

HIBRIDNA METODA ZA IZRADU TERMODINAMIČKOG MODELA ZGRADE TEMELJENA NA OTPORNIČKOKAPACITIVNOJ ANALOGIJI

Belić, Filip

Doctoral thesis / Disertacija

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:200:713332>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-04-24**

Repository / Repozitorij:

[Faculty of Electrical Engineering, Computer Science and Information Technology Osijek](#)



SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I
INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Filip Belić

**HIBRIDNA METODA ZA IZRADU TERMODINAMIČKOG
MODELA ZGRADE TEMELJENA NA OTPORNIČKO-
KAPACITIVNOJ ANALOGIJI**

Doktorska disertacija

Osijek, 2019.

Doktorska disertacija je izrađena na Zavodu za računalno inženjerstvo i automatiku
Fakulteta elektrotehnike, računarstva i informacijskih tehnologija Osijek,
Sveučilište Josipa Jurja Strossmayera u Osijeku

Mentor: dr. sc. Željko Hocenski

Doktorski rad ima 206 stranica.

Broj doktorske disertacije: 68

Povjerenstvo za ocjenu doktorske disertacije:

1. Dr.sc. *Dražen Slišković*, redoviti profesor, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, predsjednik
2. Dr.sc. *Željko Hocenski*, redoviti profesor u trajnom zvanju, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, mentor
3. Dr.sc. *Mario Vašak*, redoviti profesor, Fakultet elektrotehnike i računarstva u Zagrebu, član

Povjerenstvo za obranu doktorske disertacije:

1. Dr.sc. *Dražen Slišković*, redoviti profesor, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, predsjednik
2. Dr.sc. *Željko Hocenski*, redoviti profesor u trajnom zvanju, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, mentor
3. Dr.sc. *Mario Vašak*, redoviti profesor, Fakultet elektrotehnike i računarstva u Zagrebu, član
4. Dr.sc. *Goran Martinović*, redoviti profesor u trajnom zvanju, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, član
5. Dr.sc. *Tomislav Keser*, docent, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, član

Datum obrane doktorske disertacije: 1. veljače 2019.

SADRŽAJ

POPIS KRATICA	I
POPIS OZNAKA.....	III
POPIS SLIKA.....	IV
POPIS TABLICA.....	VII
POPIS ALGORITAMA.....	VIII
1. UVOD.....	1
1.1. Termodinamički model zgrade i HVAC sustava kao temelj energetske učinkovitog upravljanja.....	2
1.2. Polazišta i plan istraživanja.....	4
1.3. Struktura rada	5
2. MODELIRANJE I UPRAVLJANJE TOPLINSKIM PROCESIMA U ZGRADAMA	7
2.1. Toplina, zgrade i HVAC sustavi	7
2.1.1. Toplinska svojstva i procesi	8
2.1.2. Toplinski procesi i svojstva u zgradama.....	10
2.1.3. Elementi HVAC sustava.....	13
2.2. Toplinski modeli u zgradama i HVAC sustavima i pregled stanja u literaturi	16
2.2.1. Izrada toplinskih modela zgrada kroz teorijsku analizu	18
2.2.2. Pojednostavljenja toplinskog modela dobivenog fizikalnim pristupom.....	20
2.2.3. Podatkovni pristup izradi toplinskih modela zgrada	22
2.2.4. Umjetne neuronske mreže	24
2.2.5. Hibridni pristup izradi toplinskih modela zgrada	26
2.3. Upravljanje HVAC sustavima zgrada i pregled stanja u literaturi .	32
2.3.1. Klasično upravljanje	33
2.3.2. Napredne i inteligentne metode upravljanja	35
2.3.3. Prediktivno upravljanje i modelsko prediktivno upravljanje	39
2.3.4. Ostale varijante modelskog prediktivnog upravljanja	46
2.4. Sažetak pregleda i prijedlog unaprjeđenja postojećih metoda.....	49
3. IZRADA STRUKTURE TERMODINAMIČKOG MODELA ZGRADE	51
3.1. Otporničko-kapacitivna analogija za izradu toplinskog modela zgrade	52

3.1.1.	Osnovni elementi RC metode.....	53
3.1.2.	Izrada toplinskog modela.....	56
3.2.	Algoritam za strukturiranje termodinamičkog modela zgrade.....	65
3.2.1.	Matematička pozadina i algoritam	65
3.2.2.	Implementacija algoritma	70
3.3.	Primjena algoritma za strukturiranje modela stvarne zgrade	76
3.3.1.	Opis zgrade i HVAC sustava.....	76
3.3.2.	Određivanje strukture modela i početnih vrijednosti parametara.....	82
3.3.3.	Analiza dobivenog fizikalnog modela sa stajališta upravljivosti i osmotrivosti ..	85
3.3.4.	Opis mjerenja na zgradi korištenoj u istraživanju	86
3.3.5.	Simulacija korištenjem dobivenog fizikalnog modela i početnih parametara.....	89
4.	HIBRIDNA METODA ZA IZRADU TERMODINAMIČKOG MODELA ZGRADE.....	95
4.1.	Opis hibridne metode	96
4.2.	Kriteriji za prepodešavanje parametara modela	100
4.3.	Optimizacija parametara modela	101
4.3.1.	Koraci optimizacije.....	102
4.3.2.	Matematički problem.....	107
4.3.3.	Razlozi odabira funkcije, algoritma i parametara optimizacije.....	110
5.	VERIFIKACIJA HIBRIDNE METODE.....	116
5.1.	Kriteriji ocjene modela	116
5.1.1.	Kriterij složenosti	116
5.1.2.	Kriterij točnosti.....	116
5.2.	Analiza rezultata fizikalnog modela	117
5.3.	Analiza rezultata prilagođenih modela	120
5.4.	Kvaliteta predviđanja prilagođenog modela	131
5.5.	Usporedba s rezultatima dobivenim umjetnim neuronskim mrežama.....	137
5.6.	Kvaliteta predviđanja s umjetnim neuronskim mrežama i usporedba s prilagođenim modelom.....	144
6.	ZAKLJUČAK	148
	LITERATURA	152
	SAŽETAK.....	160
	ABSTRACT	161
	ŽIVOTOPIS.....	162

PRILOZI	163
Prilog P.1. Izvadak iz Glavnog arhitektonskog projekta	163
Prilog P.2. Izvadak iz Izvedbenog projekta strojarskih instalacija	170
Prilog P.3. Izvadak iz Izvedbenog elektrotehničkog projekta	175
Prilog P.4. Detaljan prikaz realnog modela zgrade s početnim parametrima (4R3C varijanta).....	176
Prilog P.5. Prikaz rezultata optimizacija s fokusom na metode optimizacije	186
Prilog P.6. Prikaz rezultata optimizacija s fokusom na odabir vremena uzorkovanja i razdiobu energije.....	187
Prilog P.7. Prikaz rezultata optimizacija s fokusom na metodu greške .	191
Prilog P.8. Prikaz rezultata optimizacija s fokusom na broj ponavljanja optimizacije	194
Prilog P.9. Prikaz rezultata optimizacija s fokusom na složenost modela	198
Prilog P.10. Prikaz rezultata predviđanja korištenjem prilagođenog modela	200
Prilog P.11. Prikaz rezultata simulacije pomoću umjetnih neuronskih mreža	205
Prilog P.12. Prikaz rezultata predviđanja korištenjem ANN metode	206

POPIS KRATICA

2R1C – Reprezentacija zida s dva otpornika i jednim kapacitetom

3R2C – Reprezentacija zida s tri otpornika i dva kapaciteta

4R3C – Reprezentacija zida s četiri otpornika i tri kapaciteta

AB – Armirano-betonski

AC (engl. *Air Conditioning*) – Klimatizacija zraka

AHU (engl. *Air Handling Unit*) – Jedinica za tretiranje zraka

ANN (engl. *Artificial Neural Networks*) – Umjetne neuronske mreže

ASHRAE (engl. *American Society of Heating, Refrigerating and Air Conditioning Engineers*) – Američko udruženje inženjera za grijanje, hlađenje i klimatizaciju

BMS (engl. *Building Management System*) – Sustav upravljanja zgradom (često se odnosi na sustav gospodarenja energijom u zgradi)

EKF (engl. *Extended Kalman Filter*) – Prošireni Kalmanov filter

FLC (engl. *Fuzzy Logic Controller*) – Neizraziti regulator

GA (engl. *Genetic Algorithm*) – Genetski algoritam

GPC (engl. *Generalized Prediction Control*) – Opće prediktivno upravljanje

HVAC (engl. *Heating, Ventilation, Air Conditioning*) – (Sustavi za) grijanje, ventilaciju i hlađenje

LS (engl. *Least Squares*) – (Problem, Metoda) najmanjih kvadrata

MIMO (engl. *Multiple-Input-Multiple-Output*) – Više ulaza, više izlaza

MISO (engl. *Multiple-Input-Single-Output*) – Više ulaza, jedan izlaz

ML (engl. *Maximum Likelihood*) – (Metoda) maksimalne vjerojatnosti

MPC (engl. *Model Predictive Control*) – Modelsko prediktivno upravljanje

NRMSE (engl. *Normalized Root Mean Square Error*) – Normalizirani korijen srednje kvadratne greške

PID (engl. *Proportional-Integral-Derivative*) – Proporcionalno–Integracijsko–Derivacijski (regulator)

RC (engl. *Resistive-Capacitive*) – Otporničko-kapacitivna (metoda)

RMS (engl. *Root-Mean-Square*) – Korijen srednje kvadratne (greške, vrijednosti)

RMSE (engl. *Root Mean Square Error*) – Korijen srednje kvadratne greške

SISO (engl. *Single-Input-Single-Output*) – Jedan ulaz, jedan izlaz

SQP (engl. *Sequential Linear Programming*) – Sekvencijalno linearno programiranje

UKF (engl. *Unscented Kalman Filter*) – Nezačinjeni Kalmanov filter

VAV (engl. *Variable Air Volume*) – (Jedinica s) promjenjivim protokom zraka

POPIS OZNAKA

J	težinska funkcija
N	duljina prediktivnog obzora
w_Y	težinski koeficijenti za izlaze
$y_i(k)$	vrijednost i-tog izlaza u k-tom koraku
$r_i(k)$	vrijednost i-te zadane vrijednosti u k-tom koraku
Y	broj izlaza
w_U	težinski koeficijenti za ulaze
$u_j(k)$	vrijednost j-tog ulaza u k-tom koraku
U	broj ulaza
y_{MIN} i y_{MAX}	ograničenja unutar kojih se razlika vrijednosti izlaza i zadane vrijednosti mora nalaziti
u_{MIN} i u_{MAX}	ograničenja unutar kojih se vrijednosti ulaza mora nalaziti
$\mathbf{x}$	vektor stanja
$\mathbf{y}$	vektor izlaza
$\mathbf{u}$	vektor ulaza (svih ili upravljačkih)
$\mathbf{v}$	vektor neupravljivih ulaza
$\mathbf{A}$	matrica stanja
$\mathbf{B}$	ulazna matrica
$\mathbf{B}_u$	ulazna matrica upravljačkih ulaza
$\mathbf{B}_v$	ulazna matrica neupravljivih ulaza
$\mathbf{C}$	izlazna matrica
$\mathbf{D}$	prolazna matrica
$\mathbf{D}_u$	prolazna matrica upravljačkih ulaza
$\mathbf{D}_v$	prolazna matrica neupravljivih ulaza
$f_R(\mathbf{A}_R, \mathbf{B}_R)$	referentni model
$f_T(\mathbf{A}_T, \mathbf{B}_T)$	testni model
$\mathbf{y}_R$	vrijednosti izlaznih veličina (mjerenja ili referentnog modela)
$\mathbf{y}_T$	vrijednosti izlaza testnog modela
e_{TOTAL}	ukupna greška
e_{RMSE}	korijen srednje kvadratne greške
e_{NRMSE}	normalizirani korijen srednje kvadratne greške
e_{MAX}	maksimalna greška
e_{TOTAL_AVRG}	prosječna ukupna greška

POPIS SLIKA

Slika 2.1. Tipični toplinski procesi u zgradi (V – vođenje, P – prijelaz, Z – zračenje, M – tok mase, I – infiltracija)	11
Slika 2.2. Toplinski procesi na vanjski zid (vođenje, prijelaz i zračenje).....	12
Slika 2.3. Centralni dio zračnog HVAC sustava, njegovi dijelovi i tok zraka.....	14
Slika 2.4. Jedan od prikaza sustava (u – upravljački ulazi; v – neupravljivi ulazi; x – unutarnja stanja sustava; w – nesigurnosti senzora; y – izlazi senzora, odnosno sustava) iz literature [14]	16
Slika 2.5. Zgrada i HVAC sustav prikazani kao model s regulatorom	17
Slika 2.6. Opći prikaz umjetne neuronske mreže s tri sloja i detalj jednog neurona (ulazi, težine, prijenosna i aktivacijska težina)	25
Slika 2.7. Prikaz rada (statička karakteristika) termostata s histerezom – uključivanje i isključivanje bojlera kada temperatura padne ispod, odnosno prijeđe iznad zadane temperature	34
Slika 2.8. Prikaz rada modelskog prediktivnog upravljanja iz perspektive trenutnog koraka.	41
Slika 3.1. Nadomjesni model zida u 3R2C varijanti (s tri otpora i dva kapaciteta).....	53
Slika 3.2. Nadomjesni model prozora u 3R varijanti (s tri otpora).....	55
Slika 3.3. Nadomjesni model zone.....	55
Slika 3.4. Zgrada (plavo su zidovi, zeleno vrata i prozori)	56
Slika 3.5. Određivanje stanja (crveno su temperature zona, a sivo okoliša).....	57
Slika 3.6. Dodavanje 3R2C nadomjesnih elemenata za zidove (plavo)	57
Slika 3.7. Dodavanje 3R nadomjesnih elemenata za prozore i vrata (zeleno).....	58
Slika 3.8. Dodavanje utjecaja Sunčevog zračenja (ljubičasto) i HVAC sustava (narančasto)	58
Slika 3.9. Osnovno sučelje ModelBuilder aplikacije i osnovni elementi (zid, otvor, prostor i izvor)	71
Slika 3.10. Prozori za uređivanje postavki zida (pomoćna i fizikalna svojstva te odnosi prema drugim osnovnim elementima).....	72
Slika 3.11. Jednostavna zgrada s dvije sobe, prikaz u ModelBuilder aplikaciji	73
Slika 3.12. Zgrada koja je korištena u istraživanju	77
Slika 3.13. Tlocrt zgrade koja je korištena u istraživanju	77
Slika 3.14. Prikaz HVAC sustava u zgradi	80
Slika 3.15. Glavni ekran aplikacije za nadzor grijanja s prikazom HVAC sustava i prostora.	81
Slika 3.16. Ekran zadavanja željenih temperatura (dnevno/noćno/ručno zadavanje).....	81
Slika 3.17. Maksimalni termodinamički model zgrade razvijen u ModelBuilder aplikaciji ...	83

Slika 3.18. Realni termodinamički model zgrade razvijen u ModelBuilder aplikaciji (objedinjeni izvori topline u prostorima)	84
Slika 3.19. Mogućnost "Fill parameters..." aplikacije ModelBuilder za podešavanje parametara	90
Slika 3.20. Pomoćna MATLAB aplikacija za simulaciju i optimizaciju.....	91
Slika 3.21. Ulazni podaci od 21.2.2018 do 26.2.2018.	93
Slika 3.22. Izlazni podaci: mjerenja i simulacija fizikalnog modela od 21.2.2018 do 26.2.2018.	93
Slika 4.1. Osnovni dijagram toka MATLAB pomoćne aplikacije za simuliranje i optimizaciju	103
Slika 4.2. Sučelje MATLAB pomoćne aplikacije.....	104
Slika 4.3. Rezultati simulacije fizikalnog i prilagođenog 4R3C modela	104
Slika 4.4. Usporedba izlaznih podataka: mjerenja (puna crta), fizikalni model (crtkano) i prilagođeni model (točkano)	105
Slika 5.1. Usporedba rezultata mjerenja i rezultata simulacije fizikalnog modela složenosti 4R3C.....	118
Slika 5.2. Usporedba rezultata mjerenja i rezultata simulacije fizikalnog modela složenosti 3R2C.....	119
Slika 5.3. Usporedba rezultata mjerenja i rezultata simulacije fizikalnog modela složenosti 2R1C.....	119
Slika 5.4. Rezultati fizikalnog modela 4R3C u zimskom skupu Referentni podaci.....	122
Slika 5.5. Rezultati prilagođenog modela 4R3C u zimskom skupu Referentni podaci.....	123
Slika 5.6. Detalj simulacije prilagođenog modela 4R3C u zimskom skupu Referentni podaci	123
Slika 5.7. Usporedba rezultata simulacije prema broju ponavljanja optimizacije	126
Slika 5.8. Usporedba trajanja optimizacije prema broju ponavljanja optimizacije.....	126
Slika 5.9. Usporedba rezultata simulacije prema složenosti modela	129
Slika 5.10. Usporedba trajanja optimizacije prema složenosti modela.....	129
Slika 5.11. Rezultati simulacije 4R3C modela u testnom skupu Zimski skup 1	130
Slika 5.12. Rezultati simulacije 2R1C modela u testnom skupu Zimski skup 1	130
Slika 5.13. Pomoćna MATLAB aplikacija za predviđanje pomoću prilagođenog modela... ..	132
Slika 5.14. Usporedba prosječne ukupne greške za scenarije trajanja 6 dana	135
Slika 5.15. Usporedba prosječne ukupne greške za scenarije trajanja 2 dana	135

Slika 5.16. Usporedba maksimalne greške za scenarije trajanja 6 dana	136
Slika 5.17. Usporedba maksimalne greške za scenarije trajanja 2 dana	136
Slika 5.18. Pomoćna MATLAB aplikacija za simulaciju i optimizaciju pomoću umjetnih neuronskih mreža	138
Slika 5.19. Usporedba rezultata simulacije prilagođenog modela i umjetnih neuronskih mreža, ukupna greška.....	140
Slika 5.20. Usporedba rezultata simulacije prilagođenog i umjetnih neuronskih mreža, korijen srednje kvadratne greške	140
Slika 5.21. Usporedba rezultata simulacije prilagođenog modela i umjetnih neuronskih mreža, normalizirani korijen srednje kvadratne greške	141
Slika 5.22. Detalj rezultata simulacije pomoću umjetnih neuronskih mreža, Zimski skup 1	141
Slika 5.23. Detalj simulacije pomoću umjetnih neuronskih mreža (noćni režim).....	143
Slika 5.24. Pomoćna MATLAB aplikacija za predviđanje pomoću umjetnih neuronskih mreža	144
Slika 5.25. Usporedba prosječne ukupne greške za scenarije trajanja 6 dana, ANN metoda	145
Slika 5.26. Usporedba prosječne ukupne greške za scenarije trajanja 2 dana, ANN metoda	146
Slika 5.27. Usporedba maksimalne greške za scenarije trajanja 6 dana, ANN metoda.....	146
Slika 5.28. Usporedba maksimalne greške za scenarije trajanja 2 dana, ANN metoda.....	147

POPIS TABLICA

Tablica 1.1. Potrošnja električne energije po sektorima i godinama (podaci za SAD) [1]–[3].	1
Tablica 3.1. Početne vrijednosti toplinskih parametara za materijale	90
Tablica 4.1. Usporedba mjerenja sa simulacijom fizikalnog i prilagođenog modela.....	106
Tablica 4.2. Algoritmi za optimizaciju u MATLAB okruženju	110
Tablica 4.3. Sažetak priloga P.5. Prikaz rezultata optimizacije s fokusom na metode optimizacije	112
Tablica 4.4. Sažetak priloga P.6. Prikaz rezultata optimizacije s fokusom na odabir vremena uzorkovanja i razdiobu energije	113
Tablica 5.1. Usporedba rezultata mjerenja i rezultata simulacije fizikalnog modela različite složenosti.....	118
Tablica 5.2. Sažetak priloga P.7. Prikaz rezultata optimizacija s fokusom na metodu greške	122
Tablica 5.3. Sažetak priloga P.8. Prikaz rezultata optimizacija s fokusom na broj ponavljanja optimizacije	124
Tablica 5.4. Sažetak priloga P.9. Prikaz rezultata optimizacija s fokusom na složenost modela	128
Tablica 5.5. Rezultati predviđanja pomoću hibridne metode	133
Tablica 5.6. Rezultati simulacije pomoću umjetnih neuronskih mreža.....	139
Tablica 5.7. Rezultati predviđanja pomoću umjetnih neuronskih mreža	145

POPIS ALGORITAMA

Algoritam 3.1. Određivanje broja stanja, ulaza i izlaza	67
Algoritam 3.2. Određivanje strukture matrice sustava A – zidovi i prostori	68
Algoritam 3.3. Određivanje strukture matrice sustava A – otvori i prostori.....	68
Algoritam 3.4. Određivanje strukture matrice ulaza B – zidovi, prostori i izvori.....	69
Algoritam 3.5. Određivanje strukture matrice ulaza B – otvori i prostori	69
Algoritam 3.6. Određivanje strukture matrice ulaza B – prostori i izvori.....	70
Algoritam 3.7. Određivanje strukture matrice izlaza C	70
Algoritam 4.1. Implementacija optimizacije korištenjem fminunc funkcije.....	108

1. UVOD

Prema dostupnim podacima o potrošnji energije [1]–[3], stambene i komercijalne građevine su veliki potrošači energije. U razvijenim zemljama, između 20% i 40% ukupne energije troši se u zgradama. Najveći dio te energije troši se upravo na grijanje, ventilaciju i hlađenje, tzv. HVAC sustave (engl. *Heating, Ventilation, Air Conditioning*). Kao što se može vidjeti u tablici 1.1., HVAC sustavi troše oko petine ukupne energije u svijetu, s trendom porasta. Ako se uzme u obzir da je ukupna potrošnja energije u svijetu za 2015. godinu procijenjena na $1,08 \cdot 10^{17}$ Wh, jasno je da čak i mala poboljšanja mogu donijeti velike uštede.

Tablica 1.1. *Potrošnja električne energije po sektorima i godinama (podaci za SAD) [1]–[3]*

Potrošač / Godina	Utrošena energija		
	2006	2008	2011
Zgrade (% od ukupno)	39%	40%	41%
Stambene (% od zgrada)	54%	54%	54%
Komercijalne (% od zgrada)	46%	46%	46%
Grijanje prostora (% od zgrada)	20%	22%	37%
Rasvjeta (% od zgrada)	18%	16%	9%
Hlađenje prostora (% od zgrada)	13%	14%	10%
Grijanje sanitarne vode (% od zgrada)	10%	10%	12%
Ostalo (% od zgrada)	39%	38%	32%
HVAC sustavi (% od zgrada)	33%	36%	47%
HVAC sustavi (% od ukupno)	13%	14%	19%

Postoji nekoliko načina ili strategija pomoću kojih se može doći do smanjenja potrošnje energije, odnosno do veće energetske učinkovitosti u zgradama:

- korištenje suvremenih metoda projektiranja zgrada i uzimanje u obzir energetske učinkovitosti već kod projektiranja (tzv. nisko-energetske i pasivne kuće)
- korištenje kvalitetnijih materijala (npr. deblja ili kvalitetnija izolacija ovojnice zgrade, kvalitetniji prozori i vrata i sl.) i uređaja (npr. učinkovitiji motori/pumpe, kućanski uređaji višeg energetskog razreda i sl.) kod izgradnje i opremanja zgrada
- korištenje energetski učinkovitijih HVAC sustava i njihovo pravilno dimenzioniranje (npr. grijanje i hlađenje temeljeno na geotermalnim izvorima i sl.)
- zamjena postojećih materijala i uređaja s energetski učinkovitijima (tzv. energetska obnova, zelena gradnja i sl.)

- promjena navika i edukacija stanara odnosno korisnika prostora da vode računa o energetskej učinkovitosti (npr. otvaranje/zatvaranja vrata i prozora, isključivanje uređaja kada se ne koriste, prikladna odjeća)
- nadzor i održavanje zgrade i njenih sustava potpomognuti korištenjem estimacijskih i dijagnostičkih alata (npr. sustav upravljanja zgradom)
- korištenje naprednih metoda upravljanja HVAC sustavima i ostalim sustavima u zgradama (npr. modelsko prediktivno upravljanje).

Osim zadnje tri, na postojećim zgradama je ove metode često nemoguće, nepraktično ili skupo primijeniti, osobito kod većih komercijalnih zgrada. Pokazalo se da postavljanje dodatne izolacije može donijeti velike uštede i često je zahvat koji se primjenjuje na postojećim zgradama, što se može primijetiti kroz činjenicu da mnoge države subvencioniraju zamjenu ili unaprjeđenje fasada na zgradama i obiteljskim kućama (osobito na onima niskog energetskog razreda). Promjena navika stanara je metoda koju je u životu jako teško aplicirati, najviše zbog ljudske psihologije. Prelazak na napredne metode upravljanja HVAC sustavima može se pokazati kao jeftini i učinkoviti put do veće energetske učinkovitosti u zgradama.

1.1. Termodinamički model zgrade i HVAC sustava kao temelj energetski učinkovitog upravljanja

Učinkovito upravljanje koje štedi energiju, a istovremeno održava prostor unutar zadanih granica ugođe cilj je kojem teži svaka suvremena primjena upravljanja HVAC sustavom. Metode koje koriste predviđanje (engl. *Prediction*), kao što je na primjer modelsko prediktivno upravljanje (MPC, engl. *Model Predictive Control*) predstavljaju jedno od praktičnih i popularnih rješenja. Koristeći termodinamički model zgrade i HVAC sustava, povijesne podatke o prošlim ponašanjima sustava i prognozu vremenskih uvjeta, moguće je predvidjeti ponašanje sustava u narednom vremenskom razdoblju. Navedenim metodama moguće je optimizirati (minimalizirati) potrošnju energije po različitim kriterijima, bilo kao najmanji utrošak energije, izbjegavanje vršnih opterećenja, stabilan rad sustava, ukupan iznos računa za energije, itd.

Da bi se ponašanje sustava moglo što bolje predvidjeti, potrebno je imati što bolji model sustava, odnosno što točniji toplinski model zgrade. Pri tome treba naglasiti da se ovdje radi o termodinamičkom modelu, a ne o statičkom toplinskom modelu zgrade. Fizikalni postupak izrade toplinskog modela temelji se na korištenju fizikalnih načela, odnosno teorijske analize. U praksi, to znači rješavanje velikog sustava koji se sastoji od brojnih algebarskih i diferencijalnih jednadžbi koje predstavljaju toplinske procese u građevini: vođenje (kondukcija) i prijelaz (konvekcija)

topline kroz elemente zgrade (vanjski zidovi, krov, podovi i stropovi, unutarnji zidovi); tok Sunčevog zračenja (radijacija) i vođenje kroz staklene površine; uskladištenje topline u pojedinim elementima zgrade; ulazak (infiltracija) vanjskog zraka i zraka iz povezanih prostorija; rasipanje (disipacija) topline iz rasvjete, opreme, ljudi i drugih objekata koji se nalaze unutar prostorija; grijanje, hlađenje, vlaženje i sušenje kao rezultat rada HVAC sustava. Iako ovakav način izrade toplinskog modela daje rezultate najbliže stvarnosti, a i rješiv je uz pomoć računala, koristi se samo na ograničenim primjerima. Kod većih zgrada, s velikim brojem zona, etaža i složenim geometrijskim rješenjima, postaje jako teško uopće postaviti ispravan matematički model, a još teže rješavati ga u stvarnom vremenu. Ovakav tip modela naziva se modelom bijele kutije (engl. *White Box*) jer su svi odnosi unutar modela poznati i definirani fizikalnim zakonitostima.

Na drugom kraju spektra metoda za izradu toplinskog modela zgrade nalazi se podatkovni pristup ili eksperimentalna analiza, koji se temelji na korištenju mjernih podataka. Primjer takvog pristupa su razne metode s umjetnim neuronskim mrežama (ANN, engl. *Artificial Neural Networks*). Rezultat ANN-a je model koji dobro prezentira informacije o sustavu prisutne u podacima: za dane ulazne veličine, ANN daje izlaze koji odgovaraju izlazima stvarnog sustava u snimljenom režimu rada. Nedostatak ovakvog pristupa je što model najčešće nema fizikalno značenje. Drugo, kod velikih sustava opet brzo raste računalna snaga i količina podataka potrebna za podešavanje modela. Modeli ovog tipa pripadaju u modele crne kutije (engl. *Black Box*), jer se zna samo ulaz i izlaz sustava, a unutarnji rad modela (odnosno fizikalna povezanost između ulaznih i izlaznih veličina sustava) nije poznat.

Srednji pristup problematici izrade toplinskog modela predstavljaju razni hibridni modeli (nazivaju se modeli sive kutije, engl. *Grey Box*), često reducirani, koji možda ne uzimaju u obzir sve procese i parametre sustava kao modeli dobiveni teorijskom analizom, niti daju odnos ulazno-izlaznih veličina kao modeli dobiveni eksperimentalnom analizom, ali su prikladni za brz izračun ponašanja sustava, rješiv u stvarnom vremenu i za veće sustave, a opet dovoljno točan za odgovarajuću primjenu (primjerice za različite metode upravljanja), a uvažavaju fizikalne zakonitosti sustava.

Jedna od metoda izrade modela je otporničko-kapacitivna analogija (RC metoda, engl. *Resistive-Capacitive* ili metoda koncentriranih parametara, engl. *Lumped Capacitances*). Ova metoda temelji se na zamjeni elemenata građevine analognim električkim elementima. Na primjer, zid se modelira pomoću tri otpora i dva kapaciteta (kod modela drugog reda; 3R2C) kojima se predstavlja procese vođenja, prijelaza i zračenja topline kroz taj zid te skladištenje (ili

akumulaciju) toplinske energije u zidu. Dio toplinskih procesa i svojstava zida se zanemaruje, iako se kod detaljnijih modela ovog tipa može uzeti u obzir. Stakleni prozor aproksimira se samo otporom koji predstavlja zračenje i vođenje topline, i slično. Elementi modela se spajaju tako da odgovaraju stvarnom rasporedu u građevini, a rezultat je električka mreža – velika kod većih zgrada, ali potpuno rješiva u stvarnom vremenu. Parametri ovog modela mogu se odrediti prema nazivnim i tabličnim vrijednostima svojstava materijala i uređaja (tada se radi o klasičnoj teorijskoj analizi), no puno bolji rezultati se mogu postići ako se njihove nazivne vrijednosti prilagode korištenjem eksperimentalne analiza nad mjerenjima iz zgrade (tada se radi o hibridnom pristupu). Prednosti povezivanja otporničko-kapacitivne analogije i određivanja parametara modela na temelju mjerenja u hibridni model su jednostavnost određivanja strukture modela, očuvanje fizikalnog značenja modela i relativno mala računalna zahtjevnost pri određivanju vrijednosti parametara modela.

1.2. Polazišta i plan istraživanja

Ovo istraživanje bavi se izradom termodinamičkog modela zgrada i HVAC sustava, s namjenom da se dobiveni model koristi u upravljanju HVAC sustavom (osobito u modelskom prediktivnom upravljanju), a sve s ciljem poboljšavanja energetske učinkovitosti u upravljanju HVAC sustavima u stambenim i komercijalnim zgradama.

Pri rješavanju ovoga problema dan je pregled literature i istražene su sljedeće teme:

- izrada termodinamičkog modela zgrade i njegovo korištenje u upravljanju sa svrhom poboljšanja energetske učinkovitosti HVAC sustava
- pregled postojećih metoda za izradu toplinskih modela zgrada i HVAC sustava i njihovo upravljanje, s fokusom na modelsko prediktivno upravljanje
- poboljšanje postojećih metoda i izrada hibridne metode za izradu toplinskog modela zgrade koja kombinira teorijsku analizu za izradu strukture modela i eksperimentalnu analizu za određivanje parametara modela te njena verifikacija.

Osnovna hipoteza ovoga istraživanja je razvoj hibridne metode za izradu toplinskog modela zgrade koja kombinira teorijski i eksperimentalni pristup modeliranju i koja može pomoći povećanju energetske učinkovitosti kroz korištenje modelskog prediktivnog upravljanja, ali i u drugim metodama upravljanja. Osnovne pretpostavke od kojih se polazi u istraživanju su sljedeće:

- moguće je stvoriti algoritam koji djelomično automatizira izradu strukture toplinskog modela zgrade temeljenog na otporničko-kapacitivnoj analogiji i tako je olakšava i ubrzava
- parametre takvog modela moguće je odrediti na temelju mjerenja sa zgrade i HVAC sustava, čime se postižu bolji rezultati nego korištenjem nazivnih vrijednosti svojstava materijala i uređaja
- takva metoda daje bolje rezultate nego druge dostupne metode.

Najbitnije znanstvene metode koje su korištene u ovom radu (ali ne i jedine) su sljedeće:

- indukcija (postizanje općeg zaključka iz pojedinih primjera)
- apstrakcija i konkretizacija (stvaranje nekog apstraktnog modela iz nekoliko konkretnih primjera te kreiranje konkretnog primjera iz tog apstraktnog modela)
- statistička metoda (statistička analiza podataka iz više reprezentativnih uzoraka)
- teorija sustava (gledanje cjeline kao sustava te njeno modeliranje kao kombinacije podsustava)
- eksperimentalna metoda (provedeni eksperimenti), metoda promatranja (promatranje rada sustava) i metoda mjerenja (mjerenje podataka na zgradi)
- modeliranje (stvaranje matematičkog modela).

1.3. Struktura rada

U ovom istraživanju istražuje se izrada toplinskog modela zgrade (i HVAC sustava kao njenog dijela) korištenjem otporničko-kapacitivne analogije za određivanje strukture modela, kod koje se početni parametri modela određuju iz nazivnih vrijednosti svojstava materijala i opreme (tablice i specifikacije proizvođača i slično). U sljedećem koraku se podaci dobiveni mjerenjima na zgradi (temperature, energije, protoci i sl.) analiziraju i koriste za prilagodbu (prepodešavanje) početnih parametara modela numeričkim metodama (multivarijabilna optimizacija). Dobiveni hibridni model treba imati veću točnost od početnog, a bez potrebe za velikim računalnim resursima za određivanje optimalnih vrijednosti parametara prema zadanom kriteriju optimalnosti.

U drugom poglavlju daje se kratak uvod u općenito područje modeliranja toplinskih procesa u zgradama. S obzirom da je ovo vrlo široko i složeno područje, koje obuhvaća razne aspekte (od fizike samih toplinskih procesa do inženjerskih problema građevine, upravljanja i mjerenja), opisani su samo osnovni pojmovi koji su potrebni za razumijevanje istraživanja predstavljenog u ovom radu. U drugom dijelu poglavlja daje se pregled najvažnijih i nedavnih istraživanja iz ovog

područja, podijeljeno na radove koji se bave toplinskim modelima u zgradama i HVAC sustavima (proces) i radove koje se bave upravljanjima HVAC sustavima u zgradama (upravljanje).

Treće poglavlje opisuje metodologiju izrade strukture termodinamičkih modela zgrada kroz korištenje otporničko-kapacitivne analogije, a koja se temelji na zamjeni elemenata zgrade s nadomjesnim električkim elementima. Glavni dio poglavlja opisuje algoritam kojim se može automatski izraditi strukturu toplinskog modela iz dostupne arhitekture (građevinskog nacrt) zgrade. Ovime nestaje potreba za ručnom izradom strukture modela kroz teorijsku analizu, a smanjuje se i mogućnost greške kod većih zgrada, odnosno složenih modela. Početne vrijednosti parametara modela određuju se iz nazivnih vrijednosti svojstava opreme i materijala. Opisana je zgrada i HVAC sustav koji se koriste u istraživanju te je prikazana implementacija algoritma za automatsku izradu strukture modela na opisanoj zgradi.

Četvrto poglavlje opisuje hibridnu metodu koja povezuje otporničko-kapacitivnu analogiju za izradu strukture modela s podatkovnim pristupom, odnosno s korištenjem metoda za prepodešavanje parametara modela, čime se dobiva hibridni prilagođeni model (model sive kutije). Početni parametri modela dobiveni teorijskom analizom se prepodešavaju na temelju mjernih podataka i zadane kriterijske funkcije. Detaljno se opisuju koraci optimizacije, matematički problem i algoritmi koji se koriste za optimizaciju, s razlozima njihova odabira.

U petom poglavlju radi se verifikacija hibridne metode na način da se rezultati simulacije prilagođenog modela iz četvrtog poglavlja (modela s prepodešenim parametrima) usporede s rezultatima simulacije fizikalnog modela iz trećeg poglavlja (modela s početnim parametrima) i mjerenjima sa zgrade. Daju se kvantitativni kriteriji za ocjenu složenosti i kvalitete modela. Osim rezultata simulacije modela korištenjem mjerenja sa zgrade, radi se i analiza kvalitete predviđanja modela, koje je vrlo bitno za korištenje u upravljanju (a osobito u modelskom prediktivnom upravljanju). Ovi rezultati se uspoređuju s rezultatima dobivenim fizikalnim modelom te s umjetnim neuronskim mrežama.

2. MODELIRANJE I UPRAVLJANJE TOPLINSKIM PROCESIMA U ZGRADAMA

U ovom poglavlju daje se podloga za naredne cjeline koje se bave toplinskim modelima i upravljanjem HVAC sustavima u zgradama. Iako su zgrade i HVAC sustavi povezani i isprepleteni pojmovi s puno više značenja nego je to promatrano u ovom radu, ovdje se promatraju odvojeno.

2.1. Toplina, zgrade i HVAC sustavi

Zgrada je građevinska struktura u kojoj borave ljudi (stanari) i za koju su od interesa unutarnji klimatski uvjeti: temperatura zraka, relativna vlažnost, koncentracija CO₂, brzina kretanja zraka, svježina zraka i sl. Zgrada se smatra pasivnim sustavom na koji djeluju vanjski faktori: prvenstveno vremenske pojave (Sunčevo zračenje, vjetar, vanjska temperatura, vlaga, itd.) i HVAC sustav. HVAC sustav, koji se promatra odvojeno od zgrade, je aktivni sustav koji djeluje na klimatske uvjete u zgradi i za to troši energiju (električnu energiju, plin, biomasu, itd.).

Zgrade se sastoje od vanjske ovojnice (engl. *Envelope*), čemu pripadaju vanjski zidovi, stropovi i podovi, krov, vanjski prozori i vrata, te od unutarnjih pregrada (zidova, vrata, prozora i sl.). Predmeti u zgradama, kao što je namještaj i uređaji, također utječu na uvjete u zgradi. Pretpostavlja se da je svaka prostorija zatvoreni prostor, no moguće je povremeno otvaranje vrata i prozora (izmjena zraka). Osim prostorije kao osnovne jedinice za koju se može promatrati unutarnje klimatske uvjete, kod većih zgrada (razne komercijalne zgrade) moguće je i promatrati skup više prostorija koje imaju neke zajedničke osobine – bilo fizička blizina i povezanost, slični parametri ili zajednički HVAC podsustav (isti izvršni elementi). Često se u radovima i istraživanjima koje se bave ovom tematikom, kao osnovna jedinica koja se promatra u zgradi koristi se pojam zona (engl. *Zone*), što se može odnositi ili na jednu prostoriju ili na više povezanih prostorija.

Što se tiče HVAC sustava, ime dolazi od engleskih riječi za grijanje (engl. *Heating*), prozračivanje ili ventilaciju (engl. *Ventilation*) i klimatizaciju zraka (engl. *Air Conditioning*), a vezano je za sve podsustave i elemente koji se tiču ovih aktivnosti. Primarni cilj HVAC sustava je održavanje unutarnjih klimatski uvjeta u zgradama uz minimalni utrošak energije, gdje drugi faktor sve više dolazi do izražaja.

Puno više detalja o zgradama i HVAC sustavima može se naći u knjizi [4] autora Underwood i Yik, gdje se daje vrlo iscrpan opis modeliranja toplinskih procesa u zgradama. Objašnjeni su procesi vođenja, prijelaza i zračenja topline te ostalih procesa na svim bitnim elementima zgrade. Prvo se bave ovojnicom zgrade, koja uključuje zidove, prozore, stropove i sl. Opisane su sve

relevantne metode za modeliranje: metode prijelazne funkcije, frekvencijska analiza, metode koncentriranih parametara (engl. *Lumped Methods*). itd. Zatim se bave pojedinačnim elementima HVAC sustava: ventili, ventilatori, pumpe, prigušnice i sl. Detaljno se opisuje modeliranje sustava u mirnom stanju te modeliranje upravljačkog sustava.

2.1.1. Toplinska svojstva i procesi

Detaljan opis svih toplinskih svojstava i procesa u zgradama izlazi iz okvira ovoga rada i bliži je području strojarstva, tako da su ovdje oni samo ukratko definirani i opisani, koliko je to potrebno za razumijevanje sljedećih poglavlja. Za detaljniji pregled topline i njenog prijenosa može se pogledati knjige [5] ili [6] u kojima su obrađene teme poput vođenja topline u jednoj ili više dimenzija, prijelaz topline u fluidima strujanjem, prirodni prijelaz topline, zračenje između ploha, kondenzacija, toplinska svojstva materijala i sl.

Postoje tri glavna načina prijenosa topline (engl. *Heat Transfer*): vođenje ili kondukcija (engl. *Conduction*), prijelaz ili konvekcija (engl. *Convection*) i zračenje ili radijacija (engl. *Radiation*).

Vođenje topline je prijenos toplinske energije zbog razlike u temperaturi (temperaturnog gradijenta). Događa se unutar tijela te između tijela koja se dodiruju. Vođenje se događa dok god postoji razlika u temperaturi unutar tijela, a energija teče iz područja više temperature u područje niže temperature. Vođenje je opisano Fourierovim zakonom, danim u trodimenzionalnom diferencijalnom obliku, koji kaže da je tok energije $\vec{q}$ kroz materijal proporcionalan negativnom gradijentu temperature ∇T , pomnoženom sa koeficijentom toplinske vodljivosti materijala k [5]:

$$\vec{q} = -k \nabla T. \quad (2-1)$$

Za potrebe ovog istraživanja može se koristiti jednodimenzionalni integralni oblik zakona, koji kaže da je tok topline ΔQ u vremenu Δt proporcionalan negativnom omjeru razlike u temperaturi ΔT , a obrnuto proporcionalan toplinskom otporu R [5]:

$$\frac{\Delta Q}{\Delta t} = -\frac{\Delta T}{R}. \quad (2-2)$$

Ovdje je koeficijent toplinske vodljivosti materijala predstavljen toplinskim otporom R koji je proporcionalan duljini materijala x (debljini paralelnoj toplinskom toku), a obrnuto proporcionalan površini materijala A (okomitoj na toplinski tok) i koeficijentu toplinske vodljivosti materijala k [5]:

$$R = \frac{x}{A k}. \quad (2-3)$$

Prijelaz topline je prijenos topline strujanjem (kretanjem) čestica u fluidima, što se odnosi na prijenos topline s česticama u gibanju i čvrstog tijela, ali i s jednih čestica na druge u gibanju (miješanje toplog i hladnog zraka). Kao i kod vođenja, čestice teže izjednačavanju temperature (prirodno strujanje), osim ako postoji neki drugi prijenos topline u fluid (prisilno strujanje). Strujanje je također opisano Fourierovim zakonom (2-1), ali za ove potrebe je dovoljan i oblik koji se naziva Newtonov zakon hlađenja, koji kaže da je tok topline ΔQ proporcionalan koeficijentu konvektivnog prijenosa topline h (koji ovisi o tipu kretanja čestica), površini kroz koju se toplota prenosi A i razlici temperature $\Delta T(t)$ između fluida i drugog medija na koji toplota prijelazi [5]:

$$\frac{\Delta Q}{\Delta t} = h A \Delta T(t). \quad (2-4)$$

Zračenje topline odnosi se na prijenos topline između dvaju tijela elektromagnetskim zračenjem i postoji kod svakog tijela koje ima temperaturu višu od apsolutne nule (0 K). Prijenos energije zračenjem opisan je jednadžbom koja kaže da je tok energije ΔQ proporcionalan koeficijentu emisivnosti ϵ , Stefan-Boltzmannovoj konstanti σ , površini koja zrači A i temperaturi T [5]:

$$\frac{\Delta Q}{\Delta t} = \epsilon \sigma A T^4. \quad (2-5)$$

Kod zgrada, vrlo je bitno Sunčevo zračenje. Prosječna snaga upadnog zračenja Sunca u gornjim slojevima atmosfere dana je tzv. solarnom konstantom i iznosi $1,361 \text{ kW/m}^2$, no Sunčevo zračenje na površini Zemlje u praksi ovisi o mnogo parametara: lokalnim vremenskim prilikama, položaju tijela (npr. zida) u prostoru, materijalu (refleksija) i slično. No u prosjeku, Svjetska meteorološka organizacija definira izravno Sunčevo zračenje na Zemljinoj površini od minimalno 120 W/m^2 [7].

Osim toplinskog otpora, još jedno svojstvo je vrlo bitno kod zgrada: toplinski kapacitet. Njime se opisan proces uskladištenja (akumulacije) topline u svaki element zgrade. Toplinski kapacitet C je vrijednost koja govori kolika je potrebna toplotna energija Q da bi tijelo promijenilo temperaturu za iznos ΔT [5]:

$$C = \frac{Q}{\Delta T}. \quad (2-6)$$

U praksi se češće koristi specifični toplinski kapacitet c , koji ovisi o materijalu, odnosno o gustoći materijala ρ i volumenu V [5]:

$$c = \frac{C}{\rho V}. \quad (2-7)$$

Osim toplinskih procesa, važni su i maseni procesi (maseni protoci i uskladištenje), osobito tok mase zraka. Ovdje se može raditi o prirodnim procesima kao što je infiltracija (ulazak vanjskog zraka u prostoriju kroz otvoren prozor) i prisilnim procesima (ulazak obrađenog zraka iz HVAC sustava u prostoriju). Prijenos topline dotokom novog zraka ovisi o toku mase zraka $\Delta m / \Delta t$, specifičnom toplinskom kapacitetu c te razlici temperature dolaznog zraka i zraka na koji toplina prijelazi ΔT [6]:


$$\frac{\Delta Q}{\Delta t} = \frac{\Delta m}{\Delta t} c \Delta T. \quad (2-8)$$

Više detalja, uključujući i utjecaj vlage na prijenos topline, može se naći u navedenoj literaturi.

2.1.2. Toplinski procesi i svojstva u zgradama

Kada se radi o zgradama, prisutni su svi nabrojani procesi u prethodnom poglavlju, u nekoliko oblika. Neki od najvažnijih procesa su prikazani na slici 2.1.:


- vođenje topline kroz elemente ovojnice zgrade i unutarnjih pregrada (vanjski zidovi, pod, strop, unutarnji zidovi, prozori, vrata, itd.)
- Sunčevo zračenje na vanjske elemente zgrade (vanjske zidove, krov) i kroz prozore
- prijelaz topline i zračenje iz rasvjete i električnih uređaja
- prijelaz topline i zračenje iz HVAC sustava (grijaći i rashladni izvršni elementi)
- prijelaz topline i tok mase zraka uvjetovanog HVAC sustavom (zrakovodni sustav)
- infiltracija vanjskog zraka i iz susjednih prostorija.



Slika 2.1. Tipični toplinski procesi u zgradi (V – vođenje, P – prijelaz, Z – zračenje, M – tok mase, I – infiltracija)

Vrlo bitan element toplinskog sustava je vanjski zid. Toplinski procesi koji djeluju na vanjski zid prikazani su na slici 2.2.:

- izmjena topline između vanjskog okoliša (zraka) i zida prijelazom topline
- vođenje topline kroz zid
- izmjena topline između zida i unutarnjeg prostora (zraka) prijelazom topline
- Sunčevo zračenje na zid i refleksija tog zračenja u vanjski okoliš
- izmjena topline između zida i vanjskog okoliša zračenjem
- izmjena topline između zida i unutarnjeg prostora zračenjem
- skladištenje topline unutar materijala od kojih se zid sastoji.



Slika 2.2. *Toplinski procesi na vanjski zid (vođenje, prijelaz i zračenje)*

Najvažnija izmjena topline, kada se govori o vanjskom zidu, je ona između unutarnjeg i vanjskog okoliša (zraka). Na slici 2.2. prikazana je situacija kada je vanjska temperatura viša od unutarnje. Toplina vanjskog zraka se prvo prenosi prijelazom na vanjsku površinu zida. Ovaj prijenos ovisi o mnogo faktora: materijali od kojih se sastoji zid, tekstura površine, brzina vjetrova, itd. Zatim se toplina vođenjem prenosi na unutarnju površinu zida, gdje se ona opet prijelazom prenosi na unutrašnji zrak. Što se tiče Sunčevog zračenja, ono se djelomično apsorbira u zid, a djelomično reflektira u okoliš. Apsorbirana toplina se opet vođenjem prenosi na unutarnju plohu. Također postoji još i razmjena topline zračenjem s unutarnjim i vanjskim okolišem, gdje se dio topline apsorbira, a dio reflektira. Slična situacija je s unutarnjim zidovima, samo nema Sunčevog zračenja.

Za detaljniji prikaz toplinskih modela u zgradama, o pojedinim elementima zgrada, o materijalima koji se koriste i njihovim svojstvima, može se pogledati knjiga [8]. Također, rad [9] opisuje kako se eksperimentalno određuju vrijednosti toplinskog otpora jednog zida. Detaljno je

opisan model prijenosa topline kroz zid te potrebna oprema za mjerenja iz kojih je moguće odrediti parametre modela. Nova metoda se uspoređuje sa standardnom metodom opisanom u standardu ISO 9869.

2.1.3. Elementi HVAC sustava

Kao što je već spomenuto, HVAC sustavi obuhvaćaju sve elemente, procese i pristupe vezane za aktivnosti koje utječu na klimatske uvjete unutar zgrada (stambenih ili industrijskih).

Slično kao i kada se govori općenito o toplinskim procesima, samo područje HVAC sustava vezano je uz područje strojarstva i tako izlazi iz opsega ovoga rada. Puno više detalja o projektiranju i radu HVAC sustava može se naći u knjigama kao što su [10] ili [11]. Također, o HVAC sustavima i njihovim dijelovima gledano s aspekta upravljanja, više se može naći u knjizi [12].

U ovom poglavlju dijelovi HVAC sustava su obrađeni samo koliko je potrebno za razumijevanje dijelova koja slijede, sljedeći terminologiju i koncepte kako su navedeni u [11]. U ovoj knjizi HVAC sustav se gleda samo kao jedan dio većeg sustava koji se brine za ugodu stanara u kući i koji se naziva sustav klimatizacije zraka (engl. AC, *Air Conditioning*).


Procesi koje obavlja AC sustav su sljedeći:

- grijanje (engl. *Heating*) – dodavanje toplinske energije u zrak s ciljem održavanja temperature u zoni
- hlađenje (engl. *Cooling*) – oduzimanje toplinske energije iz zraka s ciljem održavanja temperature u zoni
- vlaženje (engl. *Humidifying*) – dodavanje vlage u zrak s ciljem održavanja vlažnosti zraka u zoni
- sušenje (engl. *Dehumidifying*) – oduzimanje vlage iz zraka s ciljem održavanja vlažnosti zraka u zoni
- čišćenje (engl. *Cleaning*) – oduzimanje čestica prašine i ostalih nečistoća iz zraka koji ulazi u zonu s ciljem održavanja kvalitete zraka
- ventilacija (engl. *Ventilating*) – dovodenje vanjskog svježeg zraka (bogatog kisikom) u zonu s ciljem održavanja kvalitete zraka (razina ugljičnog-dioksida)
- miješanje zraka (engl. *Air Movement*) – pomicanje, miješanje zraka i dovodenja zraka u zonu s ciljem održavanja izmiješanosti i kvalitete zraka te pospješivanje transfera energije.

Koliko je koji od ovih procesa bitan i koliko se koristi ovisi o primjeni (npr. operacijska dvorana, farma, mesnica). Važno je spomenuti da su ovi procesi međusobno povezani, osobito procesi grijanja i hlađenja s procesima vlaženja i sušenja. Sa stajališta ovog istraživanja, od interesa su upravo ova četiri procesa, i nešto manje ventilacija, odnosno upravo ono što čini tipični HVAC sustav.

HVAC sustave moguće je podijeliti u četiri tipa:

- zračni sustavi (engl. *All-Air*), u kojima se obrađeni zrak koristi za klimatizaciju zona (tipičan centralni dio sustava prikazan na slici 2.3.)
- zračno-vodeni sustavi (engl. *Air-and-Water*), u kojima postoji ventilacija obrađenog zraka, ali se u zonama nalaze i lokalni uređaji za dodatnu klimatizaciju (čak i kada su lokalni uređaji npr. električki, oni se povijesno nazivaju vodenim sustavima)
- vodeni sustavi (engl. *All-Water*), kod kojih se ventilacija obavlja prirodnim putem, a ostali procesi lokalnom opremom temeljenoj na toploj ili hladnoj vodi iz centralnog postrojenja (opet vrijedi opaska za električke uređaje)
- kompaktni sustavi (engl. *Unitary*), gdje lokalni uređaji u zoni obavljaju sve procese (najčešće temeljeni na rashladnim medijima) i nema centralnog dijela sustava.



Slika 2.3. Centralni dio zračnog HVAC sustava, njegovi dijelovi i tok zraka

Uređaji koji se pojavljuju u HVAC sustavima su sljedeći:

- centralni dio sustava: rekuperator (miješa povratni zrak iz zona sa svježim vanjskim zrakom), prigušnica za vanjski zrak (određuje udio vanjskog zraka), filter zraka,

izmjenjivač za toplu vodu (engl. *Heating Coil*), izmjenjivač za hladnu vodu (engl. *Cooling Coil*), ovlaživač zraka, puhalo zraka

- sustav za hlađenje: kompresor, kondenzator, ekspanzijski ventil, evaporator, tornjevi za hlađenje
- sustav distribucije obrađenog zraka u zone: vodovi (engl. *Ducts* – jednostruki, dvostruki, trostruki), jedinice za dogrijavanje zraka, prigušnice
- vodeni sustavi: cijevi za vođenje tople i hladne vode, bojleri, hladnjaci, radijatori, konvektori, cijevni radijatori, ventilkonvektori (engl. *Fan Coils*, kaloriferi), toplinske pumpe, ventili (ručni, sigurnosni, mješači, itd.).

Ovi uređaji dolaze u više izvedbi, a moguća je kombinacija više uređaja u kompaktne jedinice.


Pregledni rad [13] Vakiloroya et al. iz 2013. daje širok pregled inovacija i poboljšanja kojima se pokušava povećati učinkovitost, kako pojedinih elemenata HVAC sustava, tako i ukupnog rada sustava. Autori se koncentriraju na sustave za hlađenje, a prikaz je orijentiran na strojarstvo. Svima istraživanjima prikazanim u radu zajedničko je što koriste neku od strategija za čuvanje energije, a podijeljeni su prema načelu rada: sustavi s isparivačima (izravni, neizravni i kombinirani), sustav s kompresijom pare (zračno hlađeni, vodeno hlađeni, geotermalni i sustavi koji koriste tlo) te razne konfiguracije. U radu je prikazano preko stotinu novih rješenja.

Osim izvršnih elemenata, HVAC sustav se sastoji od mnoštva senzora, za mjerenje procesnih veličina kao što su: senzori za mjerenje temperature (zraka, vode, zidova), vlažnosti zraka (u prostoru ili cijevima), razine (u spremnicima), tlaka (upravljački ili sigurnosni), potrošnje (vode, plina, električne energije, itd.).

S obzirom da se većina složenih sustava (uredske, industrijske zgrade, hoteli, itd.) u današnje vrijeme upravljaju računalima, sva se mjerenja sa senzora dovode na računalo (centralno ili distribuirano) koje onda upravlja izvršnim elementima. Ovakav sustav, koji može obuhvaćati i funkcije upravljanja i funkcije nadzora, se u nekim primjenama naziva sustav upravljanja zgradom (engl. *Building Management System*, BMS). Osim HVAC sustavom, može upravljati i raznim drugim poveznim aktivnostima, kao što su otvaranje i zatvaranje automatiziranih zastora, praćenje otvorenosti prozora i slično, no i može poslužiti za napredne metode upravljanja, optimiziranje rada sustava i slično.

2.2. Toplinski modeli u zgradama i HVAC sustavima i pregled stanja u literaturi


Postoji mnogo definicija modela i modeliranja. Npr. u knjizi [14] modeliranje je proces nalaženja matematičkog modela koji adekvatno prikazuje određenu fizičku situaciju. Model se sastoji od strukture modela (matematičke jednadžbe koje definiraju systemske varijable, granice modela, odnosi između varijabli i sl.) i parametara modela (koeficijenti koji određuju odnose između varijabli u matematičkim jednadžbama). Jedan od načina prikaza sustava iz navedene literature je prikazan na slici 2.4.



Slika 2.4. Jedan od prikaza sustava (u – upravljački ulazi; v – neupravljivi ulazi; x – unutarnja stanja sustava; w – nesigurnosti senzora; y – izlazi senzora, odnosno sustava) iz literature [14]

Općenito o identifikaciji sustava, odnosno o dobivanju dinamičkog matematičkog modela iz podataka, s fokusom na metode identifikacije, može se naći u knjizi "System Identification" autora Keesman iz 2011. [14]. U knjizi se obrađuju teme kao što su: metode s odzivom sustava (impulsni, stepenični, sinusni), metode s frekvencijskim odzivom (Fourierova), korelacijska i spektralna analiza, identifikacija statičkih i dinamičkih sustava, identifikacija vremenski nepromjenjivih i promjenjivih sustava, validacije modela. Slična tematika obrađena je i u knjizi Perić i Petrović [15].

U kontekstu izgradnje termodinamičkih modela zgrada i HVAC sustava te ovisno o njihovom modeliranju, model se može predstaviti kao na slici 2.5. Na zgradu koja je određena svojim stanjima x djeluju ulazi podijeljeni na upravljačke ulaze u (rezultat rada HVAC sustava, odnosno grijanja, hlađenja i ventilacije; na primjer toplinska snaga radijatora) i neupravljive ulaze w (vanjska temperatura, Sunce, vjetar, kiša, aktivnosti stanara, itd.). Izlazima y su proglašena mjerenja od interesa (temperature u zonama, vlažnost zraka, itd.). Ovdje je uveden i regulator (sustav upravljanja zgradom) koji prikuplja podatke od senzora i zatim upravlja HVAC sustavom.



Slika 2.5. Zgrada i HVAC sustav prikazani kao model s regulatorom

Postoji mnogo podjela modela, čak i kada se govori o pristupu njihovoj izradi, no razdioba koja je ovdje od interesa (i koja je detaljno prikazana u sljedećim potpoglavljima) je sljedeća:

- teorijska analiza procesa, poznata još kao fizikalni ili teorijski pristup, koji polazi od osnovnih fizikalnih opisa, procesa i svojstava da bi izgradio potpuno otvoren i poznat model sustava, gdje se dobiveni model naziva model bijele kutije (engl. *White Box*)
- podatkovni pristup, poznat još kao eksperimentalna analiza, koji analizira odnos ulaznih i izlaznih podataka i stvara model kod kojeg nisu poznati unutarnji odnosi, gdje se dobiveni model naziva model crne kutije (engl. *Black Box*)
- hibridni pristup, koji kombinira prethodna dva pristupa, gdje se dobiveni model često naziva model sive kutije (engl. *Grey Box*).

Rad [16] autora Afram i Janabi-Sharifi iz 2014. daje upravo jedan takav pregled metoda za modeliranje u HVAC sustavima, gdje su metode podijeljene na fizikalni pristup (teorijska analiza), podatkovni pristup (eksperimentalna analiza) i hibridni pristup (modeli sive kutije). Pristupi su dodano podijeljeni, kod podatkovnog pristupa prema matematičkim metodama koje koriste, a kod fizikalnog pristupa prema elementu HVAC sustava koji obrađuju. Poseban osvrt se daje na metrike za usporedbu performansi modela, što je definirano raznim tipovima greške između izlaza referentnog i testnog sustava.

Primjer rada gdje se radi detaljno modeliranje dijela zgrade može se naći u radu Gerlich [17] iz 2011. U ovom slučaju, autor se bavi utjecajem toplinskog kapaciteta zidova prostorije na točnost modela. Koriste se alati CATIA (strojarski projektantski alat), COMSOL Multiphysics (paket za simulaciju i analizu fizičkih i inženjerskih aplikacija temeljen na metodi konačnih elemenata) i MATLAB (univerzalno okruženje za matematičke probleme iz područja tehnike) i vrši analiza podataka dobivenih mjerenjem na zgradi. Zaključuje se da toplinski model daje bolje rezultate kada model uključuje ovisnost koeficijenata toplinskog prijenosa o temperaturi, nego kada su oni uzeti kao konstante.

Izvrstan rad koji se bavi pregledom suvremenih istraživanja vezanih za toplinske modele HVAC sustava koji se koriste za upravljanje je [18] autora Atam i Helsen iz 2016. Autori daju vrlo opsežan pregled sva tri pristupa modeliranju (teorijski, podatkovni i hibridni) s dodatnim podjelama, te opisuju najčešće korištene metode i zajedničke značajke. Za pojedine metode opisane su posebnosti, prednosti i nedostaci. U drugom dijelu rada se posebno osvrću na mogućnost identifikacije (engl. *Identifiability* – može li se odabrana struktura modela identificirati iz dostupnih podataka), decentraliziranu identifikaciju (engl. *Decentralized Identification* – mogućnost podjele složenog modela u jednostavnije pod-modele), grupiranje zona i reduciranje složenosti modela.

2.2.1. Izrada toplinskih modela zgrada kroz teorijsku analizu

Teorijska analiza ili fizikalni pristup modeliranju pretpostavlja da se svi elementi sustava mogu modelirati koristeći fizikalne opise, odnose i jednadžbe. Može se reći da ovo predstavlja i pristup od dolje prema gore (engl. *Bottom-Up*) jer se svaki pojedini element prvo modelira samostalno, a zatim se on slaže (ili sintetizira) zajedno s drugima, pri čemu se modeliraju njihovi međusobno odnosi. Rezultat ovog pristupa je najčešće složeni matematički model koji opisuje sustav. Nedostatak ovog pristupa je što rezultat može biti vrlo složen te ga je često potrebno pojednostavljivati da bi se mogao koristiti za potrebe upravljanja. Također, postoji mogućnost

grešaka, bilo baš zbog tih pojednostavljivanja, bilo zbog zanemarivanja nekih svojstava ili iz činjenice da stvarne komponente sustava nisu idealne. Ovakav pristup najčešće zahtijeva i dosta vremena i truda. No treba reći da se ovim pristupom mogu ostvariti najbolji rezultati. Primjeri ovakvog pristupa su analiza u vremenskoj domeni, korištenje parcijalnih diferencijalnih jednadžbi, metode prijelazne funkcije i slično.

U nastavku poglavlja opisani su radovi koji se bave modeliranjem zgrada i HVAC sustava korištenjem fizikalnog pristupa. Većina navedenih radova samo ukratko opisuje fizikalno modeliranje svakog elementa HVAC sustava jer zbog ograničenog prostora nemaju mogućnost detaljno opisivati sve relevantne odnose i značajke. Detaljan prikaz modeliranja pojedinih elemenata HVAC sustava može se naći u knjizi [4].

Jednostavan opis metoda fizikalnog pristupa i metode koncentriranih parametara za toplinsko modeliranje zgrade može se vidjeti u Karmacharya et al. iz 2012. [19]. Model je implementiran u MATLAB i Simulink okruženju, a dobiveni rezultati se validiraju prema IEA Building Energy Simulation Test (BESTest).

U radu Ma et al. [20] iz 2012. detaljno je opisana izrada toplinskog modela HVAC sustava, od dijela za pripremu tople i hladne vode, do korištenja unutar zgrade. Modeliranju se pristupa na nekoliko razina, od globalnog modela cijelog sustava, modeliranja toplinskog tereta, modeliranja glavnih komponenata sustava, do modeliranja unutrašnjosti zgrade korištenjem otporničko-kapacitivne analogije. Ovaj toplinski model je korišten kod MPC upravljanja HVAC sustavom sveučilišnog kampusa.

Autori Rehrl i Horn u svom radu [21] iz 2011. opisuju korištenje modelskog prediktivnog upravljanja na HVAC sustavu, pri čemu se rad temelji na modelu dobivenim fizikalnim pristupom. Za testiranje su izgradili laboratorijsko HVAC postrojenje temeljeno na zračnom sustavu. Postrojenje se sastoji od rekuperatora, izmjenjivača za grijanje i hlađenje, ovlaživača, ventilatora, prigušnica i sl. Svaki od elemenata sustava je opisan zajedno s njegovim stvarnim karakteristikama te je dan njegov matematički opis.

Rad autora Tashtoush, Molhim i Al-Rousan [22] također daje kratak matematički opis svakog od elemenata HVAC sustava koji je prikazan: model zone/prostorije, toplinski izmjenjivač za grijanje, ovlaživač, model senzora temperature i vlažnosti zraka, ventilator, rekuperator koji miješa vanjski s povratnim zrakom iz prostorija, model zračnih vodova, te model toplinskog izmjenjivača za hlađenje i odvlaživanje zraka. Elementi su predstavljeni diferencijalnim jednadžbama i autori

koriste Laplaceovu transformaciju da svedu sve jednačbe koje opisuju pojedine elemente na funkcije kompleksne varijable i tako dobiju objedinjeni model HVAC sustava. Za upravljanje koriste PID (engl. *Proportional-Integral-Derivative*, proporcionalno–integracijsko–derivacijski) regulator.

U radu [23] autora Muratori, Marano, Sioshansi i Rizzoni iz 2012. opisano je modeliranje stambenog HVAC sustava korištenjem fizikalnog pristupa. Zanimljivost je usporedba nekoliko različitih scenarija, odnosno kolika bi bila ostvarena ušteda korištenjem učinkovitijih materijala i uređaja: dvostruka stakla; bolja toplinska izolacija zidova; efikasniji klima uređaj; efikasnija peć; kombinirani učinak.

Autori Ogunsola, Song i Wang u radu [24] iz 2014. prikazuju izradu toplinskog modela korištenjem fizikalnog pristupa gdje je struktura modela dobivena otporničko-kapacitivnom analogijom (RC metodom). Istraživanje je fokusirano na jednu prostoriju ili zonu, gdje se 3R2C struktura koristi za vanjski zid, a 2R2C za unutarnje zidove. Sustav je predstavljen u vremenskoj domeni, što znači da je trenutna temperatura u prostoriji funkcija prethodnih vrijednosti temperatura. Za parametre su korištene tipične vrijednosti iz ASHRAE (engl. *American Society of Heating, Refrigerating and Air Conditioning Engineers*) tablica. Rezultati modela su uspoređeni s referentnim modelom izrađenim u EnergyPlus softveru i odstupaju od referentnog modela za manje od 7%. Autori također analiziraju uzroke nesigurnosti u modelu.

2.2.2. Pojednostavljenja toplinskog modela dobivenog fizikalnim pristupom

Kao što je već napomenuto, prednost i nedostatak fizikalnog pristupa je u njegovoj složenosti. Ovi modeli uzimaju u obzir veliki broj parametara i odnosa te daju najbolje rezultate, no upravo zbog toga ih je teško razviti i često su zahtjevni za simulaciju. Zbog toga se često ide u pojednostavljenje ovakvih modela – bilo kod izrade zanemarivanjem određenih pojava i odnosa ili raznim metodama koje smanjuju broj parametara i varijabli već dobivenog modela.

Deng et al u radu iz 2010. [25] koriste metodu koncentriranih parametara za izradu toplinskog modela zgrade gdje je model predstavljen u obliku mreže. Njihova zamjerka ovoj metodi je prebrz rast složenosti modela: za jednostavnu zgradu od 4 sobe u njihovom primjeru potrebno je 37 čvorova i 51 brid. Da bi smanjili složenost modela koriste metodu zvanu agregacija stanja (engl. *Aggregation of States*) koja se temelji na Markovljevim lancima i koju primjenjuju na modelu dobivenim metodom koncentriranih parametara. Rezultantni model je također predstavljen u obliku mreže, no ona se sastoji od super-čvorova (super-kapaciteta) i super-bridova (super-otpota)

te je manje složenosti. Prednosti metode su mogućnost odabira stupnja redukcije te očuvanje fizikalne reprezentacije zgrade unutar modela.

Goyal i Barooah u radu [26] iz 2011. opisuju sličnu metodu za pojednostavljenje. Početni model dobiven je metodom koncentriranih parametara i jednostavnim modeliranjem zračnog voda. U obzir se uzima i vlažnost zraka u prostorijama. Za pojednostavljenje modela koriste metodu balansirano rezanja (engl. *Balanced Truncation*) koja se inače koristi na linearnim vremenski nepromjenjivim sustavima. Budući da je dobiveni toplinski model nelinearan, potrebno ga je razdvojiti na linearni i nelinearni dio, gdje se onda linearni dio pojednostavljuje. Rezultati simulacije pokazuju odlično ponašanje pojednostavljenog modela kod vlažnosti, te malo lošije kod temperature.

U radu [27] iz 2010. autora Luo i Ariyur opisan je toplinski model prostorije temeljen na metodi koncentriranih parametara. Autori definiraju kuboid kao osnovni element modela koji predstavlja jednu prostoriju sa šest ploha (četiri zida, strop i pod) koji se mogu slagati u veće konfiguracije. Predstavljaju ekvivalentnu matricu koeficijenata toplinskog prijenosa (EHCM, engl. *Equivalent Heat transfer Coefficient Matrix*) koja definira međusobni utjecaj prostorija. Autori se ne bave procjenom parametara ni upravljanjem, ali veliku pažnju posvećuju stanju otvorenosti vrata i prozora na prostorijama.

Pedersen et al. [28] opisuju pojednostavljenje toplinskog modela pomoću metode prostornog preslikavanja (engl. *Space Mapping*). Ovu metodu primjenjuju na zgrade opremljene s TAB (engl. *Thermally Active Building*) elementima, odnosno zgrade koje u jezgri betona imaju spremnike topline što im povećava toplinski kapacitet. Za primjenu preslikavanja potrebno je prvo imati vrlo precizan "fini model". Zatim se razvija "grubi model" nižeg reda, u ovom slučaju temeljen na metodi koncentriranih parametara. Na grubom modelu se opetovano vrše takve transformacije parametara da se dobije što manja razlika između rezultata simulacije finog i grubog modela. U konačnici, dobiva se pojednostavljeni model koji dovoljno dobro prati ponašanje stvarnog sustava predstavljenog finim modelom, a koji je puno manje složen za simulaciju. Nedostatak pristupa je što se gubi fizikalno značenje modela.

Rad autora Bacher i Madsen [29] ne bavi se konkretno pojednostavljenjem modela, nego opisuje kako odabrati odgovarajući model u ovisnosti o složenosti i točnosti modela. Opisuju metodu za izradu toplinskih modela temeljenu na hibridnom pristupu, povezujući RC metodu za izradu strukturne komponente modela i statističku metodu maksimalne vjerojatnosti (ML, engl. *Maximum Likelihood*) za određivanje parametara modela. Ispituju nekoliko varijanti modela iste

zgrade, ali različite složenosti i uspoređuju njihove rezultate pomoću testova omjera vjerojatnosti (engl. *Likelihood-Ratio*).

2.2.3. Podatkovni pristup izradi toplinskih modela zgrada

Podatkovni pristup naziva se i eksperimentalna analiza, a modeli koji se ovako dobiju nazivaju se modeli crne kutije (engl. *Black Box*). Ovaj pristup se temelji na korištenju matematičkih metoda za obradu podataka gdje se koriste povijesni podaci, odnosno mjerenja ponašanja sustava u nekom prošlom razdoblju. Rezultat ovog pristupa je funkcija, ili model, koja opisuje ponašanje sustava bez uvida o fizikalnim odnosima među veličinama, odnosno bez da se zna išta o unutarnjem ponašanju sustava, uvažavajući samo odnos ulaznih i izlaznih veličina. Primjeri ovakvog pristupa su razne statističke analize, umjetne neuronske mreže, Kalmanov filter i tako dalje.

Prednost ovog pristupa je najčešće vrlo jednostavno korištenje i uglavnom dobri rezultati modela. No postoje i nedostaci:

- mjerenja nisu uvijek dostupna ili, ako jesu, puna su smetnji ili se moraju obrađivati prije korištenja za izradu modela
- u nekim slučajevima, nedostatak može biti činjenica što ne postoji fizikalno značenje dijelova modela
- također, mogući su problemi kada se pojave nova ponašanja koja nisu bila obuhvaćena mjerenjima, odnosno kada se model koristi u dijelovima radnog područja za koja nije bilo informacija u podacima korištenima za izradu modela.

U nastavku poglavlja opisani su radovi koji se bave modeliranje zgrada i HVAC sustava korištenjem podatkovnog pristupa.

Općeniti uvod u numeričke metode, na kojima se najčešće temelji podatkovni pristup, može se naći u knjizi Scitovski [30]. U knjizi su obrađene teme od osnovnih pojmova, kao što su pogreške i metrike, interpolacija i splineovi, sustavi linearnih jednadžbi, sustavi nelinearnih jednadžbi, aproksimacije funkcija do metoda od kojih se neke koriste i u prikazanim radovima: problemi najmanjih kvadrata (LS, engl. *Least Squares*), numerička integracija, numeričko rješavanje običnih i parcijalnih diferencijalnih jednadžbi. O metodama za multivarijabilnu analizu i primjenama problema najmanjih kvadrata može se naći u [31]. Knjiga obrađuje sljedeće teme: osnovna pravila algebre matrica, vektorske funkcije, matrične funkcije, višestruku regresijsku analizu, analizu glavnih komponenata, MINRES analizu i sl.

Malisani et al. u radu [32] iz 2010. objašnjavaju korištenje statističke analize vremenskih serija, odnosno mjerenja, za dobivanje pojednostavljenog toplinskog modela. Autori prvo razvijaju toplinski model jednostavne zgrade 47-og reda koji smatraju referentnim modelom – model ima četiri ulaza (vanjska temperatura, Sunčevo zračenje na zidove i pod te toplinski tok grijača) i jedan izlaz (temperatura u prostoriji). Rade simulaciju te dobivenim rezultatima neovisno dodaju šum na ulaze i izlaz, što zatim koriste u svojoj analizi kao "stvarne podatke" da bi dobili pojednostavljeni model. Njihov doprinos je razdvajanje modela na sporu i brzu komponentu. Primjenjuju parametarsku identifikaciju koristeći ARX (engl. *AutoRegressive eXogeneous*) strukturu modela za dobivanje modela drugog reda. Daljnje poboljšanje dobiva se razdvajanjem svakog od ulaza na komponente brze i spore vremenske konstante. Ovom metodom se dobivaju vrlo dobri rezultati identifikacije parametara, iako autori naglašavaju potencijalnu osjetljivost metode na šum u podacima.

Još jedan sličan pristup s korištenjem ARX strukture modela opisan je u radu [33] iz 2013. autora Wen i Burke. Struktura modela je sljedeći: unutarnja temperatura y ovisi o prošlim vrijednostima y , prošlim vrijednostima v (vanjska temperatura) i prošlim vrijednostima u (snaga HVAC sustava), sve pomnoženo težinskim koeficijentima, te o srednjoj snazi šuma. Ovo se može dodatno reducirati tako da se pretpostavi da trenutna vrijednost izlaza ovisi o prošle dvije vrijednosti izlaza, o prošloj vrijednosti ulaza i prošloj vrijednosti vanjske temperature, te da nema šuma, što znatno pojednostavljuje sustav. Za određivanje parametara modela koriste rekurzivnu LS metodu (engl. *Recursive Least Squares*).

Češki autori Cigler i Privara u radu iz 2010. [34] prikazuju korištenje prediktivnog upravljanja na primjeru HVAC sustava stvarne zgrade, dakle na MIMO sustavu. Zgrada je opremljena sustavom grijanja temeljenom na grijanju jezgre betona stropa i zračenju topline. Koriste statističke metode za identifikaciju sustava, konkretno podprostornu metodu temeljenu na Kalmanovom filtru i algebarskoj Riccattijevoj jednadžbi. Model je predstavljen u obliku sustava varijabli stanja, gdje varijable nemaju fizikalno značenje, osim ulaza (predviđanje vanjske temperature, minimalna i maksimalna vrijednosti) i izlaza (temperatura u zgradi i temperatura povratne vode). Dobiveni model se dalje koristi u MPC regulatoru za dobivanje optimalnih rezultata. Sličan pristup se može naći i u Ferkl et al. [35] iz 2010.

Autori Wu et al. u radu [36] iz 2012. godine opisuju upotrebu statističke analize mjerenja dobivenih iz sustava za upravljanje zgradom za dobivanje toplinskog modela zgrade bez potrebe za prethodnim znanjima o zgradi ili HVAC sustavu. Koriste metodu *Support Vector Regression*

(SVR) na povijesnim podacima (mjerjenja potrošnje, temperatura i vlažnost zraka unutar zgrade, podaci o vanjskoj mikro-klimi i sl.) da bi dobili model koji se može upotrijebiti za predikciju. Pristup koristi metode iz strojnog učenja (engl. ML, *Machine Learning*) da bi se model automatski poboljšavao i prilagođavao promjenama. Metoda *Incremental Local Outlier Factor* se koristi za automatsku evaluaciju, odnosno da bi se našle anomalije u podacima, nakon čega se može prilagoditi model.

Još jedan rad koji koristi *Support Vector Machines* (SVM) je rad [37] autora Xuemei, Lixing i Lanlan. Autori koriste ovaj pristup za predviđanje ponašanja potreba za hlađenjem u zgradi. *Support Vector Regression* metoda za predviđanje je kombinirana sa SAPSO (engl. *Simulated Annealing Particle Swarm Optimization*) evolucijskim algoritmom za određivanje parametara SVM modela. Predviđanje potreba za hlađenjem u ovom slučaju ovisi samo o prethodnim mjerenjima.


U radu [38] autora Lazzarin, Castellotti i Busato iz 2005. opisana je izrada toplinskog modela tzv. zelenog krova, koji se koriste za smanjivanje toplinskog zagađenja u urbanim sredinama. Autori tehnički opisuju zeleni krov, nakon čega je dan popis mjerenja koja su bila izvršena u dva scenarija, ljetnom i zimskom. Za izradu samog modela je korišten programski paket Trnsys.

U radu Aswani et al. [39] autori opisuju korištenje djelomične parametarske regresije (engl. *Semiparametric Regression*) za izradu toplinskog modela. Prvo se radi makro-model korištenjem nekih osnovnih fizikalnih zakona, dok se detaljni toplinski teret ne modelira nego se promatra kao vremenski-promjenjiva konstanta koju se modelira statistički. Izlazne varijable (temperature zona) su funkcije prošlih vrijednosti, prošlih vrijednosti ulaza, vremenskih prilika, toplinskog tereta zgrade i greške. Rezultantni model je vrlo jednostavan i ima manji broj koeficijenata koji se mogu izračunati korištenjem metode najmanjih kvadrata. Ovaj model je zatim korišten u varijanti modelskog prediktivnog upravljanja LBMPC (engl. *Learning Based Model Predictive Control*) na dva primjera: jedna prostorija i složena višekatna zgrada.

2.2.4. Umjetne neuronske mreže

Umjetne neuronske mreže su jedan primjer podatkovnog pristupa koji je dosegao veliku popularnost u zadnjim desetljećima. Ovo je jedan univerzalan pristup, u smislu da se može upotrijebiti za razne primjene, pa tako i za razvoj toplinskih modela zgrada i HVAC sustava. Izrada modela se temelji na korištenju opće strukture matematičkog modela, a parametri se određuju nekim od numeričkih postupaka.

Na slici 2.6. prikazan je opći prikaz ANN metode, s detaljem od čega se sastoji jedan neuron. Ovo je samo jedan osnovni prikaz, jer je u zadnje vrijeme razvijeno mnogo tipova mreža i varijanata njihovog treniranja, o čemu se više može naći u literaturi.



Slika 2.6. Opći prikaz umjetne neuronske mreže s tri sloja i detalj jednog neurona (ulazi, težine, prijenosna i aktivacijska težina)

ANN se temelji na biološkim neuronskim mrežama. Sastoji se od neurona koji se povezuju u mreže, imaju ulazne težinske koeficijente i računaju vrijednosti unutarnjih varijabli mreže na osnovu ulaznih i izlaznih vrijednosti koristeći prijenosnu i aktivacijsku funkciju. Svaki neuron predstavlja jednu jednadžbu u ovom sustavu jednadžbi, dok su koeficijenti jednadžbi (odnosno parametri modela) predstavljeni težinskim koeficijentima. Postoji faza treniranja, gdje se koriste

stvarna mjerenja za izračun koeficijenata u jednadžbama, i faza validacije gdje se opet koriste mjerenja za provjeru valjanosti modela prije korištenja.

Općenito o umjetnim neuronskim mrežama može se naći u Graupe [40]. Autor u knjizi opisuje razne tipove i primjene umjetnih neuronskih mreža, od bioloških neuronskih mreža i prvih umjetnih mreža temeljenih na njima, preko klasičnog perceptrona (engl. *Multi-Layer Perceptron*) i metode *Back-Propagation* za treniranje, do suvremenih primjena kao što su *Adaptive Resonance Theory* i LAMSTAR (*Large Memory STorage And Retrieval*) mreže. Također, široki pregled problema, metoda i primjena umjetnih neuronskih mreža može se naći u Jain i Mohiuddin [41].

Bakker et al. [42] koriste model procesa temeljen na ANN-u za predviđanje potrebe za toplinskom energijom – u ovom slučaju ne jedne zgrade nego cijelog susjedstva (odnosno skupine zgrada). Za predviđanje koriste tipičnu višeslojnu *Feed-Forward* neuronsku mrežu, a kao ulazne podatke koriste povijesne podatke o potrošnji toplinske energije sa satnom rezolucijom. Predviđene vrijednosti toplinskog tereta (odnosno potrebe za toplinskom energijom) vrlo vjerno prate stvarno ponašanje sustava. Sličnu metodu koriste Beghi et al. u radu [43] iz 2010. da bi predvidjeli potrebu za hladnom vodom u sustavu sa spremnikom hladne vode. Ulazni podaci koji oni koriste su vanjska suha temperatura (engl. *Dry Bulb*), vanjska vlažna temperatura (engl. *Wet Bulb*) i protok zraka (odražava intenzitet korištenja sustava za hlađenje).

Tipični primjer korištenja umjetnih neuronski mreža za predstavljanje toplinskog modela zgrade može se vidjeti u radu Dong et al. [44]. Autori se u radu bave nisko-temperaturnim podnim grijanjem, za koje izrađuju *Back-Propagation* neuronsku mrežu. Sličan primjer može se vidjeti u Huang et al. [45] iz 2013. Autori rade *Multi-Layer Perceptron* mrežu s kojom istražuju međusobni utjecaj između tri otvorene zone (bez zidova između). Umjesto jednog velikog MIMO (engl. *Multiple-Input-Multiple-Output*, više ulaza, više izlaza) sustava, rade tri manja MISO (*Multiple-Input-Single-Output*, više ulaza, jedan izlaz) sustava.

2.2.5. Hibridni pristup izradi toplinskih modela zgrada

Hibridni pristup izradi toplinskih modela, kod kojih se rezultat naziva modelom sive kutije (engl. *Grey Box*), pokušava kombinirati teorijsku analizu s eksperimentalnom. Najčešće to znači da se za strukturnu identifikaciju, odnosno za određivanje strukture i reprezentacije modela, koristi fizikalni pristup, a za određivanje vrijednosti parametara modela se koristi podatkovni pristup, odnosno eksperimentalna analiza.

Postoji mnogo načina na koji se ova hibridnost može ostvariti, ovisno o kontekstu i primjeni. U nastavku poglavlja biti će opisani su radovi koji se bave modeliranjem zgrada i HVAC sustava korištenjem hibridnog pristupa.

Andersen et al. [46] u svom radu iz 2000. objašnjavaju hibridni pristup izradi toplinskog modela zgrade, odnosno model sive kutije (engl. *Grey Box*). Njihov pristup sastoji od tri koraka: odabir i identifikacija strukture modela; procjena (estimacija) parametara iz dostupnih podataka i mjerenja; validacija izrađenog modela. U radu su ovi koraci primijenjeni na testnoj zgradi, koristeći model s koncentriranim parametrima napisan u obliku sustava s varijablama stanja kao strukturu modela, dok za procjenu parametara koriste ML metodu.

Goyal, Liao i Barooah [47] u radu iz 2011. također koriste hibridni pristup izradi toplinskog modela, ali s naglaskom da se radi o pojednostavljenom (reduciranom) modelu. Pristup su razdvojili u dva koraka: određivanje strukture modela kroz teorijsku analizu i procjena parametara. Kod određivanja strukture modela koriste metodu koncentriranih parametara drugog reda (tipa 3R2C) da bi dobili mrežni model svih zona (svaka zona je jedan čvor; svaki brid je međudjelovanje između zona). Analizom mjerenih temperatura svih pojedinih zona kroz period od nekoliko dana i otkrivanjem kovarijance dobiva se graf minimalne složenosti, gdje bridovi postoje samo između čvorova kod kojih postoji međusobni utjecaj – odnosno reducirani toplinski model. U sljedećem koraku, procjeni parametara, računaju vrijednosti R i C iz podataka (minimalizacija razlike između simulacije i mjerenja) uz nekoliko općih i ekspertnih pretpostavki: linearnost i vremenska nepromjenjivost, simetričnost parametara, ograničenja u vrijednostima, iskustva iz tuđih radova. Dodatna zanimljivost ovog pristupa je što uz vođenje topline (kondukcija) uzima u obzir i inače zanemareni prijenos topline (konvekcija), a zanemaruje samo zračenje (radijacija). Nedostatak, koji priznaju i autori, jest da model opisan u radu može uzeti u obzir ili kondukcijsku povezanost između prostorija ili konvekcijsku, a ne obje istovremeno, što je najčešći slučaj u stvarnosti.

Autori Iino, Murai i Murayama u radu iz 2009. [48] opisuju drugačiju hibridnu metodu. Oni tvrde da su modeli dobiveni eksperimentalnom analizom dovoljno dobri za korištenje kod uobičajenih uvjeta (odnosno, kada se sustav nalazi u radnom području iz kojeg su i podaci korišteni za izradu modela), ali problemi nastaju kada dođe do nepredviđenih stanja ili ekstremnih uvjeta koje ovakve metode ne mogu predvidjeti (odnosno, kada sustav izađe iz radnog područja za koje je model izrađen), i tada je potrebno koristiti fizikalne modele da bi se u obzir uzeli nova stanja i uvjeti. Primarna metoda za predviđanje ponašanja zgrade je JIT (engl. *Just-In-Time*) metoda, koja pretražuje povijesne podatke (kojih treba biti puno) za slučajem sa sličnim uvjetima i koriste te

podatke za predviđanje. Istovremeno se ti podaci uspoređuju sa rezultatima fizikalnog modela i ako dođe do razlike, radi se novo predviđanje koja uključuje i nove uvjete. Prikazuju primjer u kojem hibridna metoda ostvaruje bolje rezultate nego samo JIT metoda, a za fizikalno modeliranje koriste HASP/ACSS+ACDL simulator.

Hibridni pristup modeliranju zgrade je opisan i u radovima Lee i Braun [49] i [50] kao sporedna tema uz opis prediktivnog upravljanja hlađenjem zgrade. Struktura modela zgrade temeljena je na RC metodi, a određivanje parametara je podijeljeno na grubo pretraživanje koje traži okvirne vrijednosti otpora i kapaciteta i lokalno pretraživanje koje poboljšava vrijednosti parametara korištenjem nelinearne regresijske metode, s ciljem smanjivanja RMS (engl. *Root-Mean-Square*, korijen srednje kvadratne) greške između mjerenja i izračunatih vrijednosti.

U radu [51] autora O'Neill Narayanan i Brahme iz 2010. opisan je hibridni model gdje se za određivanje vrijednosti parametara koristi prošireni Kalmanov filter (EKF, engl. *Extended Kalman Filter*). Autori prvo razvijaju toplinski model reduciranog reda temeljen na metodi koncentriranih parametara (varijanta s 3R2C elementima). Za sustav od sedam zona predstavljen pomoću varijabli stanja dobivaju matricu sustava s 82 stanja. Zatim koriste EKF na rezultatima mjerenja da bi procijenili vrijednosti parametara modela. Prvo rade estimaciju za jednu zonu, a zatim za ukupni više-zonski sustav. Rezultate verificiraju prema mjernim podacima dobivenim od senzora.

Privara et al. u radu [52] iz 2011. prikazuju korištenje softverskog paketa EnergyPlus za izradu toplinskog modela zgrade s više zona. Kao razloge odabira hibridnog pristupa navode preveliku složenost zgrada (odnosno, samo jednog njenog dijela) za modeliranje uz pomoć fizikalnog pristupa, te probleme koje imaju modeli dobiveni eksperimentalnom analizom kada se pojave nova stanja i uvjeti (odnosno, kada sustav izađe iz radnog područja za koje je model izrađen). Također, za nove zgrade ne postoje povijesni podaci. U radu je korak po korak opisano korištenje EnergyPlus alata za modeliranje i estimaciju parametara. Kao bitan zaključak autori navode puno bolje rezultate kada se uvaži međusobni utjecaj između zona. Rezultanti model je razvijen za korištenje u MPC upravljanju.

U radu iz 2012. autora Radecki i Hencsey [53] opisana je hibridna metoda za izradu toplinskog modela zgrade. Autori prvo kreću od postavljanja strukture ili oblika modela, za što koriste metodu koncentriranih parametara prvog reda. Svaka zona je predstavljena RC elementom, gdje je C toplinski kapacitet zone, a R toplinski otpor prema nekoj drugoj zoni. Ovako dobivaju matricu koja predstavlja graf međusobnog utjecaja zona. Za određivanje parametara modela iz mjerenja koriste UKF (engl. *Unscented Kalman Filter*) metodu. UKF je slična EKF metodi, ali umjesto

Jacobian linearizacije prvog reda koristi uzorkovanje na sigma točke koje se kasnije rekombiniraju. EKF i UKF daju iste rezultate za linearne sustave, ali se UKF pokazao boljim na određenim nelinearnim sustavima. U radu [54] istih autora ovako dobiveni toplinski model se koristi u MPC upravljanju HVAC sustavom zgrade.

Autori Wang i Xu se u radu [55] bave hibridnim pristupom modeliranju unutarnjeg toplinskog tereta zgrade. Pod internim toplinskim teretom podrazumijevaju namještaj, umjetne odjeljke, disanje ljudi i biljaka, infiltrirani zrak i slično. Koriste metodu koncentriranih parametara gdje za modeliranje jedne zone za zidove i strop koriste 3R2C elemente, a za pod i unutarnji toplinski teret koriste 2R2C element. Pretpostavljaju da su parametri modela za zidove i strop poznati, dok za estimaciju parametara modela poda i unutarnjeg toplinskog tereta koriste genetski algoritam (GA, engl. *Genetic Algorithm*). Ukratko opisuju GA i njegovu primjenu na stvarnoj komercijalnoj zgradi u dva različita režima: ljeto i zima. Još jedan rad koji prikazuje hibridni pristup u kombinaciji s genetskim algoritmima je rad [56] autora Yang et al. iz 2012. Za izradu strukture modela zgrade koriste gotov softverski paket HAMBBase koji daje toplinski model. Za estimaciju parametara modela koriste već postojeću metodu SaNSDE (engl. *Self-adaptation Neighboring Search Differential Evolution*) i poboljšavaju je u metodu SaNSDE+. Metoda je temeljena na genetskom algoritmu i optimiziranju težinske funkcije razlike između mjerenja i simulacije. Sam genetski algoritam se sastoji od koraka mutacije (engl. *Mutation*), križanja (engl. *Crossover*) i selekcije (engl. *Selection*).

Rad [57] iz 2008. autora McKinley i Alleyne opisuje korištenje hibridnog pristupa za izradu toplinskog modela zgrade korištenjem mjerenja. Za opis prostorije koriste metodu koncentriranih parametara drugog reda i zovu ga toplinska mreža. Utjecaj HVAC sustava (topli zrak) na prostor zovu zona i opisuju ga jednadžbama toka mase. Tako da je model svake prostorije opisan toplinskom mrežom i zonom. Za primjer metode koriste samo jednu prostoriju, čiji se toplinski model sastoji od osam parametara (četiri otpora, dva kapaciteta, masa zraka u zoni i mjera ulaska vanjskog zraka) i četiri vanjska tereta (unutarnji i vanjski solarni teret, latentni teret i senzibilni teret). Izrađuju simulacijski model zgrade visokog reda koji koriste kao referentni model i čije rezultate koriste kao mjerenja. Metoda koja se koristi za estimaciju parametara se temelji na minimalizaciji greške, odnosno razlike između mjerenja i simulacije, korištenjem "*Hill Climbing*" metoda. Dodatno, osim promatranja samo razlike temperature (što je bilo korišteno u prijašnjim radovima), uvode i promatranje razlike vlažnosti zraka između mjerenja i simulacije.

U radu [58] autora Harihan i Rasmussen opisana procjena parametara u podsustavima HVAC sustava. Autori se fokusiraju na ciklus isparivača (engl. *Vapor Compression Cycle*), ekspanzijski ventil (engl. *Expansion Valve*) i kompresor s varijabilnom brzinom (engl. *Variable Speed Compressor*) i na kraju sam isparivač (engl. *Evaporator*). Struktura modela je izrađena na temelju teorijske analize, dok su vrijednosti parametara dobivene estimacijom iz podataka. Uobičajeno je da je za detaljno modeliranje ovih podsustava potrebno imati podatke iz senzora toka mase, no autori su pokušali odrediti parametre modela iz ograničenog skupa podataka, odnosno iz dostupnih podataka o temperaturi i tlaku. Za estimaciju koriste LS i *Simplex* metode. U radu su opisana dva eksperimenta.

Autori Lin, Middelkoop i Barooah u radu [59] bave se hibridnim pristupom modeliranju toplinskog modela zgrade, no koncentriraju se na dva bitna pitanja: Koja je minimalna složenost modela koja je potrebna da bi model mogao što točnije predvidjeti ponašanje temperature u jednoj zoni tako da se može iskoristiti u MPC upravljanju?; Kako odrediti parametre modela i koji mjerni podaci su potrebni da se ostvari željena razina točnosti? U radu generiraju nekoliko modela zgrade temeljenih na RC metodi, počevši s najsloženijim koji obuhvaća "sve" procese i nekoliko pojednostavljenih. Parametre procjenjuju iz podataka koristeći LS i ML metode. Rade nekoliko analiza o mjernim podacima. Dobivaju dva bitna rezultata: Da modeli manje složenosti (reducirani modeli) mogu dati vrlo dobre rezultate predikcije; Da je potrebno da podaci koji se koriste za procjenu parametara sadrže prisilnu komponentu (grijanje ili hlađenje).

Slična tematika obrađena je u radu [60] autora Vana et al. iz 2013. Autori se isto bave pitanjem odabira složenosti modela koji se koristi u MPC-u. No u ovom radu odabran je suprotan pristup i kreće se od najjednostavnijeg mogućeg modela kojem se povećava složenosti (u smislu broja neupravljivih ulaza i unutarnjih stanja) sve dok dodana složenost ne prestane poboljšavati točnost modela. Testni modeli su temeljeni na hibridnom fizikalnom modeliranju (CMTS, engl. *Continuous Time Stochastic Modeling Software*, u ovom slučaju Trnsys), dok su vrijednosti parametara procijenjene pomoću *Maximum Likelihood* metode.

Rad [61] autora Martinčević, Starčić i Vašak opisuje kombinaciju RC metode za određivanje strukture modela i UKF za procjenu parametara modela. Glavni razlog za ovu kombinaciju je što RC metoda daje modele s velikim brojem stanja kod kojih je kasnije teško procijeniti parametre. Dio parametara se pretpostavlja da je poznat i uzimaju se vrijednosti iz podataka o materijalima, čime se smanjuje broj parametara koje je potrebno procijeniti te se za zonu koristi model prvog reda. Umjesto izravnih mjerenja iz zgrade (dva kata FER-ove zgrade u Zagrebu), koriste podatke

dobivene iz modela generiranog komercijalnim alatom IDA-ICE. Zaključuju da je rezultatni model dovoljno dobar za korištenje u modelskom prediktivnom upravljanju.

U radu [62] autora Scotton et al. iz 2013. opisan je hibridni pristup za izradu toplinskog modela koji se fokusira na kvalitetu unutrašnjeg zraka (engl. *Indoor Air Quality*) i koncentraciju CO₂. Samo modeliranje zgrade, odnosno u ovom slučaju jedne zone, temelji se na fizikalnom pristupu, modelu s više ulaza i jednim izlazom (MISO), po jedan za koncentraciju CO₂, temperaturu i vlažnost zraka. Koriste ARMAX strukturu modela i daju fizikalne jednadžbe sustava. Procjena parametara je izvedena pomoću programskog paketa MATLAB, modula *System Identification Toolbox* i *Prediction Error* metode. Daju detaljan zaključak što je najviše utjecalo na njihov model.

Autori Ellis, Hazas i Scott predstavljaju svoj model nazvan Matchstick u radu [63] iz 2013. Posebnost ovog modela jest da koristi podatke koji su dostupni iz uobičajenih senzora kao što su temperatura u zonama, brojilo plina i vanjska temperatura. Predstavljaju vrlo jednostavan model temeljen na regresiji, dok je određivanje parametara modela izvedeno pomoću MATLAB funkcije *lsqcurvefit* (temeljena na nelinearnim najmanjim kvadratima). Model je testiran na 4 vrlo različite zgrade u različitim uvjetima (stara/moderna, SAD/Ujedinjeno Kraljevstvo, radijatori/podno grijanje/zračni sustav) i u svima je dobiven vrlo dobar rezultat kratkoročnog predviđanja temperature (što je potrebno za korištenje u MPC upravljanju). Autori daju i par prijedloga kako dodatno poboljšati model.

Rad [64] autora Park et al. iz 2013. godine prikazuje klasičnu primjenu hibridne metode za modeliranje toplinskih procesa u jednoj sobi. Soba je dobro izolirana što smanjuje utjecaj okoliša. Autori predstavljaju pojednostavljeni toplinski model sobe u kojoj je HVAC sustav predstavljen jednim električnim grijačem. Koriste RC metodu za modeliranje, dok je struktura modela predstavljena na nekoliko načina: ARMA model (engl. *Auto-Regressive Moving Average*), ARX model (engl. *Auto-Regressive with eXogenous input*), ARMAX model (engl. *Auto-Regressive Moving Average with eXogenous input*), BJ model (engl. *Box-Jenkins*) i OE model (engl. *Output Error*). Određivanje parametara modela je izvršeno pomoću metode najmanjih kvadrata (engl. *Least Squares*), dok su za kriterij greške (između mjerenih izlaza i izlaza simuliranog modela) korišteni prosjek apsolutne greške (engl. *Mean Absolute Error*) i prosjek kvadratne greške (engl. *Mean Square Error*). U analizi su predstavljeni prednosti i nedostaci korištenih modela.

U radu [65] autori De Coninck et al. prikazuju praktičnu primjenu hibridnog pristupa za izradu toplinskog modela zgrade i HVAC sustava. Opisan je skup alata temeljen na već dostupnim aplikacijama koji omogućuju jednostavnu i gotovo automatiziranu izradu toplinskog modela

zgrade. Alati su temeljeni na jeziku za modeliranje Modelica i programskom jeziku Python, a sastoje se od četiri modula:

- Modelica biblioteke *FastBuildings* za modeliranje zgrada i HVAC-a
- *.mop* datoteka koje definiraju komponente i parametre modela
- *JModelica.org* algoritma koji prevodi *.mop* datoteke i definira optimizacijski problem
- *greybox.py* Python modula sa sučeljem prema korisniku.

Za jednostavnije zgrade nije uopće potrebno ulaziti u strukturu modela, dok je kod složenijih objekata to preporučeno za dobivanje boljih rezultata. U radu je objašnjen način rada i korištenje ovih modula te je prikazano nekoliko primjera s različitim strukturama modela.

2.3. Upravljanje HVAC sustavima zgrada i pregled stanja u literaturi

U prošlom potpoglavlju prikazana je izrada toplinskih modela zgrada i HVAC sustava, dok je ovdje prikazano upravljanje (slika 2.5.). Kao i modeliranje, upravljanje (engl. *Control*) je preširok pojam koji nadilazi opseg ovoga rada, no više detalja se može naći u navedenoj literaturi.

Također, kao i modeliranje, i upravljanje je moguće razdvojiti prema mnogim kriterijima. No u ovom radu, korištena je sljedeća razdioba, objašnjenja u sljedećim potpoglavljima:

- klasično upravljanje (dvopoložajna regulacija, povratna veza, PID, itd.)
- napredne i inteligentne metode upravljanja (adaptivno upravljanje, neizrazita logika, umjetne neuronske mreže, itd.)
- prediktivno upravljanje (s posebnim osvrtom na modelsko prediktivno upravljanje i ostale varijante).

Odličan uvod u upravljanje i teoriju signala i sustava predstavlja knjiga "Feedback and Control for Everyone" dva autora Albertos i Mareels [66] iz 2010., u kojoj autori prolaze klasične teme vezane za upravljanje (signali, sustavi, upravljački sustav i podsustavi, dizajn upravljanja, itd.) s osobitim fokusom na povratnu vezu. Knjiga sadrži veliki broj praktičnih primjera i prikladna je za sve koji ulaze u svijet upravljanja.

Pregled upravljačkih metoda i tehnologija kroz povijest može se naći u radu Kozak iz 2012. [67]. Autor razlikuje četiri faze upravljanja, od čega su prve dvije faze klasične metode, a druge dvije moderne metode upravljanja. U klasične metode ubraja konvencionalno upravljanje (ručno upravljanje, povratna veza, kaskadno upravljanje, PID algoritam, itd.) te napredno upravljanje I (adaptivno i samo-prilagodljivo upravljanje, MIMO metode, itd.). Napredno upravljanje II


(optimalne upravljačke metode, robusno upravljanje, MPC, itd.) i napredno upravljanje III (hibridni pristup, neizrazita logika, neuronske mreže, ekspertne metode, itd.) pripadaju u moderne metode. Autor se još bavi prodorom ICT (engl. *Information and Communication Technology*) pristupa u upravljanje i automatiku.

Autori Aswani et al. u radu [68] iz 2012. bave se pitanjem objektivnog ocjenjivanja kvalitete upravljanja. Iako je na izgled odgovor jednostavan, autori objašnjavaju koji izazovi ovdje postoje. Često zgrade uopće nisu opremljene sustavima koji omogućuju mjerenje na kojima se može temeljiti usporedba, niti postoji odvojenost HVAC sustava od ostalih sustava u zgradi. Autori se posebno osvrću na još dva problema. Prvi je velika ovisnost ocjene o vanjskim uvjetima (primarno vanjskoj temperaturi), koja bi trebala biti ista da bi se dva upravljačka algoritma mogla usporediti. Drugi problem je zanemarivanje pristupa upravljanju – nije isto ako jedan regulator radi neprekidno, a drugi samo preko dana (a ne i noću). Opisuju metodu za mjerenje energetske učinkovitosti temeljenu na linearnoj regresiji, te metodu za mjerenje ugone stanara temeljenu na zadržavanju unutar pojasa ugone (engl. *Band of Comfort*) koja se odnosi na temperaturu. Daju primjer usporedbe klasičnog i MPC regulatora.

2.3.1. Klasično upravljanje

Pod klasičnim upravljanjem podrazumijevaju se osnovne metode upravljanja koje se temelje na povratnoj vezi (engl. *Feedback*) ili unaprijednoj vezi (engl. *Feedforward*) vezi te primjeni standardnih tipova regulatora s proporcionalnim, integracijskim i derivacijskim svojstvima i njihovim kombinacijama, od kojih najveći značaj ima PID regulator. Primjeri ovakvog upravljanja se mogu naći u svakodnevnom životu i postoje već dugo vremena, kao što su regulacija pomoćnu dvopoložajnog regulatora (engl. *On-Off*) upravljanje s ili bez histereze, PID regulator i slično.

Jedan od osnovnih primjera je klasični termostat s histerezom za bojler, čija je shema prikazana na slici 2.7. Kada temperatura koju termostat mjeri padne ispod zadane temperature T (reference ili referentne veličine) za vrijednost histereze ΔT , termostat uključuje bojler. Tek kada mjerena temperatura poraste iznad zadane temperature T za vrijednost histereze ΔT , termostat isključuje bojler.



Slika 2.7. Prikaz rada (statička karakteristika) termostata s histerezom – uključivanje i isključivanje bojlera kada temperatura padne ispod, odnosno prijeđe iznad zadane temperature

Više primjera klasičnog upravljanja može se naći u [66]. U nastavku su prikazani neki radovi koji se temelje na klasičnim metodama upravljanja za upravljanje HVAC sustavima u zgradama.

Rad Liu, Cai i Zhang [69] opisuje korištenje ulaznih i izlaznih podataka za podešavanje parametara PID regulatora tijekom rada (engl. *On-Line*), odnosno adaptivno upravljanje. Tipična primjena za ovakvo automatsko određivanje parametara je upravo HVAC. Prikaz korištenja PID upravljanja kod HVAC sustava je dan u radu [22]. Autori koriste fizikalni pristup da bi dobili model sustava te nekoliko PID regulatora, npr. za grijanje, hlađenje, vlaženje i odvlaživanje. Parametre PID regulatora (proporcionalno pojačanje, vremenska konstanta integracije i vremenska konstanta derivacije) određuju pomoću Ziegler-Nichols postupka.

Wang, Zhang i Jing u radu [70] opisuju upravljanje HVAC sustavom velike komercijalne zgrade temeljeno na klasičnim metodama. Prvo opisuju zgradu i distribuirani HVAC sustav te elemente sustava upravljanja. Osim PID regulatora, sustav upravljanja koristi i nekoliko drugih metoda da bi dobili bolje rezultate: razdvajanje vanjskih uvjeta u režime (ljet/zima, pad/rast temperature i sl.), kontinuirano podešavanje parametara regulatora ovisno o rezultatima upravljanja u zadnjem periodu (engl. *On-Line Tuning*), rad u otvorenoj ili unaprijednoj petlji (engl. *Feed-Forward Control*) i kompenziranje kašnjenja (engl. *Lag Compensation*).

Primjer kako se optimizacijom sustava za vrijeme projektiranja mogu dobiti poboljšani rezultati upravljanja opisan je u radu [71] iz 2009. autora Komareji et al. Opisuje HVAC sustav koji se sastoji od izmjenjivača topline zrak-zrak i izmjenjivača voda-zrak. Klasični sustav se sastoji od dva regulatora koji kao kriteriji regulacije (referentnu veličinu) koriste vrijednost temperature zraka uvjetovanog HVAC sustavom. Njihovo poboljšanje je odvajanje kriterija: regulator izmjenjivača zrak-zrak koristi vrijednost temperature zraka nakon izmjenjivača zrak-zrak kao referentnu veličinu, a regulator izmjenjivača voda-zrak koristi vrijednost temperature zraka nakon izmjenjivača voda-zrak kao referentnu veličinu. Također, u sustav je dodana mogućnost upravljanja pumpom za vodu kod izmjenjivača voda-zrak (klasično rješenje podrazumijeva samo upravljanje troputnim miješajućim ventilom).

Rad [72] autora Jain, Otten i Alleyne iz 2010. opisuje kombinaciju PID regulatora s rasprežnim (engl. *Decoupled*) upravljanjem bez povratne veze (engl. *Feed-Forward Control*). Primjer na kojem temelje svoj regulator je uređaj za rashlađivanje zraka. Klasični pristup je promatrati ovakav sustav kao MIMO, ali oni koriste rasprezanje da bi ga promatrali kao tri SISO (engl. *Single-Input-Single-Output*, Jedan ulaz, jedan izlaz) sustava. Korištenjem mjerenja i statističkih alata (ML metoda) za identifikaciju sustava dolaze do matematičkog modela procesa trećeg reda. Razvijaju regulator koji se sastoji od tri PID regulatora i dodaju mu kompenzaciju bez povratne veze koju temelje na rezultatima mjerenja procesnih veličina. Rezultati simulacije pokazuju puno bolje praćenje zadane vrijednosti (engl. *Tracking*), što također rezultira i manjom potrošnjom energije.

2.3.2. Napredne i inteligentne metode upravljanja

Pod naprednim metodama upravljanja mogu se svrstati metode koje unaprijeđuju klasično upravljanje, bilo uvođenjem ekspertnih sustava, multivarijabilne analize, optimizacije i funkcije cilja, decentralizacije i slično. Sve ove metode određuju upravljačke veličine prema zadanoj kriterijskoj, odnosno ciljnoj funkciji. Pod inteligentnim metodama obično se smatraju metode koje se u nekoj mjeri temelje na ostvarivanju upravljačkih algoritama na računalnim tehnologijama, kao što su neizrazito (engl. *fuzzy*) upravljanje, umjetne neuronske mreže (ANN), razne hibridne metode i slično. Prediktivno upravljanje se također može svrstati u napredne metode upravljanja, no s obzirom da se ovakve metode temelje na (eksplicitnom) modelu sustava, odvojene su u skupinu na modelima zasnovanog upravljanja..

U nastavku je prikazano nekoliko suvremenih istraživanja koje koriste napredne i inteligentne metode upravljanja za HVAC sustave.

Zanimljiv pristup upravljanju predstavljaju autori Purdon et al. u radu [73] iz 2013. Oni predstavljaju upravljanje bez modela gdje se upravljačka akcija određuje pomoću referentne vrijednosti određene glasovanjem stanara (engl. *Voting* ili *Occupant Feedback*). Sustav je zamišljen tako da stanari zgrade (kada su prisutni) glasovanjem pomoću pametnih telefona dojavljuju njihov osjećaj ugone (hladno, ugodno, vruće), što uvjetuje reakciju HVAC sustava (grijanje kada je hladno, hlađenje kada je vruće). Objašnjavaju dva moguća pristupa glasovanju: prihvatanje odluke većine kao točne (što ostavlja ostale u eventualnoj neugodi) ili minimalizacija osjećaja neugode (većini je u određenoj mjeri neugodno, ali minimalno). Dodatna ušteda može se ostvariti ako se dozvoli da unutarnja temperatura naginje ili klizi (engl. *Drift*) prema vanjskoj. Iako ovo može dovesti do malog osjećaja neugode kod stanara, istovremene dolazi do velikih dodatnih ušteda energije.

U radu [74] iz 2013. autora Wen et al. opisuje se izrada sustava upravljanja s adaptivnim unaprijednim regulatorom (engl. *Adaptive Feed-Forward*). Autori prvo opisuju dobivanje toplinskog modela pomoću metode koncentriranih parametara, čime dobiju graf kojem su čvorovi kapaciteti, a bridovi otpori. Također se modelira HVAC sustav pomoću jednadžbi mase zraka. Cilj upravljanja je pomaknuti točku ravnoteže sustava (engl. *Equilibrium*) prema željenoj radnoj točki. Pretpostavljaju da vrijednosti parametara modela nisu konstantne da bi dobili adaptivni sustav. Metoda se testira na simulaciji zgrade s 4 prostorije, gdje je referentni toplinski model dobiven fizikalnim pristupom. Dodatno se koristi i alat za izračun dinamike fluida (engl. CFD, *Computation Fluid Dynamics*) za dobivanje točnijeg referentnog modela.

Pregled korištenja neizrazite (engl. *fuzzy*) logike i neizrazitih regulatora u HVAC sustavima može se vidjeti u radu Singh, Singh i Sharma [75]. Objašnjeni su osnovni pojmovi neizrazite logike (baza znanja, izraziti i neizraziti skupovi) te integracija ovakvog pristupa s drugim metodama, kao što su: genetski algoritmi, uskupljavanje (engl. *clustering*), modelsko prediktivno upravljanje. Neizraziti pristup ima razne prednosti, osobito kod korištenja u nelinearnim sustavima, što HVAC sustavi i jesu. U radu je navedeno preko 80 referenci.

Alcala et al. [76] vrlo detaljno obrađuju tematiku upravljanja koje se temelji na neizrazitoj logici: teorija neizrazite logike, dijelovi neizrazitih regulatora, baza znanja (KB, engl. *Knowledge Base*), procedure kod dizajna upravljanja i sl. Zatim se bave genetskim algoritmima, koje koriste za određivanje parametara eksperimentalnog sustava. Rezultati im pokazuju da su moguće određene uštede u odnosu na klasičnu regulaciju pomoću dvopoložajnog regulatora, ali da treba voditi i računa o stabilnosti sustava. Zanimljivost rada je da koriste tri različita regulatora, po jedan

za svaku radnu točku sustava: jedan za ljetne uvjete, jedan za zimske te jedan za prijelazno razdoblje (proljeće/jesen). Genetski algoritam kojim određuju parametre regulatora je dopunjen s dva bitna pristupa: pristup stacionarnog stanja (engl. *Steady State Approach*) koji ubrzava konvergenciju prema boljem rješenju tako što koristi samo dvije najbolje jedinice za dobivanje sljedećeg naraštaja; te više-kriterijska genetska optimizacija. U sličnom radu iz 2000., Angelov et al. [77] koriste neizrazitu logiku da bi modelirali i upravljali bojlerom za pripremu vode za grijanje, te koriste genetski algoritam da bi odredili parametre regulatora iz mjerenja. Još jedna kombinacija regulatora temeljenog na neizrazitoj logici s genetskim algoritmima za određivanje matrice pravila neizrazitog regulatora može se vidjeti u Khan, Choudhry i Zeeshan iz 2013 [78], gdje FLC (engl. *Fuzzy Logic Controller*) upravlja cijelim HVAC sustavom.

Al-Ali et al. [79] u svom radu iz 2012. prikazuju jednostavan HVAC sustav u kojem je potreba energije za grijanje, odnosno hlađenje zgrade (obiteljske kuće) veća od dostupne energije. Regulator temeljen na neizrazitoj logici određuje koje zone se griju (ili hlade) na osnovu uvjeta u svakoj prostoriji (hladno, svježije, toplo, vruće), maksimalno povećavajući ugodu u uvjetima ograničenih resursa. Na ovaj način dostupni resursi su iskorišteni maksimalno, a sve prostorije se tretiraju podjednako.

Rad [80] autora Villar, Cal i Sedano prikazuju ekspertni sustav za upravljanje grijanjem temeljen na neizrazitoj logici, temeljen na dva ograničenja: maksimalna dostupna energija i minimalna dovoljna temperatura u prostorijama. Za upravljanje autori implementiraju dva neizrazita regulatora: prvi sadrži model zgrade i analizira aktivne potrošače da bi dobio dostupnu energiju; drugi određuje kako rasporediti dostupnu energiju da bi održao temperaturu u prostorijama na prihvatljivoj razini.

Primjer korištenja robusnog upravljanja u HVAC sustavima može se naći u Anderson et al. [81] iz 2008. Robusno upravljanje se fokusira na problem nesigurnosti u upravljanju tako što dozvoljava parametrima regulatora da poprimaju vrijednosti unutar nekog prihvatljivog raspona. U radu analiziraju jednostavan HVAC sustav koji se klasično upravlja s tri odvojena PI regulatora: prvi za rekuperator (koji miješa povratni zrak iz zona sa svježim vanjskim zrakom i pušta ga nazad u sustav kao polazni zrak); drugi za rad plinskog bojlera za pripremu tople vode; treći za troputni ventil koji određuje prijelaz topline s tople vode na ulazni zrak. Umjesto ova tri regulatora koristi se jedan više-kriterijski koji upravlja sa sva tri izvršna elementa (MIMO), dodatno uvažavajući nesigurnost vrijednosti mjerenja izlaznih veličina. Rezultati pokazuju da ovakav regulatora ima tri

puta bolje performanse (brzina dostizanja nove zadane temperature) u odnosu na sustav s pojedinačnim regulatorima.

Rad [82] autora da Costa Sousa i Kaymak iz 2001. opisuje kombiniranje pristupa neizrazite logike s modelskim prediktivnim upravljanjem. Metoda *Fuzzy Decision Making* (FDM) se koristi kod određivanja ciljeva MPC-a (težinska funkcija) i kod ograničenja (engl. *Constraints*; tvrda i meka ograničenja). Autori dokazuju da se kod određenih primjena MPC regulator može dodatno poboljšati korištenjem neizrazite logike.

U radu [83] Dounis i Caraiscos iz 2009. dan je pregled velikog broja radova koji koriste napredne metode upravljanja u HVAC sustavima, s fokusom na sustave upravljanja s više agenata (engl. *Multi Agent Control Systems*). Opisane metode podijeljene su u tri skupine. Prva skupina su konvencionalne metode upravljanja, kao što su klasični regulatori (dvopoložajni regulator s ili bez histereze, PID) te razne varijante optimalnih, prediktivnih i adaptivnih regulatora. Druga skupina su metode upravljanja koje se oslanjaju na računalnu inteligenciju (engl. *Computational Intelligence*), kao što su neizraziti regulatori, neuronske mreže i razne kombinacije takvih modela (FLC i neuronske mreže, FLC i PID, FLC s genetskim algoritmima, itd.). Treća skupina su sustavi više agenata (MACS, engl. *Multi-Agent Coordination Systems*). Ovakve sustave detaljno opisuju i daju primjere primjene u upravljanju zgradama i HVAC sustavima. Prednost ovakvih sustava je što su prilagođeni za distribuirane sustave i sustave s nekoliko razina hijerarhije, što odgovara HVAC sustavima u zgradama.

Goddard, Klose i Backhaus u radu [84] iz 2014. bave se *Demand Response* metodom. Cilj ove metode nije klasično upravljanje HVAC sustavom, nego smanjenje ukupne potrošnje energije. Metoda je prilagođena za korištenje u velikim komercijalnim zgradama gdje postoji veliki broj malih toplinskih tereta (hlađenje pojedinih uredskih prostorija) koje zajedno (agregacijom) daju veliki ukupni toplinski teret (zgrade). Ne bave se modelom zgrade, nego pretpostavljaju da male promjene zadanih vrijednosti HVAC sustava (engl. *Global Thermostat Reset*) mogu rezultirati uštedama energije, a bez da korisnici osjete pogoršanje klimatskih uvjeta u zonama. Rade nekoliko eksperimenata gdje kratkoročno podižu i smanjuju zadanu vrijednost temperature u zonama (+1,1 °C i -1,1 °C) te tako smanjuju potrošnju energije.

Pregledni rad [85] iz 2010. autora Mirinejad, Welch i Spicer bavi se inteligentnim metodama za upravljanje u HVAC sustavima. Konkretno, opisuju algoritme neizrazite logike koji su kombinirani s neuronskim mrežama (engl. *Neuro-Fuzzy Systems*) ili genetskim algoritmima (engl. *Genetic-Fuzzy Systems*). Opisano je oko 40 radova.

Rad [86] autora Wu i Guan iz 2015. godine koristi pristup temeljen na događajima (engl. *Event-Based Approach*). Time prelaze iz prostora varijabli stanja koji je vrlo velik za stvarne zgrade, u prostor događaja koji je puno manji. Rad je unaprjeđenje prijašnjih metoda koje su temeljene na Markovljevim lancima (engl. *Markov Decision Processes*), gdje oni razdvajaju događaje na globalne (cijela zgrada) i lokalne (samo jedna soba ili zona). Koristeći metodu temeljenu na lokalnim događajima, u testu sa stvarnom zgradom dobivaju rezultate koji su bolji od klasičnog upravljanja, a ne zahtijevaju velike resurse za izradu modela i upravljanje.

2.3.3. Prediktivno upravljanje i modelsko prediktivno upravljanje

Prediktivno upravljanje može se svrstati u napredne metode upravljanja, no s obzirom da postoji mnoštvo varijanata prediktivnog upravljanja sa zajedničkom osobinom da se temelje na nekom obliku modela upravljanog sustava, odvojeni su u posebnu skupinu. Jedan tipični primjer prediktivnog upravljanja je modelsko prediktivno upravljanje, odnosno MPC.

Neka se pretpostavi da postoji toplinski model zgrade i HVAC sustava opisan diskretnim vremenski nepromjenjivim sustavom jednadžbi u prostoru stanja:

$$\mathbf{T}(k+1) = \mathbf{A}\mathbf{T}(k) + \mathbf{B}_u\mathbf{u}(k) + \mathbf{B}_v\mathbf{v}(k), \quad (2-9)$$

$$\mathbf{y}(k) = \mathbf{C}\mathbf{T}(k) + \mathbf{D}\mathbf{u}(k). \quad (2-10)$$

gdje su:

- k – korak
- $\mathbf{T}$ – vektor stanja
- $\mathbf{y}$ – vektor izlaza
- $\mathbf{u}$ – vektor upravljačkih ulaza
- $\mathbf{v}$ – vektor neupravljivih ulaza
- $\mathbf{A}$ – matrica stanja
- $\mathbf{B}_u$ – ulazna matrica upravljačkih ulaza
- $\mathbf{B}_v$ – ulazna matrica neupravljivih ulaza
- $\mathbf{C}$ – izlazna matrica
- $\mathbf{D}$ – prolazna matrica.

Jedan od načina kako matematički formulirati MPC jest [35]:

$$\min_{u_1 \dots u_U(1 \dots N)} J = \sum_{k=1}^N \left(\sum_{i=1}^Y w_{Y_i} (y_i(k) - r_i(k)) + \sum_{j=1}^U w_{U_j} u_j(k) \right), \quad (2-11)$$


$$y_{MIN_i}(k) \leq (y_i(k) - r_i(k)) \leq y_{MAX_i}(k), \quad i = 1 \dots Y, k = 1 \dots N, \quad (2-12)$$

$$u_{MIN_j}(k) \leq u_j(k) \leq u_{MAX_j}(k), \quad j = 1 \dots U, k = 1 \dots N, \quad (2-13)$$

gdje su:

- J – težinska funkcija
- N – duljina prediktivnog obzora
- w_Y – težinski koeficijenti za izlaze
- $y_i(k)$ – vrijednost i-tog izlaza u k-tom koraku
- $r_i(k)$ – vrijednost i-te zadane vrijednosti u k-tom koraku
- Y – broj izlaza
- w_U – težinski koeficijenti za upravljače ulaze
- $u_j(k)$ – vrijednost j-tog upravljačkog ulaza u k-tom koraku
- U – broj upravljačkih ulaza
- y_{MIN} i y_{MAX} – ograničenja unutar kojih se razlike vrijednosti izlaza i zadane vrijednosti (ili greška izlaza) moraju nalaziti
- u_{MIN} i u_{MAX} – ograničenja unutar kojih se vrijednosti upravljačkih ulaza moraju nalaziti.

Interpretacija ove formule je sljedeća: potrebno je minimalizirati težinsku funkciju J , koja je jednaka zbroju greške izlaza (razlika predviđenih izlaza y i zadanih vrijednosti r) te zbroju upravljačkih ulaza u za sljedećih N koraka, zadovoljavajući uvjete da vrijednosti greške izlaza i vrijednosti ulaza ostanu unutar zadanih ograničenja. U kontekstu zgrada i HVAC sustava, vrijednosti izlaza y jednake su mjerenim (odnosno predviđenim) temperaturama unutar zona, zadane vrijednosti r (engl. *Setpoints*) su zadane vrijednosti temperatura, dok ulazi u predstavljaju ulaz energije u zonu kroz HVAC sustav. Tako da je fizikalna interpretacija formule (2-11) sljedeća: potrebno je regulirati HVAC sustav tako da vrijednosti temperatura u zonama budu što bliže zadanim (maksimalna temperaturna uroda) uz što nižu potrošnju energije (maksimalna energetska učinkovitost). Ova interpretacija je prikazana i na slici 2.8.



Slika 2.8. Prikaz rada modelskog prediktivnog upravljanja iz perspektive trenutnog koraka

Ova optimizacija se ponavlja u svakom koraku upravljanja (korak najčešće iznosi 15-120 minuta u HVAC primjenama) s novim vrijednostima, tako da se ovaj tip upravljanja naziva još i upravljanje s pomičnim obzorom (engl. *Receding Horizon Control*). U trenutnom koraku koriste se samo trenutne vrijednosti upravljačkih ulaza $u(k)$, dok je za sljedeći korak potrebno optimizaciju ponoviti. S obzirom da ne postoji savršeno predviđanje svih ulaza (neupravljivi ulazi v su najčešće podaci iz vremenske prognoze koja je rijetko kada potpuno pouzdana), rezultati upravljanja su suboptimalni. No ako N teži u beskonačnost ($N \rightarrow \infty$) i ako su predviđanja neupravljivih ulaza savršena, rezultati postaju globalno optimalni.

Formule (2-11) do (2-13) predstavljaju vrlo općeniti oblik MPC-a. Postoji još mnogo obilježja i mogućnosti koje je moguće uzeti u obzir kod upravljanja. Ovdje su nabrojane samo neke:

- U (2-11) do (2-13) definirana su tzv. tvrda ograničenja (engl. *Hard Constraints*) koja kažu da vrijednosti y i u moraju biti unutar nekog raspona. U praksi, ovo može dovesti do toga da je optimizacija nerješiva (engl. *Infeasible*). Tako da se često koriste meka ograničenja (engl. *Soft Constraints*), gdje se vrijednosti koje izlaze iz definiranog raspona dodatno kažnjavaju (engl. *Penalty*) tako da povećavaju ukupnu vrijednost težinske funkcije J .

- Ako je sustav nepromjenjiv (a najčešće jest, barem u nekom scenariju ili za neki broj koraka), ukupan izračun predviđanja ponašanja sustava, odnosno ukupnu optimizaciju nije potrebno raditi u svakom koraku od početka. S obzirom da se uvijek koriste ulazi koji su izračunati optimizacijom, usprkos nesavršenom predviđanju poremećaja, u sljedećem koraku neće doći do prevelike devijacije između predviđanja i stvarnog ponašanja sustava. Tako da se prethodno izračunati ulazi za korake $k+1$ i nadalje mogu iskoristiti za početne vrijednosti prilikom izračuna optimalnih upravljačkih akcija, što sigurno ubrzava izračune.
- Umjesto korištenja ulaza koji predstavljaju utrošenu energiju, moguće je koristiti i izravno cijenu energenata, čime se dobiva ekonomsko modelsko prediktivno upravljanje (engl. *Economic MPC*).
- S obzirom da su zgrade i HVAC sustavi vrlo složeni sustavi, često s nelinearnostima, promjenjivim parametrima i raznim drugim nesigurnostima, postoji mnogo varijanata modelskog prediktivnog upravljanja kojima je cilj unaprijediti upravljanje u raznim smjerovima. Dva takva su robusni i adaptivni MPC. Kod robusnog MPC-a pretpostavlja se da sustav sadrži nesigurnosti i da su moguće nepredviđene promjene neupravljivih ulaza, te se ove nesigurnosti uključuju izravno u model sustava, čime se povećava robusnost upravljanja. S druge strane, kod adaptivnog MPC-a pretpostavlja se da se sustav mijenja s vremenom te se omogućuju određene promjene parametara modela za vrijeme rada.

Vrlo detaljan pregled industrijske primjene modelskog prediktivnog upravljanja (koja povijesno i prethodi korištenju MPC-a u HVAC sustavima) daje knjiga "Modern Predictive Control" autora Bao-Cang iz 2009. [87]. Prikazuje razvoj i korištenje prediktivnih tehnologija u industriji, s fokusom na MPC i njegove ostale varijante: *Model Algorithmic Control* (MAC), *Dynamic Matrix Control* (DMC) i *Generalized Predictive Control* (GPC). Također obrađuje ostale povezane teme kao što su hibridni pristup (u knjizi se naziva sintezijski pristup; kombiniranje modelskog prediktivnog upravljanja s klasičnim optimalnim upravljanjem s ciljem povećane stabilnosti), optimizaciju, robusnost i sl. Kraći povijesni pregled i detaljan usporedni pregled suvremenih primjena modelskog prediktivnog upravljanja može se vidjeti u radu Qina i Badgwell [88].

U radu iz 2011. Chinnakani et al. [89] se bave usporedbom klasičnog upravljanja s prediktivnim metodama upravljanja. Na primjeru jednostavnog HVAC sustava (grijanje zrakom; grijač, vodovi,

rekuperator, zone) uspoređuju tri metode upravljanja: dvopoložajni regulator, inteligentni dvopoložajni regulator i optimalni regulator. Regulacija dvopoložajnim regulatorom je klasični termostatski s histerezom, dok inteligentni dvopoložajni regulator uvažava tromost sustava, odnosno toplinski kapacitet zgrade, uvodeći dodatni faktor "vrijeme tromosti" (s pretpostavkom da je sustav linearan). Optimalni regulator poznaje toplinski model zgrade i u svakom koraku računa ponašanje sustava u budućnosti te minimalizira energiju potrebnu za grijanje zgrade dok ujedno uvažava ograničenja vezana za ugodu stanara (temperatura i vlažnost zraka). Za rješavanje ovog problema koristi se *Linear Quadratic Regulator* (LQR) i Riccattijeva jednačica (engl. *Riccatti Equation*).

Zanimljivo pitanje postavljaju autori Ferkl et al. u radu [90] iz 2011.: kada je isplativo investirati u MPC upravljanje HVAC sustavom? Odgovor na ovo pitanje traže u usporedbi teoretski dobivene minimalne godišnje potrošnje energije za grijanje (koju temelje na rezultatima energetskog certificiranja zgrada i standardu EN 12831) sa stvarno ostvarenom godišnjom potrošnjom. Ako postoji značajna razlika, odnosno gubitak zbog neučinkovitosti upravljanja (autori predlažu minimalno 15%), može se ići u detaljniju izradu toplinskog modela i simulacije s MPC upravljanjem. Ako simulacije odgovaraju teoretskoj minimalnoj potrošnji, odnosno ako MPC može dostići teoretski najbolju energetsku učinkovitost, ima smisla ulagati u novo upravljanje (gledajući s tehničke strane).

Lee i Braun u radu [50] iz 2007. opisuju korištenje predviđanja za smanjivanje vršnih vrijednosti (engl. *Peaks*) u potrošnji energije kod hlađenja, dok je uobičajeni cilj prediktivnih metoda smanjenje ukupne potrošnje energije. Razvijaju hibridni model temeljen na kombinaciji metode koncentriranih parametara i procjeni parametara sustava iz mjernih podataka (iako ne objašnjavaju metodu nego se pozivaju na rad drugih autora). Uspoređuju tri pristupa upravljanja hlađenjem (gdje druga dva koriste toplinski kapacitet zgrade): klasični dnevno-noćni režim kod kojeg se temperatura održava unutar zadanih okvira tokom dana, a noću se ne regulira; pothlađivanje tokom noći i hlađenje tokom dana kada temperatura počne izlaziti iz okvira; te pothlađivanje tokom noći i preventivno minimalno hlađenje tokom dana.

Pregled radova koji se bave modelskim prediktivnim upravljanjem u HVAC sustavima može se naći u radu [91] autora Kwadzogah, Zhou i Li iz 2013. Autori prvo opisuju HVAC sustave sa strane upravljanja te kako ih modelirati (navode kako se često koriste nadomjesne RC mreže, odnosno metoda koncentriranih parametara). Zatim opisuju načela rada MPC regulatora (korištenje modela za predviđanje ponašanja korisnika prostora i korištenje rješenja za trenutni korak pri izračunu rješenja slijedećeg koraka) te težinsku funkciju koja se koristi za optimizaciju

rezultata (kombinacija potrošnje energije i ugone stanara). U radu opisuju 10 prijašnjih radova drugih autora, gdje ih uspoređuju po tipu/pristupu, korištenoj težinskoj funkciji, korištenoj metodi za optimizaciju, je li rješenje optimalno, jesu li autori koristili simulaciju ili stvarnu zgradu te posebnim karakteristikama.

U radovima Ma, Kelmann, Daly i Borelli [20] iz 2012. može se vidjeti vrlo iscrpan pregled modelskog prediktivnog upravljanja. Autori rad započinju s uvodom u načela ovakvog upravljanja i usporedo s time objašnjavaju izradu toplinskog modela temeljenu na fizikalnom pristupu. Nakon uvoda, pristupa se objašnjavanju MPC-a na stvarnom primjeru upravljanja HVAC sustavom jednog američkog sveučilišta. Upravljanju pristupaju hijerarhijski, na dvije razine: visoka razina, koja se sastoji od modeliranja izvora topline i hladnoće, te sustava za distribuciju, kao što su električni hladnjaci, tornjevi za hlađenje, pumpe za distribuciju; niska razina, koja se odnosi na dinamiku unutar zgrade, te elemente kao što su ventilatori te izmjenjivači za grijanje i hlađenje. Prvo razvijaju detaljan toplinski model za elemente visoke i niske razine. Zatim razvijaju upravljanje za obje razine: HMPC (nadređeni, engl. *High-level*) koji uzima u obzir vanjske parametre kao što su ukupni toplinski teret zgrade, vremenska prognoza i cijena energije; LMPC (podređeni, engl. *Low-level*) koji ovisi o stanarima, vremenskoj prognozi, zadanim vrijednostima i Sunčevom zračenju.

Modelske prediktivne upravljanje bave se Kelman i Borrelli u radu iz 2011. [92]. Koriste fizikalni pristup izradi toplinskog modela zgrade i uvode određene pretpostavke da bi pojednostavili model: temperatura se ponaša kao funkcija prvog reda (svaka zona je jedan koncentrirani element – kapacitet); vlažnost zraka se ne modelira eksplicitno; sva ostala dinamika se zanemaruje (trenutni odziv izvršnih elemenata); unaprijed je poznato ponašanje vanjske temperature i toplinskih tereta u zonama (savršeno predviđanje vremenske prognoze i ponašanja ukućana). Ovako dobivaju prilično jednostavan toplinski model koji obuhvaća zone (prostorije) i izvor grijanja/hlađenja (AHU, engl. *Air Handling Unit*). Model sustava se prikazuje u bilinearnom obliku i na njemu primjenjuju SQP (engl. *Sequential Quadratic Programming*) pristup za optimizaciju. Rezultati pokazuju da je moguće ostvariti MPC upravljanje zgradom u stvarnom vremenu (1 minuta).

Primjer MPC upravljanja na HVAC sustavu stvarne zgrade može se vidjeti u [34] i [35], gdje autori koriste toplinski model dobiven statističkim numeričkim metodama.

Autori Radecki i Hancey u radu [54] iz 2013. koriste toplinski model dobiven hibridnom metodom u sprezi s MPC upravljanjem. Toplinski model temeljen je na metodi koncentriranih

parametara prvog reda i estimaciji parametara iz mjerenja pomoću nezačinjenog Kalmanovog filtera (engl. *Unscented Kalman Filter*), što je opisano u prethodnom radu [53]. Za upravljanje je korišten klasični MPC regulator, s naglaskom na korištenju mekih ograničenja koja daju fleksibilnije upravljanje. Također, prema izvršnim elementima ugrađena je histereza od 15 minuta da bi se spriječilo treperenje izlaza (engl. *Jitter*). Još jedna zanimljivost njihovog pristupa je što predlažu opremanje zgrade sustavom za upravljanje energije (EMS, engl. *Energy Management System*). Čest problem kod MPC upravljanja i općenito kod toplinskih modela je što su stvarni sustavi najčešće vremenski promjenjivi i najčešće ne obuhvaćaju sve moguće scenarije. Zato predlažu da EM sustav koristi samo-uzbudu (engl. *Self-Excitation*) i stalnu estimaciju parametara (engl. *Online Estimation*), na način koji ne ometa stanare, za trajno poboljšavanje toplinskog modela zgrade.

Autori Vašak, Starčić i Martinčević u radu [93] iz 2011. opisuju korištenje modelskog prediktivnog upravljanja na primjeru obiteljske kuće. Toplinski model je temeljen na metodi koncentriranih parametara drugog reda (3R2C) i uspoređen s modelom dobivenim u programskom paketu Trnsys. Autori zatim objašnjavaju načela rada MPC upravljanja i implementiraju ga. Dio istih autora u sličnom radu [94] prikazuje modeliranje HVAC sustava temeljenog na zraku i njegovu primjenu u MPC regulatoru. U ovom radu se koncentriraju na kvalitetu unutarnjeg zraka, te ASHRAE standard koji definira uvjete za ugodu stanara vezano u zrak. MPC regulator je implementiran linearnim programiranjem.

U radu [95] iz 2012. godine autori Benghea et al. bave se utjecajem parametara modela na kvalitetu upravljanja. Autori se prvo osvrću na činjenicu da ni jedan model ne može biti točan, tako da su parametri modela uvijek u određenoj mjeri procijenjeni (ili iz nazivnih vrijednosti svojstava ili na temelju mjernih podataka). Opisuju model zgrade temeljen na metodi koncentriranih parametara za model zone i na jednadžbama toka mase za utjecaj HVAC sustava (distribucija toplog zraka). Zatim opisuju načela rada modelskog prediktivnog upravljanja, s fokusom na težinske funkcije. Zatim u težinske funkcije uvode nesigurnost koja proizlazi iz činjenice da su parametri modela procijenjeni. Korištenjem Monte-Carlo simulacija i metode najmanjih kvadrata dolaze do zaključka da su najutjecajniji parametri toplinskog modela zgrada na MPC regulator toplinski otpor poda i stropa.

Autori Sturzenegger et al. u radu [96] iz 2016. opisuju dugotrajan (ukupno 18 mjeseci) eksperiment upravljanja HVAC sustavom u uredskoj zgradi u Švicarskoj. Za modeliranje sustava koristili su RC metodu, koristeći vlastiti alat za MATLAB nazvan BRCM Toolbox (engl. *Building*

Resistance-Capacitance Modeling). Upravljanje je temeljeno na MPC-u te je podijeljeno na višu razinu (engl. *High Level*; MPC) i nižu razinu (engl. *Low Level*; lokalni regulatori). U upravljanju su također upotrijebljena dva Kalmanova filtra koja služe za predviđanje ponašanja sustava (zgrade) i vremenskih uvjeta (prognoze). Detaljno su opisana tri eksperimenta u različitim uvjetima (14 tjedana hlađenja; 6 tjedana grijanja; i 9 tjedana grijanja) te zaključci koje su donijeli. Na temelju provedenog istraživanja došli su do zaključka da još nije isplativo uložiti u MPC, ali s padom cijena opreme i porastom cijena energenata, očekuju da će to postati isplativo.

Rad [97] autora Killian i Kozek iz 2016. je pregledni rad područja modelskog prediktivnog upravljanja u HVAC sustavima, no strukturiran na zanimljiv način. Autori postavljaju 10 pitanja koja se odnose na MPC i daju odgovore potkrijepljene radovima. Pitanja koja se obrađena su:

1. Ima li MPC stvarno toliku prednost nad tradicionalnim metodama upravljanja?
2. Što je cijena uvođenja MPC-a, odnosno jesu li prednosti koje MPC donosi isplative?
3. Postoji li najbolje rješenje za izradu odgovarajućeg dinamičkog modela zgrade za korištenje u MPC-u?
4. Kako pomiriti suprotstavljene ciljeve upravljanja (ugoda stanara i minimalizacija potrošnje energije)?
5. Koji su glavni izazovi MPC primjena?
6. Jesu li potrebni mjerni signali dostupni u suvremenim zgradama?
7. Zašto je MPC dobar za kombinaciju s alternativnim izvorima energije?
8. Može li se MPC iskoristiti za sustave gospodarenja energijom u zgradi (engl. *Building Energy Management System*)?
9. Koje strategije upravljanja zgrada se mogu iskoristiti za pametne mreže (engl. *Smart Grids*)?
10. Kolika je trenutna i buduća prisutnost MPC-a na tržištu?

2.3.4. Ostale varijante modelskog prediktivnog upravljanja

Chandan i Alleyne u radu iz 2011 [98] bave se usporedbom centraliziranih i distribuiranih regulatora, s primjenom na MPC-u. Centralizirani regulator postiže rezultate bliže optimalnima, ali je osjetljiv na smetnje u ulazim podacima i komunikaciji. Distribuirani sustavi upravljanja su puno robusniji, ali daju lošije rezultate. Iako je ovo poznata kombinacija prednosti i nedostataka, autori prvi puta predstavljaju heurističku metodu za odabir stupnja distribuiranosti. Zgrada s više zona se dijeli u skupove (engl. *Clusters*), od potpuno centraliziranog sustava sa svim zonama u jednom skupu, do potpuno distribuiranog sustava sa svakom zonom u svom skupu, koristeći

metode kombinatorike. Svaka kombinacija se ocjenjuje prema dva faktora: optimalnost (CLF, engl. *Coupling Loss Factor*) vezanu uz broj skupova (idealna situacija, potpuno centralizirani sustav ima CLF nula) i robusnost (MCS, engl. *Mean Cluster Size*) vezanu uz broj elemenata u skupovima (idealna situacija, potpuno distribuiran sustav ima MCS skoro nula). Cilj metode je naći kombinaciju koja daje najbolje vrijednosti CLF i MCS (koljeno na grafu CLF/MCS).

Kret et al. [99] u radu iz 2011. se bave varijantom MPC-a zvanom *Generalized Predictive Control*. Opisuje se fizikalno modeliranje prostorije, zidova, radijatora te ventila i bojlera. Model se formulira različito ovisno da li se promatra kao linearni vremenski promjenjivi sustav (LTV, engl. *Linear Time Variant*), bilinearni vremenski promjenjivi sustav (BTV, engl. *Bilinear Time Variant*) ili kao bilinearni vremenski nepromjenjivi sustav (BTI, engl. *Bilinear Time Invariant*). Dobiveni modeli se koriste u simulaciji, gdje se uspoređuju četiri varijante GPC-a: standardni inkrementalni GPC, ne-inkrementalni GPC (engl. *Non-Incremental GPC*), modificirani inkrementalni GPC (MGPC) te modificirani ne-inkrementalni GPC (MNIGPC). Rezultati se uspoređuju prema dva kriterija: MSE (engl. *Minimum Square Error*) koji prikazuje razliku između zadanog i ostvarenog, te MSC (engl. *Minimum Square Control effort*) koji je vezan uz količinu potrošene energije.

Još jedna varijanta MPC upravljanja je opisana u radu Liao i Dexter [100]. Autori prvo rade hibridni model zone i sustava grijanja koji se temelji na prošlim vrijednostima temperatura u prostoriji i okoliša te Sunčevog zračenja, dok vrijednosti parametara modela izračunavaju iz mjernih podataka koristeći metodu najmanjih kvadrata (s obzirom da imaju relativno mali broj parametara, ovo je prihvatljivo). Svoju metodu upravljanja nazivaju IMPCS (engl. *Inferential Model Predictive Control Scheme* – zaključivajuća modelsko prediktivna upravljačka shema), a sastoji se od tri hijerarhijske razine: vanjska regulacijska petlja – najviša razina, matematički model s predviđanjem budućeg ponašanja sustava; posredna regulacijska petlja – klasični PID regulator čiji se parametri određuju iz predviđanja zadanih vrijednosti i ponašanja sustava; unutarnja regulacijska petlja – klasični dvopoložajni regulator s histerezom koji uključuje i isključuje boiler.

U radu [101] autora Ma et al. iz 2011. opisana je primjena distribuiranih MPC regulatora za grijanje i hlađenje zgrade. HVAC sustav sastoji se od jedne AHU jedinice za pripremu toplog i hladnog zraka, te nekoliko VAV jedinica koje reguliraju protok toplog ili hladnog zraka u zonu. Svaki od distribuiranih regulatora (DMPC, engl. *Distributed Model Predictive Controller*) vezan je uz jednu VAV jedinicu, odnosno uz jednu zonu. Toplinski model dobiven je korištenjem metode

koncentriranih parametara (ali bez uobičajenog 3R2C pristupa), a parametri modela dobiveni su iz podataka pomoću algoritma temeljenog na nelinearnoj regresiji. Za rješavanje problema minimalizacije kod MPC-a korišteni su SQP pristup i dualna dekompozicija.

Još jedan rad koji se bavi distribuiranim modelskim prediktivnim upravljanjem je rad [102] iz 2010. autora Morosan et. al. Autori prvo objašnjavaju načela rada MPC-a, a zatim predlažu poboljšanje koje se tiče rada u vremenu kada nema stanara u grijanim/hlađenim prostorijama. Uobičajeni pristup jest da se tada smanji zadana vrijednost (engl. *Setpoint*) – no autori predlažu da se u takvim situacijama uopće ne regulira temperatura, osim u pogledu globalne optimizacije temperature (odnosno, toliko da temperatura stigne doseći zadanu u periodu kada u prostoji ima stanara). U sljedećem dijelu rada bave se razlikama između centraliziranih i decentraliziranih sustava. Centralizirani MPC daje najbolje rezultate, ali je računalno i modelski zahtjevan te osjetljiv na kvarove; decentralizirani MPC je jednostavan za ostvariti, ali ne daje najbolje rezultate. Autori predlažu distribuirani MPC u kojem svaka zona ima svoj neovisni regulator, ali su regulatori međusobno povezani i razmjenjuju podatke o predviđenim budućim stanjima sustava. Ako se u obzir uzima i utjecaj između prostorija, dobivaju se vrlo dobri rezultati, a smanjuju se problemi s robusnošću i složenosti upravljanja.

Autori Oldewurtel et al. u radu [103] iz 2010. se bave stohastičkim modelskim prediktivnim upravljanjem. Osim klasičnih elemenata toplinskog modela kao što su zidovi, grijači i sl., njihov model obuhvaća i dodatne elemente kao što su zastori, rasvjeta, toplinski aktivni elementi zgrade (TAB, engl. *Thermally Active Building* – spremnici topline u jezgri betona), te dodatne parametre poput razine CO₂ i osvijetljenosti prostorija. Za modeliranje koriste fizikalni pristup. Stohastički pristup je obuhvaćen tako što predviđanje vremenske prognoze sadrži i nesigurnost, koja je opisana Gaussovom distribucijom. Uspoređuju tri pristupa upravljanju: RB (engl. *Rule Based* – temeljen na pravilima oblika ako-onda), MPC (modelsko prediktivno upravljanje, podijeljeno u varijante bez i s nesigurnosti), PB (engl. *Performance Bound* – optimalno upravljanje moguće jedino u teoriji). PB upravljanje je ostvareno MPC regulatorom s vrlo dugačkim obzorom predviđanja od šest dana i savršenim predviđanjem vremenske prognoze.

MPC upravljanje u sprezi s linearizacijom povratne veze prikazano je u radu [21], iako je glavna tema rada fizikalni pristup izradi toplinskog modela HVAC sustava. Također, u radu [39] autori se bave izradom toplinskog modela koji je korišten u inačici MPC-a s učenjem (engl. *Learning Based*), koja može obuhvatiti obrasce u ponašanju stanara.

Autori Mendoza-Serrano i Chmielewski u radu [104] opisuju unaprjeđenje varijante modelskog prediktivnog upravljanja koje se zove ekonomski MPC (engl. *Economic Model Predictive Control*). Glavno obilježje EMPC je da uključuje cijenu energenata (koja može biti varijabilna) izravno u težinsku funkciju koja se koristi za minimalizaciju te je fokus na manjem trošku resursa, a ne na praćenju zadanih vrijednosti (engl. *Tracking*). Opisuju varijantu s "beskonačnim obzorom" (engl. *Infinite Horizon*), s kojom su smanjili računalne zahtjeve za 99%, a žrtvovali samo 3-4% kvalitete rezultata, u odnosu na klasičnu varijantu.

Rad [105] iz 2014. autora Negenborn i Maestre daje pregled radova koje se bave distribuiranim MPC-om (DMPC, engl. *Distributed*). Razlikuju centralizirani (jedan MPC regulator za cijeli sustav), hijerarhijski (MPC regulator na višoj razini za koordinaciju i nekoliko lokalnih MPC regulatora koji su zaduženi za dijelove sustava i mogu međusobno komunicirati), distribuirani (nekoliko lokalnih MPC regulatora koji su zaduženi za dijelove sustava i mogu međusobno komunicirati) i decentralizirani (nekoliko lokalnih MPC regulatora koji su zaduženi za dijelove sustava i ne mogu međusobno komunicirati). Prednost DMPC je robusnost (jer rade neovisno jedan o drugome) i dobre performanse (jer se svaki regulator brine samo za dio sustava), a opet dobri rezultati upravljanja (jer regulatori međusobno izmjenjuju informacije o sustavu). Pojam distribuiranog MPC-a je odavno poznat i dobro istražen, a autori se koncentriraju na primjenu DMPC-a u HVAC sustavima. Nabrojana su 34 suvremena rada (2014. godina) i uspoređena prema procesima (tip sustava, tip procesa, tip modela, slučajnosti, tip upravljanja, ovisnost) i arhitekturi (arhitektura, informacije dostupne regulatoru, tip računanja, kooperativnost upravljanja, komunikacija, raspoređivanje, optimizacijske varijable). Na kraju se daje pregled tema koje su u fokusu i što se može očekivati od ovakvih istraživanja u budućnosti.

2.4. Sažetak pregleda i prijedlog unaprjeđenja postojećih metoda

Iz dostupnog pregleda može se donijeti nekoliko zaključaka koje se tiču modeliranja toplinskih procesa u zgradama i HVAC sustavima te njihova upravljanja:

- zgrade (i HVAC sustavi) su vrlo složeni sustavi, čija složenost brzo raste s brojem prostorija (osobito kod većih komercijalnih zgrada)
- korištenje otporničko-kapacitivne analogije pri izradi toplinskih modela zgrada je raširena metoda poznata većem dijelu autora, iako se malo autora bavi detaljima njene primjene

- modelsko prediktivno upravljanje je usvojeno kao obećavajući pristup za upravljanje HVAC sustavima u zgradama, no potrebno je još riješiti dosta nedostataka kod praktičnih aplikacija.

Istraživanje koje je predstavljeno u nastavku rada pokušava riješiti problem kod izrade termodinamičkih modela zgrada koji nastaje zbog složenosti zgrada, kada složenost sustava otežava izradu modela zbog postojanja velikog broja varijabli i parametara te gdje postoji velika mogućnost grešaka pri izradi modela. Problem složenosti pokušava se riješiti razvojem algoritma koji omogućuje automatsku izradu strukture toplinskog modela zgrade korištenjem fizikalnog pristupa. U drugom koraku potrebno je ispravno odrediti parametre modela, za što je odabran podatkovni pristup i optimizacija (odnosno prepodešavanje) početnih parametara (određenih iz nazivnih vrijednosti svojstava materijala i opreme teorijskom analizom). Prepodešavanje se temelji na korištenju mjernih podataka sa zgrade, čime se povezuje fizikalni pristup i otporničko-kapacitivna analogija sa modeliranjem na temelju podataka te RC metoda postaje hibridna, odnosno daje model sive kutije. Cijeli postupak pokušava se prilagoditi krajnjem cilju, a to je da je dobiveni toplinski model zgrade i HVAC sustava prilagođen za korištenje u modelskom prediktivnom upravljanju.

3. IZRADA STRUKTURE TERMODINAMIČKOG MODELA ZGRADE

Kao što je već rečeno u prvom poglavlju, HVAC sustavi u zgradama troše oko 20% ukupne energije u svijetu, što je jedan od glavnih razloga velikog truda koji se ulaže u istraživanje i razvoj HVAC sustava. Postoji nekoliko načina kako se može poboljšati energetska učinkovitost HVAC sustava, kao što su vođenje računa o učinkovitosti pri projektiranju (bolje projektiranje), korištenje materijala s boljim toplinskim koeficijentom (bolja izolacija), upotreba učinkovitijih elemenata HVAC sustava (bolji uređaji). Svi navedeni prijedlozi su ili teško izvedivi (npr. teško je izmijeniti raspored prostorija u već postojećoj zgradi) ili skupi (npr. dodavanje dodatne izolacije). Jedan relativno jednostavan i jeftin način kako poboljšati energetska učinkovitost HVAC sustava, a time i same zgrade, je unaprjeđenje upravljanja HVAC sustavom, osobito kod zgrada (npr. veće poslovne zgrade) koje već imaju ugrađene elemente naprednog nadzora i upravljanja (engl. *Building Management System* ili BAS – *Building Automation System*; sustav nadzora i upravljanja zgradom).

Ako se pogleda tipičnu obiteljsku kuću ili stan, može se primijetiti su dijelovi HVAC sustava najčešće međusobno neovisni i upravljani na najjednostavniji mogući način. Tako je npr. grijanje prostora upravljano pomoću klasičnih termostata s histerezom (i to najčešće samo jednim za cijelu kuću); hlađenje je riješeno diskretnim klimatizacijskim jedinicama; zastori (ako postoje), prozori i rasvjeta su ostavljeni korisniku potpuno na volju. Dakle, postoji samo osnovna (podređena) razina upravljanja, ali nema nadređene razine koja objedinjuje i optimizira upravljanje.

Čak i kod većih komercijalnih zgrada kod kojih se vodilo računa o energetska učinkovitosti i koje imaju ugrađeni BMS, najčešće se HVAC sustav centralizira u smislu izvora (središnje jedinice za grijanje i hlađenje), dok se upravljanje postavljeno po prostorijama (zonama) opet ostavlja korisniku ili se odredi jedna vrijednost za veći broj zona. Eventualna unaprjeđenja upravljanja se odnose na prebacivanje tereta u vrijeme jeftinije cijene energenata (engl. *Load-Shifting*) ili ograničavanje prema nekim ekspertnim pravilima (engl. RBC – *Rule Based Control*).

Pravi napredni upravljački sustav mora imati u vidu cijelu zgradu i HVAC sustav te tražiti optimalno (ili što je bliže moguće) rješenje – zadovoljavanje potreba korisnika u smislu toplinske ugone, rasvjete, kvalitete zraka, itd., uz minimalni utrošak energije. Jedan od pristupa koji ovo mogu riješiti je i modelsko prediktivno upravljanje, o čemu je s teorijske strane bilo govora u drugom poglavlju.

Da bi se MPC mogao ispravno implementirati i dati što bolja rješenja, potreban je model koji omogućava što veću točnost predviđanja ponašanja sustava, odnosno zgrade, jer svako upravljanje temeljeno na modelu procesa jer kvalitetno onoliko koliko je kvalitetan model procesa koji je u njega implementiran. S druge strane, poželjno je da je taj model što jednostavniji jer se kod MPC pristupa koristi predviđanje ponašanja sustava u svakom koraku, što može zahtijevati velike resurse. Jedna poznata metoda kojom je moguće zadovoljiti ova dva zahtjeva je otporničko-kapacitivna analogija za izradu toplinskih modela zgrada.

3.1. Otporničko-kapacitivna analogija za izradu toplinskog modela zgrade

Otporničko-kapacitivna analogija ili RC metoda za izradu toplinskog modela kao primjer fizikalnog ili hibridnog pristupa modeliranju već je spomenuta u drugom poglavlju. Ovdje je ona detaljno opisana te je dan naglasak na objašnjenju načela rada aplikacije za izradu toplinskih modela zgrada ModelBuilder koja je korištena u istraživanju.

Pri razvoju ovih modela, kao i u većini sličnih pristupa, nemoguće je uzeti u obzir sve čimbenike koji utječu na toplinske procese i ugodu stanara, nego je neke potrebno zanemariti. Tako su uvedene neke pretpostavke, odnosno pojednostavljenja modela:

- zanemaruje se vertikalna razlika temperatura okoliša i zona
- pretpostavlja se jednolika prozračenost zona
- pretpostavlja se kratkoročna nepromjenjivost parametara (fizikalnih svojstava), odnosno da je sustav vremenski nepromjenjiv (engl. *Time Invariant*)
- zanemaruje se utjecaj vlažnosti zraka.


Najkraće rečeno, otporničko-kapacitivna analogija se temelji na zamjeni toplinskih svojstava i procesa nadomjesnim električkim veličinama:

- toplinski otpor se zamjenjuje otporom
- toplinski kapacitet se zamjenjuje kapacitetom
- temperatura se zamjenjuje naponom (potencijalom)
- tok topline se zamjenjuje strujom.

Pomoću ovih nadomjesnih elemenata moguće je predstaviti sve toplinske procese i svojstva u zgradi i djelovanje HVAC sustava na zgradu.

3.1.1. Osnovni elementi RC metode

Na slici 3.1. prikazan je jedan zid u kontekstu toplinskih procesa te njegova reprezentacija pomoću RC metode, i to varijantom 3R2C. Ova varijanta znači da je zid predstavljen pomoću tri otpora i dva kapaciteta i predstavlja najčešću varijantu, obuhvaćajući dovoljnu točnost i zadovoljavajuću složenost. Moguće je koristiti i jednostavniju varijantu (2R1C) te složenije varijante (4R3C, 5R4C, itd.).



Slika 3.1. Nadomjesni model zida u 3R2C varijanti (s tri otpora i dva kapaciteta)

Ova reprezentacija, odnosno model zida, obuhvaća nekoliko toplinskih procesa i svojstva:

- Prijelaz topline i zračenje topline između vanjskog okoliša (T_{van}) i vanjske površine zida (T_{p_van}). Otpor R_{van} kombinira nadomjesni otpor prijelaza ($R_{van_strujanje}$) i nadomjesni otpor zračenja ($R_{van_zracenje}$) u paralelnom spoju ($\frac{1}{R_{van}} = \frac{1}{R_{van_strujanje}} + \frac{1}{R_{van_zracenje}}$).
- Vođenje topline kroz dva sloja zida i između vanjskih površina: između vanjske površine zida (T_{p_van}) i vanjskog sloja zida (T_{z_van}); između vanjskog sloja zida (T_{z_van}) i unutarnjeg sloja zida (T_{z_un}); između unutarnjeg sloja zida (T_{z_un}) i unutarnje površine zida (T_{p_un}).

- Slojevi zidova imaju svoj toplinski kapacitet predstavljen zamjenskim kapacitetima C_{z_van} i C_{z_un} . Što je veći broj slojeva, odnosno kapaciteta, to je model točniji.
- Prijelaz topline i zračenje topline između unutarnjeg okoliša, odnosno zone (T_{un}) i unutarnje površine zida (T_{p_un}). Otpor R_{un} kombinira nadomjesni otpor prijelaza i nadomjesni otpor zračenja u paralelnom spoju.
- Sunčevo zračenje na vanjsku površinu zida (izravni tok topline) predstavljeno je strujnim ulazom H_{rad_van} .


Kod implementacije modela, zbog jednostavnosti, najčešće se nadomjesni otpori prijelaza i zračenja između okoliša i površine zida kombiniraju s nadomjesnim otporom prijelaza između površine zida i sloja zida (serijski spoj) te se zanemaruje temperatura površine zida. Ovime se smanjuje složenost modela, a ne gubi se značajno na točnosti.

Također, moguće je predstaviti i zračenje unutarnjih objekata u zgradi (raznih elektroničkih uređaja, grijaćih izvršnih elemenata, drugih zidova i elemenata zgrade), no najčešće se ovo zračenje zanemaruje ili obuhvaća izravnim tokom topline u zonu.


Vezano uz zračenje, u stvarnosti se dio zračenja reflektira nazad u okoliš (vanjski ili unutarnji). No kod modeliranja se ova refleksija zanemaruje, odnosno modelira se samo "korisni" dio zračenja koji djeluje na zid.

Na slici 3.2. prikazan je analogni model za prozor, u varijanti 3R. Na prozor djeluju isti procesi i svojstva kao i kod zida. Najvažnija razlika između modela prozora i zida je da se kod prozora zanemaruje toplinski kapacitet stakla i izolacije, koji je vrlo mali. Također, kod modeliranja moguće je pretpostaviti da Sunčevo zračenje djeluje izravno na zonu.

Na slici 3.3. prikazan je nadomjesni model zone. Model zone prikazan je samo pomoću temperature u zoni te jednog kapaciteta C_{un} koji predstavlja toplinski kapacitet zraka (i objekata) u zoni. Tok topline H_{un} prvenstveno predstavlja zajedničko djelovanje HVAC sustava na zonu (ako postoji u toj zoni), no može obuhvatiti i Sunčevo zračenje izravno kroz prozor (ako postoji prozor prema vanjskom okolišu) te ostale toplinske utjecaje na zrak u zoni (ovisno o detaljnosti modela).



Slika 3.2. Nadomjesni model prozora u 3R varijanti (s tri otpora)




Slika 3.3. Nadomjesni model zone

Djelovanje HVAC sustava moguće je predstaviti i na složenije načine, na primjer da se izvor topline predstavi temperaturom, a sustav distribucije topline (zračni, vodeni) po zgradi predstavi kombinacijom otpora i kapaciteta. Složenost prikaza ovisi o potrebama i fokusu autora modela. Zbog ove fleksibilnost i prilagodljivosti RC metoda je vrlo popularna i korisna kod izrade toplinskih modela zgrada.

3.1.2. Izrada toplinskog modela

Na slikama 3.4. do 3.8. prikazana je izrada toplinskog modela jednostavne zgrade s dvije sobe po koracima, odnosno povezivanje osnovnih elemenata. Zbog jednostavnosti, pretpostavljen je dvodimenzionalni model, odnosno da su pod i strop savršeni izolatori.




Slika 3.4. Zgrada (plavo su zidovi, zeleno vrata i prozori)


Na slici 3.4., prvoj u nizu, prikazana je jednostavna zgrada koja se sastoji od dvije prostorije, odnosno šest vanjskih zidova i jednog unutarnjeg između dvije zone, jednih vanjskih vrata, jednih unutarnjih vrata te dva prozora. HVAC sustav je predstavljen jednim radijatorom u istočnoj prostoriji.

Na sljedećoj slici 3.5. prikazani su stanja sustava prezentirana temperaturama u zonama T_{s1} i T_{s2} (sivo) te neupravljivi ulaz prezentiran temperaturom okoliša T_v (sivo). Također, prikazani su toplinski kapaciteti zona, prezentirani kapacitetima C_{s1} i C_{s2} (crveno).


U slijedećem koraku na slici 3.6. prikazano je reprezentiranje toplinskih procesa između okoliša i unutrašnjosti kroz zidove (plavo), u 3R2C reprezentaciji. Ovdje su objedinjeni prijelaz, vođenje i zračenje topline između vanjskog okoliša i unutrašnjosti. Na primjer, za zapadni zid, to su: otpori R_{zlv} , R_{zl} , R_{zls1} te kapaciteti C_{zlv} i C_{zls1} ; i slično tome za ostale zidove. Ovdje, kao i kod ostalih elemenata, zanemarene su temperature vanjskih i unutrašnjih površina zidova.




Slika 3.5. Određivanje stanja (crveno su temperature zona, a sivo okoliša)



Slika 3.6. Dodavanje 3R2C nadomjesnih elemenata za zidove (plavo)



Slika 3.7. Dodavanje 3R nadomjesnih elemenata za prozore i vrata (zeleno)



Slika 3.8. Dodavanje utjecaja Sunčevog zračenja (ljubičasto) i HVAC sustava (narančasto)

Sljedeća slika 3.7. dodaje još iste procese kroz prozore i vrata, s razlikom da kod ovih elemenata nema toplinskog kapaciteta. Na primjer, za vrata na istočnom zidu: otpori R_{v1v} , R_{v1l} , R_{v1s1} , i slično tome za ostale zidove i prozore.

Zadnja slika u nizu, slika 3.8. prikazuje još utjecaj Sunčevog zračenja na zidove (H_{Sz1} , H_{Sz2} , H_{Sz3} , H_{Sz4} , H_{Sz5} i H_{Sz6}), kroz prozore (H_{Sp1} i H_{Sp2}) te utjecaj HVAC sustava, odnosno radijatora (H_{us2}). Zbog jednostavnosti, u ovom primjeru zanemareno je zračenje između unutrašnjih elemenata zgrade, s obzirom na njihov broj i jer bi se time uvela nelinearnost u model.

Koristeći metode za rješavanje električkih mreža, mogu se postaviti jednačbe za sve nabrojane elemente zgrade. Na primjer, za istočni zid, stanja za vanjsku i unutarnju (prema zoni 1) stranu zida dane su jednačbama:

$$C_{z1v} \frac{dT_{z1v}}{dt} = H_{Sz1} + \frac{T_v - T_{z1v}}{R_{z1v}} - \frac{T_{z1v} - T_{z1s1}}{R_{z1}}, \quad (3-1)$$

$$C_{z1s1} \frac{dT_{z1s1}}{dt} = \frac{T_{z1v} - T_{z1s1}}{R_{z1}} - \frac{T_{z1s1} - T_{s1}}{R_{z1s1}}. \quad (3-2)$$

Također, primjer za zonu 1 (istočna soba) opisan je kao:

$$\begin{aligned} C_{s1} \frac{dT_{s1}}{dt} = & H_{Sp1} + \frac{T_{z1s1} - T_{s1}}{R_{z1s1}} + \frac{T_{z2s1} - T_{s1}}{R_{z2s1}} + \frac{T_{z6s1} - T_{s1}}{R_{z6s1}} \\ & + \frac{T_{z12s1} - T_{s1}}{R_{z12s1}} + \frac{T_v - T_{s1}}{R_{v1v} + R_{v1} + R_{v1s1}} \\ & + \frac{T_v - T_{s1}}{R_{p1v} + R_{p1} + R_{p1s1}} + \frac{T_{s2} - T_{s1}}{R_{v2s1} + R_{v2} + R_{v2s2}}. \end{aligned} \quad (3-3)$$

Na sličan način mogu se postaviti jednačbe za ostale elemente zgrade.

Jedna od najčešćih reprezentacija ovih jednačbi je u obliku prostora stanja (matrice sustava), gdje je sustav kontinuiran i vremenski nepromjenjiv:

$$\dot{\mathbf{x}}(t) = \mathbf{A}\mathbf{x}(t) + \mathbf{B}\mathbf{u}(t), \quad (3-4)$$

$$\mathbf{y}(t) = \mathbf{C}\mathbf{x}(t) + \mathbf{D}\mathbf{u}(t), \quad (3-5)$$

gdje su $\mathbf{x}$ vektor stanja, $\mathbf{y}$ vektor izlaza, $\mathbf{u}$ vektor ulaza, te $\mathbf{A}$ matrica stanja, $\mathbf{B}$ ulazna matrica, $\mathbf{C}$ izlazna matrica i $\mathbf{D}$ prolazna matrica. Također, ponekad se ulazi $\mathbf{u}$ razdvajaju na upravljačke ulaze $\mathbf{u}$ (npr. djelovanje HVAC sustava kao što su radijatori) i neupravljive ulaze $\mathbf{v}$ (kao što su temperatura okoliša, Sunčevo zračenje, itd.), te sustav preuzima oblik:

$$\dot{\mathbf{x}}(t) = \mathbf{A}\mathbf{x}(t) + \mathbf{B}_u\mathbf{u}(t) + \mathbf{B}_v\mathbf{v}(t), \quad (3-6)$$

$$\mathbf{y}(t) = \mathbf{C}\mathbf{x}(t) + \mathbf{D}_u\mathbf{u}(t) + \mathbf{D}_v\mathbf{v}(t), \quad (3-7)$$

gdje su $\mathbf{B}_u$ ulazna matrica upravljačkih ulaza i $\mathbf{B}_v$ ulazna matrica neupravljivih ulaza.

Ako se jednadžba (3-1) postavi na sljedeći način, tako da su stanja i ulazi sortirani uvijek istim redoslijedom:

$$\dot{T}_{z1v} = -\frac{T_{z1v}}{C_{z1v}R_{z1v}} - \frac{T_{z1v}}{C_{z1v}R_{z1}} + \frac{T_{z1s1}}{C_{z1v}R_{z1}} + \frac{T_v}{C_{z1v}R_{z1v}} + \frac{H_{Sz1}}{C_{z1v}}, \quad (3-8)$$

može se preoblikovati u opći oblik s koeficijentima:

$$\dot{T}_{z1v} = a_{1,1}T_{z1v} + a_{1,2}T_{z1s1} + b_{1,1}T_v + b_{1,2}H_{s1v}, \quad (3-9)$$

gdje su koeficijenti:

$$a_{1,1} = -\frac{R_{z1v} + R_{z1}}{C_{z1v}R_{z1v}R_{z1}}, \quad (3-10)$$

$$a_{1,2} = \frac{1}{C_{z1v}R_{z1v}}, \quad (3-11)$$

$$b_{1,1} = \frac{1}{C_{z1v}R_{z1v}}, \quad (3-12)$$

$$b_{1,2} = \frac{1}{C_{z1v}}. \quad (3-13)$$

Sada je moguće cijeli sustav postaviti u obliku prostora stanja:

$$T = \begin{bmatrix} T_{z1v} \\ T_{z1s1} \\ T_{z2v} \\ T_{z2s1} \\ T_{z3v} \\ T_{z3s2} \\ T_{z4v} \\ T_{z4s2} \\ T_{z5v} \\ T_{z5s2} \\ T_{z6v} \\ T_{z6s1} \\ T_{z12s1} \\ T_{z12s2} \\ T_{s1} \\ T_{s2} \end{bmatrix}, \quad (3-14)$$

$$\mathbf{u} = [H_{us2}], \quad (3-15)$$

$$\mathbf{v} = \begin{bmatrix} T_v \\ H_{Sz1} \\ H_{Sz2} \\ H_{Sz3} \\ H_{Sz4} \\ H_{Sz5} \\ H_{Sz6} \\ H_{Sp1} \\ H_{Sp2} \end{bmatrix}, \quad (3-16)$$

$$\mathbf{y} = \begin{bmatrix} T_{s1} \\ T_{s2} \end{bmatrix}, \quad (3-17)$$

$$\begin{aligned}
 A = & \begin{bmatrix}
 a_{1,1} & a_{1,2} & 0 & 0 & 0 & 0 & 0 & 0 \\
 a_{2,1} & a_{2,2} & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & 0 & a_{3,3} & a_{3,4} & 0 & 0 & 0 & 0 \\
 0 & 0 & a_{4,3} & a_{4,4} & 0 & 0 & 0 & 0 \\
 0 & 0 & 0 & 0 & a_{5,5} & a_{5,6} & 0 & 0 \\
 0 & 0 & 0 & 0 & a_{6,5} & a_{6,6} & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & a_{7,7} & a_{7,8} \\
 0 & 0 & 0 & 0 & 0 & 0 & a_{8,7} & a_{8,8} \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & a_{15,2} & 0 & a_{15,4} & 0 & 0 & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & a_{16,6} & 0 & a_{16,8} \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & a_{2,15} & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & a_{4,15} & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & a_{6,16} \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\
 0 & 0 & 0 & 0 & 0 & 0 & 0 & a_{8,16} \\
 a_{9,9} & a_{9,10} & 0 & 0 & 0 & 0 & 0 & 0 \\
 a_{10,9} & a_{10,10} & 0 & 0 & 0 & 0 & 0 & a_{10,16} \\
 0 & 0 & a_{11,11} & a_{11,12} & 0 & 0 & 0 & 0 \\
 0 & 0 & a_{12,11} & a_{12,12} & 0 & 0 & a_{12,15} & 0 \\
 0 & 0 & 0 & 0 & a_{13,13} & a_{13,14} & a_{13,15} & 0 \\
 0 & 0 & 0 & 0 & a_{14,13} & a_{14,14} & 0 & a_{14,16} \\
 0 & 0 & 0 & a_{15,12} & a_{15,13} & 0 & a_{15,15} & a_{15,16} \\
 0 & a_{16,10} & 0 & 0 & 0 & a_{16,14} & a_{16,15} & a_{16,16}
 \end{bmatrix} \quad (3-18)
 \end{aligned}$$

$$\mathbf{B}_u = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ b_{u16,1} \end{bmatrix}, \quad (3-19)$$

$$\mathbf{B}_v = \begin{bmatrix} b_{v1,1} & b_{v1,2} & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ b_{v3,1} & 0 & b_{v3,3} & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ b_{v5,1} & 0 & 0 & b_{v5,4} & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ b_{v7,1} & 0 & 0 & 0 & b_{v7,5} & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ b_{v9,1} & 0 & 0 & 0 & 0 & b_{v9,6} & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ b_{1v1,1} & 0 & 0 & 0 & 0 & 0 & b_{v11,7} & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & b_{v15,8} & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & b_{v16,9} \end{bmatrix}, \quad (3-20)$$

$$\mathbf{c} = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}, \quad (3-21)$$

$$D_u = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \quad (3-22)$$

$$D_v = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}. \quad (3-23)$$

Ovime je demonstrirano korištenje RC metode, varijante 3R2C na primjeru jednostavne zgrade s dvije sobe, u dvije dimenzije, što je u osnovi vrlo jednostavan primjer strukturiranja termodinamičkog modela zgrade. No već je rečeno da je RC vrlo fleksibilna metoda, koja omogućuje prikaz vrlo složenih zgrada te HVAC sustava. Ovo su neki primjeri:

- Vertikalna interakcija elemenata zgrade, što je u prošlom primjeru zanemareno, može se riješiti jednostavnim dodavanjem "zida", npr. poda ili stropa. Svi zidovi su međusobno neovisni (zanemareni su toplinski procesi na spojevima zidova), tako da se, na primjer, pod zgrade prikazuje dodavanjem jednog novog zida (dva stanja) između svih zona u zgradi i novog neupravljivog ulaza koji predstavlja temperaturu tla ispod zgrade. Isto tako može se prikazati interakcija između katova u višekatnim zgradama, dodavanjem novog zida (pod/strop) između svake zone na različitim katovima.

- Djelovanje HVAC sustava, npr. radijator u zoni, također se može prikazati strujnim izvor koji djeluje izravno na temperaturu sobe.
- Djelovanje HVAC sustava moguće je prikazati i na složeniji način. Npr. zračni sustav koji djeluje na više soba. On se može prikazati tako da se toplinski izvor (npr. plinski bojler) prikaže kao strujni izvor, a distribucija zraka do zona predstavi RC elementima. U ovom slučaju radilo bi se o vremenski-promjenjivom sustavu, jer se vrijednosti R i C parametara mijenjaju kako se mijenjaju postavke HVAC sustava (npr. brzina ventilatora koji pokreće topli zrak u cijevima ili položaj poklopca zraka u zonu). Alternativno rješenje je da se ulaz energije u svaku zonu predstavi strujnim izvorima.
- Također, moguće je kombinirati RC elemente različite složenosti. Na primjer, može se pretpostaviti da se vanjski zidovi predstavljaju 4R3C elementima, a unutarnji 2R1C elementima.

3.2. Algoritam za strukturiranje termodinamičkog modela zgrade

Kao što se vidi u prethodnom primjeru, termodinamički model zgrade je složen, čak i kada se radi o jednostavnoj zgradi. Za izradu modela potrebno je uložiti dosta truda i vremena, a zbog velikog broja varijabli i parametara, postoji nezanemariva mogućnost za greške.

3.2.1. Matematička pozadina i algoritam

Ako se pogleda reprezentacija sustava u prostoru stanja (3-6) i (3-7), može se vidjeti da su matrice stanja A i ulaza B rijetko popunjene (engl. *Sparse Matrix*), što može doprinijeti brzini njihova rješavanja i manjem korištenju računalnih resursa.

Također, može se primijetiti da su matrice pravilnog oblika, u smislu da odražavaju fizikalnu reprezentaciju. Na primjer, kod 3R2C metode, zid uvijek nosi dva stanja dok prostor uvijek nosi po jedno stanje i jedan izlaz. Odnosno, koliko je unutarnjih akumulatora (procesa uskladištenja energije), toliko je i varijabli stanja. U primjeru, u matrici stanja A (3-18), vanjski zid se uvijek sastoji od pet elemenata, od čega su dva na dijagonali, dva ispod i iznad dijagonale, te jedan pri desnom rubu matrice. Također, ovi elementi uvijek se računaju na isti način; mijenja se samo vrijednosti parametara ovisno o svojstvima materijala od kojih je element zgrade sačinjen. Nakon analize i usporedbe većeg broja sustava, čak i kod različitih varijanti RC metode (3R2C, 4R3C, 2R1C, itd.) ove pravilnosti je lako uočiti. Iskusan korisnik RC metode može odrediti strukturu matrice bez prethodne razrade diferencijalnih jednačbi.

Konačno, moguće je automatizirati izradu toplinskog modela temeljenog na RC metodi.

Prvo, potrebno je definirati osnovne građevne elemente modela te njihova svojstva. To su:

- Izvor ***I*** – Predstavlja izvore topline, odnosno ulaze u sustav. Parametri izvora su:
 - Tip (nužni parametar), koji može biti upravljački ulaz (npr. radiator) ili neupravljivi ulaz (npr. Sunčevo zračenje).
- Prostor ***P*** – Predstavlja temperaturu unutar neke zone, odnosno stanja sustava. Parametri prostora su:
 - Tip (nužni parametar), koji određuje radi li se o prostoru (prostoriji, zoni) unutar zgrade ili o vanjskom okolišu. Može biti samo jedan vanjski okoliš u sustavu.
 - Vrijednost toplinskog kapaciteta (nužan parametar), koji ovisi o prostoru (no najčešće je to zrak). Ako je prostor vanjski okoliš, ovaj parametar se zanemaruje jer se toplinski kapacitet vanjskog okoliša smatra beskonačnim.
 - Izvor (izborni parametar), koji određuje djeluje li na ovaj prostor neki izvor ***I***. Ako je prostor vanjski okoliš, ovaj parametar se zanemaruje.
- Zid ***Z*** – Predstavlja zid između dva prostora. Prostori mogu biti par vanjski-unutarnji ili unutarnji-unutarnji, gdje se kod unutarnjih može raditi o prostorima na različitim katovima. Parametri zidova su:
 - Prostori (nužni parametri), koji određuju između kojih prostora ***P1*** i ***P2*** se nalazi zid. Nužno je uvijek pratiti istu orijentaciju prostora kod svih zidova (npr. ***P1*** je uvijek prostor lijevo ili iznad zida ***Z***).
 - Fizikalna svojstva (nužni parametri), koji određuju vrijednosti ***R*** i ***C*** parametara zida. Točna struktura ovisi o odabranoj varijanti RC metode. Tipična svojstva su duljina, visina, širina te karakteristike građevnih materijala (npr. koeficijent toplinskog otpora cigle). Kod 3R2C metode, fizikalni parametri su ***R1*** (toplinski otpor zida prema prostoru ***P1***), ***R*** (unutarnji toplinski otpor zida), ***R2*** (toplinski otpor zida prema prostoru ***P2***), ***C1*** (toplinski kapacitet dijela zida prema ***P1***) i ***C2*** (toplinski kapacitet dijela zida prema ***P2***).
 - Izvori (izborni parametri), koji određuju djeluje li na zid neki toplinski izvor (npr. Sunčevo zračenje) ***I1*** i ***I2***. Nužno je uvijek pratiti istu orijentaciju izvora kod svih zidova (npr. ***I1*** je uvijek izvor lijevo ili iznad zida ***Z***).
- Otvor ***O*** – Predstavlja otvor (prozor ili vrata) između dva prostora. Vrijede slična svojstva kao kod zida, samo na otvor ne mogu djelovati izvori:

- Prostori (nužni parametri), koji određuju između kojih prostora ***P1*** i ***P2*** se nalazi otvor. Nužno je uvijek pratiti istu orijentaciju prostora kod svih otvora (npr. ***P1*** je uvijek prostor lijevo ili iznad otvora ***O***).
- Fizikalna svojstva (nužni parametri), koji određuju vrijednosti *R* parametara otvora. Točna struktura ovisi o odabranoj varijanti RC metode. Tipična svojstva su duljina, visina, širina te karakteristike građevnih materijala (npr. koeficijent toplinskog otpora stakla). Kod 3R metode, fizikalni parametri su ***R1*** (toplinski otpor otvora prema prostoru ***P1***), ***R*** (unutarnji toplinski otpor otvora), ***R2*** (toplinski otpor otvora prema prostoru ***P2***).

Nakon što su definirani parametri, moguće je odrediti strukturu matrice. Ovdje je prikazan algoritam za 3R2C varijantu, koja je najčešća, no algoritam je vrlo sličan i za ostale varijante RC metode. Pretpostavlja se da su svi elementi posloženi u sortirane liste s indeksima.

Na početku, potrebno je izbrojati stanja, ulaze i izlaze te definirati matrice ***A***, ***B***, ***C*** i ***D***, što je prikazano u algoritmu 3.1.

Algoritam 3.1. *Određivanje broja stanja, ulaza i izlaza*

```

broj_stanja = duljina(lista_zidova)*2 + duljina(lista_prostora) - 1 // -1 jer je jedan
prostor uvijek vanjski okoliš
broj_ulaza = duljina(lista_izvora) + 1 // +1 jer je jedan prostor uvijek vanjski okoliš
broj_izlaza = duljina(lista_prostora) - 1 // -1 jer je jedan prostor uvijek vanjski
okoliš
A = nova null matrica(broj_stanja x broj_stanja)
B = nova null matrica(broj_stanja x broj_ulaza)
C = nova null matrica(broj_izlaza x broj_stanja)
D = nova null matrica (broj_izlaza x broj_ulaza)

```

Zatim se prema algoritmu 3.2. može odrediti struktura i parametri matrice sustava ***A***, vezano za zidove i njihove prostore.

Algoritam 3.2. *Određivanje strukture matrice sustava A – zidovi i prostori*

```

i=0
za svaki zid Z
    A(i,i) = -1*((1/(Z.R1*Z.C1)+ (1/(Z.R*Z.C1)))
    A(i,i+1) = 1/(Z.R*Z.C1)
    A(i+1,i) = 1/(Z.R*Z.C2)
    A(i+1,i+1) = -1*((1/(Z.R*Z.C2)))+(1/(Z.R2*Z.C2)))
    j = broj_stanja - broj_izlaza
    za svaki prostor P
        ako P nije vanjski okoliš
            ako je Z.P1 = P onda
                A(i,j) = 1/(Z.R1*Z.C1)
                A(j,i) = 1/(Z.R1*P.C)
                A(j,j) = A(j,j)-1/(Z.R1*P.C)
            ako je Z.P2 = P onda
                A(i+1,j) = 1/(Z.R2*Z.C2)
                A(j,i+1) = 1/(Z.R2*P.C)
                A(j,j) = A(j,j)-1/(Z.R_2*P.C)
            j = j+1
    i=i+2

```

Slijedi daljnje određivanje strukture i parametara matrice A , vezano za otvore i njihove prostore, definirano u algoritmu 3.3.

Algoritam 3.3. *Određivanje strukture matrice sustava A – otvori i prostori*

```

za svaki otvor O
    i = broj_stanja - broj_izlaza // index i vezan u prostor P1
    za svaki prostor P1
        j = broj_stanja - broj_izlaza // index j vezan u prostor P2
        za svaki prostor P2
            ako O.P1 = P1 i O.P2=P2 onda
                ako ni P1 ni P2 nisu vanjski okoliš onda
                    A(i,i) = A(i,i)-1/((O.R1+O.R+O.R2)*P1.C)
                    A(i,j) = A(i,j)+1/((O.R1+O.R+O.R2)*P1.C)
                    A(j,i) = A(j,i)+1/((O.R1+O.R+O.R2)*P2.C)
                    A(j,j) = A(j,j)-1/((O.R1+O.R+O.R2)*P2.C)
                ili ako P1 je vanjski okoliš, a P2 nije onda
                    A(j,j) = A(j,j)-1/((O.R1+O.R+O.R2)*P2.C)
                ili ako P1 nije vanjski okoliš, a P2 je onda
                    A(i,i) = A(i,i)-1/((O.R1+O.R+O.R2)*P1.C)
            ako P2 nije vanjski okoliš
                onda j = j+1
        ako P1 nije vanjski okoliš
            onda i = i+1

```

Sljedeći korak je određivanje strukture i parametara matrice B , vezano uz zidove i njihove prostore i izvore, što je prikazano u algoritmu 3.4. Pretpostavlja se da je prvi ulaz uvijek vanjski okoliš, zatim slijede neupravljivi ulazi, a upravljački ulazi su zadnji.

Algoritam 3.4. *Određivanje strukture matrice ulaza $\mathbf{B}$ – zidovi, prostori i izvori*

```

i=0
za svaki zid Z
    ako je Z.P1 vanjski okoliš onda
         $B(i,0) = 1/(Z.R1*Z.C1)$ 
    ako je Z.P2 vanjski okoliš onda
         $B(i+1,0) = 1/(Z.R2*Z.C2)$ 
    j = 1
    za svaki izvor I
        ako I nije upravljan onda
            ako Z.I1 = I onda
                 $B(i,j) = 1/(Z.C1)$ 
            ako Z.I2 = I onda
                 $B(i+1,j) = 1/(Z.C2)$ 
        j = j+1
    za svaki izvor I
        ako I je upravljan onda
            ako Z.I1 = I onda
                 $B(i,j) = 1/(Z.C1)$ 
            ako Z.I2 = I onda
                 $B(i+1,j) = 1/(Z.C2)$ 
        j = j+1
    i = i+2

```

Slijedi daljnje određivanje strukture i parametara matrice $\mathbf{B}$, predstavljeno u algoritmu 3.5., a vezano za otvore i njihove prostore.

Algoritam 3.5. *Određivanje strukture matrice ulaza $\mathbf{B}$ – otvori i prostori*

```

za svaki otvor O
    i = broj_stanja - broj_izlaza
    za svaki prostor P1
        j = broj_stanja - broj_izlaza
        za svaki prostor P2
            ako O.P1 = P1 i O.P2=P2 onda
                ako P1 je vanjski okoliš, a P2 nije onda
                     $B(j,0) = B(j,0)+1/((O.R1+O.R+O.R2)*P2.C)$ 
                ili ako P1 nije vanjski okoliš, a P2 je onda
                     $B(i,0) = B(i,0)+1/((O.R1+O.R+O.R2)*P1.C)$ 
            ako P2 nije vanjski okoliš
                onda j = j+1
        ako P1 nije vanjski okoliš
            onda i = i+1

```

Zadnji korak kod određivanja strukture i parametara matrice $\mathbf{B}$ je vezan uz prostore i njihove izvore, definirano algoritmom 3.6.

Algoritam 3.6. *Određivanje strukture matrice ulaza B – prostori i izvori*

```

i = broj_stanja - broj_izlaza
za svaki prostor P
    j = 1
    za svaki izvor I
        ako I nije upravljan onda
            ako P.I = I onda
                B(i,j) = 1/P.C
            j = j+1
    za svaki izvor I
        ako I je upravljan onda
            ako P.I = I onda
                B(i,j) = 1/P.C
            j = j+1
    ako P nije vanjski okoliš onda
        i = i+1

```

Zadnji korak u proceduri je odrađivanje strukture i parametara matrice C , prikazano u algoritmu 3.7., koja zapravo samo prenosi temperature prostora.

Algoritam 3.7. *Određivanje strukture matrice izlaza C*

```

i = 0
k = broj_stanja - broj_izlaza
za svaki prostor P
    ako P nije vanjski okoliš onda
        C(i,k) = 1
        i = k+1
        k = k+1

```


Ovime su određene strukture i parametri svih matrica sustava.

3.2.2. Implementacija algoritma


Za potrebe ovog istraživanja, algoritam prikazan u prethodnom poglavlju je implementiran u C# programskom jeziku, koristeći razvojno okruženje Microsoft Visual Studio Express 2015. Rezultat je aplikacija ModelBuilder koja služi za izradu toplinskog modela zgrade. Kompletan izvorni kod aplikacije moguće je pronaći u [106].

Na slici 3.9. prikazano je osnovno sučelje aplikacije. Sastoji se od površine za crtanje (engl. *Canvas*) na koju se postavljaju elementi zgrade, HVAC sustava ili okoliša. Kao i u algoritmu, to su četiri osnovna elementa:

- Zid (engl. *Wall*) –




- Otvor (engl. *Opening*) –



- Prostor (engl. *Space*) –




- Izvor (engl. *Source*) –



Elementi zgrade imaju svojstva kao što je to određeno u algoritmu (npr. zidovi imaju uz sebe vezane prostore i izvore te fizikalna svojstva). Dodatno, zidovi i otvori imaju svojstva orijentacije (horizontalna i vertikalna) te duljine, no ova svojstva ne utječu na algoritam nego služe da olakšaju slaganje sustava čime fizikalna reprezentacija postaje intuitivnija.

Nakon dodavanja elementa na površinu za crtanje, moguće ga je pomicati tipkovnicom i rotirati (u slučaju zidova i otvora). Dvoklikom na elemente otvaraju se prozori za uređivanje postavki elemenata, kao na primjer za 3R2C zid na slici 3.10.



Slika 3.9. Osnovno sučelje ModelBuilder aplikacije i osnovni elementi (zid, otvor, prostor i izvor)

The 'Wall Editor' dialog box is shown with the following fields and values:

- Name: wall6
- Length: 6
- Space 1: room1
- Space 2: outside
- R: 1
- R1: 1
- R2: 1
- C1: 1
- C2: 1
- Source 1: (empty)
- Source 2: sun_south_wall6

Buttons: OK, Cancel

Slika 3.10. Prozori za uređivanje postavki zida (pomoćna i fizikalna svojstva te odnosi prema drugim osnovnim elementima)


Nakon slaganja sustava i podešavanja parametara, aplikacija sama, koristeći algoritme iz prethodnog poglavlja, izrađuje vektore stanja, ulaza i izlaza te matrice sustava. Rezultat se prikazuje u tekstualnom okviru ispod površine za crtanje.

Osim ove osnovne funkcije, aplikacija ModelBuilder sadrži još nekoliko korisnih funkcija:

- konvertiranje verzija RC reprezentacije – Moguće je sve elemente iz jedne verzije RC reprezentacije (npr. zidove prezentirane 4R3C verzijom) pretvoriti u susjednu (po složenosti) verziju RC reprezentacije (npr. u 3R2C verziju).
- provjera modela – Provjera modela u smislu provjere da su nužni parametri zadani (npr. provjera javlja grešku ako zid nema zadana oba prostora).
- izvoz u MATLAB – Aplikacija može kreirati .m datoteku za MATLAB koja sadrži opis kontinuiranog sustava u obliku varijabli stanja (engl. *Continuous-Time State-Spaces Model*) korištenjem MATLAB funkcije *ss*. Ovakav sustav može se u MATLAB okruženju lako pretvoriti u diskretni korištenjem funkcije *c2d*.
- kreiranje ulaznih podataka – Aplikacija može kreirati .m datoteku za MATLAB koja sadrži ulazne podatke za sustav (npr. neupravljive ulaze kao što su temperatura i razina Sunčevog zračenja ili upravljačke ulaze kao što je toplinska snaga radijatora u zoni). Podaci se kreiraju za željeni vremenski raspon i vremensku konstantu te je moguće odabrati nekoliko uzoraka (konstantna vrijednost, sinus, slučajna raspodjela, itd.). Podaci se u MATLAB okruženju mogu koristiti za simulaciju sustava korištenjem funkcije *lsim*.

- ispunjavanje parametara – Moguće je automatski ispuniti sve R i C parametre za sve elemente koji ih imaju. Moguće je koristiti tablične vrijednosti za razne materijala, odrediti koeficijent slučajno odabira (0-100% u odnosu na tablične vrijednosti) ili ih sve postaviti na vrijednost 1 (što može biti korisno kod istraživanja odnosa i strukture).

Na slici 3.11. prikazan je isti sustav iz poglavlja 3.1.2 koji je bio korišten za demonstraciju izrade toplinskog modela pomoću RC metode: jednostavna zgrada s dvije sobe.



Slika 3.11. Jednostavna zgrada s dvije sobe, prikaz u ModelBuilder aplikaciji

Ako se pretpostavi da vrijednosti svih otpora i kapaciteta iznose 1 (što nije točno, no korisno je kod demonstracije odnosa strukture i parametara modela), dobivaju se sljedeći vektori stanja, ulaza i izlaza te matrice sustava:

$$\mathbf{T} = \begin{bmatrix} T_{z2v} \\ T_{z2s1} \\ T_{z3v} \\ T_{z3s2} \\ T_{z1v} \\ T_{z1s1} \\ T_{z12s1} \\ T_{z12s2} \\ T_{z4s2} \\ T_{z4v} \\ T_{z6s1} \\ T_{z6v} \\ T_{z5v} \\ T_{z5s2} \\ T_{s1} \\ T_{s2} \end{bmatrix}, \quad (3-24)$$

$$\mathbf{u} = \begin{bmatrix} T_v \\ H_{Sz1} \\ H_{Sz6} \\ H_{Sz5} \\ H_{Sz4} \\ H_{Sp1} \\ H_{Sp2} \\ H_{Sz2} \\ H_{Sz3} \\ H_{us2} \end{bmatrix}, \quad (3-25)$$

$$\mathbf{y} = \begin{bmatrix} T_{s1} \\ T_{s2} \end{bmatrix}, \quad (3-26)$$

[illegible]

$$B = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0,66 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0,33 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 1 \end{bmatrix}, \quad (3-28)$$

[illegible]

$$\mathbf{D} = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}. \quad (3-30)$$

Treba napomenuti da ova verzija algoritma i njegove implementacije ne predviđaju da jedan prostor ima uz sebe vezana dva izvora, kao što je to slučaj s istočnom prostorijom, koja ima izvore Sunčevog zračenja kroz prozor (H_{Sp2}) i radijator (H_{us2}). U uobičajenom postupku je njih potrebno zbrojiti i napraviti jedan zajednički izvor, no ovdje su oni ručno razdvojeni zbog demonstracije.

Ako se ove tablice usporede sa sustavom prikazanim u poglavlju 3.1.2., može se dokazati da se radi o identičnom sustavu (po strukturi), jednostavnim korištenjem Gaussovih transformacija matrica (zamjena redova).

3.3. Primjena algoritma za strukturiranje modela stvarne zgrade

U ovom potpoglavlju prikazano je strukturiranje termodinamičkog modela zgrade na primjeru stvarne zgrade koja je korištena u daljnjem istraživanju.


3.3.1. Opis zgrade i HVAC sustava

Na slici 3.12. prikazan je zgrada koja je korištena u ovom istraživanju. Radi se o uredsko-proizvodnoj zgradi na lokaciji u gradu Valpovu u kontinentalnoj Hrvatskoj, u vlasništvu tvrtke TEO-Belišće d.o.o.



Slika 3.12. Zgrada koja je korištena u istraživanju

Zgrada je ukupne tlocrtna površine 1.150 m^2 i sastoji se od dva dijela: uredski dio na dva kata te proizvodni dio u jednoj etaži, što je prikazano na slici 3.13.



Slika 3.13. Tlocrt zgrade koja je korištena u istraživanju

Zgrada je pravokutnog tlocrtnog oblika ukupnih dimenzija $15,74 \text{ m} \times 56,74 \text{ m}$, ukupne visine (s atikom) proizvodnog dijela $7,10 \text{ m}$, a uredskog dijela $9,10 \text{ m}$. Konstrukcija cijele zgrade je jedinstvena, međusobno povezana cjelina sa stupovima i armirano-betonskim (AB) konzolama koji nose rubne krovne nosače. Fasadu zgrade čine termopaneli debljine 12 cm , a krov čine

termopaneli debljine 16 cm i nagiba krovne plohe 3,5 stupnjeva. Uredski dio dodatno je izoliran s unutarnje strane plinobetonskim ("Siporex") blokovima debljine 10 cm i 15 cm s unutarnje strane.

Pod je vrlo dobro izoliran: AB ploča debljine 20 cm, PE folija kao hidroizolacija, XPS ("Stirodur") opeka debljine 8 cm kao termo-izolacija, bitumenska ljepenska opet kao hidroizolacija, podložni beton debljine 7 cm te sloj tucanika.

Kao izvori toplinske energije za grijanje ugrađeni su zidni kondenzacijski cirkulacijski bojleri, a grijanje je izvedeno kao podno u uredskom dijelu zgrade te stropnim toplovodnim zračućim panelima u proizvodnom dijelu zgrade. Podno grijanje ureda radi na nisko-temperaturnom režimu maksimalne temperature polazne vode od 45 °C, a toplovodni paneli u proizvodnom dijelu rade na režimu 80/60 °C. Pojedini prostori su opremljeni i inverterskim klimatizacijski jedinicama koje mogu grijati i hladiti prostor.

S obzirom da je upravljanje grijanjem u uredskom dijelu izvedeno pomoću neovisnih termostata za svaku prostoriju, istraživanje se koncentrira samo na proizvodni dio zgrade.

Proizvodni dio, na kojem je fokus istraživanja, sastoji se od četiri prostorije:

- prostor za montažu (Montaža, engl. *Assembly*), unutarnje površine 372 m²
- prostor za prijem i otpremu (Prijem, engl. *Entry*), unutarnje površine 58 m²
- prostor za mehaničku pripremu (Priprema, engl. *Mechanical*), unutarnje površine 60 m²
- skladišni prostor (Skladište, engl. *Warehouse*), 124 m².

Visine ovih prostora su 650 cm u najnižem dijelu te 700 cm u najvišem dijelu (sredina).

Prostori su međusobno odijeljeni unutarnjim zidovima od modularne blok-opeke debljine 25 cm te vratima:

- između Montaže i Prijema, te između Prijema i Skladišta:
 - dvokrilna zakretna vrata od aluminijske stolarije, punih aluminijskih profila i izo-stakla, širine 300 cm i visine 300 cm
 - zakretna vrata od aluminijske stolarije i izo-stakla, širine 180 cm i visine 225+75 cm
- između Montaže i Pripreme:
 - rolo-vrata od aluminijske stolarije, punih aluminijskih profila i izo-stakla, širine 300 cm i visine 300 cm

- zakretna vrata od aluminijske stolarije i izo-stakla, širine 180 cm i visine 225+75 cm.

Između Prijema i vanjskog okoliša nalaze se rolo (garažna) vrata od aluminijske stolarije i punih izolacijskih profila širine 350 cm i visine 350 cm.

Montaža i uredski dio su međusobno odijeljeni zidovima od modularne blok-opeke širine 25 cm. Također, između Montaže i uredskog dijela nalaze se još četvora jednokrilna vrata širine 90 cm i visine 225+75 cm, jedna dvokrilna vrata širine 180 cm i visine 225+75 cm te jedan prozor širine 200 cm i visine 100 cm.


U Skladištu se nalaze dva vanjska prozora širine 300×200 cm s trostrukim izo-staklom i koeficijentom prolaska topline najviše $U_w = 0,80 \text{ W/m}^2\text{K}$. Jedan takav prozor se nalazi u Pripremi te se još pet istih prozora nalazi u Montaži.

Više detalja o zgradi može se naći u Prilogu P.1 Izvadak iz glavnog arhitektonskog projekta.

Kao što je već spomenuto, HVAC sustav proizvodnog dijela temelji se prvenstveno na plinskom cirkulacijskom kondenzacijskom uređaju za grijanje prostora (plinski bojler) toplinskog učinka do 35 kW. Prijenos topline u prostor izveden je pomoću stropnih toplovodnih zračećih panela snage 187 W/m raspoređenih po prostorijama na sljedeći način:

- Montaža – 5 panela, svaki dužine oko 23 m
- Prijem – 4 panela, svaki dužine oko 7 m
- Priprema – 4 panela, svaki dužine oko 7 m
- Skladište – 6 panela, svaki dužine oko 7 m.

Strojarski nacrt HVAC sustava prikazan je na slici 3.14.




Slika 3.14. Prikaz HVAC sustava u zgradi


Elementi HVAC sustava su:

- plinski cirkulacijski kondenzacijski uređaj (plinski bojler) toplinskog učinka do 35 kW
- hidraulička skretnica protoka do 1,5 m³/h
- troputni miješajući ventil s otvaranjem 0-100%
- cirkulacijska pumpa grijanja s frekvencijskom regulacijom
- dvoputni ventili On-Off (normalno zatvoreni), po jedan za svaku prostoriju
- stropni toplovodni zračeći paneli
- cijevni senzor protoka i temperature polazne vode ($T_{ProdSup}$, f_{Prod})
- cijevni senzor temperature povratne vode ($T_{ProdRet}$)
- prostorni senzori temperature, po jedan za svaku prostoriju (osim montaže koja ima 2 senzora, po jedan u svakom kutu prostorije, tako da se za njih radi prosjek), smješteni na otprilike 3 m visine (T_{Assem1} , T_{Assem2} , T_{Entry} , T_{Mech} i T_{Ware})
- prostorni senzor vanjske temperature, smješten u hladu (T_{Out}).

Upravljački sustav temelji se na PLC sustavu Siemens S7-1200 s potrebnim brojem ulazno-izlaznih modula i HMI uređaju Siemens TP700 Comfort Panel. Na slici 3.15. prikazan je glavni ekran aplikacije za nadzor grijanja, a na slici 3.16. ekran zadavanja željenih temperatura.



Slika 3.15. Glavni ekran aplikacije za nadzor grijanja s prikazom HVAC sustava i prostora



Slika 3.16. Ekran zadavanja željenih temperatura (dnevno/noćno/ručno zadavanje)

Sustav grijanja izrađen je korištenjem Siemens TIA Portal programskog paketa. Ukratko opisano, radi na sljedeći način:

- bojler je uključen cijelo vrijeme kada je uključeno grijanje, osim kada ga ugasi vlastito upravljanje pri dostizanju maksimalne temperature
- troputni ventil miješa toplu vodu iz bojlera i hladnu povratnu vodu pokušavajući održati zadanu temperature polazne vode prema toplovodnim zračećim panelima
- cirkulacijska pumpa grijanja održava cirkulaciju vode u sustavu dok god je uključeno grijanje, održavajući konstantan tlak u cijevima (regulacije frekvencije prema vlastitom upravljanju pumpe), pod uvjetom da je otvoren barem jedan dvoputni ventil grijanja
- dvoputni ventili grijanja puštaju toplu polaznu vodu u toplovodne zračeće panele kada je temperatura prostora niža od zadane.

Osim sustava grijanja temeljenog na plinskom bojleru, prostorija Montaže opremljena je i s 4 klima-uređaja s inverterom, učinka hlađenja 3,5 kW i učinka grijanja 4,0 kW. Klima-uređaji su prvenstveno namijenjeni hlađenju (sušenju) zraka tokom ljeta, no mogu poslužiti i za grijanje prostorije Montaže u nuždi.

Više detalja o HVAC sustavu može se naći u Prilogu P.2 Izvadak iz Izvedbenog projekta strojarskih instalacija. Mjerenja koja se provode na sustavu detaljno su opisana u potpoglavlju 3.3.4.


3.3.2. Određivanje strukture modela i početnih vrijednosti parametara

Na slici 3.17. prikazan je termodinamički model zgrade razvijen u aplikaciji ModelBuilder.

Ovo se u nastavku naziva maksimalni termodinamički model zgrade, odnosno samo maksimalni model. Maksimalni model obuhvaća sljedeće:

- sve prostorije u kojima se mjeri i regulira temperatura (Montaža, Prijem, Priprema i Skladište)
- sva vrata i prozore
- sve stropne toplovodne zračeće panele, odnosno stropne radijatore (upravljački ulazi)
- sve klima-uređaje u Montaži (upravljački ulazi)
- strop (s obzirom na kvalitetu izolacije poda, pretpostavlja se da nema izmjene topline kroz pod)

- Sunčevo zračenje, odvojeno na "istočnu", "južnu", "zapadnu" i "stropnu" komponentu (neupravljivi ulazi; sa "sjeverne" strane se nalazi uredski dio zgrade)
- utjecaj ljudi i aktivnih strojeva te rasvjete unutar prostorija (neupravljivi ulazi)
- utjecaj odnosno izmjena topline s uredskim dijelom zgrade (kao dodatni prostor).




Slika 3.17. *Maksimalni termodinamički model zgrade razvijen u ModelBuilder aplikaciji*

S obzirom da razvijeni algoritam i njegova implementacija u aplikaciji ModelBuilder ne omogućavaju da jedan prostor ima više izvora topline, što je prisutno u ovom slučaju (npr. Montaža ima grijanje stropnim radijatorima, četiri klima-uređaja te utjecaj ljudi, strojeva i rasvjete), potrebno je izvore topline u prostorima gdje ih ima više svesti na jedan zajednički izvor.

Također, zbog jednostavnosti se utjecaj uredskog dijela zgrade prikazuje kao dodatni izvor topline na vanjsku stranu zida montaže (prema uredskom dijelu).

Tako da se umjesto maksimalnog modela koristi realni model, prikazan na slici 3.18. ili samo ukratko fizikalni model.



Slika 3.18. Realni termodinamički model zgrade razvijen u ModelBuilder aplikaciji (objedinjeni izvori topline u prostorima)

Dobiveni model (koji generira ModelBuilder aplikacija) je kontinuirani model koji u prostoru stanja izgleda kao:

$$\dot{\mathbf{T}}(t) = \mathbf{A}\mathbf{T}(t) + \mathbf{B}\mathbf{u}(t), \quad (3-31)$$

$$\mathbf{y}(t) = \mathbf{C}\mathbf{T}(t) + \mathbf{D}\mathbf{u}(t). \quad (3-32)$$

Realni model, koristeći najsloženiju inačicu RC metode 4R3C ima:

- 55 stanja (13 zidova s dvije vanjske i jednom unutrašnjom temperaturom, 4 krova s dvije vanjske i jednom unutrašnjom temperaturom te 4 prostora)
- 10 ulaza (vanjska temperatura, 4 komponente Sunčevog zračenja, utjecaj ureda te 4 zajednička izvora topline unutar prostora), od čega su 6 neupravljivi ulazi, a 4 upravljački ulazi
- 4 izlaza (temperature unutar prostora).

Odnosno, ako se pogledaju vektori i matrice koji opisuju prostor stanja:

- vektor stanja $\mathbf{T}$ duljine 55

- vektor ulaza $\mathbf{u}$ duljine 10 (odnosno, ako se ulaze razdvoji na neupravljive ulaze i upravljačke ulaze, vektor neupravljivih ulaza $\mathbf{v}$ duljine 6 i vektor upravljačkih ulaza $\mathbf{u}$ duljine 4)
- vektor izlaza $\mathbf{y}$ duljine 4
- matricu sustava $\mathbf{A}$ dimenzija 55×55
- ulaznu matricu $\mathbf{B}$ 55×10
- izlazu matricu $\mathbf{C}$ 4×55
- prolaznu matricu $\mathbf{D}$ kao nul-matricu veličine 4×10 .

Ako se pretpostave neke slučajne vrijednosti parametara (u stvarnim okvirima: zid od betona, prozori sa izo-staklima, itd., sa $\pm 40\%$ slučajnog pomaka), dobiva se vektore $\mathbf{T}$, $\mathbf{u}$ i $\mathbf{y}$ te matrice $\mathbf{A}$, $\mathbf{B}$, $\mathbf{C}$ i $\mathbf{D}$ koje su prikazani u Prilogu 4. Detaljan prikaz realnog modela zgrade s početnim parametrima.

Tako je, na primjer, vanjska temperatura zapadnog zida skladišta ($T_{wall_618_outside}$) povezana sa središnjom temperaturom zida ($T_{wall_618_inside}$), vanjskom temperaturom ($T_{outside}$) i Sunčevim zračenjem za taj zid ($H_{source_sun_west_57}$):

$$\begin{aligned}
 \dot{T}_{wall_618_outside} &= -3.38 \cdot 10^{-3} \cdot T_{wall_618_outside} + 3.32 \cdot 10^{-3} \\
 &\cdot T_{wall_618_inside} + 6.89 \cdot 10^{-5} \cdot T_{outside} + 2.86 \cdot 10^{-5} \\
 &\cdot H_{source_sun_west_57}.
 \end{aligned} \tag{3-33}$$

3.3.3. Analiza dobivenog fizikalnog modela sa stajališta upravljivosti i osmotrivosti

Dobiveni fizikalni (realni) model s početnim parametrima može se analizirati sa stajališta upravljivosti i osmotrivosti.

Prvo se može provjeriti osmotrivost i upravljivost sustava, o čemu se više može naći u [14]. Osmotrivost je mjera koja pokazuje koliko se dobro stanja sustava mogu zaključiti iz izlaza sustava. Odnosno, potpuno osmotriv sustav je onaj kod kojeg se svaka promjena stanja očitava na izlazima sustava. Osmotrivost je definirana matricom osmotrivosti $\mathbf{Ob}$:

$$\mathbf{Ob} = \begin{bmatrix} \mathbf{C} \\ \mathbf{CA} \\ \mathbf{CA}^2 \\ \vdots \\ \mathbf{CA}^{n-1} \end{bmatrix}, \tag{3-34}$$

gdje su A matrica sustava $N \times N$ i C matrica izlaza $Q \times N$. Sustav je osmotriv ako rang matrice Ob iznosi n . Za opisani realni model dobiva se rang matrice Ob od 24 što znači da je broj neosmotrivih stanja 31.

Ovo je relativno veliki broj neosmotrivih stanja (s obzirom na ukupan broj stanja), što znači da može doći do promjene stanja koja se neće očitovati na izlazima. Pri eksperimentalnoj analizi, odnosno određivanju vrijednosti parametara na temelju mjernih podataka, može se dogoditi da je nejasno u kakvom su odnosu parametri prema izlazima. Broj neosmotrivih stanja može se smanjiti pojednostavljenjem modela, no to s drugo strane uvodi greške u model.

Upravlјivost sustava je mjera koja opisuje koliko dobro se stanja sustava mogu upravljati ulazima sustava. Odnosno, potpuno upravljiv sustav je onaj kod kojeg se preko ulaza sustava mogu mijenjati sva unutarnja stanja sustava. Upravlјivost je definirana matricom upravljivost Co prikazanoj u:

$$Co = [B \quad AB \quad A^2B \quad \dots \quad A^{n-1}B], \quad (3-35)$$

gdje su A matrica sustava $N \times N$ i B matrica stanja $N \times P$. Sustav je upravljiv ako rang matrice Co iznosi n . Za opisani realni model dobiva se rang matrice Co od 47 što znači da je broj neupravljivih stanja 8.

S obzirom na ukupan broj stanja, broj neupravljivih stanja nije velik, iako se on može dodatno smanjiti pojednostavljenjem modela.

3.3.4. Opis mjerenja na zgradi korištenoj u istraživanju

Na zgradi koja je korištena u istraživanju mogu se izravno vršiti sljedeća mjerenja:

- cijevni senzor protoka i temperature polazne vode ($T_{ProdSup}, f_{Prod}$)
- cijevni senzor temperature povratne vode ($T_{ProdRet}$) tipa PT1000 s transponderom 4-20 mA
- prostorni senzori temperature, po jedan za svaku prostoriju (osim montaže koja ima 2 senzora, po jedan u svakom kutu prostorije, tako da se za njih radi prosjek), smješteni na otprilike 3 m visine (T_{Assem1} , T_{Assem2} , odnosno $T_{AssemAver}$, T_{Entry} , T_{Mech} , T_{Ware}) tipa PT1000 s transponderom 4-20 mA
- prostorni senzor vanjske temperature smješten u hladu izvan zgrade (T_{Out}) tipa PT1000 s transponderom 4-20 mA.

Ulazi koji su korišteni u realnom modelu su sljedeći:

- *outside* – vanjska temperatura
- *source_sun_east_629* – Sunčeva radijacija s istočne strane
- *source_sun_south_500* – Sunčeva radijacija s južne strane
- *source_sun_west_57* – Sunčeva radijacija sa zapadne strane
- *source_sun_roof_432* – Sunčeva radijacija na krov
- *source_heating_offices_835* – toplinski utjecaj uredskog dijela zgrade
- *source_summary_assembly_624* – zajednički ulaz topline u Montaži (grijanje stropnih radijatora, rad klima-uređaja, utjecaj strojeva, rasvjete i ljudi)
- *source_summary_mechanical_60* – zajednički ulaz topline u Pripremi (grijanje stropnih radijatora, utjecaj strojeva, rasvjete i ljudi)
- *source_summary_entry_924* – zajednički ulaz topline u Prijemu (grijanje stropnih radijatora, utjecaj strojeva, rasvjete i ljudi)
- *source_summary_warehouse_622* – zajednički ulaz topline u Skladištu (grijanje stropnih radijatora, utjecaj strojeva, rasvjete i ljudi).

S obzirom da se u modelu koriste određeni ulazi koji nisu izravno mjereni, potrebno je napraviti preračunavanje mjerenja za te ulaze. U nastavku su opisana sva mjerenja i njihova povezanost s ulazima.

Ulaz *outside* predstavlja izravno mjerenje vanjske temperature tako da je:

$$outside = T_{out}. \quad (3-36)$$

Ulazi *source_sun_east_629*, *source_sun_south_500*, *source_sun_west_57* te *source_sun_roof_432* predstavljaju Sunčevo zračenje na istočnu, južnu i zapadnu stranu zgrade te na krov. S obzirom da na lokaciji zgrade u trenutku mjerenja nije instalirana vremenska postaja koje omogućava izravno mjerenje Sunčeve radijacije, može se iskoristi prosječno mjerenje opće Sunčeve radijacije Q_{SolRad} od 1.350 kWh za godinu dana u Slavoniji (istočna Hrvatska). Korištenjem podataka o orijentaciji zgrade i formula predstavljenih u [7], može se dobiti dovoljno dobra estimacija Sunčevog zračenja za određeni scenarij (sezona ljeto, jesen, zima, proljeće).

Ulaz *source_heating_offices_835* predstavlja utjecaj uredskog dijela zgrade. Uredi su u sličnom temperaturnom režimu kao i proizvodni prostor (zadana dnevna temperatura od 23 °C te zadana noćna temperatura od 19 °C), a prostorije ureda u prizemlju su puno manje od Montaže. Utjecaj

uredskog dijela zgrade ne može se izravno mjeriti, no može se procijeniti. Na primjer, može se pretpostaviti konstantni toplinski tok, odnosno da se 5% topline koju proizvede bojler uredskog dijela vrati u prostor Montaže; može se raditi statistička procjena, a može se i pretpostaviti da nema utjecaja uredskog dijela zgrade na proizvodni.

Ulaz *source_summary_assembly_624* predstavlja zajednički ulaz topline u Montaži, koji se sastoji od tri komponente: utjecaj HVAC sustava, odnosno grijanja (Q_{HVAC_Prod}); utjecaj klima-uređaja (Q_{AC_Prod}) te utjecaj strojeva, rasvjete i ljudi (Q_{Other}).

Općenito, utjecaj HVAC sustava u svakoj od prostorija može izračunati koristeći sljedeću formulu, koja kaže da je unos toplinske energije proporcionalan protoku vode, njenoj gustoći i specifičnom toplinskom koeficijentu te razlici između temperature polazne i povratne vode:

$$Q_{HVAC} = \int_0^T \alpha(t) \cdot f_{Prod}(t) \cdot \rho_W \cdot c_{P_W} \cdot (T_{ProdSup}(t) - T_{ProdRet}(t)) dt, \quad (3-37)$$

gdje su:

- α – koeficijent koliko polazne vode odlazi u koji prostor, kojim je predstavljena razdioba toplinske energije (npr. ako su u nekom trenutku otvoreni samo dvoputni ventili Pripreme i Skladišta, tada je koeficijent α za Pripremu jednak $28/(28+42)=0,4$, gdje su 28 i 42 duljine toplovodnih zračćih panela u prostorijama Pripreme i Skladišta)
- f_{Prod} – protok polazne vode u m^3/s
- ρ_W – gustoća vode, zaokruženo na 1.000 kg/m^3
- c_{P_W} – specifični toplinski kapacitet vode, zaokruženo na 4.200 J/kgK
- $T_{ProdSup}$ i T_{RetSup} – temperature polazne i povratne vode, odnosno njihova razlika, u K.

Utjecaj klima uređaja je izuzetno teško mjeriti, s obzirom da ne postoji način kako mjeriti protok zraka iz unutarnje jedinice klima uređaja. Čak i neizravno mjerenje (npr. preko električne struje koja se troši) nije pouzdano, jer toplinski učinak ovisi o mnogo faktora (temperaturi vanjskog zraka, izvedbi vanjske i unutarnje jedinice, itd.). S obzirom da se klima-uređaj u zimskim uvjetima neće koristiti, a u ljetnim uvjetima su klima uređaji nedostatni da ohlade prostoriju Montaže (odnos, pod-kapacitirani su i koriste se samo da osuše zrak i ublaže najgore vrhunce ljetnih vrućina), može se pretpostaviti da je:

$$Q_{AC} = \begin{cases} \int_0^T 4 \cdot P \cdot dt & , u \text{ ljetnim uvjetima} \\ 0 & , u \text{ zimskim uvjetima} \end{cases} \quad (3-38)$$

gdje je P prosječna snaga korištenih klima uređaja, što prema specifikaciji proizvođača iznosi 3.500 W.

Zajednički utjecaj ljudi, strojeva i rasvjete još je teže mjeriti tako da se i ovdje može koristiti procjena.

Rasvjetni elementi, prema Prilogu P.3 Izvadak iz Izvedbenog elektrotehničkog projekta, u proizvodnom dijelu zgrade su proizvođača Beghelli, model Acciaio T5 2x54W, dakle svaka svjetiljka predstavlja toplinski utjecaj od 54 W, a raspoređene su na sljedeći način: 64 svjetiljke u Montaži, 9 svjetiljaka u Prijemu, 16 svjetiljaka u Pripremi i 16 svjetiljaka u Skladištu. Ovisno o režimu rada (dan/noć; smjena; broj radnika) može se doći do raznih procjena, s maksimalnim toplinskim utjecajem 11.340 W za cijelu zgradu, odnosno 6.912 W, 972 W, 1.728 W i 1.728 W po prostorijama Montaže, Prijema, Pripreme i Skladišta..

Koristeći ASHRAE [107] tablice, može se pretpostaviti toplinski utjecaj jednog čovjeka koji radi lagani fizički posao od oko 200 W. Dakle, ukupni toplinski utjecaj ljudi ovisi o režimu rada.

Također, s obzirom da se u proizvodnji ne koriste neprekidno strojevi, osim ručnog alata i osobnih računala, može se pretpostaviti manji konstantni toplinski utjecaj, u opsegu od nekoliko stotina vata, ovisno o režimu rada.

Zajednički utjecaj ljudi, rasvjete i strojeva može se izračunati kao:

$$Q_{Other} = \int_0^T (P_{Lighting} + P_{People} + P_{Machines}) \cdot dt. \quad (3-39)$$

3.3.5. Simulacija korištenjem dobivenog fizikalnog modela i početnih parametara

U ovom dijelu prikazana je usporedba stvarnih rezultata mjerenja s rezultatima simulacije fizikalnog modela zgrade, odnosno modela dobivenog teorijskom analizom (fizikalnim pristupom) s početnim parametrima dobivenih na temelju nazivnih podataka o svojstvima korištenih materijala.

Za postavljanje početnih parametara korištena je mogućnost "*Fill parameters...*" aplikacije ModelBuilder, prikazana na slici 3.19. Ove vrijednosti parametara ne odgovaraju potpuno vrijednostima za zgradu korištenu u istraživanju, no to nije bio ni cilj.

Slika 3.19. *Mogućnost "Fill parameters..." aplikacije ModelBuilder za podešavanje parametara*


Bez podešavanja, ova mogućnost postavlja sljedeće vrijednosti parametara, koristeći sljedeće vrijednosti za materijale prikazane u tablici 3.1.:

- jedna jedinica duljine znači 1 m stvarne duljine
- visina zidova i prostora od 3 m
- visina prozora 1 m
- ukupna debljina zidova od 30 cm, od čega je unutarnji sloj beton 20 cm, a dva vanjska sloja (prema vanjskom okolišu i prema unutrašnjem prostoru) 5 cm toplinski-izolacijskog stiropora
- izo-stakla debljine 2 cm.

Tablica 3.1. *Početne vrijednosti toplinskih parametara za materijale*

Materijal	Koeficijent prijenosa topline k (W/m ² K)	Gustoća ρ (kg/m ³)	Specifični toplinski kapacitet c (J/kgK)
Izolacijski sloj zida (stiropor)	0,0975	20	1.300
Unutarnji sloj zida (gusta cigla)	1,31	1.900	1.000
Zrak		1,205	1.010
Staklo	1,05	/	/
Plemeniti plin (ispuna prozora)	0,001772	/	/

Za simulacije je korištena pomoćna aplikacija izrađena u MATLAB okruženju koja služi za simulaciju i optimizaciju modela izrađenih u aplikaciji ModelBuilder, prikazana na slici 3.20.



Slika 3.20. Pomoćna MATLAB aplikacija za simulaciju i optimizaciju

Za simulaciju se koristi MATLAB funkcija *lsim* koja periodički učitava vektor ulaza $\mathbf{u}$ i računa stanja $\mathbf{x}$, odnosno izlaze $\mathbf{y}$, prema jednadžbama (3-4) i (3-5), odnosno njihovom diskretnom obliku:

$$\mathbf{x}(k+1) = \mathbf{A}\mathbf{x}(k) + \mathbf{B}\mathbf{u}(k), \quad (3-40)$$

$$\mathbf{y}(k) = \mathbf{C}\mathbf{x}(k) + \mathbf{D}\mathbf{u}(k). \quad (3-41)$$

Potrebno je naglasiti da aplikacija ModelBuilder stvara modele u kontinuiranom obliku dok se u MATLAB aplikaciji koristi njihov diskretni oblik, tako je modele potrebno diskretizirati. Za to je moguće iskoristiti MATLAB funkciju *c2d* koja diskretizira dani model u odnosu na zadano vrijeme uzorkovanja. U ovim primjerima korišteno je vrijeme uzorkovanja od 1 sat (3.600 sekundi), 15 minuta (900 sekundi) ili 5 minuta (300 sekundi), ovisno o eksperimentu. Vrijeme uzorkovanja manje od 5 minuta trenutno nije moguće jer se mjerenja na sustavu upravljanja ne arhiviraju u rasponu manjem od 5 minuta.


Također, kod simulacije je potrebno obratiti pozornost na početna stanja sustava. Kod mjerenih podataka to nije bitno, jer se mjeri dinamički sustav koji je u trenutku početka mjerenja već u

nekom stanju. Kod simulacije, ako to nije drugačije naglašeno, funkcija *lsim* (odnosno, bilo koji simulator) pretpostavlja da početna stanja sustava iznose nula (znači, sve vrijednosti, odnosno temperature imaju vrijednost nula), što može dovesti do greške. Zato u pomoćnoj MATLAB aplikaciji postoji mogućnost ručnog zadavanja početnih vrijednosti sustava kod simulacije (standardno 20 °C) ili postavljanja početnih stanja iz mjerenja kada se koriste mjereni izlazni podaci (pretpostavlja se da su stanja, odnosno temperature zidova, identične i jednake prosječnoj vrijednosti temperatura prostora).

Za ulazne i izlazne podatke iskorištena su mjerenja izvršena u periodu od 21. veljače do 1. ožujka 2018. godine. U tom periodu odabran je raspon od šest dana neprekinutih mjerenja koji su kasnije iskorišteni kao podaci za trening, odnosno optimizaciju parametara modela te dva dana neprekinutih mjerenja koji su iskorišteni kao podaci za testiranje, odnosno validaciju modela. U ovom primjeru zanemareno je Sunčevo zračenje, utjecaj uredskog dijela zgrade i toplinski utjecaji rasvjete, strojeva i ljudi.


Na slici 3.21. prikazani su ulazni podaci:

- vanjska temperatura (ulaz *outside* u °C)
- utjecaj grijanja Montaže (ulazi *source_summary_assembly_6242* u kWh)
- utjecaj grijanja Priprema (*source_summary_mechanical_602* u kWh)
- utjecaj grijanja Prijema (*source_summary_entry_9242* u kWh)
- utjecaj grijanja Skladišta *source_summary_warehouse_622* u kWh).



Slika 3.21. *Ulazni podaci od 21.2.2018 do 26.2.2018.*

Na slici 3.22. prikazani su izlazni podaci, mjereni na zgradi (neprekinute linije) i uspoređeni s izlaznim podacima dobivenim simulacijom modela s 4R3C strukturom i početnim vrijednostima parametara (crtkane linije).



Slika 3.22. *Izlazni podaci: mjerenja i simulacija fizikalnog modela od 21.2.2018 do 26.2.2018.*

Iz usporedbe rezultata simulacije, čak i samo vizualnom usporedbom ova dva skupa podataka, može se doći do nekoliko zaključaka:

- Prvo, rezultati su "relativno dobri", u smislu da nije došlo do zasićenja sustava i da se rezultati simulacije kreću u općim okvirima stvarnih vrijednosti (kod loše podešenih modela vrijednosti izlaza, odnosno temperature, vrlo brzo prelaze u vrijednosti od nekoliko stotina, čak i tisuća °C iznad ili ispod 0 °C).
- Drugo, rezultati su "dosta loši", u smislu da nisu upotrebljivi za predviđanje kretanja temperatura niti za ikakvo upravljanje. Greška veća od nekoliko °C kod HVAC sustava određuje hoće li se stanar/korisnik osjećati ugodno ili (vrlo) neugodno boraveći u prostoru.
- Treće, može se uočiti dominacija utjecaja vanjske temperature, dok je zavisnost o ostalim ulazima (HVAC sustav) gotovo nepostojeća. Pregledom grafa, uočava se da se nakon tri dana simulacije vrijednosti izlaza gotovo izjednačavaju i potpuno prate vanjsku temperaturu.

Više zaključaka, kao i detaljna matematička analiza ovih rezultata te predložena hibridna metoda koja omogućuje što točniju simulaciju sustava, prikazani su u poglavlju 4.

4. HIBRIDNA METODA ZA IZRADU TERMODINAMIČKOG MODELA ZGRADE

U radu [18] autora Atam i Helsen iz 2016. dane su dvije tablice koje prikazuju neke prednosti i nedostatke hibridnih toplinskih modela (ili modela sive kutije, engl. *Grey-Box*, za razliku od bijele i crne kutije) te RC nadomjesne metode. Također, radovi [59] i [60] te razni radovi koji su predstavljeni u poglavlju 2.2.2 koji se bave pojednostavljivanjem toplinskih modela dobivenih fizikalnim pristupom, prepoznaju veliku složenost kao jedan od glavnih problema RC metode. Ovo se može vidjeti i u primjeru u prethodnom poglavlju gdje toplinski model jednostavne zgrade koja se sastoji samo od dvije prostorije ima 16 stanja, 10 ulaza te 48 parametara u matrici stanja A i 15 parametara u matrici ulaza B (treba uzeti u obzir da su u navedenom primjeru već prisutna mnoga zanemarivanja). Pojednostavljivanja modela dobivenog fizikalnom analizom su moguća, no to najčešće uzrokuje i smanjivanje točnosti modela (a i najčešće se gubi fizikalna interpretacija modela).

No, neovisno o ovome problemu, RC metoda je prepoznata kao vrlo pogodna metoda za korištenje u hibridnom pristupu izradi modela, u smislu da se struktura modela odredi pomoću fizikalnog pristupa (teorijske analize), a vrijednosti parametara modela pomoću podatkovnog pristupa (eksperimentalne analize).

Rad [18] kao prednosti hibridne RC metode navodi:

- "parametri RC modela pružaju fizikalnu interpretaciju modela"
- "parametri RC modela mogu se neizravno iskoristiti za provjeru RC modela (npr. usporedbom s ASHRAE tabličnim vrijednostima)"
- "validacija modela kroz dodatne pokuse može biti nepotrebna ako su dobivene vrijednosti RC parametara u razumnom opsegu"
- "RC identifikacija parametara je popularna u krugovima koji se bave energetsom učinkovitošću zgrada i kao takva može služiti kao zajednički jezik za brže i lakše razumijevanje".

Također, kao nedostatke navodi:

- "identifikacija parametara zahtijeva ulazno-izlazne podatke s bogatim frekvencijskim spektrom"
- "općenito, ulazno-izlazni podaci dobiveni iz mjerenja u stvarnim zgradama su korelirani i nemaju bogati frekvencijski sadržaj"

- "pokuse kojima je cilj dobiti ulazno-izlazne podatke za identifikaciju parametara je teško izvoditi u zgradama sa stanarima"
- "iako postoje neke smjernice kako odrediti broj otpora i kapaciteta za elemente zgrade, za neke komplicirane građevinske strukture, izrada RC mreže može biti vrlo teška"
- "RC identifikacija parametara može biti neuspješna za srednje- do visoko-složene zgrade, u kojem slučaju decentralizirana identifikacija parametara može biti mogućnost."

U ovom radu, fokus istraživanja je na ispravljanju četvrtog nedostatka (poboljšavanje smjernica za izradu RC modela), uz uvažavanje svih ostalih prednosti i nedostataka.

4.1. Opis hibridne metode

Hibridna metoda koja se temelji na RC metodi za izradu strukture modela i određivanju parametara modela na temelju mjernih podataka koja je predstavljena u ovom istraživanju sastoji se od sljedećih koraka:

1. odrediti RC mrežu (određivanje strukture modela kroz teorijsku analizu) zgrade koja se modelira koristeći ModelBuilder aplikaciju (ili navedene algoritme)
2. odrediti početne vrijednosti RC parametara kroz teorijsku analizu pomoću nazivnih vrijednosti svojstava materijala zgrade (moguće preko ModelBuilder aplikacije)
3. provesti mjerenja ulazno-izlaznih veličina u zgradi, vodeći računa o informativnosti zabilježenih podataka (npr. mjerenje sustava u mirnom stanju, mjerenje sustava s aktivnim HVAC sustavom, pojedinačno uključivanje i isključivanje dijelova HVAC sustava za vrijeme mjerenja, mjerenje u različitim režimima vanjskih uvjeta, itd.)
4. optimizirati parametre modela (prepodešavanje parametara na temelju mjernih podataka) tako da se minimalizira greška definirana razlikom između mjerenja i izlaza modela.

Prvi i drugi korak, određivanje strukture modela i određivanje početnih parametara modela opisani su u prethodnom poglavlju: potrebno je izraditi što detaljniji model promatrane zgrade koristeći RC metodu i aplikaciju ModelBuilder. Model se kasnije može po potrebi pojednostaviti prebacivanjem u jednostavniju varijantu RC metode ili zanemarivanjem dijela procesa i svojstava. Razina detalja i struktura HVAC sustava koji je dio modela ovisi o HVAC sustavu zgrade i potrebi da se ide u detalje. HVAC sustav moguće je modelirati samo generičkim izvorom u svakoj zoni koji onda obuhvaća i elemente HVAC sustava (grijače, radijatore, zračni sustav), a moguće je

modelom detaljno opisati HVAC sustav od toplinskog izvora, preko razvoda toplinske energije do izvršnih elemenata.

Vrijednosti parametara R i C elemenata u fizikalnom modelu potrebno je samo grubo odrediti, budući da će se oni naknadno prepodesiti. Već i postavljanjem njihove vrijednosti u isti red veličine kao i ispravne vrijednosti može se dobiti vrlo dobre rezultate modela, jer točnost ovakvog modela više ovisi o točnosti strukture modela nego točnosti vrijednosti parametara [108].

S obzirom da se radi o upravljanju stvarnom zgradom i da su mjerenja uvijek vremenski diskretna, te da se u daljnjim koracima koriste numeričke metode, sustav se najčešće opisuje kao diskretni:

$$\mathbf{T}(k + 1) = \mathbf{AT}(k) + \mathbf{Bu}(k), \quad (4-1)$$

$$\mathbf{y}(k) = \mathbf{CT}(k) + \mathbf{Du}(k). \quad (4-2)$$

Treći korak, mjerenje procesnih veličina na zgradi je zasebno i složeno tehničko područje te može biti zahtjevan i problematičan korak, osobito ako u zgradi ima stanara kojima će pokusi smetati. Ukoliko se mjerenja provode samo u "normalnom" radu, pojava vrijednosti ulaza koje nisu bile obuhvaćene snimanjem može vrlo loše utjecati na točnost simulacije [48]. Na primjer, ako se mjerenja provode u zimskom režimu, vrlo je vjerojatno da će simulacija prijelaznog ili ljetnog režima biti netočna. Ili ako se podaci snimaju samo dok nema ljudi, neće biti obuhvaćene aktivnosti kao što su otvaranje vrata i prozora. Dakle, potrebno je osigurati da je mjernim podacima obuhvaćeno što više fenomena (ili frekvencija) koji se pojavljuju u radu sustava (općenito ili u određenim režimima rada).

Veličine unutar zgrade kao toplinskog sustava su vrlo korelirane. Čak je i intuitivno vrlo jednostavno predvidjeti ponašanje toplinskog sustava. Na primjer: u zimskom režimu, vanjska temperatura okoliša pada, HVAC sustav počinje djelovati i u svim prostorima podiže temperaturu. Da bi se zadovoljili spomenuti zahtjevi (niska korelacija procesnih veličina i bogati informacijski i frekvencijski sadržaj), provedba mjerenja obuhvaćala bi kratka i intenzivna djelovanja HVAC sustava (impulsni odziv) po pojedinim dijelovima sustava. U primjeru, to bi značilo da se u zgradi isključi HVAC sustav i pusti da se sustav stabilizira u nekoj radnoj točki te zatim kratkotrajno uključiti samo jedan izvršni element HVAC sustava (npr. radijator) na maksimalnom intenzitetu i snimiti odziv sustava. Ovaj pokus bi trebalo ponoviti sa svim izvršnim elementima, zasebno i u određenim međusobnim kombinacijama.

Naravno, ovakve pokuse može biti teško provesti u životu. Alternativni pristup, koji se često koristi u istraživanjima, može biti razvoj toplinskog modela zgrade u nekom komercijalnom alatu za izradu modela (TrnSys, EnergyPlus, itd.; pogledati [109]) koji se onda koristi kao referentni model za izradu ulazno-izlaznih podataka.

U mnogim sličnim istraživanjima primjenjuje se pojam režima ili scenarija, kao određenog dijela cjelokupnog radnog područja procesa, pod čime se misli na kontekst meteoroloških uvjeta. Najčešće režimi jesu zimski, ljetni i prijelazni (proljeće i jesen). Treba voditi računa da toplinski sustav može imati bitno drugačije ponašanje u različitim režimima. S jedne strane, vrijednosti svojstava elemenata zgrade, materijala i dijelova HVAC sustava mogu biti ovisna o režimu rada, tako da parametri modela mogu imati različite vrijednosti u različitim režimima. S druge strane, u većini slučajeva HVAC sustav za grijanje nije isti kao HVAC sustav za hlađenje (npr. radijatori za grijanje po zimi i zračni sustav s hladnjakom zraka za hlađenje preko ljeta). Tako da je u nekim slučajevima potrebno ponavljati pokuse za različite režime, čak i izraditi više modela.

Četvrti korak, optimizacija ili prepodešavanje parametara modela, ima za cilj prepodesiti parametre modela dobivene u drugom koraku fizikalnim pristupom kako bi se model mogao što bolje iskoristiti u modelskom prediktivnom upravljanju (gdje kvaliteta upravljanja uvelike ovisi o kvaliteti modela). Nekoliko je razloga zašto parametre modela treba prepodesiti na temelju mjernih podataka:

- kod korištenja tabličnih podataka ili podataka proizvođača za dobivanje vrijednosti parametara, nikada nije moguće biti potpuno siguran jesu li podaci odgovarajući za određeni parametar (npr. osobito kod starih zgrada, teško je znati odgovara li stvarna situacija dostupnom građevinskom projektu)
- čak i kada su parametri odgovarajući, s vremenom može doći do promjene njihovih vrijednosti (starenje materijala)
- mnoga svojstva i procesi ovise o vanjskim uvjetima, a vrlo je složeno obuhvatiti sve faktore koji utječu na model.

Još jedna prednost hibridnog pristupa je što je njime moguće dobiti adaptivni (engl. *Online*) model, kod kojeg se parametri konstantno prepodešavaju. Ovo može zahtijevati prelazak na vremenski promjenjivi model:

$$\dot{\mathbf{x}}(t) = \mathbf{A}(t)\mathbf{x}(t) + \mathbf{B}(t)\mathbf{u}(t), \quad (4-3)$$

$$\mathbf{y}(t) = \mathbf{C}(t)\mathbf{x}(t) + \mathbf{D}(t)\mathbf{u}(t). \quad (4-4)$$

No može se i pretpostaviti da je model točan i konstantan neko vrijeme, a parametri (ili dio parametara) modela se periodički obnavljaju. Ovakav pristup zahtijeva dodatne napore u implementaciji, no može rezultirati većom dugotrajnošću sustava upravljanja i većom energetsom učinkovitosti kroz duži period, jer se upravljanje prilagođava promjenama sustava.

Prepodešavanje parametara moguće je izvršiti raznim numeričkim metodama za interpolaciju funkcija (engl. *Curve Fitting*). S obzirom da se ovdje radi o multivarijabilnoj interpolaciji velikih matrica, ovaj problem može biti vrlo zahtjevan.

Optimizaciju je potrebno provesti na sljedeći način:

$$f_R(\mathbf{A}_R, \mathbf{B}_R), \quad (4-5)$$

$$f_T(\mathbf{A}_T, \mathbf{B}_T), \quad (4-6)$$

$$\mathbf{y}_R = f_R(\mathbf{u}), \quad (4-7)$$

$$\mathbf{y}_T = f_T(\mathbf{u}), \quad (4-8)$$

$$\min_{\mathbf{A}_T, \mathbf{B}_T} (\mathbf{y}_R - \mathbf{y}_T). \quad (4-9)$$

Odnosno, postoje dva modela definirana svojim matricama stanja i ulaza: referentni model $f_R(\mathbf{A}_R, \mathbf{B}_R)$ koji predstavlja idealni model sustava (umjesto njega se može koristiti skup ulazno-izlaznih podataka dobiven mjerenjima), i testni (ili generički) model $f_T(\mathbf{A}_T, \mathbf{B}_T)$ čiji se parametri prepodešavaju. Također, postoji skup ulaznih podataka $\mathbf{u}$. Rezultat mjerenja izlaznih procesnih veličina (koji odgovara simulaciji idealnog referentnog modela koristeći ulazne podatke $\mathbf{u}$) je skup izlaznih podataka $\mathbf{y}_R$, dok simulacija testnog modela daje izlazne podatke $\mathbf{y}_T$. Potrebno je minimalizirati grešku testnog modela, odnosno razliku između $\mathbf{y}_R$ i $\mathbf{y}_T$, djelujući na parametre modela definirane u matricama $\mathbf{A}_T$ i $\mathbf{B}_T$.

Ovdje je potrebno voditi računa o namjeni modela, odnosno o razlici između simulacije i predviđanja (predikcije). Ako se model planira koristiti za simulacije, tada je bitno da model ima što manju grešku izlaza (simulacija sa stvarnim ulaznim podacima daje izlaze koji su što bliže stvarnim izlaznim podacima), dok je ponegdje bitno čak i ponašanje unutarnjih stanja modela. No

ako se model planira koristiti za upravljanje (npr. modelskom prediktivnom upravljanju), onda od primarnog interesa nije točnost simulacije, nego da model ima dobra prediktivna svojstva. To znači da model treba dati dobre rezultate (mala greška izlaza) čak i kada se koristi s ulaznim podacima iz drugačijeg radnog područja od onih koji su korišteni za određivanje vrijednosti parametara modela. Za ovakve modele se kaže da imaju dobro poopćavanje ili generalizaciju. Za detalje se može pogledati [110], a osobito pristranost (engl. *Bias*) i varijancu (engl. *Variance*) te njihov odnos (engl. *Bias-Variance Tradeoff*)

Također, predikcija se najčešće vrši za neki kratkoročni vremenski period (npr. 2, 6, 24 ili 48 sati, ovisno o izvedbi). S obzirom da su u ovom slučaju od interesa samo kvaliteta izlaza u kraćem periodu, može se izvršiti i pojednostavljenje modela. Kod složenih zgrada, gdje prepodešavanje parametara modela može zahtijevati vrlo velike računalne resurse, ovo je jedan od načina kako pojednostaviti i ubrzati optimizacijski problem

4.2. Kriteriji za prepodešavanje parametara modela

Prethodno je definiran cilj optimizacije (kriterijska funkcija) kao smanjivanje greške modela (4-9). No kao što je poznato iz numeričke matematike [30], postoji nekoliko načina kako se može definirati ova razlika, odnosno funkcija greške u kontekstu toplinskih modela [108].

Prvo, može se definirati funkcija greške kao ukupna greška (TOTAL, engl. *Total Error*) e_{TOTAL} , gdje je greška jednaka zbroju apsolutnih vrijednosti razlike svih vrijednosti izlaza referentnog y_R i testnog modela y_T :

$$e_{TOTAL} = \sum_{i=1}^Q \sum_{j=1}^K |y_R(i, j) - y_T(i, j)|, \quad (4-10)$$

gdje je Q broj izlaza, a K broj koraka simulacije (s obzirom da se mjeri ukupna razlika u nekom vremenskom rasponu). Radi o standardnoj apsolutnoj grešci.

Drugo, funkcija greške može se odrediti kao korijen srednje kvadratne greške (RMSE, engl. *Root Mean Square Error*) e_{RMSE} :

$$e_{RMSE} = \sqrt{\frac{\sum_{i=1}^Q \left(\sqrt{\frac{\sum_{j=1}^K (y_R(i, j) - y_T(i, j))^2}{K}} \right)^2}{Q}}. \quad (4-11)$$

Kod ovog tipa greške, računa se drugi korijen zbroja kvadrata vrijednosti razlike svih vrijednosti pojedinog izlaza referentnog y_R i testnog modela y_T , podijeljeno s broj koraka simulacije K , nakon čega su kvadrirani i zbrojeni rezultati za svaki izlaz, podijeljeni s brojem izlaza Q i iz ove vrijednosti je izračunat drugi korijen.

Treći način definiranje funkcije greške je normalizirani korijen srednje kvadratne greške (NRMSE, engl. *Normalized Root Mean Square Error*) e_{NRMSE} :

$$e_{NRMSE} = \sqrt{\frac{\sum_{i=1}^Q \left(\frac{\sqrt{\frac{\sum_{j=1}^K (y_R(i,j) - y_T(i,j))^2}{K}}}{\max_{i,j=1\dots K} y_R(i,j) - \min_{i,j=1\dots K} y_R(i,j)} \right)^2}{Q}} \quad (4-12)$$

Postupak računanja ove greške je sličan korijenu srednje kvadratne greške samo što se kod računanja greške za pojedini izlaz, korijen zbroja kvadrata razlike pojedinog izlaza podijeli još s razlikom najveće i najmanje vrijednosti tog izlaza. Na taj način greška se može izraziti u postotcima, čime je prikladna za uspoređivanje različitih skupova podataka (npr. ako se uspoređuje skupove različitih trajanja simulacije).

S obzirom da svaka od ovih funkcija greške ima prednosti i nedostatke, u nastavku se koriste sve tri funkcije greške za definiciju kriterijske funkcije koja se koristi kod minimalizacije (4-9).

4.3. Optimizacija parametara modela

Ovo potpoglavlje bavi se četvrtim korakom hibridne metode opisana u potpoglavlju 4.1. i jednadžbama (4-5) do (4-9), nakon što su definirani svi potrebni podaci za optimizaciju.

Referentni (idealni) model f_R u ovom slučaju nije definiran eksplicitno, u obliku prostora stanja, nego kao skup ulaznih i izlaznih podataka u i y_R . Ulazno-izlazni podaci mogu se dobiti mjerenjima na stvarnoj zgradi (vanjski ulazi temperature, utjecaj HVAC sustava te vrijednosti temperatura u prostorima). Alternativno, mogu se dobiti simulacijom referentnog modela zgrade dobivenog nekim drugim pristupom i metodama (npr. korištenjem eksperimentalne analize, korištenjem komercijalnih programa za izradu modela i slično).


Također, definiran je testni model y_T , u obliku prostora varijabli stanja, određen matricama A_T i B_T s početnim vrijednostima parametara.

4.3.1. Koraci optimizacije


Na slici 4.1. prikazan je osnovni dijagram toka MATLAB pomoćne aplikacije, a koji odgovara četvrtom koraku hibridne RC metode:

- učitavanje ulaznih podataka u (neupravljivi ulazi i upravljački ulazi) iz dokumenta s podacima za trening ili testiranje (iako se u aplikaciji mogu generirati i novi podaci)
- učitavanje izlaznih podataka y_R (snimljenih kao vremenska serija) ili referentnog modela (ModelBuilder datoteka s referentnim modelom koja se može iskoristiti za generiranje izlaznih podataka)
- učitavanje testnog modela y_T (ModelBuilder datoteka s testnim modelom)
- optimizacija testnog modela s ciljem smanjivanja greške modela (razlike izlaza simulacije testnog modela i izlaznih podataka)
- krajnji rezultat – prilagođeni ili optimizirani model (model iste strukture, ali s parametrima prepodešenim na temelju mjernih podataka).

Sučelje MATLAB aplikacije prikazano je na slici 4.2. Dijelovi sučelja koji predstavljaju korake iz dijagrama toka su podijeljeni u skupine, osim optimizacije koja je u istoj skupini s testnim modelom. U istoj skupini moguće je podešavati postavke optimizacije, kao što su funkcija greške i broj iteracija. Budući da je ovo pomoćna aplikacija, implementirani su i neki dodatni alati koji su pomogli kod istraživanja: crtanje grafova ulaza i izlaza, snimanje i učitavanje modela i podataka, podešavanje početnih stanja, izračun greške između izlaza referentnog i testnog modela, automatska analiza s izvozom u .csv format, itd.




Slika 4.1. Osnovni dijagram toka MATLAB pomoćne aplikacije za simuliranje i optimizaciju




Slika 4.2. Sučelje MATLAB pomoćne aplikacije

Ako se sada ponovno iskoristi mjerne podatke od 21. veljače do 26. veljače (s vremenskom konstantom od 3.600 sekundi i zanemarenim Sunčevim zračenjem, utjecajem uredskog dijela zgrade i toplinskim utjecajem rasvjete, strojeva i ljudi) te ako se za testni model 4R3C provede optimizacija koristeći funkciju greške NRMSE kao kriterijsku funkciju, broj ponavljanja 200.000 i *fminunc* "quasi-newton" algoritam (parametri optimizacije su detaljno objašnjeni u narednim poglavljima) te se nakon toga simulira prilagođeni model, dobivaju se sljedeće vrijednosti grešaka modela, prikazane u slikama 4.3. i 4.4. i tablici 4.1.:



Slika 4.3. Rezultati simulacije fizikalnog i prilagođenog 4R3C modela



Slika 4.4. Usporedba izlaznih podataka: mjerenja (puna crta), fizikalni model (crtkano) i prilagođeni model (točkano)

Tablica 4.1. *Usporedba mjerenja sa simulacijom fizikalnog i prilagođenog modela*

Model			Podaci o optimizaciji					
Referent. model	Testni model	Algoritam	MaxFun Evals	Funkcija greška	Trening podaci	Duljina simul.	Vremen. konst.	Trajanje optimiz.
mjerenja	realni model 4R3C	fminunc, quas-newt	200.000	NRMSE	zimski, 21.2.-26.2.	144	3600	0:06:27

Simulacija s trening podacima								
Greška mjer. - sim. fizikalni			Greška mjer. - sim. prilagođeni			Poboljšanje		
TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
9,12E+03	1,65E+01	5,22E+00	3,10E+02	7,02E-01	2,04E-01	29,43	23,54	25,61

U tablici 4.1. prikazani su podaci vezani uz optimizaciju i simulaciju (ili njih više) modela:

- koji referentni podaci ili model – u ovom slučaju mjerenja izlaznih podataka na zgradi
- koji testni model – u ovom slučaju realni model 4R3C dobiven fizikalnim pristupom i aplikacijom ModelBuilder (početne vrijednosti parametara)
- algoritam optimizacije – u ovom slučaju *fminunc* s "*quasi-newton*" algoritmom
- broj evaluacija optimizacije – u ovom slučaju 200.000 evaluacija
- koja funkcija greške se koristi kao kriterijska funkcija – u ovom slučaju *NRMSE*
- koji trening podaci za optimizaciju – u ovom slučaju mjerenja iz istog perioda kao i izlazni podaci
- trajanje simulacije – u ovom slučaju 144 sata (6 dana)
- vremenska konstanta uzorkovanja mjernih podataka (kod diskretnih sustava) – u ovom slučaju 3.600 sekundi (dakle, satna mjerenja)
- koliko je trajala optimizacija – u ovom slučaju 6 minuta i 48 sekundi na testnom računalu (Dell Latitude E6420 s Intel Core i7-2720QM procesorom, 8,00 GB RAM i diskom Samsung SSD 840 EVO 250GB)
- greška fizikalnog modela, odnosno modela s početnim vrijednostima parametara (zeleno), podijeljeno na TOTAL, RMSE i NRMSE grešku
- greška prilagođenog modela, odnosno modela s prepodešenim vrijednostima parametara (plavo), podijeljeno na TOTAL, RMSE i NRMSE grešku
- poboljšanje – koliko puta su rezultati prilagođenog modela bolji od rezultata fizikalnog modela (crveno), podijeljeno na TOTAL, RMSE i NRMSE grešku.

Ovakav oblik tablice se koristi za prikaz rezultata i u narednim poglavljima.

Ako se pogleda greške prilagođenog modela i usporedi ih se s greškama fizikalnog modela prikazanim na slici 4.1., može se uočiti da su rezultati puno bolji: vizualno, izlazi prilagođenog modela vjerno prate mjerene izlaze.

Treba napomenuti da su u ovoj tablici prikazani samo rezultati simulacije prilagođenog modela korištenjem podataka za simulaciju koji su identični podacima korištenim za prilagodbu modela (koristeći nomenklaturu verifikacije i validacije modela, ovi podaci se nazivaju podaci za trening, odnosno trening-podaci). Za ispravnu validaciju točnosti modela, potrebno je napraviti simulaciju prilagođenog modela korištenjem skupa podataka različitog od podataka korištenih za prilagodbu modela (ovi podaci se nazivaju podaci za testiranje ili test-podaci). Rezultati simulacije i usporedba rezultata fizikalnog i prilagođenog modela korištenjem podataka za testiranje su prikazani u 5. poglavlju, u tablicama identičnim ovoj (drugom dijelu tablice 4.1.), samo je u opisu tablice naglašeno o kojem skupu podataka se radi.

4.3.2. Matematički problem

Optimizacija je, kao što je već rečeno prije, ostvarena pomoću MATLAB funkcije *fminunc*. Definicija funkcije, kao što je definirano u MATLAB dokumentaciji (sustavu pomoći) [111] u "*fminunc – Find minimum of unconstrained multivariable function*" jest:

$$\min_x f(x), \quad (4-13)$$

gdje su:

- $f(x)$ – funkcija koja se minimalizira, u ovom slučaju $f(\mathbf{A}_T, \mathbf{B}_T) = \mathbf{y}_R - \mathbf{y}_T$
- x – parametar funkcije po kojem se ona optimizira, u ovom slučaju $(\mathbf{A}_T | \mathbf{B}_T)$ odnosno spojene matrice $\mathbf{A}_T$ i $\mathbf{B}_T$ jer *fminunc* funkcija prima samo jedan parametar za optimizaciju u ovoj implementaciji.

Implementacija ove funkcije u MATLAB okruženju je prikazana u algoritmu 4.1.

Algoritam 4.1. Implementacija optimizacije korištenjem *fminunc* funkcije

```

A_pocetni = A_test;
B_pocetni = B_test;
AB_pocetni = horzcat(A_pocetni, B_pocetni);

f = @(AB)tezinska_funkcija_prilagodba(AB, C_test, D_test, td,
referentni_izlazni_podaci, t, x0, ulazni_podaci, index_selected_funkcije_greske);

options = optimoptions(@fminunc, 'Display', 'iter', 'Algorithm', 'quasi-newton',
'MaxFunEvals', MaxFunEvals);
AB_prilagodeni = fminunc(f, AB_pocetni, options);

```

Funkcija *tezinska_funkcija_prilagodba* je funkcija cilja, odnosno težinska funkcija. Ona vraća grešku modela (ukupna greška *TOTAL*, korijen srednje kvadratne greške *RMSE* ili normalizirani korijen srednje kvadratne greške *NRMSE*, određeno ulazom *selected_funkcija_greske*), koristeći mjerne ulazne podatke za simulaciju modela i izlazne podatke za usporedbu. Funkcija *fminunc* pokušava minimalizirati tu grešku djelujući na (optimizirajući) matricu sustava *A* i ulaznu matricu *B* (ulaz *AB*, spojene matrice *A* i *B*).

Matrice *A_test*, *B_test*, *C_test* i *D_test* određuju fizikalni model koji se optimizira, *td* je vremenska konstanta uzorkovanja, *t* je vremenski raspon simulacije (odnosno ulaznih podataka), *x0* su početna stanja sustava i *ulazni_podaci* su ulazni podaci u sustav. Sve ove pomoćne varijable su potrebne da bi se simuliralo ponašanje testnog sustava za određeni skup ulaznih podataka unutar funkcije *tezinska_funkcija_prilagodba* (koja koristi MATLAB funkciju *lsim* za simulaciju).

Referentni model je određen skupovima ulaznih podataka (varijabla *ulazni_podaci*) i izlaznih podataka (varijabla *referentni_izlazni_podaci*) te dodatno varijablama *td* i *t* (koje određuju vremensku os podatka).

Varijabla *AB_pocetni* jednaka je spojenim matricama *A_test* i *B_test*, što znači da optimizacija kreće s ovim vrijednostima kao početnim točkama. Odnosno, početne vrijednosti parametara optimiziranog sustava su identične vrijednostima parametara fizikalnog modela. Ako ovo nije navedeno, optimizacija pretpostavlja da su početne vrijednosti parametara 0 (matrica *AB* je nul-matrica u početku). Iako ovo nije nužno, s dobro pogođenim početnim parametrima može se bitno skratiti vrijeme optimizacije.

Dodatno, ovdje su još određena specifična svojstva *fminunc* funkcije:

- '*Display*' = '*iter*' – uključeno prikazivanje trenutnih rezultata u svakom koraku optimizacije

- '*Algorithm*' = '*quasi-newton*' – odabrani algoritam optimizacije kvazi-Newton
- '*MaxFunEvals*' = *MaxFunEvals* – gdje je *MaxFunEvals* korisnički zadana varijabla koja određuje broj evaluacija funkcije (optimizacija unutar svakog koraka/iteracije obavlja više evaluacija).

Detaljan opis kvazi-Newtonovog algoritma može se naći [111] u "*Unconstrained Nonlinear Optimization Algorithms*" i u [30]. Kvazi-Newton algoritmi koriste informacije o zakrivljenosti kod svake iteracije da formuliraju kvadratni problem oblika:

$$\min_x \frac{1}{2} x^T \mathbf{H} x + \mathbf{c}^T x + b, \quad (4-14)$$

gdje je $\mathbf{H}$ takozvana Hessijan matrica, odnosno pozitivno definitna simetrična matrica, $\mathbf{c}$ je vektorska konstantna i b je skalarna konstanta.

Optimalno rješenje ovoga problema se otkriva kada je parcijalna derivacija x jednaka 0, odnosno:

$$\nabla f(x^*) = \mathbf{H}x^* + \mathbf{c} = 0. \quad (4-15)$$

Dakle, optimalno rješenje može se pisati kao:

$$x^* = -\mathbf{H}^{-1}\mathbf{c}. \quad (4-16)$$

Klasična Newtonova metoda računa Hessijan matricu izravno i napreduje prema padu vrijednosti da pronade minimum nakon nekog broja iteracija, što zahtijeva veliki broj izračuna. Kvazi-Newtonova metoda izbjegava ovo tako što koristi ponašanje $f(x)$ i $\nabla f(x)$ da stvori informacije o zakrivljenosti i izračuna aproksimaciju Hessijan matrice $\mathbf{H}$ koristeći odgovarajuću metodu izračuna (tzv. osvježavanje Hessijana).

Postoji mnogo metoda za osvježavanje Hessijana, no takozvana BFGS (Broyden, Fletcher, Goldfarb i Shanno) se smatra najučinkovitijom za opću upotrebu. Ona definira:

$$\mathbf{H}_{k+1} = \mathbf{H}_k + \frac{q_k q_k^T}{q_k^T s_k} - \frac{\mathbf{H}_k s_k s_k^T \mathbf{H}_k^T}{s_k^T \mathbf{H}_k s_k}, \quad (4-17)$$

gdje su:

$$s_k = x_{k+1} - x_k, \quad (4-18)$$

$$q_k = \nabla f(x_{k+1}) - \nabla f(x_k). \quad (4-19)$$

Kao početna točka, H_0 se može postaviti kao bilo koja pozitivno definitna matrica, na primjer jedinična matrica I .

4.3.3. Razlozi odabira funkcije, algoritma i parametara optimizacije

U MATLAB okruženju postoji nekoliko gotovih metoda koje se mogu koristiti za optimizaciju, ovisno o tipu optimizacijskog problema. U [111] u poglavlju "Optimization Decision Table" prikazana je tablica 4.2. koja daje prijedloge metoda ovisno o tipu problema.

Tablica 4.2. Algoritmi za optimizaciju u MATLAB okruženju

Tip ograničenja	Oblika modela				
	Linearni	Kvadratni	Najmanji kvadrati	Glatki nelinearni	Ne-glatki
Bez ograničenja	<i>n/a (f = const., or min = -∞)</i>	<i>quadprog</i>	<i>mldivide, lsqcurvefit, lsqnonlin</i>	<i>fminsearch, fminunc</i>	<i>fminsearch</i>
Ograničeni	<i>linprog</i>	<i>quadprog</i>	<i>lsqcurvefit, lsqlin, lsqnonlin, lsqnonneg</i>	<i>fminbnd, fmincon, fseminf</i>	<i>fminbnd</i>
Linearni	<i>linprog</i>	<i>quadprog</i>	<i>lsqlin</i>	<i>fmincon, fseminf</i>	/
Opće glatki	<i>fmincon</i>	<i>fmincon</i>	<i>fmincon</i>	<i>fmincon, fseminf</i>	/
Diskretni, s ograničenjima ili linearni	<i>intlinprog</i>	/	/	/	/

S obzirom na oblik modela (diskretni sustav s prikazom u obliku prostora varijabli stanja i vrlo velikim matricama) i svojstva (nelinearni) testnog modela, u MATLAB okruženju se može upotrijebiti nekoliko metoda za optimizaciju:

- *fminsearch* – pronalazi minimum neograničene multivarijabilne funkcije koristeći metodu bez derivacija (engl. *Derivative-Free*)
- *fminunc* – pronalazi minimum neograničene multivarijabilne funkcije (mogući algoritmi *Quasi-Newton* i *Trust Region*)
- *fmincon* – pronalazi minimum ograničene nelinearne multivarijabilne funkcije (mogući algoritmi *Interior Point*, *Sequential Quadratic Programming*, *Active Set* i *Trust Region Reflective*)

- *lsqnonlin* – rješava nelinearni problem najmanjih kvadrata (mogući algoritmi *Levenberg-Marquardt* i *Trust Region Reflective*).

Nakon opsežnog testiranja više algoritama prikazanog u prilogu P.5. Prikaz rezultata optimizacija s fokusom na metode optimizacije (sažetak prikazan u tablici 4.3.) te u prilogu P.6. Prikaz rezultata optimizacija s fokusom na odabir vremena uzorkovanja i razdiobu energije (sažetak prikazan u tablici 4.4.), vidljivo je da su jedina dva kandidata za optimizaciju metode *fminunc* i *fmincon*, dok sve ostale metode daju zanemariva poboljšanja prilagođenog modela. Metoda *fminunc* koristi se samo u izvedbi s *Quasi-Newton* algoritmom, dok *fmincon* omogućava korištenje *Interior-Point*, *Sequential Quadratic Programming (SQP)* i *Active Set* algoritama. Kod *fmincon* metode, od tri algoritma, algoritmi *Interior-Point* i *SQP* daju bitna i podjednaka poboljšanja prilagođenog modela. Također, kod *fmincon* funkcije mogu se postaviti ograničenja parametara, no rezultati pokazuju da se postavljanjem ograničenja vrijednosti parametara između -1 i 1 (što stvarno jest raspon koji vrijednosti parametri zauzimaju) ne dobiva ništa bolje rezultate optimizacije, a značajno se produljuje vrijeme optimizacije. Kada se u obzir uzmu rezultati iz priloga P.6., vidljivo je da je metoda *fminunc* (s algoritmom kvazi-Newton) najbolji odabir za metodu optimizacije.

Tablica 4.3. Sažetak priloga P.5. Prikaz rezultata optimizacije s fokusom na metode optimizacije

Model			Podaci o optimizaciji					
Ref. model	Test. model	Algoritam	MaxFun Evals	Funk. greške	Trening podaci	Dulj. sim.	Vrem. konst.	Trajanje optimiz.
mjerjenja	realni model 4R3C	fminsearch	200.000	NRMSE	zimski, 21.2.-26.2.	144	3.600	0:00:07
mjerjenja	realni model 4R3C	fminunc, quasi-newton	200.000	NRMSE	zimski, 21.2.-26.2.	144	3.600	0:06:27
mjerjenja	realni model 4R3C	fmincon, interior point, s ograničenjima -1...1	200.000	NRMSE	zimski, 21.2.-26.2.	144	3.600	0:49:07
mjerjenja	realni model 4R3C	fmincon, interior point, bez ograničenja	200.000	NRMSE	zimski, 21.2.-26.2.	144	3.600	0:30:57
mjerjenja	realni model 4R3C	fmincon, sqp, s ograničenjima -1...1	200.000	NRMSE	zimski, 21.2.-26.2.	144	3.600	8:28:57
mjerjenja	realni model 4R3C	fmincon, sqp, bez ograničenja	200.000	NRMSE	zimski, 21.2.-26.2.	144	3.600	0:09:33
mjerjenja	realni model 4R3C	fmincon, active-set, s ograničenjima -1...1		NRMSE	zimski, 21.2.-26.2.	144	3.600	
mjerjenja	realni model 4R3C	fmincon, active-set, bez ograničenja		NRMSE	zimski, 21.2.-26.2.	144	3.600	
mjerjenja	realni model 4R3C	lsqnonlin, 'levenberg-marquardt	200.000	NRMSE	zimski, 21.2.-26.2.	144	3.600	0:21:38

Simulacija s trening podacima								
Greška mjer. - sim. fizikalni			Greška mjer. - sim. prilagođeni			Poboljšanje		
TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
9,12E+03	1,65E+01	5,22E+00	9,08E+03	1,65E+01	5,20E+00	1,00	1,00	1,00
9,12E+03	1,65E+01	5,22E+00	3,10E+02	7,02E-01	2,04E-01	29,43	23,54	25,61
9,12E+03	1,65E+01	5,22E+00	1,93E+02	4,28E-01	1,36E-01	47,32	38,59	38,33
9,12E+03	1,65E+01	5,22E+00	1,50E+02	3,33E-01	9,69E-02	60,70	49,65	53,81
9,12E+03	1,65E+01	5,22E+00	1,32E+02	2,84E-01	8,54E-02	69,26	58,24	61,11
9,12E+03	1,65E+01	5,22E+00	1,41E+02	3,07E-01	9,21E-02	64,60	53,90	56,62
9,12E+03	1,65E+01	5,22E+00	/	/	/	/	/	/
9,12E+03	1,65E+01	5,22E+00	/	/	/	/	/	/
9,12E+03	1,65E+01	5,22E+00	1,91E+03	4,14E+00	1,26E+00	4,77	3,99	4,16

Tablica 4.4. Sažetak priloga P.6. Prikaz rezultata optimizacije s fokusom na odabir vremena uzorkovanja i razdiobu energije

Model			Podaci o optimizaciji					
Ref. model	Test. model	Algoritam	Max FunEva	Funk. greške	Trening podaci	Dulj. sim.	Vrem. konst.	Trajanje optimiz.
mjer.	realni model 4R3C	fmincon interior-point bez ogr.	2.000.000	NRMSE	zimski, 21.2.-26.2.	144	900	7:40:16
mjer.	realni model 4R3C	fminunc, quasi-newton, bez ogr.	2.000.000	NRMSE	zimski, 21.2.-26.2.	144	900	1:29:03
mjer.	realni model 2R1C	fmincon interior-point bez ogr.	655.703	NRMSE	zimski, 21.2.-26.2.	144	900	0:31:15
mjer.	realni model 2R1C	fminunc, quasi-newton, bez ogr.	524.887	NRMSE	zimski, 21.2.-26.2.	144	900	0:19:12
mjer.	realni model 4R3C	fmincon interior-point bez ogr.	2.000.000	NRMSE	zimski, 21.2.-26.2.	144	3.600	7:24:20
mjer.	realni model 4R3C	fminunc, quasi-newton, bez ogr.	1.677.144	NRMSE	zimski, 21.2.-26.2.	144	3.600	0:54:25
mjer.	realni model 2R1C	fmincon interior-point bez ogr.	655.204	NRMSE	zimski, 21.2.-26.2.	144	3.600	0:24:09
mjer.	realni model 2R1C	fminunc, quasi-newton, bez ogr.	510.516	NRMSE	zimski, 21.2.-26.2.	144	3.600	0:15:15
mjer.	realni model 4R3C	fmincon interior-point bez ogr.	2.000.000	NRMSE	zimski, 21.2.-26.2. raspodjela po radijatorima	144	3.600	7:42:59
mjer.	realni model 4R3C	fminunc, quasi-newton, bez ogr.	1.684.296	NRMSE	zimski, 21.2.-26.2. raspodjela po radijatorima	144	3.600	0:56:03
mjer.	realni model 2R1C	fmincon interior-point bez ogr.	655.271	NRMSE	zimski, 21.2.-26.2. raspodjela po radijatorima	144	3.600	0:26:37
mjer.	realni model 2R1C	fminunc, quasi-newton, bez ogr.	562.676	NRMSE	zimski, 21.2.-26.2. raspodjela po radijatorima	144	3.600	0:16:53
mjer.	realni model 4R3C	fmincon interior-point bez ogr.	2.000.000	NRMSE	zimski, 21.2.-26.2. raspodjela po radijatorima	144	900	7:26:53
mjer.	realni model 4R3C	fminunc, quasi-newton, bez ogr.	1.666.418	NRMSE	zimski, 21.2.-26.2. raspodjela po radijatorima	144	900	1:13:01
mjer.	realni model 2R1C	fmincon interior-point bez ogr.	277.805	NRMSE	zimski, 21.2.-26.2. raspodjela po radijatorima	144	900	0:12:03
mjer.	realni model 2R1C	fminunc, quasi-newton, bez ogr.	599.226	NRMSE	zimski, 21.2.-26.2. raspodjela po radijatorima	144	900	0:23:48

Simulacija s trening podacima								
Greška mjer. - sim. fizikalni			Greška mjer. - sim. prilagođeni			Poboljšanje		
TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	Δ TOTAL	Δ RMSE	Δ NRMSE
3,65E+04	1,65E+01	5,50E+00	1,74E+02	1,07E-01	3,49E-02	209,87	154,99	157,70
3,65E+04	1,65E+01	5,50E+00	2,57E+02	1,49E-01	4,79E-02	142,19	110,93	114,71
4,18E+04	1,85E+01	6,17E+00	2,16E+02	1,27E-01	4,14E-02	193,18	145,05	149,14
4,18E+04	1,85E+01	6,17E+00	2,39E+02	1,39E-01	4,45E-02	175,05	133,22	138,48
9,11E+03	1,65E+01	5,21E+00	4,14E+01	9,65E-02	2,89E-02	219,92	171,09	180,03
9,11E+03	1,65E+01	5,21E+00	6,19E+01	1,43E-01	4,25E-02	147,08	115,59	122,59
1,04E+04	1,85E+01	5,85E+00	3,70E+01	8,77E-02	2,63E-02	281,49	210,46	222,12
1,04E+04	1,85E+01	5,85E+00	4,25E+01	9,70E-02	2,91E-02	245,08	190,41	201,08
9,12E+03	1,65E+01	5,22E+00	3,86E+01	9,01E-02	2,70E-02	236,00	183,43	193,47
9,12E+03	1,65E+01	5,22E+00	6,48E+01	1,49E-01	4,43E-02	140,76	111,22	117,66
1,04E+04	1,85E+01	5,85E+00	3,75E+01	8,86E-02	2,68E-02	278,14	208,58	218,42
1,04E+04	1,85E+01	5,85E+00	4,06E+01	9,67E-02	2,89E-02	256,64	191,15	202,23
3,66E+04	1,66E+01	5,51E+00	1,74E+02	1,06E-01	3,47E-02	209,94	155,60	158,60
3,66E+04	1,66E+01	5,51E+00	2,66E+02	1,53E-01	4,95E-02	137,63	108,27	111,29
4,18E+04	1,85E+01	6,18E+00	2,77E+02	1,58E-01	5,14E-02	150,94	117,51	120,25
4,18E+04	1,85E+01	6,18E+00	2,11E+02	1,23E-01	4,02E-02	198,03	150,29	153,83

U prilogu P.6. može se vidjeti da ne postoji veliki utjecaj na rezultate od strane razdiobe energije po prostorima. Kao što je prikazano u poglavlju 3.3.4, jednadžba (3-37), omogućuje da se detaljnije modelira HVAC sustav, u smislu da je koeficijentom α razdioba energije prikazana otvorenošću dvoputnih ventila ispred radijatora u prostorima. No ovaj prikaz razdiobe energije ima nedostatke, jer osim same otvorenosti ventila, prijenos energije između radijatora i prostora dodatno ovisi o parametrima koji nisu obuhvaćeni koeficijentom α : relativna razlika između temperature radijatora i temperature prostora (što je veća razlika, više toplinske energije se prenosi s radijatora u prostor), brzini zraka u prostoru (iako radijatori dominantno prenose energiju zračenjem, utjecaj prijenosa prijelazom topline je isto bitan), duljinom radijatora (dulji radijatori u nekom prostoru znači da strana radijatora koji je udaljeniji od polaza tople vode treba više vremena da se ugrije na radnu temperaturu), i slično. Tako da koeficijent razdiobe α unosi samo dodatnu složenost u model, a ne opravdava je boljim rezultatima, što je vidljivo iz prikazanih rezultata.

Sljedeće što se može vidjeti iz priloga P.6. je ovisnost rezultata optimizacije o odabranom vremenu uzorkovanja. Ako se gledaju samo rezultati simulacije prilagođenog modela samo korištenjem istih podataka za trening, modeli koji su prilagođeni korištenjem podataka za uzorkovanjem od 3.600 sekundi (1 sat) daju bolje rezultate od drugih vrijednosti. No ako se gledaju ukupni rezultati, odnosno rezultati simulacije korištenjem raznih skupova testnih podataka, može

se vidjeti da podaci sa uzorkovanjem od 900 sekundi (15 minuta) daju najbolje rezultate. Dodano skraćivanje vremena uzorkovanja na 300 sekundi (5 minuta) ne daje dodatno poboljšanje rezultata.

Zaključno, za naredna testiranja prilagodbe koristi se metoda optimizacije *fminunc* s algoritmom kvazi-Newton (opisanim u poglavlju 4.3.2), s ulaznim podacima bez razdiobe energije i s vremenom uzorkovanja od 900 sekundi (odnosno 15 minuta).

5. VERIFIKACIJA HIBRIDNE METODE

U ovom poglavlju opisana je analiza rezultata više različitih modela, s fokusom za model dobiven hibridnom metodom, te kvaliteta predviđanja tih modela. Koristeći iste ulazno-izlazne podatke kao i kod hibridne metode, izrađena je umjetna neuronska mreža koja simulira zgradu. S obzirom na raširenost umjetnih neuronskih mreža u istraživanjima i navedenoj literaturi, ova ANN iskorištena je kao standardna metoda za usporedbu s rezultatima hibridne metode.

5.1. Kriteriji ocjene modela

U poglavlju 3.3.5., može se uočiti da su rezultati simulacije fizikalnog modela uspoređeni sa stvarnim mjerenjima na zgradi na subjektivan način, opisno: "relativno dobri" i "dosta loši". Iako je iz grafova očigledno da postoji određena razlika između rezultata, potrebno je osmisliti objektivnu i kvantitativnu metodu, odnosno kriterij za ocjenjivanje modela.

5.1.1. Kriterij složenosti

S obzirom da je složenost modela jedan od glavnih nedostataka RC metode, prvo je prikazan kriterij kojima se može ocjenjivati složenost modela.

Sama definicija složenosti ovisi o kontekstu u kojem se upotrebljava, a ocjena složenosti može biti vrlo teška. U ovom slučaju zanima od interesa jest složenost samog modela, no ujedno i računalna složenost, u smislu računalnih resursa koji su potrebni za optimizaciju i simulaciju modela, a osobito kod predviđanja.

Iz tih razloga, za ocjenu složenosti modela može se uzeti broj stanja sustava N , odnosno broj redova ili stupaca matrica A .

Vrijednost N određuje i računalne resurse. Što je taj broj veći, potrebno je više memorije za čuvanje vrijednosti parametara i stanja te više računalnih operacija (procesorske snage) za simulaciju modela. Bitno je reći da povećanjem broj stanja N broj elemenata u matrici raste kvadratnom brzinom.

5.1.2. Kriterij točnosti

U poglavlju 4.2. opisane su kriterijske funkcije koje se koriste za procjenu parametara modela na temelju podataka (4-10), (4-11) i (4-12). Njima je definirana točnost modela, u smislu greške izlaza, odnosno razlike između simulacije modela i mjernih vrijednosti izlaznih veličina (ili izlaznih veličina referentnog idealnog modela). Isti ti kriterij mogu se koristiti kao kriterij točnosti modela:

- ukupna greška e_{TOTAL}
- korijen srednje kvadratne greške e_{RMSE}
- normalizirani korijen srednje kvadratne greške e_{NRMSE} .

Treba voditi računa da je namjena termodinamičkog modela dobivenog hibridnom metodom korištenje u modelskom prediktivnom upravljanju. Tako da nije toliko bitno da model daje dobre rezultate simulacije, nego da ima dobra predikcijska svojstva ili dobro poopćavanje, odnosno da daje dobre izlaze (mala greška modela) čak i kada se za ulazne podatke koriste podaci iz radnog režima različitog od onog iz kojeg su podaci korišteni za prepodešavanje parametara modela.

S obzirom da svaka od ovih funkcija greške ima svoje prednosti i nedostatke, u nastavku se koriste sve tri funkcije greške kao kriterij točnosti za ocjenu kvalitete modela. No bitno je napomenuti da se samo NRMSE greška može koristiti za usporedbu greške modela kada su ulazni podaci različite duljine ili koriste ulazne podatke iz različitih režima rada (jer TOTAL i RMSE ovise o apsolutnim vrijednostima izlaza; iako i kod NRMSE ova ovisnost postoji, ona je puno manje izražena).

Osim ove tri funkcije, indikativno se može koristiti i maksimalna greška (MAX, engl. *Maximum Error*) e_{MAX} :

$$e_{MAX} = \max_{i=1\dots Q, j=1\dots K} |y_R(i, j) - y_T(i, j)|. \quad (5-1)$$

Ona je definirana kao najveći apsolutni iznos razlike svih vrijednosti izlaza referentnog y_R i testnog modela y_T , gledano na cijelom intervalu simulacije. Kod korištenja ovog tipa greške treba biti oprezan, jer uvelike ovisi o netipičnim ili odudarnim vrijednostima (engl. *Outliers*), no može poslužiti kao indikator točnosti odnosno kvalitete modela.

5.2. Analiza rezultata fizikalnog modela


Ponovno će se izvršiti analiza rezultata fizikalnog modela iz potpoglavlja 3.3.5. Sada je moguće objektivno usporediti rezultate mjerenja i rezultate fizikalnog modela, odnosno početnog modela dobivenog korištenjem aplikacije ModelBuilder i nazivnih vrijednosti parametara.

Ponovno se koriste ista mjerenja od 21. veljače do 26. veljače, dok se za model koristi fizikalni model (dakle, s početnim parametrima dobivenim teorijskom analizom i unesenim kroz aplikaciju ModelBuilder) tri razine složenosti: 4R3C, 3R2C i 2R1C. Rezultati su prikazani u tablici 5.1. i slikama 5.1. do 5.3.


Uspoređujući rezultate iz grafova i tablice, može se vidjeti da su sve tri varijante simulacije rezultirale sličnim vrijednostima grešaka (unutar 10% vrijednosti pojedine greške). Očekivano, najmanje greške dobivene su kod 4R3C varijante, no kod sva tri modela apsolutna odstupanja se kreću u rasponu od 16 do 18 °C, što znači da je model neupotrebljiv. U ovim fizikalnim modelima temperatura prostora najviše ovisi o vanjskoj temperaturi, što se osobito može primijetiti na slici 5.3., gdje već nakon nekoliko sati temperatura prostora odgovara vanjskoj temperaturi.

Tablica 5.1. Usporedba rezultata mjerenja i rezultata simulacije fizikalnog modela različite složenosti


Testni model	Broj stanja N	TOTAL	RMSE	NRMSE
4R3C	55	9.120,49	16,53	5,22
3R2C	38	10.150,10	18,08	5,72
2R1C	21	10.432,20	18,48	5,85



Slika 5.1. Usporedba rezultata mjerenja i rezultata simulacije fizikalnog modela složenosti 4R3C



Slika 5.2. Usporedba rezultata mjerenja i rezultata simulacije fizikalnog modela složenosti 3R2C



Slika 5.3. Usporedba rezultata mjerenja i rezultata simulacije fizikalnog modela složenosti 2R1C

5.3. Analiza rezultata prilagođenih modela

Osim odabira algoritma i parametara optimizacije, koji su opisani u potpoglavlju 4.3.3., postoje i drugi faktori koji utječu na rezultate prilagođenog modela. U [108] prikazana je analiza kako odabir funkcije greške za kriterijsku funkciju, broja ponavljanja optimizacije i složenost modela utječu na rezultate prilagođenog modela. U ovom poglavlju je prikazana slična analiza, no provedena na prilagođenom modelu dobivenom hibridnom metodom i koristeći mjerenja sa stvarne zgrade.

Kod svih ovdje prikazanih optimizacija, kao trening podaci su korištena mjerenja od 21. veljače do 26. veljače (6 dana, odnosno 144 sata), bez razdiobe energije i s vremenom uzorkovanja od 900 sekundi (odnosno 15 minuta) te metoda optimizacije *fminunc* s algoritmom kvazi-Newton. Kao testni podaci, korišteno je nekoliko skupova podataka koji predstavljaju različite režime rada:

- referentni podaci – ista mjerenja koja su korištena za optimizaciju, odnosno mjerenja od 21. do 27. veljače 2018. (6 dana, odnosno 144 sata), bez razdiobe energije i s vremenom uzorkovanja od 900 sekundi, s vanjskim temperaturama od -9 °C do 3 °C i normalnim režimom rada
- zimski skup 1 – mjerenja od 26. do 27. veljače 2018. (2 dana, odnosno 48 sati), bez razdiobe energije i s vremenom uzorkovanja od 900 sekundi, s vanjskim temperaturama od -9 °C do 0 °C i normalnim režimom rada
- zimski skup 2 – mjerenja od 28. veljače do 1. ožujka 2018. (2 dana, odnosno 48 sati), bez razdiobe energije i s vremenom uzorkovanja od 900 sekundi, s vanjskim temperaturama od -21 °C do 0 °C i normalnim režimom rada
- prijelazni skup 1 – mjerenja od 12. do 13. ožujka 2018. (2 dana, odnosno 48 sati), bez razdiobe energije i s vremenom uzorkovanja od 900 sekundi, s vanjskim temperaturama od 4 °C do 24 °C i normalnim režimom rada
- prijelazni skup 2 – mjerenja od 10. do 15. ožujka 2018. (6 dana, odnosno 144 sata), bez razdiobe energije i s vremenom uzorkovanja od 900 sekundi, s vanjskim temperaturama od 3 °C do 26 °C i normalnim režimom rada.

Normalni režim rada podrazumijeva uključen HVAC sustav i uobičajeni rad desetak zaposlenika u prvoj smjeni (od 7 do 15 sati). Postavljena vrijednost temperature (koju regulator pokušava postići) je 21 °C u prostoru montaže tokom dana i 18 °C tokom noći, te 18 °C u prostorima prijema i otpreme, mehaničke pripreme i skladišnog prostora tokom dana i 16 °C tokom noći.

Treba naglasiti da, iako je HVAC sustav aktivan i u zimskim i u prijelaznim skupovima (odnosno režimima), s obzirom da je u prijelaznim skupovima vanjska temperatura zraka puno viša, on radi manjim intenzitetom nego je to u zimskim skupovima, tako da su ova dva tipa režima različita po energiji unesenoj iz HVAC sustava. Također, s obzirom na relativno visoke temperature vanjskog zraka, veća je vjerojatno otvorenih prozora u prijelaznim režimima, što nije obuhvaćeno mjerenjima (niti se može spriječiti dok u zgradi ima korisnika, odnosno stanara).

Prvi eksperiment bavi se izborom funkcije greške koja se koristi za kriterijsku funkciju optimizacije. Iako sve tri funkcije greške koje su prikazane u poglavlju 4.2. (TOTAL, RMSE i NRMSE) opisuju isto (odstupanje rezultata simulacije prilagođenog modela od mjerenih podataka) i pri korištenju unutar funkcije cilja ponašaju se isto (cilj prepodešavanja je minimalizirati grešku), one prikazuju grešku na različit način i daju različite rezultate.


Ako se pogleda prilog P.7. Prikaz rezultata optimizacija s fokusom na metodu greške optimizacije (sažetak prikazan u tablici 5.2.), no i rezultate ostalih priloga, može se vidjeti da optimizacija koja koristi NRMSE funkcije greške kao kriterij funkcije cilja najčešće daje najbolje rezultate.


Na slikama 5.4. i 5.5. dan je grafički prikaz rezultata simulacije fizikalnog i prilagođenog modela (varijanta 4R3C), s detaljem rezultata simulacije prilagođenog modela na slici 5.6. Može se vidjeti da rezultati simulacije prilagođenog modela vrlo vjerno prate mjerenja, s vrlo malim odstupanjima (na razini 0,1 °C). Najveća odstupanja na cijelom rasponu (veća od 0,5 °C) su zapravo netipične vrijednosti (engl. *Outliers*, zaokružene crveno) koje su istaknute na detalju na slici 5.6. Ako se pogleda maksimalna greška između mjerenja i rezultata simulacije, ona iznosi 1,06 °C i nalazi se upravo na ovim netipičnim vrijednostima.

Tablica 5.2. Sažetak priloga P.7. Prikaz rezultata optimizacija s fokusom na metodu greške


Model			Podaci o optimizaciji					
Ref. model	Test. model	Algoritam	MaxFun Evals	Funk. greške	Trening podaci	Dulj. sim.	Vrem. konst.	Trajanje optimiz.
mjerjenja	realni model 4R3C	fminunc, quasi-newton	1.380.338	TOTAL	zimski, 21.2.-26.2.	144	900	1:04:29
mjerjenja	realni model 4R3C	fminunc, quasi-newton	60.794	RMSE	zimski, 21.2.-26.2.	144	900	0:02:44
mjerjenja	realni model 4R3C	fminunc, quasi-newton	1.795.154	NRMSE	zimski, 21.2.-26.2.	144	900	1:29:03
mjerjenja	realni model 2R1C	fminunc, quasi-newton	88.679	TOTAL	zimski, 21.2.-26.2.	144	900	0:05:36
mjerjenja	realni model 2R1C	fminunc, quasi-newton	453.848	RMSE	zimski, 21.2.-26.2.	144	3.600	0:16:55
mjerjenja	realni model 2R1C	fminunc, quasi-newton	524.887	NRMSE	zimski, 21.2.-26.2.	144	3.600	0:19:12

Simulacija s trening podacima								
Greška mjer. - sim. fizikalni			Greška mjer. - sim. prilagođeni			Poboljšanje		
TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
3,65E+04	1,65E+01	5,50E+00	2,93E+02	1,75E-01	5,83E-02	124,67	94,41	94,35
3,65E+04	1,65E+01	5,50E+00	9,85E+03	5,16E+00	1,63E+00	3,71	3,21	3,37
3,65E+04	1,65E+01	5,50E+00	2,57E+02	1,49E-01	4,79E-02	142,19	110,93	114,71
4,18E+04	1,85E+01	6,17E+00	/	/	/	/	/	/
4,18E+04	1,85E+01	6,17E+00	3,56E+02	1,94E-01	6,46E-02	117,51	95,14	95,49
4,18E+04	1,85E+01	6,17E+00	2,39E+02	1,39E-01	4,45E-02	175,05	133,22	138,48

**Slika 5.4.** Rezultati fizikalnog modela 4R3C u zimskom skupu Referentni podaci



Slika 5.5. Rezultati prilagođenog modela 4R3C u zimskom skupu Referentni podaci



Slika 5.6. Detalj simulacije prilagođenog modela 4R3C u zimskom skupu Referentni podaci

Drugi eksperiment uspoređuje rezultate modela u ovisnosti o broju ponavljanja optimizacije (određeno parametrom 'MaxFunEvals' funkcije optimizacije *fminunc*). Naravno, logično je očekivati da je rezultat ovisi proporcionalno o broju ponavljanja optimizacije. Ako se pogledaju

rezultati prikazani u prilogu P.8. Prikaz rezultata optimizacija s fokusom na broj ponavljanja optimizacije (sažetak prikazan u tablici 5.3.), vidi se da je ovo očekivanje točno. U grafičkom prikazu na slici 5.7. koja prikazuje odnos NRMSE kriterija i broja ponavljanja može se primijetiti kako se greška asimptotski smanjuje povećavanjem broja ponavljanja optimizacije. Na slici 5.8. prikazana je ovisnost trajanja optimizacije o broju ponavljanja, gdje se trajanje optimizacije očekivano povećava s brojem ponavljanja optimizacije.


Također, može se vidjeti da za ovaj model (4 prostorijske, 10 ulaza, 4 izlaza), ovisno o razini složenosti modela, maksimalan broj ponavljanja optimizacije iznosi oko 1.795.000 ponavljanja za 4R3C model i oko 525.000 ponavljanja za 2R1C model. Ako se ne mijenjaju ostali parametri koji utječu na broj ponavljanja (*MaxFunctionEvaluations*, *MaxIterations*, *StepTolerance*, *ObjectiveLimit*; više detalja u [111]), metoda *fminunc* na tom broju ponavljanja dostiže najbolje moguće rezultate.

Tablica 5.3. Sažetak priloga P.8. Prikaz rezultata optimizacija s fokusom na broj ponavljanja optimizacije


Model			Podaci o optimizaciji					
Ref. model	Test. model	Algoritam	MaxFun Evals	Funk. greške	Trening podaci	Dulj. sim.	Vrem. konst.	Trajanje optimiz.
mjerjenja	realni model 4R3C	fminunc, quasi-newton	50.000	NRMSE	zimski, 21.2.-26.2.	144	900	0:02:24
mjerjenja	realni model 4R3C	fminunc, quasi-newton	100.000	NRMSE	zimski, 21.2.-26.2.	144	900	0:04:33
mjerjenja	realni model 4R3C	fminunc, quasi-newton	200.000	NRMSE	zimski, 21.2.-26.2.	144	900	0:09:30
mjerjenja	realni model 4R3C	fminunc, quasi-newton	500.000	NRMSE	zimski, 21.2.-26.2.	144	900	0:22:21
mjerjenja	realni model 4R3C	fminunc, quasi-newton	1.000.000	NRMSE	zimski, 21.2.-26.2.	144	3.600	0:45:42
mjerjenja	realni model 4R3C	fminunc, quasi-newton	1.795.154	NRMSE	zimski, 21.2.-26.2.	144	3.600	1:29:03
mjerjenja	realni model 2R1C	fminunc, quasi-newton	50.000	NRMSE	zimski, 21.2.-26.2.	144	900	0:01:58
mjerjenja	realni model 2R1C	fminunc, quasi-newton	100.000	NRMSE	zimski, 21.2.-26.2.	144	900	0:03:59
mjerjenja	realni model 2R1C	fminunc, quasi-newton	200.000	NRMSE	zimski, 21.2.-26.2.	144	900	0:07:52
mjerjenja	realni model 2R1C	fminunc, quasi-newton	500.000	NRMSE	zimski, 21.2.-26.2.	144	900	0:19:34
mjerjenja	realni model 2R1C	fminunc, quasi-newton	524.887	NRMSE	zimski, 21.2.-26.2.	144	3.600	0:19:12

Simulacija s trening podatcima								
Greška mjer. - sim. fizikalni			Greška mjer. - sim. prilagođeni			Poboljšanje		
TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
3,65E+04	1,65E+01	5,50E+00	1,05E+04	5,56E+00	1,71E+00	3,48	2,98	3,21
3,65E+04	1,65E+01	5,50E+00	4,48E+03	2,29E+00	7,40E-01	8,16	7,21	7,44
3,65E+04	1,65E+01	5,50E+00	1,17E+03	6,65E-01	2,04E-01	31,34	24,86	26,89
3,65E+04	1,65E+01	5,50E+00	5,29E+02	2,88E-01	8,90E-02	69,04	57,33	61,78
3,65E+04	1,65E+01	5,50E+00	3,29E+02	1,85E-01	5,97E-02	111,16	89,61	92,08
3,65E+04	1,65E+01	5,50E+00	2,57E+02	1,49E-01	4,79E-02	142,19	110,93	114,71
4,18E+04	1,85E+01	6,17E+00	1,70E+04	9,03E+00	3,04E+00	2,47	2,05	2,03
4,18E+04	1,85E+01	6,17E+00	5,10E+03	3,76E+00	1,29E+00	8,19	4,91	4,78
4,18E+04	1,85E+01	6,17E+00	1,14E+03	7,00E-01	2,39E-01	36,56	26,43	25,77
4,18E+04	1,85E+01	6,17E+00	2,39E+02	1,39E-01	4,46E-02	174,62	132,85	138,27
4,18E+04	1,85E+01	6,17E+00	2,39E+02	1,39E-01	4,45E-02	175,05	133,22	138,48

Simulacija s testnim skupom Zimski skup 2 (od 28.2. do 1.3.)								
Greška mjer. - sim. fizikalni			Greška mjer. - sim. prilagođeni			Poboljšanje		
TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
1,23E+04	1,79E+01	4,81E+00	6,30E+03	1,07E+01	3,09E+00	1,95	1,68	1,56
1,23E+04	1,79E+01	4,81E+00	5,24E+03	8,05E+00	2,25E+00	2,35	2,22	2,13
1,23E+04	1,79E+01	4,81E+00	9,55E+02	1,49E+00	3,44E-01	12,85	11,98	13,97
1,23E+04	1,79E+01	4,81E+00	1,20E+03	1,68E+00	4,00E-01	10,25	10,66	12,01
1,23E+04	1,79E+01	4,81E+00	7,22E+02	1,05E+00	2,45E-01	17,00	17,00	19,65
1,23E+04	1,79E+01	4,81E+00	9,45E+02	1,34E+00	2,97E-01	13,00	13,33	16,17
1,88E+04	2,56E+01	6,70E+00	5,43E+03	9,86E+00	2,43E+00	3,46	2,60	2,76
1,88E+04	2,56E+01	6,70E+00	5,98E+03	9,67E+00	2,37E+00	3,14	2,65	2,82
1,88E+04	2,56E+01	6,70E+00	1,08E+03	1,74E+00	4,26E-01	17,40	14,75	15,73
1,88E+04	2,56E+01	6,70E+00	7,79E+02	1,14E+00	2,42E-01	24,11	22,50	27,67
1,88E+04	2,56E+01	6,70E+00	7,83E+02	1,15E+00	2,44E-01	23,97	22,36	27,49



Slika 5.7. Usporedba rezultata simulacije prema broju ponavljanja optimizacije



Slika 5.8. Usporedba trajanja optimizacije prema broju ponavljanja optimizacije

No također, može se vidjeti da NRMSE asimptotski približava nuli (odnosno, kvaliteta modela raste) s brojem ponavljanja optimizacije, te da isto vrijedi za trajanje optimizacije. Ovo znači da, kada bi se i broj ponavljanja optimizacije mogao povećati mijenjanjem ostalih parametara *fminunc* metoda, to ne bi nužno dovelo do značajnog poboljšanja optimiziranog modela.

Također, ako se pogledaju rezultati simulacije prilagođenog modela korištenjem testnog skupa Zimski skup 2, može se vidjeti da najbolji rezultati nisu dobiveni kod korištenjem najvećeg broja optimizacija, nego kod modela koji su "manje optimizirani". Razlog tome je što se povećanjem broja ponavljanja optimizacije parametri modela prilagođavaju ili specijaliziraju prema skupu za treniranje. Ako postoji bitna razlika (različiti režimi rada) između skupa za treniranje i skupa za testiranje (u ovom slučaju opseg vrijednosti vanjske temperature i unos energije iz HVAC sustava), može doći do situacije gdje model koji je više prilagođen daje lošije rezultate od modela koji je manje prilagođen skupu za treniranje (što se dogodilo u ovom slučaju). Ovo se još naziva pretjerano usklađivanje modela na podatke za treniranje (*engl. Overfitting*). Za modele koji imaju dobro vladanje (malu grešku) i s podacima iz različitih radnih režima, kaže se da imaju dobro poopćavanje, o čemu je već bilo riječi u potpoglavlju 4.1.

Također, ako se optimizacija (prepodešavanje parametara) vrši kontinuirano za vrijeme rada (npr. kod adaptivnih modela) ili na slabijoj računalnoj opremi, treba odvagati da li bolji rezultati modela opravdavaju dodatno vrijeme (i resurse) optimizacije.

Može se donijeti zaključak da vrijedi općenito pravilo "više ponavljanja, bolji rezultati", ali da odgovarajući broj ponavljanja treba odrediti od slučaja do slučaja.

U trećem eksperimentu uspoređeni su rezultati modela prema složenosti modela, u ovom slučaju određeno odabranom složenošću reprezentacije jednog zida u varijantama 4R3C, 3R2C i 2R1C, koji su dostupni u ModelBuilder aplikaciji. U prilogu P.9. Prikaz rezultata optimizacija s fokusom na složenost modela (sažetak prikazan u tablici 5.4.), odnosno grafički na slikama 5.9. i 5.10., prikazani su rezultati simulacije modela u svim režimima rada.

Tablica 5.4. Sažetak priloga P.9. Prikaz rezultata optimizacija s fokusom na složenost modela

Model			Podaci o optimizaciji					
Ref. model	Test. model	Algoritam	MaxFun Evals	Funk. greške	Trening podaci	Dulj. sim.	Vrem. konst.	Trajanje optimiz.
mjerjenja	realni model 4R3C	fminunc, quasi-newton	1.795.154	NRMSE	zimski, 21.2.-26.2.	144	900	1:29:03
mjerjenja	realni model 3R2C	fminunc, quasi-newton	1.677.185	NRMSE	zimski, 21.2.-26.2.	144	900	1:08:18
mjerjenja	realni model 2R1C	fminunc, quasi-newton	524.887	NRMSE	zimski, 21.2.-26.2.	144	900	0:19:12


Simulacija s trening podacima								
Greška mjer. - sim. fizikalni			Greška mjer. - sim. prilagođeni			Poboljšanje		
TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
3,65E+04	1,65E+01	5,50E+00	2,57E+02	1,49E-01	4,79E-02	142,19	110,93	114,71
4,07E+04	1,81E+01	6,03E+00	1,91E+02	1,16E-01	3,78E-02	212,58	156,35	159,57
4,18E+04	1,85E+01	6,17E+00	2,39E+02	1,39E-01	4,45E-02	175,05	133,22	138,48

Simulacija s testnim skupom Zimski skup 1 (od 26.2. do 27.2.)								
Greška mjer. - sim. fizikalni			Greška mjer. - sim. prilagođeni			Poboljšanje		
TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
1,16E+04	1,62E+01	5,74E+00	2,21E+02	3,67E-01	1,25E-01	52,50	44,06	45,94
1,51E+04	2,03E+01	7,31E+00	4,19E+02	6,64E-01	2,34E-01	35,98	30,61	31,22
1,61E+04	2,15E+01	7,74E+00	3,49E+02	5,80E-01	1,97E-01	46,12	37,01	39,36


Simulacija s testnim skupom Zimski skup 2 (od 28.2. do 1.3.)								
Greška mjer. - sim. fizikalni			Greška mjer. - sim. prilagođeni			Poboljšanje		
TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
1,23E+04	1,79E+01	4,81E+00	9,45E+02	1,34E+00	2,97E-01	13,00	13,33	16,17
1,71E+04	2,38E+01	6,27E+00	9,41E+02	1,35E+00	3,03E-01	18,21	17,61	20,67
1,88E+04	2,56E+01	6,70E+00	7,83E+02	1,15E+00	2,44E-01	23,97	22,36	27,49

Simulacija s testnim skupom Prijelazni skup 1 (od 12.3. do 13.3.)								
Greška mjer. - sim. fizikalni			Greška mjer. - sim. prilagođeni			Poboljšanje		
TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
3,42E+03	5,03E+00	3,03E+00	2,66E+02	4,27E-01	2,77E-01	12,83	11,78	10,94
4,35E+03	6,43E+00	3,99E+00	4,07E+02	6,81E-01	4,62E-01	10,69	9,44	8,65
4,58E+03	6,94E+00	4,34E+00	3,12E+02	5,33E-01	2,72E-01	14,69	13,02	15,95

Simulacija s testnim skupom Prijelazni skup 2 (od 10.3. do 15.3.)								
Greška mjer. - sim. fizikalni			Greška mjer. - sim. prilagođeni			Poboljšanje		
TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
1,41E+04	6,59E+00	3,08E+00	1,03E+03	5,93E-01	2,57E-01	13,68	11,11	11,97
1,56E+04	7,45E+00	3,49E+00	2,19E+03	1,13E+00	5,78E-01	7,16	6,60	6,04
1,62E+04	7,84E+00	3,69E+00	2,10E+03	1,13E+00	5,05E-01	7,72	6,96	7,29




Slika 5.9. Usporedba rezultata simulacije prema složenosti modela




Slika 5.10. Usporedba trajanja optimizacije prema složenosti modela

Na slikama 5.11. i 5.12. dan je grafički prikaz rezultata simulacije 4R3C i 2R1C modela u testnom skupu Zimski skup 1.



Slika 5.11. Rezultati simulacije 4R3C modela u testnom skupu Zimski skup 1



Slika 5.12. Rezultati simulacije 2R1C modela u testnom skupu Zimski skup 1

Očekivani rezultat je bio da složeniji modeli daju bolje rezultate od jednostavnijih modela. No rezultati ovog eksperimenta pokazuju da to nije potpuno točno. Tako je 4R3C dao najbolji rezultat

u 2 slučaja, 3R1C samo jednom, a 2R1C čak 3 puta (iako su rezultati bili gotovo jednaki rezultatima 4R3C modela). Također, najjednostavniji model 2R1C ima očitu prednost u trajanju optimizacije, čak 5 puta kraće od 4R3C modela i 4 puta kraće od 3R2C modela. Može se donijeti zaključak da složenost modela nije presudna na rezultate simulacije, što je suprotno očekivanju. No prije potvrde ovog zaključka potrebno je obaviti još eksperimenata i dodatnih istraživanja, za što je potrebno više mjernih podataka u različitim režimima rada.

5.4. Kvaliteta predviđanja prilagođenog modela

Kao što je već spomenuto u poglavlju 4.1, postoji razlika kada se model planira koristiti za općenite simulacije, a kada se planira koristiti za predviđanje budućih stanja sustava, na primjer u modelskom prediktivnom upravljanju. Kod simulacije, na model se primjenjuje neki skup ulaznih podataka da bi se dobili izlazni podaci (i stanja, ako se to želi) i bitna je točnost simuliranih izlaznih podataka i stanja za neki vremenski period. No kada se radi o predviđanju, odnosno predikciji, tada je bitna kvaliteta procjene budućih izlaza za neki (najčešće kraći) vremenski period, i to često s nepotpunim ili nepreciznim ulaznim podacima ili s podacima koji su iz drugačijeg radnog režima nego oni s kojima su određeni parametri modela (ako se radi određivanje parametara modela na temelju podataka). Predikcija se može raditi čak i samo na temelju prošlih vrijednosti izlaznih stanja. Ako se podaci predviđaju za neki duži period, tada se radi o prognozi ili predskazivanju (engl. *Forecasting*).


U kontekstu toplinskih modela u zgradama i HVAC sustavima, predviđanje je temelj modelskog prediktivnog upravljanja. Konkretno, u svakom koraku MPC-a radi se predviđanje izlaza na temelju procjene i predviđanja neupravljivih ulaza (npr. vremenska prognoza s podacima o temperaturi, vjetru, Sunčevoj radijaciji i sl. u narednom periodu) te na temelju upravljačkih ulaza (ulaza energije iz HVAC sustava) koje MPC pokušava minimalizirati, s ciljem održavanja vrijednosti izlaza oko nekih zadanih vrijednosti (engl. *tracking*).

To znači da u tom slučaju nije toliko bitna točnost simulacije, nego može biti važnija kvaliteta predviđanja ponašanja sustava u sljedećih nekoliko koraka. Tako na primjer, model koji daje bolje (točnije) rezultate u sljedećih sat vremena, a potpuno je netočan nakon 12 sati, može biti korisniji u modelskom prediktivnom upravljanju od modela koji daje dobre rezultate kroz cijeli vremenski period (znači, lošiji je unutar sat vremena, ali ukupno bolji unutar 12 sati).

Također treba naglasiti da kvaliteta predviđanja uvelike ovisi o kvaliteti ulaznih podataka koji se unose u model. Čak i ako je model savršeno precizan i odražava stanje sustava, ako se u njega

unesu krivi ulazi podaci, dati će krive rezultate. Kod praktičnih primjena MPC-a, dio podataka koji se koriste kao ulazni podaci su najčešće i sami rezultat predviđanja (npr. predviđanje vanjske temperature u slijedećim satima).

Da bi se testirala kvaliteta predviđanja, izrađena je još jedna pomoćna aplikacija u MATLAB okruženju. Ona je temeljena na aplikaciji koja se koristila za simulaciju i optimizaciju modela (korištena u prethodnim poglavljima) i prikazana je na slici 5.13. Razlika od aplikacije za simulaciju je što ova aplikacija u svakom koraku radi simulaciju ulaza za zadanih sljedećih n sati i crta ih. Zato se na grafu može vidjeti raspršenje (rasap, disperzija) rezultata oko svake točke.



Slika 5.13. Pomoćna MATLAB aplikacija za predviđanje pomoću prilagođenog modela

Treba naglasiti da se ovdje primijenilo dva bitna pojednostavljenja:

1. Za ulazne podatke korišteni su isti podaci kao i kod simulacije, odnosno mjerenja na zgradi, tako da je predviđanje vrijednosti ulaza savršeno.
2. S obzirom da na testnoj zgradi ne postoje mjerenja vrijednosti temperatura koje predstavljaju stanja sustava (temperature ploha zidova i sl.), nego samo mjerenja izlaznih veličina, za vrijednosti stanja u nekom koraku od kojeg kreće predviđanje korišten je prosjek vrijednosti izlaza. Ovo rješenje je korišteno i kod aplikacije za simulacije, no u tom slučaju se ono koristi samo jednom, za izračun početnih stanja sustava. Ovdje se procijenjena početna stanja koriste u svakom koraku predviđanja.

Za određivanje kvalitete predviđanja, odnosno odstupanje predikcije od mjerenih vrijednosti, koriste se dvije funkcije greške: ukupna greška (TOTAL) i maksimalna pogreška (MAX), na način da se one računaju u svakom koraku predviđanja i zbrajaju (kod ukupne greške), odnosno uspoređuju (kod maksimalne greške). S obzirom da su funkcije greške korijen srednje kvadratne greške (RMSE) i normalizirani korijen srednje kvadratne greške (NRMSE) nelinearne funkcije, nije ih moguće zbrajati tako da one nisu upotrebljive u ovom slučaju.

Također, kod ukupne greške potrebno je zbroj grešaka podijeliti s brojem sati predikcije n . Kada se radi predviđanje za jedan sat, ukupna greška je zbroj grešaka predviđanja svakog sata. No kada se radi predviđanje za dva sata, ukupna greška je zbroj grešaka predviđanja svaka dva sata. Da bi se ove dvije vrijednosti mogle usporediti, potrebno je ukupnu grešku u drugom slučaju podijeliti s dva. Isto vrijedi i za druge vrijednosti sati predikcije n . Tako se dolazi do prosječne ukupne greške (e_{TOTAL_AVRG}):

$$e_{TOTAL_AVRG} = \frac{\sum TOTAL(n)}{n}. \quad (5-2)$$

U tablici 5.5. prikazani su rezultati predviđanja za iste ulazne i izlazne podatke za sve do sada spomenute skupove testnih podataka, odnosno sažetak priloga P.10. Prikaz rezultata predviđanja korištenjem prilagođenog modela.

Tablica 5.5. *Rezultati predviđanja pomoću hibridne metode*


fminunc, 4R3C	Trening podaci, 4R3C		Prijelazni skup 2 (od 10.3. do 15.3.), 4R3C		Zimski skup 1 (od 26.2. do 27.2.), 4R3C		Zimski skup 2 (od 28.2. do 1.3.), 4R3C		Prijelazni skup 1 (od 12.3. do 13.3.), 4R3C	
	TOT _{Avrg}	MAX	TOT _{Avrg}	MAX	TOT _{Avrg}	MAX	TOT _{Avrg}	MAX	TOT _{Avrg}	MAX
1	3.653	1,74	2.666	1,40	1.518	1,79	1.875	6,94	923	1,40
2	3.526	1,95	2.771	1,63	1.548	2,04	1.792	6,98	946	1,55
3	3.506	2,00	2.837	1,63	1.580	2,10	1.729	6,81	956	1,55
4	3.532	2,12	2.834	1,63	1.609	2,12	1.676	6,54	944	1,55
6	3.669	2,49	2.772	1,63	1.675	2,49	1.621	6,16	914	1,55
12	4.067	2,73	2.920	1,55	1.680	2,73	1.628	6,35	882	1,55
24	4.048	2,13	3.387	1,69	1.390	2,89	1.057	7,57	799	1,69
48	4.171	2,13	2.938	1,84	0	0,00	0	0,00	0	0,00

fminunc, 2R1C	Trening podaci, 2R1C		Prijelazni skup 2 (od 10.3. do 15.3.), 2R1C		Zimski skup 1 (od 26.2. do 27.2.), 2R1C		Zimski skup 2 (od 28.2. do 1.3.), 2R1C		Prijelazni skup 1 (od 12.3. do 13.3.), 2R1C	
	TOT _{Avrg}	MAX	TOT _{Avrg}	MAX	TOT _{Avrg}	MAX	TOT _{Avrg}	MAX	TOT _{Avrg}	MAX
1	3.633	1,65	3.485	2,27	1.560	1,72	1.743	6,45	1.195	2,27
2	3.120	1,65	2.998	2,27	1.350	1,72	1.477	6,47	959	2,27
3	3.031	1,66	2.829	2,27	1.309	1,72	1.412	6,18	879	2,27
4	3.015	1,66	2.745	2,27	1.287	1,72	1.365	5,76	837	2,27
6	3.083	1,85	2.674	2,27	1.280	1,85	1.348	5,20	808	2,27
12	3.489	2,23	3.045	2,27	1.313	2,23	1.441	5,33	917	2,25
24	3.667	2,20	4.078	2,88	969	2,23	976	6,67	939	2,67
48	3.730	2,20	4.132	3,17	0	0,00	0	0,00	0	0,00


Potrebno je naglasiti nekoliko detalja:

- Kod testnih skupova duljine 2 dana, odnosno 48 sati, predviđanje 48 sati unaprijed nema smisla. Razlog je što pomoćna MATLAB aplikacija napravljena tako da može predviđati samo do 48. sata, jer nakon toga nema referentnih (mjernih) podataka s kojima bi uspoređivala predviđanja.
- Također, opet kod skupove duljine 48 sati, pojavljuje se dodatna greška pri većim vrijednostima broja sati predviđanja. Opet, razlog tome je što aplikacija vrši predviđanja samo do 48. sata. Tako da, na primjer, kod vrijednosti broja sata predviđanja, nakon 24. sata aplikacija vrši predviđanja za manje od 24 sata unaprijed, čime se prividno smanjuje vrijednost prosječne ukupne pogreške. Iz toga razloga, kod vrijednosti broja sati predviđanja ne treba uspoređivati prosječnu ukupnu grešku. Ovo prividno smanjivanje postoji i kod manjih vrijednosti broja sati predviđanja, ali je puno manje i može ga se zanemariti. Također, ovo ne utječe izravno na vrijednost maksimalne greške.


Na slikama 5.14. do 5.17. prikazana je grafička usporedba kvalitete predviđanja ovisno o broju sati predviđanja, odnosno prosječna ukupna greška za skupove duljine 2 i 6 dana te maksimalna greška za skupove duljine 2 i 6 dana.




Slika 5.14. Usporedba prosječne ukupne greške za scenarije trajanja 6 dana



Slika 5.15. Usporedba prosječne ukupne greške za scenarije trajanja 2 dana



Slika 5.16. Usporedba maksimalne greške za scenarije trajanja 6 dana



Slika 5.17. Usporedba maksimalne greške za scenarije trajanja 2 dana

Iz tabličnog i grafičkog prikaza usporedbe kvalitete predviđanja može se primijetiti jedna prividna nelogičnost. Očekivalo bi se da kvaliteta predviđanja pada (odnosno da greške rastu) s vrijednošću broja sati predviđanja. No kod prosječne ukupne greške primjećuje se da greška oštro pada dok broj sati predviđanja raste s jedan na dva sata te nakon toga ponovno lagano raste. Razlog ovom oštrom padu je što se pri predviđanju za početne vrijednosti stanja sustava koristi prosječna vrijednost temperature svih prostora. S obzirom da ovo zasigurno nije točno, jer time se unosi određena početna greška. Kada se radi predviđanje za jedan sat unaprijed, ona je znatna. No pri predviđanje za više sati unaprijed, ona gubi na važnosti (jer se dijeli s brojem sati predviđanja kod izračuna prosječne ukupne greške).


Zaključno, toplinski model dobiven hibridnom metodom (dakle, model kod kojeg je struktura određena na temelju otporničko-kapacitivne analogije, a parametri su određeni na temelju mjernih podataka) može se iskoristiti za predviđanje vrijednosti temperature, na način koji se to koristi u, na primjer, modelskom prediktivnom upravljanju HVAC sustavima u zgradama.

5.5. Usporedba s rezultatima dobivenim umjetnim neuronskim mrežama

U poglavlju 2.2.4 opisane su umjetne neuronske mreže kao primjer podatkovnog pristupa izradi toplinskih modela zgrada i HVAC sustava. Kao glavne prednosti, navedene su jednostavnost korištenja i dobri rezultati, a kao glavni nedostaci nepostojanje fizikalne interpretacije dobivenog modela i osjetljivost na promjene ulaznih podataka (različiti režimi rada sustava).

U ovom dijelu, ANN je korištena kao standardna metoda i rezultati prilagođenog modela su uspoređeni s rezultatima dobivenom pomoću ANN. Razlozi odabira ANN kao referentne metode je to što koristi podatkovni pristup za izradu modela (dok se hibridna metoda služi fizikalnim pristupom za izradu strukture modela) te njena raširenost na raznim područjima i učestalost korištenja u području toplinskih modela.

Za testiranje je izrađena dodatna pomoćna aplikacija u MATLAB okruženju. Ona je temeljena na aplikaciji koja se koristila za simulaciju i optimizaciju modela (korištena u prethodnim poglavljima) i prikazana je na slici 5.18. Za implementaciju ANN korištene su MATLAB funkcije *fitnet* i *train*, koje su dio *Neural Network Toolbox* paketa [111], u podrazumijevanoj varijanti i bez ikakvog naprednog podešavanja (dakle, standardna *Multi-Layer Perceptron* mreža). Rezultati (izlazi) dobiveni pomoću ANN su ovdje prikazani crvenim debljim crtama radi lakše usporedbe s rezultatima dobivenim pomoću prilagođenog modela (plave debele crte; mjerenja izlaza su crtkana siva).



Slika 5.18. Pomoćna MATLAB aplikacija za simulaciju i optimizaciju pomoću umjetnih neuronskih mreža


U tablici 5.6. i slikama 5.19. do 5.21. prikazani su rezultati simulacije ANN, s različitim brojem skrivenih slojeva, uspoređeni s rezultatima dobivenim pomoću prilagođenog modela (model 4R3C, *fminunc* metoda, NRMSE funkcija greške, maksimalan broj ponavljanja). Detaljni podaci u više različitih režima su prikazani su u prilogu P.11. Prikaz rezultata simulacije pomoću umjetnih neuronskih mreža. Također, na slici 5.22. prikazan je detalj iz MATLAB pomoćne aplikacije gdje se vidi vremenska serija s rezultatima ANN (10 skrivenih slojeva, simulacija s trening podacima) i hibridnih metoda (crvene crte su rezultati ANN metode, plave crte su rezultat hibridne metode i izlazi su crtkani sivi).

Tablica 5.6. Rezultati simulacije pomoću umjetnih neuronskih mreža


Model			Podaci o optimizaciji					
Ref. model	Test. model	Algoritam	MaxFun Evals/ Hidden Layers	Funk. Greške	Trening podaci	Dulj. sim.	Vrem. konst.	Trajanje optimiz.
mjerjenja	/	ANN	1	/	zimski, 21.2.-26.2.	144	900	0:00:01
mjerjenja	/	ANN	2	/	zimski, 21.2.-26.2.	144	900	0:00:01
mjerjenja	/	ANN	4	/	zimski, 21.2.-26.2.	144	900	0:00:01
mjerjenja	/	ANN	8	/	zimski, 21.2.-26.2.	144	900	0:00:01
mjerjenja	/	ANN	16	/	zimski, 21.2.-26.2.	144	900	0:00:01
mjerjenja	/	ANN	32	/	zimski, 21.2.-26.2.	144	900	0:00:01
mjerjenja	/	ANN	64	/	zimski, 21.2.-26.2.	144	900	0:00:01
mjerjenja	/	ANN	128	/	zimski, 21.2.-26.2.	144	900	0:00:05
mjerjenja	realni model 4R3C	fminunc	1.795.154	NRMSE	zimski, 21.2.-26.2.	144	900	1:29:03

Simulacija s trening podacima			Simulacija s testnim skupom Zimski skup 1 (od 26.2. do 27.2.)			Simulacija s testnim skupom Zimski skup 2 (od 28.2. do 1.3.)		
TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE
8,58E+02	5,08E-01	1,62E-01	4,95E+02	8,83E-01	2,98E-01	4,95E+02	8,83E-01	2,98E-01
8,76E+02	5,03E-01	1,60E-01	5,17E+02	8,72E-01	2,95E-01	6,38E+02	1,05E+00	2,92E-01
1,13E+03	6,48E-01	2,08E-01	4,54E+02	8,03E-01	2,73E-01	5,77E+02	9,80E-01	2,66E-01
7,22E+02	4,66E-01	1,48E-01	4,28E+02	8,38E-01	2,84E-01	6,77E+02	1,17E+00	3,16E-01
6,03E+02	3,99E-01	1,27E-01	4,32E+02	8,81E-01	3,00E-01	1,51E+03	2,48E+00	6,84E-01
6,14E+02	4,04E-01	1,28E-01	4,34E+02	8,66E-01	2,95E-01	8,94E+02	1,45E+00	4,10E-01
6,27E+02	4,05E-01	1,29E-01	4,21E+02	8,52E-01	2,89E-01	9,56E+02	1,59E+00	4,24E-01
6,64E+02	4,52E-01	1,46E-01	4,35E+02	8,80E-01	3,00E-01	1,26E+03	2,41E+00	6,70E-01
2,57E+02	1,49E-01	4,79E-02	2,21E+02	3,67E-01	1,25E-01	9,45E+02	1,34E+00	2,97E-01


Simulacija s testnim skupom skup 1 (od 12.3. do 13.3.)			Simulacija s testnim skupom Prijelazni skup 2 (od 10.3. do 15.3.)		
TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE
2,91E+02	5,44E-01	2,92E-01	1,21E+03	7,14E-01	3,05E-01
2,85E+02	5,52E-01	2,95E-01	1,24E+03	7,51E-01	3,22E-01
3,56E+02	5,89E-01	3,56E-01	1,24E+03	7,02E-01	3,10E-01
4,46E+02	8,31E-01	4,55E-01	1,60E+03	9,32E-01	4,03E-01
2,06E+03	3,35E+00	2,05E+00	5,32E+03	3,07E+00	1,40E+00
1,17E+03	1,85E+00	1,13E+00	3,57E+03	1,95E+00	9,03E-01
1,61E+03	2,39E+00	1,46E+00	4,51E+03	2,26E+00	1,06E+00
1,90E+03	3,14E+00	2,26E+00	5,64E+03	3,09E+00	1,62E+00
2,66E+02	4,27E-01	2,77E-01	1,03E+03	5,93E-01	2,57E-01




Slika 5.19. Usporedba rezultata simulacije prilagođenog modela i umjetnih neuronskih mreža, ukupna greška



Slika 5.20. Usporedba rezultata simulacije prilagođenog i umjetnih neuronskih mreža, korijen srednje kvadratne greške



Slika 5.21. Usporedba rezultata simulacije prilagođenog modela i umjetnih neuronskih mreža, normalizirani korijen srednje kvadratne greške




Slika 5.22. Detalj rezultata simulacije pomoću umjetnih neuronskih mreža, Zimski skup 1

Prvo što se može zamijetiti su izrazito kraća vremena optimizacije kod ANN metode. Dok kod prilagođenog modela optimizacija (za ovaj testni model) traje nekoliko desetaka minuta ili nekoliko sati, kod ANN metode je ona gotova nakon nekoliko sekundi ili minuta (kod 1.024 skrivena sloja).

Drugo, ako se gledaju ukupni rezultati prikazani u prilogu P.11. Prikaz rezultata simulacije pomoću umjetnih neuronskih mreža, može se vidjeti (iako ova pojava nije konzistentna) da se povećanjem broja skrivenih slojeva povećava greška između rezultata ANN metode i mjerenih izlaza. Tako da je teško dati prijedlog optimalnog broja skrivenih slojeva.

Treće, na slikama 5.19. do 5.21. se može uočiti da prilagođeni model daje bolje rezultate u gotovo svim testnim režimima. Ako se pogleda slika 5.22. s grafičkim prikazom simulacije, može se primijetiti da su rezultati ANN metode poprilično rasuti oko vrijednosti izlaza, a što se može još bolje primijetiti kada se koriste velike vrijednosti broja skrivenih slojeva.

Četvrto, na slici 5.23. gdje je prikazan detalj simulacije pomoću ANN-a, može se izravno vidjeti najveći nedostatak ANN metode, odnosno općenito podatkovnog pristupa izradi modela, a to je upravo nepostojanje fizikalne interpretacije. Ako se pogleda detalj, vidi se da ANN ispravno pretpostavlja da su izlazi konstantni ("ravna crta") u periodu koji odgovara drugoj smjeni i noći. Taj rezultat je točan i ANN je prepoznao ispravan uzorak koji odgovara zadanoj vrijednosti temperature u prostoru od 16 °C (donja crvena crta u detalju), te je kao takav u ovom režimu rada ispravniji od rezultata prilagođenog modela. No kada se koriste ulazni podaci iz dnevnog režima rada (prva smjena), kada postoji puno veća dinamika i kada je HVAC sustav aktivan, može se vidjeti da ANN metoda daje bitno lošije rezultate od prilagođenog modela (npr. slika 5.22.).




Slika 5.23. Detalj simulacije pomoću umjetnih neuronskih mreža (noćni režim)

Iz ovih rezultata, može se općenito zaključiti da ANN daje dobre rezultate (malu grešku modela) u režimima gdje su ulazno-izlazni podaci slični podacima koji su korišteni za određivanje parametara (odnosno trening ANN-a) i kod kojih su ulazni podaci statični (odnosno nema velike dinamike ulaznih podataka). No u režimima rada koji su međusobno bitno drugačiji (različite radne točke) i kod kojih postoji izražena dinamika ulaznih podataka, rezultati će biti lošiji i eventualno neupotrebljivi.

5.6. Kvaliteta predviđanja s umjetnim neuronskim mrežama i usporedba s prilagođenim modelom

U ovom pokusu ponovljena je procedura iz poglavlja 5.2., samo što se umjesto prilagođenog modela za predviđanje koriste umjetne neuronske mreže. Vrijede sve napomene vezane za ulazne podatke, broj sati predviđanja i ostale kao i u prethodnom pokusu.

Opet je izrađena pomoćna aplikacija u MATLAB okruženju, prikazana na slici 5.24., temeljena na prethodnoj aplikaciji za predviđanje (slika 5.13.). Jedina razlika je što se ovdje koristi ANN za predviđanje.



Slika 5.24. Pomoćna MATLAB aplikacija za predviđanje pomoću umjetnih neuronskih mreža


Prvo što se može primijetiti na grafu jest da ovdje nema rasapa predviđenih vrijednosti kao kod hibridne metode. To znači da kod ANN-a trenutne vrijednosti ne ovise o prethodnim vrijednostima nego samo o trenutnima, odnosno da sustav nema memoriju (statičan je). Ovakav sustav kod predviđanja daje iste vrijednosti kao i kod simulacije, neovisno o vrijednosti broja sati predviđanja.


U tablici 5.7. prikazani su rezultati predviđanja za iste ulazne i izlazne podatke za sve do sada spomenute skupove testnih podataka, uz korištenje ANN metode te usporedba rezultata s hibridnom metodom, na slikama 5.25. do 5.28. Prošireni podaci prikazani su u prilogu P.12. Prikaz rezultata predviđanja korištenjem ANN metode.

Tablica 5.7. Rezultati predviđanja pomoću umjetnih neuronskih mreža


Metoda	Broj sati predv.	Trening podaci		Prijelazni skup 2 (od 10.3. do 15.3.)		Zimski skup 1 (od 26.2. do 27.2.)		Zimski skup 2 (od 28.2. do 1.3.)		Prijelazni skup 1 (od 12.3. do 13.3.)	
		TOT _{Avg}	MAX	TOT _{Avg}	MAX	TOT _{Avg}	MAX	TOT _{Avg}	MAX	TOT _{Avg}	MAX
ANN	2	2.922	2,67	12.087	3,49	1.816	3,42	4.674	6,62	3.209	3,15
ANN	6	2.649	2,67	10.868	3,49	1.560	3,42	3.684	6,62	2.582	3,15
fminunc, 2R1C	2	3.120	1,65	2.998	2,27	1.350	1,72	1.477	6,47	959	2,27
fminunc, 2R1C	6	3.083	1,85	2.674	2,27	1.280	1,85	1.348	5,20	808	2,27
fminunc, 4R2C	2	3.526	1,95	2.771	1,63	1.548	2,04	1.792	6,98	946	1,55
fminunc, 4R3C	6	3.669	2,49	2.772	1,63	1.675	2,49	1.621	6,16	914	1,55

U grafovima 5.25. do 5.28. prikazana je grafička usporedba kvalitete predviđanja ovisno o metodi i broju sati predviđanja, odnosno prosječna ukupna greška za skupove duljine 2 i 6 dana te maksimalna greška za skupove duljine 2 i 6 dana.


**Slika 5.25.** Usporedba prosječne ukupne greške za scenarije trajanja 6 dana, ANN metoda



Slika 5.26. Usporedba prosječne ukupne greške za scenarije trajanja 2 dana, ANN metoda



Slika 5.27. Usporedba maksimalne greške za scenarije trajanja 6 dana, ANN metoda



Slika 5.28. Usporedba maksimalne greške za scenarije trajanja 2 dana, ANN metoda

Iz tabličnog i grafičkog prikaza usporedbe kvalitete predviđanja prilagođenog modela i umjetnih neuronskih mreža, primjećuje se da prilagođeni model daje bolje rezultate predviđanja. Ovo je osobito izraženo kod testiranja korištenjem režima koji su drugačiji od režima koji su korišteni za određivanje parametara ANN-a, a što je već primijećeno u prethodnom poglavlju 5.3.

6. ZAKLJUČAK

Trenutno se u razvijenim zemljama (SAD, EU, Japan i slično) gotovo petina ukupne energije troši na rad HVAC sustava u zgradama stambene i komercijalne namjene. S obzirom na potrebu smanjivanja ukupne potrošnje energije i trend povećanja energetske učinkovitosti, traže se nove mogućnosti kako smanjiti energiju potrebnu za rad HVAC sustava. Pristup koji ne zahtijeva intenzivne zahvate na zgradi i HVAC sustavu je poboljšanje upravljačkih sustava za HVAC sustave.

Jedan od čestih izbora za upravljanje HVAC sustavima je modelsko prediktivno upravljanje, gdje korištenje predviđanja omogućava i smanjivanje potrošnje energije i ostvarivanje zadovoljavajućih klimatskih uvjeta unutar zgrada. Osnovni uvjet za korištenje MPC-a općenito jest postojanje eksplicitnog modela sustava, odnosno, u ovom slučaju, termodinamičkog modela zgrade i HVAC sustava. MPC radi na sljedeći način: u trenutnom koraku računa se optimalan ulaz u sustav za sljedećih N koraka (predviđanje budućeg rada sustava), gdje je ulaz u energija iz HVAC sustava, koji zadovoljava postavljena ograničenja na sustav, gdje su ograničenja definirana svojstvima HVAC sustava i dozvoljenim rasponima klimatskih uvjeta. Optimalnost je određena težinskom funkcijom J koja kombinira potrošnju energije u i razliku između zadanih klimatskih uvjeta r i mjerenih klimatskih uvjeta y , za sljedećih N koraka (zato se ova metoda i zove prediktivna). MPC koristi vrijednost ulaza u za sljedeći korak i ponovno računa optimalni ulaz za sljedećih N koraka (zbog čega se ova metoda nekada naziva i upravljanje s pomičnim obzorom). Kvaliteta predviđanja izravno ovisi o kvaliteti modela sustava. Što točniji i jednostavniji model zgrade i HVAC sustava, to će MPC davati bolje rezultate predviđanja i zahtijevati manje računalne resurse za njihov izračun.

Otporničko-kapacitivna analogija je jedan od čestih izbora za određivanje strukture termodinamičkih modela zgrada i HVAC sustava. Ova nadomjesna metoda temelji se na zamjeni elemenata zgrade analognim strukturama sastavljenim od električkih veličina, tako da se toplinska svojstva i procesi nadomjesto električkim veličinama (toplinski otpor se zamjenjuje otporom, toplinski kapacitet se kapacitetom, temperatura naponom, odnosno potencijalom i tok topline strujom). Tako se jedan zid zgrade najjednostavnije može predstaviti strukturom koja se sastoji od dva otpora i jednog kapaciteta te koja objedinjuje sve toplinske procese na zidu (vođenje topline kroz zid, prijelaz topline između okoliša i površine zida, zračenje iz raznih izvora, itd.). U standardnoj varijanti, gdje se vrijednosti parametara modela računaju iz arhitekture (građevinskog nacrt) zgrade i svojstava materijala, RC metoda pripada fizikalnom pristupu modeliranju. Iako

ovaj pristup može dati relativno dobre rezultate, ove početne vrijednosti parametara često mogu biti netočne iz više razloga: nedostatak informacija o korištenim materijalima, netočni nazivni podaci proizvođača, starenje i promjene materijala i slično. No RC metoda može pripadati i hibridnom pristupu modeliranju, ako se parametri modela računaju izravno iz mjerenja dobivenih sa zgrade. Neki od nedostataka koji se pripisuju RC metodi su: nepostojanje jasne procedure za izradu strukture modela koja predstavlja arhitekturu zgrade; složenost modela brzo raste kod kompliciranih zgrada; problemi pri određivanju vrijednosti parametara modela.

Ova disertacija predlaže novi, hibridni pristup izradi termodinamičkog modela zgrade, kod kojeg se struktura modela određuje na temelju algoritma koji arhitekturu zgrade i HVAC sustava automatski pretvara u strukturu toplinskog modela u obliku prostora stanja (matrice sustava A , B , C i D) i koji se temelji na otporničko-kapacitivnoj analogiji. Početni parametri fizikalnog modela postavljaju se na osnovi podataka o svojstvima materijala, no u sljedećem koraku radi se prepodešenje parametara na temelju mjerenja sa zgrade koje treba dati točnije vrijednosti parametara. Ovaj pristup verificiran je eksperimentima izvršenim na stvarnoj zgradi i uspoređen s rezultatima dobivenim umjetnim neuronskim mrežama. Zgrada na kojoj su obavljena mjerenja i eksperimenti je proizvodno-uredska zgrada, gdje je proizvodni dio površine 614 m² korišten za ovo istraživanje. Proizvodni dio sastoji se od četiri prostorije, a HVAC sustav se temelji na plinskom bojleru i zračećim stropnim radijatorima.

Određivanje strukture modela, prvi korak hibridnog pristupa, temelji se na definiranju struktura podataka koje predstavljaju elemente zgrade i HVAC sustava te njihove međusobne odnose korištenjem otporničko-kapacitivne analogije. Definirane su četiri osnovne strukture: izvor topline I (odnosno ulaz u sustav, koji može biti neupravljivi ulaz ili upravljački ulaz), prostor P (odnosno stanje sustava, koje može biti neki unutarnji prostor/zona ili jedinstveni vanjski okoliš; veza prema nekom izvoru I koji definira njihov odnos u kojem se izvor nalazi u prostoru i utječe na njega te svojstvo toplinskog kapaciteta prostora), zid Z (koji predstavlja odnos između dva prostora P definiran svojstvima materijala, odnosno toplinskim otporom i kapacitetom; dodatno, zid može definirati i odnos u kojem neki izvor izravno djeluje na zid, kao kod Sunčeve radijacije) te otvor O (struktura slična zidu, koja definira odnos između dva prostora, no ne može definirati odnos između izvora i otvora; na primjer, vrata i prozori). Radi lakšeg korištenja, izrađena je aplikacija *ModelBuilder* koja implementira ovaj pristup i koja omogućava grafičko definiranje struktura i njihovih odnosa, praćenjem građevinskih elemenata zgrade, iako je moguće i potpuno apstraktno definiranje. Nakon definiranja ovih struktura i odnosa, korištenjem razvijenog algoritma one se transformiraju u toplinski model u obliku prostora stanja (matrice sustava A , B , C i D). Početne

vrijednosti parametara modela određuju se iz toplinskih svojstava građevinskih elemenata. Izvršena je simulacija dobivenog fizikalnog modela s početnim parametrima i uspoređena s mjerenjima, koji očekivano pokazuju relativno loše poklapanje rezultata simulacije i mjerenja.

Određivanje parametara modela je drugi korak hibridnog pristupa i temelji se na prepodešavanju (optimizaciji ili prilagodbi) početnih vrijednosti parametara, čime se dobiva prilagođeni model. Definirane su kriterijske funkcije kao greška modela (razlika između rezultata simulacije y_T i mjerenja y_R), određene raznim metrikama: ukupna greška e_{TOTAL} , korijen srednje kvadratne greške e_{RMSE} , normalizirani korijen srednje kvadratne greške e_{NRMSE} te maksimalna greška e_{MAX} . Prepodešavanje parametara modela definirano je kao matematički problem nalaženja minimuma neograničene multivarijabilne funkcije, gdje je kriterijska funkcija greška modela, odnosno razlika y_T i y_R . Matematički problem je riješen korištenjem kvazi-Newton algoritma, iako su u radu istražene i druge mogućnosti optimizacije. Kroz veliki broj provedenih optimizacija, istraženi su uvjeti pod kojima optimizacija daje najbolje rezultate: metoda i algoritam optimizacije (*fminunc* metoda s kvazi-Newton algoritmom), vrijeme uzorkovanja (uzorkovanje od 900 sekundi), struktura ulaznih podataka (nema potrebe za pred-obrađom razdiobe energije po zonama).

Izvršena je verifikacija hibridne metode detaljnom analiza dobivenih rezultata više modela. Definirani su kriteriji koji određuju složenost modela (temeljen na broju stanja modela) i točnost modela (iste greške modela koje su korištene za kriterijske funkcije). Rezultati pokazuju veliki utjecaj odabira metrike za kriterij točnosti i da se najbolji rezultati dobivaju korištenjem NRSME metrike. Broj ponavljanja optimizacija očekivano proporcionalno utječe na rezultate, no također pokazuje da nakon neke vrijednosti, dodatno povećavanje broja ponavljanja ne daje bitno poboljšanje rezultata. Istražen je utjecaj režima rada (u smislu vremenskih uvjeta okoliša; zimski i prijelazni) gdje se pokazalo da specijalizacija modela za neki režim rada (prepodešavanje parametara na temelju mjerenja iz određenog režima) daje dobre rezultate u simulacijama gdje su testni podaci iz sličnog režima, no korištenjem istog modela u drugačijim režimima daje lošije rezultate. Utjecaj složenosti modela (definiran odabirom složenosti reprezentacije zida 4R3C, 3R2C ili 2R1C) pokazao je da manje složeni modeli ne daju bitno lošije rezultate, no zahtijevaju bitno manje vrijeme optimizacije (oko 90 minuta za 4R3C model i oko 20 minuta za 2R1C model sa sličnom točnosti modela).

S obzirom da je svrha prilagođenog modela dobivenog hibridnom metodom korištenje u modelskom prediktivnom upravljanju, testirana je kvaliteta predviđanja ovisno o broju sati

predviđanja (za koliko sati unaprijed se previđa ponašanje izlaza), mjerena prosječnom greškom (maksimalna greška podijeljena s brojem sati predviđanja) i maksimalnom greškom. Rezultati pokazuju prosječna odstupanja manja od 1 °C i maksimalna odstupanja na razini oko 1,5 °C, gdje maksimalna odstupanja rastu ako postoje bitne razlike u radnom režimu (ako su parametri prepodešeni na temelju mjerenja iz jednog režima rada, a ulazni podaci za testiranje su iz drugog režima).

Rezultati prilagođenog modela uspoređeni su s rezultatima dobivenim umjetnim neuronskim mrežama. ANN je druga metoda (pored RC metode) koja se često koristi u istraživanjima vezanim za termodinamičke modele zgrada i HVAC sustava te se temelji na podatkovnom pristupu, bez fizikalne reprezentacije modela. Usporedbom rezultata prilagođenog modela i umjetnih neuronskih mreža pokazano je da prilagođeni model daje bolje rezultate, koristeći prethodno opisane metrike. ANN se temelje samo na informacijama koje su dostupne u ulazno-izlaznim podacima korištenima za trening, što može dovesti do velikih odstupanja kod pojave novih informacija ili ekstremnih vrijednosti ulaza koje nisu bile obuhvaćene podacima korištenim za trening. Slični rezultati dobivaju se kada se prilagođeni model i ANN koriste za previđanje, odnosno prilagođeni model pokazuje bolje rezultate svim eksperimentima.

Dodatni smjerovi istraživanja i poboljšanja koja se mogu primijeniti na predloženu metodu su sljedeći:

- unaprjeđenje algoritma (na primjer, da dozvoli utjecaj više izvora na jedan zid ili prostor)
- istraživanje utjecaja složenosti modela na rezultate kada se radi pojednostavljivanje koje mijenja poznatu strukturu modela, a ne samo pojednostavljivanje pomoću jednostavnije reprezentacije (npr. 4R3C u 2R1C reprezentaciju zida)
- dodavanje neobrađenih utjecaja iz okoliša (vjetar, Sunce) kao dodatnih neupravljivih ulaza u sustav
- ispitivanje ponašanja sustava u ljetnom radnom režimu i dodatna istraživanja utjecaja režima na rezultate.

LITERATURA

- [1] J. D. Kelso, "Building Energy Data Book 2011," 2012.
- [2] International Energy Agency, *Key World Energy Statistics 2015*. Paris: OECD Publishing, 2015.
- [3] L. Perez-Lombard, J. Ortizb, and C. Pout, "A review on buildings energy consumption information," *Energy Build.*, vol. 40, no. 3, pp. 394–398, Jan. 2008.
- [4] C. P. Underwood and F. W. H. Yik, *Modelling Methods for Energy in Buildings*. Oxford, UK: Blackwell Publishing Ltd, 2004.
- [5] W. S. Janna, *Engineering Heat Transfer*, 2nd ed. Memphis: CRC Press, 1999.
- [6] A. Bejan and A. D. Kraus, *Heat Transfer Handbook*. John Wiley & Sons, 2003.
- [7] G. N. Tiwari and S. Dubey, "Solar radiation," in *Fundamentals of Photovoltaic Modules and their Applications*, no. 2, Royal Society of Chemistry, 2010, pp. 1–28.
- [8] M. G. Davies, *Building Heat Transfer*, 1st ed. John Wiley & Sons, 2004.
- [9] A. Rasooli, L. Itard, and C. I. Ferreira, "A response factor-based method for the rapid in-situ determination of wall's thermal resistance in existing buildings," *Energy Build.*, vol. 119, pp. 51–61, May 2016.
- [10] S. C. Sugarman, *HVAC Fundamentals*, 2nd ed., vol. 40, no. 6. The Fairmont Press, 2005.
- [11] R. McDowall, *Fundamentals of HVAC Systems*, 1st ed., vol. 40, no. 6. Elsevier, 2007.
- [12] R. Montgomery and R. McDowall, *Fundamentals of HVAC Control Systems*, 1st ed. Elsevier, 2009.
- [13] V. Vakiloroaya, B. Samali, A. Fakhar, and K. Pishghadam, "A review of different strategies for HVAC energy saving," *Energy Convers. Manag.*, vol. 77, no. 1, pp. 738–754, Jan. 2014.
- [14] K. J. Keesman, *System Identification*. London: Springer London, 2011.
- [15] N. Perić and I. Petrović, "Identifikacija procesa," p. 147, 2005.
- [16] A. Afram and F. Janabi-Sharifi, "Review of modeling methods for HVAC systems," *Appl. Therm. Eng.*, vol. 67, no. 1–2, pp. 507–519, Jun. 2014.
- [17] V. Gerlich, "Modelling Of Heat Transfer In Buildings," in *ECMS 2011 Proceedings edited by: T. Burczynski, J. Kolodziej, A. Byrski, M. Carvalho*, 2011, pp. 244–248.
- [18] E. Atam and L. Helsen, "Control-Oriented Thermal Modeling of Multizone Buildings: Methods and Issues: Intelligent Control of a Building System," *IEEE Control Syst.*, vol. 36, no. 3, pp. 86–111, Jun. 2016.
- [19] S. Karmacharya, G. Putrus, C. Underwood, and K. Mahkamov, "Thermal modelling of the building and its HVAC system using Matlab/Simulink," in *2012 2nd International Symposium On Environment Friendly Energies And Applications*, 2012, pp. 202–206.
- [20] Y. Ma, A. Kelman, A. Daly, F. Borrelli, and M. Yudong, "Predictive Control for Energy

- Efficient Buildings with Thermal Storage,” *IEEE Control Syst. Mag.*, vol. 32, no. January, pp. 44–64, Feb. 2012.
- [21] J. Rehrl and M. Horn, “Temperature control for HVAC systems based on exact linearization and model predictive control,” in *2011 IEEE International Conference on Control Applications (CCA)*, 2011, pp. 1119–1124.
 - [22] B. Tashtoush, M. Molhim, and M. Al-Rousan, “Dynamic model of an HVAC system for control analysis,” *Energy*, vol. 30, no. 10, pp. 1729–1745, Jul. 2005.
 - [23] M. Muratori, V. Marano, R. Sioshansi, and G. Rizzoni, “Energy consumption of residential HVAC systems: A simple physically-based model,” in *IEEE Power and Energy Society General Meeting*, 2012, pp. 1–8.
 - [24] O. T. Ogunsola, L. Song, and G. Wang, “Development and validation of a time-series model for real-time thermal load estimation,” *Energy Build.*, vol. 76, no. June, pp. 440–449, Jun. 2014.
 - [25] K. Deng, P. Barooah, P. G. Mehta, and S. P. Meyn, “Building Thermal Model Reduction via Aggregation of States,” in *American Control Conference (ACC)*, 2010, pp. 5118–5123.
 - [26] S. Goyal and P. Barooah, “A Method for Model-Reduction of Nonlinear Building Thermal Dynamics,” in *American Control Conference*, 2011, pp. 2077–2082.
 - [27] Q. Luo, K. B. Ariyur, L. Qi, and K. B. Ariyur, “Building thermal network model and application to temperature regulation,” in *2010 IEEE International Conference on Control Applications*, 2010, pp. 2190–2195.
 - [28] F. Pedersen, P. Weitzmann, and S. Svendsen, “Modeling thermally active building components using space mapping,” in *Proceedings of the 7th Symposium on Building Physics in the Nordic Countries*, 2005, vol. 1, pp. 896–903.
 - [29] P. Bacher and H. Madsen, “Identifying suitable models for the heat dynamics of buildings,” *Energy Build.*, vol. 43, no. 7, pp. 1511–1522, Jul. 2011.
 - [30] R. Scitovski, *Numerička matematika*, 2nd ed. Osijek: Odjel za matematiku Sveučilišta u Osijeku, 2004.
 - [31] J. M. F. F. ten Berge, *Least Squares Optimization in Multivariate Analysis*, 2nd ed., vol. 34. Groningen: University of Groningen, 2005.
 - [32] P. Malisani, F. Chaplais, N. Petit, and D. Feldmann, “Thermal building model identification using time-scaled identification methods,” in *49th IEEE Conference on Decision and Control (CDC)*, 2010, pp. 308–315.
 - [33] Y. Wen and W. Burke, “Real-time Dynamic House Thermal Model Identification for Predicting HVAC Energy Consumption,” in *IEEE Green Technologies Conference*, 2013, pp. 367–372.
 - [34] J. Cigler and S. Privara, “Subspace identification and model predictive control for buildings,” in *2010 11th International Conference on Control Automation Robotics & Vision*, 2010, no. December, pp. 750–755.
 - [35] L. Ferkl, J. Siroky, and S. Privara, “Model predictive control of buildings: The efficient way of heating,” in *2010 IEEE International Conference on Control Applications*, 2010, pp. 1922–1926.

- [36] L. Wu, G. Kaiser, D. Solomon, R. Winter, A. Boulanger, and R. Anderson, "Improving efficiency and reliability of building systems using machine learning and automated online evaluation," in *2012 IEEE Long Island Systems, Applications and Technology Conference (LISAT)*, 2012, pp. 1–6.
- [37] L. Xuemei, D. Lixing, and L. Lanlan, "A novel building cooling load prediction based on SVR and SAPSO," in *2010 International Symposium on Computer, Communication, Control and Automation (3CA)*, 2010, vol. 510225, no. 1, pp. 528–532.
- [38] R. M. Lazzarin, F. Castellotti, and F. Busato, "Experimental measurements and numerical modelling of a green roof," *Energy Build.*, vol. 37, no. 12, pp. 1260–1267, Dec. 2005.
- [39] A. Aswani, N. Master, J. Taneja, V. Smith, A. Krioukov, D. Culler, and C. Tomlin, "Identifying models of HVAC systems using semiparametric regression," in *2012 American Control Conference (ACC)*, 2012, pp. 3675–3680.
- [40] D. Graupe, *Principles of Artificial Neural Networks*, 2nd ed., vol. 6. Chicago: World Scientific Publishing, 2007.
- [41] A. K. Jain and K. M. Mohiuddin, "Artificial neural networks: a tutorial," *Computer (Long Beach, Calif.)*, vol. 29, no. 3, pp. 31–44, Mar. 1996.
- [42] V. Bakker, A. Molderink, J. L. Hurink, and G. J. M. Smit, "Domestic Heat Demand Prediction Using Neural Networks," in *2008 19th International Conference on Systems Engineering*, 2008, pp. 189–194.
- [43] A. Beghi, L. Cecchinato, M. Rampazzo, and F. Simmini, "Load forecasting for the efficient energy management of HVAC systems," in *2010 IEEE International Conference on Sustainable Energy Technologies (ICSET)*, 2010, pp. 1–6.
- [44] H. Dong, X. Yan, F. Chao, and Y. Li, "Predictive Control Model for Radiant Heating System Based on Neural Network," in *2008 International Conference on Computer Science and Software Engineering*, 2008, vol. 1, pp. 45–48.
- [45] H. Huang, L. Chen, M. Mohammadzaheri, E. Hu, and M. Chen, "Multi-zone temperature prediction in a commercial building using artificial neural network model," in *2013 10th IEEE International Conference on Control and Automation (ICCA)*, 2013, pp. 1896–1901.
- [46] K. K. Andersen, H. Madsen, and L. H. Hansen, "Modelling the heat dynamics of a building using stochastic differential equations," *Energy Build.*, vol. 31, no. 1, pp. 13–24, Jan. 2000.
- [47] S. Goyal, C. Liao, and P. Barooah, "Identification of multi-zone building thermal interaction model from data," in *IEEE Conference on Decision and Control and European Control Conference*, 2011, pp. 181–186.
- [48] Y. Iino, M. Murai, and D. Murayama, "Hybrid Modeling with Physical and JIT model for Building Thermal Load Prediction and Optimal Energy Saving Control," in *ICCAS-SICE*, 2009, pp. 2008–2011.
- [49] K. Lee and J. E. Braun, "Development and Application of an Inverse Building Model for Demand Response in Small Commercial Buildings," *Proc. SimBuild*, no. 2002, pp. 1–12, 2004.
- [50] K. Lee and J. E. Braun, "Reducing Peak Cooling Loads through Model-Based Control of Zone Temperature Setpoints," in *2007 American Control Conference*, 2007, pp. 5070–5075.

- [51] Z. O'Neill, S. Narayanan, and R. Brahme, "Model-based thermal load estimation in buildings," *Fourth Natl. Conf. IBPSA-USA*, pp. 474–481, 2010.
- [52] S. Privara, Z. Vana, D. Gyalistras, J. Cigler, C. Sagerschnig, M. Morari, and L. Ferkl, "Modeling and identification of a large multi-zone office building," in *2011 IEEE International Conference on Control Applications (CCA)*, 2011, pp. 55–60.
- [53] P. Radecki and B. Hencsey, "Online Building Thermal Parameter Estimation via Unscented Kalman Filtering," in *American Control Conference (ACC), 2012*, 2012, pp. 3056–3062.
- [54] P. Radecki and B. Hencsey, "Online thermal estimation, control, and self-excitation of buildings," in *52nd IEEE Conference on Decision and Control*, 2013, pp. 4802–4807.
- [55] S. Wang and X. Xu, "Parameter estimation of internal thermal mass of building dynamic models using genetic algorithm," *Energy Convers. Manag.*, vol. 47, no. 13–14, pp. 1927–1941, Aug. 2006.
- [56] Z. Yang, X. Li, C. P. Bowers, T. Schnier, K. Tang, and X. Yao, "An Efficient Evolutionary Approach to Parameter Identification in a Building Thermal Model," *IEEE Trans. Syst. Man, Cybern. Part C (Applications Rev.)*, vol. 42, no. 6, pp. 957–969, Nov. 2012.
- [57] T. L. McKinley and A. G. Alleyne, "Identification of building model parameters and loads using on-site data logs," in *Third National Conference of IBPSA-USA*, 2008, pp. 9–16.
- [58] N. Hariharan and B. P. Rasmussen, "Parameter estimation for dynamic HVAC models with limited sensor information," *Am. Control Conf. (ACC), 2010*, pp. 5886–5891, 2010.
- [59] Y. Lin, T. Middelkoop, and P. Barooah, "Issues in identification of control-oriented thermal models of zones in multi-zone buildings," in *2012 IEEE 51st IEEE Conference on Decision and Control (CDC)*, 2012, pp. 6932–6937.
- [60] Z. Vana, S. Privara, E. Zacekova, and J. Cigler, "Building semi-physical modeling - On selection of the model complexity," in *European Control Conference (ECC), 2013*, 2013, pp. 3955–3960.
- [61] A. Martincevic, A. Starcic, and M. Vasak, "Parameter estimation for low-order models of complex buildings," in *IEEE PES Innovative Smart Grid Technologies, Europe*, 2014, vol. 30, no. 8, pp. 1–6.
- [62] F. Scotton, L. Huang, S. A. Ahmadi, and B. Wahlberg, "Physics-based modeling and identification for HVAC systems," in *European Control Conference (ECC) 2013*, 2013, pp. 1404–1409.
- [63] C. Ellis, M. Hazas, and J. Scott, "Matchstick," in *Proceedings of the 12th international conference on Information processing in sensor networks - IPSN '13*, 2013, no. 1, p. 31.
- [64] H. Park, N. Martaj, M. Ruellan, R. Bennacer, and E. Monmasson, "Modeling of a Building System and its Parameter Identification," *J. Electr. Eng. Technol.*, vol. 8, no. 5, pp. 975–983, Sep. 2013.
- [65] R. De Coninck, F. Magnusson, J. Åkesson, and L. Helsen, "Toolbox for development and validation of grey-box building models for forecasting and control," *J. Build. Perform. Simul.*, vol. 9, no. 3, pp. 288–303, May 2016.
- [66] P. Albertos and I. Mareels, *Feedback and Control for Everyone*, vol. 31, no. 4. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010.

- [67] S. Kozak, "Advanced control engineering methods in modern technological applications," in *Proceedings of the 13th International Carpathian Control Conference (ICCC)*, 2012, pp. 392–397.
- [68] A. Aswani, N. Master, J. Taneja, A. Krioukov, D. Culler, and C. Tomlin, "Quantitative Methods for Comparing Different HVAC Control Schemes," in *Proceedings of the 6th International Conference on Performance Evaluation Methodologies and Tools*, 2012, pp. 326–332.
- [69] J. Liu, W. Cai, and G. Zhang, "Design and application of handheld auto-tuning pid instrument used in HVAC," in *2009 4th IEEE Conference on Industrial Electronics and Applications*, 2009, pp. 1695–1698.
- [70] J. Wang, C. Zhang, and Y. Jing, "Application of an intelligent PID control in heating ventilating and air-conditioning system," in *2008 7th World Congress on Intelligent Control and Automation*, 2008, pp. 4371–4376.
- [71] M. Komareji, J. Stoustrup, H. Rasmussen, N. Bidstrup, P. Svendsen, and F. Nielsen, "Simplified optimal control in HVAC systems," in *2009 IEEE International Conference on Control Applications*, 2009, pp. 1033–1038.
- [72] N. Jain, R. J. Otten, and A. G. Alleyne, "Decoupled Feedforward Control for an Air-Conditioning and Refrigeration System," in *American Control Conference (ACC)*, 2010, pp. 5904–5909.
- [73] S. Purdon, B. Kusy, R. Jurdak, and G. Challen, "Model-free HVAC control using occupant feedback," in *38th Annual IEEE Conference on Local Computer Networks - Workshops*, 2013, pp. 84–92.
- [74] J. T. Wen, S. Mishra, S. Mukherjee, N. Tantisujjatham, and M. Minakais, "Building temperature control with adaptive feedforward," in *52nd IEEE Conference on Decision and Control*, 2013, vol. 1, no. 5, pp. 4827–4832.
- [75] J. Singh, N. Singh, and J. K. Sharma, "Fuzzy modeling and control of HVAC systems – A review," *J. Sci. Ind. Res.*, vol. 65, no. June, pp. 470–476, 2006.
- [76] R. Alcalá, J. M. Benítez, J. Casillas, O. Cerdón, and R. Pérez, "Fuzzy Control of HVAC Systems Optimized by Genetic Algorithms," *Appl. Intell.*, vol. 18, no. 2, pp. 155–177, 2003.
- [77] P. P. Angelov, R. a. Buswell, V. I. Hanby, and J. a. Wright, "A methodology for modeling HVAC components using evolving fuzzy rules," in *2000 26th Annual Conference of the IEEE Industrial Electronics Society. IECON 2000. 2000 IEEE International Conference on Industrial Electronics, Control and Instrumentation. 21st Century Technologies and Industrial Opportunities (Cat. No.00CH37141)*, 2000, vol. 1, pp. 247–252.
- [78] M. W. Khan, M. A. Choudhry, and M. Zeeshan, "An efficient design of genetic algorithm based Adaptive Fuzzy Logic Controller for multivariable control of HVAC systems," in *2013 5th Computer Science and Electronic Engineering Conference (CEECE)*, 2013, pp. 1–6.
- [79] A. R. Al-Ali, N. A. Tubaiz, A. Al-Radaideh, J. A. Al-Dmour, and L. Murugan, "Smart grid controller for optimizing HVAC energy consumption," in *2012 International Conference on Computer Systems and Industrial Informatics*, 2012, pp. 1–4.
- [80] J. R. Villar, E. D. La Cal, and J. Sedano, "A fuzzy logic based efficient energy saving

- approach for domestic heating systems,” *Integr. Comput. Aided. Eng.*, vol. 16, no. 2, pp. 151–163, Jul. 2009.
- [81] M. Anderson, M. Buehner, P. Young, D. Hittle, C. Anderson, and D. Hodgson, “MIMO Robust Control for HVAC Systems,” *IEEE Trans. Control Syst. Technol.*, vol. 16, no. 3, pp. 475–483, May 2008.
 - [82] J. M. da Costa Sousa and U. Kaymak, “Model Predictive Control Using Fuzzy Decision Functions,” *IEEE Trans. Syst. Man. Cybern.*, vol. 31, no. 1, pp. 54–65, Jan. 2001.
 - [83] A. I. Dounis and C. Caraiscos, “Advanced control systems engineering for energy and comfort management in a building environment—A review,” *Renew. Sustain. Energy Rev.*, vol. 13, no. 6–7, pp. 1246–1261, Aug. 2009.
 - [84] G. Goddard, J. Klose, and S. Backhaus, “Model Development and Identification for Fast Demand Response in Commercial HVAC Systems,” *IEEE Trans. Smart Grid*, vol. 5, no. 4, pp. 2084–2092, Jul. 2014.
 - [85] H. Mirinejad, K. C. Welch, and L. Spicer, “A Review of Intelligent Control Techniques in HVAC Systems,” *IEEE Int. Netw. Infrastruct. Digit. Content*, pp. 1–5, 2010.
 - [86] Z. Wu, Q.-S. Jia, and X. Guan, “Optimal Control of Multiroom HVAC System: An Event-Based Approach,” *IEEE Trans. Control Syst. Technol.*, vol. 24, no. 2, pp. 662–669, 2015.
 - [87] D. Bao-Cang, *Modern Predictive Control*. CRC Press, 2009.
 - [88] S. J. Qin and T. a. Badgwell, “A survey of industrial model predictive control technology,” *Control Eng. Pract.*, vol. 11, no. 7, pp. 733–764, Jul. 2003.
 - [89] K. Chinnakani, A. Krishnamurthy, J. Moyne, A. Arbor, and F. Gu, “Comparison of energy consumption in HVAC systems using simple ON-OFF, intelligent ON-OFF and optimal controllers,” in *2011 IEEE Power and Energy Society General Meeting*, 2011, pp. 1–6.
 - [90] L. Ferkl, C. Verhelst, L. Helsen, A. Ciller, D. Komarkova, and D. Kom, “Energy savings potential of a model-based controller for heating: A feasibility study,” in *2011 IEEE International Conference on Control Applications (CCA)*, 2011, pp. 871–876.
 - [91] R. Kwadzogah, M. Zhou, and S. Li, “Model predictive control for HVAC systems — A review,” in *2013 IEEE International Conference on Automation Science and Engineering (CASE)*, 2013, pp. 442–447.
 - [92] A. Kelman and F. Borrelli, “Bilinear Model Predictive Control of a HVAC System Using Sequential Quadratic Programming,” in *International Federation of Automatic Control World Congress*, 2011, pp. 9869–9874.
 - [93] M. Vašak, A. Starčić, and A. Martinčević, “Model predictive control of heating and cooling in a family house,” in *Proceedings of the 34th International Convention MIPRO, 2011*, 2011, pp. 739–743.
 - [94] M. Vašak and A. Starčić, “Model Predictive Control of a Heating, Ventilation and Air Conditioning System,” in *36th International Convention on Information & Communication Technology Electronics & Microelectronics (MIPRO)*, 2013, pp. 913–918.
 - [95] S. Bengea, V. Adetola, K. Kang, M. J. Liba, D. Vrabie, R. Bitmead, and S. Narayanan, “Parameter estimation of a building system model and impact of estimation error on closed-loop performance,” in *IEEE Conference on Decision and Control and European Control*

- Conference*, 2011, pp. 5137–5143.
- [96] D. Sturzenegger, D. Gyalistras, M. Morari, and R. S. Smith, “Model Predictive Climate Control of a Swiss Office Building: Implementation, Results, and Cost–Benefit Analysis,” *IEEE Trans. Control Syst. Technol.*, vol. 24, no. 1, pp. 1–12, Jan. 2016.
 - [97] M. Killian and M. Kozek, “Ten questions concerning model predictive control for energy efficient buildings,” *Build. Environ.*, vol. 105, no. June, pp. 403–412, Aug. 2016.
 - [98] V. Chandan and A. G. Alleyne, “Optimal Control Architecture Selection for Thermal Control of Buildings,” in *American Control Conference*, 2011, pp. 2071–2076.
 - [99] P. Kret, K. J. Burnham, T. Larkowski, and L. Koszalka, “Control Optimisation of a Domestic Heating System,” in *2011 21st International Conference on Systems Engineering*, 2011, pp. 55–58.
 - [100] Z. Liao and A. L. Dexter, “An Inferential Model-Based Predictive Control Scheme for Optimizing the Operation of Boilers in Building Space-Heating Systems,” *IEEE Trans. Control Syst. Technol.*, vol. 18, no. 5, pp. 1092–1102, Sep. 2010.
 - [101] Y. Ma, G. Anderson, and F. Borrelli, “A Distributed Predictive Control Approach to Building Temperature Regulation,” in *American Control Conference*, 2011, pp. 2089–2094.
 - [102] P.-D. Morosan, R. Bourdais, D. Dumur, J. Buisson, and P. Moros, “Distributed model predictive control for building temperature regulation,” in *American Control Conference (ACC)*, 2010, 2010, pp. 3174–3179.
 - [103] F. Oldewurtel, A. Parisio, C. N. Jones, M. Morari, D. Gyalistras, M. Gwerder, V. Stauch, B. Lehmann, and K. Wirth, “Energy efficient building climate control using Stochastic Model Predictive Control and weather predictions,” in *American Control Conference (ACC)*, 2010, 2010, pp. 5100–5105.
 - [104] D. I. Mendoza-Serrano and D. J. Chmielewski, “HVAC control using infinite-horizon economic MPC,” in *Proceedings of the IEEE Conference on Decision and Control*, 2012, no. 3, pp. 6963–6968.
 - [105] R. R. Negenborn and J. M. Maestre, “Distributed Model Predictive Control: An Overview and Roadmap of Future Research Opportunities,” *IEEE Control Syst.*, vol. 34, no. August, pp. 87–97, 2014.
 - [106] F. Belic, “ModelBuilder - application for creating thermal models of buildings.” 2016.
 - [107] ASHRAE, *ASHRAE Handbook Fundamentals 2017 (SI)*, Har/Cdr ed. ASHRAE, 2017.
 - [108] F. Belic, Z. Hocenski, and D. Sliskovic, “Thermal modeling of buildings with RC method and parameter estimation,” in *2016 International Conference on Smart Systems and Technologies (SST)*, 2016, pp. 19–25.
 - [109] D. B. Crawley, J. W. Hand, M. Kummert, and B. T. Griffith, “Contrasting the capabilities of building energy performance simulation programs,” *Build. Environ.*, vol. 43, no. 4, pp. 661–673, Apr. 2008.
 - [110] T. Hastie, R. Tibshirani, and J. Friedman, *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, Second., vol. 1, no. 2. Springer Science & Business Media, 2013.
 - [111] MathWorks, “MATLAB Documentation,” 2017. [Online]. Available:

Literatura

<https://www.mathworks.com/help/index.html>. [Accessed: 01-Jan-2017].

SAŽETAK

Naslov: *Hibridna metoda za izradu termodinamičkog modela zgrade temeljena na otporničko-kapacitivnoj analogiji*

Ključne riječi: *termodinamički model zgrade, otporničko-kapacitivna analogija, hibridni pristup modeliranju.*

Sažetak:

U ovoj disertaciji istražena je izrada termodinamičkog modela zgrade i HVAC sustava, s namjerom da se model koristi kao temelj upravljanja u modelskom prediktivnom upravljanju, a sve s ciljem poboljšavanja energetske učinkovitosti u zgradi. Cilj istraživanja bio je razvoj metode za izradu hibridnog termodinamičkog modela zgrade tipa siva kutija koji se temelji na otporničko-kapacitivnoj analogiji za određivanje strukture modela i te određivanju parametara modela na temelju raspoloživih mjernih podataka. Predstavljen je algoritam koji omogućuje automatiziranu izradu strukture termodinamičkog modela zgrade u obliku prostora stanja iz građevinskog nacrtu zgrade. Početni parametri modela postavljaju se na temelju nazivnih podataka o svojstvima korištenih materijala, no u drugom koraku koriste se mjerenja sa zgrade za prilagodbu modela kroz prepodešavanje njegovih parametara. Za prilagodbu se koristi minimalizacija funkcije greške definirane razlikom između mjerenja i izlaza modela. Razvijena metoda i njome dobiveni modeli testirani su korištenjem mjernih podataka sa stvarne zgrade te uspoređeni s mjerenjima i rezultatima dobivenim pomoću umjetnih neuronskih mreža. Rezultati pokazuju da se predložena metoda može koristiti za automatiziranu izradu termodinamičkog modela zgrade, s rezultatima koji su dovoljno točni za korištenje u modelskom prediktivnom upravljanju, a usporedba pokazuje da hibridni model daje bolje rezultate od umjetnih neuronskih mreža.

ABSTRACT

Title: *Hybrid Method for Dynamic Thermal Modelling of Buildings Based on the Resistance-Capacitance Analogy*

Keywords: *thermodynamic model of building, resistance-capacitance analogy, hybrid approach to modeling.*

Abstract:

This thesis investigates the development of thermodynamic model of building and HVAC system, with purpose of using this model as a basis for Model Predictive Control, with goal of increasing the energy efficiency in buildings. The goal of the research was to develop a method for developing grey-box thermodynamic model of building based on resistance-capacitance analogy for structure of model and estimation of model parameters based on available measured data. It proposes an algorithm that enables automated development of structure of thermodynamic model in state-space representation based on construction drawing of building. Initial parameters of the model are based on nominal information of building materials' properties, but in second step, measured data from a building are used for fitting of model. The fitting is accomplished by minimization of error-function defined as difference between the measurements and outputs of the model. The method and developed models are tested with data from a real building and compared to measurements and results from Artificial Neural Network. Results show that proposed method enables automated development of thermal model of building, with results acceptable for use in Model Predictive Control, while comparison shows that hybrid model gives better results than Artificial Neural Network.

ŽIVOTOPIS

Filip Belić, rođen 8. rujna 1984. godine u Osijeku. Zvanje diplomiranog inženjera elektrotehnike stekao je u rujnu 2008. godine na Elektrotehničkom fakultetu Osijek obranom diplomskog rada s naslovom "Vizualizacija nadzora i upravljanja industrijskog procesa". Iste godine zapošljava se na radnom mjestu programera-projektanta u tvrtki TEO-Belišće d.o.o (tada u sastavu Belišća d.d.). Godine 2009. upisuje poslijediplomski doktorski studij na smjeru računarstvo i komunikacije. Suradnik na međunarodnom projektu TEMPUS (Collaborative Internationalization of Software Engineers in Croatia). U sklopu posla sudjelovao u izradi upravljačkih sustava na više velikih projekata, kao što su bioplinska postrojenja te postrojenja i procesi u sastavu prehrambene i poljoprivredne industrije. Uspješno implementirao nekoliko upravljanja HVAC sustavima u industriji. Godine 2011. zadužen za izradu ukupnog upravljačkog rješenja za HVAC sustav "pametne kuće" u Osijeku, čime počinje njegov interes za upravljanje HVAC sustavima. Od 2012. aktivno uključen u menadžment tvrtke u kojoj radi kao Voditelj projekta, uz nastavak rada na poslovima izrade upravljačkih sustava u industriji. Od 2016. zadužen za suradnju s kupcima i razvoj novih poslova, s fokusom na strane tvrtke. Uz poslovno djelovanje, kontinuirano radi na znanstvenom istraživanju i sudjeluje na nekoliko znanstvenih konferencija.

PRILOZI

Prilog P.1. Izvadak iz Glavnog arhitektonskog projekta

PIP PROJEKT

j.d.p.o. za projektiranje i savjetovanje
NAŠICE, Trg Izidora Kršnjavija 8
Mob:091/256-36-77

INVESTITOR:	TEO-Belišće d.o.o.
GRAĐEVINA:	Belišće, Radnička ulica br. 3
MJESTO GRADNJE:	PROIZVODNI POGON - HALA ZA MONTAŽU I POMOĆNA ZGRADA ZA ODMOR DJELATNIKA VALPOVO, Zona malog gospodarstva II k.č.br. 2792/6., k.o. Valpovo
GLAVNI PROJEKTANT:	BRANKO PRIŠČ, dipl.ing.arh.
PROJEKTANT:	BRANKO PRIŠČ, dipl.ing.arh.
ZAJEDNIČKA OZNAKA PROJEKTA:	37/15
BROJ PROJEKTA:	37/15 A
DATUM IZRADE:	ožujak, 2017.

Kao izvori toplinske energije za grijanje planirani su zidni kondenzacijski cirkulirajući kotlovi za grijanje, a grijanje je planirano kao podno u uredskom dijelu zgrade te toplovodnim zračećim panelima u proizvodnom dijelu zgrade

POMOĆNA ZGRADA ZA ODMOR DJELATNIKA

- Pomoćna zgrada za odmor djelatnika, koja je zatvorena PVC panelima, kao zaštitom od atmosferske prašine, koristit će se samo u toplijim mjesecima te kao takvoj nije potrebno grijanje.

7. Način uporabe građevine:

- Zgrada je projektirana kao cjelina i sukladno Zakonu o gradnji (NN br.153/13 i 20/17) Investitor je dužan zatražiti Uporabnu dozvolu po završetku gradnje, a prije uporabe same građevine

8. Oblikovanje građevine:

PROIZVODNI POGON – HALA ZA MONTAŽU

Konstrukcija

- Građevina je pravokutnog tlocrtnog oblika ukupnih dimenzija 15,74m x 56,74m, ukupne visine (s atikom) proizvodni dio 7,10 m, a dio administracije 9,10 m, s formiranim katom na uredskom dijelu na visini +3,70m, a prema arhitektonskim podlogama i planovima pozicija. Hala je podijeljena na dva dijela i to niži (hala) i viši (administracija), s tri osnovna funkcionalna dijela: prvi dio, između osi 1 i 3, zajedno s drugim, kranskim dijelom, između osi 3 i 6, pripada nižem dijelu hale; dok dvoetažni (Pr+1) administrativni dio, između osi 6 i 8, u kojem su smješteni uredi, pripada višem dijelu hale. Konstrukcija cijele hale je jedinstvena, međusobno povezana cjelina sa stupovima i AB konzolama koji nose rubne krovne nosače DM nižeg i višeg dijela. Glavnu nosivu konstrukciju čine montažni AB elementi: stupovi, sekundarne i glavne krovne grede te monolitna armiranobetonska stropna konstrukcija kata administrativnog dijela, dodatno oslonjena na unutarnje montažne AB stupove – u svemu prema proračunskom modelu. Međukatu AB konstrukciju administrativnog dijela čini AB stropna ploča debljine 18 cm s AB gredama 30/68cm. Ispod stropne konstrukcije prizemlja, kao i ispod krovne konstrukcije kata administrativnog dijela izvodi se spuštene ovještene strop. Vertikalnu komunikaciju između prizemlja i kata administracije čini armiranobetonsko dvokrako stubište oslonjeno na stropnu konstrukciju prizemlja te pripadajući AB zid prizemlja. Krovnu konstrukciju čine montažne sekundarne T grede (poz. ISN) raspona 800 cm, postavljene na međusobnom osnom rasteru od 242 cm, koje nose termoizolacijske čelične krovne panele debljine 16 cm i koje su oslonjene na gornji pojas glavnih krovnih greda. Glavne krovne grede se izvode kao montažne „DM“ grede, T promjenljivog poprečnog presjeka, kojima se formira dvostrešno simetrično krovno s nagibom krovnih ploha od cca. 3,5°. Raspona su 15 m, oslonjene na fasadne montažne AB stupove, na međusobnom

PIP PROJEKT

j.d.o.o. za projektiranje i savjetovanje
NAŠICE, Trg Izidora Kršnjavija 8
Mob:091/256-36-77

INVESTITOR:	TEO-Belišće d.o.o.
GRAĐEVINA:	Belišće, Radnička ulica br. 3 PROIZVODNI POGON - HALA ZA MONTAŽU I POMOĆNA ZGRADA ZA ODMOR DJELATNIKA
MJESTO GRADNJE:	VALPOVO, Zona malog gospodarstva II k.č.br. 2782/6, k.o. Valpovo
GLAVNI PROJEKTANT:	BRANKO PRIŠČ, dipl.ing.arh.
PROJEKTANT:	BRANKO PRIŠČ, dipl.ing.arh.
ZAJEDNIČKA OZNAKA PROJEKTA:	37/15
BROJ PROJEKTA:	37/15 A
DATUM IZRADE:	ožujak, 2017.

razmaku od 8 m, što je ujedno i raster glavnih poprečnih osi. Visina poprečnog presjeka grede je 53 cm nad osloncem (iznad stupa) odnosno 97 cm u sljemenu.

Uzdužnu ukrutu i stabilizaciju glavnih krovnih greda iznad oslonaca čine ukrutne rubne grede RG (pos ISKu) koje ujedno i osiguravaju zajednički rad AB stupova u uzdužnom smjeru.

AB montažni stupovi dimenzija poprečnog presjeka 50/50 cm izvode se kao konzolni, visine 6,13 m i 7,88 m, s vitkošću od 84 i 100, upeti u temeljne čašice visine 100 cm ispod kojih se izvode temeljne stope debljine 40 cm. Temeljne stope su, u nivou temeljnih čašica, poprečno i uzdužno međusobno povezane i ukružene temeljnim gredama.

Između osi 3 i 6 na visini od cca. 430 cm postavljene su uzdužne čelične kranske grede „ČKG“ oslonjene na kratke AB konzole „izvučene“ iz pripadajućih montažnih AB stupova. Ovim projektom su se proračunale čelične podložne grede ČKG, dok se pripadajuća čelična konstrukcija krana smatra opremom te se neće posebno proračunati – za istu je potrebno dostaviti proizvođačevu certificiranu tehničku dokumentaciju.

Fasadnu oblogu čine horizontalni termoizolacijski čelični paneli debljine 12 cm oslonjeni direktno na AB fasadne stupove, odnosno čelične sekundarne stupove postavljene na zabatima te u prvim kutnim poljima hale, gdje se može očekivati pojačano usisno djelovanje vjetra.

Obrada površina i materijali

- Fasadu zgrade čine termopaneli debljine 12 cm.
- Odvodnju oborinskih voda sa zgrade riješiti horizontalnim olucima od inoxa, a vertikalni limeni oluci će se postaviti na fasadu. Oborinska voda će se upuštati u sustav javne odvodnje.
- Pod u hali će biti betonski, a u administrativnom dijelu zgrade će pod biti od keramičkih pločica.
- Zidovi prostorija žbukaju se grubo i fino te farbaju posnim bojama u svjetlom tonu, a u administrativnom dijelu zgrade strop će biti "spušteni" od gips – kartonskih ploča. Zidovi u čajnoj kuhinji do visine 1,60 m, a u sanitarnim čvorovima do stropa oblažu se zidnim keramičkim pločicama sa izvlačenjem fuga.

Obrada otvora

- Na zgradi je predviđena PVC stolarija, a ulazna vrata u dio zgrade gdje je administracija predviđena je AL stolarija. Na prozore će se postaviti brisoleji.

Pokrov

- Pokrov krova čine termopaneli debljine 16 cm i nagiba krovne plohe 3.5°.

GEODETSKI SITUACIJSKI NACRT

Mjerilo 1:1000

K.o.: Valpovo
K.č.br.: 2792/6, D.L.: 81
MBR K.o.: 330973

Površina parcele P= 4.391,00 m²

Zemljište pod zgradom proizvodnog pogona P= 893,09 m²

Zemljište pod pomoćnom zgradom P= 55,00 m²

Ukupnom: P= 948,09 m²


Izgrađenost parcele:


$948,09 \times 100 / 4.391,00 = 21,59\%$

kig = 0,22


kig max. = 0,60

Zelena površina: P=2.437,95 m² (55,52 %)





PIP PROJEKT IZLOG ZA PROJEKTOVANJE IZ OBLASTI GRAĐEVINARSTVA "POSREDOVANJE U PROMETU NEPOKRETNOSTI" "POSREDOVANJE U PROMETU NEPOKRETNOSTI"		GRAĐEVINARSKI PROJEKTOVNI POGON - HALA ZA MONTAŽU MONTAŽNA PRESJEK 1-1		1:100 1:100 1:100		LIST 6
IMENLOKACIJA TEO. IZLOG D.O.O. BEOGRAD UL. BEOGRADSKA 3 11000 BEOGRAD	NAZIV HALA ZA MONTAŽU MONTAŽNA PRESJEK 1-1	ZEM. 30115	B.P. 30116	A.M. 1100	LIST 6	1:100 1:100 1:100



169

Prilog P.2. Izvadak iz Izvedbenog projekta strojarskih instalacija



ALFA & OMEGA d.o.o.
za projektiranje, inženjering i usluge
Belišće, Rana Josipa Jelačića 41
OIB:60271385112

INVESTITOR: TEO – BELIŠĆE d.o.o. Belišće, Radnička ulica 3

GRAĐEVINA: Proizvodni pogon – hala za montažu

LOKACIJA: Valpovo, Zona malog gospodarstva II, k.č.br. 2792/8, k.o. Valpovo

DOKUMENTACIJA: Izvedbeni projekt-Strojarski projekt instalacija plina, grijanja, hlađenja i hidrantske mreže

ZOP: 37/15-I

OP: 01215

Belišće, prosinac, 2018.

8

2. TEHNIČKI OPIS

Projektom je riješena instalacija plina, grijanja, hlađenja i hidrantske mreže.

PLINSKA INSTALACIJA

- Plin se koristi za potrebe proizvodnog pogona.
- Ukupno potrebna količina plina za građevinu je 6,09 m³/h.
- Za građevinu se izvodi plinski priključak iz PE-HD d32x3,0mm cijevi, priključenjem na ulični distributivni plinovod od PE-HD cijevi d63x5,8mm, pomoću sedla za spajanje pod tlakom plina d63/32
- Plin se koristi za potrebe kondenzacijskih plinskih cirklo bojlera za grijanje
- MRS-a (zaporna slavina, plinomjer i regulator tlaka) je samostojeća smještena u zelenom pojasu ispred zgrade
- MRS-a je građena iz slijedećih elemenata:
 - plinska slavina NO25, NP6
 - srednjetačnog regulatora tlaka tip KHRS-2-5AA1,KOGAZ, p_u=1-4 bar, p_L=22 mbar
 - plinomjera s mjerom G6 s temperaturnom kompenzacijom
- Neposredno uz plinska trošila montirane su zaporne plinske slavine
- nakon MRS-e cijev se vodi ukopano PE-HD cijevima do zgrade, zatim se uzdiže i pod stropom vodi do mjesta spuštanja prema plinskim trošilima
- Mjereni dio instalacije završava plinskom slavinom za svako plinsko trošilo. Plinsko trošilo je na plinsku instalaciju spojeno krutom vezom. Prodori kroz zidove i podove izvode se u zaštitnim cijevima za dva nazivna promjera većim od plinske cijevi, koja sprječava dodir plinske cijevi s materijalima za površinsku obradu zida. Međuprostor se brtvi trajno elastičnim sredstvom i osigurava dilataranje cijevi. Ovješanje cijevi, prodori kroz zidove i podove te oslonci trebaju biti riješeni tako da ne dolazi do progiba cijevi te omogućiti kompenziranje toplinskih dilatacija. Obujmnice postaviti tako da razmak između njih bude kako je prikazano u tablici:

Nazivna dimenzija (NO)	Razmak između obujmica (m)
32	3,75
25	3,50
20	3,00

- Cjevovod plina se mora oličiti. Prije ličenja cjevovod se ispituje na nepropusnost. Sve metalne dijelove treba očistiti i premazati sa dva sloja temeljne boje i završnim lakom – žuta boja RAL 1021.
- Izvedbu cjelokupne instalacije treba vršiti prema važećim smjernicama distributera plina.
- Plinska instalacija mora se izvoditi samo sa kvalitetnim i atestiranim materijalom – plinovod iz čeličnih bešavnih cijevi prema HRN C.B5.225, spojnice iz temper lijeva i odgovarajuća plinska armatura. Prije ugradnje sve cijevi, armaturu i spojnice potrebno je iznutra očistiti od svih nečistoća.
- Cijevi se međusobno spajaju zavarivanjem dok se plinomjer, plinska trošila i armatura spajaju priрубnicama, spojnica ili navojem. Spojevi na navoj smiju se izvoditi samo izvan zida. Brtvljenje izvesti sa kudeljom uz obavezno premazivanje masom otpornom na plin ili sa plastičnim brtvenim trakama. Sve cijevi oličiti žutom bojom uz predhodno čišćenje od hrđe i ličenje temeljnim premazom. Nakon izvršene montaže potrebno je izvesti ispitivanje plinske instalacije, te probni pogon instalacije.
- odvod produkata izgaranja te dovod zraka za izgaranje putem koncentričnog zrako/dimovoda iznad krova, trošila neovisna o zraku iz prostora u kojem se nalaze.
- cijeli objekt može se isključiti iz plinske mreže putem zaporne plinske slavine koja se nalazi unutar MRS-e



ALFA & OMEGA d.o.o.
za projektiranje, inženjering i usluge
Belišće, Rana Josipa Jelačića 41
OIB:60271385112

9

INVESTITOR: TEO – BELIŠĆE d.o.o. Belišće, Radnička ulica 3 ZOP: 37/15-I
GRAĐEVINA: Proizvodni pogon – hala za montažu OP: 01215
LOKACIJA: Valpovo, Zona malog gospodarstva II, k.č.br. 2792/6, k.o. Valpovo Belišće, prosinac, 2016.

DOKUMENTACIJA: Izvedbeni projekt-Strojarski projekt instalacija plina, grijanja, hlađenja i hidrantske mreže

- prije punjenja plinske instalacije zemnim plinom potrebno je istu isprati inertnim plinom prema propisima
- kompletnu plinsku instalaciju je potrebno spojiti na zajednički sustav uzemljenja građevine

UVJETI I UPUTE ZA MONTAŽU PLASTIČNIH PLINOVODA

PE - HD plinovod polaže se u zemlju na dubinu 0,8-1 m, koji se zaštićuje slojem pijeska 10 cm iznad gornjeg ruba cijevi. Udaljenost plinovoda od objekata i postojećih instalacija je takva da zadovoljava minimalne udaljenosti propisane vežećim tehničkim propisima.

Preporučene minimalne udaljenosti polietilenskih plinovoda od drugih komunalnih instalacija:

Naziv instalacije	Križanje (m)	Paralelno vođenje (m)
plinovodi međusobno	0,2	0,6
plinovodi prema vodovodu i kanalizaciji	0,2	0,6
plinovodi do visokonaponskih kablova u naselju	0,3	0,6
plinovodi prema informacijskim kablovima	0,3	0,5
plinovodi prema benzinskim stanicama i rezervoarima	-	5,0
plinovodi od šahtova i kanala	0,3	0,6

Plinovode iz PE-HD cijevi smiju izvoditi stručne ekipe poduzeća registrirana za ovakve radove koja ispunjavaju i posebne uvjete određene odgovarajućim propisima (DVGW, radni list GW 301), odnosno zahtjevima distributera plina.

Radove na izradi plinovoda iz PE-HD cijevi mogu izvoditi za to obučeni djelatnici, koji imaju odgovarajući dokaz o obučenosti - uvjerenje o obučenosti.

Izvođač radova treba imati odgovarajuće uređaje: vozila, naprave, pribor i alat za dopremu cjevovoda i elemenata plinovoda, odmotavanje cijevi s kolutova, njihovo polaganje u rov, pripremu površine za zavarivanje, ispravljanje ovalnosti i fiksiranje cijevi za vrijeme izvođenja zavora, bušenje cijevi, zavarivanje cijevi i cijevnih elemenata.

GRIJANJE I HLAĐENJE

Projektom je planirano sustav grijanja riješiti pomoću duplih sustava grijanja. Kao primarni izvor toplinske energije za grijanje planirani su zidni kondenzacijski cirklo boileri za grijanje. Grijanje je predviđeno podno u uredskom dijelu zgrade, dok je u pogonskom planirano grijanje toplovodnim zračnim panelima.

Podno grijanje će raditi na niskotemperaturnom režimu vode maksimalne temperature polaza od 45°C, dok je grijanje panelima predviđeno na režimu 80/60°C.

Osnovne karakteristike :

- izvor topline :
 - plinski kondenzacijski boileri turbo izvedbe, smješteni u montaži i kuhinji. Opremljeni sa svom potrebitom sigurnosnom i upravljačkom opremom (sigurnosni ventil, granični termostat, ekspanzijska posuda, cirkulacijska pumpa ...)
 - odvod produkata izgaranja te dovod zraka za izgaranje plinskih kondenzacijskih cirklo boileri putem koncentričnih zrako/dimovoda iznad krova, trošila neovisna o zraku iz prostora u kojem se nalaze.
- vrsta cijevi za podno grijanje: peroksidno umreženi polietilen (PeXa) kao Rautherm S17x2,0
- Regulacija temperature u uredskim prostorijama će biti izvršena putem sobnih termostata, dok je u pogonu predviđena regulacija povezana s grijaćim panelima.

U cijeloj zgradi je predviđeno upravljanje radom grijanja u ovisnosti o vanjskoj temperaturi.

Kao sekundarni sustav grijanja koriste se inverterske split jedinice koje primarno služe za rashlađivanje prostora.

Split sustav hlađenja:

Sukladno željama investitora, hlađenje je planirano u sljedećim prostorima sa sljedećim kondicijskim parametrima:



ALFA & OMEGA d.o.o.
za projektiranje, inženjering i usluge
Belišće, Bina Josipa Jelačića 41
01860271385112

10

INVESTITOR: TEO – BELIŠĆE d.o.o. Belišće, Radnička ulica 3
ZOP: 37/15-I
GRAĐEVINA: Proizvodni pogon – hala za montažu
OP: 01215
LOKACIJA: Valpovo, Zona malog gospodarstva II, k.č.br. 2792/8, k.o. Valpovo
Belišće, prosinac, 2018.
DOKUMENTACIJA: Izvedbeni projekt-Strojarski projekt instalacija plina, grijanja, hlađenja i hidrantske mreže

Prizemlje**Prostorija**

Ured poslovođe	split klima 2,5kW - zidna jedinica
Prostorija za sastanke	split klima 5,0kW - kazetna jedinica
Ured 2	split klima 2,5kW - zidna jedinica
Ured 1	split klima 2,5kW - zidna jedinica

Kat**Prostorija**

Ured 1	split klima 2,5kW - zidna jedinica
Ured 2	split klima 2,5kW - zidna jedinica
Prostorija za sastanke	split klima 3,5kW - kazetna jedinica
Konstrukcija	split klima 6,0kW - kazetna jedinica

Za svaku prostoriju su planirani „split“-sustavi, jedna vanjska + jedna unutarnja jedinica. Vanjske jedinice je planirano montirati na krovu dijela građevine, iznad predmetnih prostorija. Dok su unutarnje jedinice planirane kao zidne i kazetne - smještene u spušenom stropu prostorija. Cijevni razvod freona od unutarnjih jedinica, planiran je bakrenim cijevima u toplinskoj izolaciji, u zidu od siporexa do spušenog stropa kata i dalje kroz krov do vanjskih jedinica. Odvod kondenzata iz unutarnjih jedinica, je planirano odvesti debelostijanim PVCU cijevima za hladnu vodu, ili toplinski izoliranim PVC cijevima u spušenom stropu i estrihu poda etaža, sa spojem na najbliže oborinske vertikale građevine ili u sustav kanalizacije, preko podne rešetke ili sifona sa slikonskom lopicom, radi sprečavanje povrata neugodnih mirisa.

Slijedi opis planiranih split sustava:

tip 3 - "split" klima jedinica - inverter

1 vanjska + 1 unutarnja zidna jedinica

Qhlađ=1,3-2,5-3,2kW; Qgrij=1,3-2,8-4,7kW

el. snaga 0,31-0,62-1,41kW; 1Ph; 220V; 50HZ, napajanje na vanjsku jedinicu

ožičenje: 3 x 2,5mm² napajanje; 5 x 1,5mm² signalni vod

energetski razred A, rashladno sredstvo R 410A,

priključni cijevovod: tekućina 6,35mm; plin 9,53mm u toplinskoj izolaciji,

maximalna duljina cijevovoda 20m; maksimalna visinska razlika između vanjske i unutarnje jedinice

8m, na cijevnom razvodu, na najpogodnijem mjestu izvesti sifon, radi zadržavanja ulja kompresora

tip 4 - "split" klima jedinica - inverter

1 vanjska + 1 unutarnja kazetna jedinica

Qhlađ=1,4-3,4-3,7kW; Qgrij=1,4-4,2-5,0kW

el. snaga 1,23kW; 1Ph; 220V; 50HZ, napajanje na vanjsku jedinicu

ožičenje: 3 x 2,5mm² napajanje; 5 x 1,5mm² signalni vod

energetski razred A, rashladno sredstvo R 410A,

priključni cijevovod: tekućina 6,35mm; plin 9,53mm u toplinskoj izolaciji,

maximalna duljina cijevovoda 20m; maksimalna visinska razlika između vanjske i unutarnje jedinice

8m, na cijevnom razvodu, na najpogodnijem mjestu izvesti sifon, radi zadržavanja ulja kompresora

tip 5 - "split" klima jedinica - inverter

1 vanjska + 1 unutarnja kazetna jedinica

Qhlađ=1,7-6,0-6,7kW; Qgrij=1,7-7,0-8,0kW

el. snaga 0,4-2,0-2,8kW; 1Ph; 220V; 50HZ, napajanje na vanjsku jedinicu

ožičenje: 3 x 2,5mm² napajanje; 5 x 1,5mm² signalni vod


energetski razred A, rashladno sredstvo R 410A,

priključni cijevovod: tekućina 6,35mm; plin 12,7mm u toplinskoj izolaciji,

maximalna duljina cijevovoda 20m; maksimalna visinska razlika između vanjske i unutarnje jedinice

8m, na cijevnom razvodu, na najpogodnijem mjestu izvesti sifon, radi zadržavanja ulja kompresora





Izvadak iz projekta korišten uz dozvolu investitora (TEO-Belišće d.o.o.)

Prilog P.3. Izvadak iz Izvedbenog elektrotehničkog projekta



Izvadak iz projekta korišten uz dozvolu investitora (TEO-Belišće d.o.o.)

Prilog P.4. Detaljan prikaz realnog modela zgrade s početnim parametrima (4R3C varijanta)

$T=$

```
wall_618_outside
wall_618_inside
wall_618_space_warehouse_939
wall_927_outside
wall_927_inside
wall_927_space_mechanical_144
wall_744_outside
wall_744_inside
wall_744_space_assembly_382
wall_590_outside
wall_590_inside
wall_590_space_warehouse_939
wall_369_space_warehouse_939
wall_369_inside
wall_369_outside
wall_509_space_entry_348
wall_509_inside
wall_509_outside
wall_654_space_assembly_382
wall_654_inside
wall_654_outside
wall_442_space_warehouse_939
wall_442_inside
wall_442_space_mechanical_144
wall_420_space_warehouse_939
wall_420_inside
wall_420_space_entry_348
wall_699_space_mechanical_144
wall_699_inside
wall_699_space_entry_348
wall_208_space_mechanical_144
wall_208_inside
wall_208_space_assembly_382
wall_516_space_assembly_382
wall_516_inside
wall_516_outside
wall_436_space_entry_348
wall_436_inside
wall_436_space_assembly_382
roof_676_outside
roof_676_inside
roof_676_space_warehouse_939
roof_911_outside
roof_911_inside
roof_911_space_mechanical_144
roof_136_outside
roof_136_inside
roof_136_space_entry_348
roof_105_outside
roof_105_inside
roof_105_space_assembly_382
space_assembly_382
space_mechanical_144
space_warehouse_939
space_entry_348
```

Prilozi

$$\mathbf{u} = \begin{bmatrix} \text{outside} \\ \text{source_sun_east_629} \\ \text{source_sun_south_500} \\ \text{source_sun_west_57} \\ \text{source_sun_roof_432} \\ \text{source_heating_offices_835} \\ \text{source_summary_assembly_624} \\ \text{source_summary_mechanical_60} \\ \text{source_summary_entry_924} \\ \text{source_summary_warehouse_622} \end{bmatrix}$$

$$\mathbf{y} = \begin{bmatrix} \text{space_assembly_382} \\ \text{space_mechanical_144} \\ \text{space_warehouse_939} \\ \text{space_entry_348} \end{bmatrix}$$

Prilozi

A=

Nastavak matrice A

179

Prilozi

Nastavak matrice A

0	0	0	0	0
0	0	0	0	0
0	0	0	6,3E-05	0
0	0	0	0	0
0	0	0	0	0
0	0	6,2E-05	0	0
0	0	0	0	0
0	0	0	0	0
0	5,2E-05	0	0	0
0	0	0	0	0
0	0	0	0	0
0	0	0	5,8E-05	0
0	0	0	1,3E-04	0
0	0	0	0	0
0	0	0	0	0
0	0	0	0	3,8E-05
0	0	0	0	0
0	0	0	0	0
0	4,5E-05	0	0	0
0	0	0	0	0
0	0	0	0	0
0	0	0	6,3E-05	0
0	0	0	0	0
0	0	5,1E-05	0	0
0	0	0	7,2E-05	0
0	0	0	0	0
0	0	0	0	4,4E-05
0	0	4,6E-05	0	0
0	0	0	0	0
0	0	0	0	4,5E-05
0	0	3,5E-05	0	0
0	0	0	0	0
0	4,0E-05	0	0	0
0	6,4E-05	0	0	0
0	0	0	0	0
0	0	0	0	0
0	0	0	0	1,1E-04
0	0	0	0	0
0	5,2E-05	0	0	0
0	0	0	0	0
0	0	0	0	0
0	0	0	6,1E-05	0
0	0	0	0	0
0	0	0	0	0
0	0	1,0E-04	0	0
0	0	0	0	0
0	0	0	0	0
0	0	0	0	6,8E-05
0	0	0	0	0
1,0E-02	0	0	0	0
-3,3E-03	7,9E-05	0	0	0
2,3E-04	-8,9E-04	2,4E-05	0	2,2E-05
0	1,6E-05	-2,4E-04	0	0
0	0	0	-5,0E-04	1,8E-05
0	1,5E-05	0	1,5E-05	-2,3E-04

Prilozi

B=

Prilozi

[illegible]

$$D = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}$$

Prilog P.5. Prikaz rezultata optimizacija s fokusom na metode optimizacije

Model		Podaci o optimizaciji		
Referentni model	Testni model	Algoritam	MaxFunEvals	kriterij
mjerenja	realni model 4R3C	fminsearch	200.000	NRMSE
mjerenja	realni model 4R3C	fminunc, quasi-newton	200.000	NRMSE
mjerenja	realni model 4R3C	fmincon, interior point, s ograničenjima -1...1	200.000	NRMSE
mjerenja	realni model 4R3C	fmincon, interior point, bez ograničenja	200.000	NRMSE
mjerenja	realni model 4R3C	fmincon, sqp, s ograničenjima -1...1	200.000	NRMSE
mjerenja	realni model 4R3C	fmincon, sqp, bez ograničenja	200.000	NRMSE
mjerenja	realni model 4R3C	fmincon, active-set, s ograničenjima -1...1	21.503	NRMSE
mjerenja	realni model 4R3C	fmincon, active-set, bez ograničenja		NRMSE
mjerenja	realni model 4R3C	lsqnonlin, 'levenberg-marquardt'	200.000	NRMSE

Referentni podaci (korišteni za optimizaciju)		Optimizacija			
Podaci za optimizaciju	Sati	Vremens. konstanta	Početak	Kraj	Trajanje optimiz.
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2. raspodjela po radijatorima	144	3600	22:10:10	22:10:17	0:00:07
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2. raspodjela po radijatorima	144	3600	14:13:40	14:20:07	0:06:27
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2. raspodjela po radijatorima	144	3600	20:55:44	21:44:51	0:49:07
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2. raspodjela po radijatorima	144	3600	14:54:50	15:25:47	0:30:57
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2. raspodjela po radijatorima	144	3600	21:53:30	6:22:27	8:28:57
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2. raspodjela po radijatorima	144	3600	14:27:06	14:36:39	0:09:33
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2. raspodjela po radijatorima	144	3600	8:45:32		
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2. raspodjela po radijatorima	144	3600	14:53:23		
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2. raspodjela po radijatorima	144	3600	23:05:07	23:26:45	0:21:38

Simulacija s referentnim podacima								
TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
9,12E+03	1,65E+01	5,22E+00	9,08E+03	1,65E+01	5,20E+00	1,00	1,00	1,00
9,12E+03	1,65E+01	5,22E+00	3,10E+02	7,02E-01	2,04E-01	29,43	23,54	25,61
9,12E+03	1,65E+01	5,22E+00	1,93E+02	4,28E-01	1,36E-01	47,32	38,59	38,33
9,12E+03	1,65E+01	5,22E+00	1,50E+02	3,33E-01	9,69E-02	60,70	49,65	53,81
9,12E+03	1,65E+01	5,22E+00	1,32E+02	2,84E-01	8,54E-02	69,26	58,24	61,11
9,12E+03	1,65E+01	5,22E+00	1,41E+02	3,07E-01	9,21E-02	64,60	53,90	56,62
9,12E+03	1,65E+01	5,22E+00	/	/	/	/	/	/
9,12E+03	1,65E+01	5,22E+00	/	/	/	/	/	/
9,12E+03	1,65E+01	5,22E+00	1,91E+03	4,14E+00	1,26E+00	4,77	3,99	4,16

Prilog P.6. Prikaz rezultata optimizacija s fokusom na odabir vremena uzorkovanja i razdiobu energije

Model		Podaci o optimizaciji		
Referentni model	Testni model	Algoritam	MaxFunEvals	kriterij
mjerjenja	realni model 4R3C	fmincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton, bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 2R1C	fmincon interior-point bez ograničenja	655.703	NRMSE
mjerjenja	realni model 2R1C	fminunc, quasi-newton, bez ograničenja	524.887	NRMSE
mjerjenja	realni model 4R3C	fmincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton, bez ograničenja	1.677.144	NRMSE
mjerjenja	realni model 2R1C	fmincon interior-point bez ograničenja	655.204	NRMSE
mjerjenja	realni model 2R1C	fminunc, quasi-newton, bez ograničenja	510.516	NRMSE
mjerjenja	realni model 4R3C	fmincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton, bez ograničenja	1.666.418	NRMSE
mjerjenja	realni model 2R1C	fmincon interior-point bez ograničenja	277.805	NRMSE
mjerjenja	realni model 2R1C	fminunc, quasi-newton, bez ograničenja	599.226	NRMSE
mjerjenja	realni model 4R3C	fmincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton, bez ograničenja	1.684.296	NRMSE
mjerjenja	realni model 2R1C	fmincon interior-point bez ograničenja	655.271	NRMSE
mjerjenja	realni model 2R1C	fminunc, quasi-newton, bez ograničenja	562.676	NRMSE
mjerjenja	realni model 4R3C	fmincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton, bez ograničenja	50.067	NRMSE
mjerjenja	realni model 2R1C	fmincon interior-point bez ograničenja	308.576	NRMSE
mjerjenja	realni model 2R1C	fminunc, quasi-newton, bez ograničenja	424.485	NRMSE

Referentni podaci (korišteni za optimizaciju)			Optimizacija		
Podaci za optimizaciju	Sati	Vrem. konst.	Početak	Kraj	Trajanje optimiz.
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	22:55:33	6:35:49	7:40:16
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	22:03:00	23:32:03	1:29:03
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	21:19:15	21:50:30	0:31:15
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	22:02:06	22:21:18	0:19:12
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	3600	23:14:06	6:38:26	7:24:20
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	3600	9:47:48	10:42:13	0:54:25
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	3600	8:53:25	9:17:34	0:24:09
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	3600	22:44:11	22:59:26	0:15:15
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2. raspodj.	144	900	23:23:20	6:50:13	7:26:53
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2. raspodj.	144	900	19:43:24	20:56:25	1:13:01
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2. raspodj.	144	900	20:08:09	20:20:12	0:12:03
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2. raspodj.	144	900	22:28:11	22:51:59	0:23:48
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2. raspodj.	144	3600	22:35:47	6:18:46	7:42:59
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2. raspodj.	144	3600	20:31:21	21:27:24	0:56:03
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2. raspodj.	144	3600	21:16:46	21:43:23	0:26:37
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2. raspodj.	144	3600	22:06:30	22:23:23	0:16:53
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	300	23:05:55	6:58:20	7:52:25
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	300	22:22:31	22:26:40	0:04:09
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	300	22:31:33	22:51:47	0:20:14
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	300	22:58:12	23:20:26	0:22:14

Prilozi

TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
3,65E+04	1,65E+01	5,50E+00	1,74E+02	1,07E-01	3,49E-02	209,87	154,99	157,70
3,65E+04	1,65E+01	5,50E+00	2,57E+02	1,49E-01	4,79E-02	142,19	110,93	114,71
4,18E+04	1,85E+01	6,17E+00	2,16E+02	1,27E-01	4,14E-02	193,18	145,05	149,14
4,18E+04	1,85E+01	6,17E+00	2,39E+02	1,39E-01	4,45E-02	175,05	133,22	138,48
9,11E+03	1,65E+01	5,21E+00	4,14E+01	9,65E-02	2,89E-02	219,92	171,09	180,03
9,11E+03	1,65E+01	5,21E+00	6,19E+01	1,43E-01	4,25E-02	147,08	115,59	122,59
1,04E+04	1,85E+01	5,85E+00	3,70E+01	8,77E-02	2,63E-02	281,49	210,46	222,12
1,04E+04	1,85E+01	5,85E+00	4,25E+01	9,70E-02	2,91E-02	245,08	190,41	201,08
3,66E+04	1,66E+01	5,51E+00	1,74E+02	1,06E-01	3,47E-02	209,94	155,60	158,60
3,66E+04	1,66E+01	5,51E+00	2,66E+02	1,53E-01	4,95E-02	137,63	108,27	111,29
4,18E+04	1,85E+01	6,18E+00	2,77E+02	1,58E-01	5,14E-02	150,94	117,51	120,25
4,18E+04	1,85E+01	6,18E+00	2,11E+02	1,23E-01	4,02E-02	198,03	150,29	153,83
9,12E+03	1,65E+01	5,22E+00	3,86E+01	9,01E-02	2,70E-02	236,00	183,43	193,47
9,12E+03	1,65E+01	5,22E+00	6,48E+01	1,49E-01	4,43E-02	140,76	111,22	117,66
1,04E+04	1,85E+01	5,85E+00	3,75E+01	8,86E-02	2,68E-02	278,14	208,58	218,42
1,04E+04	1,85E+01	5,85E+00	4,06E+01	9,67E-02	2,89E-02	256,64	191,15	202,23
1,11E+05	1,67E+01	5,40E+00	6,84E+02	1,38E-01	4,39E-02	161,55	121,02	122,87
1,11E+05	1,67E+01	5,40E+00	3,14E+04	5,53E+00	1,68E+00	3,52	3,01	3,21
1,26E+05	1,86E+01	6,05E+00	1,66E+03	3,14E-01	1,04E-01	76,03	59,32	58,01
1,26E+05	1,86E+01	6,05E+00	1,28E+03	2,35E-01	7,61E-02	98,84	79,36	79,49

Simulacija s testnim skupom Zimski skup 1 (od 26.2. do 27.2.)

TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
1,16E+04	1,62E+01	5,74E+00	4,16E+02	6,55E-01	2,09E-01	27,85	24,68	27,46
1,16E+04	1,62E+01	5,74E+00	2,21E+02	3,67E-01	1,25E-01	52,50	44,06	45,94
1,61E+04	2,15E+01	7,74E+00	8,18E+02	1,22E+00	4,50E-01	19,70	17,65	17,21
1,61E+04	2,15E+01	7,74E+00	3,49E+02	5,80E-01	1,97E-01	46,12	37,01	39,36
2,88E+03	1,61E+01	6,22E+00	1,96E+02	1,23E+00	4,84E-01	14,70	13,10	12,86
2,88E+03	1,61E+01	6,22E+00	1,69E+02	1,04E+00	3,98E-01	17,05	15,52	15,64
4,00E+03	2,14E+01	8,40E+00	6,17E+02	4,00E+00	1,61E+00	6,48	5,35	5,23
4,00E+03	2,14E+01	8,40E+00	1,23E+02	7,48E-01	2,78E-01	32,42	28,61	30,27
1,16E+04	1,62E+01	5,76E+00	5,04E+02	7,84E-01	2,67E-01	23,06	20,65	21,57
1,16E+04	1,62E+01	5,76E+00	1,91E+02	3,21E-01	1,01E-01	60,86	50,45	57,16
1,61E+04	2,15E+01	7,76E+00	2,85E+02	4,85E-01	1,64E-01	56,72	44,36	47,34
1,61E+04	2,15E+01	7,76E+00	3,42E+02	6,23E-01	2,28E-01	47,24	34,49	34,06
2,89E+03	1,61E+01	6,24E+00	1,48E+02	1,02E+00	3,93E-01	19,54	15,76	15,88
2,89E+03	1,61E+01	6,24E+00	1,49E+02	9,13E-01	3,50E-01	19,33	17,67	17,84
4,01E+03	2,14E+01	8,42E+00	2,04E+02	1,33E+00	4,94E-01	19,59	16,15	17,05
4,01E+03	2,14E+01	8,42E+00	1,50E+02	9,67E-01	3,79E-01	26,67	22,15	22,20
3,54E+04	1,64E+01	5,57E+00	9,76E+02	5,09E-01	1,71E-01	36,25	32,19	32,57
3,54E+04	1,64E+01	5,57E+00	1,98E+04	9,81E+00	3,13E+00	1,79	1,67	1,78
4,89E+04	2,17E+01	7,47E+00	2,94E+03	1,40E+00	5,01E-01	16,64	15,43	14,92
4,89E+04	2,17E+01	7,47E+00	9,56E+02	5,24E-01	1,82E-01	51,16	41,39	40,95

Prilozi

Simulacija s testnim skupom Zimski skup 2 (od 28.2. do 1.3.)

TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
1,23E+04	1,79E+01	4,81E+00	8,28E+02	1,20E+00	3,23E-01	14,84	14,89	14,86
1,23E+04	1,79E+01	4,81E+00	9,45E+02	1,34E+00	2,97E-01	13,00	13,33	16,17
1,88E+04	2,56E+01	6,70E+00	5,52E+02	8,50E-01	1,83E-01	34,02	30,18	36,69
1,88E+04	2,56E+01	6,70E+00	7,83E+02	1,15E+00	2,44E-01	23,97	22,36	27,49
3,00E+03	1,75E+01	5,15E+00	2,52E+02	1,53E+00	4,65E-01	11,90	11,43	11,09
3,00E+03	1,75E+01	5,15E+00	1,23E+02	7,73E-01	2,20E-01	24,29	22,65	23,36
4,59E+03	2,52E+01	7,25E+00	1,01E+03	6,39E+00	1,77E+00	4,54	3,94	4,11
4,59E+03	2,52E+01	7,25E+00	4,82E+02	2,85E+00	8,02E-01	9,54	8,84	9,04
1,23E+04	1,79E+01	4,80E+00	7,91E+02	1,16E+00	3,10E-01	15,55	15,45	15,52
1,23E+04	1,79E+01	4,80E+00	5,66E+02	8,82E-01	2,20E-01	21,74	20,28	21,86
1,88E+04	2,57E+01	6,70E+00	5,45E+02	8,62E-01	2,30E-01	34,52	29,79	29,11
1,88E+04	2,57E+01	6,70E+00	5,98E+02	9,22E-01	2,07E-01	31,45	27,85	32,46
3,00E+03	1,75E+01	5,15E+00	2,22E+02	1,41E+00	4,09E-01	13,54	12,38	12,58
3,00E+03	1,75E+01	5,15E+00	1,46E+02	8,99E-01	2,62E-01	20,58	19,49	19,63
4,60E+03	2,52E+01	7,25E+00	6,06E+02	3,64E+00	1,06E+00	7,59	6,93	6,84
4,60E+03	2,52E+01	7,25E+00	3,63E+02	2,15E+00	5,86E-01	12,67	11,74	12,39
3,75E+04	1,81E+01	4,72E+00	1,66E+03	8,75E-01	2,19E-01	22,59	20,73	21,55
3,75E+04	1,81E+01	4,72E+00	1,96E+04	1,10E+01	3,07E+00	1,91	1,65	1,54
5,70E+04	2,59E+01	6,56E+00	3,28E+03	1,64E+00	3,66E-01	17,38	15,81	17,92
5,70E+04	2,59E+01	6,56E+00	2,65E+03	1,31E+00	2,78E-01	21,53	19,73	23,55

Simulacija s testnim skupom Prijelazni skup 1 (od 12.3. do 13.3.)

TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
3,42E+03	5,03E+00	3,03E+00	5,74E+02	9,98E-01	6,50E-01	5,95	5,04	4,66
3,42E+03	5,03E+00	3,03E+00	2,66E+02	4,27E-01	2,77E-01	12,83	11,78	10,94
4,58E+03	6,94E+00	4,34E+00	3,21E+02	5,12E-01	3,55E-01	14,25	13,56	12,24
4,58E+03	6,94E+00	4,34E+00	3,12E+02	5,33E-01	2,72E-01	14,69	13,02	15,95
8,47E+02	5,01E+00	3,21E+00	4,36E+02	2,94E+00	2,10E+00	1,94	1,70	1,53
8,47E+02	5,01E+00	3,21E+00	3,69E+02	2,10E+00	1,37E+00	2,29	2,38	2,34
1,14E+03	6,91E+00	4,60E+00	1,53E+03	1,03E+01	7,16E+00	0,74	0,67	0,64
1,14E+03	6,91E+00	4,60E+00	4,02E+02	2,73E+00	1,75E+00	2,83	2,54	2,63
3,42E+03	5,03E+00	3,04E+00	5,41E+02	9,31E-01	5,40E-01	6,33	5,40	5,62
3,42E+03	5,03E+00	3,04E+00	5,15E+02	7,75E-01	4,48E-01	6,65	6,49	6,78
4,59E+03	6,94E+00	4,35E+00	6,67E+02	1,04E+00	6,01E-01	6,88	6,67	7,23
4,59E+03	6,94E+00	4,35E+00	3,97E+02	6,26E-01	4,03E-01	11,54	11,09	10,78
8,48E+02	5,01E+00	3,22E+00	3,37E+02	2,40E+00	1,66E+00	2,52	2,08	1,94
8,48E+02	5,01E+00	3,22E+00	3,79E+02	2,20E+00	1,46E+00	2,24	2,27	2,21
1,14E+03	6,92E+00	4,60E+00	5,87E+02	4,17E+00	2,62E+00	1,94	1,66	1,76
1,14E+03	6,92E+00	4,60E+00	2,81E+02	1,88E+00	1,25E+00	4,05	3,67	3,68
/	/	/	/	/	/	/	/	/
/	/	/	/	/	/	/	/	/
/	/	/	/	/	/	/	/	/
/	/	/	/	/	/	/	/	/

Prilozi

Simulacija s testnim skupom Prijelazni skup 2 (od 10.3. do 15.3.)

TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	Δ TOTAL	Δ RMSE	Δ NRMSE
1,41E+04	6,59E+00	3,08E+00	1,19E+04	8,08E+00	3,91E+00	1,18	0,82	0,79
1,41E+04	6,59E+00	3,08E+00	1,03E+03	5,93E-01	2,57E-01	13,68	11,11	11,97
1,62E+04	7,84E+00	3,69E+00	4,24E+03	2,05E+00	1,00E+00	3,82	3,82	3,67
1,62E+04	7,84E+00	3,69E+00	2,10E+03	1,13E+00	5,05E-01	7,72	6,96	7,29
3,52E+03	6,59E+00	3,30E+00	9,92E+03	2,83E+01	1,45E+01	0,36	0,23	0,23
3,52E+03	6,59E+00	3,30E+00	2,30E+03	4,23E+00	2,12E+00	1,53	1,56	1,56
4,04E+03	7,83E+00	3,96E+00	9,90E+03	2,06E+01	1,06E+01	0,41	0,38	0,37
4,04E+03	7,83E+00	3,96E+00	6,29E+03	1,40E+01	7,06E+00	0,64	0,56	0,56
1,41E+04	6,60E+00	3,08E+00	8,23E+03	5,48E+00	2,39E+00	1,71	1,20	1,29
1,41E+04	6,60E+00	3,08E+00	3,88E+03	1,87E+00	8,46E-01	3,64	3,54	3,64
1,62E+04	7,84E+00	3,69E+00	7,23E+03	3,55E+00	1,65E+00	2,24	2,21	2,24
1,62E+04	7,84E+00	3,69E+00	1,39E+03	7,25E-01	3,32E-01	11,61	10,81	11,10
3,52E+03	6,59E+00	3,31E+00	4,04E+03	9,83E+00	4,85E+00	0,87	0,67	0,68
3,52E+03	6,59E+00	3,31E+00	2,63E+03	4,91E+00	2,47E+00	1,34	1,34	1,34
4,04E+03	7,84E+00	3,97E+00	1,59E+04	3,80E+01	1,90E+01	0,25	0,21	0,21
4,04E+03	7,84E+00	3,97E+00	2,00E+03	4,13E+00	2,08E+00	2,02	1,90	1,91
/	/	/	/	/	/	/	/	/
/	/	/	/	/	/	/	/	/
/	/	/	/	/	/	/	/	/
/	/	/	/	/	/	/	/	/

Prilog P.7. Prikaz rezultata optimizacija s fokusom na metodu greške

Model		Podaci o optimizaciji		
Referentni model	Testni model	Algoritam	MaxFunEvals	kriterij
mjerjenja	realni model 4R3C	fmnincon interior-point bez ograničenja	1.392.292	TOTAL
mjerjenja	realni model 4R3C	fmnincon interior-point bez ograničenja	2.000.000	RMSE
mjerjenja	realni model 4R3C	fmnincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 2R1C	fmnincon interior-point bez ograničenja	277.071	TOTAL
mjerjenja	realni model 2R1C	fmnincon interior-point bez ograničenja	655.612	RMSE
mjerjenja	realni model 2R1C	fmnincon interior-point bez ograničenja	655.703	NRMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton	1.380.338	TOTAL
mjerjenja	realni model 4R3C	fminunc, quasi-newton	60.794	RMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton	1.795.154	NRMSE
mjerjenja	realni model 2R1C	fminunc, quasi-newton	88.679	TOTAL
mjerjenja	realni model 2R1C	fminunc, quasi-newton	453.848	RMSE
mjerjenja	realni model 2R1C	fminunc, quasi-newton	524.887	NRMSE

Referentni podaci (korišteni za optimizaciju)			Optimizacija			
Podaci za optimizaciju	Sati	Vremenska konstanta	Početak	Kraj	Trajanje optimizacije	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	23:08:01	4:33:21	5:25:20	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	23:32:15	7:26:34	7:54:19	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	22:55:33	6:35:49	7:40:16	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	5:50:44	6:02:54	0:12:10	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	6:25:52	6:54:52	0:29:00	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	21:19:15	21:50:30	0:31:15	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	18:02:47	19:07:16	1:04:29	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	20:00:52	20:03:36	0:02:44	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	22:03:00	23:32:03	1:29:03	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	20:28:55	20:34:31	0:05:36	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	20:35:23	20:52:18	0:16:55	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	22:02:06	22:21:18	0:19:12	

Simulacija s referentnim podacima								
TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
3,65E+04	1,65E+01	5,50E+00	1,92E+02	1,22E-01	3,98E-02	190,30	135,96	138,34
3,65E+04	1,65E+01	5,50E+00	1,73E+02	1,06E-01	3,47E-02	210,94	156,39	158,42
3,65E+04	1,65E+01	5,50E+00	1,74E+02	1,07E-01	3,49E-02	209,87	154,99	157,70
4,18E+04	1,85E+01	6,17E+00	6,55E+02	4,13E+00	1,45E+00	63,80	4,47	4,25
4,18E+04	1,85E+01	6,17E+00	2,38E+02	1,39E-01	4,50E-02	175,85	132,76	137,25
4,18E+04	1,85E+01	6,17E+00	2,16E+02	1,27E-01	4,14E-02	193,18	145,05	149,14
3,65E+04	1,65E+01	5,50E+00	2,93E+02	1,75E-01	5,83E-02	124,67	94,41	94,35
3,65E+04	1,65E+01	5,50E+00	9,85E+03	5,16E+00	1,63E+00	3,71	3,21	3,37
3,65E+04	1,65E+01	5,50E+00	2,57E+02	1,49E-01	4,79E-02	142,19	110,93	114,71
4,18E+04	1,85E+01	6,17E+00	/	/	/	/	/	/
4,18E+04	1,85E+01	6,17E+00	3,56E+02	1,94E-01	6,46E-02	117,51	95,14	95,49
4,18E+04	1,85E+01	6,17E+00	2,39E+02	1,39E-01	4,45E-02	175,05	133,22	138,48

Prilozi

Simulacija s testnim skupom Zimski skup 1 (od 26.2. do 27.2.)

TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
1,16E+04	1,62E+01	5,74E+00	4,51E+02	7,00E-01	2,23E-01	25,70	23,10	25,71
1,16E+04	1,62E+01	5,74E+00	3,72E+02	5,95E-01	1,86E-01	31,16	27,18	30,82
1,16E+04	1,62E+01	5,74E+00	4,16E+02	6,55E-01	2,09E-01	27,85	24,68	27,46
1,61E+04	2,15E+01	7,74E+00	9,16E+02	6,64E+00	2,57E+00	17,59	3,23	3,01
1,61E+04	2,15E+01	7,74E+00	4,91E+02	8,04E-01	2,76E-01	32,81	26,69	28,00
1,61E+04	2,15E+01	7,74E+00	8,18E+02	1,22E+00	4,50E-01	19,70	17,65	17,21
1,16E+04	1,62E+01	5,74E+00	3,48E+02	5,41E-01	2,00E-01	33,26	29,88	28,65
1,16E+04	1,62E+01	5,74E+00	6,14E+03	9,22E+00	3,08E+00	1,89	1,75	1,86
1,16E+04	1,62E+01	5,74E+00	2,21E+02	3,67E-01	1,25E-01	52,50	44,06	45,94
1,61E+04	2,15E+01	7,74E+00	/	/	/	/	/	/
1,61E+04	2,15E+01	7,74E+00	9,61E+02	1,59E+00	5,75E-01	16,77	13,50	13,46
1,61E+04	2,15E+01	7,74E+00	3,49E+02	5,80E-01	1,97E-01	46,12	37,01	39,36

Simulacija s testnim skupom Zimski skup 2 (od 28.2. do 1.3.)

TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
1,23E+04	1,79E+01	4,81E+00	9,82E+02	1,41E+00	3,42E-01	12,51	12,70	14,06
1,23E+04	1,79E+01	4,81E+00	7,56E+02	1,09E+00	2,89E-01	16,24	16,32	16,61
1,23E+04	1,79E+01	4,81E+00	8,28E+02	1,20E+00	3,23E-01	14,84	14,89	14,86
1,88E+04	2,56E+01	6,70E+00	1,45E+03	7,88E+00	1,80E+00	12,97	3,26	3,72
1,88E+04	2,56E+01	6,70E+00	7,99E+02	1,16E+00	2,51E-01	23,49	22,06	26,71
1,88E+04	2,56E+01	6,70E+00	5,52E+02	8,50E-01	1,83E-01	34,02	30,18	36,69
1,23E+04	1,79E+01	4,81E+00	9,39E+02	1,34E+00	3,03E-01	13,08	13,34	15,88
1,23E+04	1,79E+01	4,81E+00	6,17E+03	1,04E+01	2,99E+00	1,99	1,72	1,61
1,23E+04	1,79E+01	4,81E+00	9,45E+02	1,34E+00	2,97E-01	13,00	13,33	16,17
1,88E+04	2,56E+01	6,70E+00	/	/	/	/	/	/
1,88E+04	2,56E+01	6,70E+00	1,10E+03	1,57E+00	3,50E-01	17,15	16,31	19,15
1,88E+04	2,56E+01	6,70E+00	7,83E+02	1,15E+00	2,44E-01	23,97	22,36	27,49

Simulacija s testnim skupom Prijelazni skup 1 (od 12.3. do 13.3.)

TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
3,42E+03	5,03E+00	3,03E+00	4,26E+02	6,50E-01	4,15E-01	8,02	7,73	7,30
3,42E+03	5,03E+00	3,03E+00	6,53E+02	1,23E+00	8,52E-01	5,24	4,09	3,56
3,42E+03	5,03E+00	3,03E+00	5,74E+02	9,98E-01	6,50E-01	5,95	5,04	4,66
4,58E+03	6,94E+00	4,34E+00	1,35E+03	7,89E+00	5,57E+00	3,41	0,88	0,78
4,58E+03	6,94E+00	4,34E+00	3,28E+02	5,60E-01	2,96E-01	13,97	12,39	14,65
4,58E+03	6,94E+00	4,34E+00	3,21E+02	5,12E-01	3,55E-01	14,25	13,56	12,24
3,42E+03	5,03E+00	3,03E+00	3,56E+02	5,54E-01	3,75E-01	9,59	9,07	8,09
3,42E+03	5,03E+00	3,03E+00	9,39E+03	1,47E+01	1,04E+01	0,36	0,34	0,29
3,42E+03	5,03E+00	3,03E+00	2,66E+02	4,27E-01	2,77E-01	12,83	11,78	10,94
4,58E+03	6,94E+00	4,34E+00	/	/	/	/	/	/
4,58E+03	6,94E+00	4,34E+00	3,72E+02	6,23E-01	3,66E-01	12,31	11,13	11,85
4,58E+03	6,94E+00	4,34E+00	3,12E+02	5,33E-01	2,72E-01	14,69	13,02	15,95

Simulacija s testnim skupom Prijelazni skup 2 (od 10.3. do 15.3.)

TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
1,41E+04	6,59E+00	3,08E+00	1,50E+03	8,18E-01	3,91E-01	9,44	8,06	7,87
1,41E+04	6,59E+00	3,08E+00	1,71E+04	1,04E+01	5,08E+00	0,83	0,63	0,61
1,41E+04	6,59E+00	3,08E+00	1,19E+04	8,08E+00	3,91E+00	1,18	0,82	0,79
1,62E+04	7,84E+00	3,69E+00	4,02E+03	4,90E+00	2,45E+00	4,03	1,60	1,51
1,62E+04	7,84E+00	3,69E+00	2,01E+03	1,10E+00	4,96E-01	8,06	7,10	7,43
1,62E+04	7,84E+00	3,69E+00	4,24E+03	2,05E+00	1,00E+00	3,82	3,82	3,67
1,41E+04	6,59E+00	3,08E+00	1,73E+03	9,05E-01	4,30E-01	8,17	7,29	7,16
1,41E+04	6,59E+00	3,08E+00	8,73E+04	4,48E+01	2,26E+01	0,16	0,15	0,14
1,41E+04	6,59E+00	3,08E+00	1,03E+03	5,93E-01	2,57E-01	13,68	11,11	11,97
1,62E+04	7,84E+00	3,69E+00	/	/	/	/	/	/
1,62E+04	7,84E+00	3,69E+00	3,47E+03	1,70E+00	8,03E-01	4,66	4,61	4,59
1,62E+04	7,84E+00	3,69E+00	2,10E+03	1,13E+00	5,05E-01	7,72	6,96	7,29

Prilog P.8. Prikaz rezultata optimizacija s fokusom na broj ponavljanja optimizacije

Model		Podaci o optimizaciji		
Referentni model	Testni model	Algoritam	MaxFunEvals	kriterij
mjerjenja	realni model 4R3C	fmnincon interior-point bez ograničenja	50.000	NRMSE
mjerjenja	realni model 4R3C	fmnincon interior-point bez ograničenja	100.000	NRMSE
mjerjenja	realni model 4R3C	fmnincon interior-point bez ograničenja	200.000	NRMSE
mjerjenja	realni model 4R3C	fmnincon interior-point bez ograničenja	500.000	NRMSE
mjerjenja	realni model 4R3C	fmnincon interior-point bez ograničenja	1.000.000	NRMSE
mjerjenja	realni model 4R3C	fmnincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 4R3C	fmnincon interior-point bez ograničenja	3.582.693	NRMSE
mjerjenja	realni model 2R1C	fmnincon interior-point bez ograničenja	50.000	NRMSE
mjerjenja	realni model 2R1C	fmnincon interior-point bez ograničenja	100.000	NRMSE
mjerjenja	realni model 2R1C	fmnincon interior-point bez ograničenja	200.000	NRMSE
mjerjenja	realni model 2R1C	fmnincon interior-point bez ograničenja	500.000	NRMSE
mjerjenja	realni model 2R1C	fmnincon interior-point bez ograničenja	655.703	NRMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton	50.000	NRMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton	100.000	NRMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton	200.000	NRMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton	500.000	NRMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton	1.000.000	NRMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton	1.795.154	NRMSE
mjerjenja	realni model 2R1C	fminunc, quasi-newton	50.000	NRMSE
mjerjenja	realni model 2R1C	fminunc, quasi-newton	100.000	NRMSE
mjerjenja	realni model 2R1C	fminunc, quasi-newton	200.000	NRMSE
mjerjenja	realni model 2R1C	fminunc, quasi-newton	500.000	NRMSE
mjerjenja	realni model 2R1C	fminunc, quasi-newton	524.887	NRMSE

Referentni podaci (korišteni za optimizaciju)			Optimizacija			
Podaci za optimizaciju	Sati	Vrem. konst.	Početak	Kraj	Traj. opt.	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	18:29:28	18:36:27	0:06:59	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	18:03:34	18:20:55	0:17:21	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	17:11:44	17:51:29	0:39:45	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	8:23:09	10:15:19	1:52:10	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	13:34:00	17:30:31	3:56:31	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	22:55:33	6:35:49	7:40:16	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	23:36:56	12:47:43	13:10:47	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	20:02:45	20:05:04	0:02:19	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	19:37:07	19:41:44	0:04:37	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	9:33:20	9:42:10	0:08:50	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	18:42:51	19:05:38	0:22:47	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	21:19:15	21:50:30	0:31:15	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	21:00:02	21:02:26	0:02:24	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	20:27:33	20:32:06	0:04:33	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	20:11:55	20:21:25	0:09:30	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	22:04:36	22:26:57	0:22:21	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	21:06:28	21:52:10	0:45:42	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	22:03:00	23:32:03	1:29:03	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	12:40:50	12:42:48	0:01:58	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	12:19:11	12:23:10	0:03:59	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	11:44:30	11:52:22	0:07:52	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	11:14:54	11:34:28	0:19:34	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	22:02:06	22:21:18	0:19:12	

Simulacija s referentnim podacima

Prilozi

TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
3,65E+04	1,65E+01	5,50E+00	4,80E+03	2,48E+00	8,11E-01	7,61	6,66	6,78
3,65E+04	1,65E+01	5,50E+00	1,67E+03	9,62E-01	2,99E-01	21,87	17,19	18,40
3,65E+04	1,65E+01	5,50E+00	7,02E+02	3,93E-01	1,22E-01	52,06	42,03	45,11
3,65E+04	1,65E+01	5,50E+00	2,91E+02	1,67E-01	5,41E-02	125,68	99,32	101,68
3,65E+04	1,65E+01	5,50E+00	1,89E+02	1,14E-01	3,71E-02	193,40	145,62	148,18
3,65E+04	1,65E+01	5,50E+00	1,74E+02	1,07E-01	3,49E-02	209,87	154,99	157,70
3,65E+04	1,65E+01	5,50E+00	1,72E+02	1,05E-01	3,45E-02	212,21	156,78	159,59
4,18E+04	1,85E+01	6,17E+00	2,95E+03	3,89E+00	1,35E+00	14,17	4,76	4,57
4,18E+04	1,85E+01	6,17E+00	1,31E+03	9,71E-01	3,00E-01	32,01	19,04	20,54
4,18E+04	1,85E+01	6,17E+00	3,21E+02	1,79E-01	5,86E-02	130,09	103,32	105,35
4,18E+04	1,85E+01	6,17E+00	2,17E+02	1,28E-01	4,14E-02	193,09	145,01	149,08
4,18E+04	1,85E+01	6,17E+00	2,16E+02	1,27E-01	4,14E-02	193,18	145,05	149,14
3,65E+04	1,65E+01	5,50E+00	1,05E+04	5,56E+00	1,71E+00	3,48	2,98	3,21
3,65E+04	1,65E+01	5,50E+00	4,48E+03	2,29E+00	7,40E-01	8,16	7,21	7,44
3,65E+04	1,65E+01	5,50E+00	1,17E+03	6,65E-01	2,04E-01	31,34	24,86	26,89
3,65E+04	1,65E+01	5,50E+00	5,29E+02	2,88E-01	8,90E-02	69,04	57,33	61,78
3,65E+04	1,65E+01	5,50E+00	3,29E+02	1,85E-01	5,97E-02	111,16	89,61	92,08
3,65E+04	1,65E+01	5,50E+00	2,57E+02	1,49E-01	4,79E-02	142,19	110,93	114,71
4,18E+04	1,85E+01	6,17E+00	1,70E+04	9,03E+00	3,04E+00	2,47	2,05	2,03
4,18E+04	1,85E+01	6,17E+00	5,10E+03	3,76E+00	1,29E+00	8,19	4,91	4,78
4,18E+04	1,85E+01	6,17E+00	1,14E+03	7,00E-01	2,39E-01	36,56	26,43	25,77
4,18E+04	1,85E+01	6,17E+00	2,39E+02	1,39E-01	4,46E-02	174,62	132,85	138,27
4,18E+04	1,85E+01	6,17E+00	2,39E+02	1,39E-01	4,45E-02	175,05	133,22	138,48

Simulacija s testnim skupom Zimski skup 1 (od 26.2. do 27.2.)

TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
1,16E+04	1,62E+01	5,74E+00	6,08E+03	8,41E+00	2,97E+00	1,91	1,92	1,94
1,16E+04	1,62E+01	5,74E+00	1,54E+03	2,35E+00	7,53E-01	7,54	6,87	7,62
1,16E+04	1,62E+01	5,74E+00	6,59E+02	1,00E+00	3,64E-01	17,58	16,11	15,76
1,16E+04	1,62E+01	5,74E+00	2,64E+02	4,28E-01	1,49E-01	43,97	37,76	38,62
1,16E+04	1,62E+01	5,74E+00	3,52E+02	5,48E-01	1,91E-01	32,90	29,47	30,11
1,16E+04	1,62E+01	5,74E+00	4,16E+02	6,55E-01	2,09E-01	27,85	24,68	27,46
1,16E+04	1,62E+01	5,74E+00	4,54E+02	7,09E-01	2,39E-01	25,51	22,79	24,02
1,61E+04	2,15E+01	7,74E+00	1,88E+03	6,24E+00	2,39E+00	8,60	3,44	3,24
1,61E+04	2,15E+01	7,74E+00	1,11E+03	1,89E+00	6,55E-01	14,47	11,34	11,82
1,61E+04	2,15E+01	7,74E+00	1,01E+03	1,48E+00	5,33E-01	15,96	14,51	14,53
1,61E+04	2,15E+01	7,74E+00	8,25E+02	1,23E+00	4,54E-01	19,53	17,50	17,07
1,61E+04	2,15E+01	7,74E+00	8,18E+02	1,22E+00	4,50E-01	19,70	17,65	17,21
1,16E+04	1,62E+01	5,74E+00	6,26E+03	9,46E+00	3,11E+00	1,85	1,71	1,85
1,16E+04	1,62E+01	5,74E+00	5,64E+03	7,77E+00	2,70E+00	2,05	2,08	2,13
1,16E+04	1,62E+01	5,74E+00	6,82E+02	1,19E+00	3,73E-01	17,00	13,53	15,40
1,16E+04	1,62E+01	5,74E+00	5,55E+02	7,89E-01	2,90E-01	20,88	20,49	19,79
1,16E+04	1,62E+01	5,74E+00	2,72E+02	4,36E-01	1,56E-01	42,55	37,10	36,85
1,16E+04	1,62E+01	5,74E+00	2,21E+02	3,67E-01	1,25E-01	52,50	44,06	45,94
1,61E+04	2,15E+01	7,74E+00	5,28E+03	9,84E+00	3,87E+00	3,05	2,18	2,00
1,61E+04	2,15E+01	7,74E+00	2,91E+03	5,92E+00	2,15E+00	5,54	3,63	3,60
1,61E+04	2,15E+01	7,74E+00	9,76E+02	1,53E+00	5,45E-01	16,51	14,00	14,22
1,61E+04	2,15E+01	7,74E+00	3,57E+02	5,87E-01	1,99E-01	45,15	36,58	38,96
1,61E+04	2,15E+01	7,74E+00	3,49E+02	5,80E-01	1,97E-01	46,12	37,01	39,36

Simulacija s testnim skupom Zimski skup 2 (od 28.2. do 1.3.)

Prilozi

TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
1,23E+04	1,79E+01	4,81E+00	5,70E+03	8,82E+00	2,47E+00	2,16	2,03	1,95
1,23E+04	1,79E+01	4,81E+00	1,31E+03	2,31E+00	7,15E-01	9,39	7,73	6,72
1,23E+04	1,79E+01	4,81E+00	1,54E+03	2,24E+00	4,98E-01	8,00	7,99	9,64
1,23E+04	1,79E+01	4,81E+00	8,04E+02	1,15E+00	2,58E-01	15,28	15,52	18,65
1,23E+04	1,79E+01	4,81E+00	8,18E+02	1,21E+00	2,95E-01	15,01	14,76	16,29
1,23E+04	1,79E+01	4,81E+00	8,28E+02	1,20E+00	3,23E-01	14,84	14,89	14,86
1,23E+04	1,79E+01	4,81E+00	6,76E+02	1,04E+00	2,79E-01	18,17	17,23	17,24
1,88E+04	2,56E+01	6,70E+00	2,26E+03	7,45E+00	1,79E+00	8,30	3,44	3,75
1,88E+04	2,56E+01	6,70E+00	1,03E+03	1,93E+00	4,85E-01	18,30	13,27	13,82
1,88E+04	2,56E+01	6,70E+00	7,04E+02	1,03E+00	2,27E-01	26,69	24,93	29,55
1,88E+04	2,56E+01	6,70E+00	5,49E+02	8,46E-01	1,82E-01	34,23	30,33	36,87
1,88E+04	2,56E+01	6,70E+00	5,52E+02	8,50E-01	1,83E-01	34,02	30,18	36,69
1,23E+04	1,79E+01	4,81E+00	6,30E+03	1,07E+01	3,09E+00	1,95	1,68	1,56
1,23E+04	1,79E+01	4,81E+00	5,24E+03	8,05E+00	2,25E+00	2,35	2,22	2,13
1,23E+04	1,79E+01	4,81E+00	9,55E+02	1,49E+00	3,44E-01	12,85	11,98	13,97
1,23E+04	1,79E+01	4,81E+00	1,20E+03	1,68E+00	4,00E-01	10,25	10,66	12,01
1,23E+04	1,79E+01	4,81E+00	7,22E+02	1,05E+00	2,45E-01	17,00	17,00	19,65
1,23E+04	1,79E+01	4,81E+00	9,45E+02	1,34E+00	2,97E-01	13,00	13,33	16,17
1,88E+04	2,56E+01	6,70E+00	5,43E+03	9,86E+00	2,43E+00	3,46	2,60	2,76
1,88E+04	2,56E+01	6,70E+00	5,98E+03	9,67E+00	2,37E+00	3,14	2,65	2,82
1,88E+04	2,56E+01	6,70E+00	1,08E+03	1,74E+00	4,26E-01	17,40	14,75	15,73
1,88E+04	2,56E+01	6,70E+00	7,79E+02	1,14E+00	2,42E-01	24,11	22,50	27,67
1,88E+04	2,56E+01	6,70E+00	7,83E+02	1,15E+00	2,44E-01	23,97	22,36	27,49

Simulacija s testnim skupom Prijelazni skup 1 (od 12.3. do 13.3.)

TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
3,42E+03	5,03E+00	3,03E+00	5,96E+03	9,52E+00	5,57E+00	0,57	0,53	0,54
3,42E+03	5,03E+00	3,03E+00	1,73E+03	2,80E+00	1,47E+00	1,98	1,79	2,07
3,42E+03	5,03E+00	3,03E+00	8,87E+02	1,38E+00	8,94E-01	3,85	3,63	3,39
3,42E+03	5,03E+00	3,03E+00	3,56E+02	5,40E-01	3,23E-01	9,61	9,32	9,40
3,42E+03	5,03E+00	3,03E+00	4,74E+02	8,28E-01	6,36E-01	7,21	6,07	4,77
3,42E+03	5,03E+00	3,03E+00	5,74E+02	9,98E-01	6,50E-01	5,95	5,04	4,66
3,42E+03	5,03E+00	3,03E+00	7,36E+02	1,25E+00	8,92E-01	4,64	4,02	3,40
4,58E+03	6,94E+00	4,34E+00	4,85E+03	9,59E+00	6,42E+00	0,95	0,72	0,68
4,58E+03	6,94E+00	4,34E+00	1,72E+03	3,00E+00	1,95E+00	2,67	2,31	2,23
4,58E+03	6,94E+00	4,34E+00	3,80E+02	6,03E-01	4,01E-01	12,06	11,51	10,83
4,58E+03	6,94E+00	4,34E+00	3,25E+02	5,16E-01	3,58E-01	14,11	13,44	12,12
4,58E+03	6,94E+00	4,34E+00	3,21E+02	5,12E-01	3,55E-01	14,25	13,56	12,24
3,42E+03	5,03E+00	3,03E+00	9,14E+03	1,44E+01	1,04E+01	0,37	0,35	0,29
3,42E+03	5,03E+00	3,03E+00	5,10E+03	8,27E+00	4,82E+00	0,67	0,61	0,63
3,42E+03	5,03E+00	3,03E+00	1,03E+03	1,67E+00	9,14E-01	3,31	3,00	3,32
3,42E+03	5,03E+00	3,03E+00	6,07E+02	9,50E-01	6,28E-01	5,63	5,29	4,83
3,42E+03	5,03E+00	3,03E+00	5,42E+02	8,80E-01	5,05E-01	6,31	5,71	6,00
3,42E+03	5,03E+00	3,03E+00	2,66E+02	4,27E-01	2,77E-01	12,83	11,78	10,94
4,58E+03	6,94E+00	4,34E+00	8,77E+03	1,42E+01	8,89E+00	0,52	0,49	0,49
4,58E+03	6,94E+00	4,34E+00	6,05E+03	1,00E+01	6,60E+00	0,76	0,69	0,66
4,58E+03	6,94E+00	4,34E+00	1,56E+03	2,43E+00	1,57E+00	2,94	2,85	2,77
4,58E+03	6,94E+00	4,34E+00	3,21E+02	5,52E-01	2,79E-01	14,27	12,56	15,56
4,58E+03	6,94E+00	4,34E+00	3,12E+02	5,33E-01	2,72E-01	14,69	13,02	15,95

Simulacija s testnim skupom Prijelazni skup 2 (od 10.3. do 15.3.)

Prilozi

TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	Δ TOTAL	Δ RMSE	Δ NRMSE
1,41E+04	6,59E+00	3,08E+00	6,61E+04	3,39E+01	1,58E+01	0,21	0,19	0,20
1,41E+04	6,59E+00	3,08E+00	7,47E+03	3,90E+00	1,80E+00	1,89	1,69	1,71
1,41E+04	6,59E+00	3,08E+00	7,60E+03	3,95E+00	1,87E+00	1,86	1,67	1,64
1,41E+04	6,59E+00	3,08E+00	5,41E+03	2,79E+00	1,29E+00	2,61	2,36	2,39
1,41E+04	6,59E+00	3,08E+00	4,97E+03	2,57E+00	1,34E+00	2,84	2,57	2,30
1,41E+04	6,59E+00	3,08E+00	1,19E+04	8,08E+00	3,91E+00	1,18	0,82	0,79
1,41E+04	6,59E+00	3,08E+00	1,48E+04	9,84E+00	5,00E+00	0,95	0,67	0,61
1,62E+04	7,84E+00	3,69E+00	2,78E+04	1,42E+01	6,66E+00	0,58	0,55	0,55
1,62E+04	7,84E+00	3,69E+00	9,94E+03	5,08E+00	2,39E+00	1,63	1,54	1,54
1,62E+04	7,84E+00	3,69E+00	2,75E+03	1,43E+00	6,83E-01	5,89	5,46	5,40
1,62E+04	7,84E+00	3,69E+00	4,32E+03	2,09E+00	1,02E+00	3,74	3,75	3,60
1,62E+04	7,84E+00	3,69E+00	4,24E+03	2,05E+00	1,00E+00	3,82	3,82	3,67
1,41E+04	6,59E+00	3,08E+00	8,36E+04	4,32E+01	2,19E+01	0,17	0,15	0,14
1,41E+04	6,59E+00	3,08E+00	5,71E+04	2,94E+01	1,37E+01	0,25	0,22	0,22
1,41E+04	6,59E+00	3,08E+00	8,18E+03	4,19E+00	2,01E+00	1,72	1,57	1,53
1,41E+04	6,59E+00	3,08E+00	2,06E+03	1,03E+00	4,98E-01	6,85	6,41	6,18
1,41E+04	6,59E+00	3,08E+00	9,55E+03	4,99E+00	2,34E+00	1,48	1,32	1,32
1,41E+04	6,59E+00	3,08E+00	1,03E+03	5,93E-01	2,57E-01	13,68	11,11	11,97
1,62E+04	7,84E+00	3,69E+00	2,76E+04	1,39E+01	6,34E+00	0,59	0,57	0,58
1,62E+04	7,84E+00	3,69E+00	3,46E+04	1,70E+01	8,22E+00	0,47	0,46	0,45
1,62E+04	7,84E+00	3,69E+00	1,12E+04	5,68E+00	2,70E+00	1,44	1,38	1,37
1,62E+04	7,84E+00	3,69E+00	2,07E+03	1,13E+00	5,03E-01	7,83	6,95	7,33
1,62E+04	7,84E+00	3,69E+00	2,10E+03	1,13E+00	5,05E-01	7,72	6,96	7,29

Prilog P.9. Prikaz rezultata optimizacija s fokusom na složenost modela

Model		Podaci o optimizaciji		
Referentni model	Testni model	Algoritam	MaxFunEvals	kriterij
mjerjenja	realni model 4R3C	fmnincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 3R2C	fmnincon interior-point bez ograničenja	1.829.908	NRMSE
mjerjenja	realni model 2R1C	fmnincon interior-point bez ograničenja	655.703	NRMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton, bez ograničenja	1.795.154	NRMSE
mjerjenja	realni model 3R2C	fminunc, quasi-newton, bez ograničenja	1.677.185	NRMSE
mjerjenja	realni model 2R1C	fminunc, quasi-newton, bez ograničenja	524.887	NRMSE

Referentni podaci (korišteni za optimizaciju)			Optimizacija		
Podaci za optimizaciju	Sati	Vremenska konstanta	Početak	Kraj	Trajanje optimizacije
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	22:55:33	6:35:49	7:40:16
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	13:03:31	16:01:19	2:57:48
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	21:19:15	21:50:30	0:31:15
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	22:03:00	23:32:03	1:29:03
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	17:22:08	18:30:26	1:08:18
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	22:02:06	22:21:18	0:19:12

Simulacija s referentnim podacima								
TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
3,65E+04	1,65E+01	5,50E+00	1,74E+02	1,07E-01	3,49E-02	209,87	154,99	157,70
4,07E+04	1,81E+01	6,03E+00	1,93E+02	1,14E-01	3,74E-02	211,09	158,06	161,23
4,18E+04	1,85E+01	6,17E+00	2,16E+02	1,27E-01	4,14E-02	193,18	145,05	149,14
3,65E+04	1,65E+01	5,50E+00	2,57E+02	1,49E-01	4,79E-02	142,19	110,93	114,71
4,07E+04	1,81E+01	6,03E+00	1,91E+02	1,16E-01	3,78E-02	212,58	156,35	159,57
4,18E+04	1,85E+01	6,17E+00	2,39E+02	1,39E-01	4,45E-02	175,05	133,22	138,48

Simulacija s testnim skupom Zimski skup 1 (od 26.2. do 27.2.)								
TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
1,16E+04	1,62E+01	5,74E+00	4,16E+02	6,55E-01	2,09E-01	27,85	24,68	27,46
1,51E+04	2,03E+01	7,31E+00	7,46E+02	1,12E+00	4,04E-01	20,18	18,21	18,07
1,61E+04	2,15E+01	7,74E+00	8,18E+02	1,22E+00	4,50E-01	19,70	17,65	17,21
1,16E+04	1,62E+01	5,74E+00	2,21E+02	3,67E-01	1,25E-01	52,50	44,06	45,94
1,51E+04	2,03E+01	7,31E+00	4,19E+02	6,64E-01	2,34E-01	35,98	30,61	31,22
1,61E+04	2,15E+01	7,74E+00	3,49E+02	5,80E-01	1,97E-01	46,12	37,01	39,36

Prilozi

Simulacija s testnim skupom Zimski skup 2 (od 28.2. do 1.3.)

TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
1,23E+04	1,79E+01	4,81E+00	8,28E+02	1,20E+00	3,23E-01	14,84	14,89	14,86
1,71E+04	2,38E+01	6,27E+00	1,10E+03	1,57E+00	3,52E-01	15,56	15,18	17,80
1,88E+04	2,56E+01	6,70E+00	5,52E+02	8,50E-01	1,83E-01	34,02	30,18	36,69
1,23E+04	1,79E+01	4,81E+00	9,45E+02	1,34E+00	2,97E-01	13,00	13,33	16,17
1,71E+04	2,38E+01	6,27E+00	9,41E+02	1,35E+00	3,03E-01	18,21	17,61	20,67
1,88E+04	2,56E+01	6,70E+00	7,83E+02	1,15E+00	2,44E-01	23,97	22,36	27,49

Simulacija s testnim skupom Prijelazni skup 1 (od 12.3. do 13.3.)

TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
3,42E+03	5,03E+00	3,03E+00	5,74E+02	9,98E-01	6,50E-01	5,95	5,04	4,66
4,35E+03	6,43E+00	3,99E+00	7,19E+02	1,20E+00	7,92E-01	6,05	5,35	5,04
4,58E+03	6,94E+00	4,34E+00	3,21E+02	5,12E-01	3,55E-01	14,25	13,56	12,24
3,42E+03	5,03E+00	3,03E+00	2,66E+02	4,27E-01	2,77E-01	12,83	11,78	10,94
4,35E+03	6,43E+00	3,99E+00	4,07E+02	6,81E-01	4,62E-01	10,69	9,44	8,65
4,58E+03	6,94E+00	4,34E+00	3,12E+02	5,33E-01	2,72E-01	14,69	13,02	15,95

Simulacija s testnim skupom Prijelazni skup 2 (od 10.3. do 15.3.)

TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	ΔTOTAL	ΔRMSE	ΔNRMSE
1,41E+04	6,59E+00	3,08E+00	1,19E+04	8,08E+00	3,91E+00	1,18	0,82	0,79
1,56E+04	7,45E+00	3,49E+00	3,24E+03	1,61E+00	7,60E-01	4,83	4,63	4,59
1,62E+04	7,84E+00	3,69E+00	4,24E+03	2,05E+00	1,00E+00	3,82	3,82	3,67
1,41E+04	6,59E+00	3,08E+00	1,03E+03	5,93E-01	2,57E-01	13,68	11,11	11,97
1,56E+04	7,45E+00	3,49E+00	2,19E+03	1,13E+00	5,78E-01	7,16	6,60	6,04
1,62E+04	7,84E+00	3,69E+00	2,10E+03	1,13E+00	5,05E-01	7,72	6,96	7,29

Prilog P.10. Prikaz rezultata predviđanja korištenjem prilagođenog modela

Model		Podaci o optimizaciji		
Referentni model	Testni model	Algoritam	MaxFunEvals	kriterij
mjerjenja	realni model 4R3C	fmnincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 4R3C	fmnincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 4R3C	fmnincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 4R3C	fmnincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 4R3C	fmnincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 4R3C	fmnincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 4R3C	fmnincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 4R3C	fmnincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton, bez ograničenja	1.795.154	NRMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton, bez ograničenja	1.795.154	NRMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton, bez ograničenja	1.795.154	NRMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton, bez ograničenja	1.795.154	NRMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton, bez ograničenja	1.795.154	NRMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton, bez ograničenja	1.795.154	NRMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton, bez ograničenja	1.795.154	NRMSE
mjerjenja	realni model 4R3C	fminunc, quasi-newton, bez ograničenja	1.795.154	NRMSE
mjerjenja	realni model 2R1C	fmnincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 2R1C	fmnincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 2R1C	fmnincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 2R1C	fmnincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 2R1C	fmnincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 2R1C	fmnincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 2R1C	fmnincon interior-point bez ograničenja	2.000.000	NRMSE
mjerjenja	realni model 2R1C	fminunc, quasi-newton, bez ograničenja	1.795.154	NRMSE
mjerjenja	realni model 2R1C	fminunc, quasi-newton, bez ograničenja	1.795.154	NRMSE
mjerjenja	realni model 2R1C	fminunc, quasi-newton, bez ograničenja	1.795.154	NRMSE
mjerjenja	realni model 2R1C	fminunc, quasi-newton, bez ograničenja	1.795.154	NRMSE
mjerjenja	realni model 2R1C	fminunc, quasi-newton, bez ograničenja	1.795.154	NRMSE
mjerjenja	realni model 2R1C	fminunc, quasi-newton, bez ograničenja	1.795.154	NRMSE
mjerjenja	realni model 2R1C	fminunc, quasi-newton, bez ograničenja	1.795.154	NRMSE
mjerjenja	realni model 2R1C	fminunc, quasi-newton, bez ograničenja	1.795.154	NRMSE

Prilozi

Referentni podaci (korišteni za optimizaciju)

Podaci za optimizaciju	Sati	Vremenska konstanta	Sati predikcije
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	1
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	2
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	3
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	4
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	6
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	12
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	24
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	48
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	1
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	2
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	3
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	4
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	6
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	12
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	24
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	48
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	1
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	2
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	3
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	4
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	6
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	12
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	24
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	48
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	1
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	2
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	3
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	4
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	6
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	12
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	24
zimski, mjerenja bez dobitaka i sunca, 21.2.-26.2.	144	900	48

Prilozi

Simulacija s referentnim podacima				Simulacija s testnim skupom Zimski skup 1 (od 26.2. do 27.2.)			
TOTAL	RMSE	NRMSE	MAX	TOTAL	RMSE	NRMSE	MAX
3,58E+03	2,25E+02	6,45E+02	1,86E+00	1,42E+03	8,99E+01	1,68E+02	1,84E+00
3,55E+03	2,40E+05	6,08E+02	1,99E+00	1,50E+03	9,99E+01	1,48E+02	2,00E+00
3,60E+03	2,48E+02	5,91E+02	2,00E+00	1,57E+03	1,05E+02	1,50E+02	2,00E+00
3,66E+03	2,53E+02	5,93E+02	2,00E+00	1,61E+03	1,08E+02	1,52E+02	2,00E+00
3,78E+03	2,60E+02	5,77E+02	2,00E+00	1,68E+03	1,12E+02	1,52E+02	2,00E+00
4,09E+03	2,82E+02	5,43E+02	2,61E+00	1,71E+03	1,17E+02	1,62E+02	2,61E+00
4,03E+03	2,83E+02	5,79E+02	2,33E+00	1,55E+03	1,05E+02	1,80E+02	3,30E+00
3,70E+03	2,50E+02	5,84E+02	2,33E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00
3,65E+03	2,30E+02	5,88E+02	1,74E+00	1,52E+03	9,66E+01	1,71E+02	1,79E+00
3,53E+03	2,39E+02	5,43E+02	1,95E+00	1,55E+03	1,05E+02	1,45E+02	2,04E+00
3,51E+03	2,43E+02	5,19E+02	2,00E+00	1,58E+03	1,09E+02	1,42E+02	2,10E+00
3,53E+03	2,48E+02	5,19E+02	2,12E+00	1,61E+03	1,12E+02	1,42E+02	2,12E+00
3,67E+03	2,58E+02	5,15E+02	2,49E+00	1,68E+03	1,17E+02	1,44E+02	2,49E+00
4,07E+03	2,84E+02	4,90E+02	2,73E+00	1,68E+03	1,16E+02	1,54E+02	2,73E+00
4,05E+03	2,79E+02	5,45E+02	2,13E+00	1,39E+03	9,38E+01	1,58E+02	2,89E+00
4,17E+03	2,76E+02	6,48E+02	2,13E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00
3,82E+03	2,54E+02	7,23E+02	1,81E+00	1,59E+03	1,13E+02	1,64E+02	1,81E+00
3,47E+03	2,43E+02	7,68E+02	1,81E+00	1,27E+03	9,60E+01	1,57E+02	1,81E+00
3,46E+03	2,45E+02	7,26E+02	1,81E+00	1,17E+03	8,94E+01	1,53E+02	1,81E+00
3,56E+03	2,53E+02	6,97E+02	1,81E+00	1,14E+03	8,67E+01	1,46E+02	1,81E+00
3,70E+03	2,63E+02	6,39E+02	1,81E+00	1,15E+03	8,58E+01	1,33E+02	1,81E+00
3,96E+03	2,76E+02	6,18E+02	1,88E+00	1,31E+03	9,30E+01	1,34E+02	1,88E+00
3,99E+03	2,72E+02	6,75E+02	1,75E+00	9,47E+02	6,59E+01	1,21E+02	1,88E+00
3,26E+03	2,18E+02	5,60E+02	1,80E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00
3,63E+03	2,38E+02	6,21E+02	1,65E+00	1,56E+03	1,02E+02	1,45E+02	1,72E+00
3,12E+03	2,20E+02	5,56E+02	1,65E+00	1,35E+03	9,42E+01	1,30E+02	1,72E+00
3,03E+03	2,16E+02	5,27E+02	1,66E+00	1,31E+03	9,26E+01	1,33E+02	1,72E+00
3,01E+03	2,16E+02	5,08E+02	1,66E+00	1,29E+03	9,15E+01	1,31E+02	1,72E+00
3,08E+03	2,20E+02	4,69E+02	1,85E+00	1,28E+03	9,14E+01	1,22E+02	1,85E+00
3,49E+03	2,49E+02	4,65E+02	2,23E+00	1,31E+03	9,33E+01	1,23E+02	2,23E+00
3,67E+03	2,57E+02	5,20E+02	2,20E+00	9,69E+02	6,67E+01	1,11E+02	2,23E+00
3,73E+03	2,51E+02	5,81E+02	2,20E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00

Prilozi

Simulacija s testnim skupom Zimski skup 2 (od 28.2. do 1.3.)				Simulacija s testnim skupom Prijelazni skup 1 (od 12.3. do 13.3.)			
TOTAL	RMSE	NRMSE	MAX	TOTAL	RMSE	NRMSE	MAX
1,46E+03	9,33E+01	1,89E+02	6,86E+00	9,92E+02	6,39E+01	2,07E+02	1,42E+00
1,35E+03	9,11E+01	1,63E+02	6,70E+00	9,14E+02	6,30E+01	1,97E+02	1,42E+00
1,29E+03	8,80E+01	1,55E+02	6,43E+00	8,84E+02	6,25E+01	1,77E+02	1,42E+00
1,25E+03	8,58E+01	1,43E+02	6,14E+00	8,54E+02	6,13E+01	1,63E+02	1,42E+00
1,26E+03	8,62E+01	1,23E+02	5,88E+00	7,79E+02	5,71E+01	1,41E+02	1,42E+00
1,50E+03	1,03E+02	1,35E+02	6,62E+00	6,30E+02	4,80E+01	1,13E+02	1,38E+00
9,67E+02	6,70E+01	1,14E+02	6,96E+00	7,02E+02	6,01E+01	1,53E+02	3,16E+00
0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00
1,87E+03	1,14E+02	2,38E+02	6,94E+00	9,23E+02	6,33E+01	1,63E+02	1,40E+00
1,79E+03	1,16E+02	2,09E+02	6,98E+00	9,46E+02	7,20E+01	1,78E+02	1,55E+00
1,73E+03	1,15E+02	2,02E+02	6,81E+00	9,56E+02	7,51E+01	1,68E+02	1,55E+00
1,68E+03	1,14E+02	1,85E+02	6,54E+00	9,44E+02	7,52E+01	1,63E+02	1,55E+00
1,62E+03	1,13E+02	1,58E+02	6,16E+00	9,14E+02	7,29E+01	1,59E+02	1,55E+00
1,63E+03	1,15E+02	1,34E+02	6,35E+00	8,82E+02	6,81E+01	1,74E+02	1,55E+00
1,06E+03	7,40E+01	1,15E+02	7,57E+00	7,99E+02	5,88E+01	1,62E+02	1,69E+00
0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00
2,06E+03	1,53E+02	1,88E+02	5,87E+00	2,02E+03	1,36E+02	3,68E+02	2,93E+00
1,53E+03	1,24E+02	2,55E+02	5,93E+00	1,57E+03	1,15E+02	3,22E+02	2,93E+00
1,36E+03	1,09E+02	2,62E+02	5,42E+00	1,41E+03	1,05E+02	2,81E+02	2,93E+00
1,34E+03	1,04E+02	2,37E+02	4,97E+00	1,29E+03	9,84E+01	2,54E+02	2,93E+00
1,36E+03	1,01E+02	1,93E+02	4,47E+00	1,11E+03	8,63E+01	2,15E+02	2,93E+00
1,33E+03	9,48E+01	1,43E+02	4,73E+00	8,11E+02	6,32E+01	1,56E+02	2,34E+00
1,03E+03	7,23E+01	1,45E+02	6,16E+00	6,34E+02	4,92E+01	1,38E+02	2,34E+00
0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00
1,74E+03	1,20E+02	1,38E+02	6,45E+00	1,20E+03	8,49E+01	3,08E+02	2,27E+00
1,48E+03	1,05E+02	2,08E+02	6,47E+00	9,59E+02	7,33E+01	2,60E+02	2,27E+00
1,41E+03	1,02E+02	2,51E+02	6,18E+00	8,79E+02	6,77E+01	2,20E+02	2,27E+00
1,37E+03	1,01E+02	2,39E+02	5,76E+00	8,37E+02	6,46E+01	1,97E+02	2,27E+00
1,35E+03	1,02E+02	1,99E+02	5,20E+00	8,08E+02	6,21E+01	1,76E+02	2,27E+00
1,44E+03	1,07E+02	1,39E+02	5,33E+00	9,17E+02	7,08E+01	1,90E+02	2,25E+00
9,76E+02	7,17E+01	1,19E+02	6,67E+00	9,39E+02	7,02E+01	1,84E+02	2,67E+00
0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00

Prilozi

Simulacija s testnim skupom
Prijelazni skup 2 (od 10.3. do 15.3.)

TOTAL	RMSE	NRMSE	MAX
2,68E+03	1,74E+02	6,44E+02	1,42E+00
2,44E+03	1,71E+02	7,52E+02	1,42E+00
2,37E+03	1,71E+02	7,48E+02	1,42E+00
2,32E+03	1,70E+02	7,45E+02	1,42E+00
2,19E+03	1,64E+02	7,00E+02	1,42E+00
2,11E+03	1,65E+02	6,16E+02	1,42E+00
3,51E+03	3,00E+02	9,51E+02	3,29E+00
5,45E+03	4,61E+02	1,82E+03	6,02E+00
2,67E+03	1,81E+02	5,53E+02	1,40E+00
2,77E+03	2,05E+02	7,83E+02	1,63E+00
2,84E+03	2,15E+02	8,65E+02	1,63E+00
2,83E+03	2,17E+02	9,23E+02	1,63E+00
2,77E+03	2,15E+02	9,89E+02	1,63E+00
2,92E+03	2,26E+02	1,21E+03	1,55E+00
3,39E+03	2,56E+02	1,18E+03	1,69E+00
2,94E+03	2,23E+02	9,05E+02	1,84E+00
5,95E+03	4,00E+02	1,18E+03	3,33E+00
4,89E+03	3,51E+02	1,28E+03	3,33E+00
4,63E+03	3,36E+02	1,16E+03	3,33E+00
4,46E+03	3,26E+02	1,09E+03	3,33E+00
4,14E+03	3,07E+02	1,02E+03	3,33E+00
3,37E+03	2,57E+02	9,13E+02	3,33E+00
2,89E+03	2,23E+02	8,71E+02	3,33E+00
3,13E+03	2,40E+02	1,05E+03	3,33E+00
3,48E+03	2,42E+02	9,21E+02	2,27E+00
3,00E+03	2,20E+02	1,03E+03	2,27E+00
2,83E+03	2,11E+02	1,02E+03	2,27E+00
2,75E+03	2,06E+02	1,06E+03	2,27E+00
2,67E+03	2,03E+02	1,17E+03	2,27E+00
3,04E+03	2,40E+02	1,56E+03	2,27E+00
4,08E+03	3,15E+02	1,51E+03	2,88E+00
4,13E+03	3,10E+02	1,25E+03	3,17E+00

Prilog P.11. Prikaz rezultata simulacije pomoću umjetnih neuronskih mreža

Model		Podaci o optimizaciji		
Referentni model	Testni model	Algoritam	Broj skrivenih slojeva	kriterij
mjerjenja	realni model 2R1C	ANN		1
mjerjenja	realni model 2R1C	ANN		2
mjerjenja	realni model 2R1C	ANN		4
mjerjenja	realni model 2R1C	ANN		8
mjerjenja	realni model 2R1C	ANN		16
mjerjenja	realni model 2R1C	ANN		32
mjerjenja	realni model 2R1C	ANN		64
mjerjenja	realni model 2R1C	ANN		128
mjerjenja	realni model 2R1C	ANN		256
mjerjenja	realni model 2R1C	ANN		512
mjerjenja	realni model 2R1C	ANN		1.024

Referentni podaci (korišteni za optimizaciju)			Optimizacija			
Podaci za optimizaciju	Hours	Time const.	Start time	End time	ΔTIME	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	21:05:09	21:05:10	0:00:01	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	21:17:25	21:17:26	0:00:01	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	21:26:08	21:26:09	0:00:01	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	21:31:35	21:31:36	0:00:01	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	21:39:46	21:39:47	0:00:01	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	21:44:02	21:44:03	0:00:01	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	10:32:30	10:32:31	0:00:01	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	10:26:36	10:26:41	0:00:05	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	10:14:55	10:15:11	0:00:16	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	9:48:35	9:50:16	0:01:41	
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	22:04:47	22:12:47	0:08:00	

Simulacija s referentnim podacima			Simulacija s testnim skupom Zimski skup 1 (od 26.2. do 27.2.)			Simulacija s testnim skupom Zimski skup 2 (od 28.2. do 1.3.)		
TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE
8,58E+02	5,08E-01	1,62E-01	4,95E+02	8,83E-01	2,98E-01	4,95E+02	8,83E-01	2,98E-01
8,76E+02	5,03E-01	1,60E-01	5,17E+02	8,72E-01	2,95E-01	6,38E+02	1,05E+00	2,92E-01
1,13E+03	6,48E-01	2,08E-01	4,54E+02	8,03E-01	2,73E-01	5,77E+02	9,80E-01	2,66E-01
7,22E+02	4,66E-01	1,48E-01	4,28E+02	8,38E-01	2,84E-01	6,77E+02	1,17E+00	3,16E-01
6,03E+02	3,99E-01	1,27E-01	4,32E+02	8,81E-01	3,00E-01	1,51E+03	2,48E+00	6,84E-01
6,14E+02	4,04E-01	1,28E-01	4,34E+02	8,66E-01	2,95E-01	8,94E+02	1,45E+00	4,10E-01
6,27E+02	4,05E-01	1,29E-01	4,21E+02	8,52E-01	2,89E-01	9,56E+02	1,59E+00	4,24E-01
6,64E+02	4,52E-01	1,46E-01	4,35E+02	8,80E-01	3,00E-01	1,26E+03	2,41E+00	6,70E-01
7,95E+02	5,40E-01	1,73E-01	5,16E+02	1,03E+00	3,55E-01	2,02E+03	4,68E+00	1,46E+00
7,65E+02	8,24E-01	2,57E-01	5,66E+02	1,33E+00	4,32E-01	3,69E+03	7,83E+00	2,21E+00
7,87E+02	9,75E-01	3,02E-01	6,45E+02	1,59E+00	5,51E-01	2,84E+03	5,69E+00	1,69E+00

Simulacija s testnim skupom Prijelazni skup 1 (od 12.3. do 13.3.)			Simulacija s testnim skupom Prijelazni skup 2 (od 10.3. do 15.3.)		
TOTAL	RMSE	NRMSE	TOTAL	RMSE	NRMSE
2,91E+02	5,44E-01	2,92E-01	1,21E+03	7,14E-01	3,05E-01
2,85E+02	5,52E-01	2,95E-01	1,24E+03	7,51E-01	3,22E-01
3,56E+02	5,89E-01	3,56E-01	1,24E+03	7,02E-01	3,10E-01
4,46E+02	8,31E-01	4,55E-01	1,60E+03	9,32E-01	4,03E-01
2,06E+03	3,35E+00	2,05E+00	5,32E+03	3,07E+00	1,40E+00
1,17E+03	1,85E+00	1,13E+00	3,57E+03	1,95E+00	9,03E-01
1,61E+03	2,39E+00	1,46E+00	4,51E+03	2,26E+00	1,06E+00
1,90E+03	3,14E+00	2,26E+00	5,64E+03	3,09E+00	1,62E+00
2,17E+03	3,74E+00	2,45E+00	5,75E+03	3,38E+00	1,62E+00
3,34E+03	5,22E+00	3,31E+00	9,89E+03	5,01E+00	2,30E+00
4,37E+03	7,12E+00	4,22E+00	1,28E+04	6,87E+00	3,03E+00

Prilog P.12. Prikaz rezultata predviđanja korištenjem ANN metode

Model		Podaci o optimizaciji		
Referentni model	Testni model	Algoritam	Broj skrivenih slojeva	kriterij
mjerjenja	realni model 2R1C	ANN	16	
mjerjenja	realni model 2R1C	ANN	16	
mjerjenja	realni model 2R1C	ANN	16	
mjerjenja	realni model 2R1C	ANN	16	
mjerjenja	realni model 2R1C	ANN	16	
mjerjenja	realni model 2R1C	ANN	16	
mjerjenja	realni model 2R1C	ANN	16	
mjerjenja	realni model 2R1C	ANN	16	

Referentni podaci (korišteni za optimizaciju)

Podaci za optimizaciju	Sati	Vremenska konstanta	Sati predikcije
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	1
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	2
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	3
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	4
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	6
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	12
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	24
zimski, mjerjenja bez dobitaka i sunca, 21.2.-26.2.	144	900	48

Simulacija s referentnim podacima Simulacija s testnim skupom
 Zimski skup 1 (od 26.2. do 27.2.)

TOTAL	RMSE	NRMSE	MAX	TOTAL	RMSE	NRMSE	MAX
3,27E+03	1,98E+02	7,17E+02	2,67E+00	2,05E+03	1,21E+02	3,48E+02	3,42E+00
2,92E+03	2,03E+02	7,49E+02	2,67E+00	1,82E+03	1,22E+02	2,92E+02	3,42E+00
2,80E+03	2,06E+02	7,18E+02	2,67E+00	1,72E+03	1,21E+02	2,78E+02	3,42E+00
2,73E+03	2,08E+02	6,85E+02	2,67E+00	1,66E+03	1,21E+02	2,57E+02	3,42E+00
2,65E+03	2,12E+02	6,11E+02	2,67E+00	1,56E+03	1,20E+02	2,09E+02	3,42E+00
2,47E+03	2,11E+02	4,93E+02	2,67E+00	1,26E+03	1,08E+02	1,72E+02	3,42E+00
2,18E+03	1,93E+02	4,65E+02	2,67E+00	7,81E+02	7,29E+01	1,37E+02	3,42E+00
1,71E+03	1,53E+02	3,99E+02	2,67E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00

Simulacija s testnim skupom Simulacija s testnim skupom
 Zimski skup 2 (od 28.2. do 1.3.) Prijelazni skup 1 (od 12.3. do 13.3.)

TOTAL	RMSE	NRMSE	MAX	TOTAL	RMSE	NRMSE	MAX
5,34E+03	3,03E+02	8,87E+02	6,62E+00	3,68E+03	2,28E+02	7,21E+02	3,15E+00
4,67E+03	2,97E+02	8,64E+02	6,62E+00	3,21E+03	2,23E+02	7,22E+02	3,15E+00
4,35E+03	2,90E+02	8,16E+02	6,62E+00	2,99E+03	2,17E+02	6,04E+02	3,15E+00
4,09E+03	2,81E+02	7,12E+02	6,62E+00	2,83E+03	2,11E+02	5,23E+02	3,15E+00
3,68E+03	2,62E+02	5,21E+02	6,62E+00	2,58E+03	1,99E+02	4,19E+02	3,15E+00
2,93E+03	2,20E+02	3,47E+02	6,62E+00	2,12E+03	1,69E+02	3,56E+02	3,15E+00
1,96E+03	1,51E+02	2,86E+02	6,62E+00	1,45E+03	1,15E+02	2,92E+02	3,15E+00
0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00

Simulacija s testnim skupom
 Prijelazni skup 2 (od 10.3. do 15.3.)

TOTAL	RMSE	NRMSE	MAX
1,35E+04	8,00E+02	2,64E+03	3,49E+00
1,21E+04	7,96E+02	3,76E+03	3,49E+00
1,16E+04	7,93E+02	3,91E+03	3,49E+00
1,12E+04	7,89E+02	3,91E+03	3,49E+00
1,09E+04	7,80E+02	3,79E+03	3,49E+00
1,02E+04	7,51E+02	3,69E+03	3,49E+00
9,21E+03	6,89E+02	2,95E+03	3,49E+00
7,14E+03	5,46E+02	2,12E+03	3,49E+00