



Instytut Podstawowych Problemów Techniki  
Polskiej Akademii Nauk

**PRACA DOKTORSKA**

**Wykorzystanie masy termicznej budynku przy  
sterowaniu jego systemem ogrzewczym**

Tomasz Walczak

Promotor:  
prof. dr hab. Elżbieta Kossecka

**WARSZAWA 2010**

*Składam serdeczne podziękowania Pani prof. dr hab. Elżbiecie Kosseckiej za opiekę w czasie realizacji niniejszej pracy.*

# **Wykorzystanie masy termicznej budynku przy sterowaniu jego systemem grzewczym**

## **Streszczenie**

W pracy przedstawiono wyniki symulacji numerycznych związanych z wykorzystaniem efektywnej pojemności cieplnej budynku do zmniejszenia kosztu ogrzewania pomieszczeń. Uzyskanie wyników było możliwe dzięki wykonaniu symulatora odzwierciedlającego zachowanie termiczne budynku. Przebadano zachowanie elementu grzejnego umieszczonego w masywnej przegrodzie np. w podłodze. Analizie poddano typowe strategie sterowania wykorzystujące dwutaryfowe rozliczanie kosztów energii elektrycznej. Wykazano ich wady i zalety oraz zakres stosowania. W ramach pracy zaproponowano również oryginalne połączenia dwóch metod sztucznej inteligencji - sieci neuronowych i algorytmów uczących się ze wzmocnieniem - do uczenia się optymalnego sterowania systemem grzewczym zatopionym w masywnej przegrodzie. Eksperymenty numeryczne doprowadziły do wskazania optymalnych parametrów konstrukcji budynków, które pozwalają najlepiej wykorzystać tanie źródła energii bez utraty komfortu przebywania w pomieszczeniach.

## **Effective Mass-Effect Control Using Heating System**

### **Abstract**

The results of the investigation of energy performance of massive building envelope with a heating element placed in the massive floor has been shown in the paper. The original, proposed control approach of floor heating system is based on the advanced artificial intelligent methods. The results show that the floor heating system has good thermal storage performance, which can be used to a night-running model to obtain energy-saving benefits efficient and economic running cost. The common control strategy has been also tested and the advantages and disadvantages for polish climate condition has been shown. The numerical investigation has brought to the optimal physical properties of the popular building constructions which allow to effectively utilize two-tariff energy terms without loosing inside thermal comfort.

# Spis treści

<b>1</b>	<b>Wstęp</b>	<b>10</b>
1.1	Wprowadzenie . . . . .	10
1.2	Metody zarządzania energią w budynku . . . . .	13
1.3	Teza i cel pracy . . . . .	17
1.4	Przegląd zawartości . . . . .	18
<b>2</b>	<b>Krótkoterminowe prognozowanie pogody</b>	<b>19</b>
2.1	Wprowadzenie . . . . .	19
2.2	Model neuronu . . . . .	20
2.3	Definicja funkcji celu . . . . .	22
2.4	Architektura sieci . . . . .	24
2.5	Algorytm wstecznej propagacji błędu . . . . .	25
2.6	Algorytm gradientów sprzężonych z regularyzacją . . . . .	28
2.7	Problem wag początkowych . . . . .	32
2.8	Przeuczenie i niedouczenie sieci . . . . .	33
2.9	Cel badań . . . . .	34
2.10	Technika eksperymentu . . . . .	34
2.11	Wyniki prognozowania . . . . .	36
<b>3</b>	<b>Uczenie ze wzmocnieniem a inteligentny termostat</b>	<b>39</b>
3.1	Podstawy teoretyczne algorytmów uczenia się ze wzmocnieniem . . . . .	39
3.1.1	Środowisko . . . . .	39
3.1.2	Scenariusz . . . . .	41
3.1.3	Cel uczenia . . . . .	41
3.1.4	Strategia i funkcja wartości . . . . .	42
3.1.5	Algorytmy uczenia się ze wzmocnieniem . . . . .	44
3.1.6	Wybór akcji . . . . .	46

---

3.1.7	Aproksymator funkcji wartości . . . . .	47
3.2	Architektura systemu . . . . .	48
3.3	Konstruowanie systemu . . . . .	48
3.3.1	Cel uczenia . . . . .	48
3.3.2	Stan . . . . .	49
3.3.3	Akcja . . . . .	50
3.3.4	Wzmocnienie . . . . .	50
<b>4</b>	<b>Symulacje procesów wymiany ciepła w budynku</b>	<b>52</b>
4.1	Model termiczny budynku . . . . .	52
4.2	Metoda różnic skończonych . . . . .	53
4.2.1	Rodzaje węzłów . . . . .	56
4.3	Dyskretyzacja przestrzeni i czasu . . . . .	60
4.4	Modelowanie promieniowania słonecznego . . . . .	61
<b>5</b>	<b>Wyniki symulacji</b>	<b>63</b>
5.1	Metodologia eksperymentów . . . . .	63
5.2	Konstrukcja ciężka . . . . .	68
5.2.1	Efekt sposobu wymuszenia ogrzewania przy tańszej taryfie . . . . .	80
5.2.2	Rola grubości wylewki oraz mocy zainstalowanej . . . . .	82
5.3	Konstrukcja średnio-ciężka . . . . .	88
5.3.1	Efekt sposobu wymuszenia ogrzewania przy tańszej taryfie . . . . .	99
5.3.2	Rola grubości wylewki oraz mocy zainstalowanej . . . . .	102
5.4	Konstrukcja lekka . . . . .	108
5.4.1	Efekt sposobu wymuszenia ogrzewania przy tańszej taryfie . . . . .	121
5.4.2	Rola grubości wylewki oraz mocy zainstalowanej . . . . .	123
5.5	Inteligentny termostat . . . . .	127
<b>6</b>	<b>Podsumowanie</b>	<b>132</b>
	<b>Bibliografia</b>	<b>135</b>

# Spis rysunków

2.1	Model neuronu . . . . .	20
2.2	Najczęściej stosowane funkcje przejść . . . . .	22
2.3	Architektura sieci neuronowej . . . . .	25
2.4	Wyniki prognozowania średniej temperatury za kolejne 6 godzin . . . .	36
2.5	Błąd prognozowania średniej temperatury za kolejne 6 godzin . . . .	37
2.6	Wyniki prognozowania średniej prędkości wiatru za kolejne 6 godzin .	37
2.7	Błąd prognozowania średniej prędkości wiatru za kolejne 6 godzin w kolejnych miesiącach roku . . . . .	38
3.1	Architektura systemu inteligentnego sterowania systemem grzewczym	49
4.1	Model analizowanego pomieszczenia . . . . .	53
4.2	Węzeł w jednorodnym materiale . . . . .	54
4.3	Węzeł przy powierzchni. . . . .	56
5.1	Zachowanie systemu grzewczego dla strategii 1 w dniach 8 i 9 stycznia TRM. Konstrukcja ciężka. . . . .	68
5.2	Zachowanie systemu grzewczego dla strategii 1 w dniach od 8 do 11 października TRM. Konstrukcja ciężka. . . . .	69
5.3	Odchylenia od temperatury zadanej dla strategii 1. Konstrukcja ciężka.	70
5.4	Zachowanie systemu grzewczego dla strategii 2 w dniach od 8 do 11 października TRM. Konstrukcja ciężka. . . . .	70
5.5	Zachowanie systemu grzewczego dla strategii 2 w dniach 8 i 9 stycznia TRM. Konstrukcja ciężka. . . . .	71
5.6	Odchylenia od temperatury zadanej dla strategii 2. Konstrukcja ciężka.	72
5.7	Zachowanie systemu grzewczego dla strategii 3 w dniach od 8 do 11 października TRM. Konstrukcja ciężka. . . . .	72
5.8	Zachowanie systemu grzewczego dla strategii 3 w dniach 8 i 9 stycznia TRM. Konstrukcja ciężka. . . . .	73

5.9	Odchylenia od temperatury zadanej dla strategii 3. Konstrukcja ciężka.	74
5.10	Zachowanie systemu grzewczego dla strategii 4 w dniach od 8 do 11 października TRM. Konstrukcja ciężka. . . . .	75
5.11	Zachowanie systemu grzewczego dla strategii 4 w dniach 8 i 9 stycznia TRM. Konstrukcja ciężka. . . . .	76
5.12	Odchylenia od temperatury zadanej dla strategii 4. Konstrukcja ciężka.	76
5.13	Zachowanie systemu grzewczego dla strategii 5 i wymuszeniu równym $+2^{\circ}C$ w dniach 8 i 9 stycznia TRM. Konstrukcja ciężka. . . . .	77
5.14	Zachowanie systemu grzewczego dla strategii 5 i wymuszeniu równym $+2^{\circ}C$ w dniach od 8 do 11 października TRM. Konstrukcja ciężka.	77
5.15	Odchylenia od temperatury zadanej dla strategii 5. Konstrukcja ciężka.	78
5.16	Zachowanie systemu grzewczego dla strategii 6 w dniach od 8 do 11 października TRM. Konstrukcja ciężka. . . . .	78
5.17	Zachowanie systemu grzewczego dla strategii 6 w dniach 8 i 9 stycznia TRM. Konstrukcja ciężka. . . . .	79
5.18	Odchylenia od temperatury zadanej dla strategii 6. Konstrukcja ciężka.	79
5.19	Zachowanie systemu grzewczego dla strategii 5 i wymuszeniu równym $+1^{\circ}C$ w dniach 8 i 9 stycznia TRM. Konstrukcja ciężka. . . . .	80
5.20	Zachowanie systemu grzewczego dla strategii 5 i wymuszeniu równym $+1^{\circ}C$ w dniach od 8 do 11 października TRM. Konstrukcja ciężka. . .	81
5.21	Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 1. Konstrukcja ciężka. . . . .	82
5.22	Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 2. Konstrukcja ciężka. . . . .	83
5.23	Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 3. Konstrukcja ciężka. . . . .	84
5.24	Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 4. Konstrukcja ciężka. . . . .	85
5.25	Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewania dla strategii 5. Konstrukcja ciężka. . . . .	86
5.26	Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 6. Konstrukcja ciężka. . . . .	87

---

5.27	Zachowanie systemu grzewczego dla strategii 1 w dniach 8 i 9 stycznia TRM. Konstrukcja średnio-ciężka. . . . .	88
5.28	Zachowanie systemu grzewczego dla strategii 1 w dniach od 8 do 11 października TRM. Konstrukcja średnio-ciężka. . . . .	89
5.29	Odchylenia od temperatury zadanej dla strategii 1. Konstrukcja średnio-ciężka. . . . .	90
5.30	Zachowanie systemu grzewczego dla strategii 2 w dniach od 8 do 11 października TRM. Konstrukcja średnio-ciężka. . . . .	91
5.31	Zachowanie systemu grzewczego dla strategii 2 w dniach 8 i 9 stycznia TRM. Konstrukcja średnio-ciężka. . . . .	92
5.32	Odchylenia od temperatury zadanej dla strategii 2. Konstrukcja średnio-ciężka. . . . .	92
5.33	Zachowanie systemu grzewczego dla strategii 3 w dniach od 8 do 11 października TRM. Konstrukcja średnio-ciężka. . . . .	93
5.34	Zachowanie systemu grzewczego dla strategii 3 w dniach 8 i 9 stycznia TRM. Konstrukcja średnio-ciężka. . . . .	93
5.35	Odchylenia od temperatury zadanej dla strategii 3. Konstrukcja średnio-ciężka. . . . .	94
5.36	Zachowanie systemu grzewczego dla strategii 4 w dniach od 8 do 11 października TRM. Konstrukcja średnio-ciężka. . . . .	94
5.37	Zachowanie systemu grzewczego dla strategii 4 w dniach 8 i 9 stycznia TRM. Konstrukcja średnio-ciężka. . . . .	95
5.38	Odchylenia od temperatury zadanej dla strategii 4. Konstrukcja średnio-ciężka. . . . .	95
5.39	Zachowanie systemu grzewczego dla strategii 5 i wymusznieniu równym $+2^{\circ}C$ w dniach 8 i 9 stycznia TRM. Konstrukcja średnio-ciężka. . . . .	96
5.40	Zachowanie systemu grzewczego dla strategii 5 i wymusznieniu równym $+2^{\circ}C$ w dniach od 8 do 11 października TRM. Konstrukcja średnio-ciężka. . . . .	96
5.41	Odchylenia od temperatury zadanej dla strategii 5. Konstrukcja średnio-ciężka. . . . .	97
5.42	Zachowanie systemu grzewczego dla strategii 6 w dniach od 8 do 11 października TRM. Konstrukcja średnio-ciężka. . . . .	97
5.43	Zachowanie systemu grzewczego dla strategii 6 w dniach 8 i 9 stycznia TRM. Konstrukcja średnio-ciężka. . . . .	98
5.44	Odchylenia od temperatury zadanej dla strategii 6. Konstrukcja średnio-ciężka. . . . .	98



5.45	Zachowanie systemu grzewczego dla strategii 5' i wymuszeniu równym $+1^{\circ}C$ w dniach 8 i 9 stycznia TRM. Konstrukcja średnio-ciężka.	99
5.46	Zachowanie systemu grzewczego dla strategii 5' i wymuszeniu równym $+1^{\circ}C$ w dniach od 8 do 11 października TRM. Konstrukcja średnio-ciężka. . . . .	100
5.47	Odchylenia od temperatury zadanej dla strategii 5' i wymuszeniu równym $+1^{\circ}C$ . Konstrukcja średnio-ciężka. . . . .	101
5.48	Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 1. Konstrukcja średnio - ciężka. . . . .	102
5.49	Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 2. Konstrukcja średnio - ciężka. . . . .	103
5.50	Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 3. Konstrukcja średnio - ciężka. . . . .	104
5.51	Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 4. Konstrukcja średnio - ciężka. . . . .	105
5.52	Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 5. Konstrukcja średnio - ciężka. . . . .	106
5.53	Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 6. Konstrukcja średnio-ciężka . . . . .	107
5.54	Zachowanie systemu grzewczego dla strategii 1 w dniach 8 i 9 stycznia TRM. Konstrukcja lekka. . . . .	108
5.55	Zachowanie systemu grzewczego dla strategii 1 w dniach od 8 do 11 października TRM. Konstrukcja lekka. . . . .	109
5.56	Odchylenia od temperatury zadanej dla strategii 1. Konstrukcja lekka.	110
5.57	Zachowanie systemu grzewczego dla strategii 2 w dniach od 8 do 11 października TRM. Konstrukcja lekka. . . . .	111
5.58	Zachowanie systemu grzewczego dla strategii 2 w dniach 8 i 9 stycznia TRM. Konstrukcja lekka. . . . .	112
5.59	Odchylenia od temperatury zadanej dla strategii 2. Konstrukcja lekka.	112
5.60	Zachowanie systemu grzewczego dla strategii 3 w dniach od 8 do 11 października TRM. Konstrukcja lekka. . . . .	113

5.61	Zachowanie systemu grzewczego dla strategii 3 w dniach 8 i 9 stycznia TRM. Konstrukcja lekka. . . . .	114
5.62	Odchylenia od temperatury zadanej dla strategii 3. Konstrukcja lekka.	114
5.63	Zachowanie systemu grzewczego dla strategii 4 w dniach od 8 do 11 października TRM. Konstrukcja lekka. . . . .	115
5.64	Zachowanie systemu grzewczego dla strategii 4 w dniach 8 i 9 stycznia TRM. Konstrukcja lekka. . . . .	116
5.65	Odchylenia od temperatury zadanej dla strategii 4. Konstrukcja lekka.	117
5.66	Zachowanie systemu grzewczego dla strategii 5 i wymusznieniu równym $+2^{\circ}C$ w dniach 8 i 9 stycznia TRM. Konstrukcja lekka. . . . .	117
5.67	Zachowanie systemu grzewczego dla strategii 5 i wymusznieniu równym $+2^{\circ}C$ w dniach od 8 do 11 października TRM. Konstrukcja lekka.	118
5.68	Odchylenia od temperatury zadanej dla strategii 5. Konstrukcja lekka.	118
5.69	Zachowanie systemu grzewczego dla strategii 6 w dniach od 8 do 11 października TRM. Konstrukcja lekka. . . . .	119
5.70	Zachowanie systemu grzewczego dla strategii 6 w dniach 8 i 9 stycznia TRM. Konstrukcja lekka. . . . .	119
5.71	Odchylenia od temperatury zadanej dla strategii 6. Konstrukcja lekka.	120
5.72	Zachowanie systemu grzewczego dla strategii 5 i wymusznieniu równym $+1^{\circ}C$ w dniach 8 i 9 stycznia TRM. Konstrukcja lekka. . . . .	121
5.73	Zachowanie systemu grzewczego dla strategii 5 i wymusznieniu równym $+1^{\circ}C$ w dniach od 8 do 11 października TRM. Konstrukcja lekka.	122
5.74	Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewania dla strategii 1. Konstrukcja lekka. . . . .	123
5.75	Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewania dla strategii 2. Konstrukcja lekka. . . . .	124
5.76	Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewania dla strategii 3. Konstrukcja lekka. . . . .	125
5.77	Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewania dla strategii 4. Konstrukcja lekka. . . . .	125
5.78	Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewania dla strategii 5. Konstrukcja lekka. . . . .	126

---

5.79	Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewania dla strategii 6. Konstrukcja lekka . . . . .	126
5.80	Krzywa uczenia inteligentnego termostatu. Konstrukcja lekka . . . . .	128
5.81	Zachowanie systemu grzewczego dla wyuczonej strategii w dniach 8 i 9 stycznia TRM. Konstrukcja lekka . . . . .	129
5.82	Zachowanie systemu grzewczego dla wyuczonej strategii w dniach od 8 do 11 października TRM. Konstrukcja lekka . . . . .	130
5.83	Odchylenia od temperatury zadanej dla strategii wyuczonej. Konstrukcja lekka . . . . .	130
5.84	Koszty ogrzewania dla różnych grubości wylewki i mocy zainstalowanych dla strategii wyuczonej. Konstrukcja lekka . . . . .	131
5.85	Zmniejszenie kosztu ogrzewania dla różnych grubości wylewki i mocy zainstalowanych dla strategii wyuczonej. Konstrukcja lekka . . . . .	131

# Spis tabel

5.1	Zestawienie analizowanych konstrukcji . . . . .	65
5.2	Zestawienie kosztów ogrzewania dla konstrukcji ciężkiej . . . . .	68
5.3	Zestawienie kosztów ogrzewania dla konstrukcji średnio-ciężkiej . . . . .	88
5.4	Zestawienie kosztów ogrzewania dla konstrukcji lekkiej . . . . .	108
5.5	Zestawienie kosztów ogrzewania dla poszczególnych konstrukcji i strategii wyuczonych . . . . .	127
6.1	Zestawienie optymalnej mocy ogrzewania i grubości wylewki dla poszczególnych konstrukcji. . . . .	133

# Rozdział 1

## Wstęp

### 1.1 Wprowadzenie

Zużycie energii w budownictwie w całkowitym bilansie energetycznym Unii Europejskiej to obecnie ponad 40% [24]. Kolejne miejsca zajmuje transport 31% oraz przemysł 28%. Zgodnie z ustaleniami Protokołu z Kyoto, Unia Europejska zobowiązała się do redukcji gazów cieplarnianych o 8% do roku 2012 w stosunku do stanu z 1990 roku. W tym celu w 2002 r. powstała dyrektywa o wydajności energetycznej, która ma na celu ujednoczenie przepisów, we wszystkich krajach Unii, dotyczących certyfikacji energetycznej oraz ustalenia wymagań dla nowo wznoszonych budynków. Dyrektywę oparto częściowo na już wtedy obowiązujących normach EN832 i EN13790. Co ciekawe, do tej pory nie wprowadzono wymagań dotyczących energochłonności chłodzenia oraz oświetlenia pomieszczeń.

Budownictwo jest dziedziną, w której stosunkowo najłatwiej zmniejszyć zużycie energii i w związku z tym emisję gazów cieplarnianych do atmosfery. Należy jednak pamiętać, że to nie tylko dbałość o środowisko naturalne jest motorem tych działań. Równie ważny jest aspekt polityczny i ekonomiczny. Mniejsze zapotrzebowanie na energię to również mniejsze uzależnienie od krajów bogatych w złoża naturalne oraz zdecydowanie mniejsze koszty utrzymania gospodarstwa domowego dla użytkownika końcowego.

Proporcje zużycia energii w budownictwie różnią się w zależności od kraju i warunków klimatycznych. Dla przykładu, w Niemczech [25] w bilansie całkowitym około 44% zużywanej energii pierwotnej przypada na budownictwo, z czego 32% to ogrzewanie pomieszczeń, 5% to ogrzewanie ciepłej wody użytkowej, 2% to oświetlenie, a pozostałe 5% przypada na zużycie energii elektrycznej. Szacuje się, że około 80% zużycia energii przez gospodarstwa domowe wynika ze złej izolacji istniejących budynków oraz braku systemów odzysku ciepła z wentylacji.

Głównym kierunkiem rozwoju metod mających na celu zmniejszenie energo-

chłonności budownictwa jest rozwój pasywnych metod pozyskiwania energii słonecznej, zwiększenie izolacyjności przegród ze szczególnym uwzględnieniem szczelności powietrznej konstrukcji i stosowanie systemów wentylacji z odzyskiem ciepła. Obecnie jesteśmy świadkami tworzenia się nowego standardu budownictwa, który bardzo dokładnie precyzuje wymagania dla wymienionych wyżej elementów. Jest to standard domu pasywnego [36, 98], który pozwala zmniejszyć zapotrzebowanie na energię grzewczą do około  $15\text{kWh}/\text{m}^2/\text{rok}$  w stosunku do około  $120\text{kWh}/\text{m}^2/\text{rok}$  w budynkach wznoszonych zgodnie z obecnie obowiązującym prawem. Dodatkową zaletą tego typu budownictwa jest znaczna poprawa komfortu wewnątrz oraz brak konieczności montażu klimatyzacji lub znaczne zmniejszenie zapotrzebowania na chłód [80].

Nieodłącznym elementem budownictwa pasywnego są masywne elementy konstrukcyjne, które pozwalają zmagazynować energię promieniowania słonecznego, pozyskaną w sposób bierny, poprzez odpowiednio zaprojektowane przeszklenia [83]. Dobór liczby, lokalizacji i efektywnej pojemności takich magazynów energii w stosunku do powierzchni przeszkleń nie jest zadaniem oczywistym [50]. Zbyt duże przeszklenia powodują przegrzewanie pomieszczeń i niemożność efektywnego wykorzystania zysków od energii słonecznej. Jak pokazują badania eksperymentalne, duże zdolności akumulacyjne budynku znacznie redukują wahania temperatury we wnętrzu [10], co ma istotny wpływ na jego bilans energetyczny. Pojemność cieplna budynku jest zatem bardzo istotnym czynnikiem decydującym o komforcie użytkowników i wymaga świadomego uwzględnienia już na etapie projektowania.

Energię możemy magazynować w różny sposób [26, 31]. Materiały magazynujące energię można podzielić na takie, które magazynują ją w postaci ciepła właściwego i te, które magazynują w postaci ciepła utajonego, czyli ciepła przemiany fazowej. Oprócz tego spotyka się systemy magazynujące energię w postaci chemicznej np. produkcja wodoru wykorzystywanego później w ogniwach paliwowych. Najtańsze i najbardziej popularne są dwa pierwsze sposoby. Praktyczna realizacja sprowadza się do wykonania konstrukcji budynku z ciężkiego materiału np. betonu, pełnej cegły ceramicznej czy bloczków silikatowych. Spotyka się również rozwiązania wykorzystujące kamień, wodę czy elementy metalowe. Kolejnym rozwiązaniem są materiały z domieszką organicznych lub nieorganicznych związków chemicznych, które w trakcie zmiany stanu skupienia ze stałego na ciekły wykazują bardzo dużą pojemność cieplną [33, 41].

Główny kierunek zmniejszenia zużycia energii to zatem budynki bardzo dobrze izolowane, wyposażone w magazyny energii cieplnej w różnych postaciach. Trzeba jednak zwrócić uwagę, że z punktu widzenia użytkownika końcowego zmniejszenie emisji gazów cieplarnianych do atmosfery stoi zazwyczaj na drugim miejscu za aspektem ekonomicznym. Inwestor, w zależności od stopnia swojej świadomości ekologicznej, decyduje się na rozwiązania grzewcze w swoim domu biorąc pod uwagę

głównie koszt instalacji i późniejsze obciążenia finansowe związane z eksploatacją budynku. Jak widać z przedstawionego zestawienia, ponad 80% kosztów utrzymania budynku wiąże się z ogrzewaniem. Powstaje zatem pytanie, czy w budynku o dużej pojemności cieplnej i stosunkowo małym zapotrzebowaniu na energię są jeszcze sposoby na zmniejszenie kosztu ogrzewania pomieszczeń.

Warto zwrócić uwagę, że istnieje kilka źródeł tańszej energii. Jest to np. dwutaryfowy system rozliczania energii elektrycznej, gdzie przez 10 godzin w ciągu doby energia jest znacząco tańsza. Inne przykłady to energia odpadowa, powstająca np. w trakcie pracy hybrydowych instalacji wiatrowo - słonecznych, które umożliwiają wybudowanie nawet domu samowystarczalnego w polskich warunkach klimatycznych [88, 91]. Niniejsza praca ma na celu zbadanie, czy istnieje możliwość efektywnego wykorzystania tego typu źródeł energii do obniżenia kosztu eksploatacyjnego budynku, przy niekoniecznym obniżeniu całkowitego zużycia energii.

Motywacją do tych badań są często pojawiające się w literaturze prace, dotyczące zmniejszenia zapotrzebowania na maksymalną moc chłodniczą oraz zmniejszenia zużycia energii na ten cel dzięki efektywnemu wykorzystaniu masy termicznej budynku. Rezultaty tych prac pokazują, że oszczędności finansowe różnią się dosyć znacząco w zależności od analizowanego przypadku [22, 76, 81, 49]. Wyniki prac symulacyjnych [15] wskazują, że oszczędności finansowe mogą sięgać od 0 do 35%, w zależności od analizowanego systemu. Kolejna praca [4] pokazuje oszczędności wynikające ze wstępnego chłodzenia budynku przed szczytem jego wykorzystania i zwraca szczególną uwagę na problem masy termicznej wyposażenia, która znacząco wpływa na wyniki. W pracy przeglądowej, dotyczącej optymalnej strategii sterowania systemami chłodniczymi [14], można znaleźć wniosek, że faktyczne oszczędności są bardzo czułe na stopień wykorzystania budynku, jego charakterystykę termiczną, rodzaj systemu chłodniczego oraz warunki klimatyczne. Największe oszczędności osiągnięto dla ciężkich konstrukcji i stosunkowo niskich temperatur zewnętrznych, które umożliwiały nocne chłodzenie poprzez system wentylacyjny, ale bez wykorzystania aktywnych elementów chłodzących. Wszystkie te prace zwracały dużą uwagę na wciąż niewykorzystany potencjał, dotyczący możliwości zmniejszenia zużycia energii, który tkwi w bezwładności cieplnej budynku i odpowiednim sterowaniu systemami HVAC (*ang. Heating, Ventilation and Air Conditionig*).

W rzeczywistym budynku najtańszym i najbardziej efektywnym sposobem wykorzystania magazynu, jaki stanowi masa budynku, jest wykonanie ogrzewania płaszczyznowego. Element grzejny można umieścić w masywnej podłodze lub w tynku na ścianie lub suficie. Element grzejny może być wykonany z kabla grzejnego bezpośrednio zamieniającego energię elektryczną na ciepło lub też rurek wypełnionych wodą i wtedy może być zasilany z dowolnego źródła ciepła, chociaż w tym zastosowaniu najbardziej odpowiednia jest pompa ciepła [95, 96]. Powstaje jednak problem optymalnego sterowania systemem grzewczym, który umożliwi określenie momentów

włączenia i wyłączenia instalacji w taki sposób, aby zminimalizować koszt eksploatacyjny, przy pozostaniu w zakresie optymalnego komfortu termicznego.

## 1.2 Metody zarządzania energią w budynku

Problem zarządzania energią w budynku jest ściśle powiązany z jakością życia jego mieszkańców. Na warunki komfortu składają się 3 podstawowe czynniki. Jest to komfort termiczny, komfort wizualny i jakość powietrza wewnętrznego [9, 8]. Komfort termiczny przyjęto definiować poprzez indeks PMV (*ang. Predictive Mean Vote*) [37], który jest obliczany z tzw. równania Fanger'a [45]. Wskaźnik ten pozwala określić średnie warunki, w których większość osób będzie miała takie same odczucie komfortu termicznego. Indeks PMV przyjmuje wartości od  $-3$  do  $+3$ , gdzie najniższa wartość oznacza bardzo zimno a najwyższa bardzo gorąco. Standard ASHRE [9] przyjmuje, że wartość indeksu PMV na poziomie  $0 \pm 0.5$  jest definiowany jako komfortowe warunki termiczne.

Komfort wizualny jest determinowany przez poziom iluminacji mierzony w lalach oraz oświetlenie, pochodzące bezpośrednio od słońca. Jakość powietrza wewnętrznego jest determinowana przez poziom stężenia dwutlenku węgla ( $\text{CO}_2$ ), lotnych związków organicznych (VOC), cząstek stałych czy tlenków azotu ( $\text{NO}_x$ ). Wszystkie te substancje dostają się do pomieszczeń wraz ludźmi, wyposażeniem wewnątrz czy wprost z zanieczyszczonym powietrzem zewnętrznym. Niewydajna wentylacja powoduje zawsze złe samopoczucie osób przebywających wewnątrz, a najczęstsze objawy to bóle głowy, reakcje alergiczne, zmęczenie i problemy z błonami śluzowymi. Wszystkie te objawy opisuje się w literaturze jako Syndrom Chorego Budynku [82], który najczęściej dodatkowo wiąże się jeszcze z szybką korozją konstrukcji budynku, związaną z wykraplaniem wilgoci w przegrodach i rozwojem różnego rodzaju grzybów. Z kolei nadmierne zwiększanie wentylacji powoduje przesuszenie powietrza oraz duże zużycie energii. Stąd coraz częściej wykonuje się wentylację ze zmienną wydajnością, gdzie strumień powietrza jest uzależniony od aktualnego stężenia dwutlenku węgla lub innych zanieczyszczeń [39, 17]. Jak pokazują badania eksperymentalne, tego typu rozwiązania pozwalają zaoszczędzić bardzo duże ilości energii [87, 99].

Jak widać komfort życia mieszkańców stoi w sprzeczności z niskim zużyciem energii. Wyrafinowane systemy zarządzania energią w budynku mają zatem następujące cele działania:

- **Zapewnienie komfortu** - nauczenie się akceptowalnego zakresu komfortu na podstawie preferencji użytkowników i zagwarantowanie jego wysokiego poziomu oraz szybkiej adaptacji do zmian.
- **Oszczędność energii** - racjonalne dostosowanie strategii oszczędności do warunków komfortu.



- **Dobra jakość powietrza wewnętrznego** - zapewnienie systemu wentylacji opartego na kontroli stężenia CO<sub>2</sub> czy VOC.

Trzeba też podkreślić, że realizacja optymalnego zarządzania energią w budynku jest bardzo trudna. Wynika to przede wszystkim ze zmiennych zachowań użytkownika. Może on np. podwyższyć zadaną temperaturę, co spowoduje natychmiastowe uruchomienie instalacji grzewczej, która będzie pracować aż do momentu uzyskania żądanej wartości. Może to też być włączenie czy też wyłączenie oświetlenia. Kolejny problem to używanie zasłon lub rolet, które mogą być dowolnie zmieniane w zależności od nastroju. Kompleksowe zarządzanie energią w budynku wymaga zatem koordynacji wielu podsystemów sterujących poszczególnymi elementami w budynku.

Optymalne działanie każdego podsystemu można również oprzeć o wiedzę ekspercką. Oczywiście zatrudnienie wielu osób, które będą na bieżąco sprawdzać poprawność optymalnego działania poszczególnych podsystemów w budynku byłoby trudne, drogie i mogłoby powodować konflikty pomiędzy poszczególnymi podsystemami. Z tego względu stosuje się różnego rodzaju zaawansowane techniki, które mają za zadanie optymalizację działania wszystkich elementów odpowiedzialnych za zużycie energii. Oprócz tradycyjnych metod sterowania, które wymagają modelu matematycznego budynku, coraz częściej stosuje się również metody zaczerpnięte ze sztucznej inteligencji takie jak logika rozmyta, sieci neuronowe, algorytmy genetyczne czy uczenie ze wzmocnieniem. W tej pracy skupimy się na analizie literatury związanej głównie z systemami grzewczymi.

Standardowym podejściem do sterowania systemami grzewczymi jest termostat, który załącza się, gdy temperatura zadana w pomieszczeniu jest wyższa od aktualnej [64]. Najczęściej termostat ma również ustawioną histerezę, która zapobiega bardzo częstym zmianom stanów. Często tego typu system sterowania w tradycyjnych systemach grzewczych nie daje strategii optymalnej i ma problemy z utrzymaniem dokładnie zadanej temperatury, a fluktuacje wokół zadanej temperatury powodują nieco większe zużycie energii. Z tego powodu często tradycyjny termostat zastępuje się sterownikiem PID [29]. Jednak przy źle ustawionych parametrach (a konkretnie wzmocnieniu, dobieranym doświadczalnie) cały system może stać się niestabilny i starty energetyczne mogą być jeszcze większe.

Z tych powodów zaczęto szukać kolejnych rozwiązań tego problemu. Jedną z pierwszych ścieżek poszukiwań było sterowanie adaptacyjne [20] i predykcyjne, które niestety wymagają modelu matematycznego budynku. Sterowanie predykcyjne jest szczególnie interesujące, ponieważ musi zawierać w sobie przewidywane dane dotyczące np. zysków od słońca, obecności użytkowników itd. [56, 21]. W literaturze można znaleźć udane zastosowania tego typu metod zaimplementowanych do zmniejszenia przegrzewów letnich, dzięki zastosowaniu nocnego chłodzenia [61, 79, 75]. Niestety, modele matematyczne budynków pozwalające symulować ich zachowania termiczne są często nieliniowe i dodatkowo różne dla każdego budynku, a ich opra-

cowanie bardzo czasochłonne.

Sterowanie adaptacyjne ma możliwość samoregulacji i adaptacji do zmieniających się warunków środowiska wewnętrznego. W niektórych pracach można znaleźć stwierdzenia, że sterowanie adaptacyjne w połączeniu z logiką rozmytą to najbardziej obiecujący typ sterowania, potencjalnie mogący spełnić dużą rolę w praktyce [20, 61]. Inna popularna metoda to estymacja parametryczna, a najczęściej używaną metodą jest metoda najmniejszych kwadratów. Przykładowe rozwiązanie przedstawione w pracy [20] polega na estymacji wzmocnienia i stałej czasowej regulatora PI, który steruje ogrzewaniem, wentylacją i klimatyzacją w budynku. Niestety, algorytm przestaje poprawnie działać, gdy nie jesteśmy w stanie dokładnie modelować obciążeń termicznych w budynku. Kolejnym problemem jest nieliniowe zachowanie się siłowników w instalacji. Stąd duże problemy w aplikacji praktycznej tego typu rozwiązań.

Ze wspomnianych wyżej powodów optymalne sterowanie systemami odpowiedzialnymi za zużycie energii w budynku jest procesem złożonym, a optymalna strategia działania nie jest oczywista. Podstawowe metody opisane wyżej, których zadaniem jest znalezienie strategii bliskiej optymalnej, mają następujące wady:

- wymagany jest model matematyczny budynku,
- wzięcie pod uwagę wszystkich uwarunkowań architektonicznych komplikuje proces minimalizacji funkcji kosztu eksploatacji budynku, a nawet jeśli uda się znaleźć minimum, to często wynik jest trudny do wykorzystania w praktyce,
- potrzeba estymacji parametrów czułych na drobne zmiany (szum) w czasie rzeczywistym, może powodować w praktyce fałszywe wyniki,
- metody wymienione wyżej nie dają sobie rady z zapewnieniem komfortu wewnątrz pomieszczeń. Wynika to głównie z nieliniowości niektórych elementów instalacji HVAC odpowiedzialnych za wartość indeksu PMV,
- brak wykorzystania metod algorytmów uczących się.

Bardziej rozbudowane techniki wykorzystywane do zarządzania energią w budynku sięgają do metod tzw. słabej sztucznej inteligencji. Są to przede wszystkim sieci neuronowe, algorytmy genetyczne, logika rozmyta i różne konfiguracje współpracy tych metod. Jednym z ciekawszych rozwiązań jest adaptacyjne sterowanie rozmyte [27, 16, 84], które radzi sobie z nieliniową zależnością obliczania indeksu PMV i opóźnienia czasowego. Z kolei sieci neuronowe zostały zastosowane z sukcesem do sterowania systemem grzewczym ze zmiennym przepływem i temperaturą czynnika grzewczego [48]. Wiele sukcesów związanych z zastosowaniem sieci neuronowych odnotowuje się również w Japonii, gdzie z powodzeniem stosuje się je do sterowania klimatyzatorami czy też wentylatorami [3].

Szczególnie interesująca praca [6] przedstawia propozycję systemu sterowania instalacją grzewczą za pomocą kilku sieci neuronowych, które między innymi przewidują nasłonecznienie i temperaturę zewnętrzną w kolejnym kroku decyzyjnym. Jest to nowość w stosunku do poprzednich prac, w których wszędzie wspominało o możliwym zdecydowanym poprawieniu wyników pod warunkiem posiadania modułu krótkoterminowego prognozowania parametrów pogody. Autorzy wykonali symulacje, a potem zweryfikowali praktycznie wyniki. System sterował ogrzewaniem elektrycznym i mógł tylko włączyć lub wyłączyć ogrzewanie. Dla domu pasywnego o dużej pojemności cieplnej otrzymali zmniejszenie zużycia energii o ok. 7.5% dla klimatu Grecji. Tak dobry wynik wynikał ze zdecydowanie lepszego dopasowania systemu grzewczego do potrzeb budynku. Dzięki szacowaniu składników bilansu cieplnego budynku w kolejnych krokach działania, układ nauczony stałej czasowej budynku był w stanie z wyprzedzeniem wyłączyć ogrzewanie, nie dopuszczając do przegrzewów. Zachowanie budynku pasywnego i energooszczędnego w polskich warunkach klimatycznych będzie przedmiotem prac eksperymentalnych.

W kolejnej pracy [7] ci sami autorzy zastosowali podobny, ale odpowiednio rozbudowany system sterowania do ogrzewania wodnego, podłączonego np. do pieca gazowego. W takim systemie regulacji podlega również moc przekazywana i temperatura czynnika. Uzyskano zmniejszenie zużycia energii w granicach 13% do 17% dla klimatu Grecji. Autorzy szacują, że dla klimatu północnej Europy oszczędności powinny sięgać 15%.

Zupełnie nową dziedziną sztucznej inteligencji jest uczenie się ze wzmocnieniem. Jest ona z powodzeniem stosowana do wielu zadań wymagających ciągłego doskonalenia strategii działania w nieznanym środowisku. Umożliwia adaptacje do zmian. Tego typu metody zostały zastosowane do sterowania pompą ciepła, systemem wentylacji oraz kontroli otwarcia okien [23]. Celem działania było utrzymanie komfortu wewnętrznego przy minimalnym zużyciu energii. Badania obejmowały zarówno ogrzewanie jak i chłodzenie budynku. Wynik porównano do typowego sterowania włącz/wyłącz oraz do algorytmu fuzzy-PD. Algorytm uczący się ze wzmocnieniem osiągnął nie gorsze wyniki niż dwa algorytmy wykorzystane do porównania.

Kolejna praca [5] testuje połączenie systemu uczącego się ze wzmocnieniem razem z kontrolerem PI. Głównym celem była poprawa sterowania węzownią, której model matematyczny jest nieliniowy. Okazało się, że agent uczący się ze wzmocnieniem uczy się modyfikować wyjście sterownika PI wtedy, gdy sterownik PI nie jest w stanie spełnić założonego celu sterowania.

Podsumowując można stwierdzić, że w literaturze wciąż bardzo mało przykładów aktywnego wykorzystania efektywnej pojemności cieplnej budynku do obniżenia kosztów ogrzewania. Mimo wielu prób wykorzystania metod sztucznej inteligencji do zarządzania energią w budynku, brak jest badań dotyczących znajdowania optymalnej strategii sterowania elementami grzejnymi umieszczonymi w ciężkiej konstrukcji

budynku. Trzeba podkreślić, że niniejszy problem dotyczy olbrzymiej rzeszy użytkowników, którzy na codzień korzystają z dwutaryfowego rozliczania energii elektrycznej. Dlatego ta praca ma służyć próbie znalezienia odpowiedzi na pytanie w jakich budynkach tego typu ogrzewanie przyczyni się do największych oszczędności w kosztach eksploatacyjnych oraz jakie są optymalne parametry jego stosowania.

Jako wkład własny do analizowanych zagadnień można zaliczyć zastosowanie oryginalnego połączenia dwóch różnych metod sztucznej inteligencji do sterowania systemem ogrzewania zainstalowanym w masywnych przegrodach budynku oraz znalezienie optymalnych parametrów ich działania. Po za tym, w ramach pracy powstał symulator odzwierciedlający zachowanie termiczne pomieszczenia, dzięki czemu było możliwe przetestowanie wyżej wspomnianych metod oraz powszechnie używanych strategii nadażno-programowalnych. Wykazano ich faktyczną wydajność oraz wady i zalety dla polskich warunków klimatycznych.

### 1.3 Teza i cel pracy

#### Cel pracy:

- Analiza możliwości jakie daje ogrzewanie płaszczyznowe w domu energooszczędnym do celów wykorzystania tańszej taryfy energii elektrycznej.
- Zbadanie wpływu pojemności cieplnej konstrukcji budynku na zapotrzebowanie energii w sezonie grzewczym.
- Zbadanie wpływu na koszt ogrzewania pomieszczenia i temperatur wewnętrznych powszechnie stosowanych strategii nadażno-programowalnych dla różnych wariantów wykonania budynku.
- Zbadanie wpływu ogrzewania płaszczyznowego na komfort termiczny w pomieszczeniu.
- Wskazanie optymalnych parametrów grubości betonowej wylewki, w której jest zainstalowane ogrzewanie oraz optymalnej mocy, dla której wykorzystanie tańszej taryfy jest największe.
- Próba zastosowania metod sztucznej inteligencji w celu optymalnego sterowania instalacją grzewczą minimalizującego koszt ogrzewania budynku przy pozostaniu w akceptowalnym zakresie komfortu termicznego.

#### Tezy pracy:

- Efektywna pojemność cieplna budynku ma znaczący wpływ na zużycie energii w sezonie grzewczym;

- Efektywna pojemność cieplna budynku pozwala stabilizować temperatury wewnętrzne budynku;
- Efektywna pojemność cieplna budynku pozwala obniżyć koszty ogrzewania budynku poprzez wykorzystanie tańszych lub odpadowych źródeł energii;
- Wykorzystanie metod sztucznej inteligencji do sterowania systemem grzewczym zlokalizowanym w ogrzewaniu podłogowym pozwala na dalsze obniżenie kosztów energii przeznaczonej na cele grzewcze;

## 1.4 Przegląd zawartości

W rozdziale drugim przedstawiono szczegóły algorytmu sztucznych sieci neuronowych wykorzystanych do krótkoterminowego prognozowania parametrów zmiennych pogody. Następnie zostanie przedstawiony algorytm tworzący strategię sterującą działaniem inteligentnego termostatu. W rozdziale czwartym opisano model matematyczny budynku wykorzystany w badaniach symulacyjnych niniejszej pracy. Kolejny rozdział to wyniki eksperymentów numerycznych z podziałem na różne konstrukcje budynku i różne strategie sterowania. Na koniec podsumowano całość pracy i przedstawiono jej bibliografię.

## Rozdział 2

# Krótkoterminowe prognozowanie przebiegów zmiennych pogodowych przy wykorzystaniu metod sztucznej inteligencji

### 2.1 Wprowadzenie

Krótkoterminowe prognozowanie parametrów pogodowych ma olbrzymie znaczenie dla optymalnego zarządzania energią w budynkach samowystarczalnych energetycznie. W literaturze można znaleźć bardzo wiele prób efektywnego przewidywania parametrów pogody. Używano do tego celu między innymi modeli statystycznych ARMA, metod Monte-Carlo oraz metod sztucznej inteligencji [70, 71] takich jak rekurencyjne sieci neuronowe, sieci samoorganizujące się (SOM)[65] i inne. W niniejszej pracy postanowiono wykorzystać architekturę perceptronu wielowarstwowego uczonego zaawansowanym algorytmem zapewniającym szybką zbieżność (opisanym dalej). Przy wyborze metody brano pod uwagę również szybkość nauki jako istotny czynnik w autonomicznym systemie decyzyjnym. Idea badań polega na wykorzystaniu lokalnych, historycznych danych meteorologicznych do krótkoterminowego prognozowania przyszłych parametrów pogody, bezpośrednio odpowiedzialnych za bilans energetyczny budynku. Ten rodzaj wiedzy ma szansę zdecydowanie poprawić sterowanie systemem grzewczo/chłodniczym wykorzystującym bezwładność termiczną budynku. W niniejszej pracy skupiono się przede wszystkim na bardzo krótkim okresie przewidywania, który ma szansę wpłynąć na podjęcie decyzji podejmowanej przez sterownik systemu grzewczego. Rozpatrywany horyzont czasowy sięga maksymalnie kilku godzin.


Warto dodać, że omawiana metoda może pozwolić również na przewidywanie zysków pochodzących od urządzeń pozyskujących energię ze źródeł odnawialnych

takich jak turbiny wiatrowe, ogniwa fotowoltaiczne czy kolektory słoneczne, co będzie miało bardzo istotne znaczenie dla stworzenia domu samowystarczalnego w polskich warunkach klimatycznych [88].

## 2.2 Model neuronu

Inspiracją dla twórców modelu matematycznego sztucznych sieci neuronowych były procesy zachodzące w mózgu człowieka. W 1942 r McCulloch i Pitts opracowali model komórki nerwowej, którego idea przetrwała lata i stanowi do dzisiaj podstawowe ogniwo większości używanych modeli. Twórcy sztucznych sieci neuronowych postanowili, że każdy neuron będzie charakteryzował się następującymi cechami.

- Do każdego neuronu dociera pewna liczba sygnałów, które są albo danymi wejściowymi całej sieci, albo wartościami wynikowymi innych neuronów.
- Każdy sygnał dociera do neuronu z pewną wagą.
- Każdy neuron posiada wartość progową.
- W neuronie jest obliczana ważona suma wszystkich sygnałów wejściowych, a następnie jest odejmowana od niej wartość progowa. Ta suma jest uważana za pobudzenie neuronu.
- Każdy neuron posiada funkcję aktywacji, która decyduje o wartości sygnału na jego wyjściu.



Rysunek 2.1: Model neuronu

W zapisie bardziej formalnym wygląda to następująco. Nazwijmy wektor  $x = [x_1, x_2, \dots, x_N]^T$  wektorem sygnałów wejściowych, natomiast wektor

$$W_i = [W_{i1}, W_{i2}, \dots, W_{iN}]$$

wektorem wag  $i$ -tego neuronu. Wartość  $W_{i0}$  niech będzie progami  $i$ -tego neuronu. Wtedy sygnał wyjściowy sumatora  $\mu_i$  będzie wyglądał następująco:

$$\mu_i = \sum_{j=1}^N W_{ij}x_j + W_{i0}$$

Tak skonstruowany sygnał sumatora jest podawany na część neuronu zawierającą funkcję aktywacji  $f(\mu_i)$ . Funkcja aktywacji musi spełniać dwa bardzo istotne warunki:

- ciągłość w swojej dziedzinie,
- różniczkowalność.

Daleka od spełnienia powyższych wymagań jest funkcja skokowa, która jest najbliższa biologicznemu wzorcowi i była używana w modelu McCullocha-Pittsa. Ten typ funkcji jest stosowany np. w klasyfikatorach wektorowych, gdzie sygnał wyjściowy powinien przyjmować jedną z dwóch dyskretnych wartości. Jednak do uczenia takiego systemu można jedynie zastosować algorytm typu Widrowa-Hoffa. To podejście jest bardzo powolne i mało efektywne. Dużo lepsze wyniki dają algorytmy gradientowe, które wymagają od funkcji aktywacji neuronu spełnienia powyższych warunków. Dlatego w dalszej części niniejszej pracy będą stosowane tylko funkcje ciągłe i różniczkowalne.

Podstawowe funkcje aktywacji stosowane obecnie to *funkcje sigmoidalne*. Są one przybliżeniem funkcji skokowej. Jeżeli wartości funkcji są z zakresu  $[0, 1]$ , to funkcję taką nazywamy *unipolarną*, natomiast dla dowolnych wartości z przedziału  $[-1, 1]$  funkcję *bipolarną*. Funkcja sigmoidalna unipolarna jest najczęściej przedstawiana w poniższej postaci:

$$f_u(\mu_i) = \frac{1}{1 + \exp(-\beta\mu_i)}$$

i jej pochodna:

$$\frac{df_u(x)}{dx} = \beta f_u(x)(1 - f_u(x))$$

Natomiast funkcja sigmoidalna bipolarna wygląda następująco:

$$f_b(\mu_i) = \tanh(\beta\mu_i)$$

Jednak częściej stosuje się numeryczny odpowiednik tej funkcji postaci:


$$f_b(\mu_i) = \frac{2}{1 + \exp(-\beta\mu_i)} - 1$$



której pochodna wynosi:

$$\frac{df_b(x)}{dx} = 2\beta f_u(x)(1 - f_u(x))$$

Powyższa reprezentacja tangensa hiperbolicznego jest łatwiejsza w obliczeniach, ale może powodować minimalne błędy numeryczne. Mimo to stosuje się ją dosyć powszechnie ze względu na przyspieszenie algorytmów uczących. Jest ona znakomitym rozwiązaniem dla sieci neuronowych, w których najważniejsza jest szybkość działania, a nie dokładny kształt funkcji aktywacji. W dalszych obliczeniach zostanie przyjęte  $\beta = 2$ .



Rysunek 2.2: Najczęściej stosowane funkcje przejść

Innym rodzajem funkcji aktywacji jest *funkcja liniowa*. Jest ona oczywiście ciągła i różniczkowalna. Stosuje się ją zazwyczaj w sieciach jednokierunkowych w warstwie wyjściowej, ponieważ w przeciwieństwie do funkcji rozpatrywanych powyżej nie wprowadza ograniczeń na wartość wyjściową neuronu. Jest to bardzo istotne szczególnie przy zadaniu predykcji, ponieważ w trakcie konstruowania sieci należy zapewnić, by uczony system był w stanie odwzorować całą przeciwdziedzinę prognozowanej funkcji.

## 2.3 Definicja funkcji celu

Sposoby traktowania uczenia sztucznych sieci neuronowych ze względu na cel nauki można podzielić na dwie zasadnicze metody.

- **Uczenie bez nauczyciela** (bez nadzoru) - cel uczenia nie jest określony przez konkretne przykłady, a jedynie przez informację czy podjęta przez system akcja daje wyniki pozytywne, w sensie pożądanego zachowania systemu czy też negatywne. Ten typ uczenia jest inaczej nazwany uczeniem z krytykiem i jest bardzo podobny do wykorzystywanego w niniejszej pracy uczenia ze wzmocnieniem. Jednak tutaj podejmowane przez system akcje są to np. zmiany wartości wag. Takie podejście w uczeniu sieci neuronowych jest znacznie bardziej

uniwersalne w zastosowaniu, gdyż nie wymaga obecności sygnałów żądanych na wyjściu całego systemu uczącego. Niestety, wadą tego podejścia jest duże skomplikowanie jego praktycznej realizacji.

- **Uczenie z nauczycielem** (z nadzorem) - nauczyciel podpowiada sieci wymaganą odpowiedź na zadany sygnał wejściowy.

W niniejszej pracy uczenie systemu predykcyjnego będzie odbywać się z według schematu uczenia pod nadzorem.

W uczeniu pod nadzorem każdemu wektorowi wejściowemu:

$$x(k) = [x_1(j), x_2(j), \dots, x_N(j)]^T$$

towarzyszy zadany wektor wyjściowy:

$$d(k) = [d_1(j), d_2(j), \dots, d_M(j)]^T$$

Wszystkie dane uczące są podawane do systemu w postaci pary liczb  $(x(j), d(j))$  przy czym  $j = 1, 2, \dots, p$ , jest liczbą przykładów uczących. Jeśli zatem założymy, że sygnał  $y(j)$  jest odpowiedzią sieci na pobudzenie  $x(j)$ , to błąd uczenia  $e(j)$  dla każdej pary uczącej  $(x(j), d(j))$  można zdefiniować następująco:

$$e(j) = (y(j) - d(j))$$

Celem uczenia z nauczycielem jest minimalizacja odpowiednio zdefiniowanej funkcji celu. Umożliwia to, oczywiście w sensie statystycznym, dopasowanie odpowiedzi sieci  $y(j)$  do wartości podawanych przez nauczyciela  $d(j)$ . Najczęściej spotykaną w literaturze funkcją celu jest błąd średniokwadratowy różnicy odpowiedzi sieci i wartości żądanej:

$$E = \frac{1}{2} \sum_{j=1}^p \sum_{i=1}^M e_i^2(j) = \frac{1}{2} \sum_{j=1}^p \sum_{i=1}^M (y_i(j) - d_i(j))^2$$

gdzie: M - liczba neuronów ukrytych, a p - liczba par uczących.

Taka definicja funkcji celu umożliwia, przy założeniu ciągłości funkcji aktywacji, zastosowanie do nauki sieci bardzo efektywnych algorytmów gradientowych. Do aktualizacji wag wykorzystuje się wtedy informacje o gradiencie funkcji celu zdefiniowanym następująco:

$$\nabla E = \left[ \frac{\partial E}{\partial W_1}, \frac{\partial E}{\partial W_2}, \dots, \frac{\partial E}{\partial W_n} \right]^T$$

Dokładny sposób nauki sieci neuronowych zastosowany w części eksperymentalnej niniejszej pracy jest opisany poniżej.

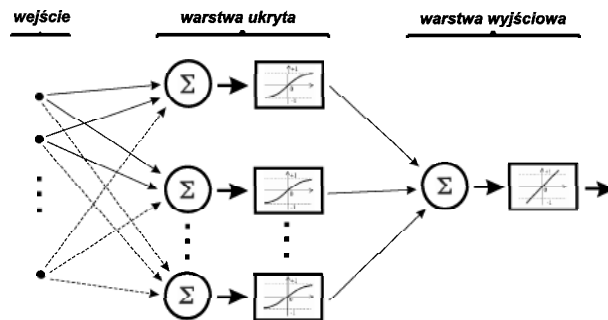
## 2.4 Architektura sieci

Jednym z najważniejszych zadań, postawionych przed konstruktorem systemu uczonego, jest dobór odpowiedniej architektury sieci neuronowej. Musi być ona odpowiednio dopasowana do rozpatrywanego problemu. Innymi słowy należy zastanowić się nad:

- a) liczbą warstw sieci,
- b) liczbą neuronów w każdej z nich,
- c) funkcji aktywacji poszczególnych neuronów,
- d) sposobem i algorytmem uczenia,
- e) metodzie doboru wag początkowych.

Topologia sieci była przedmiotem badań wielu autorów, ale pewne podsumowanie tych działań można znaleźć w pracy [66] oraz [77]. Okazuje się, że do większości zastosowań wystarcza architektura trzywarstwowa: warstwa wejściowa, ukryta i wyjściowa. Wynika to z faktu, że działanie sieci opiera się na odpowiednim składaniu funkcji aktywacji neuronów. Wiadomo, że każda funkcja może być wyrażona jako kombinacja liniowa lokalnych impulsów, natomiast sam impuls może powstać z superpozycji dwóch funkcji przesuniętych względem siebie. Jeśli zatem złożylibyśmy ze sobą dwie funkcje sigmoidalne, to odpowiednio manipulując ich przesunięciem względem siebie możemy utworzyć dowolny impuls o zadanej szerokości i stromości narastania. Podobnie dzieje się dla funkcji 3 - wymiarowej z tym, że tworzymy zamiast pojedynczego impulsu garb, który w wyniku manipulacji wagami zmienia swój kształt. Oczywiście, przy wielu neuronach ukrytych występuje nakładanie omawianych funkcji, dzięki czemu możemy uzyskać dowolny szukany przebieg. W literaturze istnieją [77] dowody formalne powyższych uwag znane pod postacią **twierdzenia Kołmogorowa**. Mówi ono, że dowolna funkcja ciągła przekształcająca  $N$  - wymiarowy zbiór danych wejściowych w  $M$  - wymiarowy wektor wyjściowy  $d$ , może być aproksymowana przez sieć neuronową z jedną warstwą ukrytą z  $(2N + 1)$  neuronami. Niestety, problemy zaczynają się, jeżeli zadana funkcja posiada nieciągłości. Wtedy najczęściej jest konieczne wprowadzenie drugiej warstwy ukrytej. Może to powodować następujące komplikacje w trakcie uczenia [66]:

1. zwiększenie niestabilności gradientu,
2. duża liczba minimów lokalnych,
3. znaczne wydłużenie czasu nauki.



Rysunek 2.3: Architektura sieci neuronowej

Teoria Kołmogorowa podaje, niestety, tylko ogólne zalecenia co do architektury, która może się znacznie różnić w konkretnych zastosowaniach. Zazwyczaj nie znamy dokładnej specyfiki rozpatrywanego problemu i nie możemy sieci uczyć w nieskończoność. Dodanie warstwy ukrytej lub zwiększenie liczby neuronów ukrytych może z kolei powodować przeuczenie lub niedouczenie sieci (ten problem został dalej opisany szerzej). Dlatego w badaniach eksperymentalnych poszukuje się optymalnej liczby neuronów ukrytych, wykonując obliczenia dla różnych ich wartości, a to powoduje, że badania są bardzo czasochłonne.

## 2.5 Algorytm wstecznej propagacji błędu

Algorytm wstecznej propagacji błędu (*ang.* **BackPropagation - BP**) został wprowadzony przez Werbosa w 1974r i ponownie odkryty przez Rumelharta w 1986r. Od tamtej pory sieci neuronowe zaczęły budzić olbrzymie zainteresowanie wielu badaczy ze względu na to, że po raz pierwszy został zaprezentowany efektywny i prosty algorytm uczenia wielowarstwowych, jednokierunkowych sztucznych sieci neuronowych.

Celem uczenia sieci jest znalezienie optymalnych wag tak, aby określone pobudzenie sieci powodowało ustawienie wartości wyjść z minimalnym błędem w stosunku do wartości referencyjnych. Ponieważ wcześniej założono ciągłość funkcji celu, to można zastosować metodę gradientową aktualizacji wag, która wyraża się poniższym wzorem:

$$W(k+1) = W(k) + \Delta W$$

gdzie:

$$\Delta W = \eta p(W)$$

a  $\eta$  jest współczynnikiem uczenia, natomiast  $p(W)$  jest kierunkiem w wielowymiarowej przestrzeni  $W$ , a  $k$  odpowiada kolejnym cyklom uczącym. W literaturze [78] można znaleźć następujący sposób postępowania w celu aktualizacji wag we wszystkich warstwach sieci.

1. Analiza sieci w kierunku od wejścia do wyjścia z pobudzeniem wektorem wejściowym  $x$ .
2. Wynik (wartość sygnałów wyjściowych każdej z warstw oraz wektor pochodnych funkcji aktywacji wszystkich neuronów) jest wykorzystywany dalej.
3. Analiza sieci od wyjścia do wejścia.
  - Zmiana funkcji aktywacji na ich pochodne
  - Na wejście (byłe wyjście) sieci należy podać różnicę między wartością otrzymaną w poprzednim punkcie a wartością zadaną.
4. Modyfikacja wag na podstawie wyników z punktów poprzednich i odpowiednich wzorów (są przedstawione dalej).
5. Opisany proces powtarza się dla wszystkich wzorców uczących do momentu spełnienia warunków zatrzymania algorytmu:
  - norma gradientu spadnie poniżej ustalonej wartości  $\epsilon$ ,
  - ustalona liczba epok uczenia zostanie wykonana.

Poniżej zostaną przedstawione wzory, według których następuje modyfikacja wag dla przypadku jednej pary uczącej  $(x, d)$  i aktualizacji wag po każdym jej podaniu. Opisany wyżej proces wyraża się następującymi przekształceniami [78]:

$$E = \frac{1}{2} \sum_{k=1}^M [f(\sum_{i=0}^K W_{ki}^{(2)} v_i) - d_k]^2 = \frac{1}{2} \sum_{k=1}^M [f(\sum_{i=0}^K W_{ki}^2 f(\sum_{j=0}^N W_{ij}^1 x_j)) - d_k]^2$$

przy czym:

- $N$  - liczba wejść sieci,
- $K$  - liczba neuronów w warstwie ukrytej,
- $M$  - liczba neuronów w warstwie wyjściowej,
- $W_{ij}$  - kolejne wagi połączeń między warstwą wejściową a ukrytą,
- $W_{ki}$  - kolejne wagi połączeń między warstwą ukrytą a wyjściową,

- indeksy przy wagach oznaczają numer warstwy 2 - wyjściowa, 1- ukryta,
- wektor wejściowy zawiera sygnał stały (tzw. bias)  $x = [1, x_1, x_2, \dots, x_N]^T$ .

Poszukiwany gradient otrzymuje się przez różniczkowanie powyższej zależności. Dla warstwy wyjściowej zależność ta przyjmuje postać:

$$\nabla_{ij}^{(2)} = \frac{\partial E}{\partial W_{ij}^{(2)}} = (y_i - d_i) \frac{df(u_i^{(2)})}{du_i^{(2)}} v_j$$

gdzie:  $u_i^{(2)} = \sum_{j=0}^K W_{ij}^{(2)} v_j$ . Jeżeli wprowadzimy dodatkową zmienną wyrażoną jako:

$$\delta_i^{(2)} = (y_i - d_i) \frac{df(u_i^{(2)})}{du_i^{(2)}}$$

to składnik gradientu względem warstwy wyjściowej można zapisać następująco:

$$\nabla_{ij}^{(2)} = \frac{\partial E}{\partial W_{ij}^{(2)}} = \delta_i^{(2)} v_j$$

Określenie gradientu dla warstwy ukrytej wygląda nieco bardziej skomplikowanie:

$$\nabla_{ij}^{(1)} = \frac{\partial E}{\partial W_{ij}^{(1)}} = \sum_{k=1}^M (y_k - d_k) \frac{dy_k}{dv_i} \frac{dv_i}{dW_{ij}^{(1)}}$$

czyli:

$$\frac{\partial E}{\partial W_{ij}^{(1)}} = \sum_{k=1}^M (y_k - d_k) \frac{df(u_k^{(2)})}{du_k^{(2)}} W_{ki}^{(2)} \frac{df(u_i^{(1)})}{du_i^{(1)}} x_j$$

Wprowadzając oznaczenia:

$$\delta_k^{(2)} = (y_k - d_k) \frac{df(u_k^{(2)})}{du_k^{(2)}}$$

$$\delta_i^{(1)} = \sum_{k=1}^M \delta_k^{(2)} W_{ki}^{(2)} \frac{df(u_i^{(1)})}{du_i^{(1)}}$$

otrzymuje następujące wyrażenie wyznaczające składową gradientu względem wag neuronów warstwy ukrytej:

$$\nabla_{ij}^{(1)} = \frac{\partial E}{\partial W_{ij}^{(1)}} = \delta_i^{(1)} x_j$$

W podstawowej wersji algorytmu BackPropagation kierunek zmiany wartości wag  $p(W)$  jest zgodny z kierunkiem ujemnego gradientu. Zatem równanie uaktualniania wektora wag przybiera postać:

$$W(k+1) = W(k) + \Delta W$$

$$\Delta W = \eta \nabla E(W)$$

W literaturze [66, 77] wymienia się kilka poważnych wad tej metody.

- Brak pewności znalezienia rozwiązania optymalnego. Wynika to z faktu, że gradient jest lokalnym wskaźnikiem kierunku zmiany przebiegu funkcji. Z tego powodu istnieje duże prawdopodobieństwo utknięcia w minimum lokalnym.
- Wolna zbieżność metody, czyli długi czas nauki.
- Duża wrażliwość na wagi początkowe.
- Duża wrażliwość na wielkość współczynnika uczenia  $\mu$ . Małe  $\mu$  powoduje znaczne spowolnienie uczenia, z kolei duże  $\mu$  może powodować oscylacje.

Z tych też powodów coraz częściej algorytm wstecznej propagacji błędów w klasycznej postaci zostaje zastępowany przez swoje modyfikacje.

## 2.6 Algorytm gradientów sprzężonych z regularyzacją

W trakcie badań eksperymentalnych nad krótkoterminowym przewidywaniem parametrów pogody wykonano bardzo wiele testów z różnymi algorytmami i w rezultacie najlepszym i najbardziej efektywnym okazał się algorytm opierający się na metodzie gradientów sprzężonych z regularyzacją (*ang.* **Scaled Conjugate Gradient SCG**). Bardzo pomocna w wyborze zbioru algorytmów do testów była praca Moller'a [67], który jest pomysłodawcą niniejszego algorytmu. Zostało tam porównane ze sobą kilka najbardziej popularnych algorytmów takich jak BackPropagation (BP), Conjugate Gradient with Line search (CGL), Brodyen-Fletcher-Goldfarb-Shanno (BFGS) oraz wspomniany już Scaled Conjugate Gradient (SCG). Po przetestowaniu wszystkich wymienionych algorytmów dobre i zdecydowanie lepsze od konkurentów, wyniki uczenia dał algorytm SCG. Poniżej zostaną przedstawione najważniejsze założenia tego algorytmu.

Omawiany algorytm wywodzi się ze zwykłej metody gradientów sprzężonych łącząc w sobie jednocześnie wyznaczanie kierunku  $p$  i optymalnego kroku w tym kierunku. Punktem wyjścia do dalszych rozważań jest kwadratowe rozwinięcie Taylora funkcji celu w kierunku  $p_k$  z krokiem  $\eta$ , którą można zapisać w postaci:

$$E(W_k + \eta p_k) \approx E(W_k) + \eta g_k^T p_k + \frac{1}{2} \eta^2 p_k^T G_k p_k$$

gdzie  $G_k$  jest przybliżoną wartością hesjanu  $H_k$  w  $k$ -tym kroku. Hesjan jest to macierz drugich pochodnych zdefiniowana następująco:

$$\begin{bmatrix} \frac{\partial E}{\partial W_1 \partial W_1} & \cdots & \frac{\partial E}{\partial W_n \partial W_1} \\ \cdot & & \cdot \\ \cdot & & \cdot \\ \cdot & & \cdot \\ \frac{\partial E}{\partial W_1 \partial W_n} & \cdots & \frac{\partial E}{\partial W_n \partial W_n} \end{bmatrix}$$

Warunek minimum funkcji celu w kierunku  $p_k$  implikuje następujące równanie:

$$\frac{\partial E}{\partial(\eta p_k)} = g_k + \eta G_k p_k = 0$$

Z powyższej zależności w sposób bezpośredni wynika wzór na optymalną wartość kroku uczenia  $\eta$  w kierunku  $p_k$ :

$$\eta = -\frac{p_k^T g_k}{p_k^T G_k p_k} = \frac{\mu_k}{\delta_k}$$

gdzie  $\mu_k = -p_k^T g_k$ ,  $\delta_k = p_k^T G_k p_k$ . Zatem do wyznaczenia współczynnika uczenia należy wyznaczyć wartości skalarne  $\mu_k$  oraz  $\delta_k$ . Wielkość pierwszej z tych zmiennych można wyznaczyć bez większych kłopotów, ponieważ zarówno gradient  $g_k$ , jak i wektor kierunkowy  $p_k$  są ściśle określone w metodzie gradientów sprzężonych [77]. Z kolei wyznaczenie wartości  $\delta_k$  byłoby bardzo nieefektywne ze względu na dużą złożoność obliczeniową oraz zajętość pamięci potrzebną do wyznaczenia wartości hesjanu. W związku z tym wyznacza się wektor  $G_k p_k$  na podstawie informacji o gradiencie w punkcie rozwiązania  $W_k$  oraz punkcie zaburzonym o wielkość względną  $0 < \sigma_k \ll 1$ . Stąd wynika wzór:

$$s_k = G_k p_k \approx \frac{g(W_k + \sigma p_k) - g(W_k)}{\sigma_k}$$

Wartość współczynnika uczenia  $\eta$  jest określona jako optymalna przez wymieniony wzór tylko wówczas, gdy hesjan jest dodatnio określony. Wynika to z faktu, że kwadratowe przybliżenie Taylora prowadzi do minimum tylko pod tym warunkiem. Wymaganie na dodatność hesjanu w przypadku sieci neuronowych jest trudne do



spełnienia. Zaproponowano więc, żeby zastosować regularyzację hesjanu, która w tym wypadku będzie dotyczyła wyrażenia  $G_k p_k$  i przybiera postać:

$$s_k = \frac{g(W_k + \sigma p_k) - g(W_k)}{\sigma_k} + \lambda_k p_k$$

Parametr regularyzacyjny  $\lambda_k$  musi być tak dobrany, aby  $\delta_k = p_k^T s_k > 0$ . Jeżeli pomimo wprowadzonej poprawki współczynnik  $\delta_k$  jest dalej ujemny, to należy dodać większą wartość  $\lambda_k$ . Załóżmy, że nowa wartość regularyzująca spełnia wymagania dodatniej określoności hesjanu,  $\delta_k > 0$ . Jeśli nową wartość  $s_k$  nazwiemy  $\bar{s}_k$  a nową wartość  $\lambda_k$  przez  $\bar{\lambda}_k$ , wtedy zachodzi równanie:

$$\bar{s}_k = s_k + (\bar{\lambda}_k - \lambda_k) p_k$$

Nowa regularyzowana wartość  $\bar{\delta}_k$  spełnia teraz zależność:

$$\bar{\delta}_k = p_k^T G_k p_k + p_k^T (\bar{\lambda}_k - \lambda_k) p_k = \delta_k + (\bar{\lambda}_k - \lambda_k) |p_k|^2 > 0$$

Stąd wynika, że:

$$\bar{\lambda}_k > \lambda_k - \frac{\delta_k}{|p_k|^2}$$

Powyższa zależność wskazuje kierunek zmian, ale nie określa jednoznacznej zależności, o ile należy zwiększyć wartość  $\lambda_k$ , choć jest oczywiste, że zależność określająca  $\bar{\lambda}_k$  powinna zawierać  $\lambda_k$ ,  $\delta_k$  i  $|p_k|^2$ . Moller zaproponował następującą formułę:

$$\bar{\lambda}_k = 2\left(\lambda_k - \frac{\delta_k}{|p_k|^2}\right)$$

Prowadzi to do wyrażenia definiującego  $\bar{\delta}_k$ :

$$\bar{\delta}_k = \delta_k + (\bar{\lambda}_k - \lambda_k) |p_k|^2 = -\delta_k + \lambda_k |p_k|^2$$

spełniającego warunek dodatniej wartości hesjanu. Wzór określający optymalny krok na kierunek  $p_k$  wygląda zatem następująco:

$$\eta = \frac{\mu_k}{\bar{\delta}_k} = \frac{\mu_k}{-p_k^T s_k + \delta_k |p_k|^2}$$

Wartość  $\delta_k$  skaluje wartość kroku nauki w ten sposób, że większa wartość tego parametru powoduje zmniejszenie kroku  $\eta$ . Aby uzyskać dobrą aproksymację hesjanu, można wprowadzić dodatkowy parametr  $\Delta_k$ , który będzie wskazywał optymalny kierunek zmian parametru  $\lambda_k$ . Definiuje się go następująco:

$$\Delta_k = \frac{E(W_k) - E(W_k + \eta p_k)}{E(W_k) - E_a(\eta p_k)}$$

gdzie  $E_a(\eta p_k)$  odpowiada aproksymowanej wartości funkcji celu przy zastąpieniu hesjanu jego wartością zregularyzowaną. Na podstawie poprzednich wzorów otrzymujemy wyrażenie:

$$\Delta_k = \frac{2\bar{\delta}_k[E(W_k) - E(W_k + \eta p_k)]}{\mu_k^2}$$

Wartość  $\Delta_k$  jest miernikiem jakości aproksymacji. Dla wartości bliskich 1 aproksymacja jest najdokładniejsza. Moller zaproponował następujący sposób zmian  $\lambda_k$ :

- jeśli  $\Delta_k > 0.75$  to  $\lambda_k := \frac{1}{4}\lambda_k$ ;
- jeśli  $\Delta_k < 0.25$  to  $\lambda_k := \lambda_k + \frac{\delta_k(1-\Delta_k)}{|p_k|^2}$ ;
- dla pozostałych wartości  $\Delta_k$  bez zmian.

Pełen przebieg algorytmu przedstawia poniższy schemat:

1. Wybierz wektor wag początkowych  $W_k$ , i współczynników  $0 < \sigma \leq 10^{-4}$ ,  
 $0 < \lambda_k \leq 10^{-6}$ ,  
 $\bar{\delta}_k = 0$ .  
 Oblicz  $p_k = -g(W_k)$  dla  $k = 1$ , *sukces = true*
2. **Jeśli *sukces = true*, to** określ  
 $\sigma_k = \frac{\sigma}{|p_k|}$ ,  $s_k = \frac{g(W_k + \sigma_k p_k) - g(W_k)}{\sigma_k}$ ,  $\delta_k = p_k^T s_k$
3. Dokonaj regularyzacji przyjmując:  
 $\delta_k = \bar{\delta}_k := \delta_k + (\bar{\lambda}_k - \lambda_k)|p_k|^2$ .  
**Jeśli  $\bar{\delta}_k < 0$  to** kontynuuj regularyzację przyjmując kolejno  
 $\bar{\lambda}_k = 2(\lambda_k - \frac{\sigma_k}{|p_k|^2})$ ,  
 $\bar{\sigma}_k = -\sigma_k + \lambda_k|p_k|^2$ ,  
 $\lambda_k = \bar{\lambda}_k$
4. Oblicz  $\mu_k$  oraz wartości kroku  $\eta_k$   
 $\mu_k = -p_k^T g_k$ ,  $\eta_k = \frac{\mu_k}{\bar{\delta}_k}$
5. Oblicz współczynnik  $\Delta_k$   
 $\Delta_k = \frac{2\sigma_k[E(W_k) - E(W_k + \mu_k p_k)]}{\mu_k^2}$

6. **Jeśli**  $\Delta_k \geq 0$ , **to** wykonaj następny krok minimalizacyjny przyjmując  $W_{k+1} = W_k + \mu_k p_k$ ,  $g_{k+1} = g(W_{k+1})$ ,  $\bar{\lambda}_k = 0$ ,  
*sukces = true*
  - **jeśli**  $k$  jest równe liczbie wag sieci, to zastosuj restart algorytmu  $p_{k+1} = -g_{k+1}$
  - **w przeciwnym przypadku**  
 $\beta_k = \frac{|g_{k+1}|^2 - g_{k+1}g_k}{\mu_k}$ ,  $p_{k+1} = -g_{k+1} + \beta_k p_k$
7. **Jeśli**  $\Delta_k \geq 0,75$ , **to** zredukuj  $\lambda_k$  przyjmując  $\lambda_k := \frac{1}{4}\lambda_k$   
**w przeciwnym przypadku**  $\bar{\lambda}_k = \lambda_k$ , *sukces = false*
8. **Jeśli**  $\Delta < 0,25$ , **to** zwiększ  $\lambda_k$ ,  
 $\lambda_k := \lambda_k + \frac{\delta_k(1-\Delta_k)}{|p_k|^2}$
9. **Jeśli**  $g_k \neq 0$ , **to** przyjmij  $k := k + 1$  i wróć do punktu 2  
**w przeciwnym przypadku** zakończ obliczenia i **zwróć**  $W_{k+1}$  jako rozwiązanie

W omawianym algorytmie pochodne funkcji celu względem poszczególnych wag neuronów są obliczane zgodnie z metodą zaprezentowaną w algorytmie BackPropagation.

W niniejszej pracy w badaniach eksperymentalnych przyjęto wartości początkowe  $\sigma = 5 \cdot 10^{-5}$  oraz  $\lambda_k = 5 \cdot 10^{-7}$ .

Powyższy opis algorytmu SCG jest bardzo skrótowy. Więcej informacji na ten temat można znaleźć w literaturze [67].

## 2.7 Problem wag początkowych

Problem inicjalizacji wag początkowych został wspomniany już wcześniej. Uczenie sieci, nawet przy zastosowaniu najlepszych algorytmów uczących, może nie prowadzić do minimum globalnego. Jest to proces trudny i długotrwały, dlatego odpowiedni dobór wag początkowych może ten proces znakomicie uprościć i przyspieszyć. Niestety, dla przypadku ogólnego nie wymyślono do tej pory algorytmu, który pozwalałby dobrać wagi w sposób optymalny. Z tego powodu najczęściej wagi są losowane, a całość rozważań sprowadza się jedynie do znalezienia odpowiedniego przedziału.

W literaturze wymienia się następujące niebezpieczeństwa wynikające ze złej inicjalizacji wag początkowych uczonej sieci:

- hiperpłaszczyzny utworzone przez neurony warstwy ukrytej leżą poza obszarem, w którym znajdują się wzorce uczące sieci, w związku z tym nie uczestniczą one w modyfikacji uczonej funkcji,
- niektóre z utworzonych hiperpłaszczyzn się pokrywają, przez co jest ich faktycznie mniej, niż wynikałoby to z liczby neuronów ukrytych.

## 2.8 Przeuczenie i niedouczenie sieci

Celem uczenia się sieci jest osiągnięcie nie tylko małego błędu na zbiorze uczącym, ale przede wszystkim małego błędu na zbiorze testowym. Możemy wtedy mówić o dobrych zdolnościach generalizacyjnych sieci. Możliwości uogólniania sieci są zależne głównie od postaci i jakości danych uczących oraz architektury sieci. W literaturze [77, 78, 66] można znaleźć pewne szacunki co do niezbędnej liczby danych uczących w zależności od złożoności sieci, dla osiągnięcia dobrych zdolności generalizujących, jednak w omawianym zastosowaniu są one bezużyteczne. Jeżeli chodzi o architekturę, to problemy z nią związane zostały już omówione. Wiadomo, że szuka się sieci o jak najmniejszym stopniu skomplikowania, jednak wybór takowej może nastąpić tylko na drodze eksperymentalnej, ponieważ nie znamy specyfiki rozważanego problemu i uczonej funkcji. Jeżeli stworzy się sieć o zbyt dużej liczbie neuronów w warstwie ukrytej i będziemy ją uczyć małą liczbą próbek, może wystąpić zjawisko zwane nadmiernym dopasowaniem czyli przeuczeniem sieci. W takim przypadku, nawet niewielkie odejście od punktów uczących może powodować duży błąd odtwarzanej funkcji. W większości zastosowań zmniejszając liczbę neuronów ukrytych przy tej samej liczbie punktów uczących, otrzymamy mniejszy błąd aproksymacji, ponieważ wszystkie wagi zostaną odpowiednio zmodyfikowane. W omawianym przypadku krótkoterminowego prognozowania pogody intuicja wskazuje, że dla zbyt małej liczby neuronów ukrytych dla rozwiązywanego problemu może się okazać, że system nie będzie chciał się uczyć. Wynika to z tego, że mała liczba wag jest niewystarczająca do opisanie wszystkich zmian zachodzących w przebiegu funkcji. Z drugiej jednak strony zbyt duża liczba neuronów ukrytych może wydłużać proces uczenia, ze względu na potrzebę aktualizacji dużej liczby wag a zatem dużej liczby wykonanych kroków, w których funkcja jest aktualizowana. Innym niebezpieczeństwem, wynikającym z dużej liczby neuronów ukrytych, może być fakt, że sieć dopasowując się do konkretnego punktu bardzo zniekształca przebieg w jego otoczeniu. Wymienione problemy będą przedmiotem eksperymentów numerycznych.

## 2.9 Cel badań

Poniżej zostały przedstawione główne problemy związane z sieciami neuronowymi, które zostały przeanalizowane w części eksperymentalnej:

- wskazanie odpowiedniego algorytmu uczenia sieci,
- znalezienie optymalnej liczby neuronów w warstwie ukrytej,
- znalezienie optymalnych wag początkowych,
- zbadanie czułości wyników uczenia na wartości wag początkowych i liczby neuronów w warstwie ukrytej.

## 2.10 Technika eksperymentu

W ramach badań przeprowadzono eksperymenty, mające na celu sprawdzenie możliwości krótkoterminowego prognozowania parametrów pogody, na podstawie lokalnych wskazań stacji meteorologicznej. Do badań wykorzystano godzinne dane meteorologiczne ze stacji meteorologicznej IMGW w Warszawie. Podjęto próby prognozowania:

- średniej temperatury zewnętrznej za kolejne 6 godzin,
- średniej prędkości wiatru za kolejne 6 godziny,
- średniej sumy nasłonecznienia za kolejne 6 godziny.

Są to parametry pogody, które bezpośrednio wpływają na bilans energetyczny budynku. Horyzont czasowy został wybrany na podstawie eksperymentów, które pozwoliły ustalić go na poziomie pomagającym w podjęciu decyzji systemowi sterowania urządzeniem grzewczym zlokalizowanym w ciężkiej przegrodzie budynku.


Prognozowanie odbywa się na podstawie następujących danych:

- $Q_s^{(-9,-6,-3,0)}$  - suma nasłonecznienia godzinowego 9, 6, 3 godziny wcześniej oraz w momencie prognozowania,
- $T_{amb}^{(-9,-6,-3,0)}$  - temperatura 9, 6, 3 godziny wcześniej oraz w momencie prognozowania,
- $v_{wind}^{(-9,-6,-3,0)}$  - prędkość wiatru 9, 6, 3 godziny wcześniej oraz w momencie prognozowania.


Zaprojektowana sieć neuronowa posiada typową trzywarstwową budowę pokazaną na rysunku 2.3. Sieć składa się z warstwy wejściowej, warstwy ukrytej i warstwy wyjściowej. W ramach pracy przetestowano bardzo wiele konfiguracji różnej liczby neuronów w warstwie ukrytej. Najlepsze efekty uzyskano dla 10 neuronów ukrytych dla każdego z prognozowanych parametrów. Do uczenia sieci zastosowano algorytm gradientów sprzężonych z regularyzacją.

## 2.11 Wyniki prognozowania


Poniżej przedstawiono przykładowe wyniki prognozowania parametrów pogody na 6 godzin do przodu. W ramach eksperymentów udało się osiągnąć zadowalające wyniki dla prognozowania średniej temperatury oraz średniej prędkości wiatru. Nie udało się niestety prognozowanie przyszłej sumy promieniowania słonecznego. Wynika to ze zbyt dużej zmienności tego parametru oraz braku wystarczających danych pogodowych. Uczenie przeprowadzono na danych klimatycznych pochodzących ze stacji meteorologicznej IMGW w Warszawie z lat 76-85, natomiast wyniki testowano na Typowym Roku Meteorologicznym (TRM). Sprawdzano też inne konfiguracje doboru zbioru uczącego i testowego ale wyniki były zawsze praktycznie identyczne. Wyniki porównano do założenia, że przyjmujemy, że parametr pogody będzie w analizowanym horyzoncie czasowym taki sam jak w chwili prognozowania. Jest to często używane uproszczenie, gdy nie ma możliwości prognozowania parametrów pogody. Uczenie przeprowadzono dla 10 neuronów ukrytych.



Rysunek 2.4: Wyniki prognozowania średniej temperatury za kolejne 6 godzin




Rysunek 2.5: Błąd prognozowania średniej temperatury za kolejne 6 godzin



Rysunek 2.6: Wyniki prognozowania średniej prędkości wiatru za kolejne 6 godzin





Rysunek 2.7: Błąd prognozowania średniej prędkości wiatru za kolejne 6 godzin w kolejnych miesiącach roku

# Rozdział 3

## Uczenie ze wzmocnieniem a inteligentny termostat

### 3.1 Podstawy teoretyczne algorytmów uczenia się ze wzmocnieniem

W tej części rozdziału zostaną opisane pokrótce podstawy teoretyczne algorytmów uczenia się ze wzmocnieniem. Jako szczególnie istotne, przedstawiona zostanie definicja funkcji celu działania ucznia oraz środowiska, w którym on funkcjonuje, jak również strategii, której się uczy. Ponadto zostanie przedstawiony schematyczny opis używanego dalej algorytmu.

#### 3.1.1 Środowisko

Modelem matematycznym środowiska dla uczenia ze wzmocnieniem jest *proces decyzyjny Markowa*. Jest on definiowany jako czwórka  $\langle X, A, \varrho, \delta \rangle$ , gdzie:

- $X$  — skończony zbiór stanów,
- $A$  — skończony zbiór akcji,
- $\varrho$  — funkcja wzmocnienia,
- $\delta$  — funkcja przejść stanów,

przy czym dla każdej pary  $\langle x, a \rangle \in X \times A$  wartość funkcji wzmocnienia  $\varrho(x, a)$  jest zmienną losową o wartościach rzeczywistych, oznaczającą nagrodę otrzymaną po wykonaniu akcji  $a$  w stanie  $x$ , natomiast wartość funkcji przejść  $\delta(x, a)$  jest zmienną losową o wartościach ze zbioru  $X$ , oznaczającą następny stan po wykonaniu akcji  $a$  w stanie  $x$ . Innymi słowy w każdym kroku czasu  $t$  nagroda  $r_t$  jest realizacją zmiennej

losowej  $\rho(x, a)$  a stan  $x_{t+1}$  jest realizacją zmiennej losowej  $\delta(x, a)$ . Z powyższych rozważań wynika, że wartości funkcji wzmocnienia  $\rho$  i funkcji przejść stanów  $\delta$  zależą tylko od aktualnego stanu i wykonywanej w tym stanie akcji. Jest to bardzo istotne, ponieważ zakłada się w ten sposób, że w każdym kroku czasu stan i przyznawana nagroda nie zależą od historii. O środowisku, które spełnia te założenia, mówi się, że posiada **własność Markowa**. Wszystkie dalej wykorzystywane algorytmy będą stosowane przy założeniu, że środowisko nauki posiada wymienione wyżej cechy. W przypadku, gdy znajomość aktualnego stanu nie wystarcza do wybrania akcji, mówi się o **stanie ukrytym** lub nie w pełni obserwowalnym.

Podsumowując powyższe rozważania, można wskazać następujące cechy środowiska uczenia się ze wzmocnieniem:

- **niepewność** — mechanizmy generowania stanów i nagród są stochastyczne. Wykonanie tej samej akcji w tym samym stanie może skutkować otrzymaniem przez ucznia różnych nagród i przejściem do różnych stanów,
- **nieznajomość** — rozkłady prawdopodobieństwa, zgodnie z którymi są generowane stany i nagrody mogą nie być znane uczniowi. Jeśli jednak taka wiedza jest dostępna, uczeń może ją wykorzystać,
- **niekontrolowalność przez ucznia** — uczeń nie może zmieniać wspomnianych rozkładów prawdopodobieństwa, choć bywa, że są one zmieniane, ale jest to właściwość środowiska, na którą uczeń nie ma wpływu,
- **obserwowalność** — wybór stanu lub nagrody nie zależy od historii.

Definicja środowiska, w którym operuje agent uczący się ze wzmocnieniem, pasuje zatem idealnie do zadania inteligentnego termostatu. Reakcja termiczna budynku jest uzależniona od czynników o charakterze losowym takich jak zyski energetyczne, obecność domowników, które są nieznane uczącemu się systemowi. Uczeń nie może też wpływać na środowisko bo nie ma wpływu na zachowania użytkowników. Najważniejszym problemem jest zatem takie dobranie mierzalnych parametrów budynku, opisujących aktualny stan środowiska, aby ta informacja była wystarczająca do podjęcia decyzji o wyłączeniu lub włączeniu ogrzewania i nie zależała od poprzednich stanów. W przypadku problemu inteligentnego sterowania, poruszanego w tej pracy, jest to spory problem, ponieważ bardzo często podjęcie decyzji o załączeniu ogrzewania będzie zależało od tego co działo się w chwilach wcześniejszych oraz od potencjalnych zysków w chwilach późniejszych. W niniejszej pracy podjęto próbę rozwiązania tego problemu.

### 3.1.2 Scenariusz

Scenariusz uczenia ze wzmocnieniem opiera się na sprzężeniu zwrotnym pomiędzy uczniem a otaczającym go środowiskiem. Te dynamiczne interakcje następują w dyskretnych chwilach czasu  $t$ , zwanych również krokami, w których uczeń ma możliwość zaobserwowania stanu  $x_t$  oraz wzmocnienia  $r_t$ , a następnie na tej podstawie wyboru akcji  $a_t$  zgodnej z aktualnie uczoną strategią. Wzmocnienie, zwane również nagrodą, przyjmuje postać rzeczywistoliczbowych wartości, których zadaniem jest ocena aktualnych poczynań ucznia. Proces uczenia polega na modyfikacji strategii wybierania akcji na podstawie doświadczenia, na które składa się aktualny stan  $x_t$ , wykonana akcja  $a_t$ , otrzymane wzmocnienie  $r_t$  po wykonaniu tej akcji, następny stan  $x_{t+1}$  będący konsekwencją wykonanej akcji. Opisany schemat wygląda następująco:

**dla wszystkich kroków czasu  $t$  wykonaj**

*obserwuj aktualny stan  $x_t$*

*wybierz akcję  $a_t$  do wykonania w stanie  $x_t$*

*wykonaj akcję  $a_t$*

*obserwuj wzmocnienie  $r_t$  i następny stan  $x_{t+1}$*

*ucz się na podstawie doświadczenia  $\langle x_t, a_t, r_t, x_{t+1} \rangle$*

**koniec dla**

Wszystkie opisywane w literaturze algorytmy [?] są w zasadzie mniej lub bardziej zaawansowanymi modyfikacjami dotyczącymi wykorzystania doświadczenia  $\langle x_t, a_t, r_t, x_{t+1} \rangle$  do autonomicznej poprawy działania systemu uczącego.

### 3.1.3 Cel uczenia

Zadaniem uczenia ze wzmocnieniem jest nauczenie się strategii takiego wybierania akcji, by maksymalizować przyjęte kryterium jakości. Ponieważ ocena działań ucznia odbywa się tylko poprzez otrzymywane nagrody, to również kryterium jakości jest od tego uzależnione. W rozpatrywanych algorytmach uczeń będzie się starał maksymalizować nagrody długoterminowo. Oznacza to, że wykonywane przez niego działania w krótkiej perspektywie czasowej mogą nie przynosić dużego zysku, ale w końcu zaczynają owocować właściwą strategią działania. Uczeń musi zatem uwzględniać opóźnione skutki wybranych przez siebie akcji, wiele kroków po ich faktycznym wykonaniu. Takie podejście nazywa się uczeniem z opóźnionym wzmocnieniem lub uczeniem się na podstawie opóźnionych nagród. W opisywanym przypadku najczęściej przyjmuje się jako kryterium jakości zdyskontowaną sumę otrzymywanych

nagród. Uczeń rozpoczynając działalność w chwili  $t = 0$ , ma obowiązek maksymalizować następujące wyrażenie:

$$E \left[ \sum_{t=0}^{\infty} \gamma^t r_t \right]$$

gdzie  $\gamma \in [0, 1]$  to współczynnik dyskontowania, którego zadaniem jest regulacja stopnia ważności nagród natychmiastowych i tych otrzymywanych w dłuższej perspektywie czasowej. Jeśli  $\gamma = 0$ , to uczeń maksymalizuje tylko nagrody aktualne, ponieważ powyższa suma redukuje się do wyrazu  $r_0$  (oczywiście przy założeniu, że  $0^0 = 1$ ). W przypadku, gdy  $\gamma = 1$  wszystkie nagrody stają się tak samo ważne, bo kryterium jakości staje się sumą wszystkich otrzymanych przez ucznia wzmocnień od początku jego działalności. Wartości pośrednie tego parametru umożliwiają ustalenie stopnia „dalekowzroczności” ucznia.

W przypadku zastosowania uczenia się ze wzmocnieniem do sterowania systemem grzewczym, sygnał wzmocnienia składa się ze składnika odpowiadającego za koszt energii wykorzystanej do ogrzewania oraz odpowiednio znormalizowanej różnicy między aktualną temperaturą wewnętrzną a wartością zadaną. Można powiedzieć, że wzmocnienie bilansuje dwa przeciwstawne sobie składniki: pierwszy odpowiedzialny za koszty eksploatacyjne a drugi odpowiedzialny za komfort użytkowników. Mamy zatem do czynienia z kosztem wykonania danej akcji w konkretnym stanie. Celem działania systemu uczącego się będzie tym przypadku minimalizacja przyjętego kryterium jakości.

### 3.1.4 Strategia i funkcja wartości

Strategia, w sensie procesu decyzyjnego Markowa  $\langle X, A, \rho, \delta \rangle$ , jest to dowolna funkcja  $\pi : X \mapsto A$ . Jednak przy takiej definicji mówimy o strategii stacjonarnej i deterministycznej, natomiast w przypadku uczenia ze wzmocnieniem mamy do czynienia ze strategią zmienną w czasie, która podlega modyfikacjom w trakcie uczenia, czyli jest niestacjonarna oraz mówimy o strategii niedeterministycznej, ponieważ wybór akcji jest stochastyczny (o czym w dalszej części pracy). W obecnych rozważaniach wykorzystana jest mimo to uproszczona definicja strategii stacjonarnej i deterministycznej, gdyż wystarcza ona do wprowadzenia dwóch kolejnych pojęć: funkcji wartości oraz funkcji wartości pary stan-akcja. Jeżeli system uczący się wybiera akcje zgodnie z uczoną strategią  $a_t = \pi(x_t)$ , to do oceny tej strategii służy funkcja wartości, która dla procesu decyzyjnego Markowa  $\langle X, A, \rho, \delta \rangle$  ze względu na strategię  $\pi$  jest określona następująco:

$$V^\pi(x) = E_\pi \left[ \sum_{t=0}^{\infty} \gamma^t r_t | x_0 = x \right]$$

gdzie symbol  $E_\pi$  oznacza wartość oczekiwaną przy założeniu posługiwania się strategią  $\pi$ . Zatem funkcja wartości przyporządkowuje każdemu stanowi wartość oczekiwaną zdyskontowanej sumy przyszłych nagród, jakie otrzymałby uczeń, gdyby zaczął naukę od tego stanu i posługiwał się strategią  $\pi$ .

Często bardziej wygodnym sposobem oceny aktualnej strategii jest funkcja wartości pary stan-akcja. Dla procesu decyzyjnego Markowa  $\langle X, A, \rho, \delta \rangle$  funkcja wartości akcji ze względu na strategię  $\pi$  jest dla każdej pary  $\langle x, a \rangle \in X \times A$  zdefiniowana następująco:

$$Q^\pi(x, a) = E_\pi \left[ \rho(x, a) + \sum_{t=1}^{\infty} \gamma^t r_t | x_0 = x, a_0 = a \right]$$

Zatem funkcja wartości akcji ze względu na strategię  $\pi$  przyporządkowuje każdej parze stan-akcja  $\langle x, a \rangle$  oczekiwaną wartość zdyskontowanej sumy przyszłych nagród, jakie byłyby otrzymane przez system rozpoczynający działalność w stanie  $x$  od wykonania akcji  $a$  i posługujący się następnie strategią  $\pi$ . Warto przy tym zauważyć, że zachodzi następująca zależność pomiędzy opisywanymi funkcjami:

$$V^\pi(x) = Q^\pi(x, \pi(x))$$

Oznacza to, że funkcja wartości akcji umożliwia wyznaczenie funkcji wartości, a więc zawiera w sobie nie mniej informacji niż ta ostatnia.

Przytoczone funkcje służą do wartościowania uczonej strategii. Należy zatem jeszcze powiedzieć, kiedy jedna strategia jest lepsza od drugiej. Jeżeli założymy, że istnieją dwie: strategia  $\pi'$  i  $\pi$  to strategia  $\pi'$  jest lepsza od  $\pi$ , co zapisuje się  $\pi' \succ \pi$ , jeśli dla każdego stanu  $x \in X$ ,  $V_{\pi'}(x) \geq V_\pi(x)$  i istnieje taki stan  $x \in X$ , dla którego  $V_{\pi'}(x) > V_\pi(x)$ . Innymi słowy lepsza strategia ma wartości nie mniejsze a przynajmniej dla jednego stanu wartość większą od strategii gorszej. Strategia, która maksymalizuje przyjęte kryterium jakości, jest nazywana **strategią optymalną** i może to być każda strategia, dla której nie istnieje strategia od niej lepsza. Takich strategii może być wiele, ponieważ więcej niż jedna może mieć taką samą funkcję wartości.

Przedstawione wyżej definicje są w pełni ściśle dla modelu decyzyjnego Markowa, który jak już zostało powiedziane, jest modelem matematycznym środowiska uczenia ze wzmocnieniem. Jednak jego właściwości (funkcja przejść i nagród) zazwyczaj nie są znane uczniowi. Dlatego niekoniecznie wymaga się od ucznia znalezienia strategii ściśle optymalnej, a do jego działania bardzo często wystarcza strategia częściowa, określona tylko dla stanów, które faktycznie występują podczas działania systemu uczącego się. Taka strategia może być optymalna tylko w przybliżeniu, to znaczy dla większości stanów ma wartości bliskie optymalnym. Chociaż formalnie cel uczenia się ze wzmocnieniem formułuje się jako znalezienie strategii optymalnej, to w praktyce na ogół wystarcza zachowanie optymalne lub prawie optymalne. Zatem

agent uczący się wykorzystywać efektywną pojemność cieplną budynku do obniżenia kosztu eksploatacyjnego systemu musi nauczyć się takiej strategii włączania i wyłączania urządzenia grzewczego, w zależności od aktualnego stanu termicznego budynku i jego otoczenia, aby ten cel osiągnąć.

### 3.1.5 Algorytmy uczenia się ze wzmocnieniem

Poniżej zostanie przedstawiony najbardziej popularny algorytm, który nie wymaga żadnej wiedzy wstępnej o otaczającym środowisku, natomiast jego działanie opiera się wyłącznie na dynamicznych interakcjach z tą przestrzenią. Algorytm w trakcie swojego działania uczy się funkcji wartości akcji, dzięki czemu ma możliwość wartościowania uczonej strategii i jednocześnie może ją poprawiać. Rozpatrywany algorytm wykorzystuje do wartościowania uczonej strategii metodę różnic czasowych TD (*ang.* **Temporal Differences**). Polega ona na predykcji wartości funkcji na podstawie dwóch kolejnych prognoz z następujących po sobie chwil czasowych. Zakłada się, że przewidywana wartość funkcji w chwili późniejszej jest dokładniejsza ze względu na zwiększającą się wiedzę ucznia wraz z upływem czasu. Korekta wartości rozpatrywanej funkcji jest dokonywana na podstawie błędu, definiowanego jako różnica wspomnianych prognoz z dwóch następujących po sobie kroków, wcześniejszej mniej dokładnej i późniejszej bardziej wiarygodnej. W przypadku algorytmów uczących się ze wzmocnieniem, wartością szacowaną w kroku  $t$  jest zdyskontowana suma przyszłych nagród, którą nazywa się dochodem TD. Jest ona zdefiniowana następująco:

$$z_t = \sum_{k=0}^{\infty} \gamma^k r_{t+k}$$

Ponieważ prawa rządzące środowiskiem mają charakter stochastyczny, dlatego też dochód TD jest niedeterministyczny i w związku z tym możemy oszacować jedynie wartość oczekiwaną rozważanego dochodu, czyli w tym wypadku funkcję wartości. Największe różnice w algorytmach uczących się ze wzmocnieniem, wynikają właśnie z różnych sposobów aktualizacji funkcji wartości lub funkcji wartości akcji [90].

#### Algorytm Q-learning

Algorytm wykorzystany w niniejszej pracy jest algorytmem niezależnym od strategii i nie musi posługiwać się strategią, której się uczy. Jak sama nazwa sugeruje, algorytm będzie się uczył funkcji wartości akcji. Występuje tu tylko jedna operacja aktualizacji. Uczona funkcja zawiera informację zarówno o wartości stanu jak i o wartości akcji w niej wykonanej. Błąd TD jest wyrażony jako różnica sumy  $r_t + \gamma \max_a Q_t(x_{t+1}, a)$ , która jest nowym oszacowaniem wartości funkcji  $Q$  uwzględniającym natychmiastową nagrodę po wykonaniu akcji  $a_t$  w stanie  $x_t$  oraz maksymalną wartością funkcji  $Q$ , w następnym stanie. Właśnie ta maksymalizacja wartości

w kolejnym stanie powoduje, że algorytm nie musi się posługiwać strategią, której się uczy. Wybór akcji w danym stanie nie musi następować zgodnie z maksymalną wartością  $Q$ . Poniżej został przedstawiony dokładny zapis tego algorytmu.

**dla wszystkich kroków czasu  $t$  wykonaj**

*obserwuj aktualny stan  $x_t$*

*$a_t := \text{wybierz\_akcje}(x_t, Q_t)$*

*wykonaj akcję  $a_t$*

*obserwuj wzmocnienie  $r_t$  i następny stan  $x_{t+1}$*

*$\Delta := r_t + \gamma \max_a Q_t(x_{t+1}, a) - Q_t(x_t, a_t)$*

*$uaktualnij^\beta(Q(x_t, a_t), \Delta)$*

**koniec dla**

W tym miejscu trzeba podkreślić, że przedstawiony powyżej algorytm jest w wersji oryginalnej. W zastosowaniu do sterownia inteligentnym termostatem następuje zmiana w regule aktualizacji. W omawianym problemie chcemy minimalizować koszt zużytej energii i odchyłkę od zadanej temperatury, zatem wybór akcji powinien minimalizować funkcję wartości  $Q$ . Dlatego przy obliczaniu wartości  $\Delta$  operator max jest zamieniony na operator min.

Algorytm Q-learning ma dobrze rozwiniętą teorię i dzięki temu istnieją dowody zbieżności tego algorytmu pod pewnymi warunkami. Po pierwsze funkcja  $Q$  jest zbieżna do optymalnej wartości, jeśli aktualizacja wartości tej funkcji w każdym kroku czasu odbywa się zgodnie z wyrażeniem:

$$Q_{t+1}(x, a) = Q_t(x, a) + \beta \Delta$$

i jednocześnie nie ulegają zmianie wartości  $Q(x', a')$  dla  $x' \neq x$  i  $a' \neq a$ . Oznacza to, że każda wartość funkcji  $Q(x, a)$  dla każdego stanu  $x$  i każdej akcji  $a$  jest jednoznacznie reprezentowana przez używany aproksymator. Po drugie  $i$ -ta aktualizacja wartości funkcji  $Q$  dla stanu  $x$  i akcji  $a$  odbywa się z wykorzystaniem rozmiaru kroku  $\beta_i(x, a)$ , przy czym wspomniany ciąg spełnia następujące warunki:

$$\sum_{i=1}^{\infty} \frac{1}{\beta_i(x, a)} = \infty$$

$$\sum_{i=1}^{\infty} \frac{1}{\beta_i^2(x, a)} < \infty$$

Warunki te oznaczają, że wartość kroku aktualizacji powinna się zmieniać wraz z



upływem czasu nauki. W praktyce rzadko stosuje się zmienny współczynnik aktualizacji. Teoretycznie nie pozwala to na osiągnięcie zbieżności, ale najczęściej umożliwia osiągnięcie stabilnej strategii, która zapewnia optymalny wybór akcji, lub prawie optymalny. Ponieważ rozmiar współczynnika aktualizacji nigdy nie maleje do wartości bliskich 0, to uczeń może dostosować się do ewentualnych zmian w stochastycznych mechanizmach rządzących środowiskiem. Konieczne jest również zapewnienie, że jeśli algorytm będzie działał nieskończenie długo, to każda akcja w każdym stanie zostanie wykonana nieskończenie wiele razy. Jest to warunek niezbędny, aby móc dobrze oszacować wartość funkcji z każdej akcji dla wszystkich odwiedzonych stanów, a jego realizacja jest możliwa dzięki zapewnieniu odpowiedniej eksploracji przestrzeni, w której znajduje się uczeń.

### 3.1.6 Wybór akcji

Wybór akcji jest jednym z najistotniejszych problemów uczenia ze wzmocnieniem. Mechanizm, według którego ten wybór następuje, musi zapewniać możliwość balansowania między dwoma przeciwstawnymi celami: eksploracją i eksploatacją. Eksploracja jest niezbędnym warunkiem do tego, aby system uczący się mógł zapoznać się z otaczającym środowiskiem oraz skutkami wykonania poszczególnych akcji w konkretnych stanach. Z kolei eksploatacja jest to wykorzystywanie już zdobytej wiedzy, czyli stosowanie nauczonej strategii. Jeżeli mechanizm wyboru akcji będzie zapewniał tylko eksplorację, to wtedy uczeń zdobywa wiedzę, ale z niej nie korzysta. Wybór akcji następuje zupełnie losowo. Z drugiej strony postępowanie tylko wedle do tej pory nauczonej strategii może powodować, że uczeń nigdy nie dowie się o istnieniu strategii od niej lepszej. Dlatego właśnie zakłada się, że uczeń w trakcie swojej nauki wykonuje akcje nie tylko zgodne z dotychczasową strategią, ale również akcje eksperymentalne, które rozszerzają jego możliwości poznania.

Często stosowanym mechanizmem wyboru akcji dla uczenia ze wzmocnieniem są tak zwane *strategie probabilistyczne*. Zapewniają one możliwość regulacji preferencji ucznia co do wyboru akcji. Strategią taką jest dwuargumentowa funkcja, przyporządkowująca każdej parze stan - akcja prawdopodobieństwo, z jakim akcja  $a$  zostanie wybrana do wykonania w stanie  $x$ ,  $\pi : X \times A \mapsto [0, 1]$ . Jedną z najpopularniejszych strategii probabilistycznych jest *strategia Boltzmana*. W części eksperymentalnej niniejszej pracy będzie wykorzystywana tylko ta strategia. Taki wybór jest podyktowany dobrymi wynikami licznie opisywanymi w literaturze oraz tym, że badanie różnych strategii eksploracji wykracza poza zakres tej pracy. Dla omawianego przypadku wyraża ją wzór:

$$\pi(x, a_{ON}^*) = \frac{\exp(-Q(x, a_{ON}^*)/T)}{\sum_a \exp(-Q(x, a)/T)} \quad a \in X$$

gdzie  $a_{ON}$  oznacza akcję polegającą na włączeniu ogrzewania. Analogicznie defin-

jujemy prawdopodobieństwo z jakim ogrzewanie zostanie wyłączone  $a_{OFF}$ . Należy tutaj zauważyć, że ze względu na cel uczenia, jakim jest minimalizacja przyjętego kryterium jakości musimy zapewnić, by omawiana strategia preferowała te akcje, które będą miały najmniejszą wartość funkcji  $Q$ . Najprostszy sposób, który spełnia to wymaganie, to wstawienie znaku minus przed wartościami funkcji wartości  $Q$ .

Parametr  $T$  reguluje stopień losowości wyboru. Dla  $T$  bliskich 1 wybór akcji będzie całkowicie losowy, natomiast dla  $T$  w pobliżu zera akcje będą wybierane zgodnie z aktualną strategią.

Okazuje się, że temperatura rozkładu Boltzmana ma ogromny wpływ na wyniki uczenia się systemu agentowego. Niezbędne okazuje się „schładzanie” strategii, które polega na stopniowym redukowaniu temperatury w trakcie uczenia lub w naszym przypadku powolne jej zwiększanie. Wpływ tego zjawiska będzie przedmiotem badań eksperymentalnych.

### 3.1.7 Aproksymator funkcji wartości

Istotą działania każdego algorytmu z rodziny  $TD(\lambda)$  jest to, że w trakcie trwania nauki jest tworzona funkcja służąca ocenie wartości danego stanu lub akcji dla osiągnięcia danej umiejętności. Przebieg tej zależności jest zmieniany cały czas w trakcie trwania nauki. Z tego powodu jednym z głównych problemów uczenia ze wzmocnieniem jest sposób przechowywania omawianej funkcji. De facto, jest to problem aproksymacji, ponieważ zadaniem jest nauczenie się przebiegu funkcji na podstawie przykładów trenujących. Aby można było zastosować taki aproksymator, musi on mieć możliwość uczenia się w trybie inkrementacyjnym na podstawie nieograniczonej liczby przykładów. Oznacza to, że dane trenujące są mu dostarczane pojedynczo a nie wszystkie na raz, a po przetworzeniu każdego przykładu uczeń doskonali swoją hipotezę, która może być przedstawiona w dowolnym momencie jego działania. Ważne jest również to, by nakład obliczeniowy wymagany do odtworzenia i aktualizacji wartości funkcji nie był zbyt duży. Najprościej funkcję można zapisać w tablicy, której każda komórka określa wartość stanu definiowanego przez indeks danej komórki. Jest to metoda najprostsza i bardzo skuteczna, ale tylko dla stosunkowo niewielkiej liczby stanów. W przypadku, gdy ich liczba bardzo wzrasta lub w szczególności jest nieskończona ze względu na ciągły charakter funkcji stanów, może się okazać, że rozmiar tablicy rozrósł się do takich rozmiarów, że korzystanie z niej staje się nieefektywne. Dyskretyzacja ciągłej przestrzeni stanów może pogorszyć rezultaty uczenia, a w dodatku w nieznanym środowisku nie bardzo wiadomo, jak to zrobić. W takich sytuacjach należy się zastanowić nad zmianą sposobu aproksymacji. Dostępnym rozwiązaniem cieszącym się w ostatnim czasie dużą popularnością są sieci neuronowe. Mają one tę zaletę, że do przechowywania przebiegu funkcji wystarczy zbiór wag poszczególnych połączeń sieci, na podstawie których można odtworzyć dowolną

wartość rozpatrywanej funkcji w bardzo krótkim czasie. Niestety, to rozwiązanie ma również wady. Przede wszystkim wymaga dużo dłuższego czasu uczenia z punktu widzenia obciążenia procesora oraz liczby wykonanych prób. Poza tym nie zawsze połączenie uczenia ze wzmocnieniem oraz sieci neuronowych daje pozytywne wyniki. Autonomiczna poprawa działania systemu może w ogóle nie nastąpić. Również nie każdy algorytm uczenia będzie dobrze współpracował z takim aproksymatorem. Mimo to w literaturze można znaleźć przykłady udanej współpracy sieci neuronowych i algorytmu uczącego się ze wzmocnieniem do konkretnych bardzo trudnych zadań. W niniejszej pracy do szacowania wartości funkcji  $Q$  wykorzystano aproksymator tablicowy, natomiast sieci neuronowe zastosowano tylko do krótkoterminowego prognozowania parametrów pogody.

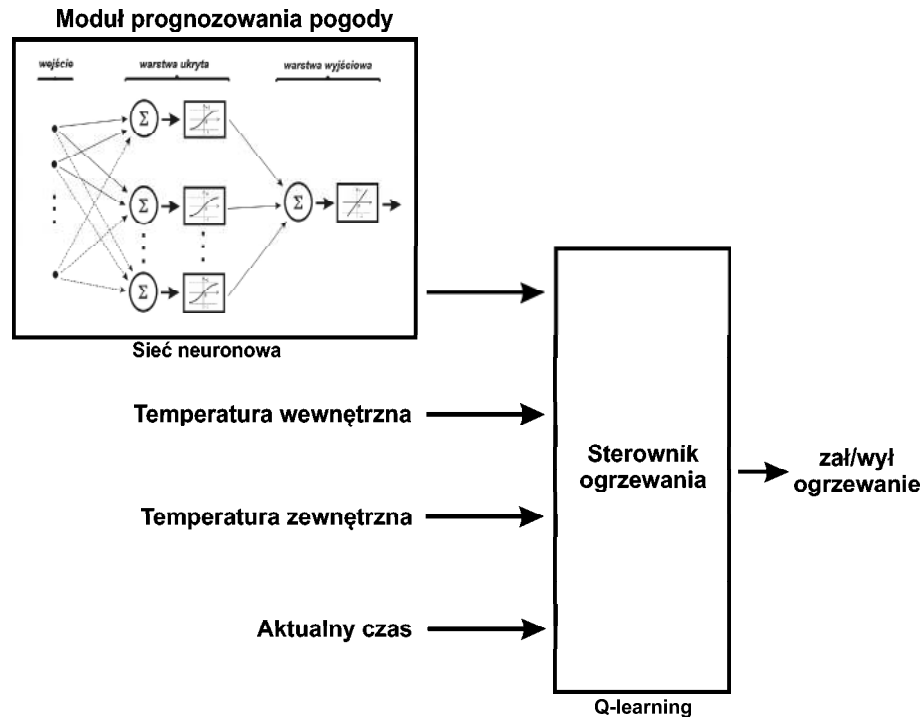
## 3.2 Architektura systemu

W pracy zaproponowano oryginalne połączenie dwóch rodzajów systemów uczenia. Pierwszym z elementów systemu jest sieć neuronowa, która przewiduje krótkoterminowe parametry pogody mające bezpośredni wpływ na zapotrzebowanie energetyczne budynku. Drugim elementem jest agent uczący się ze wzmocnieniem, który podejmuje decyzję o włączeniu lub wyłączeniu systemu grzewczego, na podstawie aktualnych warunków pogodowych, temperatury wewnętrznej oraz krótkoterminowej prognozy pogody podawanej przez sieć neuronową. Sieć jest wcześniej wyuczonym modelem pogody i podaje prognozę średniej temperatury zewnętrznej w ciągu kolejnych 6 godzin. System uczący się ze wzmocnieniem na bieżąco doskonali swoją strategię działania.

## 3.3 Konstruowanie systemu

### 3.3.1 Cel uczenia

Celem uczenia systemu jest minimalizacja przyjętego kryterium jakości, czyli w tym przypadku kosztu ogrzewania przy zachowaniu zadanego przedziału odchyłek od komfortowej temperatury. Celem uczenia jest minimalizacja nagród długoterminowo. Oznacza to, że wykonywane przez ucznia działania w krótkiej perspektywie czasowej mogą nie przynosić dużego zysku, ale w końcu zaczynają owocować właściwą strategią działania. Uczeń musi zatem uwzględniać opóźnione skutki wybranych przez siebie akcji, wiele kroków po ich faktycznym wykonaniu. Takie podejście nazywa się uczeniem z opóźnionym wzmocnieniem lub uczeniem się na podstawie opóźnionych nagród.



Rysunek 3.1: Architektura systemu inteligentnego sterowania systemem grzewczym

### 3.3.2 Stan

Definicja stanu jest ograniczona przez dane dostępne w symulatorze. Na podstawie eksperymentów dobrano następującą postać stanu:

1. temperatura wewnętrzna w danej chwili czasowej oraz 1 i 2 godziny wstecz;
2. temperatura zewnętrzna w danej chwili czasowej oraz informacje czy w ciągu trzech ostatnich godzin temperatura średnio rosła, czy spadała;
3. aktualna pora dnia, w kontekście podziału doby na taryfy;

W celu zmniejszenia liczby stanów dokonano następującej dyskretyzacji ich przestrzeni:

- dla temperatury wewnętrznej system dostaje tylko informacje o ile temperatura wewnętrzna odbiega od aktualnej temperatury komfortu w przedziale  $[-2; +2]$  ze skokiem  $0.5^{\circ}C$ ;
- dla temperatury zewnętrznej przyjęto przedział od  $[-15; 15]$  z krokiem  $1^{\circ}C$ . Skrajne przedziały zawierają wszystkie pozostałe wartości. Informacja o historycznym zachowaniu się temperatury zewnętrznej może przyjmować 3 wartości: spada, stała, rośnie;

- dla pory dnia podzielono dobę na 4 okresy: pierwszy w godzinach  $22^{00} - 6^{00}$ , drugi  $6^{00} - 13^{00}$ , trzeci  $13^{00} - 15^{00}$  i czwarty  $15^{00} - 22^{00}$ . Uczeń jest zatem informowany o tym, czy znajduje się aktualnie w czasie tańszej czy droższej taryfy;

W ten sposób przestrzeń stanów udało się ograniczyć do:

$$8 \cdot 8 \cdot 8 \cdot 30 \cdot 3 \cdot 4 = 184320 \quad (3.1)$$

co można uznać za niewielką liczbę. Wspomniany sposób dyskretyzacji przestrzeni stanów znacząco przyspieszył proces uczenia się.

### 3.3.3 Akcja

W analizowanym systemie sterowania założono tylko dwie możliwe do wykonania akcje:

1. włącz ogrzewanie
2. wyłącz ogrzewanie

Założenie było takie aby odzwierciedlić zachowanie i możliwości rzeczywistych systemów wykorzystujących ogrzewanie elektryczne. Wybór akcji następuje na podstawie strategii Boltzmana ze schłodzeniem od  $T = 1$  do  $T = 0.2$  po 150 okresach uczenia. Ma to na celu wymuszenie posługiwania się wyuczoną strategią i ograniczenie eksploracji środowiska. System ma doskonalić tego czego nauczył się do tej pory a nie szukać kolejnych możliwości.

### 3.3.4 Wzmocnienie

Wzmocnienie składa się z dwóch elementów. Pierwszy jest karą za faktyczne zużycie energii:

$$E_k = \frac{\sum_{t-24}^t E_{con}}{E_{max}} \quad (3.2)$$

gdzie  $\sum_{t-24}^t E_{con}$  to koszt energii za ostatnie 24 godziny, natomiast  $E_{max}$  to maksymalny koszt energii w tym okresie. Drugi składnik wzmocnienia jest karą za odchyłkę od zadanego komfortu termicznego. Zdefiniowany został następująco:

$$T_k = \frac{|T_{akt} - T_{zad}|}{zakres\_kom} \quad (3.3)$$

czyli jest to odchyłka temperatury wewnętrznej od zadanej. Wartość ta leży w zakresie  $[0, 1]$ , czyli jeśli różnica temperatur przekracza wartość zakresu komfortu

$|T_{akt} - T_{zad}| > zakres\_kom$  to kara wyniesie  $T_k = 1$ . W dalszych badaniach przyjęto  $zakres\_kom = 4$  co oznacza, że dopuszczalne są odchyłki  $\pm 2^\circ C$  od zadanej temperatury komfortu.

Powyższe dwa składniki są sumowane z wagami:

$$r_t = -w_1 E_k - w_2 T_k \quad (3.4)$$

Wagi  $w_1$  i  $w_2$  umożliwiają regulację wartości poszczególnych członów odpowiedzialnych za komfort i zużycie energii. W zależności od wartości wag system będzie starał się trzymać w zadanym zakresie temperatur, lub będzie pozwalał na większe wahania temperatur przy mniejszym całkowitym koszcie energii.

## Rozdział 4


# Symulacje procesów wymiany ciepła w budynku

### 4.1 Model termiczny budynku

Modelowanie procesów wymiany ciepła w budynku wymaga uwzględnienia wszystkich mechanizmów jego pozyskiwania, tracenia oraz dróg przepływu pomiędzy elementami składowymi budynku. W podstawowej literaturze na ten temat [18] proponuje się zastosować tzw. model sieciowy, który polega na podziale budynku na małe elementy przestrzenne. Każdy z nich ma stałe właściwości fizyczne i jest reprezentowany przez węzeł, który znajduje się w geometrycznym środku tej objętości. Poszczególne węzły opisują przegrody, zamknięte objętości gazu lub cieczy, jak również elementy instalacji grzewczej i wentylacyjnej. Węzły tworzą ze sobą sieć wzajemnych połączeń, których rodzaj zależy od rozmieszczenia przestrzennego i cech nadanych przez użytkownika. Oddziaływanie między węzłami określa stan termiczny elementu, a zatem również ilość energii brakującą do zapewnienia zadanego stanu wewnętrznego. Ścieżki w sieci są określane na podstawie zasady zachowania energii, masy i pędu, z uwzględnieniem podstawowych procesów wymiany ciepła tj. promieniowania, przewodzenia i konwekcji.

W praktycznych obliczeniach określany jest stan każdego z węzłów w każdej chwili czasowej. Co więcej, jego stan może ulec zmianie ze względu na np. zyski wewnętrzne czy też zmiany warunków meteorologicznych. Do niedawna większość programów symulacyjnych opierało się na metodzie jednostkowej funkcji odpowiedzi. Ta metoda nadaje się do rozwiązywania liniowych równań różniczkowych ze stałymi w czasie współczynnikami. W praktycznych zadaniach nie pozwala to na obliczanie wszystkich zależności w jednej chwili czasowej. Z tych powodów zaczęto korzystać z metod numerycznych opartych o metodę różnic skończonych [74]. Tego typu metody pozwalają na rozwiązywanie nieliniowych układów równań ze zmiennymi w czasie współczynnikami. Zapewniają dobrą dokładność obliczeń przy jednoczesnym

uwzględnieniu wszystkich powiązań między węzłami, czyli reprezentującymi je procesami fizycznymi.



Rysunek 4.1: Model analizowanego pomieszczenia

W niniejszej pracy do numerycznego modelowania wymiany ciepła w budynku wykorzystano metodę różnic skończonych. W ramach pracy wykonano symulator odzwierciedlający dynamikę jednego pomieszczenia przedstawionego na rysunku 4.1. Dalej zostaną opisane dokładne zależności wykorzystane w obliczeniach.

## 4.2 Metoda różnic skończonych

Podstawą metody różnic skończonych jest aproksymacja równania przewodzenia ciepła Fouriera, która wraz z odpowiednimi warunkami brzegowymi, opisuje przepływ ciepła przez przegrody masywne:

$$\frac{\partial \theta(x, t)}{\partial x^2} = \frac{1}{\alpha} \frac{\partial \theta(x, t)}{\partial t} - \frac{q}{\lambda} \quad (4.1)$$

gdzie  $\alpha = \frac{\lambda}{\rho C}$ . Przy jego rozwiązaniu wykorzystuje się rozwinięcie w szereg Taylora kolejnych pochodnych i zastosowanie schematu różnicowego. Dla celów tej pracy wystarczające jest rozpatrywanie tego równania tylko w jednym wymiarze. Mostki termiczne w obudowie oraz rozkład temperatur na powierzchniach nie mają znaczenia na wyniki eksperymentów. W niektórych pracach dotyczących zastosowania ogrzewania podłogowego [2] w budynkach energooszczędnych rozpatruje się jednak trzy wymiary, w celu pokazania lokalnych przegrzewów przy oknach w budynkach pasywnych.




Pomieszczenie zostaje podzielone na węzły, z których każdy jest wewnętrzny. Strumienie ciepła między węzłami  $n$  i  $k$  są proporcjonalne do różnic temperatur węzłów  $T_n$  i  $T_k$  i przewodności między nimi  $U_{n-k}$ . Przewodność pomiędzy węzłami znajdującymi się w różnych ośrodkach są obliczane jako odwrotność sum oporów na poszczególnych drogach przepływu ciepła. Zapewnia to automatycznie spełnienie warunków ciągłości strumienia ciepła na granicy ośrodków.

Do rozwiązywania równań przewodzenia ciepła najczęściej stosuje się metodę Cranka-Nicolsona [19], ze względu na jej stabilność. Polega ona na dodaniu do siebie równań różnicowych w postaci jawnej i niejawnej z równymi wagami wynoszącymi 0.5.

Dla jednorodnego materiału, w którym zachodzi jednowymiarowe przewodzenia ciepła, dla węzła  $n$  ogólna postać równania bilansu energii przyjmuje postać:

$$\rho_n C_n dx_n \frac{dT_n}{dt} = U_{n,n-1} (T_{n-1} - T_n) + U_{n,n+1} (T_{n+1} - T_n) + q_n \quad (4.2)$$

gdzie  $q_n$  oznacza objętościowy strumień ciepła.



Rysunek 4.2: Węzeł w jednorodnym materiale

W schemacie jawnym równanie przyjmuje postać:

$$\begin{aligned} \frac{\rho_n C_n dx_n}{dt} T_{n,t+1} &= \\ &= U_{n,n-1} T_{n-1,t} + \left( \frac{\rho_n C_n dx_n}{dt} - U_{n,n-1} - U_{n,n+1} \right) T_{n,t} + U_{n,n+1} T_{n+1,t} + q_{n,t} \end{aligned} \quad (4.3)$$

W schemacie niejawnym równanie przyjmuje postać:

$$\begin{aligned} -U_{n,n-1} T_{n-1,t+1} + \left( \frac{\rho_n C_n dx_n}{dt} - U_{n,n-1} - U_{n,n+1} \right) T_{n,t+1} - U_{n,n+1} T_{n+1,t+1} &= \\ &= \frac{\rho_n C_n dx_n}{dt} T_{n,t} + q_{n,t+1} \end{aligned} \quad (4.4)$$

Po dodaniu stronami otrzymujemy:

$$\begin{aligned} & -U_{n,n-1} T_{n-1,t+1} + \left(2 \frac{\rho_n C_n dx_n}{dt} - U_{n,n-1} - U_{n,n+1}\right) T_{n,t+1} - U_{n,n+1} T_{n+1,t+1} = \\ & = U_{n,n-1} T_{n-1,t} + \left(2 \frac{\rho_n C_n dx_n}{dt} - U_{n,n-1} - U_{n,n+1}\right) T_{n,t} - U_{n,n+1} T_{n+1,t} + q_{n,t+1} + q_{n,t} \end{aligned} \quad (4.5)$$

I ogólny schemat równania:

$$\begin{aligned} a_{n,n-1} T_{n-1,t+1} + a_{n,n} T_{n,t+1} + a_{n,n+1} T_{n+1,t+1} = \\ = b_{n,n-1} T_{n-1,t} + b_{n,n} T_{n,t} + b_{n,n+1} T_{n+1,t} + c_n \end{aligned} \quad (4.6)$$

gdzie  $c_n$  to współczynnik dodatkowych wymuszeń  $c_n = q_{n,t+1} + q_{n,t}$ .

Dla każdego węzła wydzielonego w pomieszczeniu musimy zatem utworzyć stosowne równania uzależniające konkretny węzeł od węzłów bezpośrednio sąsiadujących. Utworzony układ równań należy uporządkować do postaci:

$$\begin{bmatrix} a_{11}T_1 + a_{12}T_2 + \dots + a_{1J}T_J = b_1 \\ a_{21}T_1 + a_{22}T_2 + \dots + a_{2J}T_J = b_2 \\ \vdots \\ \vdots \\ a_{I1}T_1 + a_{I2}T_2 + \dots + a_{IJ}T_J = b_I \end{bmatrix}$$

i zapisać w postaci macierzowej.

$$\begin{bmatrix} a_{11} & a_{12} & \dots & a_{1J} \\ a_{21} & a_{22} & \dots & a_{2J} \\ \vdots & \vdots & & \vdots \\ \vdots & \vdots & & \vdots \\ a_{I1} & a_{I2} & \dots & a_{IJ} \end{bmatrix} \times \begin{bmatrix} T_1 \\ T_2 \\ \vdots \\ T_J \end{bmatrix} = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_J \end{bmatrix}$$

$A \qquad T \qquad B$

Powstały układ równań, w którym znane wartości temperatur z poprzedniego kroku czasowego i zadane wymuszenia termiczne znajdują się po prawej stronie:

$$A \times T = B \quad (4.7)$$

rozwiązujemy poprzez przekształcenie go do postaci:

$$T = A^{-1} \times B \quad (4.8)$$

Rozwiązanie układu wymaga zatem odwrócenia macierzy współczynników, co jest najbardziej czasochłonną operacją w trakcie symulacji energetycznych.

### 4.2.1 Rodzaje węzłów


W symulowanym pomieszczeniu oprócz węzła znajdującego się w jednolitym materiale występują jeszcze węzły:

- przy powierzchni przegrody,
- w powietrzu wewnętrznym.

W celu utworzenia stosownego równania każdy z węzłów wymaga analizy jego bilansu energii.

Bilans dla węzła przy powierzchni graniczącego ze strefą powietrzną obejmuje w ogólności strumienie ciepła związane z następującymi procesami wymiany ciepła:

- $q_c(t)$  - konwekcja na powierzchni,
- $q_R(t)$  - promieniowanie długofalowe wymiennianie z otaczającymi powierzchniami,
- $q_K(t)$  - przewodzenie,
- $q_S(t)$  - promieniowanie krótkofalowe,
- $q_M(t)$  - suma pozostałych (promieniowanie od światła, wyposażenia itp).



Rysunek 4.3: Węzeł przy powierzchni.

Gęstość strumienia ciepła przyjmowanego w drodze konwekcji:

$$q_c(t) = h_{cs}[T_x(t) - T_S(t)] \quad (4.9)$$

gdzie:  $h_{cs}$  - niezależny od czasu (lub średni) współczynnik przyjmowania dla powierzchni  $S$  wyrażony w  $\frac{W}{m^2K}$ .  $T_x(t)$  - temperatura otaczającego powietrza ( $^{\circ}C$ ) -

równa  $T_A(t)$  dla powierzchni wewnętrznych lub  $T_{A_j}(t)$  dla powierzchni zewnętrznej  $j$ .

Strumień energii przekazywany poprzez promieniowanie długofalowe można wyrazić następująco:

$$q_r(t) = \sum_{j=1}^N h_{rj,S} [T_j(t) - T_S(t)] \quad (4.10)$$

gdzie:  $N$  - liczba powierzchni wymieniających ze sobą energię,  $h_{rj,S}$  - współczynnik promieniowania pomiędzy powierzchnią  $j$  i  $S$  wyrażony w  $\frac{W}{m^2C}$ ,  $T_j(t)$  - temperatura powierzchni  $j$ . Współczynnik promieniowania pomiędzy powierzchniami  $k$  i  $l$  wyraża się następującym wzorem:

$$\begin{aligned} h_{rk,l} = & \frac{\epsilon_l \epsilon_k \sigma (A_k T_k^4 f_{k \rightarrow l} - A_l T_l^4 f_{l \rightarrow k})}{A_l (T_k - T_l) [1 - (1 - \epsilon_l)(1 - \epsilon_k) f_{l \rightarrow k} f_{k \rightarrow l}]} \\ & + \sum_{i=3}^N \frac{\epsilon_l (1 - \epsilon_i) \epsilon_k \sigma A_k T_k^4 f_{k \rightarrow i} f_{i \rightarrow l}}{A_l (T_k - T_l) [1 - (1 - \epsilon_l)(1 - \epsilon_k)(1 - \epsilon_i) f_{k \rightarrow i} f_{i \rightarrow l} f_{l \rightarrow k}]} \\ & - \sum_{i=3}^N \frac{\epsilon_k (1 - \epsilon_i) \epsilon_l \sigma A_l T_l^4 f_{l \rightarrow i} f_{i \rightarrow k}}{A_l (T_k - T_l) [1 - (1 - \epsilon_l)(1 - \epsilon_k)(1 - \epsilon_i) f_{l \rightarrow i} f_{i \rightarrow k} f_{k \rightarrow l}]} \end{aligned}$$

gdzie:

$$f_{k \rightarrow l} = A_l / (\sum A - A_k) \quad (4.11)$$

to współczynnik widoczności przegrody  $l$  przez przegrodę  $k$ . Warto zauważyć, że wymiana radiacyjna stanowi bardzo istotną część przekazywanej energii przez ogrzewanie podłogowe. Brak modelowania tego procesu powoduje bardzo duże rozbieżności w stosunku do rzeczywistych temperatur uzyskiwanych przez podłogi grzejne.

Po przekształceniach i przy założeniu, że parametry fizyczne są stałe w czasie równanie gotowe do aplikacji przyjmuje postać:

$$\begin{aligned} & - U_{n,n-1} T_{n-1,t+1} + (2 \frac{\rho_n C_n dx_n}{dt} - U_{n,n-1} - U_{n,m}) T_{n,t+1} - U_{n,m} T_{m,t+1} = \\ & = U_{n,n-1} T_{n-1,t} + (2 \frac{\rho_n C_n dx_n}{dt} - U_{n,n-1} - U_{n,m}) T_{n,t} + U_{n,m} T_{m,t} + \sum q_{n,t+1} + \sum q_{n,t} \end{aligned} \quad (4.12)$$

Jeżeli temperatura  $T_m$  jest zadana równanie przyjmuje postać:

$$\begin{aligned} & - U_{n,n-1} T_{n-1,t+1} + (2 \frac{\rho_n C_n dx_n}{dt} - U_{n,n-1} - U_{n,m}) T_{n,t+1} = \\ & = U_{n,n-1} T_{n-1,t} + (2 \frac{\rho_n C_n dx_n}{dt} - U_{n,n-1} - U_{n,m}) T_{n,t} \\ & \quad - U_{n,m} T_{m,t} + U_{n,m} (T_{m,t} + T_{m,t+1}) + \sum q_{n,t+1} + \sum q_{n,t} \end{aligned} \quad (4.13)$$

i ogólnie:

$$\begin{aligned} a_{n,n-1} T_{n-1,t+1} + a_{n,n} T_{n,t+1} + a_{n,n+1} T_{n+1,t+1} &= \\ &= b_{n,n-1} T_{n-1,t} + b_{n,n} T_{n,t} + b_{n,n+1} T_{n+1,t} + c_n \\ \text{gdzie : } c_n &= U_{n,m} (T_{m,t} + T_{m,t+1}) + \sum q_{n,t+1} + \sum q_{n,t} \end{aligned} \quad (4.14)$$

Dla powietrza równanie bilansu przyjmuje postać:

$$\rho C V \frac{dT_m}{dt} = \sum_{k=1}^N (A_k U_{k,m} (T_k - T_m)) + \rho C V \nu (1 - \eta)(T_{zew} - T_m) + Q_{ins} + Q_s + Q_z \quad (4.15)$$

gdzie:  $dt$ - rozpatrywany krok czasowy,  $A_k$  - pole powierzchni  $k$  ( $m^2$ ),  $T_k$  - temperatura powierzchni  $k$  wymieniającej ciepła z powietrzem;  $k$  różne od  $m$ ,  $\rho$  - gęstość powietrza ( $\frac{kg}{m^3}$ ),  $C$  - ciepło właściwe powietrza ( $\frac{J}{kgC}$ ),  $V$  - objętość rozpatrywanej przestrzeni ( $m^3$ ),  $U_{k,m}$  - przewodność między węzłem pod powierzchnią  $k$  i powietrzem w pomieszczeniu  $m$ ,  $\nu$  - częstość wymian powietrza ( $\frac{1}{s}$ ),  $\eta$  - stopień odzysku ciepła wentylacyjnego,  $Q_{ins}$  - strumień ciepła od instalacji grzewczej w pomieszczeniu ( $W$ ),  $Q_z$  - strumień ciepła konwekcyjne od czasowych źródeł ciepła np. oświetlenia, sprzętu elektronicznego itp.,  $Q_s$  - strumień ciepła od promieniowania słonecznego dopływającego przez okno.

Natomiast dla schematu jawnego równanie bilansu jest postaci:

$$\begin{aligned} \rho C V T_{m,t+1} &= \\ & \left( \frac{\rho C V}{dt} + \sum_{k=1}^N (A_k U_{k,m}) - \rho C V \nu (1 - \eta) \right) T_{m,t} - \\ & - \sum_{k=1}^N (A_k U_{k,m}) T_{k,t} + \rho C V \nu (1 - \eta) T_{zew,t} + Q_{ins,t} + Q_{s,t} + Q_{z,t} \end{aligned} \quad (4.16)$$

A dla schematu niejawnego przyjmuje postać:

$$\begin{aligned} \rho C V T_{m,t+1} &= \\ & \left( \frac{\rho C V}{dt} + \sum_{k=1}^N (A_k U_{k,m}) - \rho C V \nu (1 - \eta) \right) T_{m,t+1} - \\ & - \sum_{k=1}^N (A_k U_{k,m}) T_{k,t+1} + \rho C V \nu (1 - \eta) T_{zew,t+1} + Q_{ins,t+1} + Q_{s,t+1} + Q_{z,t+1} \end{aligned} \quad (4.17)$$

W pomieszczeniu z rysunku 4.1 mamy 4 węzły na poszczególnych powierzchniach, które stykają się z węzłem reprezentującym węzeł wewnętrzny. Po przekształceniach dla omawianego pomieszczenia otrzymujemy:

$$\begin{aligned}
& \left( 2 \frac{\rho C V}{dt} + \sum_{k=1}^N (A_k U_{k,m}) + \rho C V \nu (1 - \eta) \right) T_{m,t+1} - \sum_{k=1}^N (A_k U_{k,m}) T_{k,t+1} = \\
& = \left( 2 \frac{\rho C V}{dt} - \sum_{k=1}^N (A_k U_{k,m}) - \rho C V \nu (1 - \eta) \right) T_{m,t} + \sum_{k=1}^N (A_k U_{k,m}) T_{k,t} + \\
& + \rho C V \nu (1 - \eta) (T_{zew,t+1} + T_{zew,t}) + Q_{ins,t+1} + Q_{ins,t} + Q_{s,t+1} + Q_{s,t} + Q_{z,t+1} + Q_{z,t}
\end{aligned} \tag{4.18}$$

Przewodności  $U_{n,k}$  mogą przyjmować następujące postaci:

1. Węzły  $n - 1, n, n + 1$  w materiale jednorodnym:

$$U_{n,n-1} = U_{n,n+1} = \lambda_n / dx_n \tag{4.19}$$

2. Węzeł  $n - 1$  w innym materiale:

$$U_{n,n-1} = \frac{1}{\frac{dx_{n-1}}{2 \lambda_{n-1}} + \frac{dx_n}{2 \lambda_n}} \tag{4.20}$$

$$U_{n,n+1} = \lambda_n / dx_n \tag{4.21}$$

3. Węzeł  $n - 1$  lub  $m$  powietrze. Opór przejmowania ciepła  $R_{s,n-1}$ .

$$U_{n,n-1} = \frac{1}{R_{s,n-1} + dx_n / (2 \lambda_n)} \tag{4.22}$$

lub

$$U_{n,m} = \frac{1}{R_{s,m} + dx_n / (2 \lambda_n)} \tag{4.23}$$

4. Na granicy dwu ośrodków - opór kontaktowy  $R_{con}$ :

$$U_{n,n-1} = \frac{1}{\frac{dx_{n-1}}{2 \lambda_{n-1}} + R_{con} + \frac{dx_n}{2 \lambda_n}} \tag{4.24}$$

$$U_{n,n+1} = \lambda_n / dx_n \tag{4.25}$$

### 4.3 Dyskretyzacja przestrzeni i czasu

Obliczenia związane z metodą różnic skończonych obarczone są dwoma rodzajami błędów: błędami zaokrąglenia i dyskretyzacji. Pierwszy z nich, przy dzisiejszej przynajmniej 32 bitowej precyzji obliczeń komputerów, można pominąć. Z kolei drugi może wprowadzić duże rozbieżności między wynikami obliczeń a rzeczywistymi zjawiskami zachodzącymi w budynku. Błędy dyskretyzacji wynikają przede wszystkim z zastąpienia pochodnej ilorazem różnicowym. Najprostszym rozwiązaniem zwiększającym precyzję obliczeń jest zatem zwiększenie liczby węzłów oraz skrócenie kroku czasowego obliczeń. To niestety prowadzi do znacznego wydłużenia czasu obliczeń, co stanowi spory problem przy analizie większych obiektów. Podejmuje się próby nierównomiernego rozmieszczania węzłów [44], w celu zagęszczania ich tylko w miejscach wymagających większej precyzji. W obliczeniach jednowymiarowych, które są wystarczające do niniejszych rozważań, nie ma jednak konieczności stosowania tak wyrafinowanych metod.

Rozmieszczenie węzłów w przegrodach wielowarstwowych najczęściej opiera się na właściwościach termicznych każdej z nich. W literaturze spotyka się metody mające na celu oszacowanie niezbędnej liczby węzłów i ich lokalizacji. Jedną z nich jest szacowanie tzw. liczby Biota ( $\beta$ ) i czasu opóźnienia warstwy ( $t_d$ ). Dla warstwy zewnętrznej i wewnętrznej liczbę Biota oblicza się następująco:

$$\beta = \frac{0.5hx}{\lambda} \quad (4.26)$$

gdzie  $h$  jest współczynnikiem konwekcji z powierzchni,  $x$  grubość warstwy, natomiast  $\lambda$  jest współczynnikiem przewodności. Jeśli  $\beta < 1$  wtedy warstwa nie wymaga podziału, natomiast jeśli jest inaczej trzeba wydzielić w niej więcej węzłów. Kolejny parametr  $t_d$  dla  $N$  - warstwowej przegrody obliczamy następująco:

$$t_d^{0.5} = \frac{1}{N} \left( \sum_{i=1}^N \frac{x_i(\rho C)^{0.5}}{\lambda_i^{0.5}} \right) \quad (4.27)$$

Dla każdej przegrody wykonuje się obliczenia do momentu, gdy spełniony zostanie warunek dla każdej z  $i$ -tej warstwy przegrody :

$$\sum_i \frac{x_i(\rho C)^{0.5}}{\lambda_i^{0.5}} \geq t_d^{0.5} \quad (4.28)$$

Optymalizację dyskretyzacji przestrzeni opartą o powyższe równania wykonuje się głównie przy symulacjach dla bardzo dużych budynków. W nieco mniejszych problemach wykonuje się często próby eksperymentalne mające na celu określić wystarczającą dyskretyzację przy zachowaniu żądanej dokładności obliczeń. Warto też

dodać, że za duża liczba węzłów powoduje jedynie wydłużenie czasu obliczeń i zawsze poprawia dokładność. Z obliczeń wykonanych w [?] wynika, że bardzo dobrą dokładność uzyskujemy dla jednorodnej warstwy już dla 3 węzłów rozmieszczonych równomiernie przy czym dwa z nich znajdują się na granicach tej objętości. Tak też uczyniono w niniejszej pracy, z zastrzeżeniem do warstwy znajdującej się w przegrodzie masywnej, w której zatopiono element grzejny. W płycie podłogowej wydzielono więcej węzłów co umożliwiło dokładną lokalizację przestrzenną elementu grzejnego w grubości tej warstwy.

## 4.4 Modelowanie promieniowania słonecznego

W modelowanym pomieszczeniu znajduje się okno skierowane na południe. Umożliwia ono bezpośrednie przenikanie promieniowania słonecznego do wnętrza pomieszczenia. Promieniowanie to następnie jest absorbowane na powierzchni ścian i podłóg, dostarczając energię do pomieszczenia. W celu oszacowania ilości energii dostarczonej do pomieszczenia definiuje się [32] pojęcie efektywnego współczynnika transmisyjno-absorbcyjnego  $(\tau \alpha)_{eff}$ , będącego stosunkiem energii pochłoniętej w pomieszczeniu do całkowitej energii promieniowania słonecznego docierającego do zewnętrznej powierzchni okna:

$$(\tau \alpha)_{eff} = \tau_c \alpha_{eff} \frac{\tau_c \alpha_p}{\alpha_p + (1 - \alpha_p) \frac{A_f}{A_p} \tau_d} \quad (4.29)$$

gdzie  $A_f$  jest powierzchnią okna,  $A_p$  jest powierzchnią ścian pomniejszoną o powierzchnię okna,  $\alpha_p$  to absorbcyjność powierzchni wnęki,  $\tau_d$  - transmisyjność oszkleńnięcia okna dla promieniowania dyfuzyjnego, liczona dla promieniowania bezpośredniego padającego pod kątem  $60^\circ$ ,  $\tau_c$  - transmisyjność szyby dla promieniowania docierającego do jej powierzchni.

Uwzględniając fakt, że w danych pogodowych mamy dostępne dwie składowe promieniowania słonecznego (dyfuzyjną i bezpośrednią) padającego na powierzchnię poziomą, to bilans energii wynikający z właściwości analizowanego okna będzie wyglądał następująco:

$$\dot{Q}_{okna} = A_f [G_b R_b (\tau \alpha)_{b\,eff} + G_d R_d (\tau \alpha)_{d\,eff} - U(T_w - T_a)] \quad (4.30)$$

gdzie:  $G_b$  - gęstość strumienia promieniowania bezpośredniego na płaszczyznę poziomą;  $G_d$  - gęstość strumienia promieniowania dyfuzyjnego na płaszczyznę poziomą;  $R_b$  - współczynnik korekcyjny dla promieniowania bezpośredniego;  $R_d$  - współczynnik korekcyjny dla promieniowania rozproszonego;  $T_w$  - temperatura we wnętrzu pomieszczenia;  $T_a$  - temperatura otoczenia;  $U$  - współczynnik przenikania ciepła dla okna.



W celu obliczenia współczynników  $R_b$  i  $R_d$  wykorzystano model promieniowania słonecznego zaproponowany przez Liu i Jordana [12, 13]. Model ten zakłada izotropowość promieniowania dyfuzyjnego i odbitego. Zgodnie z nim współczynniki korekcyjne  $R_b$  i  $R_d$  oblicza się następująco:

$$R_d = \frac{1 + \cos\beta}{2} \quad (4.31)$$

i współczynnik  $R_b$  dla powierzchni skierowanej na południe:

$$R_b = \frac{\cos\Theta_\beta}{\cos\Theta_z} = \frac{\cos(\phi - \beta) \cos\delta \cos\omega + \sin(\phi - \beta) \sin\delta}{\cos\phi \cos\delta \cos\omega + \sin\phi \sin\delta} \quad (4.32)$$

Deklinację słoneczną  $\delta$  obliczamy zgodnie z formułą Coopera:

$$\delta = 23,45 \sin\left(360 \cdot \frac{284 + n}{365}\right) \quad (4.33)$$

gdzie  $n$  jest kolejnym dniem roku. Kąt godzinowy  $\omega$  obliczamy następująco:

$$\omega = 15 \cdot (\tau - 12) [\text{stopnie}] \quad (4.34)$$

gdzie  $\tau$  jest godziną dnia, dla której chcemy określić  $\omega$ .

W każdym dyskretnym punkcie czasowym symulacji następuje wyznaczenie bilansu energetycznego okna i uwzględnienie go w bilansie węzła reprezentującego powietrze wewnętrzne. W obliczeniach symulacyjnych przyjęto dla wszystkich przegród wewnętrznych średni współczynnik pochłaniania na poziomie  $\alpha_p = 0.48$  [32].

# Rozdział 5

## Wyniki symulacji

### 5.1 Metodologia eksperymentów

W pracy przeanalizowano 3 najbardziej popularne konstrukcje budynków w Polsce. Pierwsza to konstrukcja ciężka składająca się z betonowej podłogi pokrytej drewnem zaizolowanej styropianem, ze ścian zbudowanych z cegły silikatowej ocieplonych styropianem oraz betonowego stropu ocieplonego styropianem. Ten typ budownictwa spotyka się szczególnie często w budynkach wielorodzinnych, użyteczności publicznej, jak również coraz częściej w budynkach jednorodzinnych. Kolejna konstrukcja to konstrukcja szczególnie popularna w budownictwie jednorodzinnym. Składa się z betonowej podłogi izolowanej styropianem i pokrytej drewnem, ścian wybudowanych z betonu komórkowego pokrytego tynkiem cementowo-wapiennym oraz zaizolowanych styropianem oraz dachu wykonanego z więźby drewnianej wypełnionej wełną mineralną i od spodu pokrytej płytą gipsowo-kartonową. Ostatnia konstrukcja to technologia szczególnie chętnie stosowana dla domów prefabrykowanych. Coraz większa popularność konstrukcja ta zawdzięcza szybkiemu montażowi oraz dokładności wykonania dzięki możliwości przygotowania wszystkich istotnych elementów w fabryce. Konstrukcja składa się z betonowej podłogi pokrytej drewnem i ocieplonej styropianem, ścian wykonanych ze szkieletu drewnianego wypełnionego wełną mineralną i wykończoną od środka płytą gipsowo - kartonową oraz sufitu wykonanego w tej samej technologii.

Grubości warstw zostały tak dobrane, aby współczynnik strat ciepła wynosił  $H = 13,6W/k$  czyli około  $540W$  na pomieszczenie o powierzchni  $12m^2$ . Zapewnienie temperatury  $+20^{\circ}C$  przy temperaturze zewnętrznej  $-20^{\circ}C$  wymaga zainstalowania ogrzewania o mocy  $45W/m^2$ . Ogrzewanie jest umieszczone w warstwie masywnej podłogi w pierwszym węźle od strony izolacji. Pomieszczenie jest wyposażone w okno zlokalizowane na ścianie pionowej o rozmiarze  $1,5m$  na  $1,5m$  skierowanej na południe o współczynniku przenikalności dla promieniowania słonecznego równego  $g = 0,6$ . Współczynnik przenikania ciepła dla całego okna  $U = 1,0W/m^2K$ . Po-

mieszkanie jest wyposażone w system wentylacji z odzyskiem ciepła o sprawności  $\eta = 0,7$  zapewniającym  $\nu = 0,51/h$  wymian na godzinę. Rozpatrywane jest zatem budownictwo energooszczędne. Parametrami takimi jak:

- proporcje okna do powierzchni podłogi,
- współczynniki przenikania ciepła dla przegród,
- sprawność i wydajność systemu wentylacji,

zbliżonymi do budownictwa pasywnego.

Przy obliczeniu parametrów fizycznych ścian i sufitów wykonanych w technologii szkieletowej przyjęto uśrednione właściwości fizyczne przy założeniu, że konstrukcja drewniana stanowi 10% powierzchni przegrody, czyli np. dla dachu krokwie grubości  $7cm$  w odstępach  $70cm$  czy dla ścian - kantówki grubości  $5cm$  w odstępach  $50cm$ . Uśrednienie nastąpiło ponieważ dla analizy problemu nie ma potrzeby stosowania trójwymiarowego modelu przepływu energii.

W tabeli 5.1 przedstawiono szczegółowe zestawienie parametrów fizycznych analizowanych konstrukcji.

Tabela 5.1: Zestawienie analizowanych konstrukcji

Konstrukcja	Przegroda	Warstwa	$\lambda$ [W/mK]	$\rho$ [kg/m <sup>3</sup> ]	$C$ [kJ/kgK]	grubość [cm]
Ciężka $C = 569.3kJ/m^3$ $C = 1708.3kJ/m^2$ $\rho = 1995kg/m^2$	podłoga	I: styropian	0.04	15	1460	30
		II: beton	1.3	2200	840	6.0
		III: drewno	0.22	800	2510	1.5
	ściana	I: styropian	0.04	15	1460	24.0
		II: siliikat	0.8	1600	840	24.0
		III: tynk cem-wap	0.82	1840	840	1.5
	sufit	I: styropian	0.04	15	1460	24.0
		II: beton	1.3	2200	840	20.0
		III: tynk cem-wap	0.82	1840	840	1.5
Średnio - ciężka $C = 209.0kJ/m^3$ $C = 627.1kJ/m^2$ $\rho = 704kg/m^2$	podłoga	I: styropian	0.04	15	1460	30
		II: beton	1.3	2200	840	6.0
		III: drewno	0.22	800	2510	1.5
	ściana	I: styropian	0.04	15	1460	22.0
		II: beton kom.	0.3	500	840	24.0
		III: tynk cem-wap	0.82	1840	840	1.5
	sufit	I: wełna + 10% drewna	0.054	122.5	926	18.0
		II: wełna + 10% drewna	0.054	122.5	926	18.0
		III: płyta G-K	0.23	1000	1000	1.2
Lekka $C = 89.2kJ/m^3$ $C = 267.6.3kJ/m^2$ $\rho = 277kg/m^2$	podłoga	I: styropian	0.04	15	1460	30
		II: beton	1.3	2200	840	4.0
		III: drewno	0.22	800	2510	1.5
	ściana	I: wełna mineralna	0.044	60	750	18.0
		II: wełna + 10% drewna	0.054	122.5	926	10.0
		III: płyta G-K	0.23	1000	1000	1.2
	sufit	I: wełna + 10% drewna	0.054	122.5	926	18.0
		II: wełna + 10% drewna	0.054	122.5	926	18.0
		III: płyta G-K	0.23	1000	1000	1.2

Do obliczeń kosztów ogrzewania przyjęto koszty energii z cennika firmy PGE Zakład Warszawa-Teren z początku roku 2010. Koszt energii:

- w taryfie dziennej wynosi 0.58z/kWh w okresie od 6<sup>00</sup> do 13<sup>00</sup> i od 15<sup>00</sup> do 22<sup>00</sup> - zwana potocznie taryfą I
- w taryfie nocnej wynosi 0.33z/kWh w okresie od 13<sup>00</sup> do 15<sup>00</sup> i od 22<sup>00</sup> do 6<sup>00</sup> - zwana potocznie taryfą II.

Ocena podatności każdej z konstrukcji na wykorzystanie tańszej taryfy i inteligentne sterowanie odbywa się poprzez obliczenie:

- rocznych kosztów ogrzewania na poszczególnych taryfach energii elektrycznej dla typowego roku meteorologicznego w okresie od 1 października do 30 kwietnia,
- średnich temperatur i odchylenia standardowego od zadanej temperatury w poszczególnych okresach czasu doby:
  - obniżenie nocne: od 22<sup>00</sup> do 6<sup>00</sup> z temperaturą zadaną 19°C,
  - w ciągu dnia: od 6<sup>00</sup> do 22<sup>00</sup> z temperaturą zadaną 20°C,

- histogramu przedstawiającego liczbę godzin w analizowanym okresie z przekroczeniem zadanych temperatur z podziałem na przedziały,
- przykładowych przebiegów temperatur w podłodze grzewczej wraz z przebiegami:
  - momentów załączania ogrzewania,
  - przebiegiem sumy promieniowania słonecznego,
  - temperatury zewnętrznej.

W większości przypadków przyjęto jako referencyjne przebiegi z 8 i 9 stycznia jako charakteryzujące się niskimi temperaturami zewnętrznymi i niskim nasłonecznieniem oraz przebiegi z dni od 8 do 11 października jako charakteryzujące się wysokimi temperaturami zewnętrznymi i na przemian niską oraz wysoką sumą promieniowania słonecznego.

Dodatkowo dla zobrazowania działania inteligentnego termostatu dodano specyficzne wykresy poprawy w stosunku do analizowanych strategii nadażno-programowalnych oraz przebiegi uczenia się termostatu.

W celu znalezienia obszaru, w którym metody sztucznej inteligencji mogą przyczynić się do obniżenia kosztów ogrzewania, przy zachowaniu akceptowalnego zakresu komfortu termicznego, przeanalizowano działanie prostych strategii nadażno-programowalnych, powszechnie stosowanych przez użytkowników ogrzewań elektrycznych. Strategie te opierają swoje działanie na wymuszeniu włączenia ogrzewania w określonych porach tańszej taryfy energii elektrycznej poprzez podniesienie o  $+2^{\circ}\text{C}$  temperatury zadanej w tym okresie. Przeanalizowano następujące kombinacje:

1. nadażna z obniżeniem nocnym,
2. nadażna bez obniżenia nocnego,
3. nadażna z wymuszeniem od  $5^{00}$  do  $6^{00}$  i od  $13^{00}$  do  $15^{00}$ , wraz z obniżeniem nocnym,
4. nadażna z wymuszeniem od  $4^{00}$  do  $6^{00}$  i od  $13^{00}$  do  $15^{00}$ , wraz z obniżeniem nocnym,
5. nadażna z wymuszeniem od  $3^{00}$  do  $6^{00}$  i od  $13^{00}$  do  $15^{00}$ , wraz z obniżeniem nocnym,
6. nadażna z wymuszeniem od  $3^{00}$  do  $6^{00}$ , od  $13^{00}$  do  $15^{00}$ , oraz  $22^{00}$  do  $23^{00}$ , wraz z obniżeniem nocnym.

Histereza termostatu, wyznaczająca tzw. „martwą strefę” w przełączaniu systemu grzewczego została ustalona na  $0,5^{\circ}C$ . Zatem algorytm działania termostatu wygląda następująco:

**jeśli**  $t_{wev} < t_{zad} - H/2$  **wykonaj**

*ogrzewanie = ON*

**w przeciwnym wypadku jeśli**  $t_{wev} > t_{zad} + H/2$  **wykonaj**

*ogrzewanie = OFF*

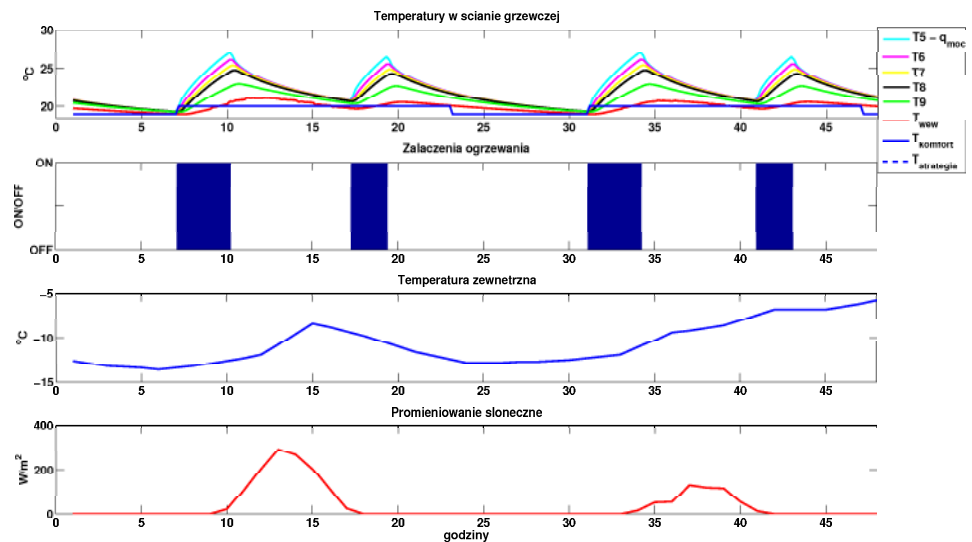
**koniec jeśli**

Obliczenia wykonano dla pomieszczenia zaopatrzonego w ogrzewanie o mocy  $100W/m^2$  z krokiem czasowym równym 10 minut.

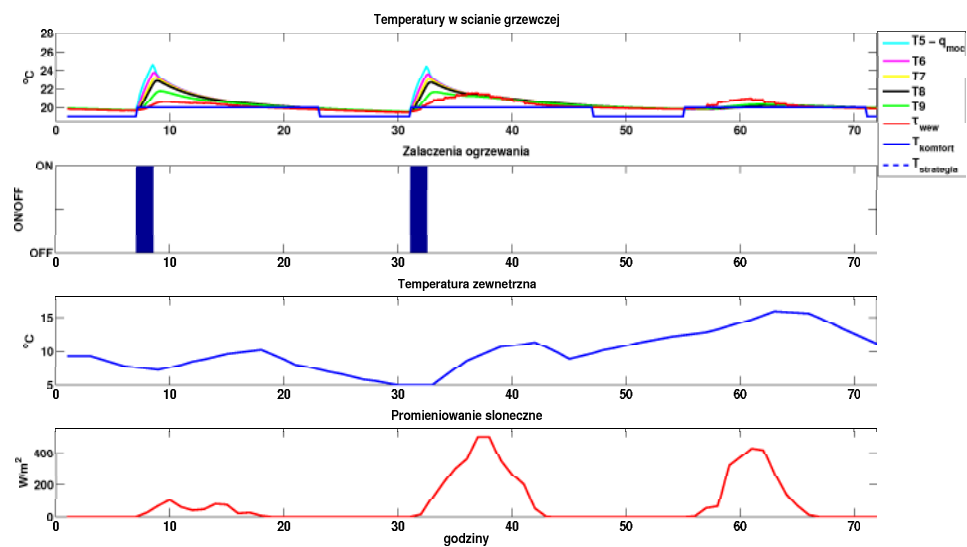
## 5.2 Konstrukcja ciężka

Tabela 5.2: Zestawienie kosztów ogrzewania dla konstrukcji ciężkiej

Strategia	Ekonomia						Komfort			
	Energia [kWh]			Koszt [zł]			Dzień		Noc	
	<i>I</i>	<i>II</i>	$\Sigma$	<i>I</i>	<i>II</i>	$\Sigma$	$T_{sr}$	$T_{std}$	$T_{sr}$	$T_{std}$
<b>1</b>	658,8	15,8	674,6	382,1	5,2	387,3	20,26	0,57	19,38	0,55
<b>2</b>	413,4	266,0	679,4	239,8	87,8	327,5	20,27	0,58	20,07	0,28
<b>3</b>	98,4	604,6	703,0	57,1	199,5	256,6	20,66	0,83	19,46	0,79
<b>4</b>	18,0	697,2	715,2	10,44	230,1	240,5	20,82	0,84	19,55	0,87
<b>5</b>	0,0	718,6	718,6	0,0	237,2	237,2	20,85	0,82	19,59	0,90
<b>6</b>	0,0	721,6	721,6	0,0	238,1	238,1	20,85	0,82	19,65	0,96



Rysunek 5.1: Zachowanie systemu grzewczego dla strategii 1 w dniach 8 i 9 stycznia TRM. Konstrukcja ciężka.




Rysunek 5.2: Zachowanie systemu grzewczego dla strategii 1 w dniach od 8 do 11 października TRM. Konstrukcja ciężka.

Jak widać, niewykorzystywanie wymuszenia w granicznych okresach tańszej taryfy energii elektrycznej skutkuje włączeniem ogrzewania prawie wyłącznie w okresie drogiej taryfy dziennej. Koszt ogrzewania wyniósł dla tego przypadku 387,3zł z czego 5,2zł na taryfie nocnej i 382,1zł na taryfie dziennej. Całkowite zużycie energii wyniosło 674,6zł, natomiast średnia temperatura dnia wyniosła  $20,22^{\circ}\text{C}$  a nocy  $19,38^{\circ}\text{C}$ . Zatem dla prostego sterowania nadążnego uzyskaliśmy najmniejsze zużycie energii oraz najbardziej zbliżone temperatury do komfortu przy jednoczesnym największym, rocznym koszcie ogrzewania.

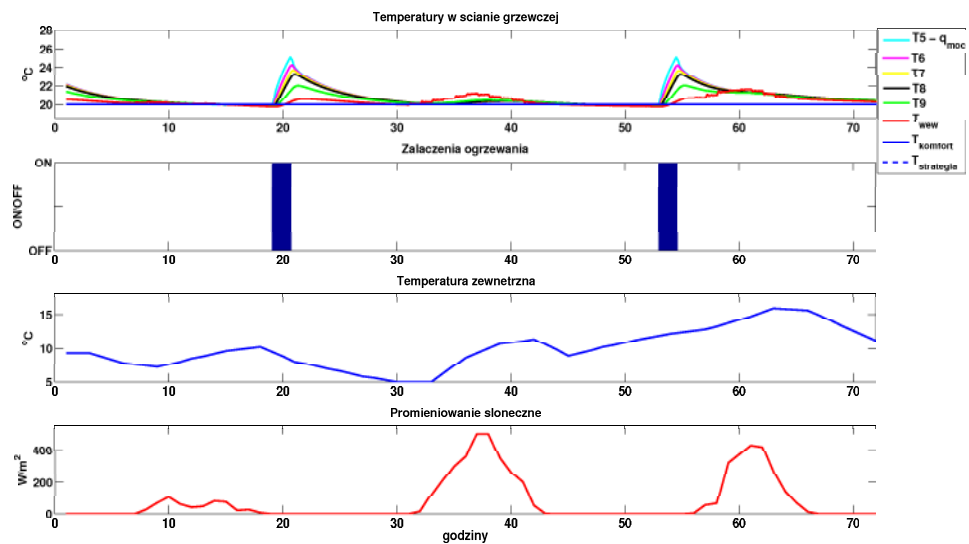
Warto również zwrócić uwagę na fakt, że po wyłączeniu ogrzewania ze względu na przekroczenie temperatury wewnętrznej, temperatura wewnętrzna wciąż rośnie przez kilka do kilkunastu godzin w zależności od warunków zewnętrznych. Jest to bardzo istotna kwestia podlegająca optymalizacji.

Na decyzje algorytmu o włączeniu lub wyłączeniu ogrzewania ma olbrzymi wpływ historia i poprzednie zachowanie systemu grzewczego, o czym najlepiej świadczy wykres zachowania systemu w dniach 8 - 11 października. Dla prostego systemu nadążnego, załączenie ogrzewania następuje dokładnie w godzinach droższej taryfy energii elektrycznej i magazynuje energię na kilka kolejnych dni. Jak widać, dla prostych strategii wymuszających działanie ogrzewania w końcówkach taryfy nocnej taki efekt zostaje wyeliminowany.

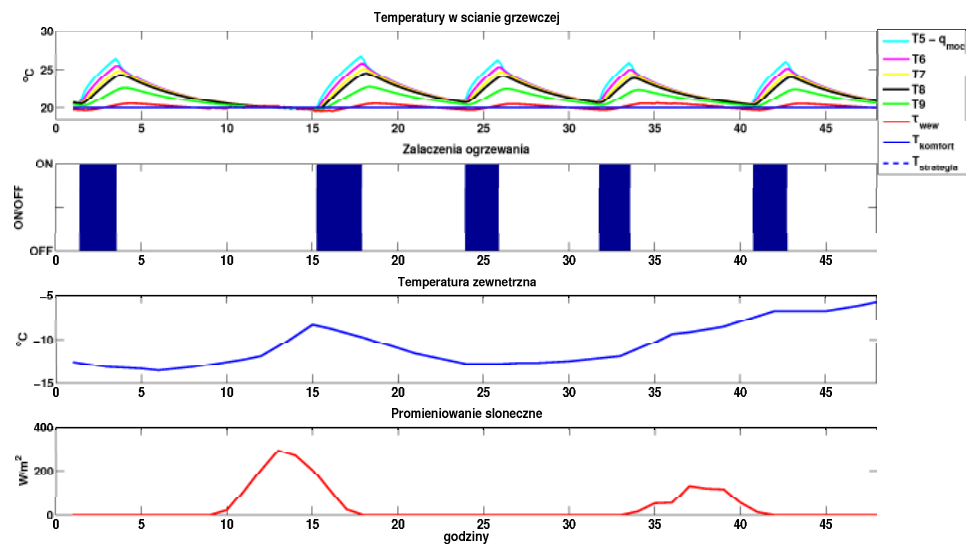




Rysunek 5.3: Odchylenia od temperatury zadanej dla strategii 1. Konstrukcja ciężka.




Rysunek 5.4: Zachowanie systemu grzewczego dla strategii 2 w dniach od 8 do 11 października TRM. Konstrukcja ciężka.

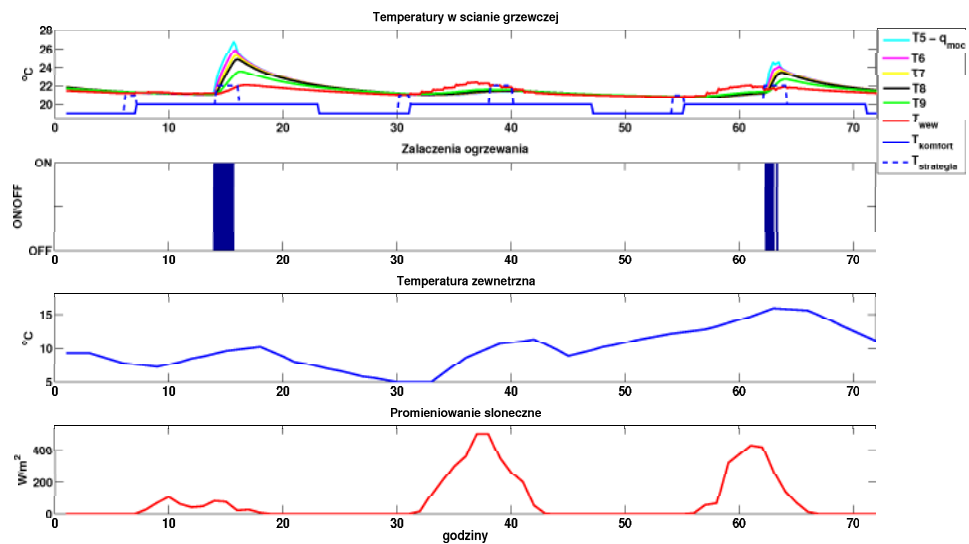


Rysunek 5.5: Zachowanie systemu grzewczego dla strategii 2 w dniach 8 i 9 stycznia TRM. Konstrukcja ciężka.

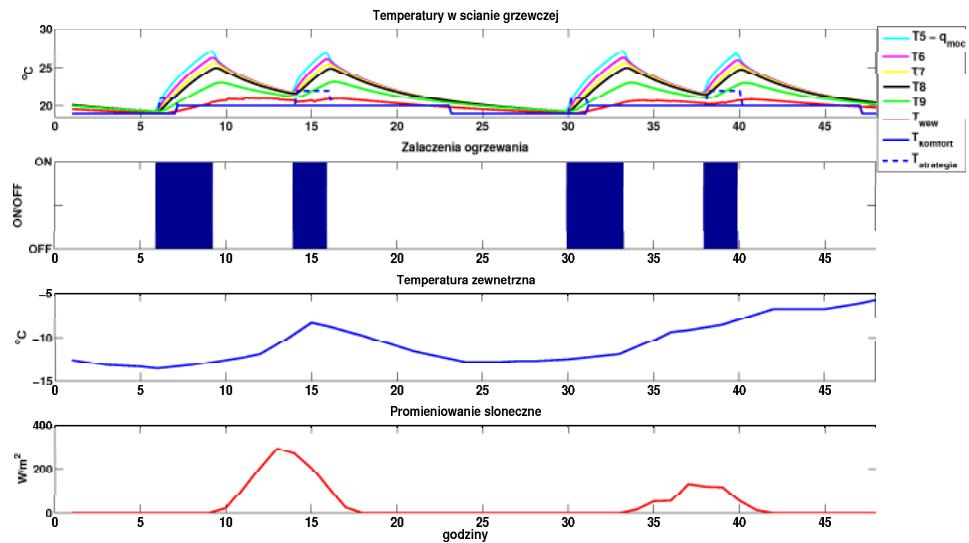
Kolejny ważny wniosek to ten, że w budynku energooszczędnym wybudowanym w ciężkiej konstrukcji nie ma możliwości uzyskania obniżenia temperatury w nocy poprzez proste wyłączenie ogrzewania. Wymaga to umyślnego wyprowadzenia energii na zewnątrz np. poprzez otwarcie okna lub rezygnację z odzysku ciepła w systemie wentylacji. To skutkuje znacznym zwiększeniem zużycia energii przez budynek. Już samo wyeliminowanie nocnego obniżenia temperatury powoduje zdecydowane obniżenie kosztów ogrzewania. Widać to wyraźnie na rysunkach obrazujących działanie strategii 2. Sumaryczne koszty ogrzewania są niższe o około 18% od prostej strategii nadążnej z obniżeniem nocnym, przy jednoczesnym zachowaniu akceptowalnego zakresu komfortu wyrażonego poprzez temperatury w poszczególnych okresach, również bardzo zbliżony do strategii pierwszej. Szczególnie efekt wykorzystania drugiej taryfy wzmacnia się dla tej strategii przy mroźnych nocach, które wymuszają działanie ogrzewania w godzinach nocnych.



Rysunek 5.6: Odchylenia od temperatury zadanej dla strategii 2. Konstrukcja ciężka.



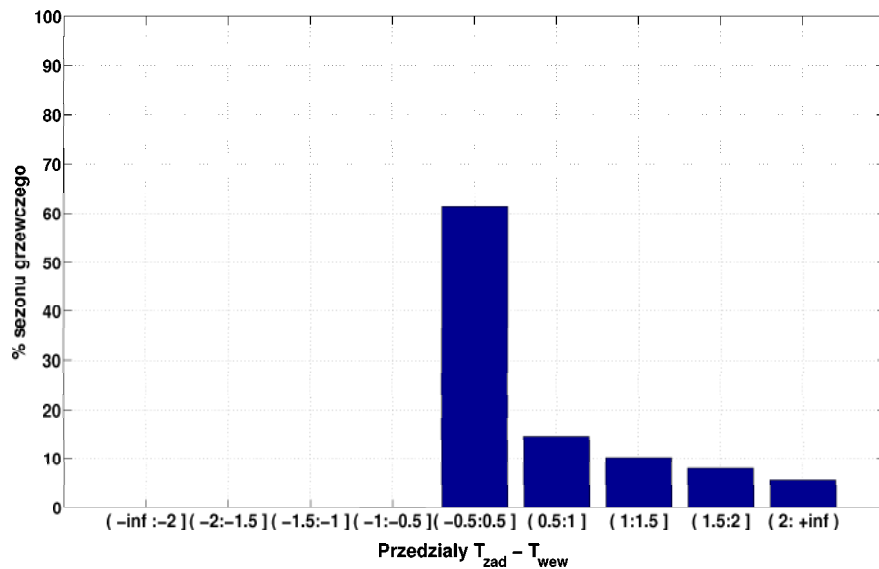
Rysunek 5.7: Zachowanie systemu grzewczego dla strategii 3 w dniach od 8 do 11 października TRM. Konstrukcja ciężka.



Rysunek 5.8: Zachowanie systemu grzewczego dla strategii 3 w dniach 8 i 9 stycznia TRM. Konstrukcja ciężka.

Z kolei dla strategii 3 wymuszenie równe  $+2^{\circ}\text{C}$ , w okresie dużego nasłonecznienia (rys. 5.7), powoduje niepotrzebne przekroczenie temperatur zadanych i włączenie ogrzewania w środku dnia, gdy temperatura wewnętrzna jest o ponad  $1^{\circ}\text{C}$  większa niż zadana. Te włączenia niepotrzebnie zwiększają zapotrzebowanie na energię i jednocześnie pogarszają komfort użytkownika budynku. Dla dużych mrozów (rys. 5.8) widać wyraźnie, że okres wymuszenia ogrzewania pod koniec nocy jest za krótki, aby system dał radę dostarczyć konieczną energię w niższej cenie. Nie zmienia to jednak faktu, że roczny koszt ogrzewania wyniósł 256,6 zł czyli o ponad 34% mniej niż dla strategii 1 przy jednoczesnym wzroście całkowitego zużycia energii o 4%.

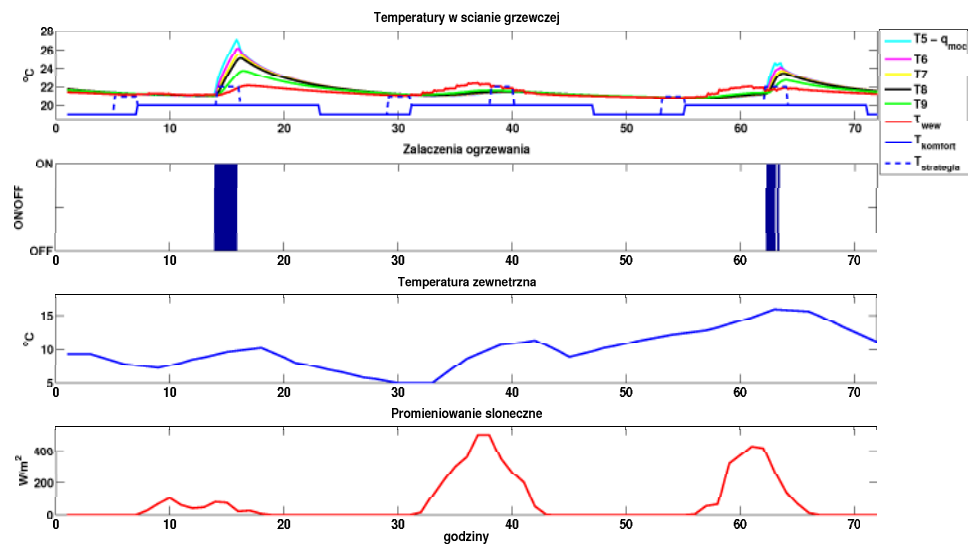
Wydłużenie okresu wymuszenia ogrzewania pod koniec nocnego okresu tańszej taryfy o jedną godzinę - strategia 4 - spowodowało lepsze jej wykorzystanie w okresach mroźnych (rys. 5.11), ale nie poprawiło to wyniku dla okresu ciepłego (rys. 5.11). Warto zauważyć, że liczba dni z temperaturą przekroczoną do  $2^{\circ}\text{C}$  (rys. 5.12) wynosi około 30% analizowanego okresu grzewczego. To uwidacznia się w sezonowym zużyciu energii na cele grzewcze, które jest wyższe o niespełna 5% w stosunku do strategii nadążnej ale jednocześnie koszt ogrzewania jest niższy o ok. 38%. Jest to zatem nawet lepszy wynik niż osiąga strategia 3.



Rysunek 5.9: Odchylenia od temperatury zadanej dla strategii 3. Konstrukcja ciężka.

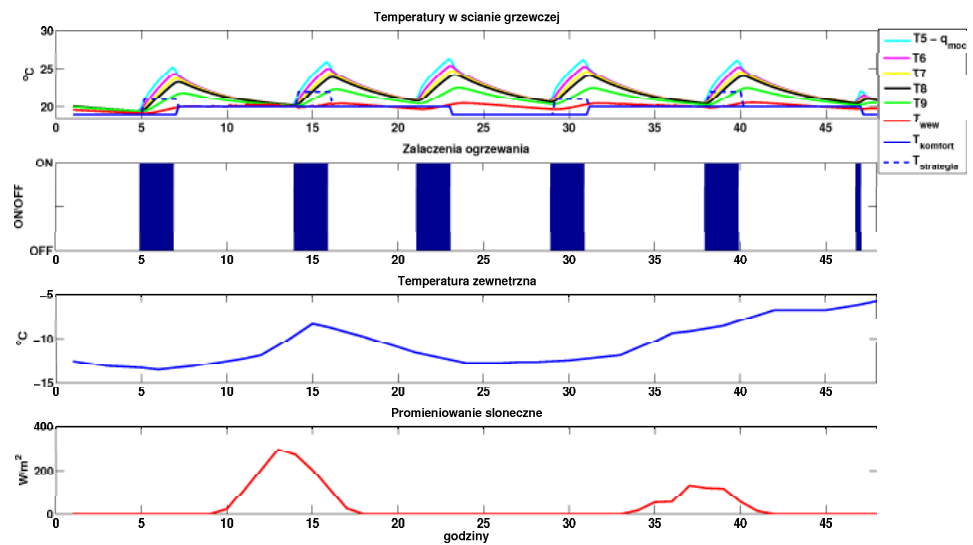
Dla strategii piątej roczny koszt ogrzewania wyniesie 237,6zł z czego na tańszą taryfę przypada 100% zapotrzebowania. Zachowanie systemu sterowania można zaobserwować na rysunkach 5.17, 5.14. Całkowite zużycie energii wzrosło tylko minimalnie do 718,6kWh. Niestety wzrasta również średnia temperatura sezonu grzewczego i wynosi dla godzin nocnych  $19,59^{\circ}C$  a dla dziennych  $20,85^{\circ}C$ , przy dosyć dużym odchyleniu standardowym równym odpowiednio  $0,90^{\circ}C$  i  $0,85^{\circ}C$ .

Dla strategii 6 wzrasta już tylko zużycie energii oraz średnia temperatura w okresie nocnego obniżenia. Wymuszenie ogrzewania na początku nocnego okresu tańszej taryfy (rys. 5.17, 5.14) nie wnosi już nic, jeśli chodzi o zmniejszenie kosztu ogrzewania.




Rysunek 5.10: Zachowanie systemu grzewczego dla strategii 4 w dniach od 8 do 11 października TRM. Konstrukcja ciężka.

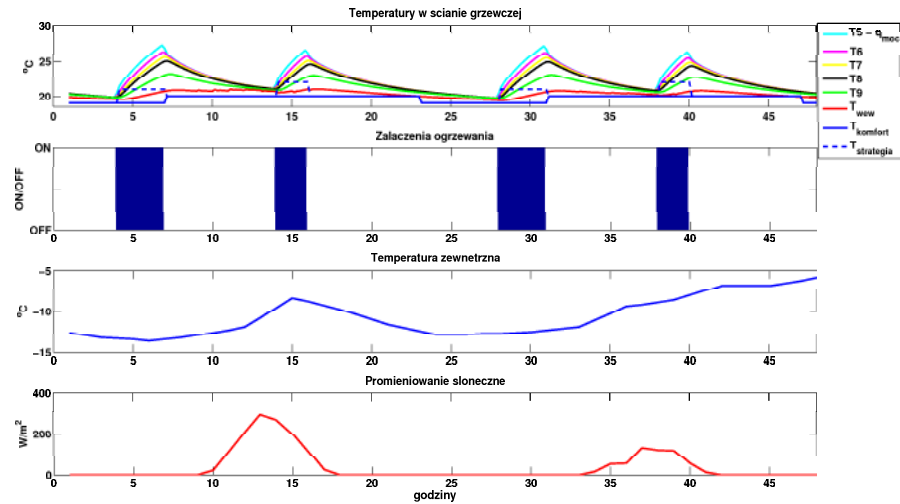
W przypadku ciężkiej konstrukcji budynku z zainstalowanym ogrzewaniem podłogowym, dzięki zastosowaniu prostych strategii sterowania możliwe jest zmniejszenie kosztu ogrzewania o około 39% przy jednoczesnym zwiększeniu zużyciu energii o około 6.5%. Zastosowanie strategii obniżających koszt ogrzewania wiąże się ze podniesieniem średniej temperatury w ciągu dnia o około  $0,59^{\circ}\text{C}$ , a w nocy o około  $0,21^{\circ}\text{C}$ . Dla najlepszej strategii około 30% sezonu grzewczego ma przekroczone temperatury do  $2^{\circ}\text{C}$ , a tylko około 8% czasu o więcej niż  $2^{\circ}\text{C}$ , a ok. 52% mieści się idealnie w zadanym przedziale komfortu. Dla prostej strategii nadążnej prawie 75% sezonu ma temperatury zgodnie z założonym komfortem, a około 25% czasu z temperaturą przekroczoną do ok.  $1.5^{\circ}\text{C}$ . Mimo przekroczenia zadaných temperatur przez najlepszą strategię nadążno-programowaną można uznać, że zachowuje ona akceptowalne warunki komfortu przy jednoczesnym bardzo znaczącym obniżeniu kosztu ogrzewania. Kierunek poprawy w tym przypadku to tylko wyeliminowanie niepotrzebnych włączeń przy znacznie przekroczonych wartościach temperatury zadanej.



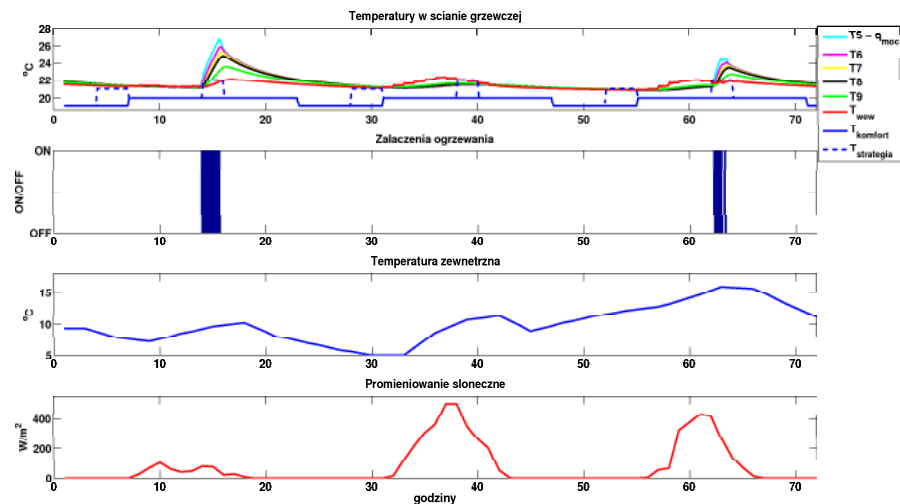
Rysunek 5.11: Zachowanie systemu grzewczego dla strategii 4 w dniach 8 i 9 stycznia TRM. Konstrukcja ciężka.



Rysunek 5.12: Odchylenia od temperatury zadanej dla strategii 4. Konstrukcja ciężka.




Rysunek 5.13: Zachowanie systemu grzewczego dla strategii 5 i wymuszeniu równym  $+2^{\circ}\text{C}$  w dniach 8 i 9 stycznia TRM. Konstrukcja ciężka.

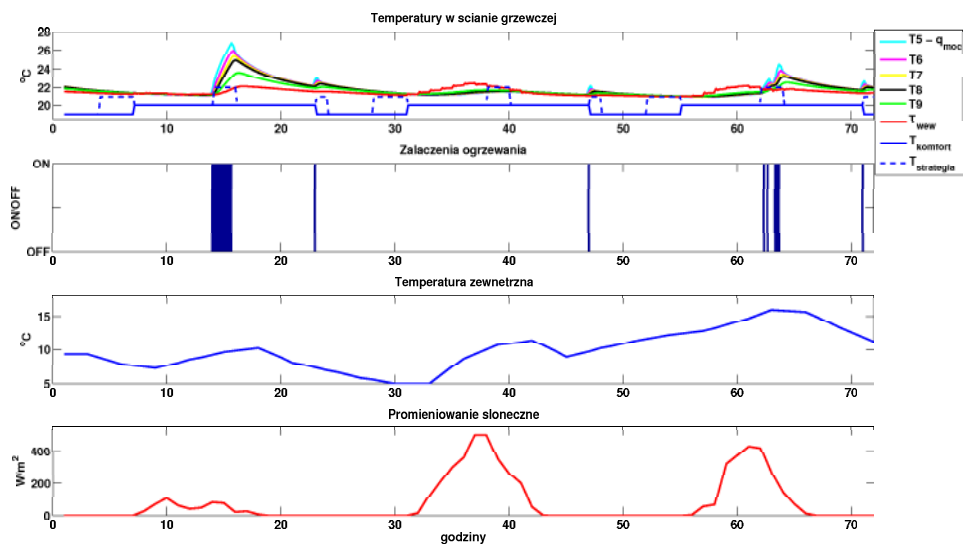


Rysunek 5.14: Zachowanie systemu grzewczego dla strategii 5 i wymuszeniu równym  $+2^{\circ}\text{C}$  w dniach od 8 do 11 października TRM. Konstrukcja ciężka.

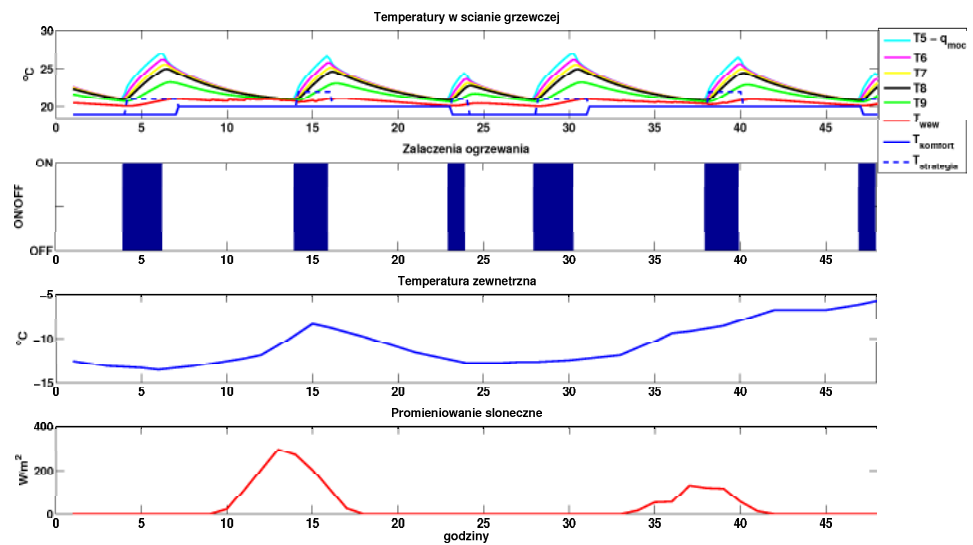





Rysunek 5.15: Odchylenia od temperatury zadanej dla strategii 5. Konstrukcja ciężka.



Rysunek 5.16: Zachowanie systemu grzewczego dla strategii 6 w dniach od 8 do 11 października TRM. Konstrukcja ciężka.



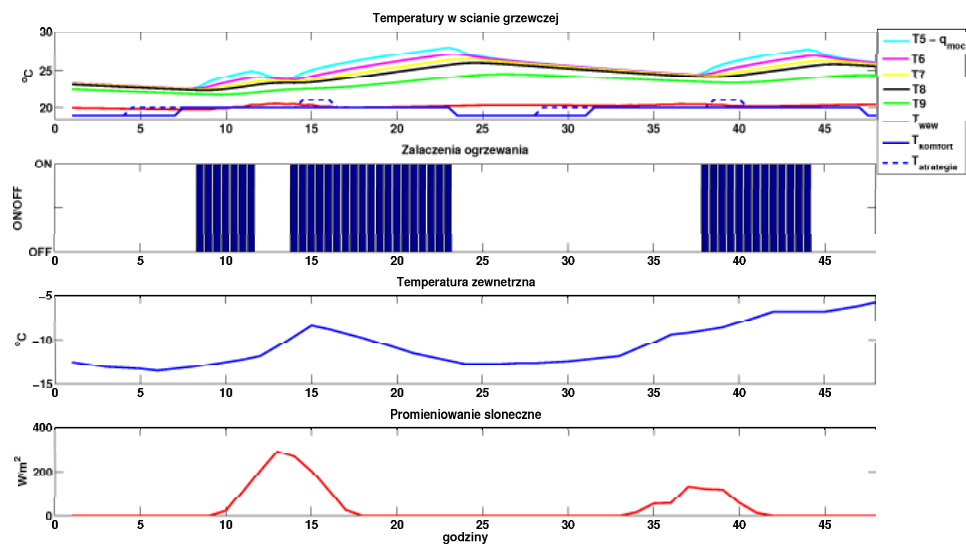
Rysunek 5.17: Zachowanie systemu grzewczego dla strategii 6 w dniach 8 i 9 stycznia TRM. Konstrukcja ciężka.



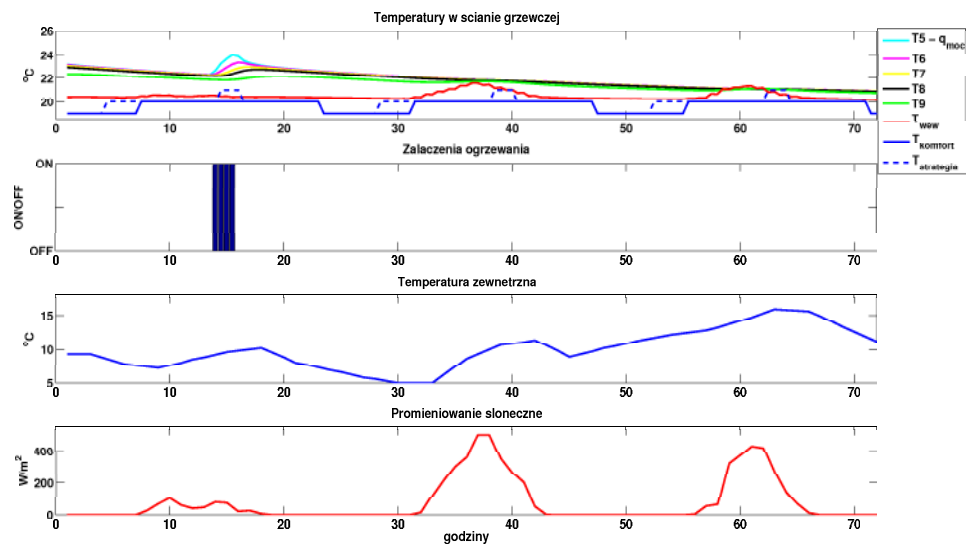
Rysunek 5.18: Odchylenia od temperatury zadanej dla strategii 6. Konstrukcja ciężka.

### 5.2.1 Efekt sposobu wymuszenia ogrzewania przy tańszej taryfie

Pozostaje pytanie, jak na koszt ogrzewania i komfort w pomieszczeniu wpłynie zmniejszenie wymuszenia do  $+1^{\circ}\text{C}$  dla strategii, która charakteryzowała się najmniejszym kosztem ogrzewania, ale dosyć wysokimi temperaturami sezonu grzewczego.



Rysunek 5.19: Zachowanie systemu grzewczego dla strategii 5 i wymuszeniu równym  $+1^{\circ}\text{C}$  w dniach 8 i 9 stycznia TRM. Konstrukcja ciężka.




Rysunek 5.20: Zachowanie systemu grzewczego dla strategii 5 i wymuszeniu równym  $+1^{\circ}\text{C}$  w dniach od 8 do 11 października TRM. Konstrukcja ciężka.

Dla wymuszenia równego  $+1^{\circ}\text{C}$  roczne koszty ogrzewania wyniosły 259,6zł z czego 176,8zł przypada na taryfę nocną a 82,8zł na taryfę dzienną. Całkowite zużycie energii wyniosło 678,6kWh czyli na poziomie prostej strategii nadążnej. Średnia temperatura w ciągu dnia wyniosła  $20,60^{\circ}\text{C}$  a nocy  $19,49^{\circ}\text{C}$ . Na wykresach 5.19,5.20 widać olbrzymie różnice w zachowaniu się systemu grzewczego. W przypadku silnego wymuszenia dla godzin na granicy taryfy nocnej widać, że system rzeczywiście włącza się właśnie w tym czasie. Słabsze wymuszenie, które powoduje prawie niewyczuwalne zmiany w założonym przez użytkownika komforcie cieplnym skutkuje niestety, częstymi włączeniami w taryfie dziennej i większymi rachunkami za energię mimo mniejszego jej zużycia. Obniżenie rachunków wymaga zatem zdecydowanego wymuszenia, co może skutkować większymi rozbieżnościami od temperatury zadanej. Warto jednak zauważyć, że wymuszenie na poziomie  $+2^{\circ}\text{C}$  od temperatury zadanej w danym okresie czasowym nigdy nie jest osiągnięte a jedynie zapewnia załączenie ogrzewania. Moc urządzenia grzewczego jest dla tego przypadku niewystarczająca aby ogrzać tak dużą masę pomieszczenia w tych krótkich przedziałach czasowych.

### 5.2.2 Rola grubości wylewki oraz mocy zainstalowanej


Kolejną istotną kwestią jest wpływ grubości warstwy masywnej, w której znajduje się ogrzewanie oraz mocy zainstalowanej na sezonowy koszt ogrzewania. Aby odpowiedzieć na to pytanie, zostały wykonane obliczenia dla różnych grubości płyty grzewczej w zakresie od 4cm do 26cm oraz dla mocy w zakresie 100% do 1000% mocy obliczeniowej równoważącej straty przy  $-20^{\circ}C$ . Grubości wylewki zostały dobrane w takim zakresie, aby najlepiej odzwierciedlać rzeczywiste konstrukcje stosowane obecnie w budownictwie. Mamy zatem wartość 4cm, która jest absolutnie minimalną grubością wylewki podłogowej oraz grubość 26cm, która jest grubością ogrzewanej płyty fundamentowej. Tak duży zakres mocy wynika z teoretycznych możliwości dziesięciokrotnego przekroczenie zapotrzebowania na moc dla budynków pasywnych. Obliczenia wykonano z 20 minutowym krokiem czasowym.



Rysunek 5.21: Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 1. Konstrukcja ciężka.


Dla prostej strategii mającej na celu utrzymanie zadanej temperatury w okresie dnia i nocy, minimum kosztów przypada dla warstw betonu powyżej 8cm i mocy wynoszącej 100% mocy równoważącej straty przy  $-20^{\circ}C$ . Widać wyraźnie, że wraz ze wzrostem mocy zainstalowanej i grubości wylewki rośnie również znacząco koszt ogrzewania. Zachowanie układu można tłumaczyć tym, że od rozpoczęcia ogrzewania grubej wylewki do momentu zmiany temperatury pomieszczenia mija kilka godzin. Dopiero wtedy następuje wyłączenie ogrzewania, podczas gdy podłoga wciąż oddaje

energię do pomieszczenia i temperatura wciąż rośnie. Dla małych mocy, dopasowanych do zapotrzebowania pomieszczenia na moc nie ma tego zjawiska, ponieważ ogrzewania działa prawie cały czas zahaczając również o tańszą taryfę energii elektrycznej. Objawia się to też niższymi średnimi temperaturami dnia i nocy. Różnice w kosztach ogrzewania w zależności od grubości i mocy zainstalowanej sięgają 12%.




Rysunek 5.22: Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 2. Konstrukcja ciężka.

Dla strategii drugiej (rys. 5.22) minimalny koszt rocznego ogrzewania został osiągnięty dla warstwy betonu o grubości 16cm i mocy zainstalowanej wynoszącej 100% mocy równoważącej straty przy  $-20^{\circ}C$  czyli w tym przypadku  $45W/m^2$ . Różnice w kosztach ogrzewania w zależności od konstrukcji i mocy zainstalowanej sięgają 19%. Minimum otrzymane akurat dla tej grubości wylewki wydaje się być wynikiem dopasowania opóźnienia przeładowania masy termicznej wylewki do analizowanych warunków klimatycznych. Dopasowanie to spowodowało lepsze wykorzystanie tańszej taryfy energii elektrycznej. Jednak, co do zasady, w celu utrzymania stałej temperatury nie ma potrzeby wykonywać grubej wylewki i instalować dużej mocy ogrzewania.



Rysunek 5.23: Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 3. Konstrukcja ciężka.


Dla kolejnej strategii 3 (rys. 5.23) minimalny koszt rocznego ogrzewania przypada dla warstwy betonu o grubości 4cm i mocy zainstalowanej wynoszącej 450% mocy równoważącej straty przy  $-20^{\circ}\text{C}$  czyli w tym przypadku  $202,5\text{W}/\text{m}^2$ . Różnice w kosztach ogrzewania w zależności od konstrukcji i mocy zainstalowanej dla strategii 3 sięgają 29%. Krótszy czas wymuszenia ogrzewania na tańszej taryfie skutkuje przesunięciem minimum w stronę większej mocy zainstalowanej. Warto zwrócić uwagę na w miarę płaski przebieg tego wykresu, co oznacza, że grubość warstwy masywnej nie ma wpływu na koszt ogrzewania.



Rysunek 5.24: Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 4. Konstrukcja ciężka.


Minimalny koszt rocznego ogrzewania dla strategii 5 (rys. 5.25) jest praktycznie identyczny dla warstwy betonu o grubości 4cm i 6cm oraz mocy zainstalowanej wynoszącej odpowiednio 300% i 250% mocy równoważącej straty przy  $-20^{\circ}\text{C}$  czyli w tym przypadku  $135\text{W}/\text{m}^2$  i  $112.5\text{W}/\text{m}^2$ . Różnice w kosztach ogrzewania sięgają 22% przy czym kluczowym parametrem jest moc zainstalowana. Dla małych wartości mocy zbliżonych do obliczeniowego zapotrzebowania system nie zdąży wykorzystać tańszej taryfy energii elektrycznej. Wzrost mocy powoduje wzrost średnich temperatur, a to powoduje zwiększenie zużycia energii. Ten efekt jest szczególnie widoczny dla dużych grubości i dużej mocy zainstalowanej. Zwiększanie grubości warstwy betonu, w której znajduje się ogrzewanie praktycznie nie powoduje obniżenia kosztu ogrzewania bez względu na moc zainstalowaną. Konstrukcja w całości ma już na tyle dużą pojemność cieplną, że dalsze jej powiększanie nie powoduje oszczędności.





Rysunek 5.25: Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewania dla strategii 5. Konstrukcja ciężka.

Dla strategii 6, (rys. 5.26) minimum przypada na grubość 6cm i moc 200%, natomiast rozbieżności w kosztach sięgają 15%. Warto zwrócić uwagę na duży wzrost kosztów ogrzewania dla skrajnych grubości wylewki przy dużych mocach. Można mówić zatem o dopasowaniu charakterystyki dynamicznej pomieszczenia wraz ze strategią sterowania ogrzewaniem do warunków klimatycznych.



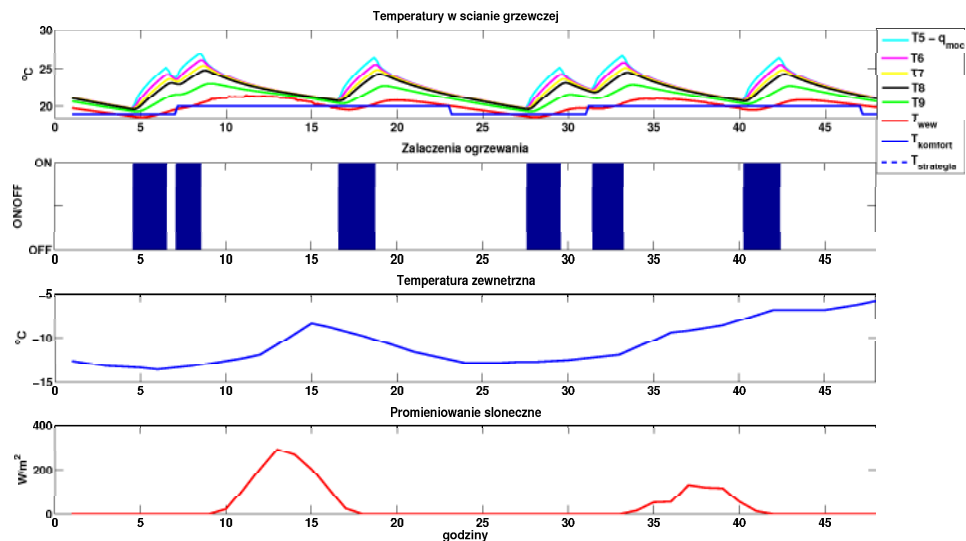
Rysunek 5.26: Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 6. Konstrukcja ciężka.

## 5.3 Konstrukcja średnio-ciężka

Kolejną analizowaną konstrukcją jest konstrukcja średnio-ciężka. Szczegóły poszczególnych przegród zestawiono w tabeli 5.1.

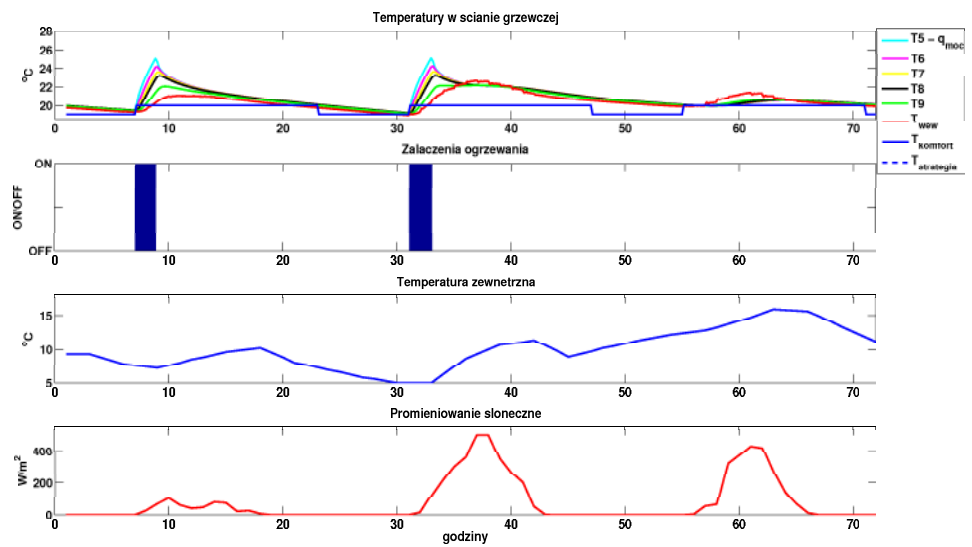
Tabela 5.3: Zestawienie kosztów ogrzewania dla konstrukcji średnio-ciężkiej

Strategia	Ekonomia						Komfort			
	Energia [kWh]			Koszt [zł]			Dzień		Noc	
	<i>I</i>	<i>II</i>	$\Sigma$	<i>I</i>	<i>II</i>	$\Sigma$	$T_{sr}$	$T_{std}$	$T_{sr}$	$T_{std}$
<b>1</b>	730,4	41,0	771,4	423,6	13,5	437,1	20,50	1,00	19,37	0,76
<b>2</b>	423,2	355,6	778,8	245,5	117,3	362,8	20,50	0,97	20,17	0,54
<b>3</b>	162,2	633,4	795,6	94,1	209,1	303,1	20,90	1,09	19,43	0,86
<b>4</b>	32,0	772,2	804,2	18,5	254,8	273,4	21,00	1,12	19,48	0,91
<b>5</b>	6,6	804,6	811,2	3,8	265,5	269,3	21,08	1,11	19,54	0,96
<b>6</b>	5,0	809,0	814,0	2,9	267,0	269,9	21,02	1,10	19,66	1,04
<b>5'</b>	204,0	566,8	770,8	118,3	187,1	305,4	20,51	0,91	19,36	0,72




Rysunek 5.27: Zachowanie systemu grzewczego dla strategii 1 w dniach 8 i 9 stycznia TRM. Konstrukcja średnio-ciężka.

Zachowanie systemu w tym przypadku charakteryzują zdecydowanie wyższe temperatury w ciągu dnia i nocy w stosunku do konstrukcji ciężkiej. Warto również zwrócić uwagę na wyższe temperatury w podłodze grzewczej, które będą miały znaczący wpływ na sprawności źródeł typu pompa ciepła, również zasilanych energią elektryczną.



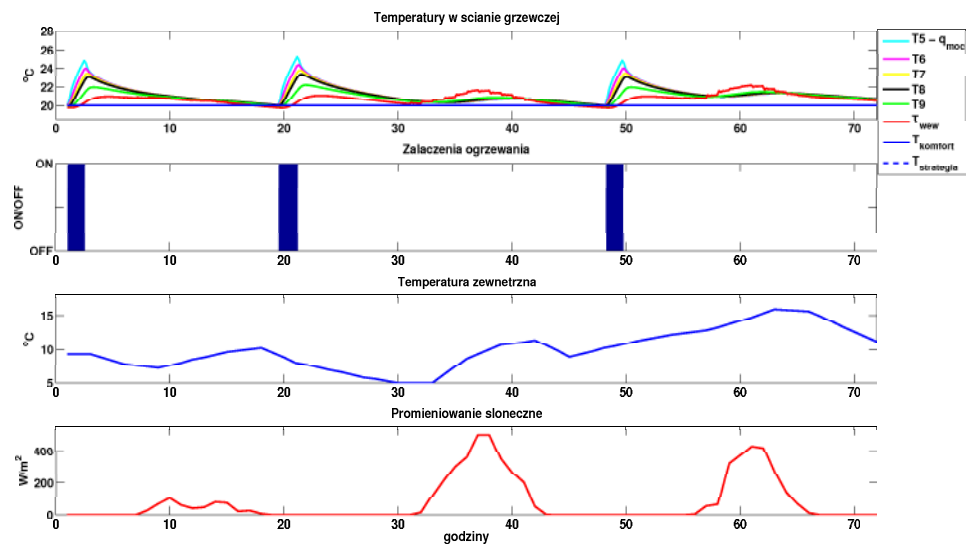
Rysunek 5.28: Zachowanie systemu grzewczego dla strategii 1 w dniach od 8 do 11 października TRM. Konstrukcja średnio-ciężka.



Rysunek 5.29: Odchylenia od temperatury zadanej dla strategii 1. Konstrukcja średnio-ciężka.

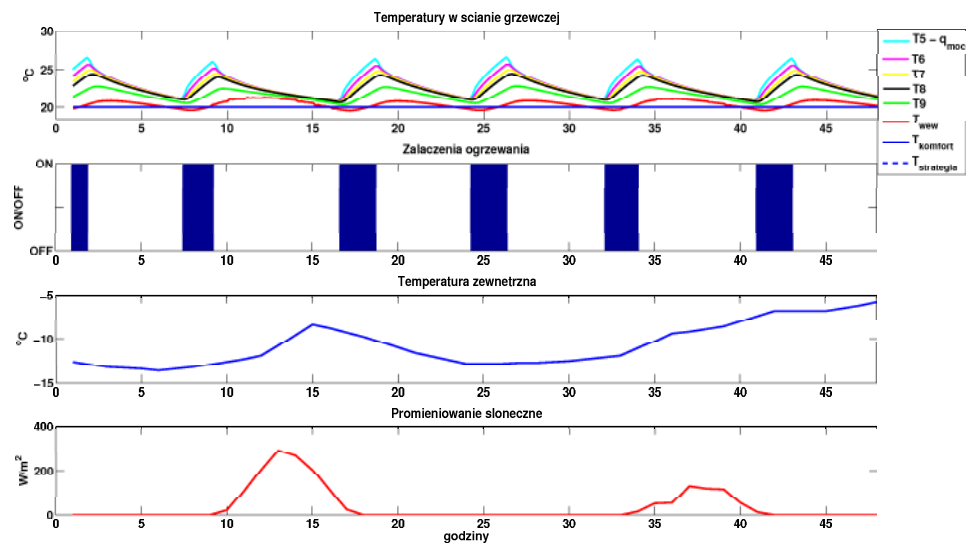
W przypadku tej konstrukcji jest już możliwe osiągnięcie zadanych temperatur w nocy (rys. 5.27). Mniejsza efektywna pojemność cieplna konstrukcji pozwala na większe wahania temperatury wewnętrznej. Niestety, skutkuje to również zwiększeniem zapotrzebowania na energię o około 12% w stosunku do konstrukcji ciężkiej.

Dla strategii drugiej, utrzymującej stałą temperaturę w ciągu doby zużycie energii jest większe niż dla analogicznej strategii dla konstrukcji ciężkiej. Uwagę zwracają również wyższe wahania temperatury w ciągu poszczególnych okresów, wyrażone poprzez odchylenie standardowe. I tak dla dnia wynosi 0.97 i nocy 0.54.




Rysunek 5.30: Zachowanie systemu grzewczego dla strategii 2 w dniach od 8 do 11 października TRM. Konstrukcja średnio-ciężka.

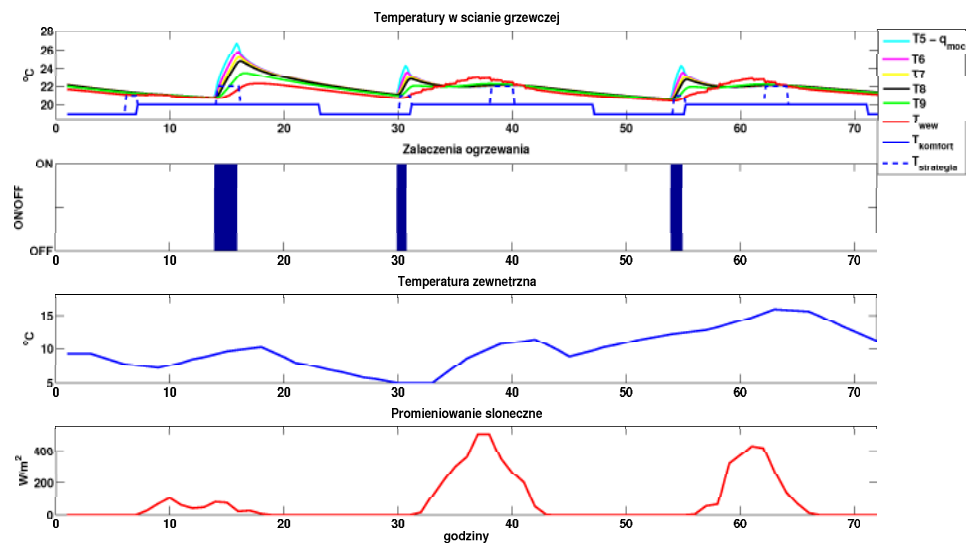
Dla strategii trzeciej, w przypadku tej konstrukcji nie ma już efektu niepotrzebnego włączenia ogrzewania w okresach dziennego wymuszenia, ponieważ temperatura powietrza w pomieszczeniu ma średnio wyższą temperaturę (rys. 5.33). Wciąż jednak okres wymuszenia pod koniec nocnego okresu tańszej taryfy jest zbyt krótki (rys. 5.34) i powoduje włączenie ogrzewania. Koszt ogrzewania jest jednak o 12% wyższy niż dla identycznej strategii zastosowanej dla konstrukcji ciężkiej przy jednoczesnym 3% wzroście zużycia energii.



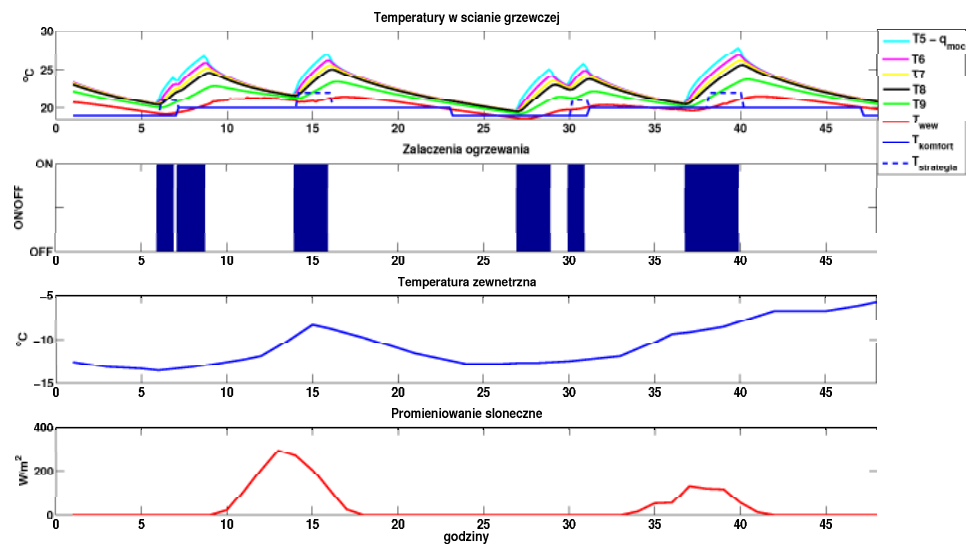
Rysunek 5.31: Zachowanie systemu grzewczego dla strategii 2 w dniach 8 i 9 stycznia TRM. Konstrukcja średnio-ciężka.



Rysunek 5.32: Odchylenia od temperatury zadanej dla strategii 2. Konstrukcja średnio-ciężka.




Rysunek 5.33: Zachowanie systemu grzewczego dla strategii 3 w dniach od 8 do 11 października TRM. Konstrukcja średnio-ciężka.

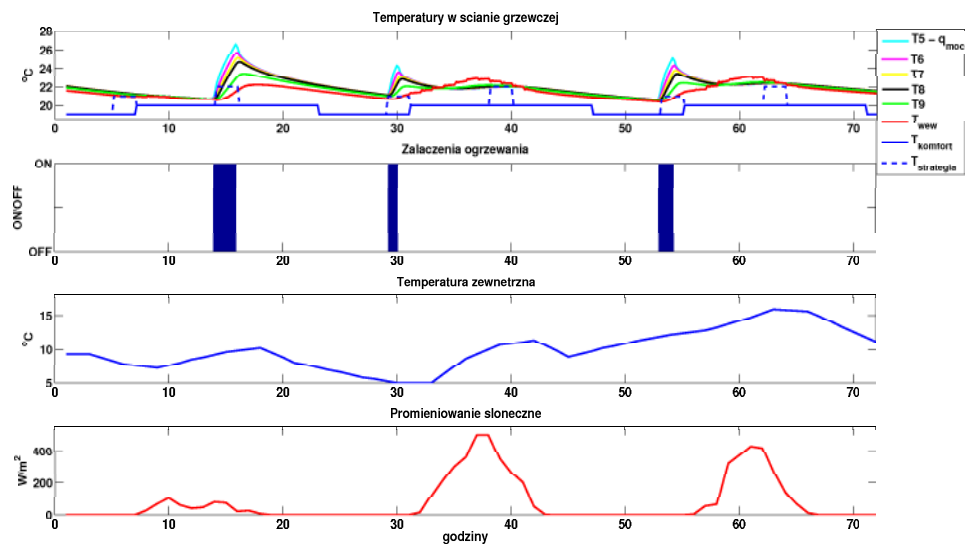


Rysunek 5.34: Zachowanie systemu grzewczego dla strategii 3 w dniach 8 i 9 stycznia TRM. Konstrukcja średnio-ciężka.

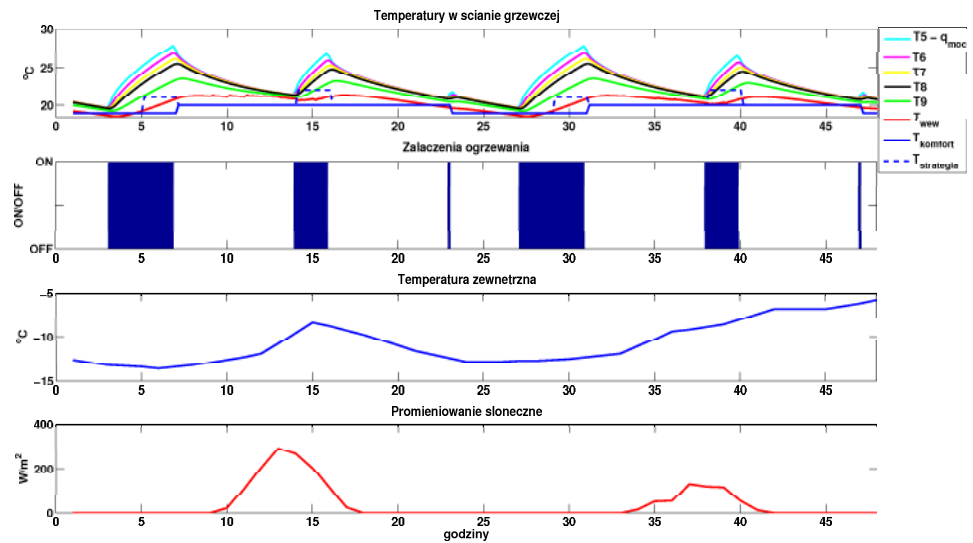





Rysunek 5.35: Odchylenia od temperatury zadanej dla strategii 3. Konstrukcja średnio-ciężka.



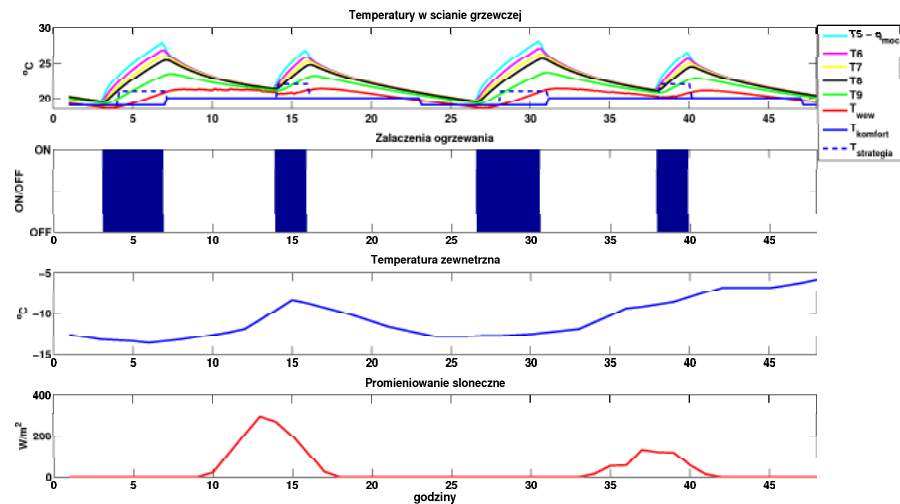
Rysunek 5.36: Zachowanie systemu grzewczego dla strategii 4 w dniach od 8 do 11 października TRM. Konstrukcja średnio-ciężka.



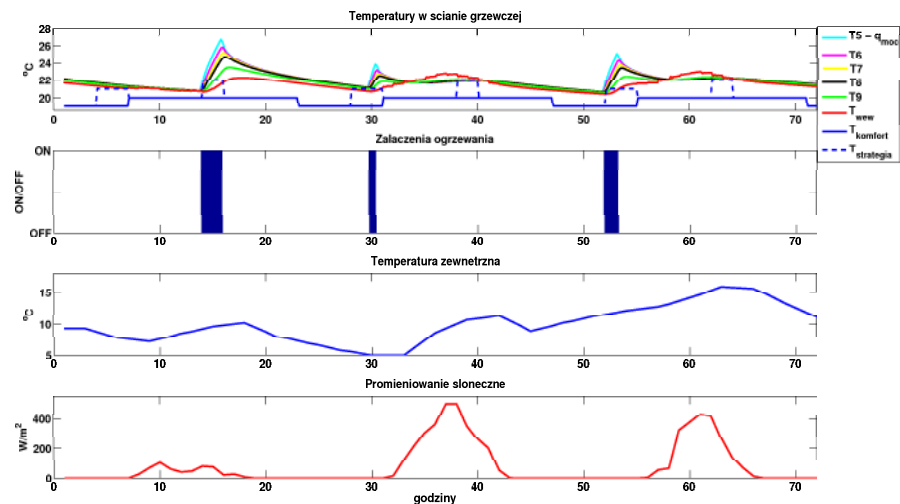
Rysunek 5.37: Zachowanie systemu grzewczego dla strategii 4 w dniach 8 i 9 stycznia TRM. Konstrukcja średnio-ciężka.




Rysunek 5.38: Odchylenia od temperatury zadanej dla strategii 4. Konstrukcja średnio-ciężka.



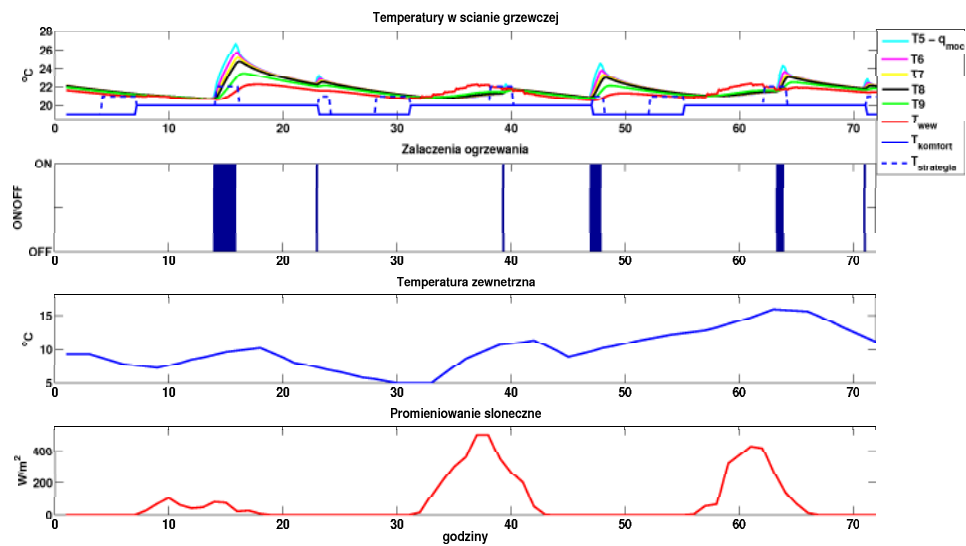
Rysunek 5.39: Zachowanie systemu grzewczego dla strategii 5 i wymuszeniu równym  $+2^{\circ}\text{C}$  w dniach 8 i 9 stycznia TRM. Konstrukcja średnio-ciężka.



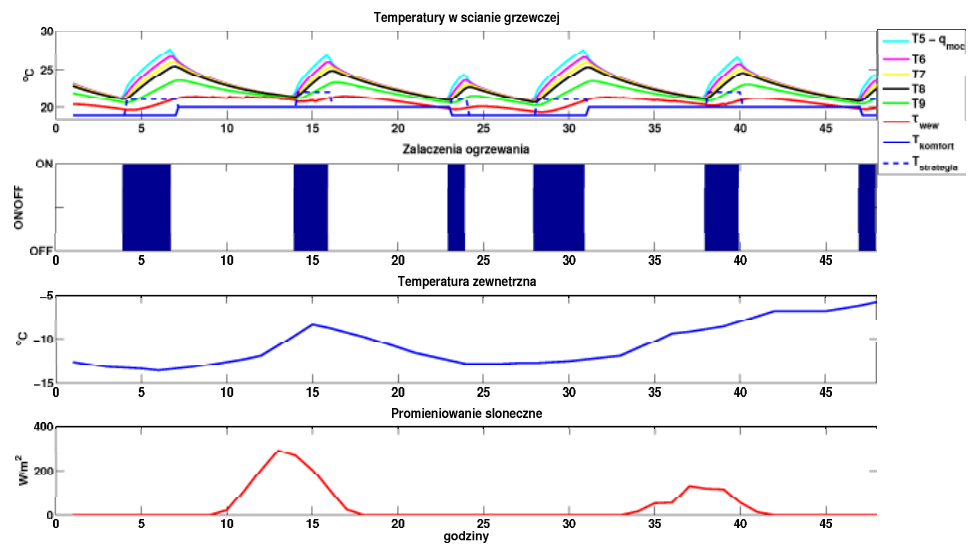
Rysunek 5.40: Zachowanie systemu grzewczego dla strategii 5 i wymuszeniu równym  $+2^{\circ}\text{C}$  w dniach od 8 do 11 października TRM. Konstrukcja średnio-ciężka.




Rysunek 5.41: Odchylenia od temperatury zadanej dla strategii 5. Konstrukcja średnio-ciężka.



Rysunek 5.42: Zachowanie systemu grzewczego dla strategii 6 w dniach od 8 do 11 października TRM. Konstrukcja średnio-ciężka.

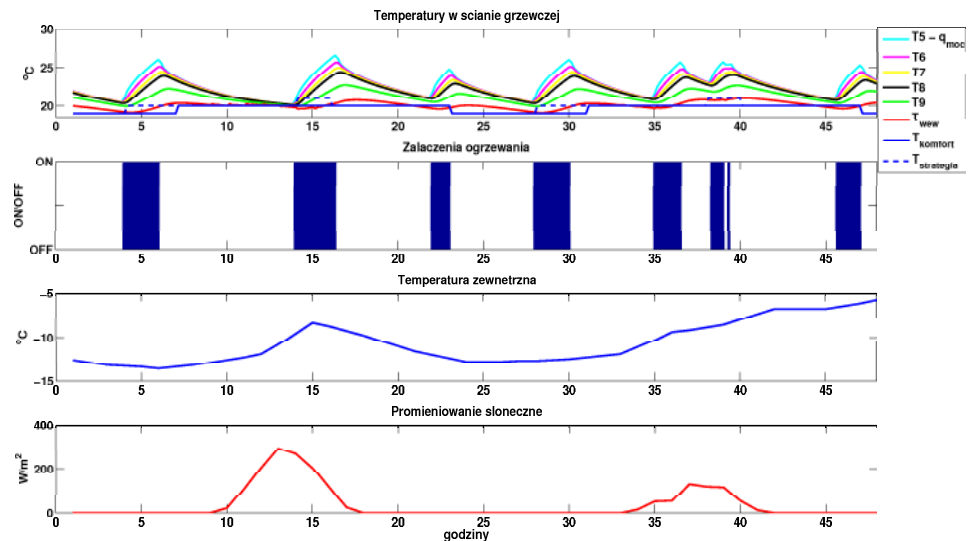


Rysunek 5.43: Zachowanie systemu grzewczego dla strategii 6 w dniach 8 i 9 stycznia TRM. Konstrukcja średnio-ciężka.



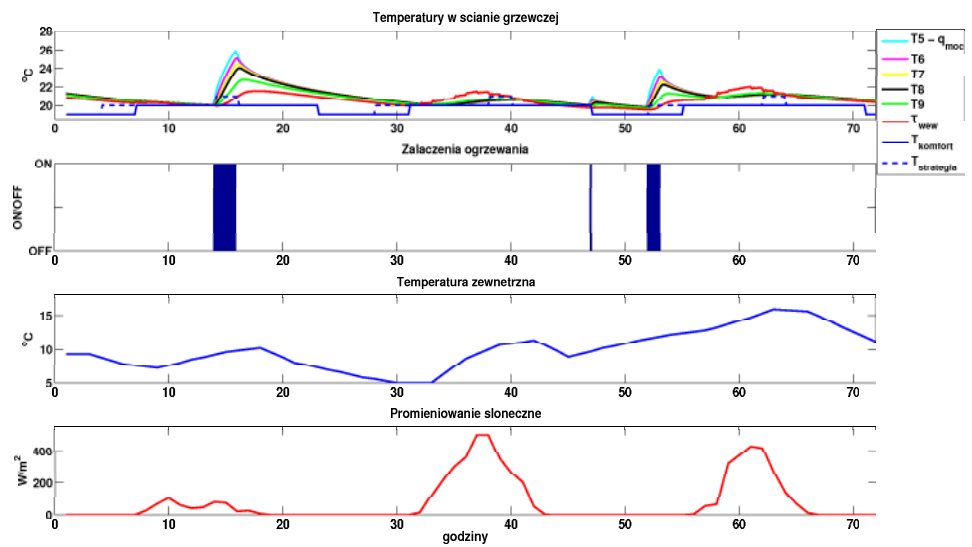
Rysunek 5.44: Odchylenia od temperatury zadanej dla strategii 6. Konstrukcja średnio-ciężka.

### 5.3.1 Efekt sposobu wymuszenia ogrzewania przy tańszej taryfie




Rysunek 5.45: Zachowanie systemu grzewczego dla strategii 5' i wymuszeniu równym  $+1^{\circ}\text{C}$  w dniach 8 i 9 stycznia TRM. Konstrukcja średnio-ciężka.

Obniżenie wymuszenia dla strategii piątej spowodowało podwyższenie kosztu energii o 12% w stosunku do strategii piątej działającej z wymuszeniem  $+2^{\circ}\text{C}$ , natomiast obniżyło to średnie temperatury dnia o  $0.57^{\circ}\text{C}$ , a nocy o  $0.18^{\circ}\text{C}$ .




Rysunek 5.46: Zachowanie systemu grzewczego dla strategii 5' i wymuszeniu równym  $+1^{\circ}\text{C}$  w dniach od 8 do 11 października TRM. Konstrukcja średnio-ciężka.



Rysunek 5.47: Odchylenia od temperatury zadanej dla strategii 5' i wymuszeniu równym  $+1^{\circ}C$ . Konstrukcja średnio-ciężka.




### 5.3.2 Rola grubości wylewki oraz mocy zainstalowanej.




Rysunek 5.48: Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 1. Konstrukcja średnio - ciężka.

Minimum osiągnięte dla minimalnej mocy 100% i minimalnej grubości 4cm. Różnice sięgają 22%.




Rysunek 5.49: Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 2. Konstrukcja średnio - ciężka.

Minimum osiągnięte dla 16cm i 100%. Różnice sięgają 22%.




Rysunek 5.50: Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 3. Konstrukcja średnio - ciężka.

Minimum osiągnięte dla 4cm i 450%. Różnice sięgają 18%.




Rysunek 5.51: Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 4. Konstrukcja średnio - ciężka.

Minimum osiągnięte dla 6cm i 300%. Różnice sięgają 24%.



Rysunek 5.52: Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 5. Konstrukcja średnio - ciężka.

Minimum osiągnięte dla 8cm i 250%. Różnice sięgają 25%.



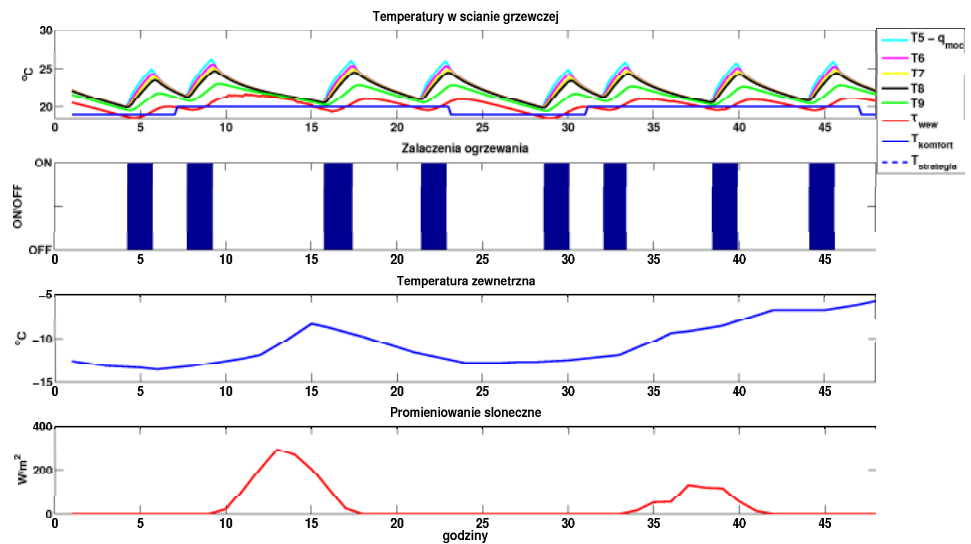
Rysunek 5.53: Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewanie dla strategii 6. Konstrukcja średnio-ciężka

Minimum osiągnięte dla 8cm i 200%. Różnice sięgają 16%.

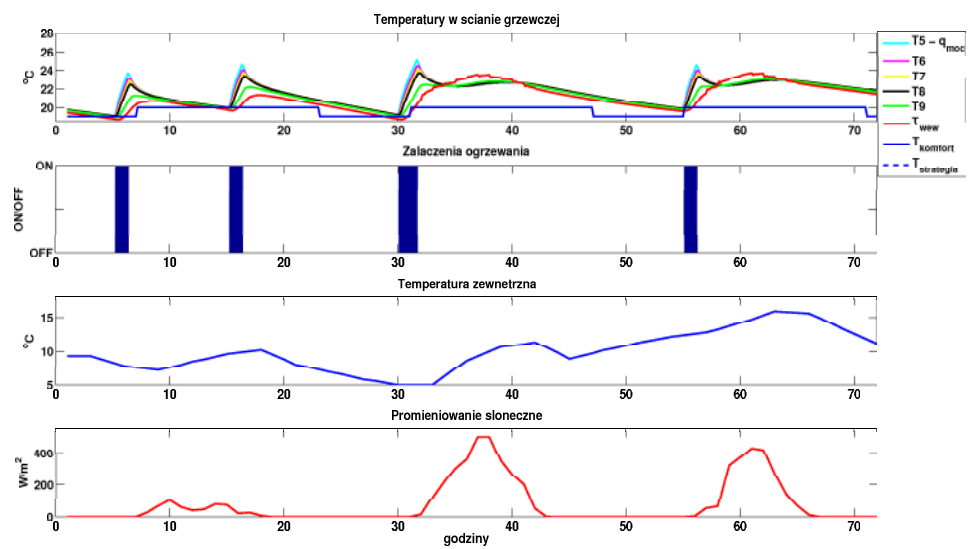
## 5.4 Konstrukcja lekka

Tabela 5.4: Zestawienie kosztów ogrzewania dla konstrukcji lekkiej

Strategia	Ekonomia						Komfort			
	Energia [kWh]			Koszt [zł]			Dzień		Noc	
	<i>I</i>	<i>II</i>	$\Sigma$	<i>I</i>	<i>II</i>	$\Sigma$	$T_{sr}$	$T_{std}$	$T_{sr}$	$T_{std}$
<b>1</b>	531,0	264,0	795,0	308,0	87,1	395,1	20,70	1,31	19,32	0,87
<b>2</b>	412,0	394,6	806,6	239,0	130,2	369,2	20,67	1,28	20,23	0,71
<b>3</b>	101,0	719,2	820,2	58,6	237,3	295,9	21,12	1,44	19,37	0,93
<b>4</b>	50,8	779,0	829,8	29,5	257,1	286,5	21,25	1,46	19,41	0,97
<b>5</b>	60,2	771,2	831,4	34,9	254,5	289,4	21,20	1,45	19,48	1,05
<b>6</b>	86,4	750,8	837,2	50,1	247,8	297,9	21,11	1,42	19,69	1,16
<b>5'</b>	366,8	431,8	798,6	212,8	142,5	355,3	20,66	1,22	19,43	0,92




Rysunek 5.54: Zachowanie systemu grzewczego dla strategii 1 w dniach 8 i 9 stycznia TRM. Konstrukcja lekka.



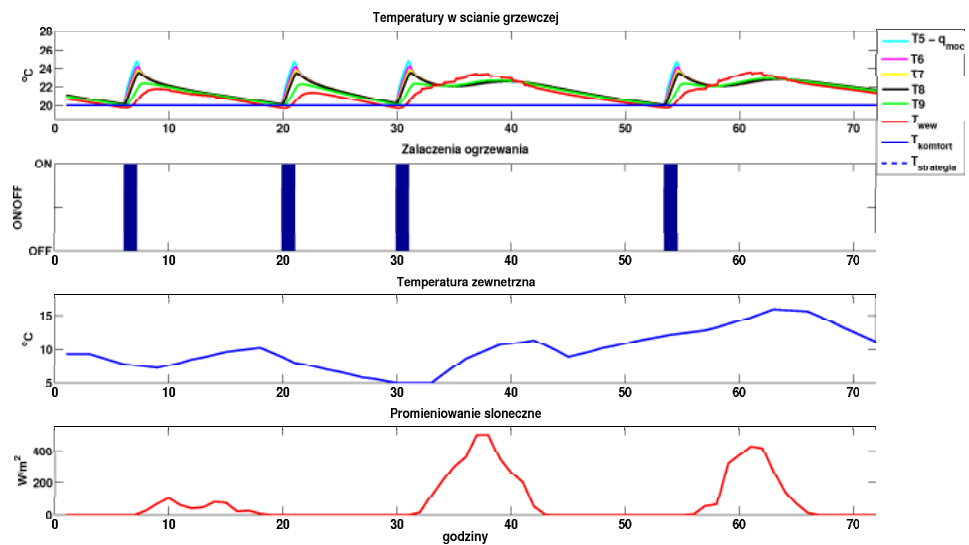
Rysunek 5.55: Zachowanie systemu grzewczego dla strategii 1 w dniach od 8 do 11 października TRM. Konstrukcja lekka.





Rysunek 5.56: Odchylenia od temperatury zadanej dla strategii 1. Konstrukcja lekka.

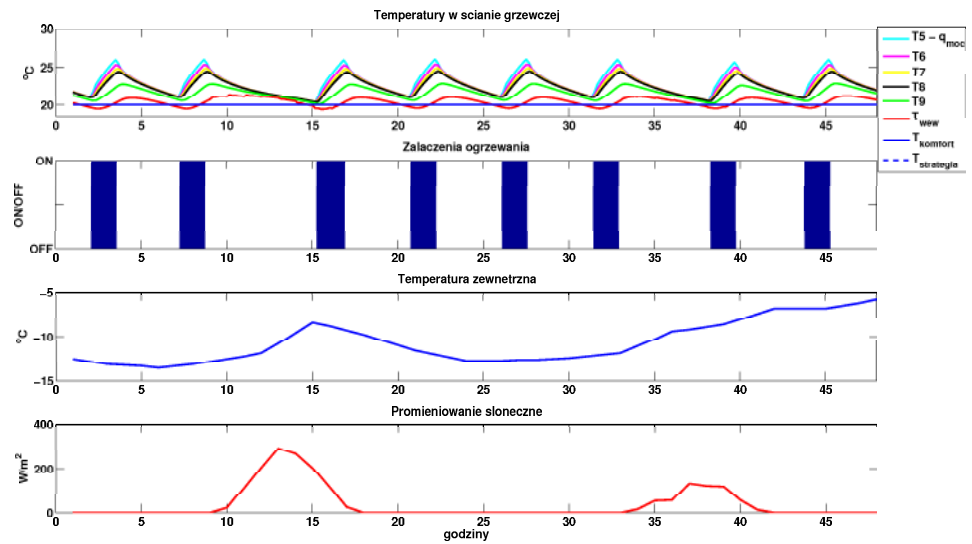
Mimo braku wymuszenia wykorzystywania tańszej taryfy energii elektrycznej na jej krańcach, dla konstrukcji lekkiej obserwujemy włączenia ogrzewania również w okresie taniej taryfy nocnej (rys. 5.54). Na uwagę zasługuje szybka zmiana temperatury pomieszczenia przy podniesieniu temperatury w podłodze grzewczej. Koszt ogrzewania wyniósł dla tego przypadku 395,1zł z czego 87,1zł na taryfie nocnej i 308,0zł na taryfie dziennej. Całkowite zużycie energii wyniosło 795,6kWh, natomiast średnia temperatura dnia wyniosła  $20,70^{\circ}C$  a nocy  $19,31^{\circ}C$ . Zatem dla prostego sterowania nadażnego uzyskaliśmy prawie identyczny koszt ogrzewania jak dla konstrukcji ciężkiej przy jednocześnie większym o 15% zużyciu energii. Wynika to z braku opóźnień na przeładowanie konstrukcji i włączeń ogrzewania również w nocy. Zwracają uwagę również wysokie temperatury powietrza wewnętrznego w momencie pojawienia się promieniowania słonecznego.




Rysunek 5.57: Zachowanie systemu grzewczego dla strategii 2 w dniach od 8 do 11 października TRM. Konstrukcja lekka.

Warto również zauważyć, że dla lekkiej konstrukcji system ma możliwość utrzymania nieco niższej temperatury w okresie nocnym tylko poprzez wyłączenie ogrzewania (rys. 5.55).

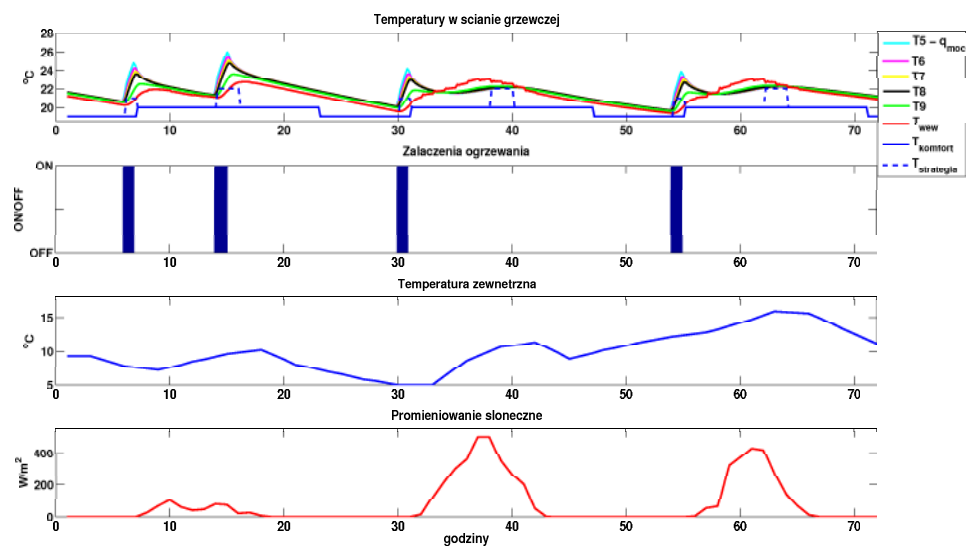
Wyeliminowanie nocnego obniżenia temperatury nie powoduje tak zdecydowanego obniżenia kosztów ogrzewania jak to było dla konstrukcji ciężkiej. Obniżenie kosztów ogrzewania w stosunku do strategii 1 wyniosło 7% przy 1.5% wzroście zużycia energii. Jest to o 11% więcej niż dla konstrukcji ciężkiej.



Rysunek 5.58: Zachowanie systemu grzewczego dla strategii 2 w dniach 8 i 9 stycznia TRM. Konstrukcja lekka.



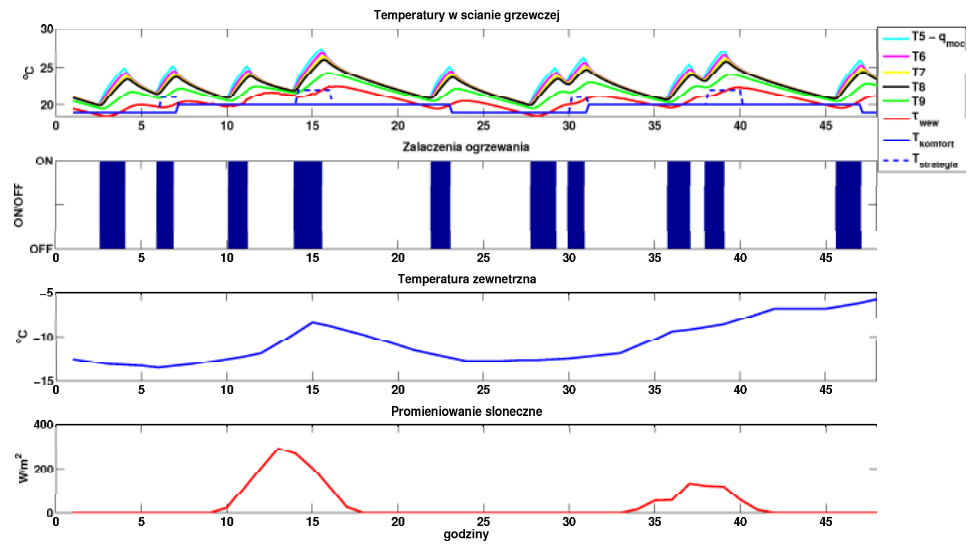
Rysunek 5.59: Odchylenia od temperatury zadanej dla strategii 2. Konstrukcja lekka.




Rysunek 5.60: Zachowanie systemu grzewczego dla strategii 3 w dniach od 8 do 11 października TRM. Konstrukcja lekka.

Z kolei dla strategii 3 wymuszenie równe  $+2^{\circ}\text{C}$  w okresie dużego nasłonecznienia (rys. 5.60) powoduje niepotrzebne przekroczenie temperatur zadanych i włączenie ogrzewania w środku dnia, gdy temperatura wewnętrzna jest o ponad  $1^{\circ}\text{C}$  większa niż zadana. Te włączenia niepotrzebnie zwiększają zapotrzebowanie na energię i jednocześnie pogarszają komfort użytkownika budynku. Dla dużych mrozów (rys. 5.61) widać wyraźnie, że okres wymuszenia ogrzewania pod koniec nocy jest za krótki aby system dał radę dostarczyć konieczną energię w niższej cenie. Nie zmienia to jednak faktu, że roczny koszt ogrzewania wyniósł 256,6 zł czyli o ponad 34% mniej niż dla strategii 1 przy jednoczesnym wzroście całkowitego zużycia energii o 4%.

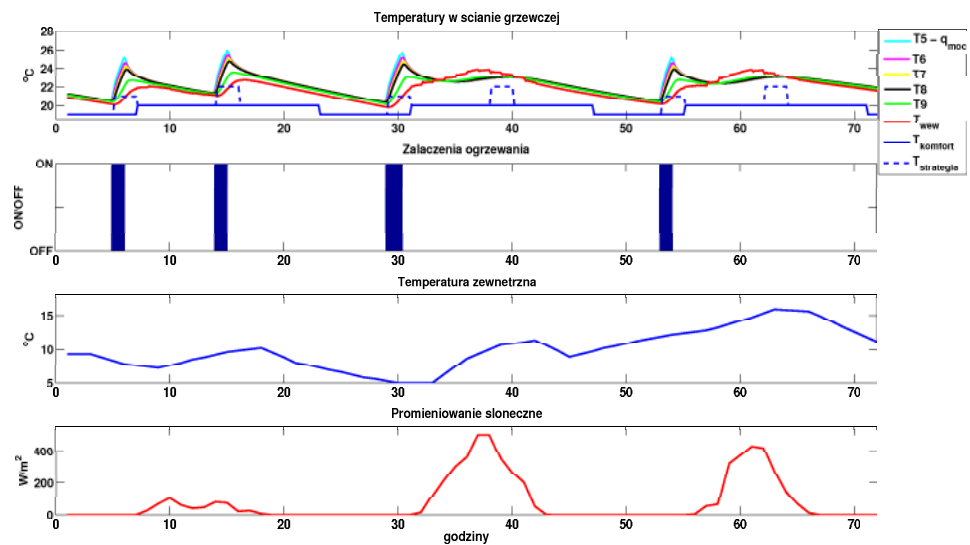
Wzdłużenie okresu wymuszenia ogrzewania pod koniec nocnego okresu tańszej taryfy o jedną godzinę - strategia 4 - spowodowało lepsze jej wykorzystanie w okresie mroźnym (rys. 5.64), jak również dla okresu ciepłego (rys. 5.63). Warto zauważyć, że liczba dni z temperaturą przekroczoną do  $2^{\circ}\text{C}$  (rys. 5.65) wynosi około 30% analizowanego okresu grzewczego, a powyżej  $2^{\circ}\text{C}$  około 14%. To uwiadcza się w sezonowym zużyciu energii na cele grzewcze, który jest wyższy o niespełna 4% w stosunku do strategii nadążnej, ale jednocześnie koszt ogrzewania jest niższy o ok. 38%. Jest to zatem nawet lepszy wynik niż uzyskuje strategia 3.



Rysunek 5.61: Zachowanie systemu grzewczego dla strategii 3 w dniach 8 i 9 stycznia TRM. Konstrukcja lekka.



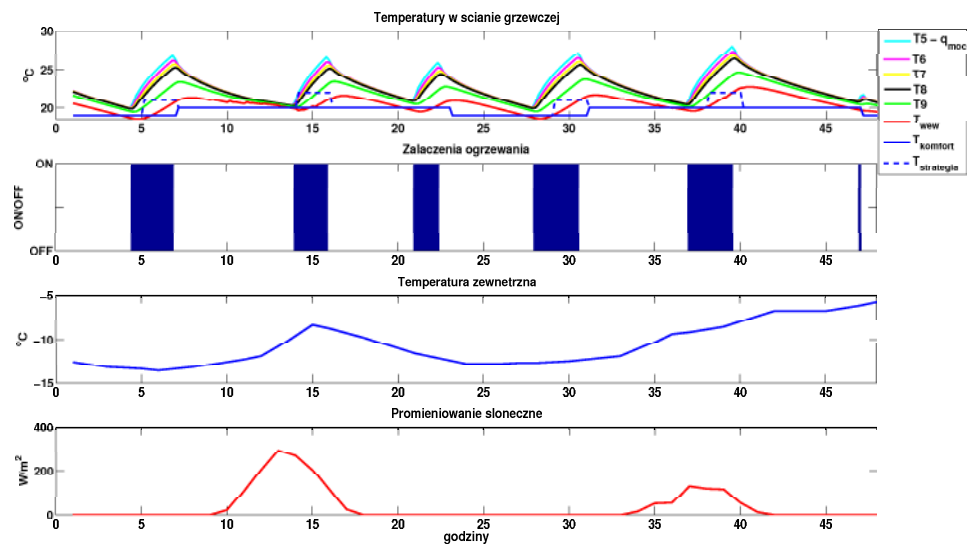
Rysunek 5.62: Odchylenia od temperatury zadanej dla strategii 3. Konstrukcja lekka.



Rysunek 5.63: Zachowanie systemu grzewczego dla strategii 4 w dniach od 8 do 11 października TRM. Konstrukcja lekka.


Dla strategii piątej roczny koszt ogrzewania wyniesie 289,4zł z czego na tańszą taryfę przypada 93% zapotrzebowania. Zachowanie systemu sterowania można zaobserwować na rysunkach 5.70, 5.67. Całkowite zużycie energii wzrosło do 831,4kWh. Jest to zatem wynik gorszy niż dla strategii 4, która okazała się najlepsza dla konstrukcji lekkiej.

Dla strategii 6 wzrasta już tylko zużycie energii oraz średnia temperatura w okresie nocnego obniżenia. Wymuszenie ogrzewania na początku nocnego okresu tańszej taryfy (rys. 5.70, 5.67) powoduje podniesienie sezonowego kosztu ogrzewania.

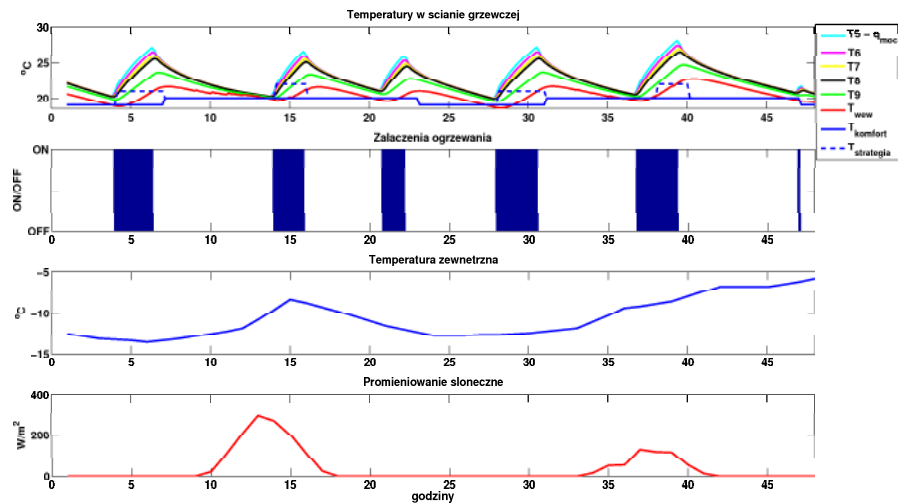


Rysunek 5.64: Zachowanie systemu grzewczego dla strategii 4 w dniach 8 i 9 stycznia TRM. Konstrukcja lekka.

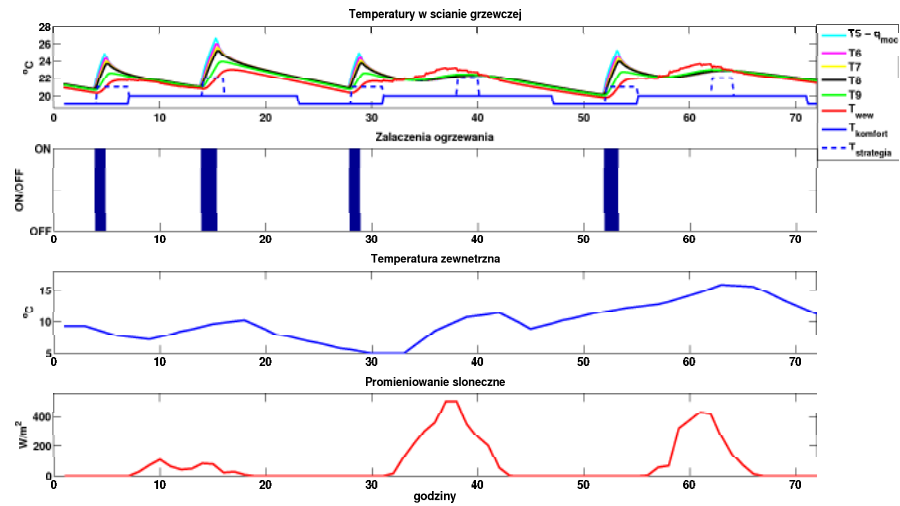
Dla lekkiej konstrukcji budynku z zainstalowanym ogrzewaniem podłogowym, dzięki zastosowaniu prostych strategii sterowania możliwe jest zmniejszenie kosztu ogrzewania o około 38% przy jednoczesnym zwiększeniu zużyciu energii o około 4%. Zastosowanie strategii obniżających koszt ogrzewania wiąże się z podniesieniem średniej temperatury w ciągu dnia o około  $0,5^{\circ}\text{C}$  a w nocy o około  $0,15^{\circ}\text{C}$ . Dla najlepszej strategii - 4 - około 30% sezonu grzewczego ma przekroczone temperatury do  $2^{\circ}\text{C}$  a jednocześnie ponad 14% czasu o więcej niż  $2^{\circ}\text{C}$  a ok. 56% mieści się idealnie w zadanym przedziale komfortu. Dla prostej strategii nadążnej prawie 66% sezonu ma temperatury zgodnie z założonym komfortem, a około 24% czasu z temperaturą przekroczoną do ok.  $+2^{\circ}\text{C}$ . Mimo przekroczenia zadanych temperatur przez najlepszą strategię nadążno-programowalną można uznać, że zachowuje ona akceptowalne warunki komfortu przy jednoczesnym bardzo znaczącym obniżeniu kosztu ogrzewania.




Rysunek 5.65: Odchylenia od temperatury zadanej dla strategii 4. Konstrukcja lekka.

Rysunek 5.66: Zachowanie systemu grzewczego dla strategii 5 i wymuszeniu równym  $+2^{\circ}C$  w dniach 8 i 9 stycznia TRM. Konstrukcja lekka.

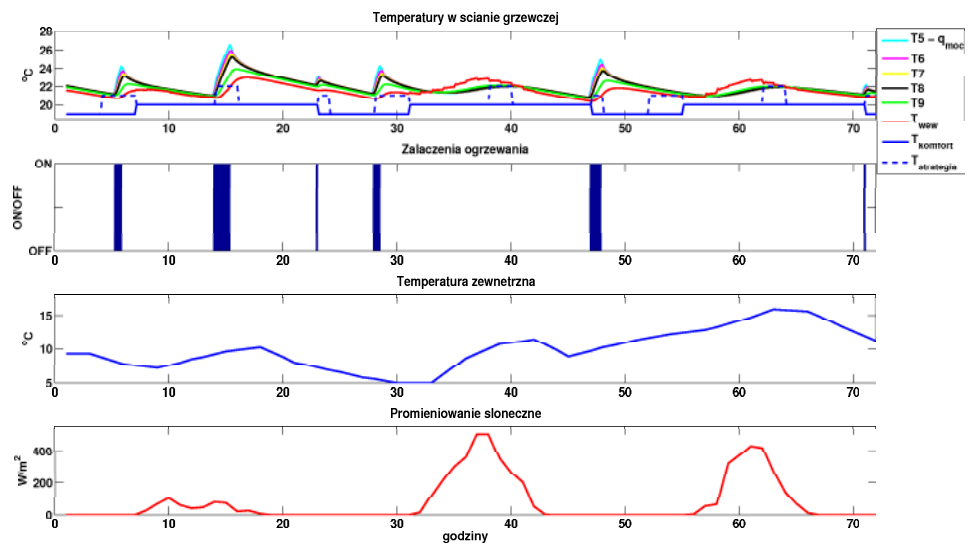




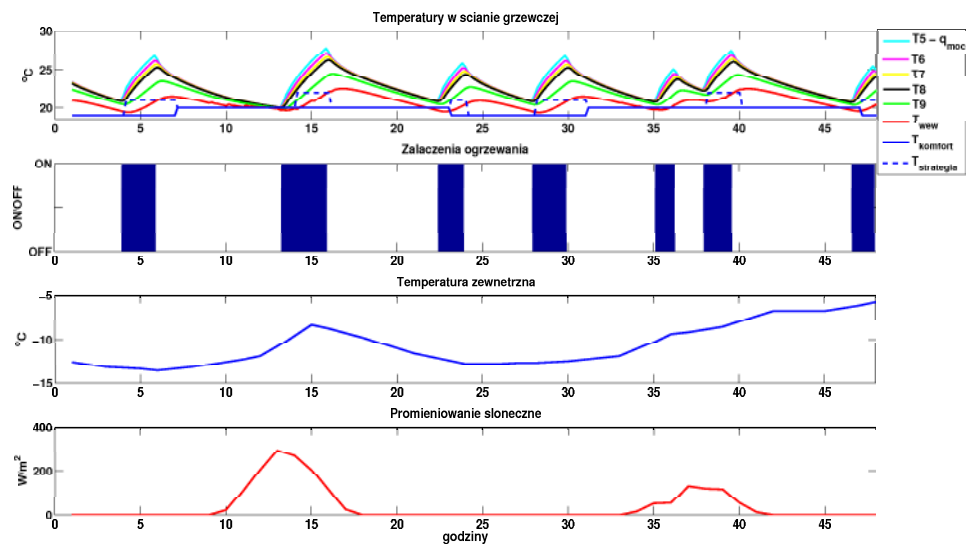
Rysunek 5.67: Zachowanie systemu grzewczego dla strategii 5 i wymuszeniu równym  $+2^{\circ}\text{C}$  w dniach od 8 do 11 października TRM. Konstrukcja lekka.




Rysunek 5.68: Odchylenia od temperatury zadanej dla strategii 5. Konstrukcja lekka.



Rysunek 5.69: Zachowanie systemu grzewczego dla strategii 6 w dniach od 8 do 11 października TRM. Konstrukcja lekka.



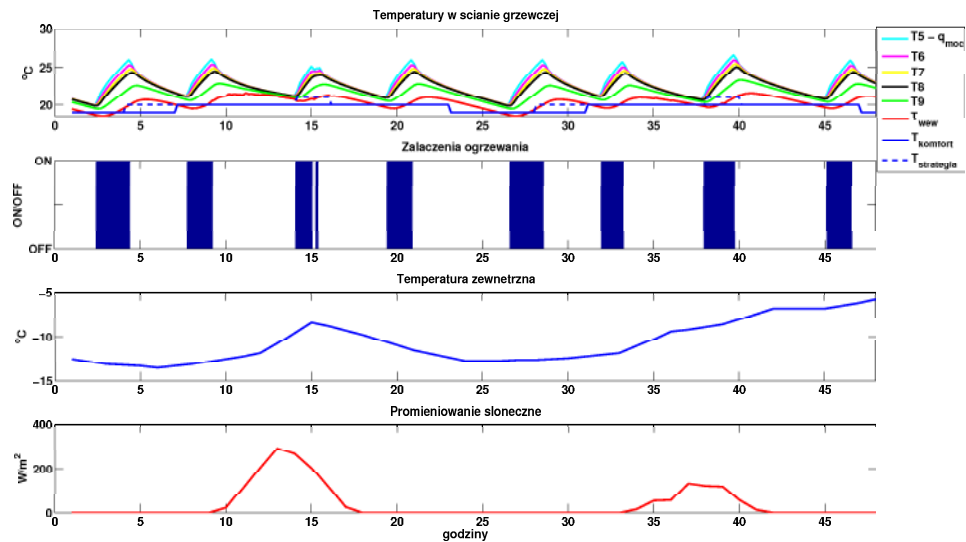
Rysunek 5.70: Zachowanie systemu grzewczego dla strategii 6 w dniach 8 i 9 stycznia TRM. Konstrukcja lekka.



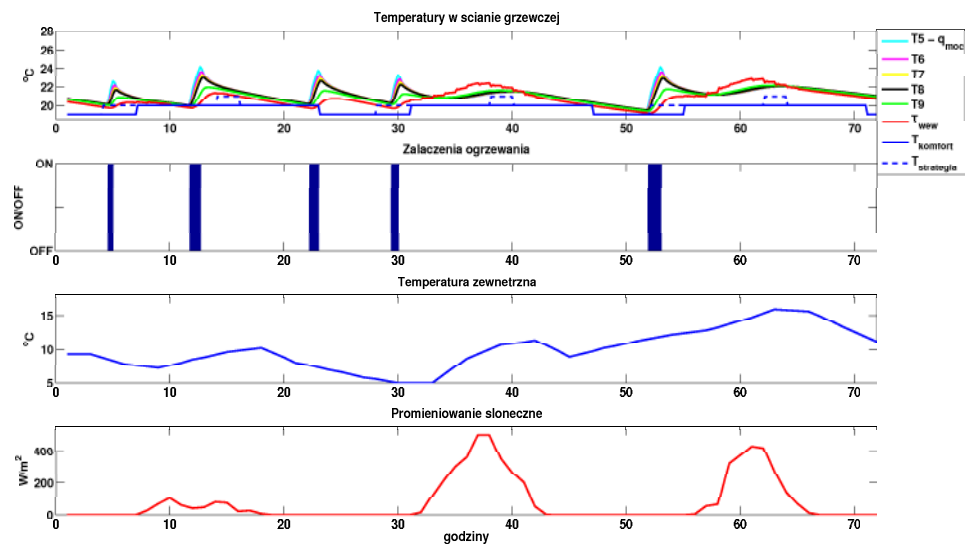
Rysunek 5.71: Odchylenia od temperatury zadanej dla strategii 6. Konstrukcja lekka.

### 5.4.1 Efekt sposobu wymuszenia ogrzewania przy tańszej taryfie

Zmniejszenie wymuszenia ogrzewania do  $+1^{\circ}\text{C}$  dla strategii, która charakteryzowała się najmniejszym kosztem ogrzewania spowodowało podniesienie kosztu ogrzewania o 19% w stosunku do najlepszej z testowanych strategii. Zachowanie systemu jest zatem niezadowolające mimo niższych średnich temperatur dnia i nocy.



Rysunek 5.72: Zachowanie systemu grzewczego dla strategii 5 i wymuszeniu równym  $+1^{\circ}\text{C}$  w dniach 8 i 9 stycznia TRM. Konstrukcja lekka.




Rysunek 5.73: Zachowanie systemu grzewczego dla strategii 5 i wymuszeniu równym  $+1^{\circ}\text{C}$  w dniach od 8 do 11 października TRM. Konstrukcja lekka.

Dla wymuszenia równego  $+1^{\circ}\text{C}$  roczne koszty ogrzewania wyniosły 355,2zł z czego 212,8zł przypada na taryfę nocną a 142,5zł na taryfę dzienną. Całkowite zużycie energii wyniosło 798,6kWh czyli praktycznie tyle samo co dla prostej strategii nadążnej.


### 5.4.2 Rola grubości wylewki oraz mocy zainstalowanej

W przypadku konstrukcji lekkiej najlepsze efekty osiągnięto dla strategii 5 (rys. 5.78). Minimum przypada dla mocy 200% i grubości 8cm. Różnice dla tej strategii sięgają 20%. Prawie identyczny koszt otrzymano dla podłogi o grubości 10cm i mocy 250% - różnica poniżej < 1%. Dla strategii pierwszej minimum przypadło dla mocy minimalnej i minimalnej grubości. W tej konfiguracji system charakteryzuje się najmniejszą bezwładnością i najłatwiej zapewnić temperaturę zadaną, choć koszty ogrzewania są największe. Dla strategii drugiej (rys. 5.75) minimum przypadło na grubość 16cm i minimalną moc. Tak podwyższona efektywna pojemność cieplna dopasowała się do charakterystyki pogodowej typowego roku meteorologicznego i pozwoliła na maksymalizację zużycia energii na tańszej taryfie.


Na wykresie (rys. 5.78) widać też optymalny zakres grubości wylewki dla konstrukcji lekkiej. Minimum kosztów przypada na grubości w zakresie od 8cm do 12cm przy mocach zainstalowanych na poziomie 250% - 300%




Rysunek 5.74: Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewania dla strategii 1. Konstrukcja lekka.



Rysunek 5.75: Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewania dla strategii 2. Konstrukcja lekka.




Rysunek 5.76: Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewania dla strategii 3. Konstrukcja lekka.




Rysunek 5.77: Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewania dla strategii 4. Konstrukcja lekka.





Rysunek 5.78: Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewania dla strategii 5. Konstrukcja lekka.



Rysunek 5.79: Koszty ogrzewania pomieszczenia w zależności od mocy zainstalowanej oraz grubości warstwy masywnej, w której znajduje się ogrzewania dla strategii 6. Konstrukcja lekka

## 5.5 Inteligentny termostat

W ramach pracy podjęto też próby wykorzystania metod sztucznej inteligencji opisanych w rozdziałach 2 i 3 do nauczenia się sterowaniem systemem grzewczym w celu osiągnięcia minimalnego kosztu ogrzewania przy zachowaniu akceptowalnego komfortu wewnątrz. Próby uczenia przeprowadzono dla każdej z konstrukcji oddzielnie. Poniżej przedstawiono wyniki uczenia prezentując działanie przykładowej wyuczonej strategii.


Eksperymenty przeprowadzono przy tych samych założeniach co strategii nadążno-programowalne tzn. dla tych samych konstrukcji i grubości wylewek betonowych .

Tabela 5.5: Zestawienie kosztów ogrzewania dla poszczególnych konstrukcji i strategii wyuczonych

Konstrukcja	Ekonomia						Komfort			
	Energia [kWh]			Koszt [zł]			Dzień		Noc	
	<i>I</i>	<i>II</i>	$\Sigma$	<i>I</i>	<i>II</i>	$\Sigma$	$T_{sr}$	$T_{std}$	$T_{sr}$	$T_{std}$
<b>lekka</b>	34,2	769,8	804,0	19,8	254,1	273,9	20,09	2,11	19,42	1,03
<b>średnio-ciężka</b>	0,0	805,0	805,0	0,0	265,6	265,6	21,00	1,05	19,65	1,03
<b>ciężka</b>	0,0	717,0	717,0	0,0	236,6	236,6	20,84	0,81	19,58	0,90

Istotną poprawę wyników uzyskano tylko dla konstrukcji lekkiej. Konstrukcja ciężka i średnio-ciężka, mimo że okazała się niepodatna na stosowane algorytmy sztucznej inteligencji to wydaje się mieć wciąż potencjał do obniżenia energii, ale stosunkowo niewielki. Wynika to z bardzo wolnych zmian temperatury wewnętrznej znacznie przekraczających czas trwania tańszej taryfy energii elektrycznej. Zatem gdy strategia nadążno-programowalna osiągnęła już 100% zużycie energii na tańszej taryfie, to jedyna szansa na obniżenie kosztu energii to obniżenie jej zużycia całkowitego a to jest trudne do osiągnięcia ze względu na zadane temperatury komfortu.

**Konstrukcja lekka** Na wykresach 5.81 i 5.82 przedstawiono efekty działania wyuczonej strategii dla konstrukcji lekkiej. Są to wyniki osiągnięte po 250 rocznych cyklach nauki przy wykorzystaniu danych pogodowych Typowego Roku Meteorologicznego dla Warszawy. Postępy uczenia zostały pokazane na wykresie 5.80. Widać, że uczeń na początku wykonuje działania całkowicie chaotycznie, co powoduje ciągłe załączanie ogrzewania i w związku z tym bardzo wysokie koszty. Z czasem koszty maleją i uczeń dochodzi do quasi optymalnej strategii. Trzeba zauważyć, że każda strategia jest nieco inna, a dalsze wykresy pokazują tylko jedną z nich.

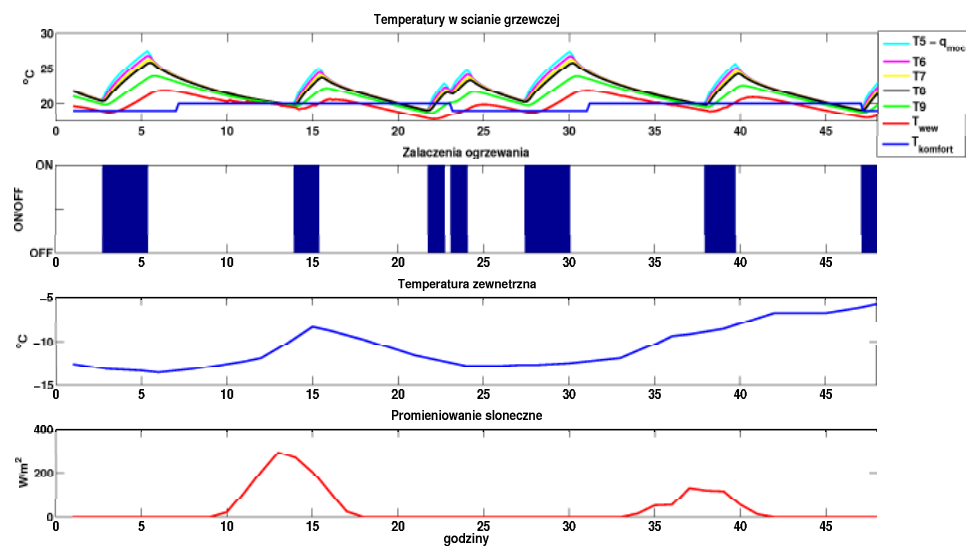


Rysunek 5.80: Krzywa uczenia inteligentnego termostatu. Konstrukcja lekka

Wyniki działania wyuczonej strategii przedstawiono na rysunkach 5.81, 5.82, 5.83. Termostat nauczył się włączać ogrzewanie w tańszej taryfie energii elektrycznej ale pozwala na większe spadki temperatury w ciągu dnia niż to miało miejsce dla najlepszej strategii nadażno-programowalnej. Na histogramie 5.83 można zaobserwować, że ok. 18% ma obniżone temperatury w przedziale  $[-2; -1.5]$  natomiast ok. 12% sezonu ma temperatury przekroczone o ponad 2 stopnie. Tylko około 45% czasu w pomieszczeniu jest temperatura dokładnie zadana. Na tle strategii nadażno-programowlanych nie jest to jednak zły wynik.

Na rysunku 5.84 przedstawiono koszty ogrzewania w zależności od grubości wylewki i mocy zainstalowanej dla wyuczonej strategii. Okazuje się, że dla tej strategii sterowania optymalne są mniejsze moce systemu grzewczego. Zakres optymalnych grubości nadal pozostaje powyżej 8cm, ale system działa dobrze również dla większych grubości wylewki. Nadal jednak wraz ze wzrostem mocy zainstalowanej i grubości wylewki rośnie koszt ogrzewania pomieszczenia.

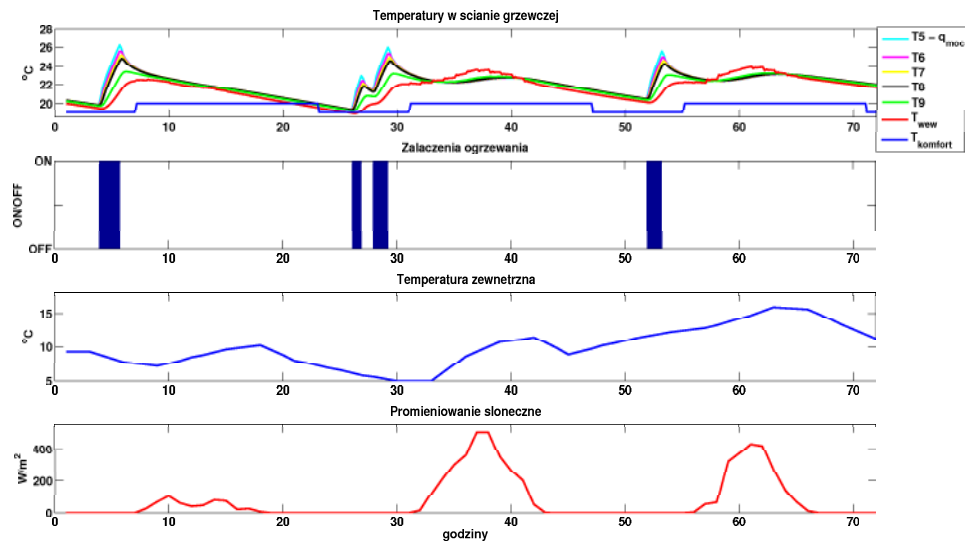
Porównując wykres 5.84 do wyników dla najlepszej strategii nadażno-programowalnej (rys. 5.78) otrzymujemy wykres obrazujący stopień poprawy strategii wyuczonej w stosunku do nadażno-programowalnej (rys.5.85). Strategia bardzo dobrze poradziła sobie z dużymi kosztami energii przy małych mocach zainstalowanych obniżając koszt ogrzewania przy 100% mocy zainstalowanej nawet o 30% jednak koszty ogrzewania są wciąż wyższe niż dla obszaru optymalnego dla tej konstrukcji. W tym zakresie tj. w przedziale 8cm-12cm i mocach na poziomie 250% – 350% poprawa nie jest już taka jednoznaczna. Dla przykładu dla 8cm i 250% mocy nastąpiło pogorszenie




Rysunek 5.81: Zachowanie systemu grzewczego dla wyuczonej strategii w dniach 8 i 9 stycznia TRM. Konstrukcja lekka

o ponad 2%. Dla 12cm i 200% grubości nastąpiła prawie 8% poprawa. Generalnie strategia działa gorzej dla bardzo dużych mocy zainstalowanych.


Dla konstrukcji lekkiej wyuczona strategia przynosi zatem znaczne obniżenie kosztu ogrzewania dla małych mocy zainstalowanych. Działanie strategii wiąże się z dużymi wahaniami temperatur wewnętrznych sięgających nawet  $2^{\circ}\text{C}$  przy zachowaniu średnich temperatur dnia i nocy bardzo zbliżonych do zadanych temperatur komfortu.




Rysunek 5.82: Zachowanie systemu grzewczego dla wyuczonej strategii w dniach od 8 do 11 października TRM. Konstrukcja lekka



Rysunek 5.83: Odchylenia od temperatury zadanej dla strategii wyuczonej. Konstrukcja lekka



Rysunek 5.84: Koszty ogrzewania dla różnych grubości wylewki i mocy zainstalowanych dla strategii wyuczonej. Konstrukcja lekka



Rysunek 5.85: Zmniejszenie kosztu ogrzewania dla różnych grubości wylewki i mocy zainstalowanych dla strategii wyuczonej. Konstrukcja lekka

# Rozdział 6

## Podsumowanie

W pracy przedstawiono wyniki symulacji numerycznych związanych z wykorzystaniem efektywnej pojemności cieplnej budynku do zmniejszenia kosztu ogrzewania pomieszczeń. Uzyskanie wyników było możliwe dzięki wykonaniu symulatora odzwierciedlającego zachowanie termiczne budynku. Przebadano zachowanie elementu grzejnego umieszczonego w masywnej przegrodzie np. w podłodze. Analizie poddano typowe strategie sterowania wykorzystujące dwutaryfowe rozliczanie kosztów energii elektrycznej. Wykazano ich wady i zalety oraz zakres stosowania. W ramach pracy zaproponowano również oryginalne połączenia dwóch metod sztucznej inteligencji - sieci neuronowych i algorytmów uczących się ze wzmocnieniem - do uczenia się optymalnego sterowania systemem grzewczym zatopionym w masywnej przegrodzie. Eksperymenty numeryczne doprowadziły do wskazania optymalnych parametrów konstrukcji budynków, które pozwalają najlepiej wykorzystać tanie źródła energii bez utraty komfortu przebywania w pomieszczeniach.

Na podstawie przeprowadzonych badań można sformułować następujące wnioski:

1. Efektywna pojemność cieplna ma znaczący wpływ na koszty ogrzewania pomieszczenia oraz komfort wyrażany przez przybliżenie do temperatur zadanych;
2. Silne ogrzewanie grubych warstw betonu wiąże się z utratą komfortu termicznego w pomieszczeniu i podwyższeniem zużycia energii w budynku. Mimo dużej pojemności cieplnej brak jest kontroli nad rozładowaniem zmagazynowanej energii, która zależy jedynie od aktualnego bilansu energii w pomieszczeniu;
3. Duża pojemność cieplna przegród nieogrzewanych znakomicie wpływa na stabilizację temperatur w pomieszczeniu i poprawia wykorzystanie zysków od energii słonecznej, czy źródeł wewnętrznych;
4. Duża efektywna pojemność cieplna pomieszczenia eliminuje możliwość dobowych zmian temperatury w pomieszczeniu np. obniżenia nocnego;

5. Sterowanie ogrzewaniem wymuszające wykorzystanie tańszej taryfy energii elektrycznej pozwala obniżyć koszty ogrzewania o 40% przy jednoczesnym wzroście zużycia energii do 6%

### Zalecenie projektowe:

1. Dobieranie mocy ogrzewania proporcjonalnie do faktycznego zapotrzebowania - powszechne praktyki projektowe polegające na dobieraniu mocy ogrzewania bardzo zgrubnie i wiara, że termostaty wyregulują temperaturę, tak jak to się dzieje przy tradycyjnych grzejnikach może skończyć się przegrzewami pomieszczeń;
2. Wykorzystanie tańszej taryfy energii elektrycznej wymaga instalowania większej mocy niż to wynika z normy PN12831. Pełne wykorzystanie tańszej taryfy wiąże się z instalacją mocy proporcjonalną do liczby godzin z tańszą taryfą. Dla warunków Zakładu Warszawa-Teren ta wartość wynosi  $24h/10h = 2.4$ . Na podstawie przeprowadzonych badań można przyjąć następujące wartości:

Tabela 6.1: Zestawienie optymalnej mocy ogrzewania i grubości wylewki dla poszczególnych konstrukcji.

Konstrukcja	Moc [%]	Grubość wylewki [cm]
<b>ciężka</b>	200 - 300	4 - 8
<b>średnio-ciężka</b>	250 - 350	6 - 10
<b>lekka</b>	250 - 350	8 - 12

3. Wykonywanie ogrzewania w bardzo grubych wylewkach, np. w płycie fundamentowej, powoduje podniesienie średniej temperatury pomieszczeń, co jest szczególnie widoczne przy zainstalowaniu dużej mocy ogrzewania. Budynek z taką pogłogą grzejną dla każdej z konstrukcji powodował wyższy koszt ogrzewania pomieszczenia.

Warto zauważyć, że powyższe zalecenia szczególnie łatwo spełnić dla budownictwa energooszczędnego, za względu na małe jednostkowe zapotrzebowanie na moc. Trzeba też dodać, że moc zainstalowana nie będzie w praktyce równa mocy emitowanej przez ogrzewanie podłogowe. Jest to moc używana chwilowo do naładowania magazynu w postaci masywnej wylewki. Energia zmagazynowana jest później oddawana w zdecydowanie dłuższym czasie, dzięki czemu temperatury powierzchni podłogi mogą pozostać na akceptowalnym poziomie. Oczywiście załączenie mocy zainstalowanej cały czas może doprowadzić do przekroczenia dozwolonych temperatur powierzchni podłogi a nawet do jej uszkodzenia. Dlatego w praktyce powinny



być instalowane dodatkowe czujniki temperatury wylewki, które wyłączą ogrzewanie w razie przegrzewu.

Pogrubianie wylewki betonowej, w której znajduje się ogrzewanie podłogowe, powoduje też zwiększenie efektywnej pojemności cieplnej pomieszczeń. Trzeba jednak jeszcze raz podkreślić, że pogrubienie warstwy nagrzewanej bez kontroli nad jej rozładowywaniem wcale nie wpływa na zmniejszenie kosztu ogrzewania, natomiast powoduje pogorszenie komfortu wewnętrznego pomieszczenia.

**Metody sztucznej inteligencji.** W ramach pracy wykonano bardzo dużą liczbę eksperymentów związanych z wykorzystaniem metod sztucznej inteligencji do sterowania ogrzewaniem podłogowym. Dla ciężkiej konstrukcji i średnio-ciężkiej nie udało się uzyskać obniżenia kosztów ogrzewania. Zmniejszenie kosztu wyniosło poniżej 1%, a dla niektórych mocy wręcz uległo pogorszeniu, ale nie większemu niż 4%. Te dwie konstrukcje charakteryzują się bardzo dużą efektywną pojemnością cieplną. W związku z tym zmiany temperatur są bardzo powolne - jest to efekt przeładowania dużej pojemności. Dla takich konstrukcji testowane metody sztucznej inteligencji nie sprawdziły się. Sytuacja ma się inaczej dla konstrukcji lekkiej. Tutaj szczególnie dla mocy zbliżonych do zapotrzebowania zgodnego PN12831 uzyskano bardzo dużą poprawę. Koszty ogrzewania spadły nawet o 30% osiągając koszty ogrzewania większe tylko o ok.13% niż dla konstrukcji ciężkiej. Dla większych mocy ten efekt nie był już tak zauważalny. Dla przewymiarowania mocy zainstalowanej do ponad 500% wyniki ulegały wręcz pogorszeniu lub nie poprawiały się.

Inteligentne sterowanie bezwładnościowymi systemami grzewczymi, wykorzystującymi metody sztucznej inteligencji, ma zatem duży potencjał do poprawy działania tych systemów, szczególnie gdy charakteryzują się one stosunkowo małą efektywną pojemnością cieplną.

**Kierunki dalszych prac.** Wykorzystanie metod sztucznej inteligencji do zarządzania energią w budynku jest tematem nowym i wprowadzającym nowe możliwości w dziedzinie obniżania kosztu ogrzewania pomieszczeń. W pracy przedstawiono wstępne, bardzo zachęcające wyniki działania inteligentnego termostatu sterującego ogrzewaniem podłogowym. Dalsze badanie powinny skupiać się przede wszystkim na dopracowaniu szybkiego symulatora, umożliwiającego szybką weryfikację różnych metod sztucznej inteligencji do omawianego zagadnienia wraz z różnymi postaciami reprezentacji stanu dla systemu uczącego się. Jest to wciąż niewystarczająco zbadana dziedzina i na pewno możliwe jest dalsze doskonalenie strategii sterowania. Kolejnym krokiem powinno być wdrożenie opracowanych metod do rzeczywistego systemu sterującego. Po uzyskaniu pomyslnych wyników testów w rzeczywistych warunkach można myśleć o jego wdrożeniu do produkcji.

# Bibliografia

- [1] R.E. Abdel-Aal: Hourly temperature forecasting using abductive networks. *Engineering Applications of Artificial Intelligence* 17 (2004) 543–556
- [2] Athienitis A.K., Chen Y.: The effect of solar radiation on dynamic thermal performance of floor heating systems. *Solar Energy* Vol. 69, pp229-237, 2000
- [3] Asakawa K, Takagi H.: Neural networks in Japan. *Communications of the ACM* 1994;37(3):106–12.
- [4] I. Andresen, M. Brandemuehl: Heat storage in building thermal mass: a parametric study. *ASHRAE Transactions* 98 (2) (1992) 910–918.
- [5] Anderson CW, Hittle D, Kretchmar M, Young P.: Robust reinforcement learning for heating, ventilation and air conditioning control of buildings. In: Si J, Barto AG, Powell WB, Wunsch DII, editors. *Handbook of learning and approximate dynamic programming*. IEEE Press/Wiley Interscience; 2004. p. 517–34.
- [6] Argirioua A.A , Bellas-Velidisb I., Kummertc M., Andre P.: A neural network controller for hydronic heating systems of solar buildings. *Neural Networks* 17 (2004) 427–440
- [7] Argirioua A.A , Bellas-Velidisb I., Balarasa C.A.: Development of a neural network heating controller for solar buildings. *Neural Networks* 13 (2000) 811-820
- [8] ASHRE handbook 2005: HVAC Fundamentals. ASHRE 2009
- [9] ASHRE Standards 62.2-2003: Ventilation and acceptable indoor air quality in low-rise residential buildings. ASHRE 2003.
- [10] Balaras C.A.: The role of thermal mass on the cooling load of buildings. An overview of computational methods *Energy and Buildings* 24, 1996
- [11] Burghes D, Graham A.: *Introduction to control theory including optimal control*. Ellis Horwood Ltd.; 1980.

- 
- [12] B.Y.H. Liu, R.C. Jordan: Daily Insolation on Surfaces Tilted Toward the Equator ASHRAE 3 (10), 53, 1962
- [13] B.Y.H. Liu, R.C. Jordan: The Interrelationship and Characteristic Distribution of Direct, Diffuse and Total Solar Radiation Solar Energy 4, 1960
- [14] J. Braun: Load control using building thermal mass. Journal of Solar Energy Engineering 125 (3) (2003) 292–301.
- [15] J.E. Braun: Reducing energy costs and peak electrical demand through optimal control of building thermal mass. ASHRAE Transactions 96 (2) (1990) 876–888.
- [16] Calvino F, Gennusca ML, Rizzo G, Scaccianoce G.: The control of indoor thermal comfort conditions: introducing a fuzzy adaptive controller. Energy and Buildings 2004;36:97–102.
- [17] Chi-Chi Lin, Kuo-Pin Yu, Ping Zhao, Grace Whei-May Lee : Evaluation of impact factors on VOC emissions and concentrations from wooden flooring based on chamber tests. Building and Environment 44 (2009) 525–533
- [18] Clarke J.A.: Energy Simulation in Building Design. Butterworth-Heinemann 2001
- [19] Crank, J., P. Nicolson : A practical method for numerical evaluation of solutions of partial differential equations of the heat conduction type. Proc. Camb. Phil. Soc. 43: 50–67, (1947).
- [20] Curtis PS, Shavit G, Kreider K.: Neural networks applied to buildings—a tutorial and case studies in prediction and adaptive control. ASHRAE Transactions 1996;102(1).
- [21] Chen T.: Real-time predictive supervisory operation of building thermal systems with thermal mass. Energy and Buildings 2001;33(2):141–50.
- [22] J.P. Conniff: Strategies for reducing peak air-conditioning loads by using heat storage in the building structure. ASHRAE Transactions 97 (1) (1991) 704–709.
- [23] Dalamagkidis K, Kolokotsa D, Kalaitzakis K, Stavrakakis GS. Reinforcement learning for energy conservation and comfort in buildings. Building and Environment 2007;42(7):2686–98.
- [24] Deschamps G.: European Energy Consumption. Meeting of the Enerbuild network in Malmo, Sweden (2001)
- [25] Diekmann B., Heinloth K.: Energie. Teubner Verlag, 1997

- [26] Domański R.: Magazynowanie energii cieplnej. PWN, 1990
- [27] Dounis AI, Manolakis DE.: Design of a fuzzy system for living space thermal-comfort regulation. *Applied Energy* 2001;69:119–44.
- [28] T.G. Doeswijk; K.J. Keesman: Adaptive Weather Forecasting using Local Meteorological Information. *Biosystems Engineering*, 2005 421-431
- [29] Dounis AI, Bruant M, Santamouris MJ, Guarrancino G, Michel P.: Comparison of conventional and fuzzy control of indoor air quality in buildings. *Journal of Intelligent & Fuzzy Systems* 1996;4(2):131–40.
- [30] Dounis AI, Manolakis DE.: Design of a fuzzy system for living space thermal-comfort regulation. *Applied Energy* 2001;69:119–44.
- [31] Dincer I, Rosen M.A. : Thermal Energy Storage System and Application. WILEY 2002
- [32] J. A. Duffie, W.A. Beckman: Solar engineering of thermal processes Wiley 2006
- [33] Dzieniszewski W., Wnuk R. : Termodynamika strukturalnego zasobnika ciepła z pełnym przebiegiem przemiany fazowej złoża PCM w fazach ładowania i rozładowania w cyklu dobowym. XI Konferencja „Fizyka Budowli w Teorii i Praktyce”, Łódź 2007
- [34] EnergyPlus Energy Simulation Software, <http://www.eere.energy.gov>
- [35] Emmerich SJ, Persily AK. : State of the art review of CO2 demand controlled ventiaition technology and application. National Instiute of Standards and Technology, California Energy Commission, Technical report (demand-controlled ventiaition assessment). 2003
- [36] Feist W., Munzenberg U., Thumulla J., Darup B.S., Schlagowski G.: Podstawy budownictwa pasywnego PIBP, Gdańsk 2007
- [37] Fanger P.O. : Thermal comfort: Analysis and aplications in environmental engineering. New York, McGraw-Hill 1972
- [38] Gawin D., Kossecka E.: Typowy rok meteorologiczny do symulacji wymiany ciepła i masy w budynku. Politechnika Łódzka, Łódź (2002)
- [39] Haghghat F., Huang H. : Integrated IAQ model for prediction of VOC emissions from building material *Building and Environment* 38 (2003) 1007 – 1017
- [40] Hagentoft C.E: Introduction to Building Physics. Studentlitteratur 2003

- [41] Heim D. : Two solution methods of heat transfer with phase change within whole building dynamic simulation. 9th IBPSA Conference, Montreal 2005
- [42] Henze G.P., Pfafferott J., Herkel S., Felsmann C.: Impact of adaptive comfort criteria and heat waves on optimal building mass control *Energy and Buildings* 39, 2007
- [43] House J, Smith T.: A system approach to optimal control for HVAC and building systems. *ASHRAE Transactions* 1995;101(2):647–60.
- [44] R.Holopainen, P.Tuomaala, J.Piippo: Uneven gridding of thermal nodal networks in floor heating simulations *Energy and Building* 39 (2007) 1107-1114
- [45] ISO 7730: Moderate thermal environment-determination of the PMV and PPD indices and specification of the conditions for thermal comfort. 1994
- [46] Inoue T, Kawase T, Ibamoto T, Takakusa S, Matsuo Y.: The development of an optimal control system for window shading devices based on investigations in office buildings. *ASHRAE Transactions* 1998;104:1034–49.
- [47] Kandil N., Wamkeue R., Saad M., Georges S.: An efficient approach for short term load forecasting using artificial neural networks *Electrical Power and Energy Systems* 28 (2006) 525–530
- [48] Kanarachos A, Geramanis K.: Multivariable control of single zone hydro-  
nic heating systems with neural networks. *Energy Conversion Management* 1998;13(13):1317–36.
- [49] K.R. Keeney, J. Braun: A simplified method for determining optimal cooling control strategies for thermal storage in building mass. *International Journal of HVACR Research* 2 (1) (1996) 59–78.
- [50] Kisielewicz T. : Wpływ izolacyjnych, dynamicznych i spektralnych właściwości przegród na bilans cieplny budynków energooszczędnych Politechnika Krakowska, 2008
- [51] Kossecka E., Kosny J.: Influence of insulation configuration n heating and cooling loads in a continuously used building *Energy and Building* 34, 2002
- [52] Kossecka E., Walczak T.: Szacowanie wydajności hybrydowej instalacji solarno-wiatrowej dla domu jednorodzinnego w warunkach klimatu Polski. *Zeszyty Naukowe Politechniki Rzeszowskiej Nr 229, Budownictwo i Inżynieria Środowiska z. 40, 277-282, Rzeszów 2006.*
- [53] Kossecka E., Walczak T.: Wydajność instalacji fotowoltaicznych w warunkach klimatu Polski. *Fizyka Budowli w Teorii i Praktyce, t. II, 2007, 141-146.*

- [54] Kossecka E., Walczak T.: Wydajność instalacji fotowoltaicznych w warunkach klimatu Polski. Materiały Konferencyjne – Streszczenia XI Polskiej Konferencji Fizyka Budowli w Teorii i Praktyce, Łódź'2007, 73-74.
- [55] Kosny J., Kossecka E.: Multi-dimensional heat transfer through complex building envelope assemblies in hourly energy simulation programs *Energy and Buildings* 34 2002
- [56] Kummert M, Andre P, Nicolas J.: Optimal heating control in a passive solar commercial building. *Solar Energy* 2001;69(Nos. 1–6):103–16.
- [57] Lam HN.: Stochastic modeling and genetic algorithm based optimal control of air conditioning systems. *Building Simulation* 1993;435–41.
- [58] Liu S., Henze G.P.: Experimental analysis of simulated reinforcement learning control for active and passive building thermal storage inventory Part 1. Theoretical foundation. *Energy and Buildings* 38 (2006) 142–147
- [59] Liu S., Henze G.P.: Experimental analysis of simulated reinforcement learning control for active and passive building thermal storage inventory Part 2: Results and analysis. *Energy and Buildings* 38 (2006) 148–161
- [60] Lopez L, Sanchez, Doctor F, Hagrass H, Callaghan V.: An evolutionary algorithm for the off-line data driven generation of fuzzy controllers for intelligent buildings. In: *Systems, man and cybernetics, 2004 IEEE international conference on volume 1; 2004.p. 42–7.*
- [61] Lute PJ, Paassen VAH.: Predictive control of indoor temperatures in office buildings energy consumption and comfort. In: *Clima 2000; 1989.*
- [62] H. Lundstedt: Progress in space weather predictions and applications. *Advances in Space Research* 36, 2005 2516-2523
- [63] H. Lundstedt: Solar activity modelled and forecasted: A new approach. *Advances in Space Research* 38 (2006) 862–867
- [64] Levermore GJ. *Building energy management systems: an application to heating and control.* London: E & FN SPON; 1992.
- [65] Maqsooda I., Khanb M.R., Huanga G.H., Abdallac R.: Application of soft computing models to hourly weather analysis in southern Saskatchewan, Canada *Engineering Applications of Artificial Intelligence* 18 (2005) 115–125
- [66] T. Masters: *Practical Neural Network Recipes in C++.* London, Academic Press 1993

- [67] M.F. Moller: A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning. *Neural Networks Vol.6* 1993
- [68] Morel N, Bauer M, El-Khoury, Krauss J.: Neurobat, a predictive and adaptive heating control system using artificial neural networks. *International Journal of Solar Energy* 2000;21:161–201.
- [69] H. R. Maier, G. C. Dandy: Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environmental Modelling & Software* 15, 2000 101-124
- [70] I. Maqsood, M. R. Khan, A. Abraham: An ensemble of neural networks for weather forecasting. *Neural Computing & Applications*, 2004 112-122
- [71] I. Maqsood, A. Abraham: Weather analysis using ensemble of connectionist learning paradigms. *Applied Soft Computing* 7 (2007) 995–1004
- [72] I. Maqsooda, M. R. Khanb, G. H. Huang, R. Abdalla: Application of soft computing models to hourly weather analysis in southern Saskatchewan, Canada. *Engineering Applications of Artificial Intelligence* 18 (2005) 115–125
- [73] Arthur Mac JW, Grald EW.: Optimal comfort control for variable-speed heat pumps. *ASHRAE Transactions* 1998;94:1283–97.
- [74] Minkowycz W.J., Sparrow E.M., Murthy J.Y.: *Handbook of Numerical Heat Transfer*. Wiley 2006
- [75] Milanic S, Karba R.: Neural network models for predictive control of a thermal plant. In: *Proceedings of the international conference on EANN'96*; 1996. p.151–4.
- [76] F.B. Morris, J.E. Braun, S.J. Treado: Experimental and simulated performance of optimal control of building thermal storage. *ASHRAE Transactions* 100 (1) (1994) 402–414.
- [77] S.Osowski: *Sieci neuronowe*. Warszawa, OWPW 1994.
- [78] S.Osowski: *Sieci neuronowe w ujęciu algorytmicznym*. Warszawa, WNT 1996.
- [79] Paassen AH, Liem SH, Lute PJ.: Digital control systems for passive solar buildings. In: *CEC-Project Pastor*; 1990.
- [80] Pfafferott J., Herkel S., Kalz D.E., Zeuschner A.: Comparison of low-energy office buildings in summer using different thermal comfort criteria *Energy and Buildings* 39 2007

- [81] A. Rabl, L.K. Norford: Peak load reduction by preconditioning buildings at night. *International Journal of Energy Research* 15 (1991) 781–798.
- [82] Redlich C.A., Sparer J.: Sick building syndrom. *Lancet* 1997
- [83] Strom I., Joosten L., Boomstra Ch.: *Passive House Solutions, Promotion of European Passive House Project Intelligent Europe Programme* 2006
- [84] Singh J, Singh N, Sharma JK.: Fuzzy modelling and control of HVAC systems—a review. *Journal of Scientific and Industrial Research* 2006;65(6):470–6.
- [85] Teeter J, Chow MY.: Application of functional link neural network to HVAC thermal dynamic system identification. *IEEE Transactions on Industrial Electronics* 1998;45(1):170–6.
- [86] Tuohy P., McElroy L., Johnstone C.: Thermal mass, insulation and ventilation in sustainable housing - an investigation across climate and occupancy. 9th International IBSA Conference, Montreal (2005)
- [87] Wachenfeldt B.J., Mysen M., Schild P.G.: Air flow rates and energy saving potential in school with demand-controlled displacement ventilation. *Energy and Building* 39, 2007
- [88] Walczak T., Kossecka E.: Hybrydowa instalacja solarno - wiatrowa dla energooszczędnego domu jednorodzinnego. *Fizyka Budowli w Teorii i Praktyce*, tom 1, 338-345 (2005).
- [89] Walczak T. : Hybrydowa instalacja słoneczno - wiatrowa z turbiną typu Savoniusa. *Polska Energetyka Słoneczna* Nr 3-4/2005, 35-40.
- [90] Walczak T., Cichosz P.: A Distributed Learning Control System for Elevator Groups. *Lecture Notes in Computer Science* 4029, 1226-1232, 2006.
- [91] Walczak T. : Analiza symulacyjna funkcjonowania hybrydowej instalacji słoneczno – wiatrowej z buforem energii. *Zeszyty Naukowe Politechniki Rzeszowskiej* Nr 229, *Budownictwo i Inżynieria Środowiska* z. 40, 531-538, Rzeszów 2006.
- [92] Walczak T., Kossecka E.: Productivity of wind turbines in the Central Poland region. V Symposium *Environmental Effects on Buildings and People - actions, influences, interactions, discomfort*, Kazimierz Dolny, Poland, October 24-27, 2007
- [93] Walczak T., Kossecka E.: Productivity of wind turbines in the Central Poland region. Monografia “*Environmental Effects on Buildings and People - actions, influences, interactions, discomfort*”, Wyd. Pol. Lub. 2007, 241-246.



- 
- [94] Walczak T.: Wykorzystanie metod sztucznej inteligencji do zarządzania energią w budynku. Zeszyty Naukowe Politechniki Rzeszowskiej Budownictwo i Inżynieria Środowiska, Rzeszów 2008.
- [95] Walczak T.: Dom z pompą. Ładny Dom, marzec 2006, 75-78.
- [96] Walczak T.: Czy warto mieć pompę ciepła. Ładny Dom, marzec 2007, 71-76.
- [97] Wang S, Jin X.: Model-based optimal control of VAV air-conditioning system using genetic algorithms. Building and Environment 2000;35:471-87.
- [98] Wnuk R.: Budowa domu pasywnego w praktyce. Przewodnik Budowlany (2006)
- [99] Veld P.O.: Introduction to EC RESHYVENT-EU cluster project on demand controlled hybrid ventilation for residential buildings. Building and Environment 43 (2008) 1342-1349
- [100] Zaheer-uddin M, Zheng GR.: Optimal control of time scheduled heating, ventilating and air conditioning processes in buildings. Energy Conversion and Management 2000;41:49-60.