuruose atlikto apklausų tyrimo duomenys. Apklausų metu vartotojams uždavus klausimą apie temperatūros ir kitų mikroklimato parametrų reguliavimo galimybes, iki 71 proc. respondentų atsakė, kad patys reguliuoja inžinerinių sistemų parametrus, nors pastato valdytojai yra apriboję tokias reguliavimo galimybes ir to daryti tiesiog negalima. Tokie rezultatai tik patvirtina, kad vartotojai ne itin nusimano apie pastato mikroklimato valdymo sistemas (Bielskus et al. 2019).

Kaip jau minėta, Peper et al., 2016 tyrimo metu buvo nustatyta, kad vartotojų elgsenos įtaka pastatų energijos suvartojimui pagal atliktus tyrimus siekia apie 50 proc. Todėl kiek įmanoma tikslesnis vartotojų elgsenos aprašymas pastato energijos suvartojimo prognozavimo etape ir esamų sistemų reguliavimas yra reikšmingas siekiant kuo tiksliau nustatyti pastatų energinį naudingumą ir energiją taupančias technologijas.

Vartotojų elgsenos poveikio energijos sąnaudoms ir jų prognozavimo tobulinimo tyrimų augantį aktualumą atliko Harptutlugil et al., (2021). Autorius pabrėžė, kad vartotojų elgsenos tyrimų apžvalgoje nuo 1982 m. iki 2017 m. matoma, kad 1982 metais buvo publikuota vos keletas straipsnių, tačiau į žmonių elgesį pastatuose ir į jų įtaką energijos suvartojimui buvo pradėta detaliau gilintis nuo 2008 m., kai buvo pastebėta, kad pastatai yra energetiškai efektyvūs, bet energijos vartojimas tarp vienodų pastatų labai skirtingas. Todėl straipsnių apie žmonių elgsenos įtaką nuo 2008 m. jau sparčiai daugėjo, 2019 m. buvo paskelbtos net 475 publikacijos (Harptutlugil et al., 2021).

Modeliuojant vartotojų elgseną ypač svarbi yra kuo didesnė duomenų statistinė įvairovė (Yan et al. 2017). Happle et al. 2018 pastebi, kad vartotojų elgsenos neatitikimas gali daryti poveikį pastatų energetiniams modeliams ne tik pastato ribose, bet ir prognozuojant bendrą miesto kvartalų, rajonų energijos suvartojimą.

Taigi vartotojų elgsenos, kaip esminio pastato energijos vartojimo veiksnio, pažinimas ir įvertinimas yra būtinas visuose pastato gyvavimo etapuose, jei siekiama mažinti energijos suvartojimą bei kartu mažinti ir CO₂ koncentraciją, išsiskiriančią dėl žmonių veiklos.

1.2. Pastatų vartotojų elgsenos ypatumai

Energijos suvartojimas tiesiogiai priklauso nuo vartotojų elgsenos – teigia Peper (2016). VE pastatuose apima tokius veiksmus kaip vietinės šildymo, vėdinimo ir oro kondicionavimo sistemos reguliavimas, langų varstymas, apšvietimo valdymas, pritemdymas naudojant žaliuzes, kad būtų išvengta akinimo ar per didelio saulės šilumos kiekio, termostato nustatymų reguliavimas, ventiliatorių naudojimas, perėjimas į šiltesnes ar vėsesnes vietas ir kt. (Hong et al. 2015).

Nustatyta, kad atvirojo tipo biuruose energijos netaupantys vartotojai energijos sąnaudas padidino iki dviejų kartų, nei buvo prognozuota, tuo metu vartotojai, taupiai naudojantys energiją dėl savo sąmoningų įpročių, net sumažino energijos suvartojimo kiekį, kurie buvo prognozuoti projektavimo etape (Peper et al, 2016). Todėl Hong et al. (2017) jau aptartas tyrimas tik patvirtino Peper 201 m. padarytą išvadą apie vartotojų elgsenos įtaką pastatų energijos suvartojimui.

Vartotojai yra linę imtis iniciatyvos valdant juos supančią aplinką. Tokios vartotojų elgsenos priežastys yra įvairios – tai lemia tiek psichologiniai, tiek socialiniai veiksniai, be to, įtaką daro ir tokie ilgalaikiai veiksniai kaip kultūra ar ekonominė padėtis. Analizuojant vartotojų elgseną dažnai trūksta sociologinių ar psichologinių taikymo metodų, tačiau labai dažnai tai susiję ir su tam tikrais vartotojų asmeniniais privatumo apribojimais (Yan & Hong, 2018).

Autorius Hong vartotojų elgseną išskyrė į dvi pagrindines kategorijas: prisitaikomoji ir neprisitaikomoji elgsena. Šios elgsenos kategorijos ir joms būdingi bruožai pateikti 1.1 lentelėje.

1.1 lentelė. Vartotojų elgsenos kategorijos (Hong et al. 2017)

Table 1.1. Categories of user behaviour (Hong et al. 2017)

Vartotojų elgsenos klasifikacija			
Prisitaikomoji		Neprisitaikomoji	
Aplinka keičiama taip, kad būtų pritaikyta vartotojų poreikiams	Keičiama vartotojų elgsena, kad prisitaikytų prie aplinkos	Pranešimas apie diskomfortą ar nusiskundimai. Neveiklumas, jokių veiksmų neatlikimas.	Vartotojų buvimas patalpoje (pasyvi elgsena).
Atidaromi ar uždaromi langai. Nuleidžiamos žaluzės. Reguliuojami termostatai. Valdomas apšvietimas. Valdoma papildoma įranga.	Keičiamas vartotojų apsirengimo lygis (clo). Vartojami karšti / šalti gėrimai, maisto produktai. Keičiama darbo vieta, judėjimas erdvėje ieškant jaukios vietos aplinkoje.		

Prisitaikomoji elgsena apima vartotojų elgesį, siekiant pagerinti komforto sąlygas arba pačiam vartotojui prisitaikyti prie komforto sąlygų. Humphrey ir Nicol (1998), analizuodami šią kategoriją, teigia, kad vartotojas imsis visų įmanomų priemonių, kad prisitaikytų atitinkamoje aplinkoje. Kitaip tariant, jei

įvyksta diskomfortą sukeliančių pokyčių, žmonės elgiasi taip, kad sugrįžtų į savo komforto zoną.

Neprisitaikomoji elgsena – pasyvus vartotojų elgesys, kurį nusako vartotojų buvimas arba nebuvimas, neveiklumas arba išreiškiami skundai.

Poveikį bendram energijos suvartojimui taip pat turi ir vartotojų medžiagų apykaitos išskiriama šiluma ir sąmoningas jų aktyvumas. Vartotojai savo elgesiu sąveikauja su pastatų sistemomis, kad pagerintų asmeninį komforto lygį įvairiais galimais būdais. Delzendeš vartotojų elgseną pagal aktyvumą skirsto į pasyvią ir aktyvią elgseną (1.2 lentelę) (Delzendeš et al. 2017).

1.2 lentelė. Aktyvios ir pasyvios vartotojų elgsenos suskirstymas (Delzendeš et al. 2017)
Table 1.2. Active and passive occupancy behaviour division (Delzendeš et al. 2017)

Vartotojų elgsenos įtaka energijos suvartojimui			
Vartotojų statusas	Vartotojų elgsenos įtaka energijos suvartojimui	Energijos šaltiniai	
Vartotojų nebuvimas	–	–	
Vartotojų buvimas (pasyvi elgsena)	Metabolinė šiluma, išsiskirianti iš vartotojų	Vidiniai pritekiai	
	Naudojamos ŠVOK sistemos ir nustatymų ribos		
Aktyvus energijos naudojimas (aktyvi elgsena)	Naudojamas dirbtinis apšvietimas ir saulės šešėliavimas	Vidiniai pritekiai	Energijos vartojimas
	Naudojamos ŠVOK sistemos ir nustatymų ribos		
	Karšto vandens vartojimas		
	Prietaisų naudojimas		
	Langų varstymas ir pan.	Vėdinimas	

Pasyvi elgsena – tai elgsena, kurią lemia vartotojų buvimas ar nebuvimas pastate ir išskiriama šiluma, bei elgsena, kai vartotojo sąmoningi ar nesąmoningi veiksmai (pvz., jų buvimas patalpoje ir išskiriama metabolinė šiluma) nedaro įtakos pastato ar jo dalies energijos suvartojimui.

Aktyvi elgsena pasireiškia, kai vartotojai aktyviais veiksmais sąveikauja su pastatų inžinerinėmis sistemomis, kad užsitikrintų ir pagerintų šiluminį, vizualinį ir akustinį komfortą bei gerą patalpų oro kokybę ir savo savijautą. Tokie veiksmai

atliekami reguliuojant mikroklimato sistemas, naudojant elektros prietaisus, reguliuojant šėšėliavimo priemones, varstant langus, vartojant karštą vandenį ir pan.

Kitą vertus, VE priklauso ir nuo kelių pagrindinių išorinių veiksnių. Delzen-deh et al. (2017) išskyrė šiuos:

1. **Klimatas:**

- Lauko klimato parametrai – metų laikai, lauko oro temperatūra, drėgmė, krituliai, vėjas, saulės spinduliuotė, užterštumas ir kitos lauko klimato sąlygos.
- Pastatų mikroklimato parametrai – oro temperatūra, santykinė drėgmė, CO₂, lakieji organiniai junginiai, oro judėjimo greitis patalpoje ir kt.

2. **Savijauta** – vartotojo būseną, kuri gali lemti asmeninį prisitaikymą prie patalpų mikroklimato arba ergonomikos. Įtaką gali daryti ligos, nuotaika ir kt.

3. **Socialiniai santykiai** – priklausymas tam tikrai socialinei grupei, santykiai šeimoje, mokykloje, kitose mokymosi įstaigose, darbovietėse ar kitur įgytos patirtys.

4. **Architektūra, konstrukciniai elementai** – bene mažiausią įtaką daran-tis veiksnys, mat vartotojai praktiškai nedaro įtakos jau pastatyto pas-tato architektūriniais ar konstrukciniams ir kitiems inžineriniams sprendiniams, todėl vartotojo elgesys pasireiškia tik prisitaikymu prie architektūrinių sprendimų.

5. **Ekonominis aspektas** – vartotojų finansinė padėtis. Šis veiksnys turi ryškų poveikį vartotojų elgsenai, nes nepriteklus verčia vartotoją aktyviai taupyti energiją ar, atvirkščiai, jos suvartoti daugiau nei įprastai.

6. **Politika ir reglamentavimas** – valstybės politikų priimtos energijos taupymo priemonės ir jų reglamentavimas. Kaip an-tai, kai Lietuvos Respublikoje 2020 m. nuo kovo mėnesio dėl COVID-19 pandemijos buvo įvestas karantinas, kurio metu buvo apribota darbo biuruose ga-limybė ir ribotas tiesioginis asmenų kontaktas, galimybės patekti į par-duotuves, uždarytos kavinės, kitos pasilinksminimo ar susitikimų vie-tos, galiausiai apribota judėjimo laisvė Lietuvos Respublikos teritorijoje. Šie apribojimai buvo įvesti keletą kartų ir truko daugiau nei metus (paskutiniai ribojimai, susiję su COVID-19 pandemija, at-šaukti 2021-07-01).

Kiekvienas paminėtas išorinis veiksnys daro reikšmingą poveikį kalbant apie energijos suvartojimą. Be to, kuo pastatas mažesnis ar energetiškai efektyvesnis, tuo didesnė vieno žmogaus įtaka pastatui.

Apibendrinant galima pastebėti, kad energijos suvartojimas pastatuose kinta, atsižvelgiant į skirtingus individualius VE aspektus, kuriems dargi didelę įtaką

daro ir išoriniai veiksniai. Į tai būtina atsižvelgti atliekant vartotojų elgesio analizę ir prognozuojant tikėtiną vartotojų elgesį konkrečiuose pastatuose.


1.3. Vartotojų veiklos profiliai skirtinguose energijos modeliavimo įrankiuose

Dabartiniai energijos modeliavimo varikliai, tokie kaip TRNSYS, ESP-r, IES ar *EnergyPlus*, apskaičiuoja suvartojamos energijos kiekį pastatuose taikant vienodą skaičiavimo metodiką. Modeliuojant gaunama įvairi reikšminga informacija: šildymo, vėsinimo ir vėdinimo sistemų projektavimo, apšvietimo duomenys, CO₂ emisija, šilumos nuostoliai į aplinką, bendras energijos suvartojimas ir išlaidos, kt. Visgi galutinių rezultatų patikimumas yra labai susijęs su pradinio pastato modelio detalizavimo (kuris dažnai yra supaprastintas) tikslumu įvedant į programą. Pvz., *DesignBuilder*, viename iš pirmaujančių energijos modeliavimo įrankių, energinių sistemų grafikas yra programinės įrangos skyriuje „Veikla“. Šiame skyriuje numatyti tokie profiliai: užimtumas (norint pakeisti žmonių tankumą kiekvienoje zonoje), aktyvumo faktorius, apranga ir kompiuterių bei kitos įrangos naudojimas. Kitas plačiai naudojamas įrankis – *EcoDesigner* – turi mažiau užimtumo profilių, įskaitant vartotojų buvimo grafiką ir veiklos tipus, kurie lemia vidinius šilumos pritekįs, priklausomus nuo vartotojų. Galiausiai *Autodesk Revit Architecture* energetikos dalyje yra ribota vartotojų elgsenos grafikų pasiūla. Todėl dauguma specialistų, kurie modeliuoja energijos suvartojimą, energijos analizei parenka tokius užimtumo grafikus, kurie numatyti energijos modeliavimo programinėje įrangoje, nes neturi pakankamų žinių įvertinti galimą realų užimtumą.

Vartotojų elgsena išskirta pagal anksčiau tekste minėtas kategorijas ir aktyvumą. Kaupiant duomenis ir atliekant modeliavimą paprastai tiriami atskiri vartotojų elgsenos bruožai, o ne jų visuma. Vartotojų veiklos profiliai ar modeliai, kurie dažnai vadinami užimtumo modeliais, apibūdina vartotojų buvimą, nebuvimą ir judėjimą erdvėse. Šiuose modeliuose aprašomi įvairūs prisitaikomosios ir neprisitaikomosios elgsenos tipai, pavyzdžiui, žaliuzių reguliavimas, langų atidarymas, lempų perjungimas ir prietaisų naudojimas. Vartotojų veiklos modeliai susieja vartotojų buvimą ir veiklą bei jais vadovaujantis galima pritaikyti su šia veikla susijusių prietaisų, apšvietimo ar vandens naudojimą (Happle et al. 2018). Visi vartotojų profiliai priskiriami tam tikrai patalpų paskirčiai, pvz.: biurui, paroduotuvės, gydymo įstaigos ir pan.

Visos pasaulio šalys kultūriškai yra nevienodos, todėl vartotojų elgsena pastatuose taip pat yra nevienoda. Skirtingos šalys turi vartotojų buvimo valandinius profilius pastatuose, o jų neturinčios vadovaujasi kultūriškai panašių šalių grafikais. Tarp šių buvimo profilių pastebimi akivaizdūs skirtumai, priklausantys nuo

šalies. 1.1 paveiksle kaip pavyzdys pateikiamas ASHRAE, EN 16798-1:2019 bei Kinijos GB5018-2018 normose pateikiamų vartotojų profilių biurams palyginimas.



1.1 pav. Kinijos ir kitų valstybių normose pateikiamas vartotojų profilių biurams palyginimas


Fig. 1.1. Comparison of user profile norms for offices in China and other countries

Analizuojant profilius išryškėja tam tikri kultūriniai, klimato, ekonominiai ir kiti skirtumai. Iš pateiktų profilių labiausiai išsiskiria Kinijos modelis dėl mažiausių vartotojų aktyvumo svyravimų. Pagal šį profilį vartotojai praleidžia daugiausiai laiko biuruose. Taip pat matyti, kad per pietų pertrauką Kinijos vartotojų profilyje vartotojų užimtumas sumažėja 10 proc. – mažiau nei kitose valstybėse – tai atskleidžia, kad kultūriniai skirtumai išties daro įtaką pietų pertraukos trukmei.

Europos Sąjungos normatyve EN16798-1:2019 vartotojų profilis išsiskiria tuo, kad didžiausias vartotojų intensyvumas pasiekia 70 proc., o tuo metu ASHRAE ir GB50189-2018 profiliuose didžiausias intensyvumas siekia 90 proc. Atsižvelgiant į minėtus standartus, galima pastebėti tendenciją, kad maždaug pusė darbuotojų yra įpratę pietauti ne darbo vietoje.

DesignBuilder parinktyse atvirojo tipo biurams yra siūlomas vartotojų užimtumo grafikas, kurio užimtumas prasideda nuo 7:00 h ryto ir per 2 h pasiekia užimtumo piką, kuris siekia 100 proc. Taip pat skiriasi vartotojų intensyvumas pietų pertraukos metu – pagal profilį užimtumas sumažėja palyginus nedaug – iki 75 proc., po pietų pertraukos vėl pasiekia didžiausią užimtumą, o darbo diena baigiasi 17:00 h. Apibendrinant galima pastebėti, kad duomenys, nurodyti 1.2

paveikslo grafike, ir realūs vartotojų užimtumo grafikai pagal tyrimus, atliktus atvirojo tipo biuruose (Bielskus et al. 2019), gerokai skiriasi ir tarpusavyje nesutampa.



1.2 pav. Dienos vartotojų užimtumo grafikų palyginimas skirtinguose energijos modeliavimo įrankiuose su faktiniu užimtumu

Fig. 1.2. Comparison of daily user occupancy schedules in different energy modelling tools with actual occupancy

Iš 1.3 paveikslo matyti, kad faktinis vartotojų buvimas yra kelis kartus mažesnis, nei nurodoma normose (tiriamasis pastatas – A).

O'Brien savo atliktoje studijoje nagrinėjo ir lygino daugelio šalių nacionalinius reglamentus, kuriuose buvo išskirti profiliai biurams. Tyrimas apėmė tokias šalis kaip Australija, Austrija, Belgija, Brazilija, Kanada, Kinija, Danija, Anglija, Prancūzija, Vokietija, Vengrija, Indija, Pietų Korėja, Švedija, Šveicarija, JAE, JAV. Autoriai pastebėjo, kad šiuose profiliuose ryškių nesutapimų atsiranda būtent dėl kultūrinių skirtumų (O'Brien et al. 2020).

Paprastai didžiausias vartotojų užimtumas pasiekiamas per 1–2 h. Visgi tokiose šalyse kaip Brazilija, Singapūras ir Naujoji Zelandija iš karto pereinama iš visiškai laisvo iki visiškai užimtumo režimo – visa tai turi įtakos tolesniam energijos poreikių įvertinimui. Taip pat pastebėtas Anglijos reglamento ypatumas, kai įrangos veikimo profiliuose siūlomas 100 proc. veikimas nuo 17:00–19:00 h, nors paprastai tokiu metu vartotojų užimtumas yra mažas ir siekia nuo 25 proc. iki 50 proc. Tai yra visiškai neoptimalu, nes įrangos veikimas turi proporcingai mažėti kaip ir vartotojų skaičius biure.

Vertinant pietų pertraukos laiką, tokių valstybių kaip Australija, Brazilija, Naujoji Zelandija, Singapūras vartotojų profiliuose siūloma iš viso neišskirti pietų pertraukos, bet ją vertinti įrangos ir apšvietimo profiliuose. Tuo metu Indija ir JAV numato net 45 proc. darbo vietų užimtumo sumažėjimą pietų pertraukos metu. Taip pat studija parodė, kad daugelis valstybių pagal reglamentuose nustatytus profilius pasiekia 90–100 proc. patalpų užimtumą, o dar kitose studijose pabrėžta, kad nurodyti dydžiai yra gerokai didesni nei faktiniai duomenys. Eksperimentiškai Bielskus nustatė, kad faktinis užimtumas atvirojo tipo biure yra maždaug 3,5 karto mažesnis, lyginant su numatytais *DesignBuilder* užimtumo grafikais, ir 2,7 karto mažesnis nei nurodyti EN 16798-1:2019 standarte (Bielskus et al. 2019).

Realaus energijos vartojimo neatitikimas projektiniam energijos vartojimui visuomet pasireiškia, kai modeliuojamomis kompiuterinėmis programomis suskaičiuojami pastato energijos poreikiai. Projektiniai duomenys labai stipriai skiriasi nuo realaus suvartojimo dėl to, kad modeliavimo programos nepakankamai tiksliai vertina vartotojų buvimo pastate dinamiką (pasyvią elgseną) ir tam tikrų pastatų ar net vietovių vartotojų elgsenos specifiką (Menezes et al., 2012).

Taigi nors praktikoje egzistuoja skirtingi energijos prognozavimo įrankiai, visgi pastebima, kad prognozavimo įrankiai savo veikimą grindžia vienoda skaičiavimo metodika. Be to, analizių rezultatųvumui didelę įtaką daro subjektyvūs kultūriniai, klimato, ekonomikos ir pan. aspektai. Akivaizdu, kad taip kuriami vartotojų profiliai greičiau yra orientacinio pobūdžio, nei teikia didelę praktinę naudą. Tai pagrindžia ir tyrimų metu nustatyti įrankiais sukurtų prognozių ir faktinio vartotojų elgesio skirtumai.

1.4. Vartotojų elgsenos prognozavimo modeliai

Siekdami nustatyti vartotojų elgesio poveikį energijos suvartojimui bei ištirti suvartojimą lemiančius veiksniai mokslininkai taiko įvairius mokslinius modelius. Šiame skyriuje bus apžvelgti dažniausiai taikomi modeliai, atskleidžiant jų prielaidas ir trūkumus.

Vienas iš mokslininkų pamėgtų modelių duomenims tirti yra atlikti energijos suvartojimo palyginimus arba apklausas. Pagrindinis dėmesys buvo skiriamas vartotojų elgsenai biuruose stebėti, siekiant nustatyti reikšmingiausius kintamuosius. Sardonou (2008) taikė apklausų modelį, atkreipdama dėmesį į energijos suvartojimą ir šiluminį komfortą, kuriems įtakos turi rankiniu būdu valdomų langų naudojimas.

Vienas iš būdų pabrėžti ir ištirti vartotojų elgesio įtaką pastato energiniam naudingumui yra lyginti identiškių pastatų energijos suvartojimą. Socolow (1976) yra palyginęs kelių namų ūkių suvartojamų dujų kiekius tomis pačiomis

sąlygomis ir nustatęs, kad suvartojami energijos kiekiai skyrėsi iki 71 proc., o nurodyta priežastis buvo skirtingi vartotojų įpročiai (Socolow, 1976).

Tyrimų sritis, susijusi su vartotojų elgsenos pastatuose supratimu ir modeliaavimu, sparčiai vystosi (Schweiker, 2017), o gauti rezultatai suteikia aiškesnį supratimą apie vartotojų elgseną ir jos poveikį energijos sąnaudoms. Visgi tyrimuose vis dar yra spragų (Zhang et al. 2018). Kuriami vartotojų elgsenos deterministiniai ir statistiniai modeliai, kurie rodo priklausomybę nuo taikomų kintamųjų įvesties duomenų juos kuriant (Balvedi et al. 2018). Vis dar iššūkiu laikomas gaunamų duomenų konvertavimas ir integravimas į pastatų energinio modeliavimo priemones, siekiant sumažinti atotrūkį tarp prognozuojamo ir faktinio energijos suvartojimo pastatuose. Be to, būtų tikslinga atlikti tyrimus apie skirtingų vartotojų elgsenos tarpusavio ryšius, kad būtų sukurtos realistinės prielaidos energijos vartojimo pastatuose prognozėms kurti (Delzendeh et al. 2017). Tarptautinė energetikos agentūra taip pat nurodė, kad trūksta patikimų mokslinių metodų, kaip apibrėžti ir modeliuoti su energijos vartojimu susijusią vartotojų elgseną pastatuose (Hong et al. 2016).

Šiuo metu supratimas apie vartotojų elgsenos svarbą pastato projektavimo, naudojimo ir modernizavimo etapuose yra ribotas, todėl susiduriama su dideliais energijos vartojimo neatitikimais, lyginant sumodeliuotas ir faktines pastato charakteristikas (Hong et al. 2016). Dėl šios priežasties duomenų rinkimas energijos vartojimui prognozuoti, pastato naudojimo režimų, kaip ir vartotojų elgsenos keitimas yra kitas tvaraus energijos vartojimu ir pastato informaciniu modeliu (BIM) grindžiamo projektavimo iššūkis. Moustafa et al. (2017) savo tyrime įvertino greitai besikeičiantį vartotojų elgesį siekiant šiluminio komforto ir energijos vartojimo efektyvumo.

Vartotojų elgsenos grafikai energinio modeliavimo priemonėse visada nurodomi kaip statiniai elementai. Jie nurodomi visų tipų pastatuose, neišskiriant atvirojo tipo biurų bei neatsižvelgiant į vartotojų darbo profilius, kurie daro įtaką skirtingiems vartotojų buvimo grafikams. Realybėje susiduriama su kitokia situacija, kai siekiant pagerinti komforto sąlygas vartotojai pereina į aktyvų reguliavimą. Siekiant ištirti realią vartotojų elgseną ir gautus profilius bei juos taikyti modeliavimo procesuose, taikomi skirtingi vartotojų elgsenos modeliavimo modeliai.

Remiantis Mahdavi et al. (2017) vartotojų elgsenos modelius būtų galima suskirstyti į 3 pagrindines grupes, kurios pateiktos 1.3 lentelėje.

Nors tyrimuose taikomi skirtingi metodai, tačiau kiekvienas jų turi savų privalumų ir trūkumų. Mahdavi et al. (2017) aptaria kiekvieną iš jų toliau.

Grafikai – pagrindinis šio metodo privalumas yra tai, kad jis gan paprastas ir jam reikalingas tik vienas duomenų tipas, tai yra suplanuota darbo diena ar savaitė. Standartizuota darbo savaitė palengvina tolesnį duomenų interpretavimą. Dėl to plačiai taikomas energinio modeliavimo priemonėse bei rekomenduojamas įvairiuose standartuose bei reglamentuose.

1.3 lentelė. Vartotojų elgsenos modeliai (Mahdavi et al. 2017)

Table 1.3. Occupancy behaviour patterns (Mahdavi et al. 2017)

Vartotojų elgsenos modeliai		
Prisitaikomosios	Neprisitaikomosios	Modeliuojantis buvimas
• Pastatų grafikai • Bernulio modelis • Diskretinis Markovo laiko modelis • Diskretinis Markovo įvykių modelis • Regresiniai metodai	• Grafikai • Grafikai vartotojams prognozuoti • Išgyvenimo, patirties metodai	• Vartotojų grafikai • Diskretiniai Markovo laiko modeliai • Išgyvenimo, patirties metodai

Bernulio procesuose pateikiama prisitaikomoji vartotojų elgsena su aplinkos kintamaisiais. Bernulio procesų apribojimas yra tas, kad modeliai kuriami remiantis pastato komponento būsenos (pvz., lango būsenos) stebėjimais, o ne faktine sąveika su juo (lango atidarymas ar uždarymas). Kitaip tariant, šiuose modeliuose aprašoma ne lango atidarymo ar uždarymo tikimybė, o tikimybė, kad langas bus atidarytas. Be to, Bernulio procesuose nepaisoma ypatingų užimtumo profilių.

Diskrečių įvykių ir laiko Markovo modeliai – modeliai, kuriuose susiejami konkretūs vartotojų elgsenos taškai su išoriniais veiksniais, kurie yra tiesiogiai susiję su vartotojų elgsena, pvz., patalpų oro užterštumas. Tačiau, kai yra klaidos tikimybė, ieškoma vartotojų elgsenos atitinkamo įvykio (elgsenos taško atitikmens), kuris priklauso nuo laiko sąveikos ar išorinių veiksnių. Kitas metodo apribojimas yra tas, kad jo prognozuojamas vartotojų elgesys tiesiogiai priklauso nuo išorinių veiksnių prognozių tikslumo.

Regresiniai metodai – susiejami vartotojų elgsenos konkretūs taškai su išoriniais veiksniais atsižvelgiant į laiką.

Išgyvenimo metodai – juos taikant numatomas periodas, kai vartotojo ir sąveikaujančios sistemos būseną lieka nepakitusi. Ši charakteristika leidžia modeliavimo metodą tinkamai perkelti ir į kitų pastatų modelius.

Vienas iš dažniausiai taikomų modelių yra prisitaikomosios elgsenos modeliavimas. Todėl autoriai šį modelį nagrinėja iš įvairių perspektyvų siekdami patobulinti energijos prognozavimo, reguliavimo tikslumą ir tirdami vartotojų elgseną.

Zhun Yu darbe taikė modelį, skirtą vartotojų elgsenos įtakai pastato energijos vartojimui ištirti. Šis metodas pagrįstas pagrindine duomenų gavybos technika (klasterinė analizė). Norint pašalinti duomenų neatitikimus, mažiausias ir didžiausias normalizavimas atliekamas kaip duomenų išankstinio apdorojimo žingsnis prieš juos sugrupuojant. Klasterinėje analizėje kaip skirtingų požymių svertiniai

koeficientai naudojami pilkieji reliaciniai laipsniai ir dviejų veiksmų aktualumo matas (Zhun et al. 2010).

Johnson vartotojų elgesiui modeliuoti taikė Markovo grandinę pagrįstą statistinį modelį. Jo tikslas buvo atskleisti, kaip sukurtas vartotojų elgesio modelis imituoja atskirus vartotojus, siekiant parodyti, kaip vartotojas gali sąveikauti su viso pastato energijos poreikiais (Johnson et al. 2014).

Tyrimai rodo, kad siekiant prognozuoti užimtumą pastatuose, kai kurie autoriai bando pritaikyti ekstremalaus mokymosi mašininių modelį (ELM). Pavyzdžiui, Chen šio metodo pagrindu sukūrė vyniojimo metodą (angl. *Wrapper Method*), kuris skirtas pasirinkti geriausią aplinkos parametrų savybių rinkinį, ir pateikė sintezės sistemą, skirtą užimtumui pastatuose įvertinti (Chen et al. 2016).

Wolf išanalizavo ir nustatė, kad anglies dioksido (CO_2) lygis patalpose priklauso ne tik nuo žmonių skaičiaus jose, bet ir nuo žmonių aktyvumo lygio (Wolf et al. 2018). Todėl tyrime pasiūlytas naujas modelis, pagrįstas CO_2 korekcija siekiant įvertinti vartotojų aktyvumo lygį. Šiame darbe nagrinėjami paslėpti Markovo modeliai (HMM) ir autoregresiniai paslėpti Markovo modeliai (ARHMM). Pastarieji dar vadinami *Markov* perjungimo modeliais (Wolf et al. 2018). Pereira ir Ramos taikė statistinės analizės įrankius (angl. *Change Point Analysis* – CPA), skirtus vartotojų veiksams gyvenamuosiuose pastatuose ištirti, naudodant patalpų aplinkos stebėjimo sistemos duomenis, įskaitant temperatūrą, santykinę drėgmę ir anglies dioksidą (Pereira et al. 2018). Šio modelio principas grindžiamas tuo, kad vartotojų veiksmai sukelia staigius paminėtų parametrų poslinkius, nukrypimus. Atlikus parametrų pokyčių analizę nustatomas pokyčių skaičius laike ir tikslūs pokyčių momentai, kurie vėliau yra susiejami su vartotojų elgsena. Masood vidaus patalpų užimtumui įvertinti pasiūlė naują modelį, vadinamąjį hibridinio funkcinio mastelio ekstremalaus mokymosi mašininių modelį (angl. *Hybrid Feature-Scaled Extreme Learning Machine* HFS-ELM) (Masood et al. 2018).

Lyginant su deterministiniais metodais, kuriuose atsižvelgiama į stochastinį vartotojų elgesį, gali sukurti realistiškesnius energijos vartojimo profilius miesto ar rajono lygmenyje. Tačiau miesto mastu atliekant pastato modernizavimo potencialo analizę, siekiant įvertinti bendrą metinį energijos taupymą, greičiausiai nereikia sudėtingo statistinio vartotojų elgsenos modelio. Statistinį vartotojų modelį galima pritaikyti rajoninių energetikos sistemų projektavimui, kuris reikalauja realistiškų ir patikimų įvertinimų (Happle et al. 2018).

Chen pateikė naują (ang. *Novel Ensemble*) ELM modelį, skirtą vartotojų elgsenai atpažinti naudojant išmaniųjų telefonų ryšio galimybes, tokias kaip *Wi-Fi*, *Bluetooth* ir kt (Chen et al. 2019). Užimtumo lygiui prognozuoti ir energijos suvartojimui apskaičiuoti pastate Wei taikė akląjį sistemų identifikavimą ir dirbtinius neuroninius tinklus (Wei et al. 2019). Jiang pasiūlė modelį, vadinamą atnaujintu kolektyvinio ekstremalaus mokymosi mašininio mokymosi technika (angl. *novel ensemble extreme learning machine technique*), kuri leidžia įvertinti

užimtumo lygi pagal anglies dioksido koncentraciją (Jiang et al. 2020). Rezultatai parodė, kad prognozavimo modeliai, apimantys ekstremalaus mokymosi mašininį modelį (angl. *extreme learning machine*), rodo didelį tikslumą ir patikimumą. Tokie duomenimis pagrįsti metodai tapo populiarūs dėl jų galimybių atskleisti statistinius modelius be ekspertų įsitraukimo (Sun et al. 2020).

Modeliai, pagrįsti Markovo grandine, buvo taikomi daugumoje analizuotų tyrimų, imituojant vartotojų buvimą arba veiklą (Yamaguchi et al. 2003; Page et al. 2008; Virote et al. 2012; Dobbs et al. 2014; Liu et al. 2019). Kai kurie kiti rečiau taikomi metodai apima Monte Karlo, regresijos ir laiko eilučių modelius (Wang et al. 2015), dinaminę Markovo laiko lango išvadą (angl. *Dynamic Markov Time-Window Inference*), autoregresyvų slenkančio vidurkio algoritmą (angl. *Auto-Regressive Moving Average*) ir atraminių vektorių regresijos algoritmą (angl. *Support Vector Regression models*) (Wang et al. 2017), Gauso metodą (Liu et al., 2019), (Kim et al. 2019), agento pagrindo algoritmą (angl. *Agent-Based Models*) (ABM) (Jia et al. 2020), dirbtinius neuroninius tinklus (Lam et al. 2009; Dong et al. 2010; Chokwitthaya et al. 2019).

Daugumoje tyrimų, susijusių su vartotojų užimtumo duomenų kaupimu ir modeliavimu, daugiausia dėmesio skiriama vartotojų buvimo elgesiui analizuoti: tiriamas laikas, kai vartotojas pradeda dirbti, baigia darbą, eina pietauti ir grįžta po pietų (Yamaguchi et al. 2003; Page et al. 2008; Wang et al. 2011; Chen et al. 2014). Kai kuriuose tyrimuose buvo pateikti užimtumo skaičiaus nustatymo algoritmai, pagrįsti aplinkos duomenų (t. y. CO₂, bendrųjų lakiųjų organinių junginių, santykinės drėgmės, lauko temperatūros, rasos taško, judesio, akustikos) analize iš jutiklių (Lam et al. 2009; Dong et al. 2010; Dong et al. 2011; Han et al. 2012; Sandels et al. 2015). Dažnai tyrimuose derinami aplinkos matavimų duomenys, energijos suvartojimo duomenys ir vartotojų užimtumo stebėjimas (Ai et al. 2014; Wanget al. 2015). Tyrimuose modeliuojant individualizuotus užimtumo profilius, be aplinkos duomenų, buvo tiriama durų varstymo būseną, pagal kurią prognozuotas vartotojų užimtumas (Yang et al. 2014).

Atliekant vartotojų aktyvumo tyrimus, buvo tiriama kiekviena darbo vieta su PIR jutikliais ir energijos suvartojimas naudojant maitinimo kištukų skaitiklius (Milenkovic et al. 2013). Taip pat analizuotas ir stebėtas šiluminės energijos perdavimas į patalpas, siekiant sumažinti energijos suvartojimą prieš darbo dieną ir kuo geriau panaudoti sukauptą šiluminę energiją darbo dienos metu (Dobbs et al. 2014a; Dobbs et al. 2014b). Taip pat buvo taikomi metodai, pagrįsti *Wi-Fi* ir *Bluetooth* signalų stiprumas su vartotojų išmaniaisiais prietaisais, metodai skirti energijos suvartojimui nustatyti realiuoju laiku, kartu taikoma vietos nustatymo funkcija (Jain et al. 2016; Wang et al. 2017; Salimi et al. 2019; Frei et al. 2020). Netiesioginiam užimtumo stebėjimui ir duomenų kaupimui apie CO₂, temperatūrą ir santykinę drėgmę buvo naudojami tarpusavyje sąveikaujančių prietaisų tinklai, skirti keisti informacija tarpusavyje (Vanus et al. 2019).

1.4 lentelėje pateikti kitų autorių tekste nepaminėtų vartotojų užimtumo tyrimai. Lentelėje pateiktas autorių taikytas modelis, vartotojų stebėjimo laikotarpiai ir vartotojų užimtumui prognozuoti taikyti kintamieji.

1.4 lentelė. Vartotojų profilių prognozavimo metodai ir atliktų studijų apžvalga
Table 1.4. User profile prediction methods and review of studies

Šaltinis	Taikytas modelis	Atliktų tyrimų laikotarpis	Kintamieji
1	2	3	4
Yamaguchi et al. 2003	Markovo grandinė	Nenurodyta	Laikai, kai vartotojas pradeda ir baigia darbą, eina pietauti, grįžta po pietų
Page et al. 2008	Markovo grandinė	Daugiau nei 2 metai, iš jų pritaikomi 6 mėnesių duomenys	Vertinamas daugiausia buvimas darbo vietoje
Wang et al. 2011	Gauso mišinio modeliu pagrįsti paslėpti Markovo modeliai	Buvimas ar nebuvimas, laiko intervalas – 15 min įprastomis darbo dienomis nuo 8:00 h iki 17:00 h	Atvykimo ir išvykimo laikas, pietų laikas, tarpinio pasivaikščiojimo laikotarpiai
Chen et al. 2015 ir 2014	Markovo grandinė	10 savaitių, kas 2 min	Atvykimo ir išvykimo laikas, vartotojų skaičius
Lam et al. 2009 ir Dong et al. 2011	Neuroniniai tinklai, atraminių vektorių mašinos ir paslėpti Markovo modeliai	6 savaitių ir 3 savaitių periodai. Užimtumas fiksuojamas darbo dienomis nuo 08:00 h iki 18:00 h	CO ₂ , CO, TVOC, RH, lauko temperatūra, rasos taškas, mažos dalelės, judėjimas, akustika
Dong et al. 2010	Artimiausio atstumo Markovo grandinė	2 mėnesių laikotarpis, užimtumo duomenys nuo 08:00 h iki 18:00 h	CO ₂ , vidaus temperatūra, santykinė drėgmė, akustika, apšvietimas ir judėjimas
Han et al. 2012	Autoregresyvus paslėptas Markovo modelis, sumaišytoji Markovo grandinė	1 metai	CO ₂ , CO, TVOC, RH, lauko patalpos, drėgmė, oro greitis, vartotojų buvimas

1.4 lentelės tęsinys

1	2	3	4
Virote et al. 2012	Markovo grandinė	Nenurodyta	Buvimas kambaryje, šviesų įjungimas ir išjungimas
Milenkovic et al. 2013	Sluoksniuose paslėptas Markovo modelis	Daugiau nei 100 h duomenų, gautų iš įvairių patalpų tipų	Staliniai infraraudonųjų spindulių jutikliai (PIR) ir maitinimo kištuko matuokliai
Dobbs et al. 2014a ir 2014b	Markovo grandinė	40 h	Gyventojų buvimas, lauko ir grunto temperatūrų šilumos perdavimas į bendrą erdvę
Yang et al. 2014	Regresijos, laiko eilučių, stochastinių procesų modeliavimas	2 mėnesių ir 6 mėnesių laikotarpiai. Nuotraukos buvo daromos kas 10 s	Apšvietimas, garsai, judėjimas, CO ₂ , vidaus temperatūra, santykinė drėgmė, PIR, durų atidarymo ir uždarymo padėtis
Ai et al. 2014	Autoagresyvus paslėptasis Markovo modelis	Kas 20 s penkias dienas per savaitę. Tyrimų trukmė – 2 savaitės	CO ₂ , RH, vidaus temperatūra, oro judrumo greitis, vartotojų užimtumas
Sandels et al. 2015	Markovo grandinė	18 mėnesių	Vidaus temperatūra; tiekiamo oro srautas, patalpų oro slėgis
Wang et al. 2015	Markovo grandinė – Monte Karlas ir polinominė regresija	2012–2014 m. laikotarpis nuo pirmadienio iki penktadienio su 10 min intervalu	Gyventojų buvimas, energijos suvartojimas
Jain et al. 2016	Afiniteto sklidimas ir Markovo grandinė	Nenurodyta	Belaidžio ryšio signalai iš vartotojų įrenginių, vartotojų buvimas
Wang et al. 2017	DMTWI, ARMA and SVR	9 dienos. Belaidžio ryšio įrenginių nuskaitymo dažnis yra 1 min	Vartotojų buvimas
Salimi et al. 2019	Markovo grandinė	6 savaitės, taikomas 3 savaitių laikotarpis	Vartotojui pritaikytas metodas, taikomas skirtingų objektų padėčiai apskaičiuoti
Lee et al. 2019	Markovo garandinės ir Gauso modelis	Nenurodyta	Stebėta: miegas, maisto gaminimas, laisvalaikis ir kt.

1.4 lentelės pabaiga

1	2	3	4
Lee et al. 2019	Dirbtiniai neuro- niniai tinklai (ANN)	24 h grafikas, kas 10 min	Lytis, amžius, profesija, pajamos, išsilavinimas ir užimtumo laikotarpis
Chen et al. 2016	ELM, SVM, ANN, KNN (K artimiausioji kai- mynystė), LDA, CART	32 dienos	CO ₂ ir vartotojų buvimas
Masood et al. 2018	Hibridinės ypaty- bių atrankos Ekstremalaus mo- kymosi mašininis modelis (HFS- ELM)	28 dienos	CO ₂ , vidaus temperatūra, santykinė drėgmė ir varto- tojų buvimas
Bielskus et al. 2020	Nuosekliojo ryšio ekstremalaus mo- kymosi mašininis modelis su dife- rencialinės evo- liucijos optima- zacija (DE- OSELM)	3 mėnesiai, kas 5 min	CO ₂ , vidaus temperatūra, santykinė drėgmė ir varto- tojų buvimas
Motuzienė et al. 2021	Ekstremalaus mo- kymosi mašininis modelis (ELM) su optimizacijomis: genetinis algorit- mas (GA) ir imi- tuoto atkaitinimo (SA) optimizacija	3 mėnesiai, kas 5 min	CO ₂ ir vartotojų buvimas
Motuzienė et al. 2022	Ekstremalaus mo- kymosi mašininis modelis su (ELM) imituoto atkaiti- nimo (SA) opti- mizacija	7 mėnesiai, kas 5 min	CO ₂ ir vartotojų buvimas

TVOC – bendras lakiųjų organinių junginių kiekis (angl. *Total Volatile Organic Compounds*);

RH – santykinė drėgmė (angl. *Relative Humidity*);

LDA – tiesinė diskriminacinė analizė (angl. *Linear Discriminant Analysis*);

CART – klasifikavimo ir regresijos medžiai (angl. *Classification And Regression Trees*).

Iš 1.4 lentelės matyti, kad dauguma atliktų tyrimų pabrėžia tinkamesnio ir tikslesnio vartotojų profilių prognozavimo modelio poreikį. Visi aptarti modeliai rodo didelį prognozavimo tikslumą ir galimybes, bet visi aptarti modeliai turi ir trūkumų. 1.4 lentelėje vienas iš esminių aptartų tyrimų rodiklių patikimam prognozavimui yra duomenų kiekis ir jų kokybė. Todėl neturint pakankamai patikimų duomenų, modelio prognozavimas tampa nepatikimas. Gyvenamuosiuose pastatuose energija vartojama esant nuolatinėms apkrovoms, pagal tam tikrą modelį atsiranda ir suvartotos energijos kiekiai, todėl šis kintamumas yra stabilus. Pvz., mišrios paskirties pastatuose energijos poreikiai nuolat keičiasi, tad šie svyravimai lemia ir netikslų prognozavimą. Šiuo metu siūlomi modeliai turi apribojimų, jie apima ribotus matavimo laikotarpius. Be to, jie nevertina sezoninių skirtumų tarp skirtingo elgesio scenarijų ir negali visiškai atspindėti statistinio gyventojų elgesio pobūdžio.

1.5. Dirbtinio intelekto taikymas pastatų projektavimo ir eksploataavimo etapais

Taikant kompiuterines programas pastatų suvartojamos energijos kiekiui prognozuoti, tokias kaip *DesignBuilder*, *TRNSYS*, *Energy Plus* ar į jas panašias, dėl programos riboto lankstumo visuomet pastebimas energijos suvartojimo neatitikimas lyginant faktinio suvartojimo kiekius su prognozuotais ar numatytais energijos kiekiais. PIM (PIM – pastatų informacinis modelis) programos modeliuoja pagal apibrėžtas fizikines formules ar kito pastato faktinį elgesį, neatsižvelgiant į realų vartotojų elgesį.

Dirbtinio intelekto taikymas projektavimo etapu yra tik pirmuose tyrimų etapuose. 1.5 lentelėje pateikti autoriai, kurie taikė dirbtinį intelektą projektavimo etape. Nurodytoje lentelėje pateiktas energijos suvartojimo prognozavimas pastatuose priklausomai nuo vartotojų elgsenos. Beveik visi autoriai paminėjo esamas problemas ir šių modelių taikymo galimybes šiandieninėje situacijoje.

Pagal atliktą mašininio mokymosi modelio taikymą projektavimo etapuose Hong išskyrė vartotojų elgsenos integravimą į projektavimo fazę, kad dėl nepakankamos informacijos apie vartotojų elgseną kiekio ši taikymo sritis yra nepakankamai ištirta (Hong et al. 2020). Viena pastate veikianti sistema nesuplanuoja, kad gauti duomenys būtinai tiks ir kitiems pastatams.

Anksčiau pastebėta, kad dirbtinis intelektas pastato projektavimo ir naudojimo etape dažniausiai taikomas pastatų suvartojamos energijos kiekiui sumažinti, tai yra ŠVOK sistemos reguliuojamos pagal lauko ar vidaus temperatūras, taip pat ir prognozuojant vartotojų komfortą, šį ŠVOK sistemų ir dirbtinio intelekto raidos skirstymą atliko Chi-Cheng (2019). Dirbtinis intelektas, dažniausiai taikomas

pastatų ŠVOK valdyti, turi didelę ekonominę naudą, bet pastatų, kuriems taikomas dirbtinis intelektas pasitaiko ypač retai.

1.5 lentelė. Dirbtinių neuroninių tinklų taikymas pastatų projektavimo etape

Table 1.5. Using artificial neural networks in the building design phase

Šaltinis	Tyrimo tikslas	Taikyti modeliai		ANN kintamųjų kiekis
		Statistiniai modeliai	Projektavimo modeliai	
1	2	3	4	5
Zhou et al. 2015	Prognozavimas – valandiniai dienos apšvietos lygiai ir valandiniai energijos suvartojimo kiekiai	SVM, PCA	<i>EnergyPlus</i>	81
Ioannis et al. 2015	Patalpų vizualinio komforto sąlygų gerinimas, daugiau dėmesio skiriamas biurams	FFNs, SVM, RF, palyginimui KNNs	DA ir DGP	DA – 12 kintamųjų, DGP – 15 kintamųjų
Alshibani et al. 2017	Energijos suvartojimo sąnaudos priklausomai nuo architektūrinių sprendinių (atitvaros, vieta ir kt.)	ANNM	3D – N/A	Pastato vietovė, sistemos, plotai, langai ir kitos atitvaros, taip pat vartojų amžius ir jų skaičius
Lorenz et al. 2017	Prognozuojamos dienos apšvietos variacijos dėl lango matmenų	ANN	<i>Diva for Rhino</i>	-
Goufeng et al. 2019	Šiluminio komforto prognozavimo tikslumo pagerinimas	ANN	Revit API, EXCEL	Temperatūra, RH, oro judrumo greitis, aktyvumo tipas, CLO, lytis, amžius, žmonių ūgis ir masė
Ahmed et al. 2019	Suvartojamos energijos kiekio mažinimas tarp modeliuotų suvartojamos energijos kiekių ir realaus pastato suvartojamos energijos kiekio	ANN	<i>Revit</i> ir <i>revit</i> papildinys <i>Insight360</i> (<i>EnergyPlus</i> bazė)	-

1.5 lentelės pabaiga

1	2	3	4	5
Re Cecconia et al. 2019	Energijos poreikių mažinimo prognozavimas atliekant aplinkos analizę	ANN	GIS (Geografinė informacinė sistema)	Žiemos dienolaipsniai, statybos metai, visas paviršius, tūris, dispersanto paviršius, langai, grindys
Tianzhen Hong et al. 2020	Apžvalginė publikacija, kurioje aprašomos ANN ir BIM tendencijos pastato gyvavimo cikle	-	-	-
Ying Hong et al. 2020	Išbandyti statybos sąnaudų funkcijos prognozę	ANNs	-	7

FFNs – perdavimo tinklams (angl. *for Feedforward Networks*);

SVM – atraminių vektorių mašininis modelis (angl. *Support Vector Machines*);

RF – atsitiktiniai miškai (angl. *Random Forest*);

KNNs – K artimiausioji kaimynystė (angl. *K-Nearest Neighbors*);

ANNM – dirbtiniais neuroniniais tinklais pagrįstas modelis (angl. *Artificial Neural Network-Based Model*).

Šią situaciją lemia kelios priežastys ir ateities iššūkiai:

- dirbtinio intelekto ir ŠVOK specialistų trūkumas. Trūksta ŠVOK specialistų, kurie suprastų pastatų ŠVOK sistemas ir energijos taupymo potencialą bei gebėtų išmokyti dirbti su dirbtinio intelekto programomis;
- projektavimo etape dirbtinio intelekto pritaikymas yra sudėtingas ir kompliktuotas dėl dirbtinių neuroninių tinklų ir projektavimo programų komunikacijos nesuderinamumo;
- kibernetinio saugumo aspektai. Dirbtinis intelektas bus pasiekiamas iš bet kurios pasaulio vietos, taip pat ir ir pažeidžiamas;
- pradinės investicijos yra didesnės nei šiuo metu priimtose tradicinės ŠVOK sistemos;
- nėra sukaupta pakankamai reikiamų duomenų, kuriuos būtų galima panaudoti vertinant ir taikant dirbtiniu intelektu grįstas programas. Taip yra dėl to, kad esami pastatai nekaupia duomenų, o galintys šiuos duomenis kaupti nėra pritaikyti dirbtiniam intelektui. Be to, vieno pastato duomenis ne visada bus galima pritaikyti kitam pastatui dėl vartotojų elgsenos, kuri dažnai yra nulemta įmonės vidaus taisyklių ir pačių vartotojų specializacijos ir atliekamos veiklos.

Šios disertacijos tikslas – pritaikyti mašininio mokymosi modelį su optimizacijomis ŠVOK sistemai reguliuoti atvirojo tipo biurams, siekiant sumažinti suvartojamos energijos kiekį. Vėdinimo sistemos modeliavimas atliekamas *Matlab* aplinkoje. Šis metodas gali būti taikomas tiek visam pastatui, tiek tik tam tikrai jo daliai.

Panašų tyrimą atliko Zakula programoje TRNSYS. Minėtu atveju buvo atlikta patalpų moduliacija, o *Matlab* aplinkoje buvo sumodeliuotas *Adaptive MPC* modelis (Zakula et al. 2014). Rezultatai parodė šio modelio perspektyvas ir platų pritaikomumo spektrą. Siekiant pritaikyti dirbtinius neuroninius tinklus, literatūros apžvalgoje nagrinėta Ilambirai publikacija, kurioje tarpusavyje palyginti dviejų tipų patalpų VAV valdikliai. Vienas iš jų yra PID valdiklis, o kitas – su dirbtiniais neuroniniais tinklais. Autorius pastebėjo, kad su antruoju valdikliu buvo išvengta reguliavimo svyravimų, kurių susidaro su PID reguliatoriumi. Todėl iš atlikto tyrimo autorius mato valdiklių naudą ir pritaikomumą su dirbtiniais neuroniniais tinklais. Šie valdikliai turi pranašumų nustatytiems parametrų palaikyti išlyginant svyravimus (Ilambirai et al. 2019). Wang vėdinimo sistemoje su vėsinimo funkcija ieškojo optimaliausių nustatymo taškų taikant genetinį algoritmą (Wang et al. 2000). Huang et al. (2009), Afram et al. (2017), Fan et al. (2010) tyrinėjo vėdinimo sistemas su VAV sklendėmis, pastatuose palaikant vėsos ar šiluminį komfortą.

1.6. Pirmojo skyriaus išvados ir disertacijos uždavinių formulavimas

Atlikus mokslinių tyrimų apžvalgą buvo nustatyta, kad:

1. Vartotojų elgsena yra skirstoma ir klasifikuojama į prisitaikomąją ir neprisitaikomąją, taip pat pasyvią ir aktyvią.
2. Vartotojų elgsenai poveikį daro išoriniai veiksniai, pvz., klimato, savijautos, socialiniai, architektūriniai, ekonominiai, politiniai.
3. Standartizuoti vartotojų užimtumo grafikai, kurie taikomi modeliuojant pastatų suvartojamos energijos kiekius, naudojami kiekvienos valstybės priimtuose reglamentuose. Iš ASHRAE, EN 16798-1:2019 bei Kinijos GB5018-2018 normose pateikiamų vartotojų profilių biurams palyginimo pastebimas skirtumas, kuris gali siekti net iki 3 ir daugiau kartų.
4. Mašininio mokymosi modelių taikymas pastato eksploatacijos laikotarpiu yra vienas iš dažniausiai nagrinėjamų valdymo modelių, turinčių didelį ateities potencialą.

5. Daugelis autorių nagrinėjo viso pastato ŠVOK sistemas, taikant mašininio mokymosi modelius prognozuojant, optimizuojant komforto lygio palaikymą ir sutaupomos energijos kiekius. Dar mažesnė dalis autorių nagrinėjo vėdinimo sistemas su VAV sklendėmis, kurios palaiko pastato temperatūrą, CO₂ ir santykinę drėgmę, sistemos optimalių nustatymų nustatymą.

Išnagrinėjus kitų autorių atliktus tyrimus pastebėta, kad yra tikslinga taikyti dirbtinių intelektu paremtas programas dėl vartotojų elgsenos veiksmų prognozavimo ir ŠVOK sistemos atsako. Siekiant sukurti programą, kuri paremta dirbtinio intelekto algoritmu vartotojų prognozei įgyvendinti, reikia spręsti šiuos uždavinius:

1. Atlikti literatūros analizę apie vartotojų elgsenos įtaką pastato energijos suvartojimui ir vartotojų elgsenai įtaką darančius veiksnius.
2. Atlikti eksperimentinius tyrimus atvirojo tipo biuruose. Sukaupiti, sugrupuoti pastatų mikroklimato ir pasyviosios vartotojų elgsenos duomenis.
3. Patikrinti pasirinktųjų matematinių modelių vartotojų elgsenos prognozavimo kokybinį patikimumą ir išrinkti tinkamiausią modelį tęsiant tyrimus.
4. Taikant kompiuterinę programą *Matlab* su mašininio mokymosi metodu, praplėsti matematinį modelį vėdinimo sistemos valdymo optimizavimui (AI-VAV), imituojant atvirojo tipo biurą, pritaikant turimus eksperimentinius ir vartotojų elgsenos duomenis.
5. Patikrinti sukurtojo AI-VAV modelio gautų rezultatų patikimumą kiekybiniu ir kokybiniu aspektais. Įvertinti AI-VAV modelio energijos taupymo potencialą, lyginant su dažniausiai pastatuose taikomomis CAV ir VAV sistemomis.


Duomenys ir tyrimo metodika

Šiame skyriuje pristatomas vėdinimo sistemos oro kiekio reguliavimas taikant mašininio mokymosi metodą su optimizavimo funkcija. Mašininio mokymosi modelis – ekstremalaus mokymosi mašininis modelis (ELM) su optimizacijomis imituoto atkaitinimo (SA) ir genetiniu algoritmais (GA). Optimizacijos taikymo tikslas – gautus duomenis, pasižyminčius dideliu nuokrypiu, palyginti su kaimyniniais duomenimis. Optimizuoti duomenys perduodami į ELM ir pagal perduotus duomenis apmokomas algoritmas. ELM tikslas – pagal gaunamus kintamuosius prognozuoti netolimą ateitį ir atitinkamai koreguoti vėdinimo sistemos oro kiekius.

Viso disertacijos tyrimo metodika pateikta grafiškai 2.1 paveiksle. Šis darbas susideda iš trijų pagrindinių etapų, tai yra:

1. Eksperimentiniai tyrimai objektuose. Duomenų rinkmenos kaupimas ir analizė.
2. Vartotojų elgsenos prognozavimo modelio analizė ir validavimas.
3. Pasiūlytas AI-VAV modelis pastato vėdinimo sistemai valdyti, siekiant sumažinti suvartojamos energijos kiekį.

Skyriaus tematika paskelbti du autoriaus straipsniai (Bielskus et al. 2020; Motuzienė et al. 2021).



2.1 pav. Baigiamojo darbo tyrimo metodinė schema
 Fig. 2.1. Methodical scheme of the dissertation

2.1. Tiriamieji objektai

Faktiniam užimtumo profilių tyrimui buvo pasirinkti biurų paskirties tvarūs ir energiją taupantys pastatai su atvirojo tipo biurų patalpomis. Atvirojo tipo biurai pasirinkti todėl, kad darbo vieta nėra priklausanti aiškiai indentifikuojamam asmeniui ir tokiu atveju tyrimas atliekams ne individualiems asmenims, o jų grupei. Kita priežastis yra tai, kad vis daugiau įmonių renkasi atvirojo tipo biurus, nes populiarėja nuotolinis darbas ir nebereikalingas biuras visiems darbuotojams vienu metu. Pagrindiniai pastatų duomenys pateikti 2.1 lentelėje.

Pastatuose mikroklimato ir vartotojų elgsenos fiksavimą atliekant COVID-19 laikotarpiu, ypač sudėtinga buvo pateikti į pastatų vidų, nes biurų savininkai, nuomininkai nenorėjo įsileisti dėl galimų rizikų, nepaisant to, kad buvo imtasi visų atsargumo priemonių ir laikytasi valstybinių institucijų nurodymų.

2.1 lentelė. Tiriamųjų pastatų pagrindiniai rodikliai

Table 2.1. Main indicators of the investigated buildings

Parametrai	Pastatas A	Pastatas B	Pastatas C
Statybos metai	2017	2017	2014
Pastato paskirtis	Administracinės paskirties		
Naudingas plotas	22 507 m ²	2405 m ²	2 208,91 m ²
Pastato aukštingumas	9	2	11
Pastatų energetinė klasė	B	B	B
Energijos sąnaudos šildymui metus	19,44 kWh	43,09 kWh	41,43 kWh
CO ₂ kiekis per metus pagal sertifikavimą	19,25 kg/m ²	26,06 kg/m ²	28,05 kg/m ²
Darnumo sertifikatas	LEED GOLD	-	-
Stebėjimo laikotarpis	Nuo 2019-08-01 iki 2019-12-23	Nuo 2021-01-05 iki 2021-11-27	Nuo 2021-12-16 iki 2022-05-14

Visi tiriamieji pastatai yra administracinės paskirties, pastatyti pastatai yra C – 2014 m., o A ir B – 2017 m. Vilniaus mieste. Pastatai pagal matmenis yra nevienodi, skiriasi pastatų aukštingumas – pastatas A yra 9 aukštų, pastatas B – 2 aukštų, o pastatas C – 11 aukštų. Pagal energetinį sertifikavimą visi pastatai yra B klasės, bet vadovaujantis energetinio sertifikavimo duomenimis šiluminės

energijos suvartojimo kiekis skiriasi, nes pastatas A, palyginus su pastatu B ir C, suvartoja mažiau nei 2 kartus energijos pagal energijos sertifikavimo standartą.

Komfortą pastate A šildymo sezono metu palaiko radiatorių sistema, o vėsinimo sezono metu – aktyvios šaldomos sijos (su vėdinimu). 2,5 m virš grindų sumontuoti termostatai reguliuoja kambario oro temperatūrą šildant ar vėsinant. Termostatai yra centralizuotai valdomi iš pagrindinės valdymo sistemos (BMS – pastato valdymo sistema), todėl vartotojai neturi galimybės reguliuoti patalpų klimato parametrų, tai daryti gali tik pastatą prižiūrintis personalas. Vėdinimo sistema – šakotinė, pastovaus oro srauto, šviežias oras į patalpas tiekiamas per aktyvias šaldymo sijas, o darbo valandomis oro srautas yra pastovus. Vėdinimo ir vėsinimo sistemos įjungiamos nuo 06:30 h iki 19:00 h. Šildymo metu visuomet veikia radiatorinė sistema.

Komfortą pastate B šildymo sezono metu palaiko radiatorių sistema, o vėsinimo sezono metu – freoninės multisplitinės sistemos. Patalpų lubose yra įrengti vėsinimo vidiniai blokai. 1,5 m virš grindų sumontuoti termostatai reguliuoja kambario oro temperatūrą siekiant atvėsinti patalpą. Patalpų temperatūra šildymo sezonu yra reguliuojama su radiatoriniais termostatais, kurie sumontuoti ant kiekvieno radiatoriaus. Vėdinimo sistema – šakotinė, pastovaus oro srauto, šviežias oras į patalpas tiekiamas per lubose sumontuotus difuzorius, o darbo valandomis oro srautas yra pastovus. Vėdinimo ir vėsinimo sistemos įjungiamos nuo 06:30 h iki 19:00 h. Šildymo laikotarpiu visuomet veikia radiatorinė sistema.

Komfortą pastate C šildymo sezono metu palaiko radiatorių sistema, o vėsinimo sezono metu – freoninės sistemos. Patalpų lubose yra įrengti vėsinimo vidiniai blokai. 1,5 m virš grindų sumontuoti termostatai reguliuoja kambario oro temperatūrą. Patalpų temperatūra šildymo sezonu yra reguliuojama su radiatoriniais termostatais, kurie sumontuoti ant kiekvieno radiatoriaus. Vėdinimo sistema – šakotinė, pastovaus oro srauto, šviežias oras į patalpas tiekiamas per lubose sumontuotus difuzorius, o darbo valandomis oro srautas yra pastovus. Vėdinimo ir vėsinimo sistemos įjungiamos nuo 06:30 h iki 19:00 h. Šildymo metu visuomet veikia radiatorinė sistema.

2.1.1. Matavimų skirstymas į grupes

Atliekant pasyviosios vartotojų elgsenos tyrimus reikalingas ypač didelis duomenų kiekis, kuris vėliau yra apdorojamas grafiškai ar kitais metodais. Šiame darbe apie vartotojus kaupiami šie pagrindiniai duomenys: vartotojų užimtumas, patalpų vidaus temperatūra, santykinė drėgmė, oro judrumas, anglies dioksido koncentracija. Autorius Hong 2017 m. išskyrė pagrindinius vartotojų elgsenos stebėjimo metodus, kurie pristatyti 2.2 lentelėje. Duomenų kaupimas išskirstytas į dvi pagrindines grupes (Hong et al. 2017).

2.1 lentelė. Objektivių ir subjektyvių matavimų skirstymas**Table 2.1.** Classification of objective and subjective measurements

Objektyvūs matavimai				Subjektyvūs matavimai
Fiziniai, jutiminiai				Nefiziniai, nejutiminiai
Išmanūs matavimai ir patato duomenys	Vidiniai ir išoriniai aplinkos duomenys	Vartotojų vidiniai veiksmai su valdymo sistema	Vartotojų duomenys	Apklausų duomenys ir savęs vertinimo ataskaitų duomenys

2.1 lentelėje pateikiamos (Hong et al. 2017) dvi pagrindinės kategorijos – objektyvūs ir subjektyvūs matavimai. Objektyvūs matavimai apima pažangias apskaitas ir duomenų sistemas, vidaus ir išorės duomenis, vartotojų sąveiką su valdymo sistemomis. Dažniausiai tai yra griežtai apibrėžti fizikinių, cheminių parametrų matavimai, kurių matavimų rezultatų patikimumui vartotojai nedaro įtakos.


Subjektyvūs matavimai – tai matavimai, kurie nėra apibrėžiami taip tiksliai kaip objektyvūs, todėl šie duomenys yra mažiau patikimi nei objektyvūs. Subjektyviems matavimams yra priskiriamos apklausos ir savęs vertinimo ataskaitų duomenys.

Duomenys apie vartotojus, tokie kaip amžius, išsilavinimas ir pan., yra priskiriami abejoms matavimų grupėms, t. y. ir objektyviems, ir subjektyviems matavimams.

2.1.2. Tyrimui taikyta įranga

Vienas iš svarbiausių matavimo parametrų šiame darbe – žmonių buvimas, turintis įtakos patalpų mikroklimato palaikymo sistemų energijos suvartojimo pokyčiams. Patalpų ar darbo vietų užimtumą galima stebėti naudojant tokius įrenginius kaip 3D gylio kameros, kurias plačiai ištyrė Diraco et al.(2015). 3D kameros gali labai tiksliai užfiksuoti žmonių buvimą ir elgesį. Kitas ištirtas metodas yra PIR (pasyvus infraraudonųjų spindulių jutiklis) su triukšmo jutiklių pagrindu arba VOC (lakieji organiniai junginiai), CO₂ (anglies dioksidas) ir santykinė drėgmė, tačiau jie fiksuoja tik žmonių buvimą ar nebuvimą patalpose (Pedersen et al. 2017). CO₂, VOC, RH (santykinė drėgmė) yra jutikliai, kurie fiksuoja išmatuotų parametrų padidėjimą, palyginti su įprastais parametrais, taip nurodant buvimą patalpoje. Tai nėra tikslus užimtumo nustatymo metodas, nes jis rodo, kad kambarys yra užimtas, tačiau nepateikia informacijos apie tikslų vartotojų skaičių.

Tyrimo objektų patalpose PIR judesio detektoriai buvo įrengti kiekvienoje darbo vietoje po stalais (2.2 pav.). Darbo vietos (stalai) buvo sunumeruotos, o prie stalų esantys numeriai priskirti tam tikram PIR jutikliui (2.3 pav.).



2.2 pav. Tiriamųjų objektų patalpų fotofiksacija. Kairėje – pastato A, o dešinėje – B
Fig. 2.2. Photofixation of the premises of the research objects. Building A is on the left, and B is on the right



2.3. pav. Tiriamųjų patalpų darbo vietose sumontuotų PIR daviklių planai.

Kairėje – pastato A, dešinėje viršuje – B, kairėje apačioje – pastato C
Fig. 2.3. Plans for PIR detectors installed at workplaces of researched premises.
 Building A is on the left, building B is on the top right, and building C is on the bottom left


Matavimo įrangos charakteristikos pateiktos 2.2 lentelėje. 3D kamera, naudojama pastate B, skaičiuoja įeinančių ir išeinančių asmenų skaičių ir kas valandą generuoja ataskaitas (2.5 pav.).

2.2. lentelė. Naudotos įrangos modeliai ir parametrai

Table 2.2. Models and parameters of used equipment

Įrangos modelis	Parametras	Matavimo ribos	Tikslumas	Matavimo periodas
1	2	3	4	5
HOBO MX102A	CO ₂	0–5000 ppm	±50 ppm ±5 % esant 25 °C	5 min
	Temperatūra	0–50 °C	±0,21 °C	5 min
	Santykinė drėgmė	1–90 %	±2 %	5 min
Almemo FVA605 TA1/TA50	Oro judėjimo greitis	0,1–1,0 m/s	±(0,04 m/s + 1 % nuo matuojamos vertės)	5 min
Almemo WBGT	Temperatūra	–50–+200 °C	±50 ppm ±5% esant 25 °C	5 min
Hikvision ids-2cd6412fwd/c	Žmonių skaičiavimas	Didžiausiais žmonių kiekis – 10	Iki 98 %	60 min
TABLEAIR SBL UNI SET	Darbo vietos užimtumo skaičiavimas	0–+50 °C	0,5 °C	1 min

Kamera sumontuota prie įėjimo durų ir prijungta prie belaidžio ryšio tinklo, leidžiančio pasiekti nuotolinę prieigą. Darbo vietos užimtumui matuoti naudojami PIR + temperatūros jutikliai. Šių daviklių duomenys laikomi tikslesniais, nes jie montuojami po stalu (2.3 pav.). Po stalais sumontuoti jutikliai naudojant dvigubo patikrinimo metodiką – kai vartotojai atsisėda prie stalo, reaguoja PIR jutiklis, o temperatūros jutiklis papildomai patvirtina užimtumą ir tik tada signalas siunčiamas naudojant belaidį ryšį siunčiant duomenis į maršruto parinktuvą, o bevieliu internetu – į serverį. Priešingai, dvigubas patikrinimas naudojamas, kai vartotojai atlaisvina darbo vietą. Signalai taip pat perduodami nuotoliniu būdu per belaidį ryšį 1 min laiko tikslumu.




2.4. pav. Kairėje – PIR daviklių sumontavimas darbo vietoje.

Dešinėje – interaktyvi ataskaita daviklių gamintojo debesyje

Fig. 2.4. On the left, installation of PIR sensors at the workplace.

On the right, the interactive report in the cloud of the sensor manufacturer

PIR jutikliai negali stebėti bendro patalpos užimtumo, palyginti su 3D kamera. 2.5 paveiksle pateikiama 3D kameros montavimo vieta duomenims surinkti. Pastate B taikyta 3D kamera vartotojų skaičiavimo bendroje erdvėje. Šios kameros pasižymi tuo, kad skaičiuoja įeinančius ir išeinančius asmenis, todėl vartotojų gali būti daugiau nei darbo vietų, to negali užfiksuoti PIR judesio davikliai darbo vietose. Bet vartotojų skaičiavimo patikimumas yra mažesnis, nes išduodamos tik 1 valandos ataskaitos. Todėl vėlesniems tyrimams 3D kamerų duomenys nėra taikomi.



2.5 pav. 3D kameros taikoma įranga, sumontavimas vietoje ir internete pateikiama ataskaita daviklių gamintojo debesyje

Fig. 2.5. 3D camera applicable equipment, on-site installation, and the interactive report in the sensor manufacturer's cloud

Pastatuose atliktų matavimų laikotarpis: pastate A – nuo 2019-08-01 iki 2019-12-23, pastate B – nuo 2021-01-05 iki 2021-11-27, pastate C – nuo 2021-12-16 iki 2022-05-14.

2.2. Tiriamųjų objektų patalpos

Darbe nagrinėjami trys pastatai – A, B ir C, esantys Vilniaus mieste. Vertinant šiuos tris pastatus buvo tikrinamas prognozavimo algoritmų patikimumas. Taip pat *Matlab* aplinkoje buvo sumodeliuotos kintamojo srauto vėdinimo sistemos su mašininio mokymosi modeliu vartotojams prognozuoti. Detalesnė pastatų patalpų informacija pateikta 2.3 lentelėje, o tirtųjų patalpų darbo vietų išdėstymas pateiktas 2.3 paveiksle.

2.3 lentelė. Pagrindinės patalpų ir jose esančių vėdinimo sistemų charakteristikos

Table 2.3. Fundamental characteristics of indoor spaces and their ventilation systems

Parametrai	Pastatas A	Pastatas B	Pastatas C
Plotas, m ²	168	123,57	93,1
Aukštis, m	2,9	3,32	2,80
Tiekiamas / šalinamas oro kiekis pagal projektą, m ³ /h	–	505/400	–
Oro tiekimo ortakio skersmuo ir kiekis	8 atšakos po 125 mm skersmens	2 atšakos po 160 mm skersmens	–
Oro šalinimo ortakio skersmuo ir kiekis	Grotos sienose	2 atšakos po 200 mm skersmens	–
Darbo vietų skaičius	32	14	8

Lyginant tris tiriamuosius pastatus visuose pastatuose yra mechaninės tiekimosios ir ištraukimosios vėdinimo sistemos su šilumos atgavimo funkcija. O tiriamųjų patalpų plotas, numatytas žmogui, yra pagal pastatus: C vartotojui skirtas didžiausias plotas – 11,6 m²/žm., o mažiausias plotas yra pastate A – 5,25 m²/žm. Tai parodo, kad pastate C yra daugiau laisvos vietos ir nėra išnaudotas visas galimas plotas pagal projektavimo galimybes, numatytas darbo vietai įrengti.

Pastato A patalpa aukščiau ir žemiau ribojasi su kitomis patalpomis, o vidinė siena – su virtuvės zona ir pokalbių kambariais, visos išorinės atitvaros yra stiklinės. Pastato B patalpa sudaryta iš mūrinių sienų, sienos ribojasi su koridoriumi stikline pertvara, žemiau grindų ir aukščiau lubų ribojasi su lauku. Minėta patalpa turi didelius paviršių plotus, kurie ribojasi su lauku. Pastato C patalpa ribojasi aukščiau ir žemiau su kitomis patalpomis, o vidinė siena – su virtuvės zona, pokalbių kambariais ir koridoriumi, atitvara, besiribojanti su lauku, yra stiklinė.

2.3. Ekstremalaus mokymosi mašininis modelis su integruotais optimizacijų algoritmais


Norint pasiekti optimalų vienos patalpos ŠVOK valdymą nepakanka vien tik tradicinių sprendimų taikant reguliavimą pagal patalpos parametrus. Šiai problemai spręsti yra pasitelkiami mašininio mokymosi ar kitos statistinių duomenų apdorojimo pagrindu paremti modeliai. Vienas iš tokių modelių taikomas ir šiame darbe – tai ekstremalaus mokymosi mašininis modelis su imituoto atkaitinimo ir genetinių algoritmų optimizacijomis.

Ekstremalaus mokymosi mašininis modelis yra pagrįstas statistine duomenų ir jų pasikartojimų įvairove. Kompiuterinėje programoje *Matlab* įdiegta ekstremalaus mokymosi mašina su optimizacijomis. Programa pirmoje fazėje gautus visus duomenis suskirsto atsitiktine tvarka į tris dalis, atitinkamai norimam mokymų (angl. *Training*), testavimo (angl. *Testing*) ir validavimo (angl. *Validation*) kiekiui. Darbe yra nagrinėjama viena ŠVOK dalis – vėdinimas. Mašininio mokymosi modelis yra tik vienas iš viso darbo elementų, modeliuojant patalpos užterštumą priklausomai nuo prognozuotų vartotojų skaičių. Todėl antrasis darbo etapas – taikant CO₂ koncentraciją pagal prognozuotą vartotojų kiekį ir įvertinus realų patalpos užimtumą apskaičiuoti anglies dioksido kiekį iš naujo apmokant neuroninius tinklus. Tokį duomenų ir rezultatų tikslinimo procesą kartoti kiekvieną kartą analizuojant gautus duomenis.

2.3.1. Ekstremalaus mokymosi mašininis modelis

ELM algoritmas yra vienas iš mašininio mokymosi modelių, kurį pirmą kartą pristatė Huang 2004 m. (Huang et al. 2004). Algoritmas yra paprastas, veikia itin greitai ir pasižymi geru apibendrinimo našumu. Algoritmas skaičiavimo metu stengiasi išlaikyti mažiausią mokymų paklaidą ir mažiausią svorių normą. Dėl minėtų privalumų ELM sulaukdavo vis didesnio dėmesio ir plataus pritaikymo įvairiose srityse, tokiose kaip medicina, jūrinė aplinka, medžiagų mechanika ir kt. Siūlomi įvairūs algoritmo patobulinimai, kurie įgalina jo pritaikomumą ir didelių duomenų analizei (Chen et al. 2017). Taigi iki šiol ELM potencialas nėra pakankamai išnaudojamas pastato užimtumo prognozavimo srityje, kur svarbus ne tik prognozavimo tikslumas, bet ir prognozavimo greitis, nes tai susiję su pastato paslaugų sistemų valdymu. Ekstremalaus mokymosi mašininio modelio standartinė SLFNN schema pateikta 2.6 paveiksle.

SLFNN (angl. *Single Hidden Layer Feed forward Neural Network*) – vieno paslėptojo sluoksnio tiekimo į priekį neuroninis tinklas.



2.6. pav. Standartinė struktūra SLFNN

Fig. 2.6. Standart structure for SLFNN

Ekstremalaus mokymosi mašininis modelis yra vieno paslėptojo sluoksnio perdavimo tinklas su atsitiktiniais paslėptaisiais neuronais (angl. *Single Hidden*) N – atskiroms imitims (x_i, t_i) , kur yra įvesties vektorių rinkinys, priklausantis realiųjų skaičių aibei $\{x_i\}^T \in R^n$, ir užsibrėžtų vektorių (skaičius, kuris turi vertę ir kryptį) rinkinys, taip pat priklausantis realiųjų skaičių aibei $\{t_i\}^T \in R^m$ (arba $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$ ir $t_i = [t_{i1}, t_{i2}, \dots, t_{in}]^T \in R^m$), kurie yra perkeltami į matricą. Šiame tyrime nagrinėjami elementai: x_i – anglies dioksido koncentracija ar kitas parametras, o t_i – vartotojų elgseną apibūdinantis dydis. Standartinė SLFNs išraiška su paslėptaisiais neuronais (L) ir aktyvacijos funkcija $g(x)$, pateikta matematine išraiška, yra (Huang et al. 2004):

$$o_j = g_i(x_j) = \sum_{i=1}^L \beta_i g(w_i x_j + b_i), \quad (2.1)$$

čia $j = 1, \dots, N$, $g_i(x)$ – aktyvacijos funkcija, kuri gali būti sigmodės ir radialinis pagrindas, sinusinė, kosinusinė, eksponentinė ir daugelis kitų nepastovių funkcijų.

Šiame darbe nagrinėjama ir taikoma sigmoidinė aktyvacijos funkcija, kuri išreikšta pagal 2.2 formulę:

$$g(x) = \frac{1}{1 + \exp(-x)}, \quad (2.2)$$

$w_i = (w_{i1}, w_{i2}, \dots, w_{im})^T$ – svorinis vektorius sujungia i -tąjį paslėptąjį neuroną su įeinančiu neuronu, kuris išreiškiamas pagal formulę:

$$w_i = \begin{cases} \frac{x_{02} - x_{01}}{w \cdot x_{i+1} + w \cdot x_i} w, & \text{jei } 1 \leq i \leq N - 1 \\ 0, & \text{jei } i = N. \end{cases} \quad (2.3)$$

b_i – i -tojo paslėptojo neurono slenkstis. Viduje skliaustelių w_i ir x_j žymima kaip $w_i \cdot x_j$. Laikoma, kad išvesties neuronai yra tiesinės priklausomybės.

$$b_i = \left\{ \frac{x_{01}w_i x_{i+1} - x_{02}w_i x_i}{w_i x_{i+1} + w_i x_i}, \text{ jei } 1 \leq i \leq N-1, x_{01}, \text{ jei } i = N. \right. \quad (2.4)$$

Standartinė vieno paslėptojo sluoksnio tiekimo į priekį neurononinio tinklo (SFLNN), skaičiavimo schema su L paslėptaisiais neuronais ir aktyvacijos funkcija $g_i(x)$ gali apytiksliai įvertinti paslėptųjų neuronų L bandymus $\sum_{j=1}^L \|o_j - t_j\| = 0$, kai egzistuoja tokie dydžiai β_i, w_i, b_i , čia

$$\sum_{i=1}^L \beta_i g(x_j) = \sum_{i=1}^L \beta_i g(w_i x_j + b_i) = t_j, j = 1, \dots, N, \quad (2.5)$$

$\beta_i = (\beta_{i1}, \beta_{i2}, \dots, \beta_{im})^T$ – yra svorinis vektorius, kuris sujungia i -tąjį paslėptąjį neuroną su išvesties neuronu.

Anksčiau pateikta N lygtis gali būti perrašyta kaip $H\beta = T$ ir išskleista į matricinę išraišką:

$$H(w_1, w_2, w_L, b_1, b_2, b_L, x_1, x_2, x_L) = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) \cdots g(w_L \cdot x_1 + b_L) \\ g(w_1 \cdot x_N + b_1) \cdots g(w_L \cdot x_N + b_L) \end{bmatrix}, \quad (2.6)$$

$\beta = (\beta_1, \beta_2, \dots, \beta_L)$ Huang (Huang et al. 2004) vadinamas paslėptojo sluoksnio išvesties matrica neuroniniame tinkle. Matricos 1-asis stulpelis H vadinamas išvesties i -tuoju neuronu, atitinkančiu įvesties neuronus $(x_1, x_2, \dots, x_L)$. Aktyvacijos ir perdavimo funkcijos yra visuomet ir yra be galo diferencijuojamos, o bandymų skaičius yra žymiai didesnis nei paslėptųjų mazgų $L \ll N$.

Pagrindinės modelio savybės yra:

Minimali mokymo paklaida. Specialus sprendimas $\beta^* = H^T T$ yra vienas iš mažiausiųjų kvadratų bendrosios tiesinės sistemos sprendinių $H\beta = T$, tai reiškia, kad mažiausią mokymo paklaidą galima pasiekti taikant specialų sprendimą:

$$\min \|H\beta - T\|^2 \rightarrow 0 \text{ ir } \beta^* = H^\dagger T, \quad (2.7)$$

čia $H^\dagger$ – Moore–Penrose apibendrinta atvirkštinė matrica H .

Beveik visų mokymosi algoritmų tikslas – pasiekti mažiausią mokymosi paklaidą, tačiau dauguma negali pasiekti šio tikslo dėl vietinių minimalių begalinių mokymosi pasikartojimų.

Mažiausios svorio normos. Specialus sprendimas $\beta^* = H^\dagger T$ turi mažiausią normą tarp visų mažiausiųjų kvadratų sprendinių $H\beta = T$:

$$\|\beta^*\| = \|H^\dagger T\| \leq \|\beta\|, \forall \beta \in R^{L \times N}, \quad (2.8)$$

$$\{\beta: \|H\beta - T\| \leq \|Hz - T\|, \forall z \in R^{xN}\}. \quad (2.9)$$

Mažiausia $H\beta = T$ mažiausiųjų kvadratų sprendinių norma yra vienintelė ir lygi $\beta^* = H^\dagger T$.

Ekstremalaus mokymosi mašininio modelio parašytas pseudokodas pateiktas 2.7 paveiksle.

Pareikalavimas: mokymosi duomenys: $\{x_i\}^T \in R^n$ ir $\{t_i\}^T \in R^m$ ($x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$ ir $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^m$)

Paslėptojo išvesties neurono funkcija $g(x)$ ir paslėptojo neurono skaičius, L

Užtikrinimas: išvesties svorinis vektorius, β

Atsitiktinis paslėptojo neurono generacijos parametras (w_j, x_j, b_j), čia $j = 1, \dots, N$

Skaičiuojama paslėptojo sluoksnio išvesties matrica H


Skaičiuojami išvesties svoriai $\beta: \beta = H^\dagger T$, čia $T = [t_1, t_2, \dots, t_N]^T$

Pabaiga

2.7. pav. ELM pseudokodas

Fig. 2.7. ELM pseudocode

2.8 paveiksle pateikta ekstremalaus mokymosi mašininio modelio hierarchinė schema.



2.8 pav. ELM mokymosi etapai


Fig. 2.8. Steps of the ELM learning procedure

Hierarchinėje schemoje nurodomi pagrindiniai ekstremalaus mokymosi mašininio modelio skaičiavimo etapai.

2.3.2. Genetinio algoritmo optimizacija

Ekstremalaus mašininio mokymosi metodo optimizacija yra genetinis atsitiktinės atrankos algoritmas, imituojantis natūralią atranką ir genetiką. Genetinis algoritmas veikia pagal galimų sprendimų populiaciją ir ieško rezultato, lygaus arba artimo tam tikros problemos atsakymui. Naujos kartos sprendimai generuojami iš

ankstesnės kartos sprendimų, atliekant kryžminimą (rekombinaciją), mutaciją ir kartojant šį procesą. Šis procesas veda į sprendimų, kurie yra geresni nei tie, iš kurių jie buvo sukurti, evoliuciją. Genetinio algoritmo pagrindiniai etapai pateikiami 2.9 paveiksle.



2.9. pav. Standartinė genetinio algoritmo struktūra
(Abualigah et al. 2019)

Fig. 2.9. Standard structure of a genetic algorithm
(Abualigah et al. 2019)

Populiacijos dydžio inicijavimas (angl. *population initialization*). Šiame etape nustatomas populiacijos dydis M ir atsitiktinai sugeneruotos populiacijos chromosomos nustatomos kaip pradinis $Y(0)$. Populiacijos dydis gali siekti 100 ir daugiau kartų (tėvai, vaikai, anūikai, proanūikiai, propoanūikiai ir t. t.)

Tinkamumo skaičiavimas (angl. *fitness calculation*). Šiame etape nustatomas kiekvienos chromosomos tinkamumas populiacijoje $Y(t)$. Populiacija laikoma funkcija $f(y)$, kuri priklauso nuo populiacijos dydžio ($y \in M$).

$$f(y) = \begin{bmatrix} y_1 \\ \vdots \\ y_M \end{bmatrix} = \begin{bmatrix} x_{11} & \cdots & x_{1m} \\ \vdots & \cdots & \vdots \\ x_{M1} & \cdots & x_{Mm} \end{bmatrix}. \quad (2.10)$$

Tinkamumo funkcija – $fit(y)$, $y \in (y_1, \dots, y_m)$, kai yra taikoma dirbtinių neuro-ninių tinklų optimizijoje:

$$fit(y_i) = \frac{1}{n} \sum_{j=1}^n (O_j - T_j)^2, \quad (2.11)$$

čia O_j yra j -ojo prognozuojamoji išėjimo reikšmė, T_j yra faktinis išvesties duomuo, n yra bendrasis įvesties duomenų kiekis.

Nutraukti (angl. *terminate*). Įvykus evoliucinei algebrai N , evoliucija sustabdoma ir optimaliu sprendimu pasirenkama N kartų tinkamiausia chromosoma. Jei nėra pasiekama evoliucinė algebra, vykdoma atranka.

Atranka (angl. *selection*). Šiame žingsnyje, taikant atrankos operatorių, parenkamos L tėvų poros iš $Y(t)$. Kai $L \geq M$, skaičiavimas tęsiamas. Kitu atveju, jei $L < M$, iteracijos nutraukiamos (skaičiavimas sustoja).

Parametras (-ai): M – nustatomi genomų blokai (populiacijos dydis)
Išvestys: atsitiktinai parenkamas chromosomų rinkinys iš M
Inicijavimas:
 $t \leftarrow 0$
 inicijuoti $Y(t)$ nustatymą iš atsitiktinio chromosomų rinkinio M
ĮVERTINIMAS TINKAMUMAS (M_t , $Y(t)$)
Kai nutraukimo sąlygos neįvykdytos
 { Pasirinkti chromosomą iš M_t (suderinti tinkamumą)
 Chromosomų atranka
 Chromosomų kryžminimas
Atlikti { Chromosomų mutacija
 ĮVERTINIMAS TINKAMUMAS (M , įterpiamos chromosomos iš išorės
 $Y(t+1) \leftarrow$ sukuriamą naują populiaciją
 $t \leftarrow t+1$
Sugrąžinimas (gaunamas tinkamiausias ryšys iš geriausios populiacijos $Y(t)$)
Procesas: **ĮVERTINIMAS TINKAMUMAS** (M , Y)
 M – nustatomas populiacijos dydis
 Y – populiacijos chromosomos
Kiekvienai chromosomai $j \in Y$
Atlikti { generuojami genomų blokai
 gaunamos reikšmės O_j ir T_j
 $fit(y)$ tinkamumo funkcija

2.10. pav. Standartinis genetinio algoritmo pseudokodas (Zaritsky & Sipper, 2004)

Fig. 2.10. Pseudocode of the standard genetic algorithm (Zaritsky & Sipper, 2004)

Kryžminimas (angl. *crossover*). Tai vienas iš trijų pagrindinių algoritmo operatorių. Kryžminimas (taip pat vadinamas rekombinacija) yra procesas, kai dviejų atsitiktinai atrinktų chromosomų tėvų genetinė informacija sujungiama ir sukuriamas palikuonis (vaikas). Kryžminimas atliekamas su didele tikimybe P_c , kuri apskaičiuojama pagal (2.12) lygtį. Jei ši vienos iš pirminių chromosomų tikimybė yra mažesnė nei P_c , tada sukuriamas vienas ar keli taškai, kad būtų atliktas

kryžminimas ir gautos naujos vaikų chromosomos bei suformuoti L tarpiniai individai.

Kryžminimo rezultatas yra nauja populiacija $Y(t + 1)$.

$$P_c = \frac{fit(y_i)}{\sum fit(y_i)}, \quad (2.12)$$

Y_i yra i -toji chromosoma populiacijoje, $fit(y_i)$ yra tinkamumo i -toji chromosoma. $\sum fit(y_i)$ yra visų populiacijos chromosomų suminė tinkamumo vertė.

Mutacija (angl. *mutation*). Šis žingsnis reikalingas norint išlaikyti populiacijos įvairovę ir užkirsti kelią pirmalaikiam konvergavimui. Mutacija padeda paįvairinti populiaciją, taigi padeda genetiniam algoritmui išvengti vietinio optimumo.

Anksčiau pateiktas standartinio genetinio algoritmo pseudokodas, kuris išverstas į lietuvių kalbą. Pseudokodą 2004 m. pristatė Zaritsky (Zaritsky & Sipper, 2004). Pseudokodas pateiktas 2.10 paveiksle. Prieš taikant šį pseudokodą, jį reikia konvertuoti į konkrečią kalbą, taikomą atitinkamai kompiuterinei programai.

2.3.3. Imituoto atkaitinimo algoritmo optimizacija

Imituotas atkaitinimas (angl. *Simulated Annealing*, SA) yra nesudėtingas, galingas tikimybinis algoritmas, taikomas įvairioms optimizavimo problemoms spręsti (Zhan et al. 2015). Jis pagrįstas konkrečios tikslo funkcijos globalaus minimumo paieška, siekiant išvengti vietinių minimumų, atliekant atsitiktinę paiešką kaimynystėje. Kitaip tariant, algoritmas yra pagrįstas atsitiktiniu sudėtingesniu sprendimu, o ne tiesiausio kelio pasirinkimu. Jei atsitiktinai pasirinktas žingsnis pagerina sprendimą, jis yra priimamas. Priešingu atveju SA vis tiek juda su mažesne tikimybe nei 1. Tikimybė mažėja eksponentiškai ir priklauso nuo eigos.

Bendrai SA turi dvi iteracines kilpas – vidinę ir išorinę. Prieš pradėdant SA, turi būti nustatyta pradinė temperatūra (t_0), kuri yra pagrindinis valdymo parametras, sumažinamas optimizavimo procese (Sieniutycz et al. 2018). Atkaitinimas prasideda tuomet, kai sukuriamas pradinis sprendinys (x_0). Tai laikoma geriausiu dabartiniu sprendimu. Kitas žingsnis – kaimynystės struktūros sukūrimas. Šiame etape pasirenkamos dvi pozicijos i ir j bei naudojama atvirkštinė eiga, įterpimo ir apsiskeitimo operatoriai kaimyniniams sprendimams kurti. Sukuriamas įvesties duomenų sąrašas, kuris naudojamas kandidato apsisprendimo tikimybei p apskaičiuoti. Jei sprendimo funkcija $f(x)$ yra blogesnė už kandidato sprendimo funkciją $f(y)$, tai sprendinio priėmimo tikimybę galima apskaičiuoti pagal (2.13) lygtį.


$$p = \exp \frac{-(f(y)-f(x))}{t}. \quad (2.13)$$

Kiekvienoje iteracijoje naudojamas didžiausias sąrašo duomuo. Kiekvieną kartą, kai randamas netinkamas sprendimas, sugeneruojamas atsitiktinis skaičius

r . Jei $r < p$, tada yra priimtas blogas kandidato sprendimas (Zhan et al. 2015). Todėl kiekvienai d_i ir p_i porai atsitiktinai parenkamas r_i , o tada $r_i < p_i$. Naujiems duomenims t_i apskaičiuojamas pagal lygtį.

$$t_i = \frac{-d_i}{\ln(r_i)}. \quad (2.14)$$

Kai sąlyga įvykdoma, vidinė kilpa sustabdoma. Visų duomenų vidurkis t_{av} naudojamas duomenų sąrašui atnaujinti, t. y. t_{max} pašalinamas iš sąrašo ir įkeliamas duomenų vidurkis, nes $t_{av} < t_{max}$, o visada $t_i < t_{max}$. Tokiu būdu, atliekant paiešką, duomenys susitraukia. Išorinis ciklas sustabdomas, kai pasiekama žemiausia temperatūros riba arba pasiekiamas iš anksto nustatytas pakartojimų skaičius. Imituoto atkaitinimo optimizacijos algoritmo schema parodyta 2.11 paveiksle.



2.11. pav. Standartinė imituoto atkaitinimo algoritmo struktūra (Zhan et al. 2015)
Fig. 2.11. Standard structure of a simulated annealing algorithm (Zhan et al. 2015)

Nustatoma pradinė temperatūra, t_0

Sukuriami vidiniai sprendiniai, x_0

Kol nesilaikoma konvergencijos sąlygų:

Nustatoma temperatūra, t

Kai $j = 1, \dots, N$

Atsitiktinai parenkama reikšmė $y \in N(x)$.

Jei $f(y) < f(x)$, tuomet $x \leftarrow y$.

Kitu atveju tikimybė $p(x, y, t) = \exp\left(\frac{-(f(y)-f(x))}{t}\right)$, tada $x \leftarrow y$.

Kai pabaiga

Kol pabaiga

Grįžti radus geriausią sprendimą

2.12. pav. Imituoto atkaitinimo algoritmo pseudokodas (Ruiz-Torrubiano et al. 2010)

Fig. 2.12. Pseudocode of the simulated annealing algorithm
(Ruiz-Torrubiano et al. 2010)

Anksčiau pateikto imituoto atkaitinimo algoritmo pseudokodas išverstas į lietuvių kalbą. Pseudokodą 2010 m. pristatė Ruiz (Ruiz-Torrubiano et al. 2010). Pseudokodas pateiktas 2.12 paveiksle. Prieš taikant šį pseudokodą, jį reikia konvertuoti į konkrečią kalbą, taikomą atitinkamai kompiuterinei programai.

2.3.4. Vartotojų prognozavimo patikimumo skaičiavimas

Vartotojų prognozavimo paklaidų dydžiui (kokybei) pagal Carbone et al. (1982) vertinti labiausiai tinkamos metodikos, kurias taikant skaičiuojamos absoliučiosios paklaidos ar paklaidų kvadratai. Viena iš tokių metodikų yra šaknis iš vidutinės kvadratinės paklaidos (angl. *Root Mean Squared Error*, RMSE). RMSE metodikos skaičiavimo formulė pateikiama čia:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=0}^N (o_i - t_i)^2}, \quad (2.15)$$

čia o_i – prognozuota reikšmė, t_i – faktinė reikšmė.

Kita vertinimo metodika, kuri taikoma šiame darbe modelio gerumui įvertinti, yra R kvadrato paklaida, kitaip dar vadinama determinacijos koeficientu. Tai viena iš svarbiausių tiesinės regresijos modelio charakteristikų, kuri taikoma visuose aprašymuose, skaičiavimuose. R^2 formulė išreiškiama:

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \underline{y})^2}, \quad (2.16)$$


čia y_i – faktinė reikšmė; $\hat{y}_i$ – prognozuota reikšmė; $\underline{y}$ – prognozuotų reikšmių vidurkis.

Kuo R^2 reikšmė didesnė, tuo tiksliau modelis apskaičiuoja duomenis, bet negali būti didesnis už ≤ 1 . R^2 didelė reikšmė dar neužtikrina, kad modelis yra prasmingas.

2.4. Anglies dioksido koncentracijos patalpoje modeliavimas

Kintamosios vėdinimo sistemos pagrindinis veikimo principas – užtikrinti tinkamą oro kokybę patalpoje, o vienas iš atvejų yra pastovios anglies dioksido koncentracijos palaikymas. Šis bandymas atliekamas kompiuterinių programų *Matlab* ir *Excel* aplinkose, todėl kiekvieną kartą, pasikeitus prognozuojamam vartotojų kiekiui ir patiekiamam šviežiam orui, bus perskaiciuojama anglies dioksido koncentracija pagal realų vartotojų skaičių patalpoje. Oro judėjimas ir CO_2 užterštumas patalpoje atvaizduoti 2.13 paveiksle.

Anglies dioksido koncentraciją patalpoje apskaičiuoti galima taikant teorines lygtis, kurioms reikalingas tikslus žmonių skaičius ir tai, kurį laiką tarpą patalpose būna vartotojai, taip pat patalpų oro kartotinumą ir pradinės anglies dioksido koncentracijos.



2.13 pav. Patalpos oro kaitos ir CO₂ koncentracijos kaitos schema

Fig. 2.13. Diagram of indoor air change and CO₂ concentration change

Anglies dioksido koncentracija patalpoje po tam tikro laiko (kai joje yra žmonių) išreiškiama pagal (2.17) formulę (Engineering ToolBox, 2005):

$$c = \left(\frac{q}{n \cdot V} \right) \cdot \left[1 - \left(\frac{1}{e^{nt}} \right) \right] + (c_0 - c_i) \cdot \frac{1}{e^{nt}} + c_i, \quad (2.17)$$

čia c – anglies dioksido koncentracija patalpoje, (m^3/m^3); q – anglies dioksido kiekis, patenkantis į patalpą nuo žmonių kvėpavimo, (m^3/h); V – patalpos tūris, (m^3); e – eksponentinė konstanta, (2,718...); n – oro kaita patalpoje, (h^{-1}); t – laikas h , (5 min = 5/60 h); c_i – anglies dioksido koncentracija į patalpas šviežiame ore, (m^3/m^3); c_0 – pradinė anglies dioksido koncentracija patalpoje, kai $t = 0$ h, (m^3/m^3).

Formulėje pateikiami anglies dioksido koncentracijos matavimo vienetai m^3/m^3 , todėl skaičiuojant yra perskaičiuojami ppm.

Tiekiamas šviežias oras į patalpas skaičiuojamas žinant patalpos tūrį ir oro kartotinumą. Žinoma, kad atliekant skaičiavimus kartotinumą nėra žinomas, bet žinomas šviežias tiekiamo oro kiekis, todėl:

$$G = n \cdot V, \quad (2.18)$$

todėl

$$n = \frac{G}{V}. \quad (2.19)$$

Todėl (2.19) formulė yra išreiškiama pagal tyrimo eigą:

$$c = \left(\frac{o_{fi} \cdot q_i}{G_{i-1}} \right) \cdot \left[1 - \left(\frac{1}{e^{\frac{G_{i-1} \cdot t}{V}}} \right) \right] + (c_{i-1} - c_i) \cdot \frac{1}{e^{\frac{G_{i-1} \cdot t}{V}}} + c_i, \quad (2.20)$$

čia q_i – anglies dioksido kiekis, patenkantis į patalpą nuo vieno žmogaus kvėpavimo, iš 2.4 lentelės, (m^3/h); o_{fi} – faktinis žmonių buvimo kiekis aktualiu laiku, žm; G_{i-1} – tiekiamas į patalpą šviežio oro kiekis pagal prognozuotą užimtumą (prieš 5 min), (m^3/h); c_{i-1} – pradinė anglies dioksido koncentracija patalpoje, kai $t = 0 \text{ h}$, (m^3/m^3).

Anglies dioksido koncentracija patalpoje, išsiskirianti nuo žmonių, gali būti naudojama nustatant vėdinimo sistemos efektyvumą arba teorinę CO_2 koncentraciją. Patalpoje anglies dioksido koncentracijos dydis tiesiogiai priklauso nuo patalpoje esančių žmonių skaičiaus, todėl teoriniams skaičiavimams reikalinga žinoti vartotojų aktyvumo lygį ir pagal jį išskvepiamo CO_2 kiekį 1 žmogui. Žmonių išskvepiamo anglies dioksido kiekis ir jų aktyvumo lygiai pateikti 2.4 lentelėje (Engineering ToolBox, 2005).

2.4 lentelė. Vartotojų išskiriamas CO_2 koncentracijos kiekis, priklausantis nuo jų aktyvumo lygio

Table 2.4. Amount of CO_2 emitted by users from the active level

Aktyvumo lygiai	Oro kiekis kvėpuojant žmogui	CO_2 išsiskyrimas 1 žmogui
	(m^3/h)	(m^3/h)
Miegas	0,3	0,013
Poilsio ir mažo aktyvumo	0,5	0,02
Normalus (vidutinis) darbas	2-3	0,08 – 0,13
Sunkus darbas	7-8	0,33 – 0,38

Tolesniuose tyrimuose yra taikoma „poilsio ir mažo aktyvumo“ lygio išskiriama CO_2 koncentracija, nes biurų paskirties pastatuose žmonių darbas yra mažo aktyvumo ir išskiriami anglies dioksido kiekiai vienam vartotojui siekia $0,013 \text{ m}^3/\text{h}$.

2.5. Antrojo skyriaus išvados

1. Objektų tyrimai atlikti COVID-19 pandemijos atžvilgiu: pastato A – prieš pandemiją, pastato C – po pandemijos, o pastato B – pandemijos ir jos ribojimų švelninimo laikotarpiu.
2. Parinkti vartotojų elgsenos prognozavimo metodai su optimizacijomis: ekstremalaus mokymosi mašininis modelis su imituoto atkaitinimo ir genetiniu algoritmais. Šie metodai pasižymi privalumu, kad skaičiavimo trukmė yra kelis kartus trumpesnė nei kitų modelių. Visų mašininio mokymosi modelių tikslas – pasiekti mažiausią mokymosi paklaidą, tačiau dalis kitų mašininio mokymosi modelių negali pasiekti iškeltų tikslų dėl vietinių minimalių begalinių mokymosi pasikartojimų lyginant su kitomis analogiškėmis programomis.
3. Parengta eksperimentinių tyrimų bazė, aprašyti tiriamieji objektai ir sudaryta grafinė tyrimo schema, atsižvelgiant į tiriamuosius parametrus.

Mašininio mokymosi su optimizacijomis modeliai ir vėdinimo sistemos valdymo modelio analizė bei patikrinimas

Šios disertacijos tyrimo tikslas – kurti ir tobulinti ŠVOK sistemas taikant mašininio mokymosi su optimizacijomis metodus siekiant sumažinti energijos suvartojimo sąnaudas. Kaip ir buvo minėta, ŠVOK sistemos suvartoja apie 50 proc. visos pagamintos energijos. Modernizuojant sistemas galima sutaupyti iki 60 proc. energijos (Cheng et al. 2019).

Siame skyriuje yra pateikiami tiriamųjų pastatų vartotojų elgsenos ir patalpų mikroklimato parametrų matavimo rezultatai, į kuriuos atsižvelgus nustatoma esamos pastatų vėdinimo sistemos trūkumai ir vartotojų įtaka patalpos mikroklimatui.


Vėliau atlikta modelių SA-ELM ir GA-ELM jautrumo analizė, kurioje nustatomi tinkamiausi vidiniai parametrai, į kuriuos atsižvelgus prognozavimo patikimumas nenukenčia, bet skaičiavimo trukmė išlaikoma trumpiausia.

Paskutiniame tyrimo etape yra testuojamas sukurtas vėdinimo sistemos valdymo modelis AI-VAV, kai nustatomos energijos sutaupymo galimybės ir rekomendacijos.

Skyriaus tematika publikuoti trys autoriaus straipsniai (Bielskus et al. 2020; Motuzienė et al. 2021; Motuzienė et al. 2022).

3.1. Tiriamųjų objektų empirinių duomenų analizė

Šio darbo tyrimai prasideda nuo vartotojų elgseną apibūdinančių empirinių duomenų surinkimo, jie toliau darbe vadinami kintamaisiais. Šie duomenys yra pasirinkti įvertinus tuos, kurie geriausiai koreliuoja su pasyviaja vartotojų elgsena. 3.1 paveiksle pateikta pirmojo etapo schema, kurioje nurodoma iš sukauptų duomenų sudaryta grafinė analizė.




3.1 pav. Pirmojo etapo tyrimų schema

Fig. 3.1. Schema of the first phase of research

Atvirojo tipo biuruose tyrimo metu buvo matuoti ir kaupiti šie parametrai:


- anglies dioksido koncentracija patalpose;
- patalpų oro temperatūra;
- patalpų santykinė drėgmė;
- oro judrumo greitis patalpose;
- lauko oro temperatūra (tik pastato A tyrimo metu);
- saulės spindulių (tik pastato A tyrimo metu);
- lauko oro santykinė drėgmė (tik pastato A tyrimo metu).

Pirmajame tyrimo etape buvo sukaupti trijų tiriamųjų pastatų A, B ir C duomenys ir atlikta duomenų analizė, kuri pateikta grafiškai toliau. 3.2, 3.3 ir 3.4 paveiksluose pateiktas faktinis oro užterštumas, viso tyrimo metu paskirstant savaitės darbo dienomis. Tyrimų laikotarpis truko nuo 11 iki 38 savaitių.




3.2 pav. Pastato A užimtumas tirtojo laikotarpio darbo savaitėje

Fig. 3.2. Occupancy of building A during the working week of the studied period



3.3 pav. Pastato B užimtumas tirtojo laikotarpio darbo savaitėje

Fig. 3.3. Occupancy of building B during the working week of the studied period



3.4 pav. Pastato C užimtumas tirtojo laikotarpio darbo savaitėje

Fig. 3.4. Occupancy of building C during the working week of the studied period


Kaip jau buvo nurodyta, pastato A matavimai atlikti prieš COVID-19 pandemiją, pastato B – pandemijos metu ir taikytų ribojimų švelninimo laikotarpiu, o pastato C – po pandemijos pabaigos. Vartotojų elgsena pandemijos metu ir po jos pasikeitė, t. y. sumažėjo tiesioginio darbo biuruose laikas ir susiformavo dažnesnio nuotolinio darbo įpročiai. Iš visų trijų paveikslų matyti, kad vartotojų užimtumas biuruose savaitės pradžioje yra didžiausias, o darbo savaitės pabaigoje – mažiausias, tai atskleidžia tendenciją, kad vartotojų praleidžiamas darbo laikas biure per darbo savaitę mažėja.

Toliau pateikiamos tirtųjų pastatų histogramos, vaizduojančios žmonių tankio pasikartojimo dažnius (3.5 pav.).

Vadovaujantis matavimų duomenimis matyti, kad žmonių tankis pastatuose, t. y. darbo kabinetuose, dominuojančią laiko dalį yra labai mažas ir jis svyruoja nuo 58 proc. iki 99 proc. – ši informacija pateikta skaitine išraiška 3.1 lentelėje.

Taigi vadovaujantis trijų pastatų patikimais ilgalaikiais matavimais galima teigti, kad pastatuose nė karto nebuvo užfiksuotas 100 proc. užimtumas, o dažniausiai pasikartojantis minimalus užimtumas yra 99 proc. (pastate B), kai vartotojų yra mažiau arba lygu 0,033 žm./m². Šiek tiek didesnė tankių pasiskirstymo įvairovė yra pastebima pastate A (matuota prieš pandemiją) ir pastate C (matuota

pandemijai besibaigiant ar jai pasibaigus), tačiau dviejuose pastatuose praktiškai visą laiką vyrauja minimalus patalpų užimtumas.



3.5 pav. Pastatų A (kairėje), B (viduryje) ir C (dešinėje) patalpų užimtumo (tankio, žm./m²) histograma (darbo valandomis)

Fig. 3.5. Histogram of occupancy (density, m/m2) of buildings A (on the left), B (in the middle), and C (on the right) (during working hours)

3.1 lentelė. Vartotojų užimtumas pastatuose per visą tirtąjį laikotarpį


Table 3.1. Occupancy in buildings during the entire studied period

Pastatas	Maksimalus išmatuotas užimtumas žm. nuo darbo vietų skaičiaus	Dominuojantis žmonių tankis, žm./m²	Per visą matavimo laikotarpį dominuojantis tankis pasikartoja, %
Pastatas A	14/32	<0,033	58 % (373 h iš 647 h)
Pastatas B	6/14	<0,033	99 % (1768 h iš 1788 h)
Pastatas C	7/8	<0,033	90 % (2226 h iš 2479 h)

Nustatant ribinius vartotojų užimtumo tankius yra vadovaujamosi Lietuvos Respublikoje galiojančiomis normomis, kurios taikomos pastatų projektavimo etape:


1. Pagal HN32:2004 reikalavimai projektuojant darbo vietą – ne daugiau kaip $0,167 \text{ žm./m}^2$.
2. Pagal STR 2.01.02:2016 projektuojant pastato energinį naudingumą (sertifikuojant) administraciniams pastatams taikomas žmonių tankis – $0,05 \text{ žm./m}^2$ (visam pastatui, ne kabinetams).
3. *DesignBuilder* dinaminio modeliavimo programoje kabinetams įprastai (jeigu neįvedama kitokia) taikoma $0,11 \text{ žm./m}^2$ norma.

Taigi, 3.5 paveiksle pavaizduotas ir projektuoti naudojamas užimtumas administraciniams pastatams yra daug didesnis nei realus užimtumas. Tai rodo skirtingais laikotarpiais atlikti matavimai. Buvo pasirinkti skirtingi matavimo pastatuose laikotarpiai COVID-19 pandemijos atžvilgiu. Nepaisant to, vartotojai prieš pandemiją neturėjo įpročio ar poreikio dirbti iš namų, o pandemijos metu keitėsi vartotojų įpročiai, dažniau buvo dirbama nuotoliniu būdu iš namų dėl taikomų judėjimo apribojimų. Tačiau pastebima, kad ir pasibaigus pandemijos apribojimams į darbą biuruose grįžo tik dalis darbuotojų, pasikeitė darbo kultūra, darbdaviai ir darbuotojai išmoko derinti darbą iš namų ir pradėjo taikyti hibridinį darbo modelį. Dėl šių priežasčių darbdaviams privalu racionaliau naudoti darbo vietas – mažinti jų kiekį, šildyti, vėdinti ir vėsinti mažesnius plotus bei mokėti mažesnius mokesčius.



3.6 pav. Išmatuotas anglies dioksido ir vartotojų užimtumas pastate B
Fig. 3.6. Measured carbon dioxide and occupancy behaviour of the building B

Toliau pateikiami anglies dioksido koncentracijos ore ir mikroklimato parametrų matavimų rezultatai. Buvo išanalizuoti kiekvieno pastato pagrindiniai mikroklimatą apibūdinantys parametrai: patalpų temperatūra, CO₂ koncentracija ir santykinis oro drėgnumas. Oro judrumo matavimai neparodė nuokrypių nuo higienos normų, todėl toliau analizuojami nebuvo. CO₂ kitimo kreivių koreliacija su užimtumu pateikta 3.6 paveiksle. Šie duomenys vėliau naudojami kuriant matematinius modelius.



3.7 pav. Pastatų oro užterštumo anglies dioksidu (ppm) histograma (darbo valandomis).

Kairėje – pastato A, viduryje – pastato B, dešinėje – pastato C duomenys

Fig. 3.7. Building air pollution by carbon dioxide (ppm) histogram (working hours).

Building – A on the left, B – in the middle, and C – on the right

Priimtina CO₂ koncentracijos riba patalpoje yra laikoma 1000 ppm, o tai atitinka vidutinę IDA 2 patalpos oro kategoriją. Aukštą oro kokybę atitinka IDA 1 kategorija, kai CO₂ koncentracija neviršija 800 ppm. Iš grafiko akivaizdu, kad

pastatas didžiąją laiko dalį yra perteklinai vėdinamas net ir tada, jei būtų siekiama palaikyti aukštą oro kokybę, ir tai lemia neefektyvų energijos vartojimą. 3.7 paveiksle, kur CO₂ koncentracija vertinta tik darbo valandomis, matyti, kad CO₂ koncentracija beveik visą laiką svyruoja tarp 400–700 ppm, o didžiąją laiko dalį neviršija 600 ppm, todėl neišnaudojamas energijos taupymo potencialas vėdinimo sistemą valdant pagal realius poreikius, t. y. valdymas nesiejamas su realiu patalpų užimtumu. Panaši situacija yra ir kituose pastatuose, tai matyti iš 3.6 paveikslo, taip pat palyginimas pateikiamas 3.2 lentelėje.

3.2 lentelėje yra apskaičiuota darbo valandų dalis, kai patalpos yra pervėdinamos. Visuose pastatuose oras praktiškai visą laiką (88,4 proc. – 99,9 proc. darbo laiko) atitinka IDA 1 kategorijai keliamus reikalavimus, tačiau labai didelę laiko dalį jis neviršija nė 600 ppm, tai kai kuriuose šaltiniuose nurodoma kaip žemutinė IDA 1 kategorijos riba. Net palaikant aukščiausius standartus atitinkančią oro kokybę, patalpos vis tiek pervėdinamos nuo 29,1 proc. iki 81,7 proc. darbo laiko. Tai rodo neefektyvų sistemų valdymą ir galimą neišnaudojamą energijos taupymo potencialą.

3.2 lentelė. CO₂ koncentracija pastatų patalpose


Table 3.2. CO₂ concentration in buildings

Pastatas	Maksimali išmatuota koncentracija, ppm	Dominuojanti koncentracija, ppm	Darbo valandos, kai patalpos pervėdinamos, %	
			≤600 ppm	≤800 ppm
Pastatas A	1210	701–800	29,1	90,5
Pastatas B	940	501–600	81,7	99,9
Pastatas C	1203	501–600	66,5	93,0

Apibendrinant atliktos stebėsenos duomenis galima teigti, kad visus pastatus vienija tipinės problemos – pastatų pervėdinimas bei tai, kad visų patalpų užimtumas yra mažesnis, nei numatoma projektuojant. Didžiausi nesutapimai, itin susiję su žmonių skaičiumi patalpose, susidaro dėl skirtingo vėdinimo sistemos valdymo. Patalpų užimtumo stebėseną gali leisti iš anksto prognozuoti žmonių skaičių patalpose ir leisti pastato valdymo sistemai reguliuoti oro kiekius patalpoje, tokiu būdu taupant energiją.

Kitame poskyryje aprašoma, kaip buvo kuriami matematiniai prognozavimo modeliai, atlikta jautrumo ir patikimumo analizė, kurios metu buvo nustatyti optimaliausi mašininio mokymosi modelio nustatymo parametrai.

3.2. Prognozavimo modelio jautrumo ir patikimumo analizė



3.8 pav. Antrojo etapo tyrimų schema

Fig. 3.8. Schema of the second phase of research

Matlab kompiuterinė programa, kurioje yra ekstremalaus mašininio mokymosi (ELM) su optimizacijos modeliu algoritmas, leidžia prognozuoti vartotojų užimtumą pagal pastatuose A, B ir C matuojamus CO₂ koncentracijos duomenis atsižvelgiant į įvairius matavimo laikotarpius. Siekiant skaičiavimo modelio patikimumo, matavimai buvo fiksuojami kas 5 minutes. Dažniausiai įprastos duomenims, naudojamiems neuroninių tinklų modeliuose, mokyti, testuoti ir patvirtinti proporcijos yra 60/20/20 proc. arba 50/25/25 proc. (Chen et al., 2020),

tačiau, pasak Nguyen (2021), geriausias rezultatas pasiekiamas, kai santykis pasiskirsto 70/10/20 proc. (Nguyen et al., 2021). Modelyje taip pat taikomas duomenų santykis: 70 proc. mokymui, 10 proc. – testavimui ir 20 proc. rezultatų validavimui (3.9 pav.).




3.9 pav. Duomenų rinkinio padalijimas modelyje procentais

Fig. 3.9. Splitting the data set in the model

Vienas iš pagrindinių duomenų, kurie perduodami mašininio mokymosi modeliui, reikalavimų yra tas, kad duomenys privalo turėti tarpusavio sąryšį, koreliaciją. Tai reiškia, kad prognozavimo patikimumas priklausys nuo duomenų koreliacijos. Šiuo atveju tirtųjų pastatų A, B, C ir kartu jų visų duomenys buvo perkelti į kompiuterinę programą PSPP ir ja buvo apskaičiuoti Pirsono (*Pearson*) koreliacijos koeficientai. Skaičiavimo rezultatai pateikti dvipusėje matricoje 3.10 paveiksle.

Iš dvipusių matricų, pateiktų 3.10 paveiksle, matyti, kad vartotojų darbo vietos užimtumas labiausiai koreliuoja su anglies dioksido koncentracija, kuri siekia nuo 0,506 iki 0,834, kai tiesinis sąryšis gali būti 1. Taip pat pastebima, kad vidutinis koreliacijos ryšys tarp vartotojų ir saulės spinduliuotės pastatui A siekia 0,515. O tarp kitų parametrų koreliacijos su vartotojais nors ir yra, bet jos, palyginti, silpnos ir mažai reikšmingos taikant modeliuose ir prognozuojant vartotojų įpročius. Taigi šiuo atveju darbe toliau bus nagrinėjamas vartotojų ir anglies dioksido tarpusavio sąryšis.

Bielskus et al. (2020) nagrinėjo, kuris iš vidaus mikroklimato parametrų daro didžiausią įtaką vartotojų elgsenos prognozavimui su modeliu DE-OSELM. Buvo modeliuoti trys atskiri variantai, kai modelis atlieka vartotojų prognozavimą pagal santykinę drėgmę, temperatūrą ir anglies dioksido koncentraciją pasirinktą vieną darbo dieną iš viso matavimo laikotarpio.




čia Žm. sk. – patalpoje darbo vietų užimtumas, žm.; RH_v – patalpos vidaus oro santykinė drėgmė, %; t_v – patalpos vidaus oro temperatūra, °C; CO₂_v – anglies dioksido koncentracija patalpoje, ppm; G_t – saulės spinduliuotė, W/m²; T_is – lauko oro temperatūra, °C; RH_is – lauko oro santykinė drėgmė, %

3.10 pav. Pastatų A, B, C ir bendrųjų duomenų tarpusavio koreliacijos ryšiai

Fig. 3.10. Interrelation relationship between buildings A, B, and C and the overall data

Grafiškai 3.11 paveiksle pateikti rezultatai, iš kurių matyti, kad temperatūra ir santykinė drėgmė nėra pagrindiniai parametrai, pagal kuriuos tikslinga prognozuoti, nes jų poveikis prognozėje yra arba mažas, arba visai nereikšmingas. Tačiau pagal CO₂ galima pakankamai tiksliai prognozuoti, nes iš pateikto grafiko matyti, kad R² koeficientas tirtai vienai dienai yra 0,84, o bendras viso tirtąjo laikotarpio – 0,71. Patalpų vidaus temperatūra ir santykinė drėgmė daro įtaką rezultatams R² koeficientu 0,01. Šie duomenys patvirtina 3.10 paveiksle pateiktus Pirsono koreliacijos skaičiuotus koeficientus, parodančius esamą anglies dvideginio koreliaciją su vartotojų užimtumu labiau nei su patalpos temperatūra ir santykinė drėgmė.



3.11 pav. DE-OSELM rezultatai vienai darbo dienai, kai kintamieji yra šie vidaus parametrai: pagal CO₂ (kairėje), pagal temperatūrą (viduryje), pagal santykinę drėgmę (dešinėje) (Bielskus et al. 2020)

Fig. 3.11. DE-OSELM results for one working day when the variables are indoor parameters: for CO₂ (on the left), for temperature (in the middle), and for relative humidity (on the right) (Bielskus et al. 2020)

Tiriant tris parametrus buvo pastebėta, kad pagal lauko įvesties duomenis nėra tikslinga prognozuoti, kadangi jie nedarė reikšmingos įtakos vartotojų elgsenos prognozei, nes biurų darbuotojų elgesį lemia ne tik fizikiniai parametrai, bet ir socialiniai veiksniai, pvz., įmonių darbo socialinė aplinka. Taip pat tyrime pastebėta, kad kituose skaičiavimo etapuose, esant vis didesniai imties duomenų dydžiui, prognozė yra vis tikslesnė palyginus su pirmomis dviem savaitėmis. Taip pat pastebėta, kad didžiausią įtaką vartotojų prognozei turi vidaus patalpos parametras – anglies dioksido koncentracija.

Nustačius, kad duomenims taikyti tinkamiausia yra anglies dioksido koncentracija, buvo atlikta jautrumo analizė Ekstremalaus mašininio mokymosi modelio su optimizacijomis SA ir GA. Jautrumo analizei taikyti naudoti pastatų A ir B duomenys. Sudaroma ELM su optimizacijomis tyrimų programa, kuri pateikta 3.3 lentelėje.

3.3. lentelė. Modelio jautrumo analizės programa

Table 3.3. Model sensitivity analysis program

	ELM		Pastatas	
	SA	GA	A	B
Minimalus duomenų rinkinio dydis patikimam prognozavimui	+	+	+	
Įtaka rezultatams dėl neuronų dydžio nustatymų	+	+	+	


3.3 lentelės pabaiga

	ELM		Pastatas	
	SA	GA	A	B
Įtaka rezultatams dėl populiacijos dydžio nustatymų	+	+	+	
Įtaka rezultatams dėl didžiausios iteracijos dydžio nustatymų	+	+	+	
Įtaka rezultatams dėl vartotojų sumažėjimo darbo vietose	+			+

Prieš atliekant išsamią analizę buvo atliktas testas siekiant išsiaiškinti, ar GA-ELM (ekstremalaus mokymosi mašininis modelis su genetinio algoritmo optimizacija) ir SA-ELM (ekstremalaus mokymosi mašininis modelis su imituoto atkaitinimo algoritmo optimizacija) modelių prognozės yra patikimos, bei padarytos šios prielaidos:


- paslėptųjų neuronų skaičius – 20;
- populiacijos dydis (angl. *Pop Size*) – 100;
- maksimalus iteracijų skaičius (angl. *MaxIter*) – 100.

3.12 ir 3.13 paveiksluose pateikiami SA-ELM ir GA-ELM modelių skaičiavimo rezultatai, kuriuose nurodomi empiriniu būdu sukaupiti užimtumo duomenys ir prognozuojamas užimtumas. Rezultatų patikimumas buvo įvertintas taikant R^2 ir $RMSE$ paklaidų skaičiavimo metodus. Visą analizuojamą laikotarpį abiejų modelių patikimumas yra labai panašus: SA-ELM – $R^2 = 0,74$ ir $RMSE = 1,802$ taikant skaičiavimo laiką iki kelių sekundžių, atitinkamai GA-ELM – $R^2 = 0,73$ ir $RMSE = 1,903$.




3.12 pav. Taikant SA-ELM modelį gauti vartotojų užimtumo prognozės rezultatai pagal CO₂

Fig. 3.12. SA-ELM model user employment forecast results based on CO₂



3.13 pav. Taikant GA-ELM modelį vartotojų užimtumo prognozės rezultatai pagal CO₂
Fig. 3.13. GA-ELM model occupancy forecast results based on CO₂


3.14 paveiksle pavaizduotas abiejų modelių mokymosi ir prognozavimo patikimumas nuo 1 iki 8 savaitių.



3.14 pav. Modelių patikimumas priklausomai nuo matavimų laikotarpio
Fig. 3.14. The reliability of the models depends on the measurement period

Grafike matyti, kad SA-ELM po 8 savaičių mokymosi duomenų suteikia šiek tiek didesnę tikslumą nei GA-ELM. Taip pat svarbu pažymėti, kad rezultatų tikslumas labai priklauso nuo matavimo laikotarpio – kuo ilgesnis laikotarpis, tuo patikimesnis prognozavimas. Taigi tai įrodo, kad trumpalaikiai matavimai lemia mažą patikimumą, nes duomenų rinkinys nėra pakankamas. Tuo metu jau nuo 4 savaitės prognozavimo patikimumas tampa pakankamas ir siekia daugiau $R^2 - 0,75$ – o tai tik įrodo, kad modeliams mokytis užtenka 4 savaičių.

Anksčiau atliktuose skaičiavimuose pateikti rezultatai yra aukšto prognozavimo patikimumo, kuris siekia daugiau $R^2 - 0,75$, bet, siekiant nustatyti trumpiausią prognozavimo trukmę ir išlaikyti aukštą patikimumą, buvo atlikta jautrumo analizė. Šiuo tikslu buvo atlikta 900 skaičiavimų, kurių metu buvo keičiami šie parametrai: neuronų kiekis, populiacijos dydis ir maksimalus iteracijų skaičius. Jų modeliavimo rezultatų tikslumas išreiškiamas *RMSE* (*RMSE* 1 taškas yra gautas iš 5 verčių modeliavimo vidurkio).




3.15 pav. RMSE priklausomybė nuo paslėptųjų neuronų skaičiaus

Fig. 3.15. Dependence of RMSE on the number of neurons

Taikant abu modelius su skirtingomis optimizacijomis buvo iš viso atlikta 200 kartų skaičiavimų (kiekvienam po 40 reikšmių $\times$ 5 modeliavimai), siekiant įvertinti didžiausią neuronų skaičiaus įtaką rezultatų tikslumui (3.15 pav.).

Akivaizdu, kad didesnis neuronų skaičius padidina prognozavimo tikslumą, o reikšminga įtaka pastebima nuo 25 neuronų. Dar didesnis neuronų skaičius yra netikslingas, nes prognozavimo pokytis nuo 25 neuronų nėra reikšmingas. RMSE vertės iš visų 200 modeliavimų skiriasi taip: SA-ELM nuo 1,773 iki 1,994 ir GA-ELM – nuo 1,758 iki 1,934.




3.16 pav. RMSE priklausomybė nuo populiacijos dydžio

Fig. 3.16. Dependence of RMSE on population size

Matyti (3.16 pav.), kad genetinio algoritmo skaičius 20 yra pagrįstas populiacijos dydžiu, nes didesnis populiacijos skaičius beveik neturi įtakos tikslumui ir tik padidina modeliavimo trukmę. Tuo metu SA-ELM modelio populiacijos dydis apskritai neturi įtakos rezultatų tikslumui ir skaičiavimo trukmei, trunkančiai iki kelių sekundžių, todėl grafike išvis nerodoma. RMSE vertės iš visų 125 modeliavimų skiriasi taip: SA-ELM nuo 1,788 iki 1,950 ir GA-ELM – nuo 1,776 iki 3,622.

3.17 paveiksle parodytas dviejų modelių tikslumo palyginimas pagal maksimalų iteracijų skaičių ir atskleista, kokia įtaka yra daroma skaičiavimo trukmei. Kiekvienam alternatyviam optimizavimo modeliui buvo atlikti 125 modeliavimai.




3.17 pav. RMSE priklausomybė nuo maksimalaus iteracijų skaičiaus
Fig. 3.17. Dependence of RMSE on the maximum number of iterations

3.17 paveiksle matyti, kad didesnis GA-ELM iteracijų skaičius lemia skaičiavimo trukmę, galinčią užtrukti ilgiau nei 1 min. Tuo metu SA-ELM modeliavimo laikas svyruoja nuo 1 iki 5 s. Iš gautų rezultatų akivaizdu, kad abiem modeliams 10 iteracijų galima laikyti pagrįstu skaičiumi. RMSE vertės iš visų 125 modeliavimų skiriasi taip: SA-ELM nuo 1,777 iki 3,602 ir GA-ELM – nuo 1,766 iki 3,602.

Visi modeliavimai atskleidžia, kad abu optimizavimo algoritmai demonstruoja labai panašų tikslumą, o pagrindinis skirtumas yra modeliavimo trukmė, tai yra pagrindinis SA-ELM metodo privalumas, nes visais atvejais prognozavimo trukmė yra ypač trumpa.

Nustčius SA-ELM ir GA-ELM modelių jautrumą, atliktas kitas tyrimas, kuriuo galima nustatyti, kiek efektyvus prognozavimas, kai yra sumažėjęs vartotojų užimtumas. Faktinis užimtumo sumažėjimas priklausė nuo 2020 m. prasidėjusios COVID-19 pandemijos ir judėjimo bei lankymosi viešose vietose apribojimų valstybės lygmeniu. Duomenys kaupti pandemijos laikotarpiu pastate B, ir modeliavimas atliekamas taikant modelį SA-ELM, nes ankstesniajame tyrime šis modelis parodė turintis privalumų lyginant su genetinio algoritmo optimizacija (trumpesnė skaičiavimo trukmė, tai yra ypač svarbu).

Užimtumo prognozavimas taikomas įvairiais pandemijos laikotarpiais (3.18 pav.) – kiekvienam laikotarpiui yra sukaupta daugiau nei 2 mėnesių duomenų. Kaip anksčiau buvo nustatyta (Bielskus ir kt., 2020; Motuzienė et al. 2021), pakankamu stebėjimų laikotarpiu yra 4 savaitės. Šiame bandyme tyrimo laikotarpiai yra ilgesni nei 4 savaitės kiekvieną pandemijos laikotarpį, bet prognozavimo tikslumas yra nepakankamas ir jo patikimumas siekia $R^2 = 0,27$ griežto karantino laikotarpiu ir atitinkamai padidėja lengvojo karantino ir poka-rantininiu laikotarpiu iki $R^2=0,50$; $0,56$. Patikimumo padidėjimas tiesiogiai priklauso nuo pastato B vartotojų lankomumo, nes pandemijos laikotarpiu buvo at-laisvinami judėjimo apribojimai Lietuvos vartotojams.



3.18 pav. Vartotojų užimtumo prognozė skirtingais COVID-19 pandemijos laikotarpiais
Fig. 3.18. Forecast of user employment during different periods of the COVID-19 pandemic

Iš anksčiau nustatytų tyrimų matyti, kad geras modelio prognozavimo rodiklis priklauso nuo vartotojų užimtumo ir pakankamo laikotarpio duomenų. Todėl atvejų, kai COVID-19 pandemijos laikotarpiu vartotojų judėjimo ir elgsenos laisvė buvo apribota ir vartotojų buvimas patalpose sumažėjęs, modelis negali patikimai prognozuoti.

Šiame skyriuje yra aptariamas mašininio mokymosi modelis su optimizacija ir jo validavimas. Trečiojo etapo tyrimo schema pateikta 3.19 paveiksle. Tolesniems skaičiavimams pasirinkta viena iš dviejų modelių optimizacijų yra SA-ELM. Imituoto atkaitinimo optimizacija parodė aukštą prognozavimo patikimumą ir tikslumą, taip pat trumpiausią skaičiavimo trukmę, kuri yra ypač svarbi greitai vėdinimo sistemos veiklai.

Siekiant validuoti modelį būtina atlikti atitinkamus testavimo etapus. Validavimo programa pateikta toliau lentelėje, kurioje yra bandoma apmokyti AI-VAV įvertinus pradinių duomenų pateikimą, tai yra nepateikiant ir savaime mokantis bei pateikiant jau realius duomenis, pagal kuriuos AI-VAV prognozuoja. Siekiant teisingai įvertinti AI-VAV lyginama su VAV vėdinimo sistemos funkcija ir jos energijos sutaupymo potencialu. 3.4 lentelėje pateikti modelių bandymai ir paklaidų bei gerumo dydžiai. Kaip ir anksčiau buvo paminėta, taikomos tokios paklaidų skaičiavimo metodikos, tai yra:

- determinacijos koeficientas (R^2), kuriuo nusakomas modelio gerumas, kuo šis rodiklis arčiau 1, tuo modelis geriau sudarytas;
- šaknis iš vidutinės kvadratinės paklaidos (angl. *Root Mean Squared Error*, RMSE), kuria nustatoma modelio paklaida, kuo šis dydis mažesnis, tuo modelis tiksliau prognozuoja.

3.4 lentelė. AI-VAV metodikos modeliavimo programa


Table 3.4. AI-VAV methodology simulation program

Bandymas	Apmokomas AI-VAV	Pastatai					
		A		B		C	
		RMSE	R^2	RMSE	R^2	RMSE	R^2
I	su 100 laiko žingsnių	–	–	0,61	0,07	0,59	0,20
II	su 8000 laiko žingsnių	–	–	–	–	0,63	0,33
III	A su 9500 laiko žingsnių C su 10 000 laiko žingsnių	2,17	0,71	–	–	0,59	0,34
IV	A su 9500 laiko žingsnių C su 10 000 laiko žingsnių Darbo valandos 8.00–18.00	3,38	0,29	–	–	1,28	0,2
V	SA-ELM kartu su VAV funkcija A su 9500 laiko žingsnių C su 10 000 laiko žingsnių	2,28	0,70	–	–	0,61	0,30


Iš gautų tyrimų matyti, kad pastato B AI-VAV modelis mokosi esant ypač mažam prognozavimo patikimumui, tai yra vartotojų užimtumas nepakankamas mokyti, todėl pastatas B nėra toliau vertinamas kituose validavimo etapuose.

Tokia pastato B modelio skaičiavimo nepatikimumo ir nesimokymo priežastis yra per mažas vartotojų užimtumas patalpose, tuomet kai buvo ribojamas žmonių judėjimas Lietuvos Respublikos teritorijoje COVID-19 pandemijos laikotarpiu.

Toliau pateiktos dviejų pastatų – A ir C – grafinės išraiškos (3.20 ir 3.21 pav.), kuriose pavaizduoti 3-iojo varianto validavimo rezultatai. Grafike pateikti ir validuoti AI-VAV duomenys, taip pat ir alternatyvios VAV sistemos pagal CO₂ koncentraciją duomenys. Iš grafiko matyti, kad VAV sistemai buvo suformuotas tikslas siekti 800 ppm CO₂ koncentracijos palaikymo, o AI-VAV modeliui – 52 m³/h oro kiekio 1 asmeniui tikslas. Matoma tendencija, kad AI-VAV mokinosi ir pateikė vartotojų patalpoje prognozes, kai CO₂ koncentracija yra daugiau kaip 700 ppm. Dėl šios priežasties vėdinimo sistemos su AI-VAV valdymo funkcija atveju oro kokybė buvo prastesnė nei su VAV valdymo funkcija.



3.20 pav. Pastato C mokymosi rezultatai AI-VAV 3-uoju variantu
Fig. 3.20. Results of training with option 3 of AI-VAV for building C



3.21 pav. Pastato A mokymosi rezultatai AI-VAV 3-uoju variantu
Fig. 3.21. Results of training with option 3 of AI-VAV for building A


Kaip teigta anksčiau, AI-VAV modelis mokosi ir palaiko prastesnę oro kokybę nei nustatytasis VAV modelis, tad šiuos skirtumus galima pamatyti toliau grafikuose (3.22 pav.). Grafikuose pavaizduotos pastatų A ir C 3-iojo varianto oro užterštumo anglies dvideginio histogramos. Laikotarpis, kuriuo AI-VAV neužtikrina oro kokybės, pateiktas 3.5 lentelėje.

4-uoju tyrimo variantu IVAV modeliui buvo perduoti tik darbo dienų ir darbo valandų duomenys, t. y. eliminuojant vartotojų nebuvimo laikotarpį, kuris galimai daro įtaką prognozavimo ir sistemos veikimo patikimumui.

Toliau pateiktos dviejų pastatų – A ir C – grafinės išraiškos (3.23 ir 3.24 pav.), kuriose yra nurodyti 4-ojo varianto validavimo rezultatai. Grafike pateikiami validuoti AI-VAV duomenys, taip pat ir alternatyvios VAV sistemos pagal CO₂ koncentraciją duomenys. Grafike atskleidžiama, kad VAV sistemai buvo iškeltas tikslas siekti 800 ppm CO₂ koncentracijos palaikymo, o AI-VAV modeliui iškeltas tik 52 m³/h oro kiekio 1 asmeniui tikslas. Pastebima tendencija, kad AI-VAV mokinosi ir pateikė vartotojų patalpoje prognozes, kai CO₂ koncentracija yra daugiau kaip 700 ppm.


4-uoju variantu pasiektos *RMSE* ir *R²* reikšmės: pastatui A atitinkamai 3,38 ir 0,29, o pastatui C – atitinkamai 1,28 ir 0,2. Tai rodo du kartus prastesnį prognozavimo patikimumą nei kitais variantais. Ši patikimumo paklaida atsirado todėl, kad įvertinus duomenis buvo neįtrauktos nedarbo valandos, kurios nusako

vartotojų buvimą (nebuvimą) – 0. Todėl įvertinus šį pakeitimą prognozavimo patikimumas yra panašus ir į kitų variantų.




3.22 pav. AI-VAV ir VAV CO₂ pasikartojimo histograma 3-uoju variantu. Kairėje – pastato A, o dešinėje – pastato C

Fig. 3.22. AI-VAV and VAV CO₂ repetition histogram in option 3. Building A is on the left, and C is on the right




3.23 pav. Pastato C mokymosi rezultatai 4-uoju variantu

Fig. 3.23. Results of training with option 4 for building C



3.24 pav. Pastato A mokymosi rezultatai 4-uoju variantu
Fig. 3.24. Results of training with option 4 for building A

4-ojo varianto oro užterštumo anglies dvideginio histogramoje (3.25 pav.) pastebimi AI-VAV ir VAV prognozių skirtumai kaip ir anksčiau pateiktose histogramose (laikotarpis, kuriuo AI-VAV neužtikrina oro kokybės, pateiktas 3.5 lentelėje).



3.25 pav. AI-VAV ir VAV anglies dioksido pasikartojimo histograma 4-uoju variantu.


Kairėje – pastato A, o dešinėje – pastato C

Fig. 3.25. AI-VAV and VAV carbon dioxide repetition histogram in option 4; building A is on the left, and C is on the right


4-uoju testavimo variantu yra mašininio mokymosi modelis su optimizacija, veikiantis su tradicine VAV sistema. Tai reiškia, kad jei prognozė neatitinka tikrosios padėties, o CO₂ koncentracija viršija 950 ppm, tuomet įsijungia VAV sistemos algoritmas, kuris patikslina ir sumažina CO₂ koncentraciją iki tol, kol ji grįžta į numatytąją koncentraciją, ir vėl įjungiamas mašininio mokymosi modelis. Pastatų A ir C skaičiavimo rezultatai pateikti 3.26 ir 3.27 paveiksluose.

4-uoju variantu SA-ELM ir VAV sistemų algoritmai taikomi kartu. Pastebima, kad prognozavimo kokybė šiuo atveju nepasikeitė lyginant su anksčiau validuotais variantais, bet apskritai oro kokybė pagerėjo CO₂ koncentracijos užterštumo aspektu. Visgi pastebima, kad pastate A oro CO₂ koncentracija neviršijo 1000 ppm tirtuoju laikotarpiu (tai sudarė 0 %), taip pat ir pastate C ji nebuvo pakilusi daugiau 1000 ppm. CO₂ pasikratojimo histogramos pateiktos 3.27 paveiksle.


Iš testuotų variantų pastebima, kad pastato A 3-uoju ir 4-uoju variantais diskomforto trukmė buvo ilgesnė – tai yra iš viso 1,6 % tirtuoju laikotarpiu, todėl pagal užterštumą patalpoje tinkamiausias yra 5-asis variantas, kai AI-VAV veikia kartu su VAV. Taip pasiekiamas geras energijos taupymo rezultatas (jis aptariamas 3.5 poskyryje). Pastate C 2-uoju variantu CO₂ koncentracija viršijo 2,2 %, o trečiuoju – beveik 1,5 %. Todėl ir šiuo (kaip ir pastato A atveju) atveju geriausiu variantu laikytinas 5-asis.



3.26 pav. Pastato C mokymosi rezultatai AI-VAV 5-uoju variantu
Fig. 3.26. Results of training with option 5 of AI-VAV for building C



3.27 pav. Mokymosi rezultatai pastato A AI-VAV 5-uoju variantu
Fig. 3.27. Results of training with option 5 of AI-VAV for building A



3.28 pav. AI-VAV ir VAV CO₂ pasikartojimo histograma 5-uoju variantu.
 Kairėje – pastato A, o dešinėje – C

Fig. 3.28. AI-VAV and VAV CO₂ repetition histogram in option 5.
 Building A is on the left, and C is on the right

3.5 lentelė. Trukmė, kurią AI-VAV modelio validavimas neužtikrina oro kokybės
Table 3.5. Duration of non-assurance of air quality for the validation of the AI-VAV model

Pastatas A			CO ₂ koncentracija, kai daugiau 1000 ppm	
Variantai	Laikotarpis	Trukmė val.	≥1000 ppm, val.	≥1000 ppm, %
3	6786	566	9	1,6
4	2085	531	20	3,7
5	6786	566	0	0,0
Pastatas C			CO ₂ koncentracija, kai daugiau 1000 ppm	
Variantai	Laikotarpis	Trukmė val.	≥1000 ppm, val.	≥1000 ppm, %
2	10 448	871	19	2,2
3	8001	667	10	1,5
4	8000	2036	0	0,0
5	11 630	969	0	0,0

Visi aptarti variantai atskleidė didelį prognozavimo tikslumą, bet vis dėlto tiksliausiai prognozuota pastato A atveju. Atliktas modelio validavimas parodo, kad esant mažai kintančiam (nedinamišakam) vartotojų užimtumui prognozuojama geriau nei pastatuose, kuriuose vartotojų užimtumas yra nepastovus. Todėl siekiant AI-VAV modelį pritaikyti pastato vėdinimo sistemose, darbo vietų užimtumas turi būti kuo pastovesnis, sumažinant darbo vietų skaičių, daliai darbuotojų dirbant nuotoliniu būdu, o kitiems biuruose pagal įmonės viduje nustatytą darbo vietų užimtumo grafiką.

3.4. Vėdinimo sistemos energetinis efektyvumas taikant mašininio mokymosi modelį

Šioje skyriaus dalyje yra aptariamas mašininio mokymosi modelio su optimizacijomis validavimas pagal 3.4 lentelės programą ir šiluminės energijos suvartojimas, išreiškiamas 1 žmogui. Pasirinktuoju būdu yra patogiau vertinti bet kokio dydžio pastatą su žinomu vartotojų skaičiumi. Pažymima, kad validavimas nebus aptariamas 1-uju variantu, kadangi AI-VAV prognozavimo rezultatai buvo nepatenkinami.

Skaiciuojant energetinius elektros ir šilumos sutaupymo rezultatus buvo pasirinkti kriterijai, kurie pateikti 3.6 lentelėje.

3.6 lentelė. Energinio vertinimo metu priimti kriterijai**Table 3.6.** Criteria adopted during the energy assessment

Pasirinktas kriterijus	Reikšmė
Šildymo sezono trukmė dienomis	225
Šiltojo sezono trukmė dienomis	140
Šildymo sezono vidutinė temperatūra, °C	0,2
Pastatų patalpų vidutinė temperatūra šildymo laikotarpiu, °C	22
Vėdinimo įrenginio ventiliatorių efektyvumas, %	50
Vėdinimo įrenginio ventiliatorių variklių efektyvumas, %	90
Šilumos atgavimo įrenginio efektyvumas, %	70
Vėdinimo sistemos bendras pasipriešinimas, Pa	350

Skaiciavimo rezultatai pateikti 3.7 lentelėje, kurioje pateikiamas bendras energijos suvartojimas, išreikštas 1 žmogui, ir energetinis sistemų palyginimas, atskleidžiantis, kiek sutaupoma ar prarandama dėl sistemų veikimo palyginimų.

Iš 3.6 lentelėje pateiktų duomenų pastebima, kad energijos suvartojimas tarp AI-VAV ir VAV kiekvienai tirtai sistemai yra pakankamai nedideliu skirtumu ir siekia nuo 3,8 iki 12,9 %. Tuo metu taikant AI-VAV ir CAV energijos suvartojimo skirtumas išauga iki 80 % (įskaitant šiluminę ir elektrinę energiją). Didžiausias energijos sutaupymas tarp AI-VAV ir VAV pasiekiamas A pastatui 3-uoju variantu, bet kaip aptarta anksčiau, šiuo variantu ilgiausiai neužtikrinama oro kokybė, CO₂ koncentracijai viršijant 900 ppm. Galiausiai, pastatui C visais variantais energijos suvartojimas pastebimas panašus.

3.7 lentelė. Energetinis vertinimas validavimo variantu**Table 3.7** Energy evaluation as a validation option

Pastatas A										
	El. kWh/žm.			Šil. kWh/žm.			El. skirtumas, %		Šil. skirtumas, %	
Var.	AI-VAV	VAV	CAV	AI-VAV	VAV	CAV	AI-VAV / VAV	AI-VAV / CAV	AI-VAV / VAV	AI-VAV / CAV
I	-	-	-	-	-	-	-	-	-	-
II	-	-	-	-	-	-	-	-	-	-
III	9,5	10,9	44,6	29,5	33,9	138,7	12,9	78,7	12,9	78,7
IV	12,8	13,3	44,6	38,7	41,4	138,7	4,1	71,4	6,6	72,1
V	10,3	11,1	44,6	32,0	34,6	138,7	7,5	76,9	7,5	76,9

3.7 lentelės pabaiga

Pastatas C										
	El. kWh/žm.			Šil. kWh/žm.			El. skirtumas, %		Šil. skirtumas, %	
Var.	AI-VAV	VAV	CAV	AI-VAV	VAV	CAV	AI-VAV / VAV	AI-VAV / CAV	AI-VAV / VAV	AI-VAV / CAV
1	-	-	-	-	-	-	-	-	-	-
2	10,0	10,5	42,7	31,1	32,6	138,7	4,7	76,6	4,7	77,6
3	9,2	9,7	42,7	28,7	30,2	138,7	4,7 %	78,4	4,7	79,3
4	9,6	10,1	42,7	29,7	31,4	138,7	5,5 %	77,6	5,5	78,6
5	9,2	9,6	42,7	28,6	29,7	138,7	3,8 %	78,5	3,8	79,4

Aptarti energetiniai suvartojimo palyginimai atskleidžia, kad optimaliausias energijos suvartojimo palyginimas tarp skirtingų sistemų pastatuose A ir C pasiekiamas 5-uju variantu; pastato A atveju tarp AI-VAV ir VAV energijos sutau-poma 7,5 %, o pastato C atveju – 3,8 %. Be to, patalpų užterštumas viso tirtjojo laikotarpio metu neviršija pastato A atveju 3,8 %, o pastato C – 0,4 %.

3.5. Trečiojo skyriaus išvados

1. Atlikus eksperimentinius tyrimus pastatuose A, B ir C buvo sukaupti tokie duomenys kaip patalpų oro temperatūra, santykinė drėgmė, judrumas ir CO₂ užterštumo lygis, taip pat pasyvi vartotojų elgsena – darbo vietų užimtumas. Tyrimo laikotarpis pastatuose truko nuo 11 iki 38 savaičių. Pastebėta, kad visuose pastatuose vartotojų užimtumas savaitės pradžioje yra didžiausias, o darbo savaitės pabaigoje sumažėja.
2. Nustatyta, kad visą tyrimo laikotarpį nebuvo 100 % darbo vietų užimtumo, o dažniausiai pasikartojantis pastatų A, B ir C užimtumas, kai $< 0,033 \text{ žm./m}^2$ yra pastate A – 58 %, pastate B – 99 % ir C – 90 %. Didžiausias oro užterštumas anglies dvideginiu yra pastate A (tarp 701–800 ppm), tuo metu pastatuose B ir C sudaro 501–600 ppm (atitinkamai išreiškta procentais visam tirtam laikotarpiui pastate A – 29,1 %, pastate B – 81,7 % ir pastate C – 66,5 %). Visuose pastatuose susiduriama su ta pačia problema – pervėdinimu, be to, faktinis patalpų užimtumas taip pat mažesnis, nei nurodo normos.
3. Taikant Pirsono (angl. *Pearson*) koreliacijos koeficientus, nustatyta, kad tirtų pastatų vartotojų darbo vietų užimtumas geriausiai

koreliuoja su CO₂ koncentracija, kuri siekia nuo 0,506 iki 0,834. Todėl prognozuojant vartotojus tinkamiausias ryšys pastebimas tarp vartotojų ir CO₂ koncentracija.

4. Analizė parodė, kad 4 savaitių matavimo laikotarpis gali būti laikomas pakankamu patikimam pastato užimtumo prognozavimui, kai standartinis užimtumas yra didesnis nei 0,05 žm./m². Kai patalpų užimtumas yra nuo 0,00 iki 0,032 žm./m², prognozavimo modelio patikimumas sumažėja, nes prognozavimo patikimumas priklauso nuo patalpų užimtumo – tai yra $R^2 = 0,27 - 0,56$.
5. Tirtieji modeliai (GA-ELM ir SA-ELM) parodė panašų ir aukštą prognozavimo tikslumą visą matuotą laikotarpį. Prognozuojant biurų užimtumą pastatuose, naudojant matavimų metu gautus CO₂ koncentracijų duomenis, buvo surinkti rezultatai iš 900 modeliavimo atvejų tikslumo jautrumui patikrinti. Pakankamas prognozavimo tikslumas buvo pasiekiamas abiejų modelių atveju, kai neuronų skaičius buvo ne mažesnis kaip 25, populiacijos dydis – ne mažesnis kaip 20 ir pakartojimų skaičius – ne mažesnis kaip 10, esant modeliavimo greičiui iki 5 s.
6. Pastatų A, B ir C patalpų vėdinimo sistemų ir oro užterštumo jose skaičiavimo modelyje buvo atlikti 5 skirtingi AI-VAV bandymų variantai, kurių metu siekta nustatyti didžiausią skaičiavimo modelio apmokymo galimybę. Dėl nepatikimo prognozavimo pastato B atveju validavimas nebuvo atliekamas.
7. Aptarti energetiniai suvartojimo palyginimai atskleidžia, kad efektyviausias energijos suvartojimo palyginimas tarp skirtingų sistemų atskleidžiamas pastatų A ir C atveju, ir tai yra 5-asis variantas. Šiuo variantu pastate A pasiektas energijos sutaupymas tarp AI-VAV ir VAV sudarė – 7,5 %, tuo metu pastate C – 3,8 %, be to, patalpų užterštumas CO₂ koncentracija viso modeliuoto laikotarpio metu neviršijo 1000 ppm.

Bendrosios išvados

1. Atlikta mokslinių tyrimų analizė parodė, kad mašininio mokymosi modelių (dirbtinio intelekto) taikymas prognozuojant pasyvią vartotojų elgseną (patalpų užimtumą) yra efektyvus būdas optimizuoti pastatų energijos suvartojimą, bet šiandien pastatų ŠVOK sistemose tai yra sunkiai įgyvendinama dėl duomenų stokos ar jų prastos kokybės.
2. Šio darbo apimtyje buvo tiriami trys atvirojo tipo biurai. Tyrimų metu nustatyta, kad faktinis darbo vietų užimtumas yra daugiau nei 3 kartus mažesnis, nei nurodo normatyviniai dokumentai, skirti pastatų projektavimui, o išanalizavus stebėsenos duomenis, stipriausia koreliacija buvo rasta tarp patalpų užimtumo ir CO₂ koncentracijos patalpose. Tai leidžia daryti išvadą, kad prognozuojant patalpų užimtumą galima valdyti vėdinimo sistemą.
3. Tyrimų metu buvo analizuotas vartotojų elgsenos prognozavimas pagal CO₂ koncentraciją taikant ekstremalaus mokymosi mašininių modelių (ELM) su dviem skirtingomis optimizacijomis – genetiniu (GA) ir imituoto atkaitimo algoritmais (SA). Nustatyta, kad patikimam modelio prognozavimui pakanka 4 savaitių stebėsenos duomenų (5 minučių laiko žingsniu), o jautrumo analizė atskleidė, kad optimalus modelio prognozavimo patikimumas ir trumpiausia prognozavimo

- trukmė yra tais atvejais, kai neuronų skaičius yra mažesnis kaip 25, populiacijos dydis – ≥ 20 ir pakartojimų skaičius – ≥ 10 .
4. Vėdinimo sistemos energijos taupymas yra pagrįstas vartotojų darbo vietos prognozavimu taikant mašininio mokymosi modelį SA-ELM. Modeliavimo rezultatai parodė, kad pastatui B, kai vartotojų užimtumas yra mažesnis nei $0,033 \text{ žm./m}^2$ ir tai sudaro 99 % viso tirtojo laiko, tuomet prognozavimas nėra patikimas. Taip pat nustatyta, kad pastato A modeliavimo rezultatai parodė aukštą prognozavimo patikimumą: RMSE siekė nuo 2,17 iki 2,2, R^2 paklaida sudarė apie 0,7. O pastato C patikimumas yra mažesnis nei A, jo atveju RMSE siekė nuo 0,57 iki 0,61, R^2 paklaida – nuo 0,2 iki 0,34.
 5. Atlikus sukurto AI-VAV modelio validavimą, buvo modeliuoti penki variantai ir jų metu nustatyta, kad siekiant tinkamai išmokyti modelius reikalingas duomenų kiekis turi būti mažesnis nei 8500 matavimo taškų, o tai sudaro 4 savaites. Iš penkių AI-VAV modelių tinkamiausias yra penktasis, nes pastato A atveju daugiausiai energijos sutaupoma tarp AI-VAV ir VAV – 7,5 %, o pastato C atveju – 3,8 %, kai palaikomas patalpų užterštumas viso modeliuoto laikotarpio metu neviršijo 1000 ppm.

Literatūra ir šaltiniai

Abualigah, L., Al Shinwan, M., Al Jawabreh, Y., Ahmad, E., Alsalti, O., Eideh, T., Al Diaba, M., & Shehab, M. Genetic algorithm in Wireless Networking: a Review. *International Journal of Science and Advanced Information Technology*, 8(6), November – December 2019, 148–154.

<https://doi.org/10.30534/ijisait/2019/238620198>

Afram, A., Janabi-Sharifi, F., Fung, A. S., & Raahemifar, K. (2017). Artificial neural network (ANN) based model predictive control (MPC) and optimization of HVAC systems: A state of the art review and case study of a residential HVAC system. *Energy and Buildings*, 141, pp. 96–113. <https://doi.org/10.1016/j.enbuild.2017.02.012>

Ai, B., Fan, Z., & Gao, R. X. (2014, June). Occupancy estimation for smart buildings by an auto-regressive hidden Markov model. In *2014 American Control Conference*, pp. 2234–2239. IEEE. <https://doi.org/10.1109/ACC.2014.6859372>

Alshibania, A., & Subhi Alshamraniba, O. (2017). ANN/BIM-based model for predicting the energy cost of residential buildings in Saudi Arabia. *Journal of Taibah University for Science*, 11, 1317–1329. <https://doi.org/10.1016/j.jtusci.2017.06.003>

Balvedi, B. F., Ghisi, E., & Lamberts, R. (2018). A review of occupant behaviour in residential buildings. *Energy and Buildings*, 174, 495–505. <https://doi.org/10.1016/j.enbuild.2018.06.049>

Bielskus, J., & Motuzienė, V. (2019). Vartotojų energijos taupymo ir šiluminio komforto supratimo tyrimas darniuose pastatuose. *Mokslas – Lietuvos ateitis*, 11, 1–5. <https://doi.org/10.3846/mla.2019.10599>

Bielskus, J., & Motuzienė, V. The influence of schedules of open office occupants' presence on building's energy demand. In *11th International conference "Environmental Engineering"*, 21–22 May 2020, Vilnius Gediminas Technical University, Lithuania (pp. 1–7). <https://doi.org/10.3846/enviro.2020.827>

Bielskus, J., Motuzienė, V., Vilutienė, T., & Indriulionis, A. (2020). Occupancy prediction using differential evolution online sequential extreme learning machine model. *Energies*, 13(15), 4033. <https://doi.org/10.3390/en13154033>

Carbone, R., & Armstrong, J. S. (1982). Evaluation of extrapolative forecasting methods: Results of a survey of academicians and practitioners. *Journal of Forecasting*, 1, 215–217. <https://doi.org/10.1002/for.3980010207>

Chatzikonstantinou, I., Sariyildiz, S. Approximation of simulation-derived visual comfort indicators in office spaces: a comparative study in machine learning. *Architectural Science Review*, 59(4), 307–322. <https://doi.org/10.1080/00038628.2015.1072705>

Chen C., Li K., Duan M., & Li K. (2017). Chapter 6 – Extreme learning machine and its applications in big data processing. In *Intelligent Data-Centric Systems* (pp. 117–150), <https://doi.org/10.1016/B978-0-12-809393-1.00006-4>

Chen, Z., & Soh, Y. C. (2014, August). Modeling building occupancy using a novel inhomogeneous Markov chain approach. In *2014 IEEE International Conference on Automation Science and Engineering (CASE)*, pp. 1079–1084. <https://doi.org/10.1109/CoASE.2014.6899459>

Chen, Z., Jiang, C., & Xie, L. (2018). A novel ensemble ELM for human activity recognition using smartphone sensors. *IEEE Transactions on Industrial Informatics*, 15(5), 2691–2699. <https://doi.org/10.1109/TII.2018.2869843>

Chen, Z., Masood, M. K., & Soh, Y. C. (2016). A fusion framework for occupancy estimation in office buildings based on environmental sensor data. *Energy and Buildings*, 133, 790–798. <https://doi.org/10.1016/j.enbuild.2016.10.030>

Cheng, C. C., & Lee, D. (2019). Artificial intelligence-assisted heating ventilation and air conditioning control and the unmet demand for sensors: Part 1. Problem formulation and the hypothesis. *Sensors*, 19(5), 1131. <https://doi.org/10.3390/s19051131>

Chokwitthaya, C., Zhu, Y., Dibiano, R., & Mukhopadhyay, S. (2019). Combining context-aware design-specific data and building performance models to improve building performance predictions during design. *Automation in construction*, 107, 102917. <https://doi.org/10.1016/j.autcon.2019.102917>

Coleman, S., Touchie, M. F., Robinson, J. B., & Peters, T. (2018). Rethinking Performance Gaps: A Regenerative Sustainability Approach to Built Environment Performance Assessment. *Sustainability*, 10(12), 4829.

<https://doi.org/10.3390/su10124829>

D. Yan, & Hong, T. (2018). *Definition and Simulation of Occupant Behavior in Buildings. Annex 66 Final Report.*

<https://annex66.org/?q=Publication%0Ahttps://www.iea-ebc.org/projects/project?AnnexID=66>

De Wilde, P. (2014). The gap between predicted and measured energy performance of buildings: A framework for investigation. *Automation in Construction*, 41, 40–49. <https://doi.org/10.1016/j.autcon.2014.02.009>

Delzendeh, E., Wu, S., Lee, A., & Zhou, Y. (2017). The impact of occupants' behaviours on building energy analysis: A research review. *Renewable and sustainable energy reviews*, 80, 1061–1071. <https://doi.org/10.1016/j.rser.2017.05.264>

Delzendeh, E., Wu, S., Lee, A., & Zhou, Y. (2017). The impact of occupants' behaviours on building energy analysis: A research review. *Renewable and sustainable energy reviews*, 80, 1061–1071. <https://doi.org/10.1016/j.rser.2017.05.264>

Diraco, G., Leone, A., & Siciliano, P. (2015). People occupancy detection and profiling with 3D depth sensors for building energy management. *Energy and Buildings*, 92, 246–266. <https://doi.org/10.1016/j.enbuild.2015.01.043>

Dobbs, J. R., & Hincey, B. M. (2014). Model predictive HVAC control with online occupancy model. *Energy Build.*, 82, 675–684. <https://doi.org/10.1016/j.enbuild.2014.07.051>

Dobbs, J. R., & Hincey, B. M. (2014). Predictive HVAC control using a Markov occupancy model—IEEE Conference Publication. In *Proceedings of the IEEE Conference—American Control Conference (ACC), Portland, OR, USA, 4–6 June 2014.* <https://doi.org/10.1109/ACC.2014.6859389>

Dong, B., & Lam, K. P. (2011). Building energy and comfort management through occupant behavior pattern detection based on a large-scale environmental sensor network. *Journal of Building Performance Simulation*, 4(4), 359–369. <https://doi.org/10.1080/19401493.2011.577810>

Dong, B., Andrews, B., Lam, K. P., Höynck, M., Zhang, R., Chiou, Y. S., & Benitez, D. (2010). An information technology enabled sustainability test-bed (ITEST) for occupancy detection through an environmental sensing network. *Energy and Buildings*, 42(7), 1038–1046. <https://doi.org/10.1016/j.enbuild.2010.01.016>

Engineering ToolBox. (2005). Air Change Rates in typical Rooms and Buildings. https://www.engineeringtoolbox.com/air-change-rate-room-d_867.html

Fan, B., Du, Z., Jin, X., Yang, X., & Guo, Y. (2010). A hybrid FDD strategy for local system of AHU based on artificial neural network and wavelet analysis. *Building and environment*, 45(12), 2698–2708. <https://doi.org/10.1016/j.buildenv.2010.05.031>

Frei, M., Deb, C., Stadler, R., Nagy, Z., & Schlueter, A. (2020). Wireless sensor network for estimating building performance. *Automation in Construction*, 111, 103043. <https://doi.org/10.1016/j.autcon.2019.103043>

Hammad, A. W. A. (2019). Minimising the Deviation between Predicted and Actual Building Performance via Use of Neural Networks and BIM. *Buildings*, 9, 131; <https://doi.org/10.3390/buildings9050131>

Han, Z., Gao, R. X., & Fan, Z. (2012, May). Occupancy and indoor environment quality sensing for smart buildings. In *2012 IEEE international instrumentation and measurement technology conference proceedings* (pp. 882–887). <https://doi.org/10.1109/I2MTC.2012.6229557>

Happle, G., Fonseca, J. A., & Schlueter, A. (2018). A review on occupant behavior in urban building energy models. *Energy and Buildings*, 174, 276–292. <https://doi.org/10.1016/j.enbuild.2018.06.030>

Hong, T., Taylor-Lange, S. C., D'Oca, S., Yan, D., & Corgnati, S. P. (2016). Advances in research and applications of energy-related occupant behavior in buildings. *Energy and buildings*, 116, 694–702. <https://doi.org/10.1016/j.enbuild.2015.11.052>

Hong, T., Wang, Z., Luo, X., Zhang, W. (2020). State-of-the-art on research and applications of machine learning in the building life cycle. *Energy & Buildings*, 212, 109831. <https://doi.org/10.1016/j.enbuild.2020.109831>

Hong, T., Yan, D., D'Oca, S., & Chen, Ch.-fei. (2017). Ten questions concerning occupant behavior in buildings: The big picture. *Building and Environment*, 114, 518–530. <https://doi.org/10.1016/j.buildenv.2016.12.006>

Hong, Y., Hammad, A. W. A., Akbarnezhad, A., & Arashpour, M. (2020). A neural network approach to predicting the net costs associated with BIM adoption. *Automation in Construction*, 119, 103306. <https://doi.org/10.1016/j.autcon.2020.103306>

Huang, G., Wang, S., & Xu, X. (2009). A robust model predictive control strategy for improving the control performance of air-conditioning systems. *Energy Conversion and Management*, 50(10), 2650–2658. <https://doi.org/10.1016/j.enconman.2009.06.014>

Huang, G.-B., Zhu, Q.-Y., & Siew, Ch.-K. (2004). Extreme learning machine: a new learning scheme of feedforward neural networks. In *2004 IEEE International Joint Conference on Neural Networks*, 25–29 July 2004. <https://doi.org/10.1109/IJCNN.2004.1380068>

Ilambirai, R. C., Sivasankari, P., Padmini, S., & Chowdary, H. (2019, June). Efficient self-learning artificial neural network controller for critical heating, ventilation and air conditioning systems. In *AIP Conference Proceedings*, 2112(1), 020163. AIP Publishing LLC. <https://doi.org/10.1063/1.5112348>

Jain, S., & Madamopoulos, N. (2016, October). Ahorrar: Indoor occupancy counting to enable smart energy efficient office buildings. In *2016 IEEE International Conferences on Big Data and Cloud Computing (BDCloud), Social Computing and Networking (SocialCom), Sustainable Computing and Communications (SustainCom) (BDCloud-SocialCom-SustainCom)*, pp. 469–476. <https://doi.org/10.1109/BDCloud-SocialCom-SustainCom.2016.75>

- Jia, M., & Srinivasan, R. (2020). Building performance evaluation using coupled simulation of EnergyPlus™ and an occupant behavior model. *Sustainability*, 12(10), 4086. <https://doi.org/10.3390/su12104086>
- Jiang, Ch., Chen, Z., Su, R., Masood, M. K., & Soh, Y. C. (2020). Bayesian filtering for building occupancy estimation from carbon dioxide concentration. *Energy and Buildings*, 206, 109566. <https://doi.org/10.1016/j.enbuild.2019.109566>
- Jradi, M., Arendt, K., Sangogboye, F. C., Mattera, C. G., Markoska, E., Kjærgaard, M. B., & Veje, C.T., & Jørgensen, B.N. (2018). ObepME: An online building energy performance monitoring and evaluation tool to reduce energy performance gaps. *Energy & Buildings* 166, 196–209. <https://doi.org/10.1016/j.enbuild.2018.02.005>
- Kim, S., Jung, S., & Baek, S. M. (2019). A model for predicting energy usage pattern types with energy consumption information according to the behaviors of single-person households in South Korea. *Sustainability*, 11(1), 245. <https://doi.org/10.3390/su11010245>
- Lam, K. P., Höynck, M., Dong, B., Andrews, B., Chiou, Y. S., Zhang, R., ... & Choi, J. (2009). Occupancy detection through an extensive environmental sensor network in an open-plan office building. *IBPSA Building Simulation*, 145, 1452–1459.
- Liang, Q., Wang, Q., Zhang, Q., Wei, J., Lim, S. X., Zhu, R., Hu, J., Wei, W., Lee, Ch., Sow, Ch.-H., Zhang, W., Wee, A. T. Sh. (2019). High-performance, room temperature, ultra-broadband photodetectors based on air-stable PdSe2. *Advanced Materials*, 31(24), 1807609. <https://doi.org/10.1002/adma.201807609>
- Liu, X., Yang, Y., Li, R., & Sieverts Nielsen, P. (2019). A stochastic model for residential user activity simulation. *Energies*, 12(17), 3326. <https://doi.org/10.3390/en12173326>
- Lorenz, C. L., Packianather, M., Spaeth, A., & Bleil De Souza, C. (2018). Artificial neural network-based modeling for daylight evaluations. <https://doi.org/10.1080/00038628.2019.1700901>
- Lorenz, C-L., Packianather, M., Spaeth, A. B., Bleil De Souza, C. Artificial Neural Network-Based Modelling for Daylight Evaluations, TU Delft, Faculty of Architecture and the Built Environment, the Netherlands 05-07 June 2018.
- Ma, G., Liu, Y., & Shang, Sh. (2019). Building Information Model (BIM) and Artificial Neural Network (ANN) Based System for Personal Thermal Comfort Evaluation and Energy Efficient Design of Interior Space, *Sustainability*, 11, 4972, <https://doi.org/10.3390/su11184972>
- Mahdavi, A., Tahmasebi, F., Gunay, B., O'Brien, W., & D'Oca, S. (2017). *Technical Report : Occupant Behavior Modeling Approaches and Evaluation*.
- Masood, M. K., Jiang, Ch., & Chai Soh, Y. (2018). A novel feature selection framework with Hybrid Feature-Scaled Extreme Learning Machine (HFS-ELM) for indoor occupancy estimation. *Energy and Buildings*, 158, 1139–1151. <https://doi.org/10.1016/j.enbuild.2017.08.087>

Menezes, A. C., Cripps, A., Bouchlaghem, D., & Buswell, R. (2012). Predicted vs. actual energy performance of non-domestic buildings: Using post-occupancy evaluation data to reduce the performance gap. *Applied Energy*, 97, 355–364. <https://doi.org/10.1016/j.apenergy.2011.11.075>

Milenkovic, M., & Amft, O. (2013). Recognizing energy-related activities using sensors commonly installed in office buildings. *Procedia Computer Science*, 19, 669–677. <https://doi.org/10.1016/j.procs.2013.06.089>

Motuzienė, V., Bielskus, J., Lapinskienė, V., & Rynkun, G. (2021). Office building's occupancy prediction using extreme learning machine. model with different optimization algorithms. *Environmental and Climate Technologies*, 25(1), 525–536. <https://doi.org/10.2478/rtuect-2021-0038>

Motuzienė, V., Bielskus, J., Lapinskienė, V., & Rynkun, G. (2021). Energy performance gap analysis in energy efficient residential buildings in Lithuania. *Environmental and Climate Technologies*, 25(1), 610–620. <https://doi.org/10.2478/rtuect-2021-0045>

Motuzienė, V., Bielskus, J., Lapinskiene, V., Rynkun, G., & Bernatavičienė J. (2022). Office buildings occupancy analysis and prediction associated with the impact of the COVID-19 pandemic. *Sustainable Cities and Society*, 77, 103557. <https://doi.org/10.1016/j.scs.2021.103557>

Moustafa, W. S., Abdelrahman, M. M., & Hegazy, I. R. (2018, April). Building performance assessment of user behavior as a post occupancy evaluation indicator: Case study on youth housing in Egypt. In *Building Simulation*, 11(2), 389–403. Tsinghua University Press. <https://doi.org/10.1007/s12273-017-0395-7>

Nguyen, Q. H., Ly, H.-B., Ho, L. S., Al-Ansari, N., Le, H. V., Tran, V. Q., Prakash, I., & Pham, B. Th. (2021). Influence of Data Splitting on Performance of Machine Learning Models in Prediction of Shear Strength of Soil. Hindawi. *Mathematical Problems in Engineering*, 15, Article ID 4832864. <https://doi.org/10.1155/2021/4832864>

Nguyen, Q. H., Ly, H.-B., Ho, L. S., Al-Ansari, N., Le, H. V., Tran, V. Q., Prakash, I., & Pham, B. T. (2021). Influence of Data Splitting on Performance of Machine Learning Models in Prediction of Shear Strength of Soil. *Mathematical Problems in Engineering*, 4832864. <https://doi.org/10.1155/2021/4832864>

Nicol, J. F., & Humphreys, M. (1998). Understanding the adaptive approach to thermal comfort. *ASHRAE transactions*, 104(1), 991–1004.

Nicole Harper. (2017). How to Close the Building Energy Performance Gap. *Construction International*, 21.

O'Brien, W., Tahmasebi, F., Andersen, R. K., Azar, E., Barthelmes, V., Belafi, Z. D., Berger, Ch., Chen, D., De Simone, M., d'Oca, S., Hong, T., Jin, Q., Khovalyg, D., Lamberts, R., Novakovic, V., Park, J. Y., Plagmann, M., Rajus, V. S., Vellei, M., Verbruggen, S, & Zhou, J. (2020). An international review of occupant-related aspects

of building energy codes and standards. *Building and Environment*, 179(2019, December), 106906. <https://doi.org/10.1016/j.buildenv.2020.106906>

Page, J., Robinson, D., Morel, N., & Scartezzini, J.-L. (2008). A generalized stochastic model for the simulation of occupant presence. *Energy and buildings*, 40(2), 83–98. <https://doi.org/10.1016/j.enbuild.2007.01.018>

Pedersen, T. H., Nielsen, K.U., & Petersen, S. (2017). Method for room occupancy detection based on trajectory of indoor climate sensor data. *Building and Environment*, 115, 147–156. <https://doi.org/10.1016/j.buildenv.2017.01.023>

Peper, S., & Feist, W. (2016). Monitoring und Bilanzrechnung: Ganz ohne Performance GAP. In Proceedings of the CESBP Central European Symposium on Building Physics and BauSIM.

Pereira, P. F., & Ramos, N. M. (2018). Detection of occupant actions in buildings through change point analysis of in-situ measurements. *Energy and Buildings*, 173, 365–377. <https://doi.org/10.1016/j.enbuild.2018.05.050>

Re Cecconia, F., Morettia, N., & Tagliabue L. C. (2019, August). Application of artificial neural network and geographic information system to evaluate retrofit potential in public school buildings. *Renewable and Sustainable Energy Reviews*, 110, pp. 266–277. <https://doi.org/10.1016/j.rser.2019.04.073>

Ruiz-Torrubiano, R., & Suárez, A. (2010). Hybrid Approaches and Dimensionality Reduction for Portfolio Selection with Cardinality Constraints. *IEEE Computational Intelligence Magazine*, 5, pp. 92–107. <https://doi.org/10.1109/MCI.2010.936308>

Salimi, S., Liu, Z., & Hammad, A. (2019). Occupancy prediction model for open-plan offices using real-time location system and inhomogeneous Markov chain. *Building and Environment*, 152, 1–16. <https://doi.org/10.1016/j.buildenv.2019.01.052>

Sandels, C., Widén, J., & Nordström, L. (2015, July). Simulating occupancy in office buildings with non-homogeneous Markov chains for Demand Response analysis. In 2015 IEEE Power & Energy Society General Meeting (pp. 1–5). <https://doi.org/10.1109/PESGM.2015.7285865>

Sardianou, E. (2008). Estimating space heating determinants: An analysis of Greek households. *Energy and buildings*, 40(6), 1084–1093. <https://doi.org/10.1016/j.enbuild.2007.10.003>

Schaumann, D., Pilosof, N. P., Sopher, H., Yahav, J., & Kalay, Y. E. (2019). Simulating multi-agent narratives for pre-occupancy evaluation of architectural designs. *Automation in Construction*, 106, 102896. <https://doi.org/10.1016/j.autcon.2019.102896>

Sieniutycz, S., & Jeżowski, J. Brief review of static optimization methods. *Energy Optimization in Process Systems and Fuel Cells* (Third Edition) 2018, 1–41. <https://doi.org/10.1016/B978-0-08-102557-4.00001-3>

Socolow, R. H. (1978, April). The Twin Rivers program on energy conservation in housing: highlights and conclusions. *Energy and Buildings*, 1(3), 207–242. [https://doi.org/10.1016/0378-7788\(78\)90003-8](https://doi.org/10.1016/0378-7788(78)90003-8)

Sun, Y., Haghighat, F., & Fung, B. C. M. (2020). A review of the -state-of-the-art in data -driven approaches for building energy prediction. *Energy Build.*, 221, 110022. <https://doi.org/10.1016/j.enbuild.2020.110022>

SUSRIS. (2013). International Energy Agency 2013. <https://iea.blob.core.windows.net/assets/a22dedb8-c2c3-448c-b104-051236618b38/WEO2013.pdf> Hong, T., Wang, Z., Luo, X., & Zhang, W. (2020). State-of-the-art on research and applications of machine learning in the building life cycle. *Energy and Buildings*, 212, 109831. <https://doi.org/10.1016/j.enbuild.2020.109831>

Vanus, J., Gorjani, O. M., & Bilik, P. (2019). Novel proposal for prediction of CO2 course and occupancy recognition in Intelligent Buildings within IoT. *Energies*, 12(23), 4541. <https://doi.org/10.3390/en12234541>

Virote, J., & Neves-Silva, R. (2012). Stochastic models for building energy prediction based on occupant behavior assessment. *Energy and buildings*, 53, 183–193. <https://doi.org/10.1016/j.enbuild.2012.06.001>

Wang, C., Yan, D., & Jiang, Y. (2011, June). A novel approach for building occupancy simulation. *Building simulation*, 4(2), 149–167. Tsinghua Press. <https://doi.org/10.1007/s12273-011-0044-5>

Wang, S., & Jin, X. (2000). Model-based optimal control of VAV air-conditioning system using genetic algorithm. *Building and Environment*, 35(6), 471–487. [https://doi.org/10.1016/S0360-1323\(99\)00032-3](https://doi.org/10.1016/S0360-1323(99)00032-3)

Wang, W., Chen, J., & Song, X. (2017). Modeling and predicting occupancy profile in office space with a Wi-Fi probe-based Dynamic Markov Time-Window Inference approach. *Building and Environment*, 124, 130–142. <https://doi.org/10.1016/j.buildenv.2017.08.003>

Wang, Z., & Ding, Y. (2015). An occupant-based energy consumption prediction model for office equipment. *Energy and Buildings*, 109, 12–22. <https://doi.org/10.1016/j.enbuild.2015.10.002>

Yamaguchi, Y.; Shimoda, Y.; Mizuno, M. (2003). Development of district energy system simulation model based on detailed energy demand. In *Proceedings of the Eighth International IBPSA Conference, Eindhoven, The Netherlands, 11–14 August 2003*, 8, 1443–1450.

Yan, D., Hong, T., Dong, B., Mahdavi, A., D'Oca, S., Gaetani, I., & Feng, X. (2017). IEA EBC Annex 66: Definition and simulation of occupant behavior in buildings. *Energy and Buildings*, 156, 258–270. <https://doi.org/10.1016/j.enbuild.2017.09.084>

Yang, Z., & Becerik-Gerber, B. (2014). Modeling personalized occupancy profiles for representing long term patterns by using ambient context. *Building and Environment*, 78, 23–35. <https://doi.org/10.1016/j.buildenv.2014.04.003>

Yingyi, Ch., Song, L., Liu, Y., Yang, L., & Li, D. (2020). A Review of the Artificial Neural Network Models for Water Quality Prediction. *Applied Sciences*, 10, 5776. <https://doi.org/10.3390/app10175776>

- Yingyi, Ch., Song, L., Liu, Ye., Yang, L., & Li, D. (2020). A review of the artificial neural network models for water quality prediction. *Applied Sciences*, 10(17), 5776. <https://doi.org/10.3390/app10175776>
- Yu, Z., Haghighat, F., Fung, B. C., & Yoshino, H. (2010). A decision tree method for building energy demand modeling. *Energy and Buildings*, 42(10), 1637–1646. <https://doi.org/10.1016/j.enbuild.2010.04.006>
- Zakula, T., Armstrong, P. R., & Norford, L. (2014). Modeling environment for model predictive control of buildings. *Energy and buildings*, 85, 549–559. <https://doi.org/10.1016/j.enbuild.2014.09.039>
- Zaritsky, A., Sipper, M. The Preservation of favored building blocks in the struggle for fitness: the puzzle algorithm. In *IEEE Transactions on Evolutionary Computation*, 8(5), 43–455. <https://doi.org/10.1109/TEVC.2004.831260>
- Zhan S.-H., Lin, J., Zhang, Z.-J., Zhong, Y.-W. (2016). List-based simulated annealing algorithm for traveling salesman problem. *Corporation Computational Intelligence and Neuroscience*, 1712630. <https://doi.org/10.1155/2016/1712630>
- Zhang, Y., Bai, X., Mills, F. P., & Pezzey, J. C. (2018). Rethinking the role of occupant behavior in building energy performance: A review. *Energy and Buildings*, 172, 279–294. <https://doi.org/10.1016/j.enbuild.2018.05.017>
- Zhou, S., & Liu, D. (2015). Prediction of daylighting and energy performance using artificial neural network and support vector machine. *American Journal of Civil Engineering and Architecture*, 3(3A), 1–8.

Autoriaus mokslinių publikacijų disertacijos tema sąrašas

Straipsniai recenzuojamuose mokslo žurnaluose

Bielskus, J., Motuzienė, V., Vilitienė, T., & Indriulionis, A. (2020). Occupancy prediction using differential evolution online sequential extreme learning machine model. *Energies*, 13(15), 4033. <https://doi.org/10.3390/en13154033>

Motuziene, V., Bielskus, J., Lapinskiene, V., Rynkun, G., & Bernatavičienė J. (2022). Office buildings occupancy analysis and prediction associated with the impact of the COVID-19 pandemic. *Sustainable Cities and Society*, 77 (2022) 103557. <https://doi.org/10.1016/j.scs.2021.103557>

Straipsniai kituose leidiniuose

Bielskus, J., & Motuzienė, V. (2019). Vartotojų energijos taupymo ir šiluminio komforto supratimo tyrimas darniuose pastatuose. *Mokslas – Lietuvos ateitis*, 11, 1–5. <https://doi.org/10.3846/mla.2019.10599>

Bielskus, J., & Motuzienė, V. The influence of schedules of open office occupants' presence on building's energy demand. In *11th International Conference "Environmental Engineering"*, 21-22 May 2020, Vilnius Gediminas Technical University, Lithuania. <https://doi.org/10.3846/enviro.2020.827>

Motuziene, V., Bielskus, J., Lapinskienė, V., & Rynkun, G. (2021). Office Building's Occupancy Prediction Using Extreme Learning Machine. *Model with Different Optimization Algorithms. Environmental and Climate Technologies*, 25(1), 525–536. <https://doi.org/10.2478/rtuct-2021-0038>

Motuziene, V., Bielskus, J., Lapinskienė, V., & Rynkun, G. (2021). Energy Performance Gap Analysis in Energy Efficient Residential Buildings in Lithuania. *Environmental and Climate Technologies*, 25(1), 610–620. <https://doi.org/10.2478/rtuct-2021-0045>

Summary in English

Introduction

Formulation of the problem

The amounts of energy consumed by buildings are increasing despite them becoming more energy efficient. In the buildings sector, the growth in energy consumption is directly linked to the needs of users and their requirements. Increasingly more new buildings are being designed with user ergonomics in mind rather than energy efficiency or building sustainability certificates (BREEAM, LEED, Well, etc.). In Q3 and Q4 of 2022, the political situation in Europe – with energy prices doubling and even tripling – will make energy savings even more relevant, linking them to the cost of running buildings.

User behaviour is a key factor that needs to be understood and adapted to save energy in buildings.

Machine learning techniques, or, more generally, artificial intelligence, are increasingly employed in user behaviour research. While research on the application of AI shows great potential for reducing energy demand, it still faces challenges due to the large amount and quality of data collected. Research on the impact of user behaviour on energy costs and on improving energy cost prediction is developing rapidly, but no fundamental solutions have yet been proposed.

Relevance of the dissertation

Reducing energy consumption is becoming increasingly relevant to achieving the sustainable development goals of the European Union. In 2021, the EU set goals for reducing greenhouse emissions in the European Union by 55% before 2030 (compared to the 1990 levels) and achieving complete climate neutrality by 2050. Increasing energy efficiency in buildings remains a pressing matter since buildings continue to account for around 40% of all energy consumption volumes across the EU.

Practice shows that actual demands for energy in buildings often substantially differ from those designed, and this performance gap can sometimes reach a staggering 1.5 times (Harper, 2017). For calculations under the certification methodology for building energy performance, the impact of building occupants is considered against a fixed standard behaviour pattern, which leads to repeat errors in design projects.

Minimisation of the impact of user behaviour on the levels of energy consumption can be achieved at several stages of the lifecycle of a building: the design, the implementation, and the operation phase. All these three phases are conducive to predicting user behaviour.

The predictions are made with a variety of models that usually involve machine learning and guarantee a prediction accuracy and reliability rate of up to 90%.

With HVAC systems, the highest level of energy savings can be achieved by upgrading ventilation systems. Erickson et al. (2015) and Brandemuehl et al. (1999) found that a reduction of the average amount of supply air in buildings where the expected is measured against the highest possible number of users results in a 10–15% drop in the level of energy consumption, while the quality of the indoor areas remains fair.

This dissertation addresses the potential of energy savings in a building ventilation system.

The object of research

The object of the research is open-plan offices and their ventilation systems.

The aim of the dissertation

To develop a theoretical model for the control of a variable air volume system using machine-learning algorithms (AI-VAV) to reduce energy consumption by researching the passive behaviour of users in office buildings.

The tasks of the dissertation

The following objectives were set to achieve the objective of the work:

1. To analyse scientific and other literature on the topic of predicting user behaviour and applying machine learning in building information models;
2. To conduct long-term monitoring of the behaviour of real building occupants, analyse data on occupancy and microclimate parameters and prepare a data sample for the development of a mathematical prediction model.

3. To analyse the feasibility of applying machine learning-based methods for predicting occupancy, develop a model, and apply and validate it by evaluating the following:
 - the importance of the input data for the model and the need for a minimum amount of data for forecasting;
 - the sensitivity of the models to variations of the machine learning parameters and the reliability of the model's estimations at low occupancy rates.
4. To validate the developed mathematical model of the AI-VAV system in a *Matlab* environment and:
 - to determine the qualitative reliability of this model in predicting occupancy and calculating CO₂ concentrations in the simulated room;
 - to provide recommendations for the application of the model developed.
5. Present application recommendations for the developed model.

The research methodology

Experimental studies were carried out in open-plan office buildings to collect indoor and outdoor microclimatic parameters as well as occupancy data. Data analysis and processing were carried out in preparation for the use of the empirical data in a machine-learning model.

The prediction of user behaviour was carried out in *Matlab*, where an extreme learning machine (ELM) model was written by integrating various optimisation algorithms.

The predictions of UB were made using *Matlab* software with an extreme machine-learning (ELM) model that had two different optimisations: a genetic algorithm (GA) and a simulated annealing (SA) algorithm.

This dissertation looks into a ventilation system that has its controls grounded on a machine-learning model, which is simulated by replacing the control system with the newly developed AI-VAV model in a *Matlab* environment. The advantage of this system is that it allows the incoming data to be processed faster and applied to predict the number of people in the room.

Scientific novelty of the dissertation

The dissertation produced the following new results for the science of civil engineering:

1. An analysis of user behaviour was performed, and data on passive user behaviour under different conditions, including the periods of lockdown and mitigation of the COVID-19 pandemic, was collected.
2. A machine learning model with different optimisation algorithms was applied to predict user behaviour. A sensitivity analysis was performed to identify the optimal parameters for high prediction reliability and the shortest computation time.
3. Based on experimental studies, an AI-VAV model of the ventilation system has been developed to simulate an open-plan office space, predicting user behaviour.

Practical significance of achieved results

This paper presents a machine learning model with optimisation algorithms to predict user behaviour based on outdoor and indoor physical parameters. The model allows for predicting user behaviour and correspondingly controlling the ventilation system to supply fresh air to the indoor areas according to the actual expected demand. The results can be used not only in open-air buildings but also in other types of buildings (e.g., shopping malls, theatres, etc.) to program the control of HVAC systems, predicting the actions to be taken according to recurring events required during operation.

Defended statements

1. The machine learning model ELM, with its optimisations, predicts user occupancy to an accuracy of 0.9 (according to the determination coefficient R^2) with a user occupancy rate of at least 0.033 m²/hp;
2. For the machine learning model, four weeks of carbon dioxide and user job monitoring data (in 5-minute time steps) is sufficient to make a reliable prediction;
3. The AI-VAV model allows for an increase in the energy efficiency of the ventilation system by predicting the occupancy in the room and by controlling the operation of the ventilation system.

Approval of the research results

Six articles were published on the topic of the dissertation: two in peer-reviewed scientific journals with a citation index in *Clarivate Analytics Web of Science* databases (Bielskus et al. 2020; Motuzienė et al. 2021); one in international conference publications referenced in the *Clarivate Analytics Web of Science* database *Conference Proceedings* (Bielskus et al. 2020); and three in other peer-reviewed journals (Bielskus et al. 2019, Motuzienė et al. 2021; Motuzienė et al. 2021).

The results of the research were publicised at two scientific conferences in Lithuania and abroad:

- The 11th International Conference Environmental Engineering 2020 in Vilnius, Lithuania;
- The Conference of Environmental and Climate Technologies (CONNECT) 2021 in Riga, Latvia.

The structure of the dissertation

The dissertation consists of an introduction, three chapters, a summary of results, and three annexes.

The dissertation consists of 113 pages (excluding appendices), 20 numbered formulas, 43 figures and 17 tables. In total, 100 literature sources were consulted during the writing of the dissertation.

1. User behaviour and prediction models

The available energy modelling engines, such as TRNSYS, ESP-r, IES or EnergyPlus, calculate energy consumption in buildings using a uniform calculation methodology. The final results are data for the design of heating, cooling and ventilation systems, lighting, CO₂ emissions, heat loss to the environment, total energy consumption and costs, and other data. The reliability of the final results is strongly related to the accuracy of the detail of the original building model (which is often simplified) at the time of its input into the software.

Most specialists who design energy models choose the default occupancy graphs in energy modelling software for their energy analysis because they do not have enough knowledge to estimate the likely real occupancy.

Data collection and modelling usually focus on individual user behaviour traits rather than all of them. User activity profiles or patterns, often referred to as occupancy patterns, describe the presence, absence and movement of users in spaces. These models describe different types of adaptive and maladaptive behaviour, such as adjusting blinds, opening windows, switching lights and using appliances. User activity models link the presence and activities of users and may consider the use of appliances, lighting or water associated with these activities (Happle et al. 2018). All user profiles are assigned to specific premises, e.g., offices, shops, medical facilities, etc.

The field of research on understanding and modelling user behaviour in buildings is developing rapidly (Schweiker, 2017), and the results provide a clearer understanding of user behaviour and its impact on energy costs. However, there are still gaps in the research (Zhang et al. 2018). Deterministic and statistical models of user behaviour are being developed, showing the dependence on the variables input data applied in their development (Balvedi et al. 2018). The conversion and integration of the incoming data into building energy modelling tools to reduce the gap between predicted and actual energy consumption in buildings is still a challenge. In addition, it would be appropriate to research the interrelationships between different user behaviours to develop realistic assumptions for building energy consumption forecasting (Delzendeh et al. 2017).

Consumer behaviour graphs are always specified as static elements in energy modelling tools. They shall be specified for all building types, excluding open-plan offices, and without considering occupant profiles, which influence different occupancy schedules. In reality, the situation is different, with users switching to active regulation to improve comfort conditions. Different methods of modelling user behaviour are used to investigate real user behaviour and the resulting profiles and apply them to modelling processes.

While user behaviour prediction models show a high degree of predictive accuracy and capability, all the models discussed above have their limitations. One of the key indicators for reliable forecasting in the studies discussed is the quantity and quality of the data. Therefore, the lack of sufficiently reliable data makes the models' forecasting unreliable.

Artificial intelligence, commonly applied to the HVAC management of buildings, has significant economic benefits, but AI-enabled buildings are extremely rare. There are several reasons and future challenges for this situation:

- Shortage of AI and HVAC professionals.

- Complex and challenging application of artificial intelligence in the design phase.
- Cybersecurity aspects.
- Higher initial investment than the cost of the traditional HVAC systems adopted today.
- Insufficient relevant data is available to inform the evaluation and application of AI-based software.

2. Data and research methodology

This chapter presents the control of air volume in a ventilation system using a machine learning approach with optimisation. The machine learning model is an Extreme Learning Machine Model (ELM) with optimisations via Simulated Annealing (SA) and Genetic Algorithm (GA). The optimisation application aims to obtain data with a high degree of deviation compared to adjacent data. The optimised data is fed to the ELM, and the algorithm is trained on the data that is fed. The objective of the ELM is to predict the near future based on the variables obtained and to adjust the ventilation system air quantities accordingly.

The methodology of the whole dissertation research is presented graphically in Figure S2.1. This dissertation consists of three main phases, namely:

1. Experimental research on the site. Compilation and analysis of data files;
2. Analysis and validation of user behaviour prediction models;
3. An AI-VAV model is proposed to control the ventilation system of a building to reduce energy consumption.

Sustainable and energy-efficient office buildings with open-plan office space were selected for the actual occupancy profiles. The buildings offer better conditions for their users.

While recording the microclimate and use behaviour in the buildings during COVID-19, accessing the inside of the buildings was particularly difficult as office owners and tenants were reluctant to let anyone in because of the potential risks, despite taking all precautions and following the instructions of the authorities.

All the buildings under research are office buildings built in 2017 in Vilnius city. The buildings vary in size and height, with Building A being nine floors high; Building B, two floors high; and Building C, eleven floors high. All buildings have class B energy certification but have different energy consumption parameters according to their energy certification, with Building A consuming less than half of the energy according to the energy certification standard compared to Building B and Building C.

One of the most important measurement parameters in this work is the presence of occupants, which influences changes in the energy consumption of indoor climate support systems.

On the premises of the subject sites, PIR motion detectors were installed under the desk at each workstation.

Traditional solutions based on room-specific control alone are insufficient to achieve optimal HVAC control of a single room. Machine learning or other models based on statistical data processing are used to address this problem. One such model applied in this work is the Extreme Machine Learning model with simulated annealing and genetic algorithm optimisations.




Fig. S2.1. Methodological scheme of the dissertation research

The ELM algorithm is one of the machine learning models first introduced by Huang in 2004 (Huang et al. 2004). The algorithm is simple, runs extremely fast and has good generalisation performance.

The pseudocode written by the extreme machine learning model is shown in Figure S2.2.

START: learning data: $\{x_i\}^T \in R^n$ and $\{t_i\}^T \in R^m$ ($x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$ and $t_i = [t_{i1}, t_{i2}, \dots, t_{in}]^T \in R^m$)
 Hidden output neuron function $g(x)$ and number of hidden neurons, L ;
Assurance: Output weight vector, β
 Random parameter for hidden neuron generation (w_j, x_j, b_j), here $j = 1, \dots, N$;
 Calculate hidden layer output matrix H ;
 Calculate output weights $\beta: \beta = H^+TH^+T$, here $T = [t_1, t_2, \dots, t_N]^T$;
END

Fig. S2.2. ELM pseudocode

One optimisation of the extreme machine learning approach is the Genetic Algorithm, which mimics natural selection and genetics. The genetic algorithm operates on a population of possible solutions and searches for a result that is equal to or close to the answer to a given problem. A new generation of solutions is produced from the previous generation of solutions through crossover (recombination) and mutation, repeating the process all over again. This process leads to the evolution of solutions that are better than the ones from which they were created.

Below is the pseudocode for the standard genetic algorithm. The pseudocode was introduced by Zaritsky in 2004 (Zaritsky & Sipper, 2004). The pseudocode is shown in Figure S2.3.

Parameter (s): M – genome blocks are determined (pop size)
Output: a set of chromosomes is randomly selected from M
Initialization
 $t \leftarrow 0$
 Initialize $Y(t)$ to random individuals from M
 EVALUATE-FITNESS-GA ($M, Y(t)$)
When termination conditions are not met
 select chromosome from M_t (match fitness)
 select individuals from $Y(t)$
 Recombine individuals
do {
 mutate individuals
 EVALUATE – FITNESS-GA (M , chromosomes are inserted from outside)
 $Y(t+1) \leftarrow$ Newly created individuals
 $t \leftarrow t+1$
Return (superstring derived from best individual $Y(t)$)
Procedure EVALUATE-FITNESS -GA (M, Y)
 M - seto f population size
 Y –population of individuals
For each individual $j \in Y$
 generate derived string
do {
 resulting values O_j or T_j
 fit(y) fitness function

Fig. S2.3. Pseudocode of the standard genetic algorithm (Zaritsky et al. 2004)

One extreme machine learning approach to optimisation is Simulated Annealing (SA), which is a low-complexity, powerful stochastic algorithm that is used to solve a variety of optimisation problems (Zhan et al. 2015). It is based on finding the global minimum of a given objective function to avoid local minima by performing a random neighbourhood search.

```

Generate initial temperature,  $t_0$ ;
Generate initial configuration,  $x_0$ ;
While convergence criteria are not met do:
    Fix temperature,  $t$ ;
    for  $j = 1, \dots, N$ ,
        Choose randomly an element  $y \in N(x)$ .
        If  $f(y) < f(x)$ , then  $x \leftarrow y$ .
        Else, with probability  $p(x, y, t) = \exp\left(\frac{-(f(y) - f(x))}{t}\right)$ , then  $x \leftarrow y$ .
    End for
End while
Return the best solution found.

```

Fig. S2.4. Pseudocode of the simulated annealing algorithm (Ruiz-Torrubiano et al. 2010)

The pseudocode was introduced by Ruiz-Torrubiano (Ruiz-Torrubiano et al. 2010) and is presented in Figure S2.4.

The main principle of a variable ventilation system is to ensure the right air quality in the room, and one of the cases is to maintain a constant concentration of carbon dioxide. This test is carried out in *Matlab* and *Excel* so that each time the predicted number of occupants and the fresh air supplied changes, the carbon dioxide concentration will be recalculated according to the actual number of occupants in the room.

Indoor carbon dioxide concentrations can be calculated using theoretical equations that require the exact number of occupants and the length of time the occupants are indoors, as well as indoor air repeatability and initial carbon dioxide concentrations.

The concentration of carbon dioxide in a room after a certain time (when there are occupants) is expressed with the following formula (S2.1) (Engineering ToolBox, 2005):

$$c = \left(\frac{q}{n \cdot V}\right) \cdot \left[1 - \left(\frac{1}{e^{nt}}\right)\right] + (c_0 - c_i) \cdot \frac{1}{e^{nt}} + c_i \quad (\text{S2.1})$$

The value of indoor carbon dioxide concentration is directly related to the number of occupants in the room, so the theoretical calculations require knowledge of the activity level of the occupants and the amount of CO₂ exhaled per person.

In further studies, resting and low-activity CO₂ concentrations are used, as the occupancy in office buildings is low and carbon dioxide emissions per user are 0.013 m³/h.

3. Analysis and verification of machine learning models with optimisations for ventilation system control

The first phase of the research involved collecting and analysing data for the three buildings, A, B, and C.

The measurements show that the density of people in the buildings, i.e., in the offices, is very low for the dominant part of the time, ranging from 58% to 99%.

Thus, based on reliable long-term measurements in the three buildings, the most recurrent minimum occupancy is 99% (in Building B), with 0.033 persons/m² or fewer. Slightly more diversity in the density distribution is observed in Buildings A (measured before the pandemic) and C (measured at or after the pandemic).

The CO₂ concentrations were only assessed during working hours, showing that CO₂ concentrations fluctuate between 400–700 ppm most of the time and do not exceed 600 ppm most of the time, without tapping into the energy-saving potential of controlling the ventilation system according to actual demand, i.e. the control is not linked to the actual occupancy rate. A similar situation exists in other buildings, as can be seen in Figure S3.1.




Fig. S3.1. Building air pollution with carbon dioxide (ppm) histogram (working hours).
Left-to-right: Building A, Building B, and Building C

In all buildings, the air meets the requirements for IDA category 1 virtually all the time (88.4%–99.9% of the time), but for a very large part of the time, it is below 600 ppm, which some sources refer to as the threshold for IDA category 1. Even when the air quality is maintained at the highest standards, the premises are still ventilated between 29.1% and 81.7% of the working time. This points to inefficient management of the systems and an untapped potential for energy savings.

One of the main requirements of the data transmitted to the machine learning model is that the data must be correlated. This means that the reliability of the prediction will depend on the correlation of the data. In this case, the data for each of the buildings A, B, and C, and the aggregate data for them was transferred to the computer program PSPP and

Pearson correlation coefficients were calculated. The results of the calculation are shown in the two-sided matrix in Figure S3.2.




Fig. S3.2. Intercorrelation relationship between buildings A, B, C and overall data

From the two-sided matrices in Figure 3.10, it can be seen that user workplace occupancy has the highest correlation with carbon dioxide concentration, ranging from 0.506 to 0.834, with a linear correlation of 1. As for the other parameters, although there are correlations with users, they are relatively weak and of little significance in the application of the methodologies and the prediction of user habits. Thus, in this case, the correlation between users and carbon dioxide will be further explored in the paper.

Once it was determined that the carbon dioxide concentration was the most appropriate in terms of the data, a sensitivity analysis was performed using Extreme Machine Learning with SA and GA optimisations. Data from Buildings A and B was used for the sensitivity analysis.

Figure S3.3 shows the learning and prediction reliability of both methodologies between one and eight weeks. The graph shows that SA-ELM provides slightly higher accuracy than GA-ELM after eight weeks of learning data. Thus, this demonstrates that short-term measurements lead to low reliability due to insufficient data sets. At that point, from week four onwards, the reliability of the forecasting becomes sufficient and reaches a higher R^2 (0.75 and above), which only proves that four weeks are enough to learn the methodology.




Fig. S3.3. The reliability of the methodology depends on the measurement period

The results of the previous calculations have a high prediction confidence of an R^2 above 0.75, but to determine the shortest prediction time and to maintain the high confidence, a sensitivity analysis was carried out by varying the following parameters: the number of neurons, the population size and the maximum iteration count. The accuracy of their modelling results is expressed in RMSE.

A larger number of neurons increases the accuracy of the prediction, with a significant effect from 25 neurons onwards. There is no point for the number of neurons to go even higher, as the change in prediction from 25 neurons onwards is not significant. The genetic algorithm's number of 20 is based on the population size, as a larger population number has almost no effect on the accuracy and only increases the simulation time. In the SA-ELM model, the population size does not affect the accuracy of the results whatsoever, and the computation time, which can be up to a few seconds, is not shown in the graph at all. A comparison of the accuracy of the two models in terms of the maximum number of iterations and the impact on the computational time is revealed. It is observed that the higher number of iterations of GA-ELM leads to a computation time that can take more than 1 minute. At the same time, the simulation time of SA-ELM varies between 1 and 5 s. It is clear from the results that ten iterations can be considered a reasonable amount for both models.

Having established the sensitivity of the SA-ELM and GA-ELM models, further research was carried out to determine how effective forecasting is when consumer occupancy is reduced. The actual reduction in occupancy was conditional on the COVID-19 pandemic, which began in 2020, and the restrictions on movement and access to public places at a national level. The data was collected during the pandemic period in Building B, and the simulations were carried out using the ELM-SA methodology, as this model has been shown in previous research to have advantages over Genetic Algorithm Optimisation (shorter computational time, which is particularly important).

Occupancy forecasting is applied during various periods of the pandemic. In this research, the survey periods are longer than four weeks in each pandemic period, but the

accuracy of the prediction is insufficient and its reliability R^2 is as low as 0.27 in the strict quarantine period and increases in the light quarantine and post-quarantine periods to an R^2 of 0.50 and 0.56, respectively.

Five ventilation system control models, AI-VAV, were created using machine learning models. Validation of the methodology requires appropriate testing steps. To assess the AI-VAV correctly, it is compared with the ventilation function of the VAV and its energy-saving potential.

Below are the calculation results of the fifth AI-VAV model. The fifth testing option is a machine learning model with optimisation running on a traditional VAV system. This means that if the prediction does not match the actual situation and the carbon dioxide concentration exceeds 950 ppm, then the VAV system algorithm is triggered, which adjusts and reduces the CO₂ concentration until it is restored to the predicted concentration and the machine learning model is triggered again. The calculation results for Buildings A and C are shown in Figure S3.4.




Fig. S3.4. AI-VAV and VAV carbon dioxide repetition histogram in the fifth variant. Building A is on the left, and C is on the right

The fifth option combines the algorithms of the SA-ELM and VAV systems. It is observed that the quality of prediction in this case has not changed compared to the previously validated variants, but the overall air quality has improved in terms of pollution with carbon dioxide concentration. However, it is noted that in Building A, the air CO₂ concentration did not exceed 1000 ppm during the period under research (0%), nor did it rise above 1000 ppm in Building C. The histograms of carbon dioxide sequestration are shown in Figure S3.4.

The simulations under the above conditions show that the difference in energy savings between AI-VAVs and VAVs is not significant and only starts at 3.8%. This difference could be reduced if the indoor carbon dioxide concentration is kept below 1000 ppm. Nevertheless, the AI-VAV model is superior to VAV system control and requires only four weeks of data to train the system to a sufficient level of flow prediction and ventilation control.

The results of the energy consumption and savings calculations are presented in Table 3.7, which shows the total energy consumption per person and the energy comparison of the systems in terms of savings or losses due to the comparison of system performances.

Table 3.7. Energy evaluation as a validation option

Building A										
Options	Electricity kWh/ person			Heat kWh/person			Electricity difference, %		Heat difference, %	
	AI- VAV	VAV	CAV	AI- VAV	VAV	CAV	AI- VAV / VAV	AI- VAV / CAV	AI- VAV / VAV	AI- VAV / CAV
III	9.5	10.9	44.6	29.5	33.9	138.7	12.9	78.7	12.9	78.7
IV	12.8	13.3	44.6	38.7	41.4	138.7	4.1	71.4	6.6	72.1
V	10.3	11.1	44.6	32.0	34.6	138.7	7.5	76.9	7.5	76.9
Building C										
II	10.0	10.5	42.7	31.1	32.6	138.7	4.7	76.6	4.7	76.6
III	9.2	9.7	42.7	28.7	30.2	138.7	4.7	78.4	4.7	78.4
IV	9.6	10.1	42.7	29.7	31.4	138.7	5.5	77.6	5.5	77.6
V	9.2	9.6	42.7	28.6	29.7	138.7	3.8	78.5	3.8	78.5

Based on the data presented in Table 3.7, the difference in energy consumption for each of the systems studied with the options between AI-VAV and VAV is relatively small, ranging from 3.8 to 12.9 per cent.

The above energy consumption comparisons suggest that the most optimal comparison of energy consumption between the different systems is Option 5 for Building A and C since it achieves savings of 7.5% between AI-AV and VAV for Building A and 3.8% for Building C, while the indoor pollution does not exceed 3.8% for Building A and 0.4% for Building C over the whole period studied.

General conclusions

1. The research analysis has shown that the application of machine-learning models (artificial intelligence) to predict passive user behaviour (occupancy of indoor premises) is an effective way to optimise energy consumption in buildings, yet one that today can be hardly implemented in the HVAC systems of buildings owing to the shortage or inadequate quality of data.
2. This dissertation addressed three open-plan offices. The research has shown that the factual occupancy of workplaces is more than three times below what is prescribed in the normative documents regulating the design of the buildings, and analysis of monitoring data has pointed to the occupancy of premises and the indoor CO₂ concentrations as having the highest correlation, which suggests that

the ventilation system can be controlled by predicting the occupancy of indoor areas.

3. The research has analysed the prediction of user behaviour based on CO₂ concentration with an extreme machine-learning (ELM) model with two different optimisations: a genetic algorithm (GA) and a simulated annealing (SA) algorithm. It has been established that a reliable prediction of the model can be achieved with just four weeks' worth of monitoring data (measured at five-minute intervals), and a sensitivity analysis has revealed the prediction reliability of the model to be optimal and the prediction duration, the shortest when the count of neurons is 25 or higher, the size of the population is ≥ 20 , and the number of repetitions is ≥ 10 .
4. The energy savings in a ventilation system are grounded on predicting the workplace with the machine-learning model SA-ELM. The simulation results have shown that the user occupancy in building B is at least 0.033 person/m², accounting for 99% of the time covered by the research; hence, the level of reliability of prediction is low. It has also been found that the simulation results for Building A have a high degree of prediction reliability, with the RMSE totalling between 2.17 and 2.2 and the R^2 amounting to around 0.7. For building C, the level of reliability was lower compared to building A, with the RMSE standing between 0.57 and 0.61 and the R^2 measuring between 0.2 and 0.34.
5. The validation of the AI-VAV model as developed was followed by a simulation of five options, which showed that for the models to be trained properly, the required amount of data has to be at least 8,500 measuring points, which translates into four weeks. Out of the five AI-VAV models simulated, option five is the most appropriate, with the degree of energy economy between AI-VAV and VAV standing at 7.5% for building A and at 3.8% for building C when the level of indoor pollution is within 1,000 ppm throughout the period of simulation.

Jonas BIELSKUS

MAŠININIO MOKYMOSI MODELIO TAIKYMAS
PASTATO VĖDINIMO SISTEMOS VALDYMO
EFEKTYVUMUI DIDINTI

Daktaro disertacija

Technologijos mokslai,
Statybos inžinerija (T 002)

APPLICATION OF A MACHINE LEARNING MODEL
TO IMPROVE THE EFFICIENCY OF THE VENTILATION
CONTROL SYSTEM IN A BUILDING

Doctoral Dissertation

Technological Sciences,
Civil Engineering (T 002)

Lietuvių kalbos redaktorė Dalia Markevičiūtė
Anglų kalbos redaktorė Jūratė Griškėnaitė

2024 05 13. 10,5 sp. l. Tiražas 20 egz.
Leidinio el. versija <https://doi.org/10.20334/2024-033-M>
Vilniaus Gedimino technikos universitetas
Saulėtekio al. 11, 10223 Vilnius
Spausdino UAB „Ciklonas“,
Žirmūnų g. 68, 09124 Vilnius