

Jarosław Grochowalski

Optymalizacja pracy kotła fluidalnego  
uwzględniającego zużycie erozyjne,  
zwiększająca dyspozycyjność jednostki w  
aspekcie uciepłownienia bloku energetycznego

Rozprawa doktorska

Promotor:

dr hab. inż. Bartłomiej Hernik, prof. PŚ

Dyscyplina naukowa:

Inżynieria Środowiska, Górnictwo i Energetyka

Politechnika Śląska

Gliwice, 2022



# Spis treści

<b>Podziękowania</b> . . . . .	<b>7</b>
<b>Wykaz skrótów</b> . . . . .	<b>9</b>
<b>1. Wprowadzenie</b> . . . . .	<b>11</b>
1.1. Uwarunkowania środowiskowe . . . . .	11
1.2. Analizowany obiekt . . . . .	14
1.3. Pomiar diagnostyczny . . . . .	20
1.4. Cel Pracy . . . . .	28
1.5. Przegląd literatury . . . . .	29
1.6. Opis koncepcji . . . . .	31
1.7. Zakres rozprawy . . . . .	32
<b>2. Model Predykcyjny</b> . . . . .	<b>35</b>
2.1. Sieci neuronowe . . . . .	35
2.2. Korelacja danych . . . . .	38
2.3. Model Predykcyjny . . . . .	42
2.3.1. Zasada działania modelu do predykcji temperatury . . . . .	44
2.3.2. Dane do nauki sieci neuronowych . . . . .	46
2.3.3. Architektura Modelu Predykcyjnego . . . . .	47
2.4. Testy obiektowe . . . . .	68
2.4.1. Pierwszy test na obiekcie . . . . .	71
2.4.2. Drugi test na obiekcie . . . . .	75
<b>3. Obliczenia numeryczne</b> . . . . .	<b>81</b>
3.1. Model numeryczny analizowanego kotła fluidlanego . . . . .	82
3.1.1. Siatka numeryczna modelu . . . . .	84
3.2. Przyjęty model matematyczny . . . . .	85
3.3. Walidacja modelu . . . . .	89
3.4. Obliczenia erozji . . . . .	89
3.4.1. Przypadek 1 . . . . .	94

---

3.4.2. Przypadek 2 . . . . .	100
<b>4. Podsumowanie . . . . .</b>	<b>107</b>
<b>Bibliografia . . . . .</b>	<b>110</b>
<b>Dodatek A. Kod źródłowy modelu do predykcji temperatury na ruszcie analizowanego kotła fluidalnego . . . . .</b>	<b>117</b>
<b>Dodatek B. Kod źródłowy obliczający błąd średniokwadratowy rozkładu temperatury na ruszcie analizowanego kotła fluidalnego . . . . .</b>	<b>121</b>
<b>Dodatek C. Kod źródłowy klasy, służącej do zmiany ilości paliwa i powietrza wtórnego dostarczanego do komory paleniskowej analizowanego kotła fluidalnego . . . . .</b>	<b>123</b>
<b>Streszczenie . . . . .</b>	<b>128</b>

# Contents

<b>Acknowledgments</b> . . . . .	<b>7</b>
<b>Symbols</b> . . . . .	<b>9</b>
<b>1. Introduction</b> . . . . .	<b>11</b>
1.1. Environmental permits . . . . .	11
1.2. Analyzed object . . . . .	14
1.3. Boiler Diagnostic . . . . .	20
1.4. Objectives . . . . .	28
1.5. Literatura . . . . .	29
1.6. Idea Description . . . . .	31
1.7. Outline of the thesis . . . . .	32
<b>2. Prediction Model</b> . . . . .	<b>35</b>
2.1. Neuron network . . . . .	35
2.2. Data Correlation . . . . .	38
2.3. Prediction Model . . . . .	42
2.3.1. The principle of operation of the temperature prediction model . . .	44
2.3.2. Data for learning neural networks . . . . .	46
2.3.3. Predictive model architecture . . . . .	47
2.4. On-site tests . . . . .	68
2.4.1. First on-site test . . . . .	71
2.4.2. Second on-site test . . . . .	75
<b>3. CFD Calculation</b> . . . . .	<b>81</b>
3.1. Fluidized bed boiler numeric model . . . . .	82
3.1.1. Numerical mesh . . . . .	84
3.2. Mathematic model . . . . .	85
3.3. Model validation . . . . .	89
3.4. Erosion calculation . . . . .	89
3.4.1. Case 1 . . . . .	94

3.4.2. Case 2 . . . . .	100
<b>4. Summary . . . . .</b>	<b>107</b>
<b>Bibliography . . . . .</b>	<b>110</b>
<b>Abstract . . . . .</b>	<b>130</b>

## Podziękowania

Rozprawa doktorska została zrealizowana w ramach doktoratu wdrożeniowego realizowanego ze środków finansowych programu Ministra Nauki i Szkolnictwa Wyższego pn. „Doktorat wdrożeniowy” ustanowionego zgodnie z postanowieniami art. 26 ust. 3f i nast. ustawy z dnia 30 kwietnia 2010 r. o zasadach finansowania nauki (t.j. Dz.U. z 2016 r. poz. 2045 ze zm., zwaną dalej „FNU”) oraz na podstawie Rozporządzenia Ministra Nauki i Szkolnictwa Wyższego w sprawie szczegółowych kryteriów i trybu przyznawania, przekazywania oraz rozliczania środków finansowych na naukę, trybu wyznaczania opiekuna pomocniczego i przyznawania stypendium doktoranckiego w ramach programu „Doktorat wdrożeniowy” z dnia 28 kwietnia 2017 r. (Dz.U. z 2017 r. poz. 873).

Rozprawa powstała dzięki współpracy przemysłu - firmy Tauron Wytwarzanie S.A. oraz jednostki szkolnictwa wyższego - Politechniki Śląskiej w Gliwicach. Włożony nakład pracy zwiększy dyspozycyjność eksploatowanej jednostki wytwórczej energii elektrycznej.

Serdeczne podziękowania dla kolegów z pracy oraz Politechniki Śląskiej za wsparcie swoją wiedzą i doświadczeniem.

Dziękuję mojemu promotorowi dr hab. inż. Bartłomiejowi Hernik, prof. PŚ oraz Panu mgr inż. Stanisławowi Noworycie, za pomoc przy realizacji pracy.

Na koniec serdeczne podziękowania dla prof. dr hab. inż. Wojciecha Adamczyk, dzięki którego pomocy i zaangażowaniu udało się rozwiązać napotkane problemy i zakończyć sukcesem moją przygodę z doktoratem.

Dziękuję mojej rodzinie za wsparcie oraz wyrozumiałość przez cały okres studiów.

## Wykaz publikacji

### Wykaz publikacji stanowiących wkład w powstanie niniejszej książki

- J. Grochowalski, B. Hernik, A. Skorek-Osikowska: Analiza zużycia erozyjnego rur ścian ekranowych w kotle fluidalnym, *Rynek Energii* 3 (2019) 47–54.
- J. Grochowalski, P. Jachymek, M. Andrzejczyk, M. Klajny, A. Widuch, P. Morkisz, B. Hernik, J. Zdeb, W. Adamczyk: Towards application of machine learning algorithms for prediction temperature distribution within CFB boiler based on specified operating conditions, *Energy* 2021, Vol. 237, <https://doi.org/10.1016/j.energy.2017.10.029>.



## Wykaz skrótów

ACF	Powietrze do podajników węgla	ML	Machine Learning
AdaGrad	Adaptive gradient algorithm	MSE	Mean Squared Error
Adam	Adaptive Moment Estimation	NADAM	Nesterov-accelerated Adaptive Moment Estimation
AI	Artificial Intelligence	NSAB	Nadrzędny regulator bloku
AKPiA	Aparatura kontrolno pomiarowa i automatyka	OB	Palnik rozpałkowy
ANN	Artificial Neural Network	PA	Powietrze pierwotnego do Windbox
By-pass	Objęściowy podgrzewacz powietrza	PAF	Wentylator powietrza pierwotnego
Eco		R <sup>2</sup>	Współczynnik determinacji
CF	Podajnik węgla	RAHP	Rotary Air Preheater
CFB	Circulating Fluidized Bed	RD	Przepustnica regulacyjna
CFD	Computational Fluid Dynamicce	RMSE	Root Mean Square Error
DCS	Distributed Control System	RMSProp	Root Mean Square Propagation
DDPM	Dense Discrete Phase Mode	SA	Dysze powietrza wtórnego na poziomie +2,4,6 m
FM	Przepływomierz powietrza	SAF	Wentylator powietrza wtórnego
HEL	Hybrydowa metoda Eulera-Lagrange'a	SDG	Stochastic gradient descent
IT	Information technology	UDF	User Defined Function
KSE	Krajowy System Energetyczny	UMC	Unit Master Controller
KTGF	Kinetic theory of granular flow	Windbox	Skrzynia powietrza pierwotnego
LSSVM	Least-squares support-vector machines		
MAE	Mean absolute error		



## Wprowadzenie

Energetyka zawodowa w Polsce oparta jest o paliwa kopalne. Wzrastające wymagania dotyczące ograniczeń w emisji [3] dla paliw kopalnych wynikające z chęci ochrony klimatu, postępujący w coraz szybszym tempie *Zielony Zwrot* [78], czy konieczność zapewnienia stabilnej mocy do systemu energetycznego to tylko część wyzwań z jakimi musi się zmierzyć energetyka. Pomimo szybkiego wzrostu udziału produkcji energii elektrycznej z odnawialnych źródeł energii, Polska wciąż zależna jest od produkcji energii z paliw kopalnych (głównie z węgla), której udział w produkcji energii elektrycznej w 2021 roku wyniósł 81% [71].

Energetyka konwencjonalna to główne źródło emisji dwutlenku węgla CO<sub>2</sub> (obok transportu, przemysłu i rolnictwa), stąd tak duże znaczenie, aby podstawowymi jednostkami wytwórczymi energii elektrycznej były nowoczesne jednostki wytwórcze, o wysokiej sprawności wytwarzania energii elektrycznej.

Rozprawa doktorska przedstawia możliwość optymalizacji jednego z najnowocześniejszych bloków energetycznych, oddanego do eksploatacji w 2009 roku o mocy elektrycznej 460 MWe należący do spółki Tauron Wytwarzanie S.A., zlokalizowany w Elektrowni Łagisza. Sprawność wytwarzania energii elektrycznej tego bloku wynosi brutto 45%, a jednostką wytwórczą pary jest przepływowy kocioł fluidalny na parametry nadkrytyczne.

### 1.1. Uwarunkowania środowiskowe

Jednym z głównych tematów obecnych w przestrzeni społecznej jest dbałość o środowisko i przeciwdziałanie zachodzącym zmianom klimatu. Temat w znacznej mierze dotyczy energetyki konwencjonalnej opartej o paliwa kopalne, jako głównemu odpowiedzialnemu za emisje zanieczyszczeń, w tym emisję gazu cieplarnianego CO<sub>2</sub>. W 2021 roku zmieniły się przepisy określające dopuszczalną emisję zanieczyszczeń, ograniczając dopuszczalne limity emisji przez energetykę węglową, zgodnie z Decyzją Wykonawczą Komisji (UE) 2021/2326 z dnia 30 listopada 2021r. [3].

Przyjęte ustalenia odnośnie emisji wprowadziły m.in. bardziej restrykcyjne wymogi dla zanieczyszczeń pyłowo – gazowych takich jak: SO<sub>2</sub>, NO<sub>x</sub>, pyłów (Tab. 1.1) oraz dodatkowo dla takich substancji jak Hg, HCl, HF, NH<sub>3</sub>. Blok energetyczny wyposażony w kocioł fluidalny jest w stanie spełnić najnowsze wymagania limitów emisji z 2021 roku

bez konieczności realizacji dodatkowych inwestycji związanych z zabudową dodatkowych instalacji odsiarczania czy odazotowania spalin.

Tabela 1.1

Standard emisyjny dla bloku 460 MWe w Elektrowni Łagisza zgodnie z Decyzją Wykonawczą Komisji (UE) 2021/2326 z dnia 30 listopada 2021r [3]

	SO <sub>2</sub> , mg/m <sup>3</sup> <sub>u</sub>	NO <sub>2</sub> , mg/m <sup>3</sup> <sub>u</sub>	Pył, mg/m <sup>3</sup> <sub>u</sub>
Kocioł w Elektrowni Łagisza	200	200	20

Proces odsiarczania spalin w analizowanym kotle fluidalnym realizowany jest bezpośrednio w komorze paleniskowej. W dolnej części analizowanego kotła na bocznych ścianach leżą komory paleniskowej zabudowanych jest po 6 wlotów sorbentu (mączki kamienia wapiennego CaCO<sub>3</sub>) na prawej i lewej ścianie. Intensywna fluidyzacja materiału złoża, węgla oraz sorbentu oraz niska temperatura spalania (850÷900°C) sprzyja procesowi odsiarczania bezpośrednio w komorze paleniskowej. Proces odsiarczania w komorze paleniskowej pozwala na usunięcie około 90% związków siarki już w trakcie procesu spalania [13].

Niskie temperatury procesu spalania w kotłach fluidalnych (850÷900°C) mocno ograniczają tworzenie się „termicznych” NO<sub>x</sub>, tym samym zmniejszając emisję NO<sub>x</sub> w porównaniu do kotłów pyłowych, w których temperatura w paleniskach osiąga wartość 1400÷1600°C. Analizowany kocioł fluidalny posiada zabudowaną dodatkową instalację wtrysku roztworu amoniaku. Instalacja umożliwia redukcję emisji NO<sub>x</sub> poprzez bezpośredni wtrysk 25% roztworu amoniaku NH<sub>4</sub>OH do oktagonalnych separatorów cząstek stałych (cyklonów).

Poziomy emisji odnoszą się do stężenia wyrażonego jako masa wyemitowanej substancji w objętości spalin w znormalizowanych warunkach, tj. suchy gaz w temperaturze 273.15 K, ciśnienie 101.3 kPa przy referencyjnym poziomie tlenu 6% objętości.

Pomimo stosunkowo niskiej emisji jaką oferuje technologia spalania węgla w kotle fluidalnym, spalanie węgla powoduje emisję CO<sub>2</sub>, gazu który w dużym stopniu jest odpowiedzialny za postępujące zmiany klimatu. Z tego powodu następuje coraz większa presja na odchodzenia od węgla na rzecz „Zielonej Energii”. Parlament Europejski oraz Rada Unii Europejskiej w 2008 zatwierdziły pakiet energetyczno-klimatyczny, tzw. pakiet 3x20%, który zawierał regulacje zmierzające do przeciwdziałania postępującym zmianom klimatu (plan do 2020 roku), takie jak:

- ograniczenie emisji gazów cieplarnianych,
- zwiększenie udziału energii z odnawialnych źródeł,

- podniesienie sprawności energetycznej urządzeń Unii Europejskiej.

Przyjęty pakiet stanowił punkt wyjściowy dla kolejnych, znacznie bardziej ambitnych celów związanych z redukcją emisji gazów cieplarnianych. 24 października 2014 roku liderzy Unii Europejskiej uzgodnili nowe cele polityki klimatyczno-energetycznej do roku 2030, które zobowiązywały kraje członkowskie do redukcji emisji CO<sub>2</sub> do 2030 roku o co najmniej 40% w porównaniu do roku 1990. Po rewizji polityki klimatycznej Unii europejskiej w 2018 i 2020 roku, aktualne cele przedstawiają się następująco [74]:

- redukcja emisji gazów cieplarnianych minimum o 55% w porównaniu z emisją z 1990 r.,
- wzrost do minimum 32% udziału źródeł odnawialnych w zużyciu finalnym energii brutto,
- wzrost efektywności energetycznej o 32.5%.

Uchwałą z 2 lutego 2021 r. Rada Ministrów Polski przyjęła „Politykę energetyczną Polski do 2040 r. (PEP2040)” [79], wyznaczającą ramy transformacji energetycznej w Polsce do roku 2040. Zgodnie z przyjętą polityką energetyczną Polski, krajowe zasoby węgla pozostaną istotnym elementem bezpieczeństwa energetycznego Polski a zapotrzebowanie na moc będzie pokrywane własnymi zasobami. Wzrost zapotrzebowania na energię elektryczną będzie pokrywany z innych źródeł niż konwencjonalne bloku węglowe.

Zgodnie z przyjętą strategią, będzie następował stały wzrost udziału odnawialnych źródeł energii elektrycznej, a ich udział w strukturze krajowego zużycia energii elektrycznej netto ma wynieść co najmniej 32% w 2030 r. Wzrost udziału energetyki odnawialnej będzie realizowany poprzez dalszy rozwój fotowoltaiki oraz morskich farm wiatrowych. Zgodnie z przyjętym dokumentem szacuje się, że morska energetyka wiatrowa do roku 2040 roku osiągnie zainstalowaną moc ok. 11 GW (w tym ok. 5.9 GW do 2030 r.). Nastąpić ma również dalszy wzrost zainstalowanych mocy fotowoltaicznych do ok. 10÷16 GW w 2040 r. (w tym ok. 5÷7 GW w 2030 r.). Zakłada się, że do 2040 r. ponad 50% zainstalowanych mocy stanowiąc będą źródła zero emisyjne.

Oprócz rozwoju fotowoltaiki i energetyki wiatrowej, przyjęty dokument zakłada również rozwój energetyki jądrowej. Do W 2033 r. uruchomiony ma zostać pierwszy blok jądrowy o mocy ok. 1÷1.6 GW. Przyjęte założenia zakładają oddanie kolejnych bloków do eksploatacji co 2-3 lata (docelowo zakłada się budowę 6 bloków jądrowych).

Przyjęte regulacje prawne oraz rosnące koszty do uprawnień emisji CO<sub>2</sub> sprawiają, że koszt produkcji energii elektrycznej z bloków węglowych stale wzrasta, co stawia nowe wyzwania dla eksploatowanych bloków energetycznych. Właściwa polityka remontowa, optymalizacja pracy, wzrost dyspozycyjności czy podniesienie sprawności jednostek

energetycznych to przyszłościowy kierunek rozwoju eksploatowanych konwencjonalnych bloków węglowych.

## 1.2. Analizowany obiekt

Kotły fluidalne zaczęto wdrażać w energetyce już w latach 60tych XX wieku, ze względu na szereg zalet jakie oferuje ta technologia:

- duża elastyczność paliwowa - możliwość spalanie stosunkowo słabych gatunkowo paliw,
- duża sprawność wytwarzania ciepła,
- niska emisja zanieczyszczeń,
- brak konieczności budowy dodatkowych instalacji, do odsiarczania spalin - możliwość odsiarczania bezpośrednio w komorze paleniskowej.

Pomimo ogromnego rozwoju technologii fluidalnej i zalet jakie oferuje ta technologia, kotły te posiadają jedną zasadniczą wadę, która nie została wyeliminowana. Jest to intensywna degradacja powierzchni ogrzewalnych na skutek zachodzących procesów erozji i korozji. Zjawiskiem dominującym jest erozji powierzchni ogrzewalnych, najczęstszej przyczyny awarii w kotłach fluidalnych [12]. Najbardziej narażonymi obszarami na erozję są [13]:


- rury ekranowe powyżej zakończenia obmurza (zakończenie leja komory paleniskowej),
- ściany kotła w pobliżu okien wylotowych spalin,
- dolne części przegrzewaczy grodziowych pary.

Analizowany obiekt to pierwszy tej wielkości w świecie blok energetyczny wyposażony w kocioł fluidalny CFB(ang. Circulating Fluidized Bed) z cyrkulacyjnym złożem na parametry nadkrytyczne o wydajności 1300 ton pary na godzinę. Jest to jeden z najnowocześniejszych kotłów energetycznych na świecie (i w Polsce), którego sprawność brutto osiąga 95%, a moc elektryczna bloku wynosi 460 MWe. Widok ogólny kotła wraz z urządzeniami pomocniczymi zaprezentowano na Rys. 1.1

Analizowany blok energetyczny wyposażony w kocioł fluidalny, który charakteryzuje się następującymi parametrami:

- wydajność 361 kg/s,

- minimalna wydajność kotła 141 kg/s,
- temperatura pary świeżej 560°C,
- ciśnienie pary przed turbiną 27.5 MPa,
- temperatura pary wtórnie przegrzanej 580°C,
- ciśnienie pary wtórnej 5.09 MPa,
- temperatura wody zasilającej 290°C,
- sprawność kotła brutto 95%,
- sprawność bloku brutto 45%.
- sprawność bloku brutto dla skojarzonej produkcji 53.42%.



Rys. 1.1. Widok analizowanego kotła fluidalnego wraz z urządzeniami pomocniczymi (źródło Sumitomo SHI FW Energia Polska Sp. z o.o.)

Analizowany kocioł fluidalny składa się z komory paleniskowej o wymiarach 10.6 m x 27.6 m x 48 m, ośmiu separatorów oktagonalnych cząstek stałych (po cztery na lewej i prawej stronie komory paleniskowej), ośmiu zewnętrznych przegrzewaczy pary (cztery przegrzewacze pary świeżej oraz cztery przegrzewacze pary wtórnie przegrzanej) oraz ciągu konwekcyjnego. Parownik kotła stanowią ściany komory paleniskowej wraz zlokalizowanymi w środkowej części komory paleniskowej (Rys. 1.2) trzema powierzchniami krzyżowymi będącymi częścią parownika. Dolną część komory paleniskowej (do wysokości 9 m nad ruszt) tworzy lej, pokryty w całości obmurzem żaroodpornym. W górnej części komory paleniskowej na stropie zawieszonych jest osiem grodzi przegrzewacza pary świeżej II stopnia. Materiał złoża recyrkuluje z komory paleniskowej poprzez separatory cząstek stałych do zewnętrznych przegrzewaczy pary, skąd po oddaniu ciepła zawracany jest do komory paleniskowej.



Rys. 1.2. Dno dyszowe analizowanego kotła. Widoczne od lewej: wlot paliwa, wlot materiału recyrkulowanego z zewnętrznego przegrzewacza pary (3 sztuki). Na wprost powierzchnia krzyżowa będąca częścią parownika. Widoczne od prawej: wlot paliwa, wlot materiału recyrkulowanego z zewnętrznego przegrzewacza pary (3 sztuki), wlot palnika rozpalającego. Na ruszcie widoczne zabudowane dysze powietrza pierwotnego


II ciąg kotła składa się z dwóch kanałów spalin (na wylocie z separatorów cząstek stałych), które łączą się i tworzą ciąg konwekcyjny, w którym zabudowane są przegrzewacze pary świeżej, wtórnej oraz podgrzewacz wody. W dalszej części spaliny z kotła rozdzielone są w stosunku 85/15 na obrotowy podgrzewacz powietrza typu Ljungström (RAPH) oraz obojętny podgrzewacz kondensatu, w których to



wymiennikach spaliny oddają ciepło odpowiednio do powietrza oraz do kondensatu. Następnie spaliny przepływają przez wysokosprawny elektrofiltr oraz końcowy wymiennik ciepła, tzw. chłodnicę spalin, w której temperatura spalin obniżana jest do wartości około 85°C. Po chłodnicy spalin spaliny kierowane są do chłodni kominowej.

Rysunek 1.3 prezentuje zabudowane w dolnej części leja komory paleniskowej wloty do komory, takie jak:

- 32 dysze powietrza wtórnego,
- 14 podajników paliwa,
- 10 olejowych palników rozpałkowych,
- 5 punktów podawania materiału złoża/piasku,
- 4 punkty podawania popiołu lotnego recykulowanego,
- 12 punktów podawania mączki kamienia wapiennego,
- 7802 dysze powietrza pierwotnego.



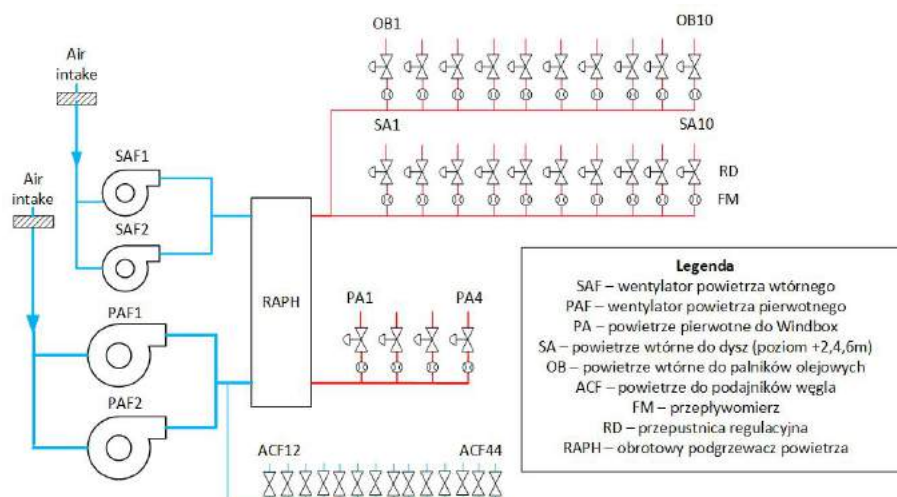
Rys. 1.3. Umieszczenie termopar na ruszcie kotła, poziom +250mm

Powietrza pierwotne dostarczane jest do kotła przy pomocy dwóch wentylatorów powietrza pierwotnego (Rys. 1.4). Powietrze to, po podgrzaniu w wstępnym podgrzewaczu powietrza (do temperatury około 68°C) oraz w obrotowym podgrzewaczu powietrza (do temperatury około 280°C) dostarczane jest do skrzyni powietrza pierwotnego, skąd 7802

dyszami powietrza pierwotnego (zabudowanymi w dnie komory paleniskowej) dostarczane jest równomiernie do komory paleniskowej (Rys. 1.2).

Powietrze wtórne dostarczane jest do kotła przez dwa wentylatory powietrza wtórnego. Powietrze to, po podgrzaniu w wstępnym podgrzewaczu powietrza (do temperatury około 78°C) oraz obrotowym podgrzewaczu powietrza (do temperatury około 285°C) transportowane jest do 32 dysz powietrza wtórnego oraz 10 palników rozpałkowych i wprowadzane jest do dolnej części komory paleniskowej. Dysze powietrza wtórnego zlokalizowane są na bocznych ścianach leja kotła na wysokości 2,4 i 6 m nad rusztem kotła. Olejowe palniki rozpałkowe zabudowane są na całym obwodzie leja komory paleniskowej na wysokości 1 m nad rusztem kotła. W analizowanym kotle fluidalnym stosunek dostarczanego powietrza pierwotnego do wtórnego wynosi 57 do 43.

Uproszczony schemat układu dystrybucji powietrza pierwotnego i wtórnego do kotła fluidalnego zaprezentowany jest na Rys. 1.4.



Rys. 1.4. Dystrybucja powietrza pierwotnego i wtórnego do analizowanego kotła


Paliwo do kotła fluidalnego dostarczane jest za pomocą czterech niezależnych linii (po dwie linie na stronę kotła). Każda linia składa się z dwóch podajników zgrzeblowych, które poprzez zabudowane dozowniki węgla, odpowiednio rozdzielają paliwo do 14 podajników naściennych węgla (po 7 na prawej i lewej ścianie kotła). Uproszczony schemat dystrybucji paliwa do analizowanego kotła fluidalnego zaprezentowano na Rys. 1.5.

Bezpieczna eksploatacja kotła fluidalnego wymaga ciągłej kontroli jego parametrów pracy (zwłaszcza ciśnienia i temperatury). Komora paleniskowa analizowanego kotła wyposażona jest w 8 pomiarów ciśnienia oraz 36 pomiarów temperatury, zabudowanych są na czterech wysokościach nad rusztem kotła:

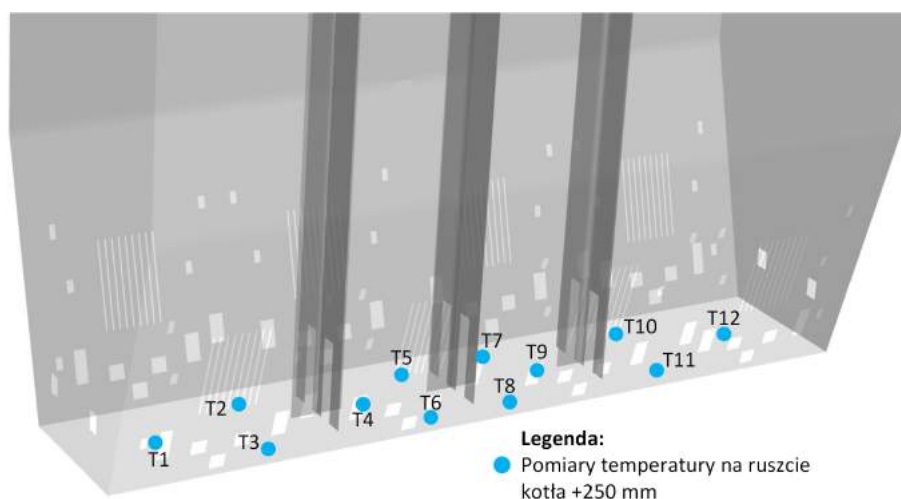
- 8 pomiarów ciśnienia złoża na poziomie +250 mm.

- 12 pomiarów na poziomie 250 mm powyżej rusztu (Rys. 1.6,
- 8 pomiarów na poziomie +1 m powyżej rusztu,
- 8 pomiarów na poziomie +2 m powyżej rusztu,
- 8 pomiarów na poziomie +48 m (na stropie),

Za pomocą tych pomiarów monitorowana jest w sposób ciągły temperatura i ciśnienie złoża i spalin w trakcie eksploatacji kotła.



Rys. 1.5. Uproszczony schemat dystrybucji paliwa do analizowanego kotła fluidalnego




Rys. 1.6. Miejsce zabudowy termopar w dnie rusztowym analizowanego kotła fluidalnego

W trakcie normalnej pracy bloku, nadzór parametrów kotła oraz ich regulacja realizowana jest poprzez nadrzędny regulator bloku (NSAB), który zarządza wszystkimi parametrami bloku w tym również głównym regulatorem kotła. Główny regulator kotła reguluje między innymi wymaganą ilość wody zasilającej, paliwa oraz powietrza

dostarczanego do kotła w celu uzyskania zadanej wydajności kotła, wynikającą z bieżącego zapotrzebowania na moc cieplną i elektryczną bloku energetycznego.

### 1.3. Pomiary diagnostyczne

Doświadczenia remontowo-diagnostyczne na analizowanym kotle fluidalnym związane z występującymi problemami z zużyciem erozyjnym powierzchni ogrzewalnych pokrywają się z przykładami z literatury, zwłaszcza z miejscami szczególnie narażonymi na występowanie zjawiska erozji powierzchni ogrzewalnych [13]. Do obszarów tych w szczególności należą rury parownika w rejonie okien wylotowych spalin z komory paleniskowej do separatorów oktagonalnych cząstek stałych. W analizowanym kotle, rury w tym rejonie zabezpieczone są poprzez pokrycie ich obmurzem ogniotrwałym (Rys. 1.7), co skutecznie zabezpiecza powierzchnie ogrzewalne w tym rejonie przed erozją. Kolejnym obszarem silnie narażonym na erozję są dolne powierzchnie rur przegrzewacza wiszącego pary.



Rys. 1.7. Obmurze ogniotrwałe zabezpieczające rury parownika w okolicy okna przelotowego spalin do separatorów oktagonalnych

W analizowanym kotle powierzchnie te są zabezpieczone przed erozją poprzez osłony montowane na zewnętrznej rurze przegrzewacza każdej grodzi (Rys. 1.8) oraz poprzez pokrycie kolan przegrzewacza powłoką trudno ścieralną (Rys. 1.9) tzw. metalizacja [57], co skutecznie zabezpiecza rury przegrzewacza przed nadmierną erozją.

Ostatnim obszarem (według dostępnej literatury oraz doświadczeń remontowych) są rury parownika w miejscu zakończenia obmurza, w dolnej części komory paleniskowej (Rys. 1.10). W analizowanym kotle fluidalnym rury te zabudowane są zgodnie z autorskim rozwiązaniem producenta kotła, tworząc odgięcie rur tzw. kick-out<sup>®</sup> (Rys. 1.11), natomiast powyżej tego odgięcia, rury parownika zabezpieczone są powłoką trudno ścieralną do wysokości 7m powyżej linii zakończenia obmurza. Lej komory paleniskowej w



Rys. 1.8. Osłona skrajnej rury przegrzewacza grodziowego



Rys. 1.9. Erozja ścianki rury kolana przegrzewacza grodziowego

całości pokryty jest obmurzem ogniotrwałym (Rys. 1.12), co zabezpiecza rury parownika przed intensywną erozją od materiału złoża.

Racjonalna i odpowiedzialna polityka zarządzania majątkiem produkcyjnym polega między innymi na planowaniu działań remontowych. Jednym z filarów przy dążeniu do utrzymania wysokiej dyspozycyjności bloku 460MW jest predykcja zużycia grubości rur parownika, co umożliwia zaplanowanie z wyprzedzeniem koniecznych wymian bądź napraw rur ekranowych, aby uniknąć nieplanowanych postojów awaryjnych na skutek nieszczelności części ciśnieniowej kotła. W tym celu wykonuje się okresowe pomiary diagnostyczne polegające m.in. na pomiarach grubości ścian powierzchni ogrzewalnych. W oparciu o wytyczne producenta kotła oraz doświadczenia własnych służb remontowo-diagnostycznych, w komorze paleniskowej wyznaczono poziomy pomiarowe na których wykonywane są pomiary grubości ścian rur parownika. Z uwagi na fakt, że największa erozja rur parownika występuje w obszarze powyżej linii zakończenia obmurza



Rys. 1.10. Lej komory paleniskowej zabezpieczony obmurzem ogniotrwałym

ogniotrwałego, w rejonie tym wykonywane pomiary grubości rur parownika wykonywane są z dużym zagęszczeniem siatki pomiarowej.

Pomiary grubości ścianki rur wykonywane są metodą ultradźwiękową, zgodnie z Polską Normą PN-EN ISO 19809:2019-08 [2]. W komorze paleniskowej analizowanego kotła zabudowane są rury ekranowe o dwóch wymiarach: 31.8x7.1 mm (grubość minimalna 4.23 mm) oraz 38x8 mm (grubość minimalna 5.06 mm). Na podstawie wykonanych wyników pomiarów grubości ścian rur ekranowych określa się możliwość dalszej ich eksploatacji, konieczność naprawy (poprzez miejscowe napawanie rur) lub zabezpieczenia rur poprzez natrysk powłoki trudno ścieralnej na powierzchnię rur (metalizację) [57].

W niniejszej rozprawie, wykonano analizę ubytków grubości ścianki rur parownika, zlokalizowanych do 1.5 m nad linią zakończenia obmurza ogniotrwałego. Na podstawie dostępnych archiwalnych danych pomiarowych, przeanalizowano ubytki grubości rur na czterech poziomach diagnostycznych. Lokalizację poziomów pomiarowych na linię zakończenia obmurza zaprezentowano na Rys. 1.3:

- poziom pomiarowy A1 – wysokość 309 mm,
- poziom pomiarowy B1 – wysokość 609 mm,
- poziom pomiarowy B2 – wysokość 959 mm,
- poziom pomiarowy B3 – wysokość 1.309 mm.



Rys. 1.11. Odgięcie rur parownika tuż powyżej linii zakończenia obmurza



Rys. 1.12. Lej komory paleniskowej - rury w całości zabezpieczone obmurzem ogniotrwałym. Widoczne od lewej: palnik rozpałkowy, wlot paliwa (nad nim usytuowana dysza powietrza wtórnego z podawaniem sorbentu), wlot materiału recykulowanego z zewnętrznego przegrzewacza pary (3 sztuki), wlot paliwa)

W trakcie wieloletniej eksploatacji analizowanego kotła, zaobserwowano dużą zmienność lokalizacji obszarów, w której występowała zwiększona erozja rur parownika.

Praktycznie w każdym postoju remontowym kotła, rury ekranowe w innym rejonie wykazywały duże zużycie erozyjne, które odbiegało od średniej erozji na danym poziomie pomiarowym. Szczegółowa analiza archiwalnych danych za okres ponad 3 lat pracy kotła, z okresu 2011÷2014 roku potwierdziła spostrzeżenia. W sumie analizowany okres obejmuje 17000 godzin pracy kotła (30 miesięcy). W okresie tym wyprodukowano ponad 5 800 000 MWh energii elektrycznej:

- pierwszy okres – 947 455 MWh,
- drugi okres – 2 121 834 MWh,
- trzeci okres – 2 749 136 MWh.

W tym czasie czterokrotnie wykonano kompleksowe pomiary diagnostyczne grubości ścianki rur ekranowych. Ubytki grubości ścianki w okresach międzyremontowych obliczono zgodnie z Rów. (1.1):

$$U_{okres} = g_j - g_i \quad (1.1)$$

gdzie  $U_{okres}$  definiuje ubytek za analizowany okres,  $g$  definiuje zmierzoną wartość grubości w danym okresie,  $j$  definiuje pomiar po analizowanym okresie pracy a  $i$  definiuje pomiar przed analizowanym okresem. Dane diagnostyczne skorygowano o dostępne informacje o wymianie rur w danym obszarze na nowe, bądź o wykonanie miejscowej odbudowy grubości ścianki rury przez napawanie.

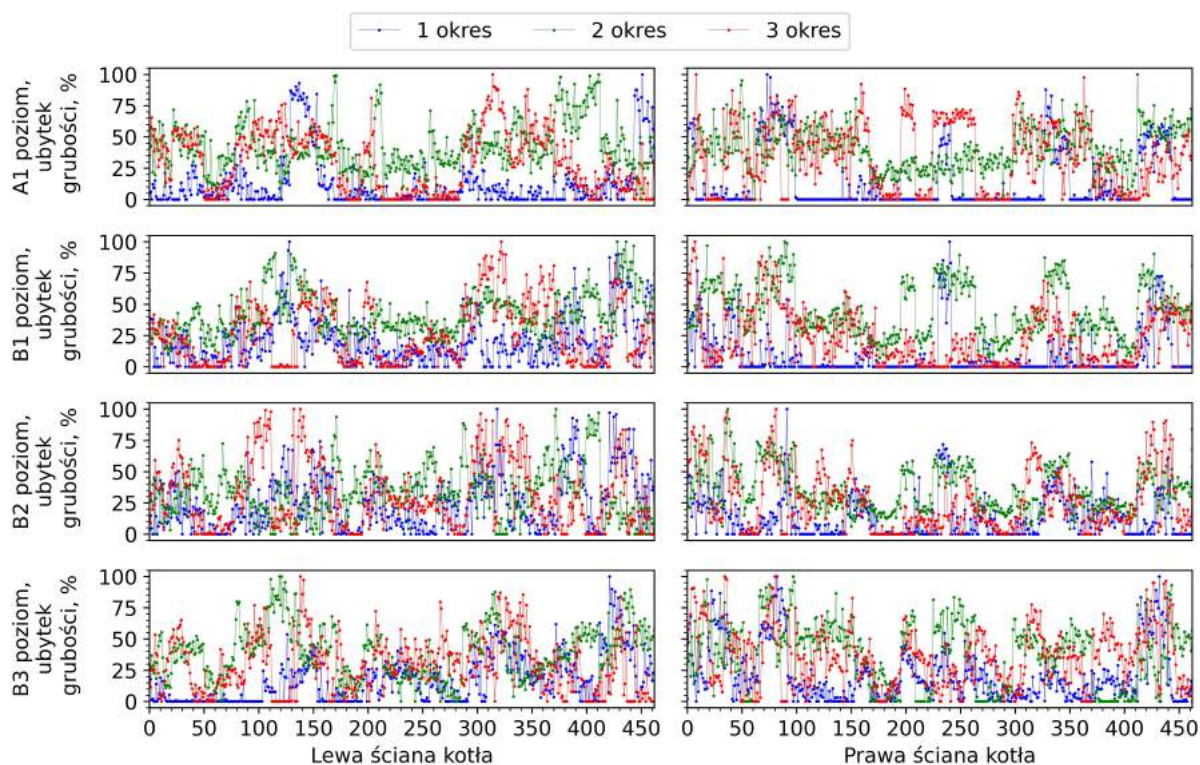
Obliczoną zgodnie z Rów. (1.1) wartość ubytku w poszczególnych okresach pracy kotła zaprezentowano na Rys. 1.13, gdzie wartość ubytku ścianki rur przedstawiono jako wartość procentową w odniesieniu do obliczonej wartości maksymalnej dla danego poziomu pomiarowego.

Analizując obliczone ubytki grubości rur (Rys. 1.13) wyraźnie widać rozbieżność w lokalizacji maksymalnych ubytków grubości na każdym z analizowanych poziomów diagnostycznych ( $B3 \div A1$ ). Ponadto widać, że w każdym z trzech analizowanych okresów pracy kotła, maksymalna erozja występuje w innym obszarze kotła.

Aby zrozumieć przyczynę zmienności lokalizacji intensywnej erozji i występowania tzw. pików erozji, wykonano analizę historycznych danych eksploatacyjnych, które pobrano z systemu DCS. W każdym z analizowanych okresów porównano rozkład dostarczanego paliwa przez poszczególne podajniki węgla (Rys. 1.14) oraz rozkład temperatury na dnie rusztowym (Rys. 1.15), dla pomiarów rejestrowanych przez termopary na poziomie +250 mm (Rys. 1.6).

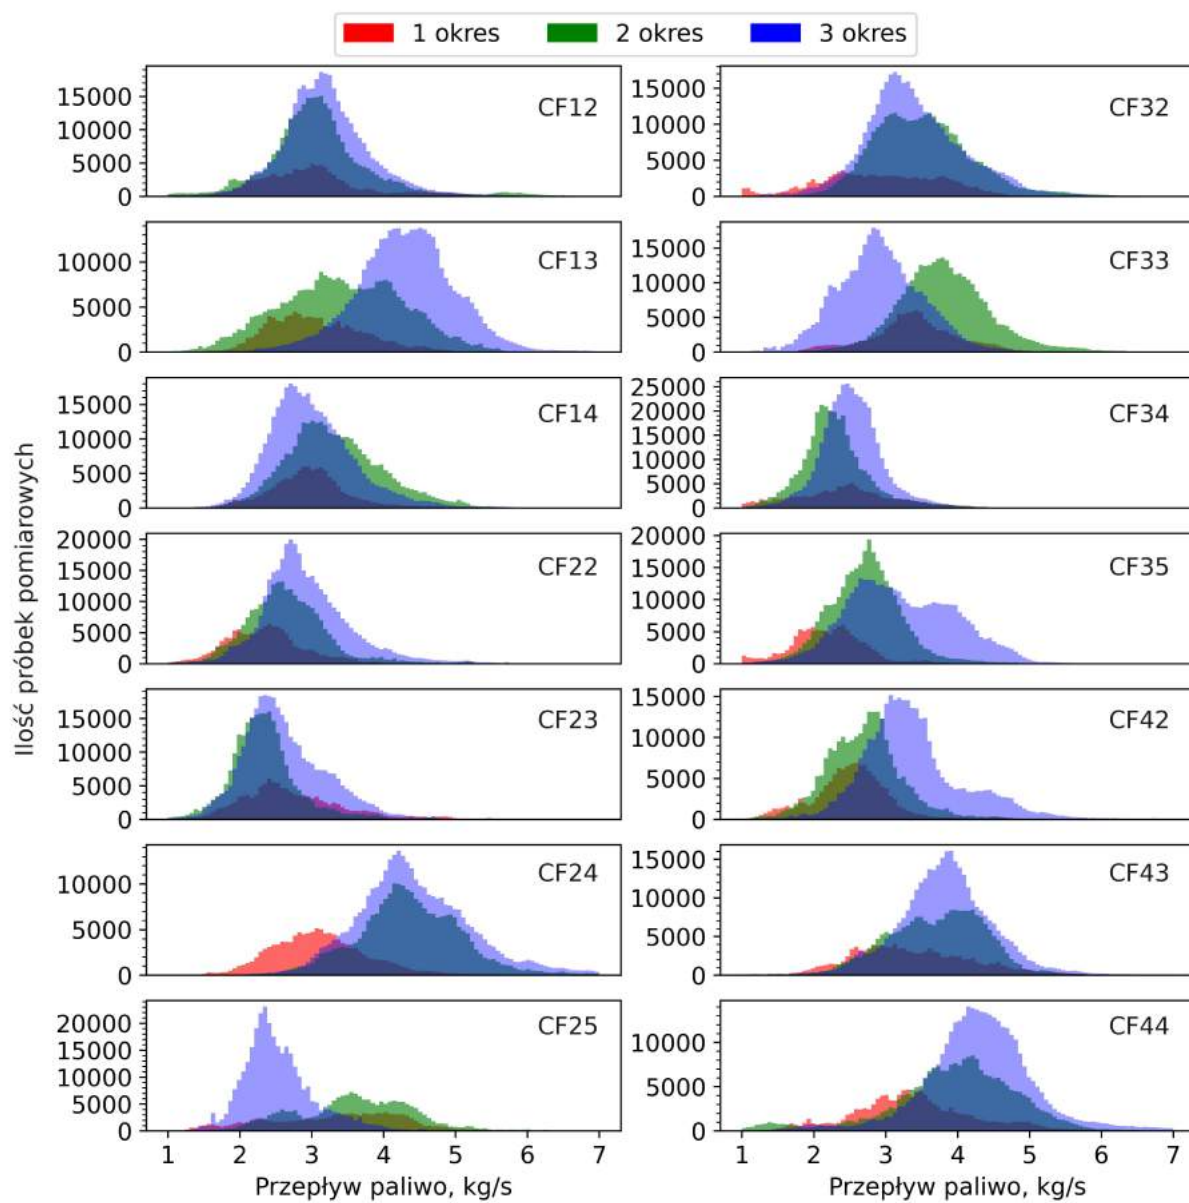
Rysunek 1.14 prezentuje rozkład paliwa dostarczanego przez poszczególne podajniki paliwa do komory paleniskowej. Widać wyraźne różnice pomiędzy każdym z analizowanych okresów pracy kotła. Poszczególne podajniki paliwa różnią się czasem pracy z określoną wydajnością.



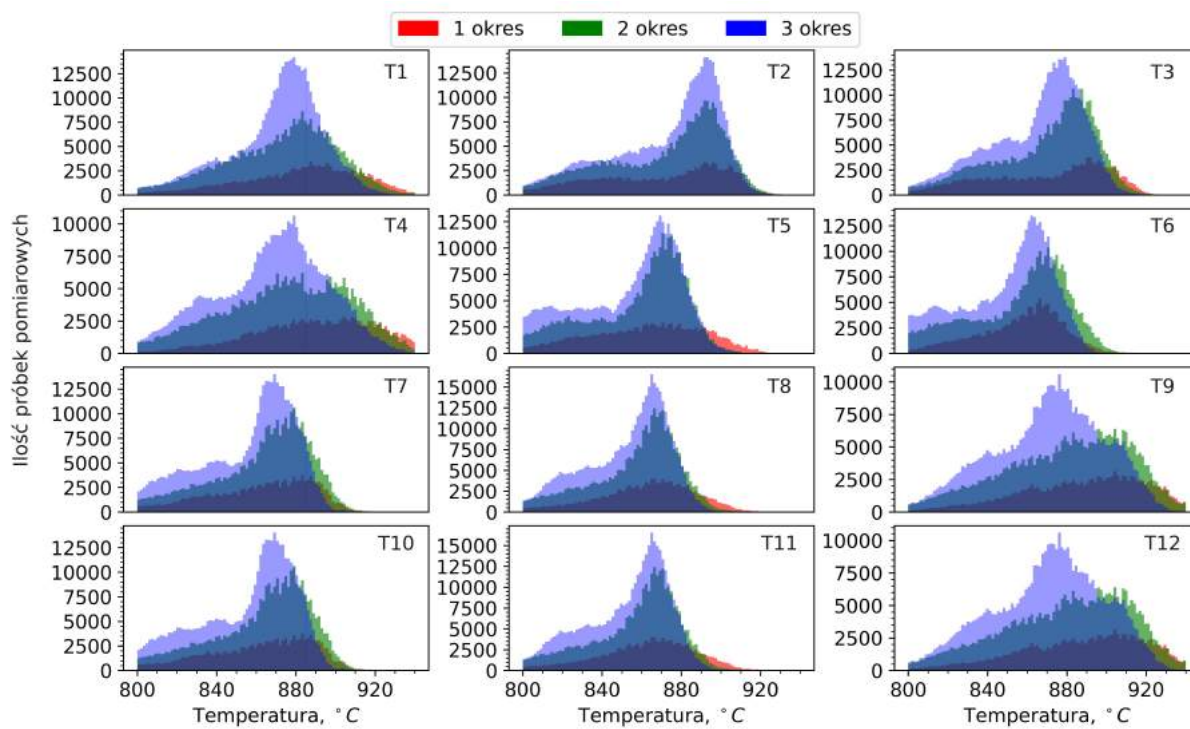


Rys. 1.13. Ubytki grubości ścian rur parownika na lewej i prawej ścianie kotła, dla czterech poziomów diagnostycznych ( $B3 \div A1$ )

Rysunek 1.15 prezentuje zarejestrowany rozkład dwunastu temperatur ( $T1 \div T12$ ) zabudowanych na wysokości +250 mm nad rusztem kotła. wyraźne widać różnice pomiędzy każdym z analizowanych okresów pracy kotła. Poszczególne obszary kotła różniły się czasem pracy z określoną temperaturą.



Rys. 1.14. Wydajność podajników węgla w trzech analizowanych okresach pracy kotła



Rys. 1.15. Zarejestrowane temperatury na ruszcie w trzech analizowanych okresach pracy kotła

## 1.4. Cel Pracy

Pierwszy remont kapitalny bloku 460 MW zrealizowany został w 2019 roku. W trakcie remontu zmodernizowano turbozespół bloku pod kątem uciepłownienia jednostki energetycznej. Sumaryczna zainstalowana moc cieplna bloku w Elektrowni Łagisza to 150 MWt (w trakcie pracy kaskadowej wymienników możliwe jest osiągnięcie maksymalnej mocy cieplnej 180 MWt).

Zrealizowana inwestycja znacząco wpłynęła na wzrost sprawności brutto bloku energetycznego (z 45% do 53.42%) dla skojarzonej produkcji energii elektrycznej i ciepła. Dzięki tej inwestycji, po wycofaniu z eksploatacji bloków 120 MW, możliwa jest dostawa energii cieplnej do okolicznych miast takich jak Będzin, Dąbrowa Górnicza, Sosnowiec, Katowice. Modernizacja turbozespołu podniosła znacznie rentowność analizowanej jednostki energetycznej, jak również obniżyła negatywny wpływ produkcji energii elektrycznej z węgla na środowisko.

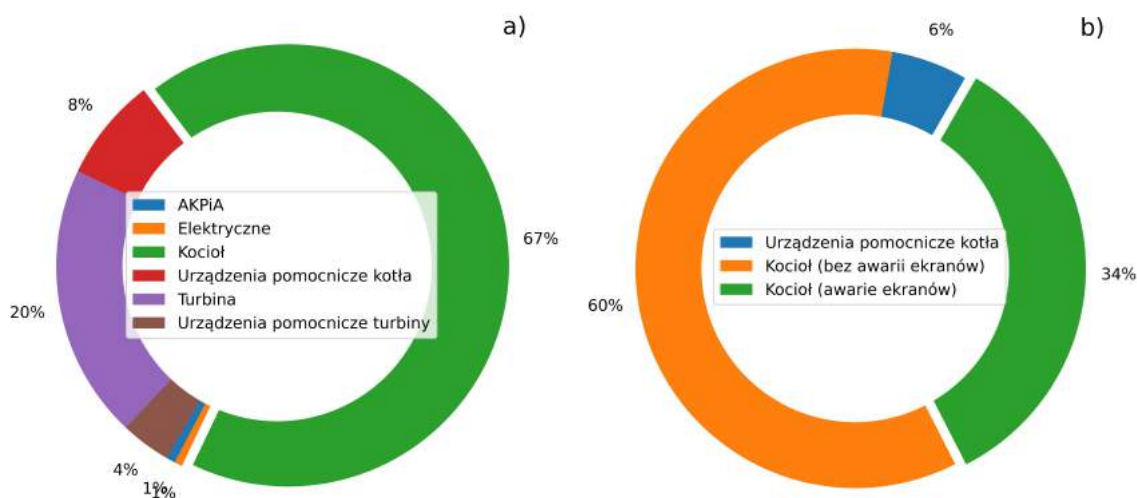
Uciepłownienie bloku energetycznego przyniosło także nowe wyzwania przed eksploatującym tę jednostkę wytwórczą - w trakcie okresu grzewczego, (trwającego od września do kwietnia) konieczne jest zapewnienie stabilnej i niezawodnej pracy bloku energetycznego pod kątem dostaw ciepła dla okolicznych miast.

Na potrzeby realizowanej pracy, na podstawie danych eksploatacyjnych analizowanego bloku energetycznego zebrano dane dotyczące awaryjności tej jednostki w latach 2009-2019. Dostępne dane przeanalizowano pod kątem obszaru wystąpienia awarii (kocioł fluidalny, turbina parowa, aparatura kontrolno-pomiarowa i automatyka (AKPiA), urządzenia elektryczne, urządzenia pomocnicze kotła, urządzenia pomocnicze turbiny).

Analiza danych wskazuje, że główną przyczyną awaryjności analizowanego bloku energetycznego są awarie kotła, które odpowiadają za 67% całkowitego czasu postojów awaryjnych (Rys. 1.16a). Z tego aż 90% czasu postojów awaryjnych kotła spowodowanych było nieszczelnościami części ciśnieniowej, w tym 31% to nieszczelności spowodowane erozją rur ekranowych (Rys. 1.16b).

Wyeliminowanie potencjalnej przyczyny awarii na skutek erozji rur ekranowych stanowi duży potencjał do zwiększenia dyspozycyjności bloku energetycznego.

Celem autora niniejszej pracy, było znalezienie sposobu, który poprzez optymalizację pracy analizowanego kotła fluidlanego (rozkładu dostarczanego paliwa do kotła przez poszczególne podajniki) doprowadzi do ograniczenia niekorzystnego zjawiska erozji rur ekranowych w dolnej części komory paleniskowej. Zgodnie z przyjętym założeniem dla prowadzonych badań, wyrównanie rozkładu temperatur na ruszcie kotła wpłynie na zmniejszenie intensywności erozji powierzchni grzewczych analizowanego kotła fluidalnego. Realizacja założonego celu przyniesie dodatni efekt ekonomiczny, środowiskowy oraz społeczny w postaci:



Rys. 1.16. Przyczyny awarii bloku 460 MW za okres 2009÷2019. Po prawej porównanie awaryjności bloku (a), po lewej porównanie awaryjności analizowanego kotła (b)

- podniesienia dyspozycyjności bloku energetycznego,
- wydłużenia okresów międzyremontowych,
- optymalizacji gospodarki remontowej,
- obniżenia kosztów produkcji energii elektrycznej,
- obniżenia emisji zanieczyszczeń,
- obniżenia kosztów związanych z uruchomieniem bloku,
- niezakłóconej produkcji ciepła w trakcie sezonu grzewczego.

Ponadto niezawodność tej jednostki wytwórczej bezpośrednio wpływa na bezpieczeństwo energetyczne państwa oraz na bezpieczeństwo energetyczne lokalnego środowiska - ciepło dostarczane jest do sieci ciepłowniczych zasilających okoliczne miasta.

## 1.5. Przegląd literatury

W otaczającej nas rzeczywistości często nie zdajemy sobie nawet sprawy jak bardzo codzienne czynności coraz bardziej zależą od szeroko pojętej implementacji algorytmów głębokiego uczenia. Czy tego chcemy czy nie, sztuczna inteligencja coraz bardziej będzie nas otaczać - od codziennego odblokowania telefonu przy pomocy wizerunku, wydawania poleceń głosowych [68] czy używaniu translatorów.

Wykorzystanie algorytmów sztucznej inteligencji jest również coraz szerzej spotykane w przemyśle, w tym również w energetyce. Dzisiaj profesjonalne zarządzanie majątkiem produkcyjnym z założenia wykorzystuje algorytmy głębokiego uczenia, wspierając proces decyzji biznesowych, jak np. IBM Maximo [61] czy GE Predix [59]. Nowoczesne technologie nie tylko pomagają, ale czasem wręcz wykonują zadania, które jeszcze nie dawno nie były możliwe do wykonania, tak jak predykcja w czasie rzeczywistym awarii całych instalacji technologicznych, gdzie śledzonych jest jednocześnie kilkaset a czasem kilka tysięcy parametrów w poszukiwaniu występujących anomalii.

W internecie znaleźć można wiele przykładów najróżniejszego wdrożenia algorytmów sztucznej inteligencji, jednakże dostępna literatura dotycząca wykorzystania technik uczenia maszynowego, czy szerzej sztucznej inteligencji pod kątem predykcji parametrów operacyjnych kotła czy erozji w kotłach fluidalnych jest uboga. Zdecydowana większość dostępnej literatury dotyczącej zagadnień związanych z kotłami energetycznymi koncentruje się na opracowaniu wiarogodnych i zwalidowanych modeli numerycznych kotła wykorzystujących obliczenia numeryczne CFD. Modele CFD pozwalają na dokładną symulację procesów termodynamicznych zachodzących w kotle i z dużą dokładnością obliczyć wielkości wyjściowe. Jednakże technika ta wymaga po pierwsze dużych mocy obliczeniowych, po drugie każdorazowo wymagany jest długi czas obliczeń, po trzecie dobrze zwalidowanego modelu oraz dobrej znajomości wszystkich danych wejściowych oraz zachodzących zjawisk.

Algorytmy sztucznej eliminują część tych ograniczeń. Raz dobrze wyuczony model pozwala natychmiast otrzymać wynik obliczeń i daną wyjściową. Często pozwala to pominąć analizę zachodzącego procesu - dobrze dobrana sieć neuronowa niejako „sama” znajduje właściwe zależności pomiędzy danymi wejściowymi a wyjściowymi. Upraszcza i przyspiesza to cały proces obliczeń. W dostępnej literaturze można znaleźć szereg przykładów wykorzystania modeli AI do rozwiązywania problemów technicznych w energetyce, jednakże koncentrują się one głównie na zagadnieniach związanych z optymalizacją parametrów kotła pod kątem emisji bądź wydajności.

„Tradycyjne” podejście do metod optymalizacji procesów w energetyce polegające na wykorzystaniu technik numerycznych CFD, które prezentuje np. Hernik [20] optymalizując położenie dysz OFA w celu poprawy spalania oraz obniżenia emisji NO<sub>x</sub>, czy Adamczyk [5] badając proces dopalania gazów pochodzących z procesu zgazowania osadów ściekowych na emisję tlenków azotu (NO<sub>x</sub>) w wielkogabarytowym kotle pyłowym jest coraz częściej zastępowane przez wykorzystanie technik AI.

Smrekar [41] opisuje szczegółowo proces wykorzystania sieci neuronowych na emisję tlenków NO<sub>x</sub> w zależności od parametrów operacyjnych kotła węglowego, a w [40] opisuje doświadczenia związane z predykcją parametrów pary (temperatura, przepływ i ciśnienie) w oparciu o parametry eksploatacyjne kotła takie jak ilość paliwa, otwarcie zaworu

parowego i ciśnienie wody zasilającej przy wykorzystaniu modeli ANN (ang. Artificial Neural Network). Si [39] przedstawia wykorzystanie modeli predykcyjnych do redukcji  $\text{NO}_x$  dla kotła węglowego wyposażonego w instalację katalitycznego odazotowania spalin SCR, Lia [24] opisuje predykcję  $\text{NO}_x$  w oparciu o parametry kotła takie jak rodzaj i ilość węgla, przepływ powietrza pierwotnego i wtórnego czy położenia pracujących palników węgla. Natale [33] przedstawia doświadczenia eksperymentalne i wyniki dotyczące szybkości erozji poziomych rur parownika w w kotle fluidalnym ze złożem pęcherzykowym, Xu [47] przedstawia wykorzystanie obliczeń numerycznych do modelowania ściany kotła wraz z palnikami do przewidywania emisji  $\text{NO}_x$  w kotle. Diaz [15] opisuje wykorzystanie sieci neuronowych do predykcji temperatury wymiennika ciepła oraz jej kontroli na wyjściu z z wymiennika ciepła. Szentannai [43] opisuje procedurę stworzenia matematycznego modelu kotła fluidalnego z złożem cyrkulacyjnym w celu optymalizacji pracy kotła pod kątem procesu fluidyzacji, temperatury złoża czy emisji  $\text{CO}_2$  i  $\text{NO}_x$ . Lv [29] opisuje wykorzystanie kombinacji algorytmu FCM (ang. fuzzy c-means cluster algorithm), LS-SVM (ang. Least-squares support-vector machines) oraz PLS (ang. Partial least squares regression) do predykcji poziomu emisji  $\text{NO}_x$  kotła pyłowego na parametry nadkrytyczne o mocy 660 MW. Iliyas [21] opisuje zastosowanie modelu ANN do predykcji emisji  $\text{NO}_x$  oraz poziomu  $\text{O}_2$  w celu optymalizacji procesu spalania w kotle gazowym o mocy 160 MW. Romeo [36] prezentuje wdrożenie modelu ANN do sterowania cyklami parowych zdmuchiwozacy sadzy w celu ograniczenia zanieczyszczeń powierzchni ogrzewalnych kotła opalanego biomasą.

Autor nie znalazł w literaturze przykładów wykorzystania szeroko pojętej sztucznej inteligencji do redukcji intensywności erozji w kotle energetycznym. Najbardziej zbliżone zagadnienie poruszyli Lv and Hong w [28] którzy w swojej pracy opisują doświadczenia związane z budową modelu do predykcji temperatury złoża w kotle fluidalnym z złożem cyrkulacyjnym. Przy wykorzystaniu techniki LSSVM (ang. Least-squares support-vector machines), porównują ze sobą 5 różnych modeli predykcyjnych, prezentując bardzo dobre wyniki predykcji. Predykcję wykonano w oparciu o dane operacyjne kotła, między innymi ilości podawanego paliwa do kotła. Dokładność modeli porównywano na podstawie uzyskanych wartości błędu średnio kwadratowego RMSE (dla danych rzeczywistych i obliczeniowych).

## 1.6. Opis koncepcji

Proponowana w przedstawionej rozprawie koncepcja, zakłada ograniczenie intensywności erozji rur ekranowych powyżej linii zakończenia obmurza w komorze paleniskowej. Doświadczenia eksploatacyjne analizowanego kotła fluidalnego wskazują, że lokalne ubytki grubości ścianki rury parownika w bardzo szybkim tempie mogą doprowadzić

do nieszczelności ciśnieniowej na skutek perforacji rur parownika. Erozja jest nieodłącznym zjawiskiem zachodzącym w paleniskach fluidalnych [13], jednak ideą zaprezentowanej pracy jest doprowadzić do stanu, w którym zjawisko erozji będzie w miarę równomiernie na całym obwodzie ścian szczelnych komory paleniskowej. Dzięki temu, możliwe będzie nie tylko wydłużenie czasu bezpiecznej eksploatacji kotła bez nieszczelności, ale również, oszacowanie czasu bezpiecznej pracy kotła.

Jednym ze sposobów realizacji tego celu jest wyrównanie rozkładu temperatury w całym przekroju komory paleniskowej, co zgodnie z założeniami ma ograniczyć występowanie dużych fluktuacji erozji rur parownika. Efekt ten, może zostać osiągnięty poprzez optymalizację parametrów eksploatacyjnych kotła pod kątem osiągnięcia wyrównanego rozkładu temperatury na ruszcie analizowanego kotła fluidalnego.

## 1.7. Zakres rozprawy

Rozprawa została podzielona na cztery rozdziały oraz załączniki, w których załączono kod źródłowy wykorzystany do nauki sieci neuronowych oraz zmiany parametrów eksploatacyjnych kotła.

Rozdział **Wprowadzenie** prezentuje ogólne informacje o uwarunkowaniach środowiskowych dotyczących energetyki konwencjonalnej w obecnym czasie. W rozdziale przedstawiono również ogólny opis analizowanego kotła fluidalnego oraz jego podstawowe parametry eksploatacyjne. W rozdziale zaprezentowano wyniki analizy awaryjności bloku energetycznego oraz sposób i metodologię prowadzonej diagnostyki rur ekranowych. W rozdziale również przeanalizowano wyniki pomiarów grubości rur parownika za okres trzech lat eksploatacji. Zaprezentowano również ogólny opis koncepcji rozprawy wraz z przeglądem dostępnej literatury, która odnosi się do zagadnień poruszanych w niniejszej rozprawie.

Rozdział **Model predykcyjny** zawiera podstawowe informacje o sieciach neuronowych i możliwości ich zastosowania. W rozdziale opisano techniki obliczeniowe oparte na algorytmach sztucznej inteligencji, wykorzystujące techniki uczenia maszynowego tzw. ML (ang. Machine Learning) w celu rozwiązania postawionego problemu. Ponadto przedstawiono wyniki obliczonych korelacji pomiędzy parametrami eksploatacyjnymi kotła. W dalszej kolejności zaprezentowano sposób poszukiwania modelu do predykcji temperatury wraz z testami poszczególnych sieci neuronowych. Ponadto przedstawiono wyniki obliczeń dokładności predykcji temperatury dla poszczególnych modeli. Na zakończenie rozdziału zaprezentowano testy obiektowe jakie zostały wykonane w celu potwierdzenia możliwości wpływu na rozkład temperatury za pomocą zmiany rozkładu dystrybucji powietrza oraz paliwa dostarczanego do komory paleniskowej. Całość badań zrealizowano przy założeniu, że jakiegokolwiek zmiany parametrów eksploatacyjnych kotła nie mogą wpływać na wydaj-



ność kotła fluidalnego a tym samym na produkcję energii elektrycznej i ciepłej. Wszystkie konieczne obliczenia wykonano przy pomocy ogólnie dostępnego, darmowego oprogramowania *Python Open Source* [69] wraz z zaimplementowanymi w bibliotece *Tensorflow*, [72] funkcjami uczenia maszynowego.

Rozdział **Model numeryczny kotła CFB** prezentuje sposób potwierdzenia postawionej tezy, że wyrównany rozkład temperatury wpływa na ograniczenie fluktuacji erozji rur ekranowych w komorze paleniskowej. Zaprezentowano model numeryczny analizowanego kotła fluidalnego stworzony w ramach projektu POIR.01.01.01-00-1253/19-00, który był współfinansowany przez Narodowe Centrum Badań i Rozwoju. Następnie przedstawiono w jaki sposób sprawdzono działanie modelu na zmianę parametrów eksploatacyjnych kotła. Ostatnia część rozdziału to przedstawienie obliczeń numerycznych dla dwóch niezależnych przypadków ruchowych kotła fluidalnego dla których porównano różne warianty rozkładu temperatury na ruszcie kotła: ruchowy, wyrównany oraz odmienny. W rozdziale pokazano rozwiązanie postawionego zadania, bazujące na numerycznej mechanice płynów CFD (ang. Computational Fluid Dynamics). Do modelowania modeli wielofazowych wykorzystano komercyjne oprogramowanie Ansys<sup>®</sup>Fluent [54]. Oprogramowanie to posiada półotwartą strukturę, dzięki której możliwa jest modyfikacją kodu w celu wykorzystania własnych modeli matematycznych, dostosowanych do rozwiązywanych problemów. Możliwość ta została wykorzystana poprzez wykorzystanie autorskich funkcji użytkownika UDF (ang. User Defined Function).

Ostatni rozdział **Podsumowanie** to przegląd zadań zrealizowanych w ramach pracy, wraz z wnioskami płynącymi po wykonaniu przyjętych założeń.



## 2

# Model Predykcyjny

## 2.1. Sieci neuronowe

Sieci neuronowe to podstawa działania szeroko rozumianej sztucznej inteligencji AI (ang. Artificial intelligence). Sztuczna sieć neuronowa ANN (ang. Artificial Neural Network) to połączenie pojedynczych sztucznych neuronów, których działanie naśladuje pracę neuronów w ludzkim mózgu.

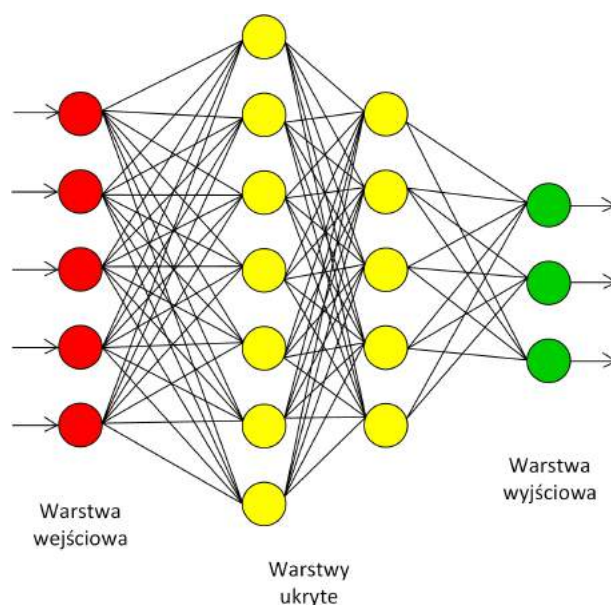
Początki sieci neuronowych sięgają lat czterdziestych ubiegłego wieku, kiedy to w 1943 roku Warren McCulloch i Walter Pitts stworzyli matematyczny opis ludzkiego neuronu [30], za pomocą którego można było rozwiązywać proste zagadnienia logiczne. W 1957 roku F. Rosenblatt [37] zaprezentował Perceptron, czyli prostą sieć neuronową, składającą się z jednego bądź wielu niezależnych neuronów McCullocha-Pittsa, implementujących algorytm uczenia nadzorowanego do klasyfikacji binarnej. Od tamtej pory następuje stały rozwój w tej dziedzinie, który zaowocował stworzeniem wielu zaawansowanych modeli sieci neuronowych.

Upraszczając, sieć neuronowa składa się z wielu wzajemnie połączonych węzłów nazywanych neuronami, tworzących tzw. warstwy:

- warstwa wejściowa
- warstwa ukryta (jedna lub więcej)
- warstwa wyjściowa

Do warstwy wejściowej przesyłane są dane i to z niej dane przesyłane są dalej do każdego neuronu warstwy ukrytej. Warstwa ukryta to warstwa pośrednia, w której zachodzi proces uczenia sieci, czyli szukania zależności pomiędzy danymi (liniowymi lub nieliniowymi). Sieć neuronowa może zawierać jedną lub wiele warstw ukrytych, a ich ilość zależy od złożoności rozwiązywanego problemu. Warstwa wyjściowa sieci neuronowej zwraca wynik rozwiązanego problemu.

Uproszczony schemat sieci neuronowej wielowarstwowej przedstawiono na Rys. 2.1, gdzie kolor czerwony reprezentuje neurony warstwy wejściowej do której dostarczane są informacje, kolor żółty reprezentuje warstwy ukryte, a warstwę wyjściową zaprezentuje kolor zielony.



Rys. 2.1. Uproszczony schemat sztucznej sieci neuronowej

Zasada działania sieci jest następująca: każdy z neuronów w sieci neuronowej ma przypisaną swoją wagę oraz próg zadziałania. Aby neuron przekazał dalej informację, musi zostać aktywowany, co następuje po przekroczeniu wartości progowej. Poniżej ustalonej wartości progowej, neuron nie przekazuje informacji do następnej warstwy sieci.

Aby sieć neuronowa mogła rozwiązywać postawione problemy, najpierw musi zostać przeprowadzony proces jej uczenia. Proces uczenia sieci prowadzony jest na specjalnie przygotowanym zbiorze danych. Podczas uczenia sieci, do każdego neuronu przypisywana jest waga, tak aby funkcja kosztu [70] (wartość błędu sieci neuronowej) była jak najmniejsza. Im niższa wartość kosztu, tym dokładniejszy wynik zostanie zwrócony przez sieć neuronową. Funkcję kosztu określa się na etapie uczenia sieci - jako funkcję kosztu można wykorzystać np. sumę kwadratów błędów pomiędzy wartościami obliczonymi a rzeczywistymi. W trakcie uczenia sieci, dostarczone dane treningowe pozwalają nauczyć się w jaki sposób poprawnie rozwiązać zadanie - dane treningowe wraz z prawidłowymi wynikami wprowadzane są wielokrotnie do sieci neuronowej, a uzyskane wyniki porównywane są z prawidłowymi wynikami. Wynik porównania rzeczywistych wyników z wartościami obliczonymi przez sieć neuronową przekazywany jest z powrotem do sieci i następuje stopniowa zmiana wag dla poszczególnych neuronów. Początkowo wszystkie wagi mają charakter losowy, a co za tym idzie wynik modelu jest również losowy. W trakcie uczenia sieć staje się coraz bardziej dokładna w predykcji znanych wyników. Proces ten jest powtarzany aż do uzyskania wymaganej dokładności sieci neuronowej.

Obecnie dzięki dużemu wsparciu światowych liderów branży IT, następuje bardzo szybki rozwój szeroko rozumianej sztucznej inteligencji, a zwłaszcza sieci neuronowych

czy uczenia maszynowego. Łatwy dostęp do specjalistycznego oprogramowania oraz darmowych szkoleń z zakresu programowania sieci neuronowych, sprawia, że bardzo łatwo rozpocząć przygodę z sztuczną inteligencją. Świetnym przykładem są takie firmy jak NVIDIA [65], wiodący producent kart graficznych czy Google [60] światowy lider branży IT. Firmy te są bardzo mocno zaangażowane w projekty wspierające algorytmy AI, oferując cały szereg bezpłatnych szkoleń z tego zakresu oraz darmowe oprogramowanie, a nawet wsparcie sprzętowe takie jak Colab [58].

Łatwy dostęp do nowych technologii przekłada się na próby drożenia rozwiązań z zakresu AI do wielu aspektów codziennego życia. Coraz więcej zagadnień technicznych próbuje się rozwiązywać wykorzystując możliwości jakie daje ta nowa dziedzina. Jedynym ograniczeniem zastosowania AI w naszym codziennym życiu jest tylko i wyłącznie nasza wyobraźnia.

Do ważniejszych zastosowań sieci neuronowych należą:

- predykcja, na podstawie danych wejściowych przewidywana są dane wyjściowe,
- klasyfikacja i rozpoznanie,
- kojarzenie danych, sieć pomaga wykrywać istotne powiązania pomiędzy danymi,
- analiza dostępnych danych,
- filtracja sygnałów, sieć wykorzystywana jako filtr danych,
- optymalizacja, sieć wykorzystywana do optymalizacji procesów.

Obecnie coraz częściej wykorzystuje się algorytmy uczenia maszynowego do obliczenia wyników bardzo skomplikowanych modeli matematycznych. Właściwy dobór sieci neuronowej, etap uczenia sieci neuronowej oraz walidacja stworzonego modelu jest procesem czasochłonnym. Jednak w odróżnieniu od innych technik obliczeniowych (np obliczeń numerycznych CFD (ang. Computational Fluid Dynamics), które każdorazowo wymagają długiego czasu do obliczenia wyników, raz wytrenowany model sieci neuronowej pozwala otrzymać wynik prawie natychmiast po wprowadzeniu nowych danych wejściowych. Jest to jedna z największych zalet sieci neuronowych. Ponadto sieci neuronowe umożliwiają rozwiązywanie skomplikowanych problemów, bez konieczności znajomości matematycznych reguł opisujących zagadnienie - sieci neuronowe na podstawie dostarczonych danych same odnajdują powiązania i zależności pomiędzy dostarczonymi danymi.

Na potrzeby rozwiązania postawionego problemu w tej rozprawie wykorzystano jeden z obszarów szeroko rozumianej sztucznej inteligencji AI jakim jest uczenie maszynowe ML (ang. Machine Learning). W uczeniu maszynowym algorytmy trenowane są pod kątem znajdowania wzorców i korelacji w dużych zbiorach danych w celu znalezienia najlepszego

rozwiązania. Dokładność modeli wykorzystujących uczenie maszynowe zależy jest od ilości i jakości dostępnych danych. Uczenie Maszynowe dzieli się na trzy zasadnicze rodzaje: nadzorowane, bez nadzoru i wzmacniane.

W zrealizowanej pracy skorzystano z nadzorowanego uczenia maszynowego, w którym wykorzystany został wcześniej przygotowany zestaw danych, na podstawie których model jest trenowany aby znaleźć poprawne rozwiązania. Dzięki takiemu rozwiązaniu możliwa jest analiza nowych danych i szukanie rozwiązań, które sprawdziły się w podobnych, wcześniej analizowanych przypadkach.

## 2.2. Korelacja danych

Celem pracy jest wyrównanie rozkładu temperatury za pomocą zmiany parametrów eksploatacyjnych analizowanego kotła, co powinno przełożyć się na ograniczenie fluktuacji erozji rur ekranowych w komorze paleniskowej. Aby wpływać na temperaturę na ruszcie kotła, konieczna jest zmiana optymalizacja parametrów kotła pod kątem rozkładu temperatur, bez zmiany jego wydajności.

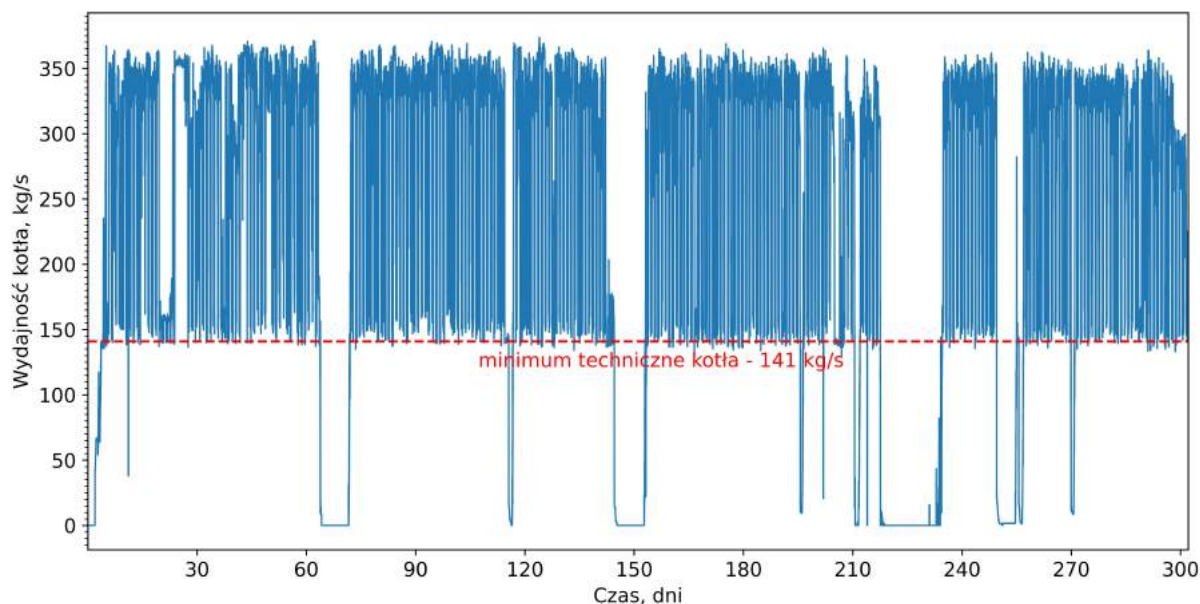
Aby podołać temu zadaniu, prace nad koncepcją ograniczenia erozji powierzchni ogrzewalnych w kotle fluidalnym rozpoczęto od znalezienia korelacji pomiędzy parametrami eksploatacyjnymi analizowanego kotła fluidalnymi takimi jak ilość dostarczanego paliwa i powietrza do komory paleniskowej a temperaturą mierzoną w 12 punktach na wysokości 250 mm nad rusztem komory paleniskowej. Rozmieszczenie zabudowanych pomiarów temperatury zaprezentowano na Rys. 1.6.

Sprawdzenie wzajemnych korelacji pomiędzy ustalonymi parametrami wykonano w oparciu o współczynnik korelacji liniowej Pearson'a  $|r|$ , który określa poziom zależności liniowej między zmiennymi [34]. Wartość współczynnika korelacji  $|r|$  pozwala określić siłę wzajemnych zależności pomiędzy analizowanymi parametrami. Współczynnik korelacji liniowej Pearson'a może przyjmować wartość od  $-1$  to  $+1$ , a znak współczynnika  $|r|$  wskazuje na kierunek korelacji. Jeżeli współczynnik jest ujemny oznacza, że wzrostowi jednej zmiennej towarzyszy zmniejszenie drugiej zmiennej, natomiast jeżeli współczynnik jest dodatni wzrostowi jednej zmiennej towarzyszy wzrost drugiej zmiennej. Wielkość współczynnika korelacji  $|r|$  wskazuje na siłę korelacji, i może być interpretowany jako:

- $|r| < 0.2$  praktycznie brak zależności pomiędzy zmiennymi,
- $0.2 < |r| < 0.4$  wyraźna, ale słaba zależność,
- $0.4 < |r| < 0.7$  umiarkowana zależność,
- $0.7 < |r| < 0.9$  dosyć silna zależność,

- $|r| > 0.9$  bardzo silna liniowa zależność pomiędzy zmiennymi.

Do obliczeń wartości współczynnika korelacji  $|r|$  z systemu *DCS* pobrano dane ruchowe za okres około dziesięciu miesięcy eksploatacji analizowanego kotła. Wybrany okres eksploatacji obejmuje cały zakres zmian wydajności kotła fluidalnego, od minimum technicznego równego 141 kg/s do maksymalnej wydajności kotła wynoszącej 361 kg/s. Zmiany obciążenia kotła w tym okresie zaprezentowano na Rys. 2.2 (kolor niebieski).



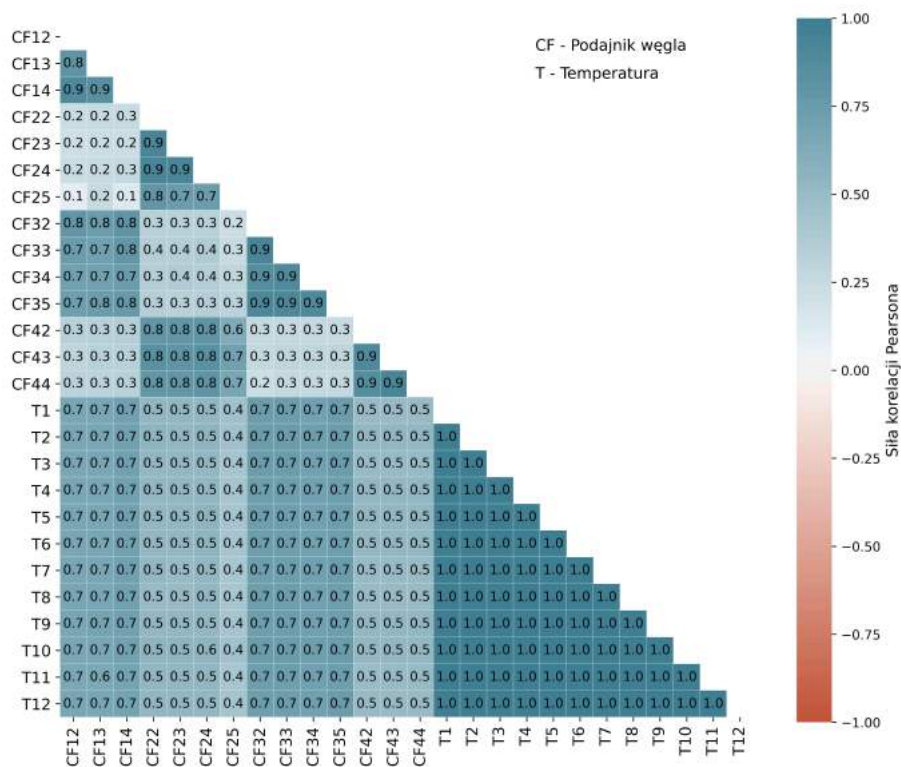
Rys. 2.2. Zmiana wydajności kotła fluidalnego w analizowanym okresie czasu

Na podstawie zebranych danych obliczono wartość współczynnika korelacji  $|r|$  pomiędzy temperaturą  $T1 \div T12$  mierzoną na ruszcie komory paleniskowej a parametrami ruchowymi analizowanego kotła fluidalnego, takimi jak ilość paliwa dostarczanego do kotła, ilość powietrza (pierwotnego i wtórnego) dostarczanego do kotła, ciśnienia w komorze paleniskowej czy wydajności kotła. Obliczone wartości współczynnika korelacji  $|r|$  zawierają się w granicach  $0.3 \div 0.9$ , co oznacza, że temperatura na ruszcie komory paleniskowej jest dobrze skorelowana z parametrami ruchowymi kotła. Na podstawie tych wyników, wytypowano zmienne, które będą wprowadzone do modelu do predykcji temperatury.

Wartość współczynnika korelacji  $|r|$  dla najistotniejszych korelacji pomiędzy temperaturą na ruszcie kotła ( $T1 \div T12$ ) a ilością dostarczanego paliwa przez poszczególne podajniki węgla (CF) oraz pomiędzy temperaturą na ruszcie kotła ( $T1 \div T12$ ) a powietrzem wtórnym dostarczanym przez palniki rozpałkowe zaprezentowano odpowiednio na Rys. 2.3 oraz Rys. 2.4.

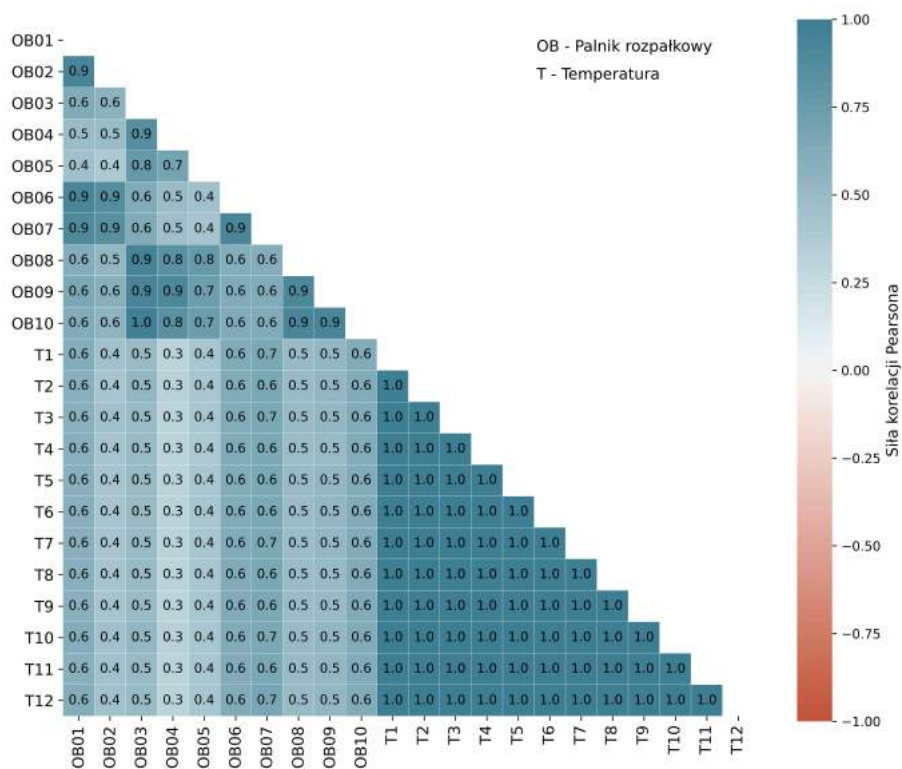
Parametry kotła w analizowanym okresie dla którego obliczono wzajemne korelacje zmieniały się w następującym zakresie:

- temperatura T1÷T12 - 860÷930 °C
- ilość paliwa dostarczanego do podajników węgla - 0÷7 kg/s
- ilość powietrza wtórnego dostarczanego do palników rozpałkowych - 0÷6 Nm<sup>3</sup>/s



Rys. 2.3. Obliczony współczynnik korelacji Pearsona  $|r|$  pomiędzy temperaturą a ilością paliwa dostarczaną przez podajniki węgla CF





Rys. 2.4. Obliczony współczynnik korelacji Pearsona  $|r|$  pomiędzy temperaturą a ilością powietrza wtórnego dostarczaną przez palniki rozpałkowe

### 2.3. Model Predykcyjny

Wiedza z zakresu występujących korelacji pomiędzy temperaturą na ruszcie kotła a pozostałymi parametrami ruchowymi kotła umożliwiła rozpoczęcie prac na stworzeniem modelu do predykcji temperatury na podstawie danych ruchowych kotła. Wybrane dane wejściowe do sieci neuronowej dobrze są skorelowane z temperaturą, jednocześnie odzwierciedlają jakość dostarczanego paliwa do kotła (np. ciśnienie mierzone w dolnej części komory paleniskowej).

Założenie jest następujące: stworzyć model predykcyjny, umożliwiający obliczenie temperatury w 12 punktach na ruszcie kotła, w oparciu o bieżące dane operacyjne kotła fluidalnego, które są rejestrowane w systemie *DCS*. Na podstawie występujących wzajemnych korelacji, do stworzenia modelu do predykcji temperatury wytypowano następujące dane:


- 2 pomiary przepływu pary świeżej,
- 14 pomiarów wydajności podajników węgla,
- 10 pomiarów przepływu powietrze wtórnego (+2,4,6 m),
- 10 pomiarów przepływu powietrza wtórnego do palników rozpałkowych,
- 4 pomiary przepływu powietrza pierwotnego,
- 8 pomiarów ciśnienia w komorze paleniskowej.

Pomiar temperatury na ruszcie analizowanego kotła realizowany jest przez dwanaście pomiarów temperatury (lokalizacja pomiarów temperatury Rys. 1.6). Model predykcyjny obliczający temperaturę został tak skonfigurowany, aby warstwa wyjściowa sieci neuronowej posiadała jedno wyjście - a więc obliczała jedną temperaturę. Aby obliczyć dwanaście temperatur zbudowano więc dwanaście modeli, a wynik obliczeń ze wszystkich modeli tworzy rozkład temperatury  $T1 \div T12$ , który jest mierzony na wysokości 250 mm powyżej rusztu kotła.

Następnym krokiem było opracowanie konfiguracji sieci neuronowej do predykcji temperatury w komorze paleniskowej. Do zaprojektowania modelu do predykcji wykorzystano ogólnie dostępne oprogramowanie typu Open-Source *Python* [69] wraz z dostępnymi bibliotekami *TensorFlow* [72], które zawierają większość znanych algorytmów ANN.

Stworzenie sieci neuronowej wymaga dostarczenia danych wejściowych, które są niezbędne do nauki modelu i późniejszej jego walidacji. W tym celu z systemu *DCS* pobrano dane ruchowe, na podstawie których model oblicza temperaturę na ruszcie komory paleniskowej. Dane pobrano z systemu za okres od Listopad 2019 (po zakończeniu

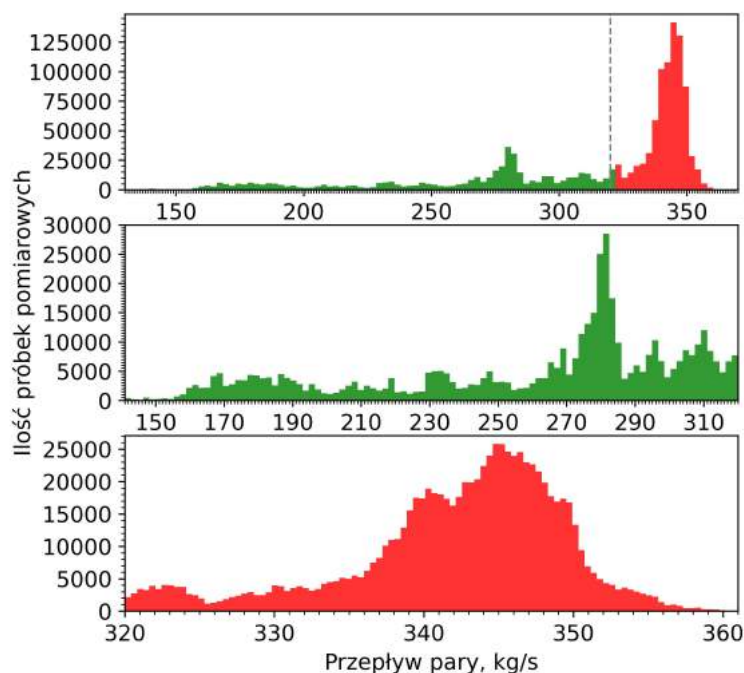
remontu kapitalnego analizowanego kotła) do Lipiec 2020 (rozpoczęcie prac nad modelem predykcynnym), z pominięciem okresów postojów remontowych bloku energetycznego. Zmiany wydajności analizowanego kotła w tym okresie zaprezentowano na Rys. 2.5. Kolor czerwony reprezentuje okres, w którym analizowany kocioł pracował z wydajnością powyżej 320 kg/s produkcji pary świeżej, kolor zielony reprezentuje obciążenie kotła niższe niż 320 kg/s pary świeżej.



Rys. 2.5. Zmiana wydajności analizowanego kotła fluidalnego w okresie 11.2019÷07.2020

Analiza wydajności kotła w analizowanym okresie wskazuje, że dominującym zakresem wydajności kotła fluidalnego jest praca z wydajnością pary powyżej 320 kg/s (sumarycznie 63% analizowanego czasu pracy kotła), co zaprezentowano na Rys. 2.6. Kolor czerwony zaprezentuje okres, w którym blok pracował z wydajnością powyżej 320 kg/s pary świeżej, kolor zielony reprezentuje okres w którym obciążenie kotła było niższe niż 320 kg/s pary świeżej.

Nie ma ograniczeń dla zakresu pracy modelu do predykcji temperatury - prawidłowe działanie modelu zależy jedynie od jakości dostarczonych danych do nauki modelu. Możliwe jest stworzenie modelu obliczającego temperaturę na ruszcie dla pełnego zakresu wydajności kotła (od minimum technicznego 141 kg/s do maksymalnej wydajności kotła 361 kg/s). Biorąc pod uwagę rozkład wydajności analizowanego kotła (Rys. 2.6) skoncentrowano się na opracowaniu modeli do predykcji temperatury dla wydajności kotła powyżej 320 kg/s. Drugim argumentem, który przemawiał za taką konfiguracją modelu do predykcji był fakt, że w zakresie wydajności analizowanego kotła 320÷361 kg/s (średnio 340 kg/s) ilość powietrza dostarczanego do komory paleniskowej (powietrze wtórne + pierwotne) zmienia się w przedziale 260÷300 m<sup>3</sup>/s (średnio 280 m<sup>3</sup>/s). W zakresie wydajności analizowanego kotła 141÷320 kg/s (średnio 270 kg/s) ilość dostarczanego powietrza do komory paleniskowej zmienia się w przedziale 150÷260 m<sup>3</sup>/s (średnio 236 m<sup>3</sup>/s). Większa ilość spalin zwiększa prędkość spalin w komorze paleniskowej, a erozja rur ekranowych zależy od prędkości podniesionej do potęgi  $n$ , zgodnie z Rów. (3.4). Tak znacząca różnica w ilości powietrza dostarczanego do komory paleniskowej dla zakresu wydajności powyżej 320 kg/s w stosunku do wydajności poniżej 320 kg/s, sprawia, że intensywność erozji jest znacznie większa dla górnego zakresu pracy analizowanego kotła.



Rys. 2.6. Ilość próbek pomiarowych dla zakresów wydajności kotła w okresie 11.2019÷07.2020

Ponadto takie zawężenie zakresu działania modelu do predykcji na tym etapie pozwoli zwiększyć dokładność obliczeń temperatury na ruszcie analizowanego kotła.

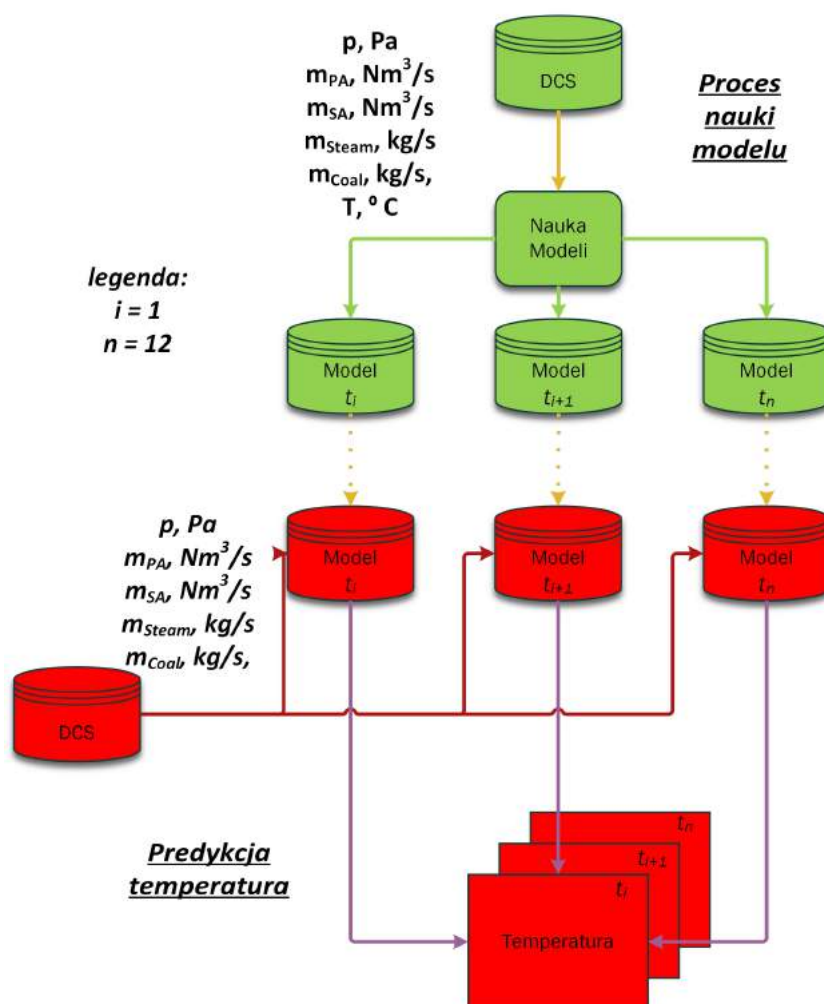
### 2.3.1. Zasada działania modelu do predykcji temperatury

W celu obliczenia 12 temperatur  $T1 \div T12$  zaprogramowano łącznie 12 modeli predykcyjnych - jeden model dla każdej temperatury. Tym samym proces nauki modelu został powtórzony 12 razy. Założono, że każdy model trenowany jest dokładnie na tych samych danych wejściowych (wytypowanych parametrach ruchowych kotła), różni się jedynie temperaturą wyjściową (mierzona temperatura na ruszcie kotła), której predykcji jest uczony. Rozkład temperatury na ruszcie komory paleniskowej otrzymujemy łącząc wyniki obliczeń temperatury z każdego modelu predykcyjnego.

Lokalizacja fizycznej zabudowy fizycznych pomiarów temperatury na ruszcie komory zaprezentowana jest na Rys. 1.6.

Uproszczoną zasadę działania modeli obliczeniowych temperatury na ruszcie komory przedstawiono na Rys. 2.7. Kolor zielony reprezentuje proces uczenia modeli w oparciu o historyczne dane ruchowe kotła, które zostały dostarczone do modelu na etapie uczenia. Na tym etapie powstaje 12 gotowych modeli predykcyjnych, które zostały zapisane. Przygotowane modele wykorzystywane są następnie do wykonywania obliczeń temperatury na ruszcie komory  $T1 \div T12$ , na podstawie nowych, nieznanych wcześniej

danych ruchowych kotła. Jak wspomniano wcześniej proces nauki modeli jest czasochłonny i w zależności od ilości danych od stopnia skomplikowania sieci neuronowej (np. ilość warstw czy ilość neuronów w danej warstwie) może trwać kilka a czasem kilkanaście godzin. Kolor czerwony reprezentuje proces obliczenia temperatury  $T_1 \div T_{12}$  na podstawie nowych danych ruchowych przy wykorzystaniu wcześniej (kolor zielony) wytrenowanych modeli do predykcji. W odróżnieniu od procesu nauki sieci neuronowych, proces obliczenia temperatury przy wykorzystaniu gotowych wytrenowanych modeli jest bardzo szybki - wyniki obliczeń dostajemy bezpośrednio po wprowadzeniu nowych danych ruchowych.



Rys. 2.7. Uproszczony schemat działania sieci neuronowych do predykcji temperatur  $T_1 \div T_{12}$

### 2.3.2. Dane do nauki sieci neuronowych

Etap uczenia sieci neuronowych wymaga dostarczenia danych o wysokiej jakości (dane nie powinny posiadać zakłóceń). Im więcej danych dostarczymy do modelu na etapie jego uczenia, tym większą otrzymany dokładność końcowego wyniku. Aby sprostać temu zadaniu, z systemu *DCS* pobrano dane ruchowe analizowanego kotła fluidalnego za okres od Listopada 2019 do Lipca 2020. Zmianę wydajności kotła fluidalnego w tym okresie zaprezentowano na Rys. 2.6. Pobrane surowe dane z *DCS* zostały poddane obróbce w celu usunięcia zakłóceń w postaci *szumów* pochodzących np. od niesprawnego pomiaru.

Dane do nauki sieci neuronowych zostały przefiltrowane pod kątem wartości, które występują podczas niezakłóconej eksploatacji kotła:

- wydajność powyżej 320 kg/s,
- temperatury w zakresie 860÷930 °C,
- przepływ powietrza wtórnego do palników rozpałkowych  $> 1 \text{ m}^3/\text{s}$ ,
- wydajność podajników węgla  $> 1 \text{ kg/s}$ ,
- ciśnienia w komorze paleniskowej w zakresie 40÷70mbar,
- dane uśrednione co 10 s.

Wprowadzenie powyższych założeń wyeliminowało fałszywe dane ruchowe kotła, występujące na skutek niesprawnych (uszkodzonych) pomiarów czy z chwilowych anomalii wynikających z krótkotrwałych zakłóceń stabilnej pracy bloku energetycznego. Podczas procesu filtrowania danych ruchowych kotła z początkowej wielkości około 1 500 000 zestawów danych ruchowych po uwzględnieniu powyższych kryteriów pozostało około 100 000 zestawów danych.

Ilość przygotowanych danych jest wystarczająca na potrzeby przeprowadzenia procesu nauki sieci neuronowej. Wcześniej przygotowane dane podzielono losowo wykorzystując zaimplementowaną w bibliotece *sklearn* oprogramowania *Python* gotową funkcję *train\_test\_split* [73]). Dane zostały podzielone, aby otrzymać zestawy danych koniecznych do przeprowadzania procesu nauki modeli jak również późniejszej walidacji, zgodnie z podziałem:

- 3000 zestawów danych do walidacji gotowego modelu do predykcji,
- 80% pozostałych danych do nauki modelu,
- 20% pozostałych danych do walidacji modelu na etapie jego nauki.

### 2.3.3. Architektura Modelu Predykcijnego

Sieci neuronowe wymagają indywidualnego podejścia do każdego zjawiska czy procesu, dla którego mają znaleźć rozwiązanie. Każdy model wymaga niejako zaprojektowania struktury sieci neuronowej, czyli dobrania wszystkich wymaganych parametrów, tak aby możliwe było otrzymanie prawidłowego wyniku. Nie ma konkretnych wytycznych jak powinna być skonfigurowana sieć neuronowa, zależy to od rodzaju i złożoności analizowanego zjawiska. Z pomocą przychodzą liczne fora internetowe, na których entuzjaści tej dziedziny zamieszczają gotowe przykłady rozwiązań. Użytkownicy tych stron bardzo chętnie dzielą się swoimi doświadczeniami, projektami oraz wiedzą. Oprócz szeregu dostępnych informacji, które można znaleźć na forach internetowych, istnieją również opracowane poradniki, które oferują „gotowe mapy” [56] ze wskazówkami jak dobrać właściwy algorytm do rozwiązania danego zagadnienia.

Ogólnie dostępna wiedza z zakresu ANN sprawia, że stosunkowo łatwo można znaleźć wskazówki jak rozwiązać nasz przypadek. Zatem wydaje się, że problemem nie jest znalezienie rozwiązania przy pomocy sieci neuronowych, ale znaleźć optymalne rozwiązanie naszego zadania, dla którego otrzymamy największą dokładność. Tym bardziej, że z uwagi na ilość dostępnych algorytmów, parametrów i ich wzajemnej konfiguracji, zadanie to należy do najprostszych.

Poza wyborem właściwego algorytmu rozwiązującego dane zadanie (ang. optimizer), trzeba skonfigurować szereg pozostałych parametrów (ang. hyperparameters), takich jak ilość ukrytych warstw sieci neuronowej, ilość neuronów w każdej z warstw oraz szereg innych pozostałych parametrów modelu służących do kontroli procesu uczenia modelu, które wpływają na dokładność obliczeń wykonanych przez sieć neuronową [64].

Każda zmiana parametrów sieci neuronowej wpływa na zachowanie modelu, np. czas trwania nauki modelu, dokładność uzyskanych wyników czy wręcz możliwość rozwiązania postawionego zagadnienia czyli znalezienia poprawnego wyniku. Ustalenie optymalnej konfiguracji modelu do predykcji, to niejako metoda prób i błędów.

Z pomocą przy wyborze odpowiedniej sieci neuronowej przychodzą ogólnie dostępne narzędzia, które „wyręczają” nas w poszukiwaniu właściwych hyperparametrów sieci neuronowej, np. narzędzia zawarte w darmowej bibliotece *Optuna* [67], możliwej do zaimplementowania w oprogramowaniu *Python*, wykorzystującej dostępne biblioteki *PyTorch*, *Tensorflow*, *Keras*, *Scikit-Learn*, *XGBoost*, itp.. Narzędzie to pozwala na wykonanie testów różnych konfiguracji modeli oraz dobór niektórych parametrów sieci neuronowej np. prędkości uczenia sieci (ang. learning rate).

W opisaney rozprawie, poszukiwanie konfiguracji modelu do predykcji temperatury przeprowadzono wykonując szereg testów, które podzielono na kilka etapów, zawężając ilość testowanych sieci neuronowych. Aby znaleźć optymalną konfigurację modelu do

predykcji wykorzystywano wcześniej przygotowane dane eksploatacyjne analizowanego kotła. Proces uczenia modelu predykcyjnego jest czasochłonny, dlatego w początkowych testach ilość danych ograniczono do 1000 danych (800 zestawów danych treningowych i 200 danych do walidacji w trakcie nauki modelu). Łącznie na potrzeby znalezienia optymalnej konfiguracji modelu do predykcji temperatury przetestowano kilkanaście tysięcy różnych konfiguracji parametrów sieci neuronowych, analizując jak zmiana poszczególnych parametrów (funkcja aktywacji,[49], bias initializer [62], weight initializer [76], batch size [55] czy *learning rate* [75]) wpływa na dokładność uzyskiwanych wyników gotowego modelu do predykcji.

Parametry sieci neuronowej zmieniano w zakresie:

- estymator: SGD, Adam, Nadam, Adagrad, RMSprop,
- funkcja aktywacji: relu, softmax, softplus, softsign, tanh, selu, elu,
- *bias initializer*: RandomNormal, RandomUniform, Zeros, Ones, GlorotNormal, GlorotUniform, Constant, VarianceScaling,
- *weight initializer*: zeros, uniform, normal, he normal, lecun uniform, glorot uniform,
- *batch size*: 16,32,64,
- *learning rate*: 0.01, 0.001, 0.0001, 0.00001
- ilość ukrytych warstw: 1, 2, 4, 6, 8, 12,
- ilość neuronów w ukrytych warstwach: 64, 128, 256, 512, 1024.

Po zakończeniu wstępnych testów porównano wyniki końcowe gotowych modeli. Jako metodę porównania dokładności modeli przyjęto wartość obliczonego błędu średniokwadratowego *MSE* (ang. Mean Squared Error) [?].

Po zakończeniu pierwszego etapu testów konfiguracji modeli do predykcji i ocenie ich dokładności na podstawie obliczonych wartości *MSE*, do dalszej nauki wytypowano dwa estymatory *Adam* [52, 51, 53] oraz *RMSprop* [66],[50].

Do kolejnego etapu testów zwiększono ilość danych treningowych: 30 000 danych do nauki modelu oraz 6000 danych do walidacji modelu na etapie nauki. Na podstawie wcześniejszych wyników, parametry modeli w trakcie testów zmieniano w zakresie:

- estymator: Adam, RMSprop,
- funkcja aktywacji: relu, tanh, selu,
- *bias initializer*: RandomNormal, RandomUniform, Zeros, Ones, GlorotNormal, GlorotUniform, Constant, VarianceScaling,



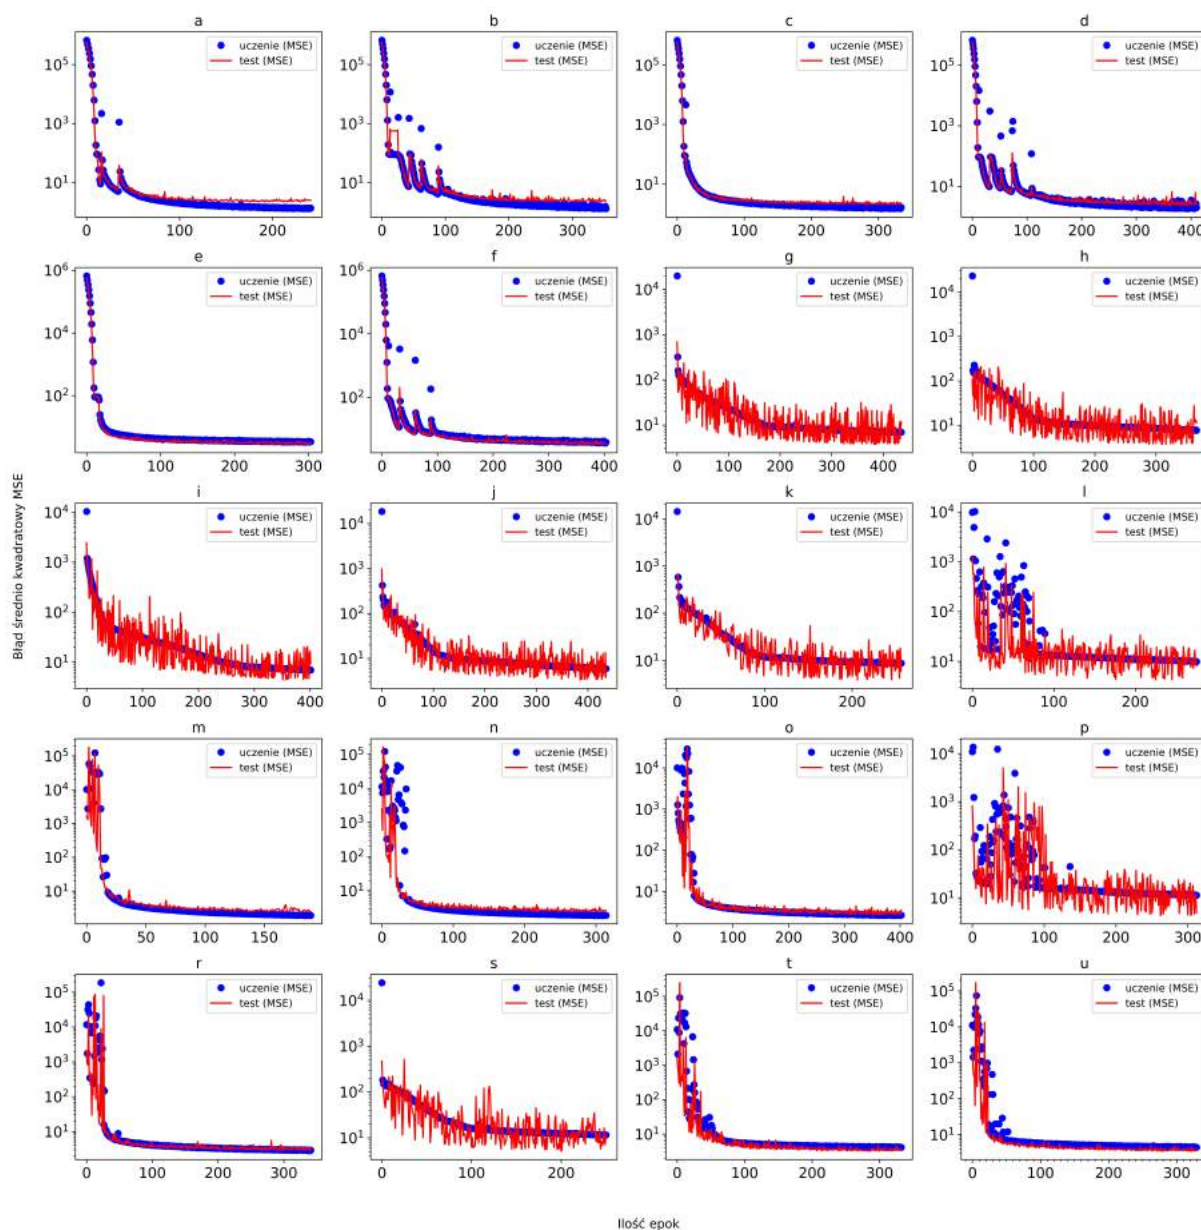
- *weight initializer*: zeros, uniform, normal, he normal, glorot uniform ,
- *batch size*: 16, 32, 64,
- *learning rate*: 0.001,
- ilość ukrytych warstw: 2, 4, 8,
- ilość neuronów w ukrytych warstwach: 64, 128.

W tym etapie wykonano obliczenia dla kilkudziesięciu konfiguracji modeli, ponownie proces uczenia zajął łącznie kilkaset godzin z uwagi na znaczące zwiększanie ilości danych treningowych. Na podstawie obliczonej wartości błędu średniokwadratowego  $MSE$  dwadzieścia najlepszych modeli do predykcji, a podstawowe wartości parametrów sieci neuronowych dla tych modeli zaprezentowano w Tab. 2.5,2.6.

Podczas nauki sieci neuronowej monitorowany jest przez cały czas błąd średniokwadratowy. Przy prawidłowo dobranych parametrach modelu, wraz z kolejnymi iteracjami sieć stopniowo zmienia wartość wag dla poszczególnych neuronów, a wynik obliczeń temperatury jest coraz dokładniejszy. Przebieg procesu nauki testowanych modeli dla jednej z temperatur zaprezentowano Rys. 2.8. Niebieskie punkty reprezentują obliczoną wartość błędu średniokwadratowego dla procesu nauki sieci neuronowej, natomiast czerwona linia obrazuje obliczoną wartość błędu średniokwadratowego dla danych testowych. Po przebiegu wartości obliczonego błędu (Rys. 2.8) widać, jak model reagował na kolejne zmiany wartości wag dla poszczególnych neuronów. Można zaobserwować, że trzy rodzaje zachowanie testowanych modeli w trakcie nauki. Kilka modeli (np. a,c) wraz z każdą kolejną iteracją wykonuje obliczenia z większą dokładnością. Niektóre modele (np. d,u) w początkowej fazie nauki zachowuje się dosyć nieprzewidywalnie, ale sieć szybko prawidłowo koryguje wagi neuronów i wynik obliczeń jest coraz bliższy wartościom rzeczywistym temperatury. Część modeli (np. g,p) przez cały okres nauki wykazuje dużą niestabilność obliczanego wyniku. Ponadto charakterystyczne jest, że każda sieć neuronowa wymagała innej ilości powtórzeń aby osiągnąć najmniejszy błąd średniokwadratowy, czyli największą dokładność wyniku.


Dokładność poszczególnych sieci można ocenić również analizując wartość temperatury rzeczywistej oraz temperatury obliczonej przez model predykcijny. Rysunek 2.9 prezentuje różnice w rozkładzie temperatury rzeczywistej do temperatury obliczeniowej dla poszczególnych modeli. Zielone punkty na wykresach to rozkład temperatur dla danych testowych, niebieskie punkty to rozkład temperatur dla danych testowych. Bardzo łatwo na tej podstawie oszacować dokładność wyników obliczanych przez sieć neuronową - większość modeli cechuje się prawidłowym rozkładem temperatur. W modelach g,s widać duże różnice pomiędzy wartością rzeczywistą a obliczoną temperaturą.

Rysunek 2.10 prezentuje obliczony błąd względny (zgodnie z Rów.(2.4)) dla poszczególnych konfiguracji modeli. Im bardziej płaskie skupienie punktów, tym większa dokładność obliczeń modeli i mniejszy błąd obliczeń. Dla najlepszych testowanych modeli, obliczony błąd względny jest poniżej 0.5% dla większości dostarczonych danych.

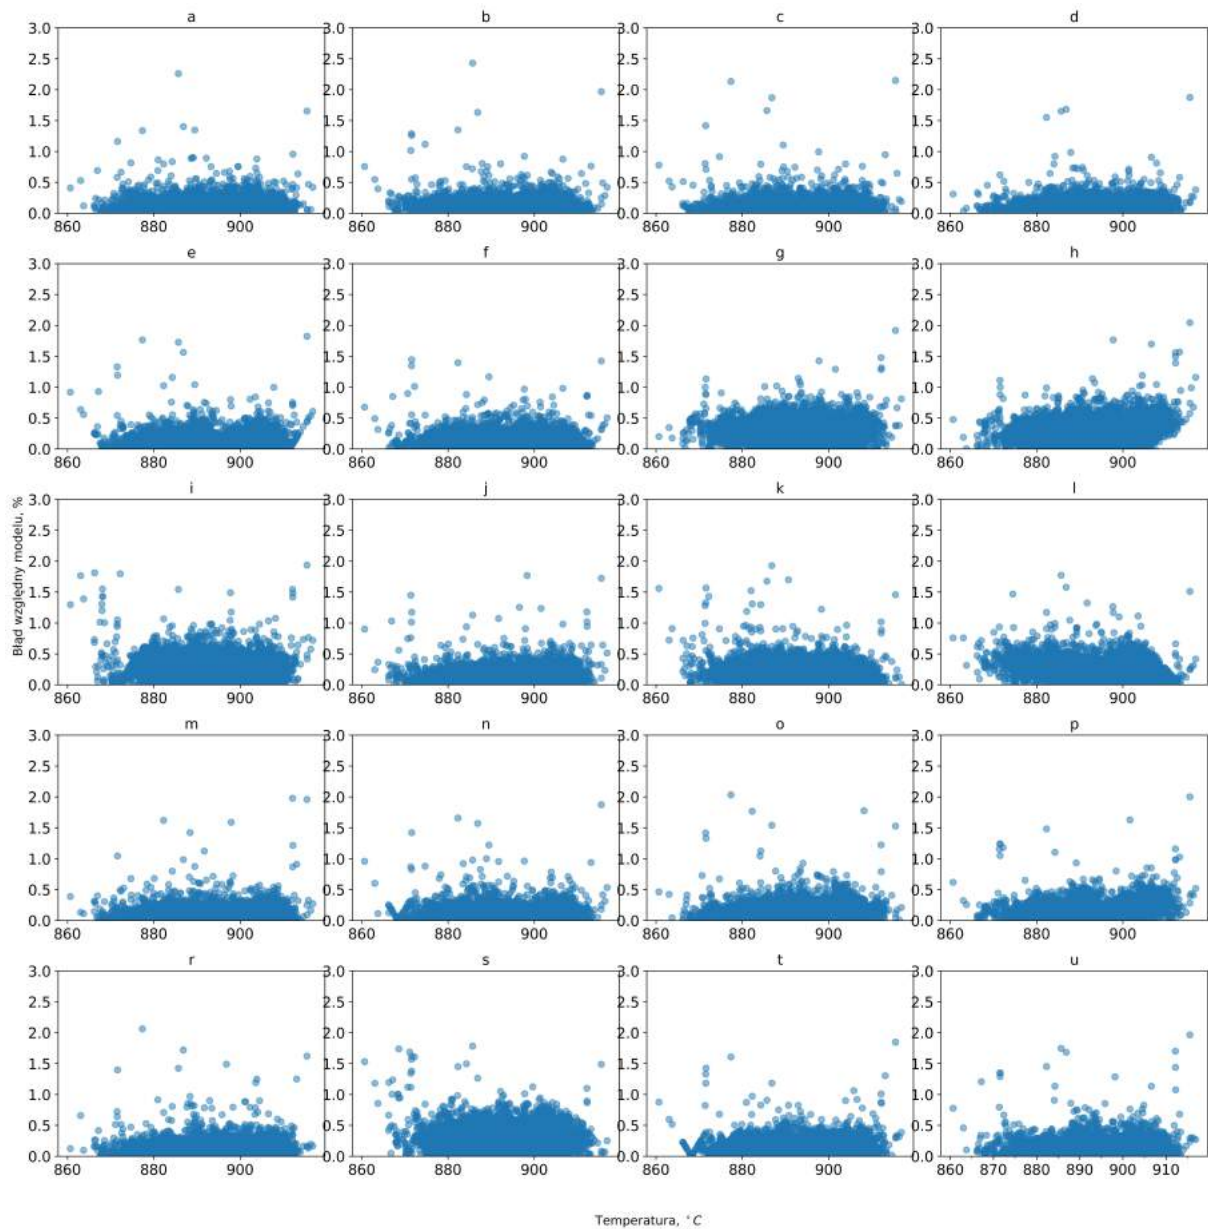


Rys. 2.8. Obliczony błąd średniokwadratowy  $MSE$  w trakcie kolejnych iteracji procesu uczenia dla temperatury  $T_1$

Po zakończeniu procesu nauki modeli sprawdzono, jak poszczególne sieci neuronowe zachowują się dla nowych danych, które nie zostały użyte na etapie uczenia modelu. Dla najlepszych dwudziestu modeli wykonano obliczenia temperatury dla rzeczywistych



Rys. 2.9. Rozkład temperatury rzeczywistej T1 do temperatur obliczonej T1



Rys. 2.10. Obliczony błąd względny testowanych modeli dla temperatury T1

danych, które zostały przygotowane na etapie filtrowania danych do nauki modelu. Upřednio przygotowane 3000 danych wykorzystano w tym etapie, i dla każdego modelu wykonano obliczenia temperatury T1÷T12.

Po wykonaniu obliczeń temperatury przez modele, porównano otrzymane wyniki. Dla obliczonych temperatur przez poszczególne modele obliczono generowane przez model błędy:

błąd średniokwadratowy  $MSE$  [1]:

$$MSE(T_{DCS}, T_{pred}) = \frac{1}{N} \times \sum_{i=1}^N (T_{DCS,i} - T_{pred,i})^2 \quad (2.1)$$

współczynnik determinacji  $R^2$  [1],[77]:

$$R^2(T_{DCS}, T_{pred}) = \frac{\sum_{i=1}^N (T_{DCS,i} - T_{pred,i})^2}{\sum_{i=1}^N (T_{DCS,i} - \bar{T}_{DCS})^2} \quad (2.2)$$

błąd bezwzględny  $\Delta T$ :

$$\Delta T_i = T_{DCS,i} - T_{pred,i} \quad (2.3)$$

błąd względny  $\delta_T$ :

$$\delta_{T_i} = \frac{|T_{DCS,i} - T_{pred,i}|}{T_{DCS,i}} \times 100\% \quad (2.4)$$

odchylenie standardowe z próby  $\sigma_T$ :

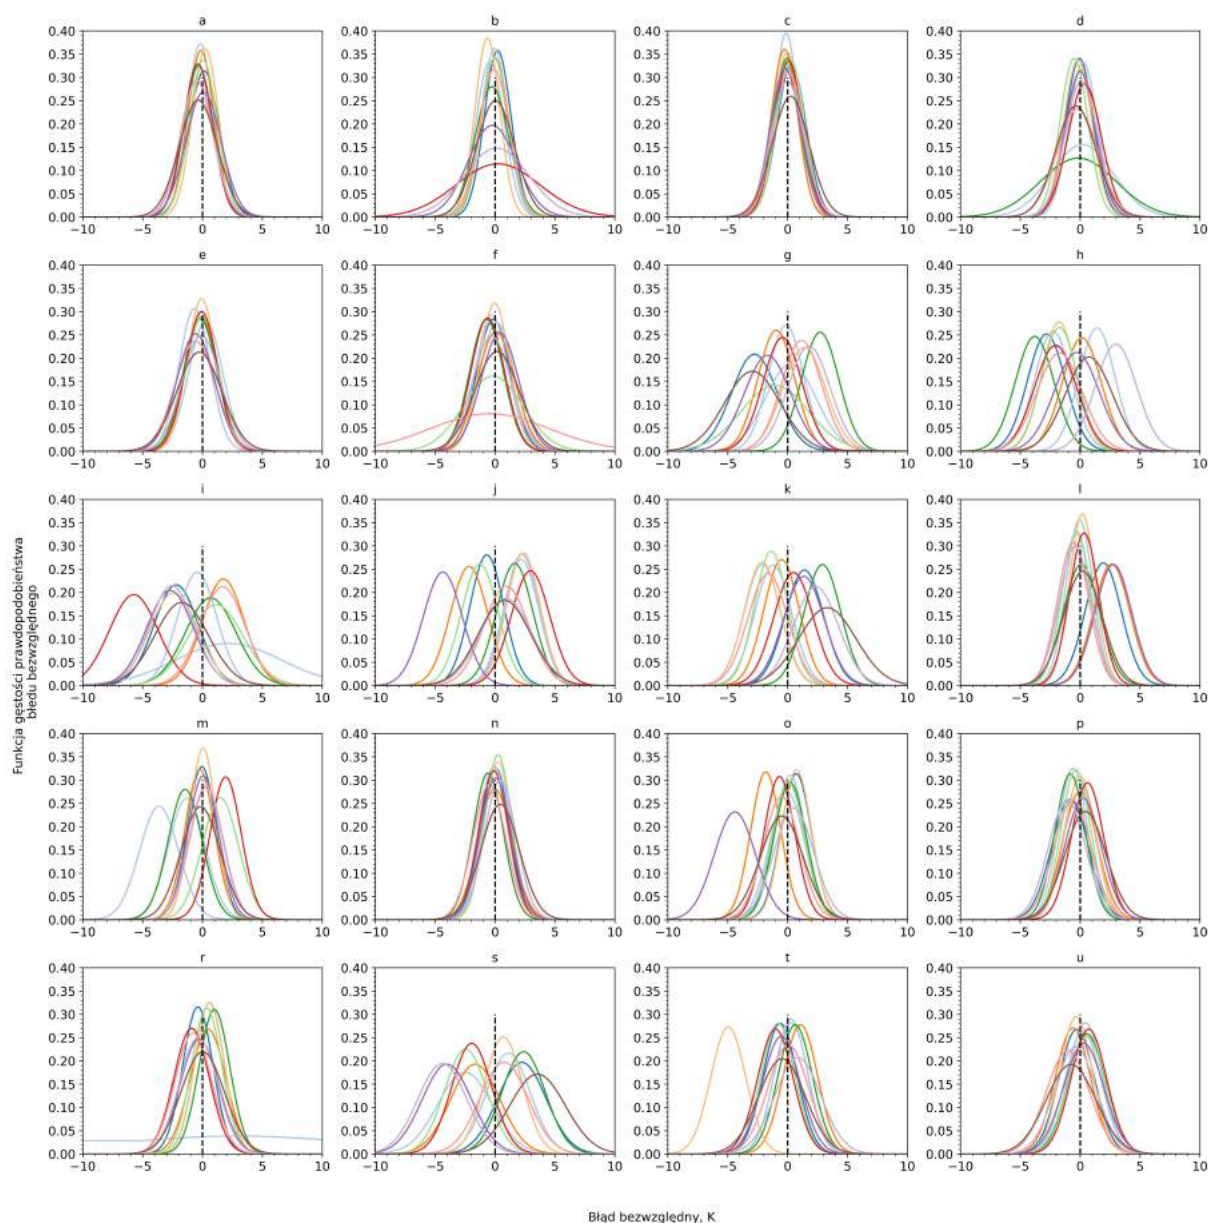
$$\sigma_T = \sqrt{\frac{\sum_{i=1}^N (\Delta T_i - \bar{\Delta T})^2}{N - 1}} \quad (2.5)$$

średni błąd bezwzględny estymacji  $MAE$  [1]:

$$MAE = \frac{1}{N} \times \sum_{i=1}^N |T_{DCS,i} - T_{pred,i}| \quad (2.6)$$

gdzie  $T_{DCS}$  jest temperaturą rzeczywistą zmierzoną w analizowanym kotle fluidalnym,  $T_{pred}$  jest temperaturą obliczoną przez model do predykcji,  $N$  to ilość danych do walidacji a  $i$  to kolejny zestaw danych wejściowych.

Błąd bezwzględny  $\Delta T$  obliczony zgodnie z Rów. (2.3) dla wybranych modeli dla temperatur T1÷T12 zaprezentowano w postaci funkcji gęstości rozkładu prawdopodobieństwa błędu bezwzględnego a wyniki zaprezentowanego na Rys. 2.11. Bardzo wyraźnie widać różnice w dokładności obliczeń temperatury dla poszczególnych modeli. Sieci neuronowe a,c,e,n oraz o cechują się wysoką dokładnością wyników obliczeń dla wszystkich



Rys. 2.11. Funkcja gęstości rozkładu prawdopodobieństwa błędów bezwzględnych testowanych modeli dla temperatury T1÷T12

dwunastu temperatur. Liczbową wartość obliczonego odchylenia standardowego  $\sigma$  błędów bezwzględnych zestawiono w Tab. 2.1. Najniższe obliczone wartości  $\sigma$  (a więc najlepsze) dla poszczególnych temperatur zostały pogrubione.

Oprócz wartości odchylenia standardowego  $\sigma$ , obliczono błąd średniokwadratowy  $MSE$ , współczynnik determinacji  $R^2$ , oraz wartość błędów bezwzględnych i względnych. Otrzymane wyniki dla temperatury T1 zestawiono w Tab. 2.2,2.3,2.4.

Tabela 2.1

Obliczona wartość odchylenia standardowego  $\sigma$ . Opis modeli Tab. 2.5,2.6

model	T1 ,K	T2 ,K	T3 ,K	T4 ,K	T5 ,K	T6 ,K	T7 ,K	T8 ,K	T9 ,K	T10 ,K	T11 ,K	T12 ,K
a	1.27	1.07	1.23	<b>1.11</b>	1.10	1.23	1.18	1.21	1.36	1.48	1.35	1.59
b	<b>1.11</b>	1.10	<b>1.19</b>	1.17	<b>1.04</b>	1.42	1.17	3.49	<b>1.26</b>	2.02	2.69	1.59
c	1.22	<b>1.01</b>	1.20	<b>1.11</b>	1.13	<b>1.17</b>	1.18	<b>1.19</b>	1.27	<b>1.25</b>	1.37	<b>1.54</b>
d	1.17	1.20	2.56	1.26	1.18	3.15	1.17	1.39	1.72	1.28	1.37	1.67
e	1.40	1.30	1.42	1.38	1.22	1.40	1.37	1.33	1.69	1.58	1.60	1.87
f	1.41	1.36	1.44	1.55	1.25	1.41	2.47	1.39	4.94	1.57	1.61	1.86
g	1.91	1.47	2.13	1.54	1.79	1.56	2.82	1.63	1.67	1.94	1.77	2.32
h	1.58	1.51	1.55	1.64	1.44	1.62	1.50	1.75	1.89	1.88	1.73	1.97
i	1.84	4.41	1.64	1.74	2.01	2.12	2.30	2.04	1.88	1.95	1.86	2.24
j	1.42	1.41	1.47	1.56	1.40	1.52	1.53	1.62	1.87	1.64	2.13	2.18
k	1.61	1.54	1.53	1.48	1.50	1.53	1.38	1.64	1.66	1.70	1.88	2.39
l	1.52	1.12	1.22	1.53	1.08	1.53	1.20	1.22	1.30	1.53	1.34	1.63
m	1.21	1.53	1.64	1.24	1.08	1.42	1.52	1.30	1.40	1.29	1.39	1.64
n	1.22	1.22	1.22	1.42	1.18	1.27	<b>1.13</b>	1.25	1.38	1.31	<b>1.33</b>	1.61
o	1.27	1.46	1.28	1.26	1.24	1.35	1.35	1.30	1.51	1.72	1.66	1.79
p	1.54	1.23	1.32	1.45	1.29	1.27	1.24	1.36	1.55	1.53	1.55	1.71
r	1.26	1.23	10.37	1.49	1.23	1.29	1.28	1.48	1.54	1.62	1.59	1.82
s	2.03	2.27	1.84	2.07	1.59	1.82	1.77	1.68	2.02	2.07	2.05	2.32
t	1.42	1.38	1.41	1.44	1.46	1.44	1.42	1.49	1.70	1.58	1.93	1.95
u	1.49	1.41	1.51	1.47	1.35	1.55	1.58	1.49	1.80	1.68	1.74	2.07

Tabela 2.2

Błędy obliczeń temperatury T1 dla wybranych sieci neuronowych, część 1

	a	b	c	d	e	f	g
Błąd średnio-kwadratowy MSE, Rów. (2.1)	1.72	3.18	1.54	2.96	2.29	4.52	6.61
współczynnik determinacji $R^2$ , Rów. (2.2)	0.98	0.96	0.98	0.97	0.97	0.95	0.92
Średni błąd względny, %, Rów. (2.4)	0.1	0.09	0.1	0.09	0.12	0.12	0.32
Odchylenie standardowe $\sigma$ , K, Rów. (2.5)	1.27	1.11	1.22	1.17	1.4	1.41	1.91

Tabela 2.3

Błędy obliczeń temperatury T1 dla wybranych sieci neuronowych, część 2

	h	i	j	k	l	m	n
Błąd średnio- kwadratowy MSE, Rów. (2.1)	7.17	11.27	7.35	6.49	3.46	3.89	1.78
współczynnik determinacji $R^2$ , Rów. (2.2)	0.92	0.86	0.91	0.93	0.96	0.95	0.98
Średni błąd względny, %, Rów. (2.4)	0.32	0.27	0.13	0.19	0.23	0.1	0.1
Odchylenie standardowe $\sigma$ , K, Rów. (2.5)	1.58	1.84	1.42	1.61	1.52	1.21	1.22

Tabela 2.4

Błędy obliczeń temperatury T1 dla wybranych sieci neuronowych, część 3

	o	p	r	s	t	u
Błąd średnio- kwadratowy MSE, Rów. (2.1)	4.17	2.38	11.95	10.54	4.9	2.89
współczynnik determinacji $R^2$ , Rów. (2.2)	0.94	0.97	0.87	0.87	0.94	0.97
Średni błąd względny, %, Rów. (2.4)	0.12	0.15	0.11	0.28	0.13	0.12
Odchylenie standardowe $\sigma$ , K, Rów. (2.5)	1.27	1.54	1.26	2.03	1.42	1.49



Tabela 2.5

Podstawowe parametry testowanych modeli do predykcji temperatury, część 1

Model	Konfiguracja modelu
a	Optimizer: Adam, Kernel: glorot uniform, Bias: zeros Activation: tanh, Unit: 128, Batch size: 32, Warstwy: 4 Użyte funkcje: Bez BatchSize, Bez DropOut
b	Optimizer: Adam, Kernel: glorot uniform, Bias: zeros Activation: tanh, Unit: 128, Batch size: 32, Warstwy: 8 Użyte funkcje: Bez BatchSize, Bez DropOut
c	Optimizer: Adam, Kernel: glorot uniform, Bias: zeros Activation: tanh, Unit: 128, Batch size: 32, Warstwy: 4 Użyte funkcje: Bez DropOut
d	Optimizer: Adam, Kernel: glorot uniform, Bias: zeros Activation: tanh, Unit: 128, Batch size: 32, Warstwy: 8 Użyte funkcje: Bez DropOut
e	Optimizer: Adam, Kernel: glorot uniform, Bias: zeros Activation: tanh, Unit: 128, Batch size: 32, Warstwy: 4 Użyte funkcje: BatchSize, DropOut
f	Optimizer: Adam, Kernel: glorot uniform, Bias: zeros Activation: tanh, Unit: 128, Batch size: 32, Warstwy: 8 Użyte funkcje: BatchSize, DropOut
g	Optimizer: RMSprop, Kernel: glorot uniform, Bias: GlorotUniform Activation: selu, Unit: 128, Batch size: 32, Warstwy: 4 Użyte funkcje: Bez DropOut
h	Optimizer: RMSprop, Kernel: normal, Bias: GlorotUniform Activation: selu, Unit: 128, Batch size: 32, Warstwy: 4 Użyte funkcje: Bez DropOut
i	Optimizer: RMSprop, Kernel: normal, Bias: Ones Activation: selu, Unit: 128, Batchsize: 32, Warstwy: 4 Użyte funkcje: Bez DropOut
j	Optimizer: RMSprop, Kernel: glorot uniform, Bias: GlorotUniform Activation: selu, Unit: 128, Batch size: 32, Warstwy: 4 Użyte funkcje: Bez BatchSize, Bez DropOut
k	Optimizer: RMSprop, Kernel: normal, Bias: GlorotUniform Activation: selu, Unit: 128, Batchsize: 32, Warstwy: 4, Użyte funkcje: Bez BatchSize, Bez DropOut

Tabela 2.6

Podstawowe parametry testowanych modeli do predykcji temperatury, część 2

Model	Konfiguracja modelu
l	Optimizer: RMSprop, Kernel: glorot uniform, Bias: GlorotUniform Activation: selu, Unit: 128, Batch size: 32, Warstwy: 8 Użyte funkcje: Bez BatchSize, Bez DropOut
m	Optimizer: RMSprop, Kernel: normal, Bias: GlorotUniform Activation: selu, Unit: 128, Batch size: 32, Warstwy: 8 Użyte funkcje: Bez BatchSize, Bez DropOut
n	Optimizer: RMSprop, Kernel: normal, Bias: Ones Activation: selu, Unit: 128, Batch size: 32, Warstwy: 8 Użyte funkcje: Bez BatchSize, Bez DropOut
o	Optimizer: RMSprop, Kernel: glorot uniform, Bias: GlorotUniform Activation: selu, Unit: 128, Batch size: 32, Warstwy: 8 Użyte funkcje: Bez DropOut
p	Optimizer: RMSprop, Kernel: normal, Bias: GlorotUniform Activation: selu, Unit: 128, Batch size: 32, Warstwy: 8 Użyte funkcje: Bez DropOut
r	Optimizer: RMSprop, Kernel: normal, Bias: Ones Activation: selu, Unit: 128, Batch size: 32, Warstwy: 8 Użyte funkcje: Bez DropOut
s	Optimizer: RMSprop, Kernel: normal, Bias: GlorotUniform Activation: selu, Unit: 128, Batch size: 32, Warstwy: 4 Użyte funkcje: BatchSize, DropOut
t	Optimizer: RMSprop, Kernel: normal, Bias: GlorotUniform Activation: selu, Unit: 128, Batch size: 32, Warstwy: 8 Użyte funkcje: BatchSize, DropOut
u	Optimizer: RMSprop, Kernel: normal, Bias: Ones Activation: selu, Unit: 128, Batch size: 32, Warstwy: 8 Użyte funkcje: BatchSize, DropOut

Po analizie obliczonych błędów generowanych przez sieć neuronową, wybrano parametry modelu do predykcji, który charakteryzował się najmniejszą wartością błędu średniokwadratowego  $MSE$  oraz błędu bezwzględnego. Spośród testowanych modeli, najdokładniejsze wyniki temperatury na ruszcie analizowanego kotła fluidalnego zostały obliczone przy wykorzystaniu jednego z najnowszych dostępnych estymatorów „Adam” [52, 51, 53]. Wybrany estymator, oprócz wysokiej dokładności charakteryzuje się takimi zaletami jak:

- stosunkowo proste wdrożenie przy użyciu małej ilości kodu,
- wysoka wydajność obliczeniowa,
- niskie wymagania pamięci sprzętowej,
- możliwość rozwiązywania problemów z dużą ilością danych
- łatwa zmiana i interpretacja hyperparametrów [64].

Finalna konfiguracja sieci neuronowej ma następujące parametry:

- cztery ukryte warstwy,
- 128 neuronów w ukrytych warstwach,
- jedna warstwa znormalizowana (ang. batch normalization),
- *kernel regularizer*: l2 class (0.001),
- *batch size*: 32,
- *learning rate*: 0.001,
- funkcja aktywacji: *tanh*,
- bias initializer: *zeros*,
- weight initializer: *glorot\_uniform*.

Naukę wybranej sieci neuronowej do obliczenia temperatury na ruszcie analizowanego kotła przeprowadzono wykorzystując wszystkie uprzednio przygotowane dane w ilości 100 000 zestawów danych. Tak jak poprzednio, podczas nauki sieci neuronowej monitorowano błąd średniokwadratowy, który pozwala na bieżącą ocenę postępu nauki sieci neuronowej określa moment zakończenia procesu treningu modelu w przypadku braku poprawy otrzymywanego wyniku.

Proces nauki sieci neuronowej dla temperatur  $T1 \div T12$  zaprezentowano na Rys. 2.12. Niebieskie punkty reprezentuje obliczoną wartość błędu średniokwadratowego dla procesu nauki sieci neuronowej, natomiast czerwona linia obrazuje obliczoną wartość błędu średniokwadratowego dla danych testowych. Wartość błędu  $MSE$  wskazuje, że parametry sieci neuronowej są prawidłowo dobrane - z każdą kolejną iteracją, wagi poszczególnych węzłów zmieniane są prawidłowo a obliczony błąd średniokwadratowy  $MSE$  maleje. Można zauważyć, że proces nauki sieci neuronowych dla każdej temperatury w znaczący sposób różni się ilością powtórzeń, po której osiągnięto maksymalną dokładność modelu.

Rozkład temperatury rzeczywistej do temperatury obliczeniowej dla danych do nauki modelu zaprezentowano na Rys. 2.13. Zielone punkty na wykresach to rozkład temperatur dla danych treningowych, niebieskie punkty to rozkład temperatur dla danych testowych. Dla wszystkich dwunastu temperatur  $T1 \div T12$  występuje liniowa zależność pomiędzy temperaturą rzeczywistą a obliczoną przez sieci neuronowe.

Obliczono również błąd względny dla danych treningowych, wyniki zaprezentowano na Rys. 2.14. Błąd względny dla każdej z obliczanych temperatur jest poniżej 0.5%. Tylko dla kilku wyników obliczeń (z całkowitej ilości 100 000 danych) wartość błędu względnego przekracza 0.5%.

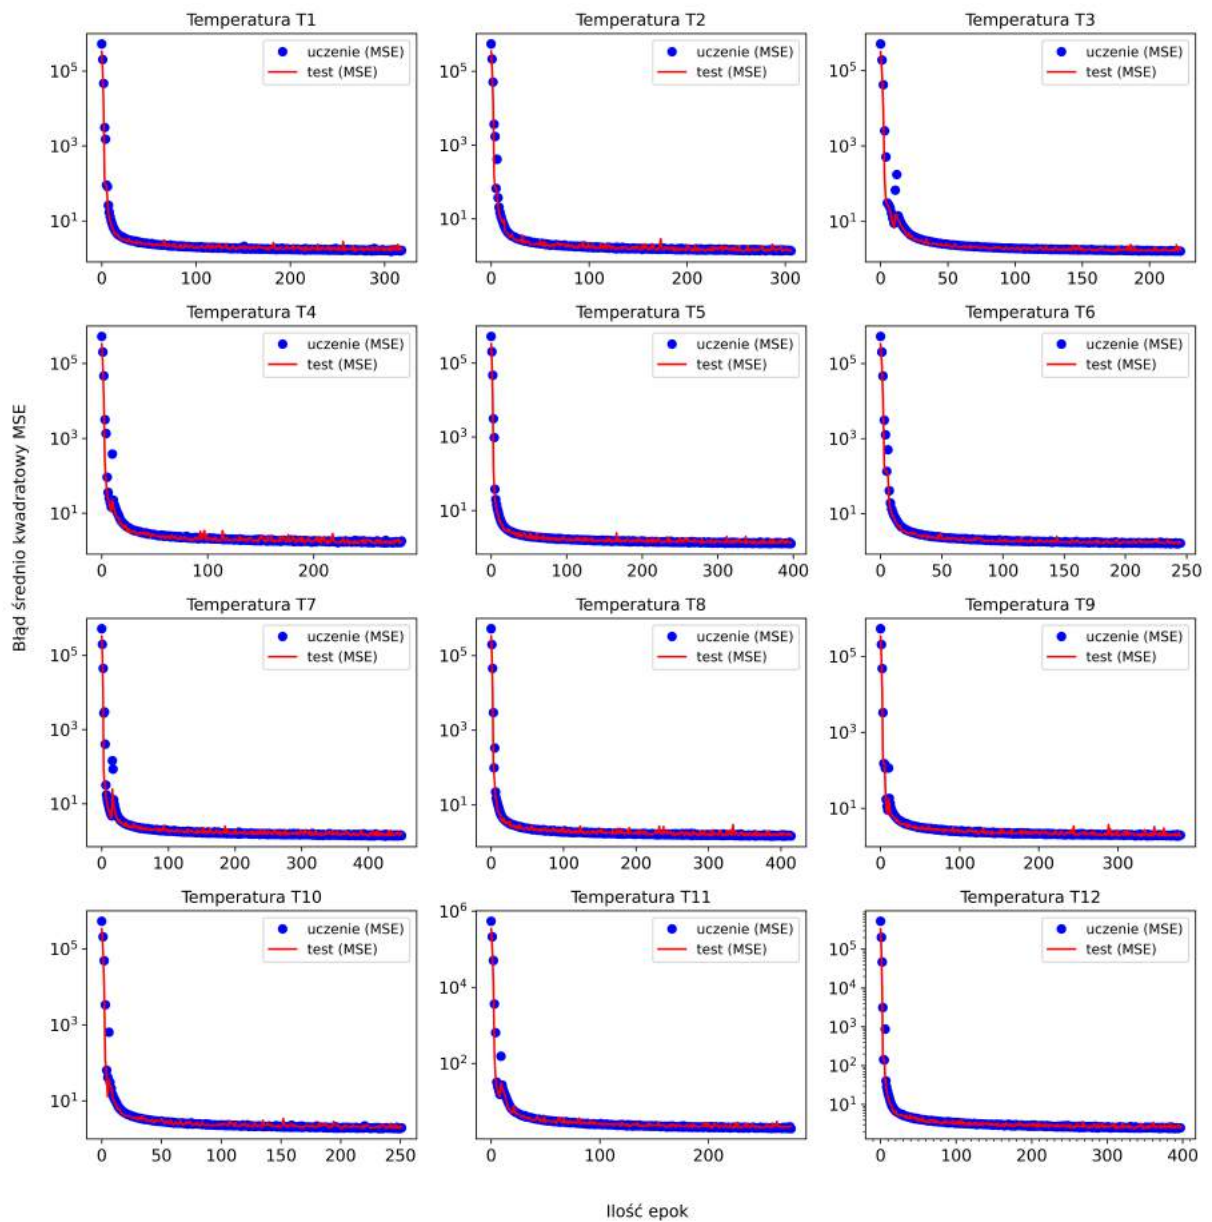
Po zakończonym procesie uczenia sieci neuronowych, kolejnym krokiem było obliczenie błędów generowanych przez sieć neuronową dla nowych danych. Dla przygotowanych wcześniej 3000 danych do walidacji modelu obliczono temperaturę  $T1 \div T12$ , a wyniki predykcji porównano z temperaturą rzeczywistą. Dla obliczonych wartości temperatury obliczono błąd generowany przez sieci neuronowe.

Wartość obliczonego odchylenia standardowego  $\sigma$  zaprezentowano na Rys. 2.15 jako funkcję gęstości rozkładu prawdopodobieństwa błędu bezwzględnego. Obliczona wartość odchylenia standardowego  $\sigma$ , wskazuje, że prawdopodobieństwo obliczenia prawidłowej temperatury jest bardzo duże - odchylenie standardowe dla temperatur  $T1 \div T12$  wynosi około  $1^\circ\text{C}$ .

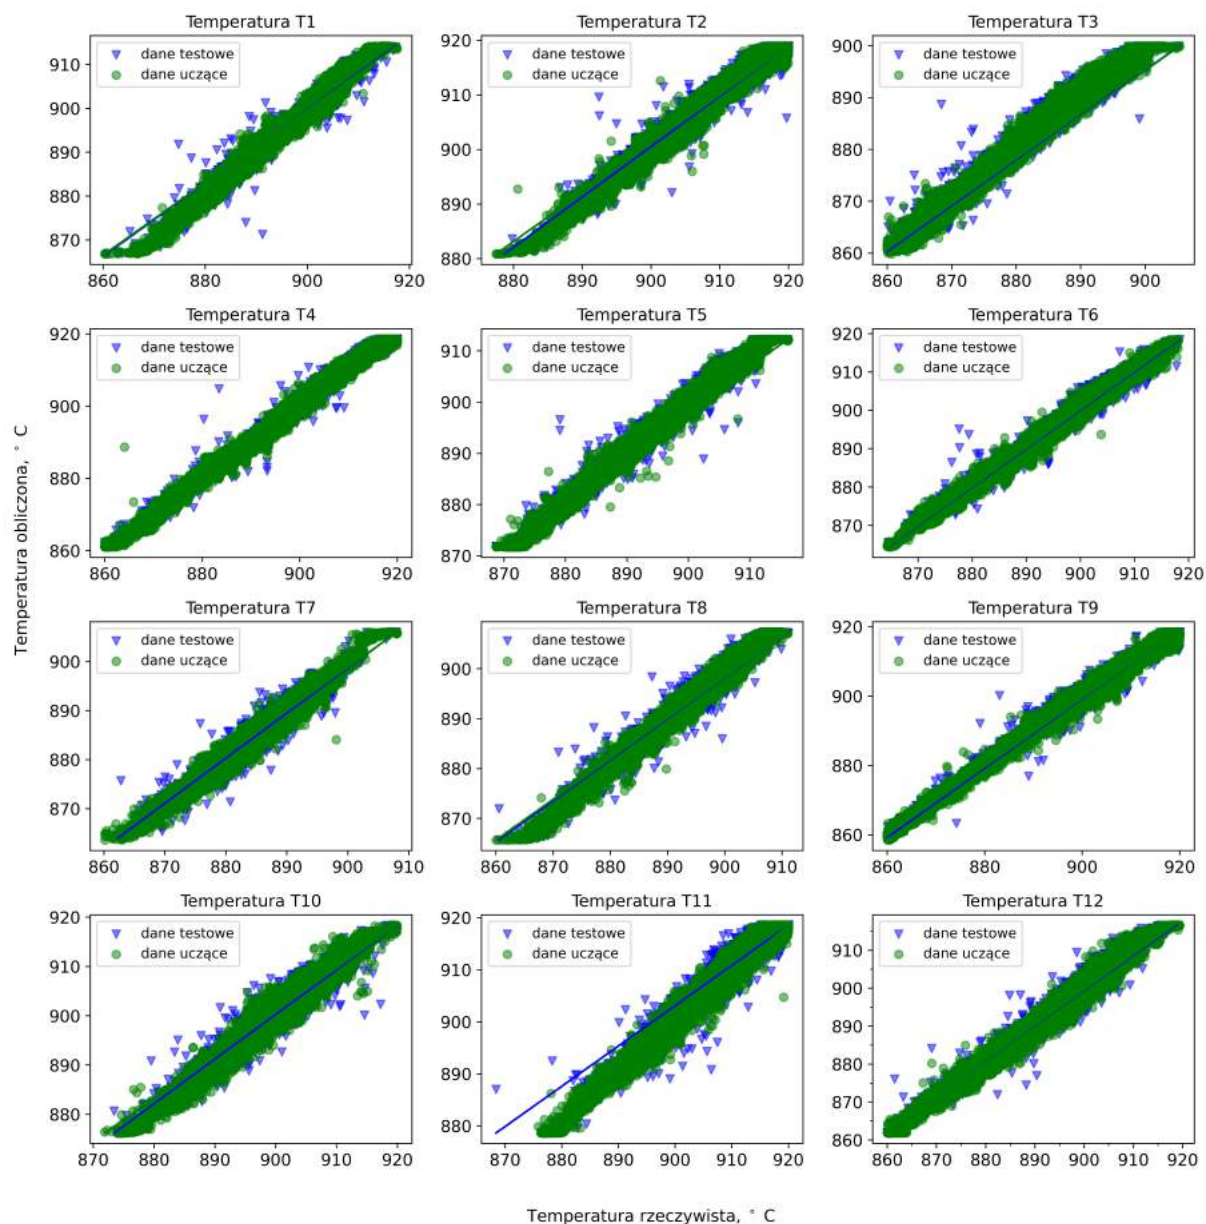
Wartości liczbowe obliczonych błędów zestawiono w Tab. 2.7,2.8.

Znalezienie właściwej konfiguracji sieci neuronowej do obliczenia poprawnego wyniku jest procesem czasochłonnym. Przedstawiony w tym rozdziale sposób, pokazuje, jak poprzez kolejne testy i zawężanie konfiguracji sieci neuronowej znaleziono model, który cechuje się dużą dokładności predykcji szukanej wartości. Wartość obliczonych błędów końcowego modelu potwierdza, że wybrana końcowa konfiguracja sieci neuronowych była właściwa.

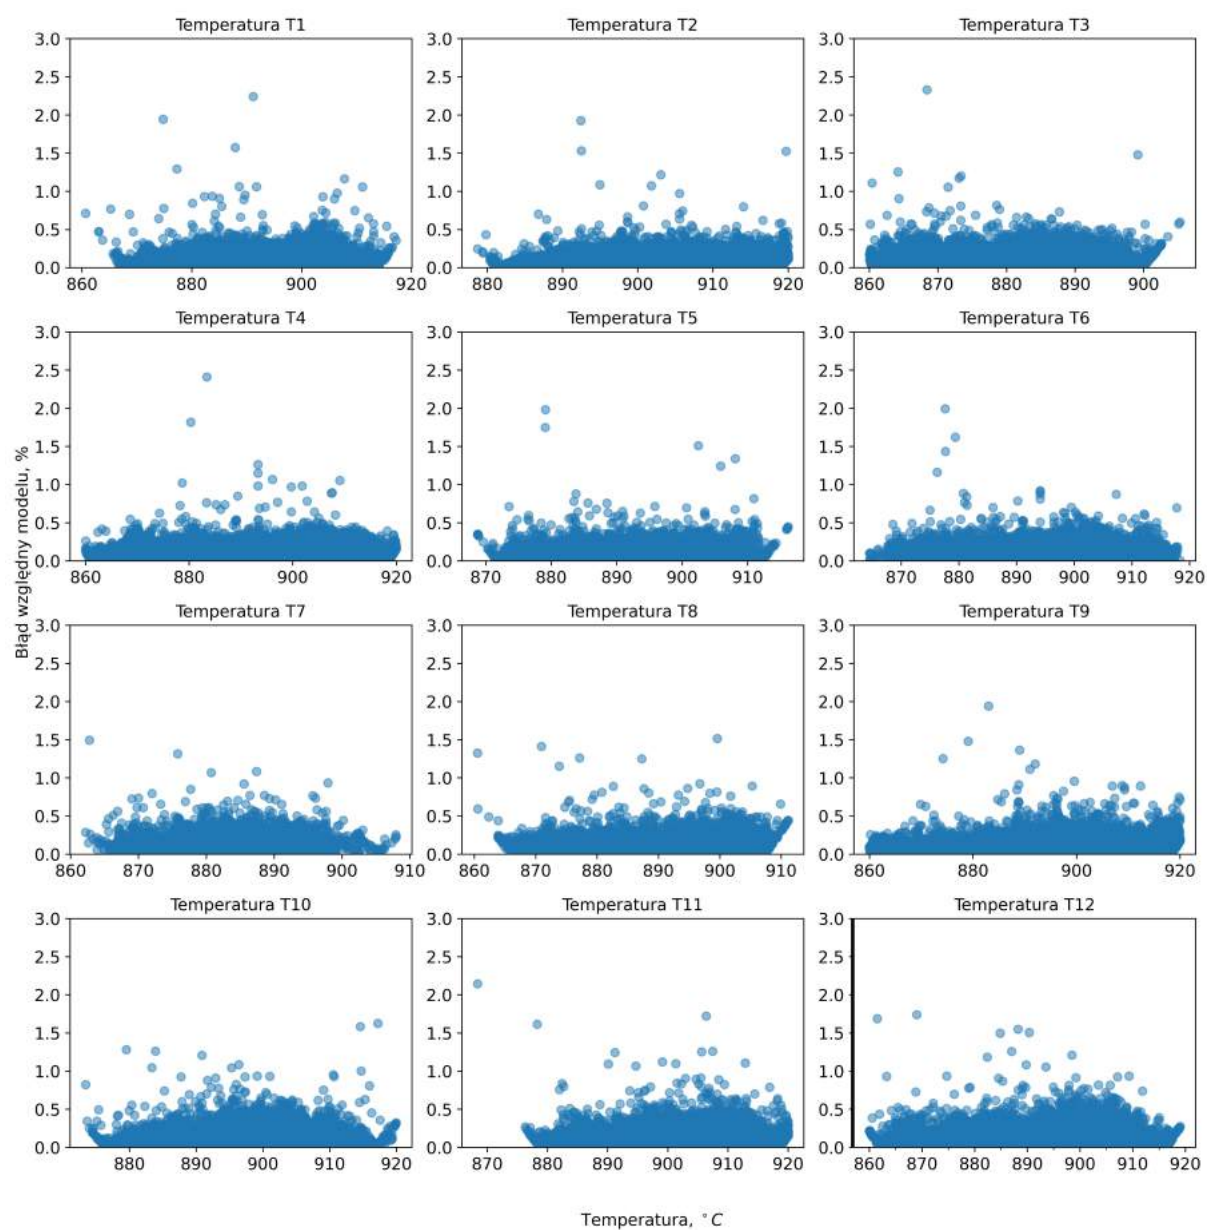
Obliczoną wartość temperatury wykorzystano do obliczenia niepewności pomiarowej otrzymanych wyników. Zgodnie z danymi katalogowymi zabudowanych w analizowanym kotle termopar mierzących temperaturę  $T1 \div T12$ , ich błąd pomiarowy wynosi  $\pm 2.5 \text{ K}$ ,




Rys. 2.12. Obliczony błąd średnio kwadratowy MSE dla temperatur T1÷T12 na etapie nauki sieci neuronowej



Rys. 2.13. Rozkład temperatury rzeczywistej do temperatur obliczonej dla temperatury T1÷T12



Rys. 2.14. Obliczony błąd względny dla temperatury T1÷T12



Rys. 2.15. Funkcja gęstości rozkładu prawdopodobieństwa błędu bezwzględnego dla temperatur T1÷T12

wartość tą przyjęto jako niepewność pomiaru temperatury. Jako niepewność pomiarową modelu do predykcji temperatury przyjęto wartość obliczonego błędu średniokwadratowego  $MSE$ . Niepewność pomiarową sieci neuronowej zobrazowano na Rys. 2.16,2.17. Aby zachować czytelność, niepewność pomiarową zaprezentowano dla 100 losowych danych. Zielony kolor reprezentuje niepewność pomiarową dla rzeczywistych pomiarów, natomiast kolor czerwony to niepewność pomiarowa dla wartości obliczonych przez model.

Kod źródłowy w języku *Python* który został użyty do wytrenowania sieci neuronowych zaprezentowany jest w Załączniku A.

Tabela 2.7

Obliczony błąd modelu do predykcji temperatury T1÷T6

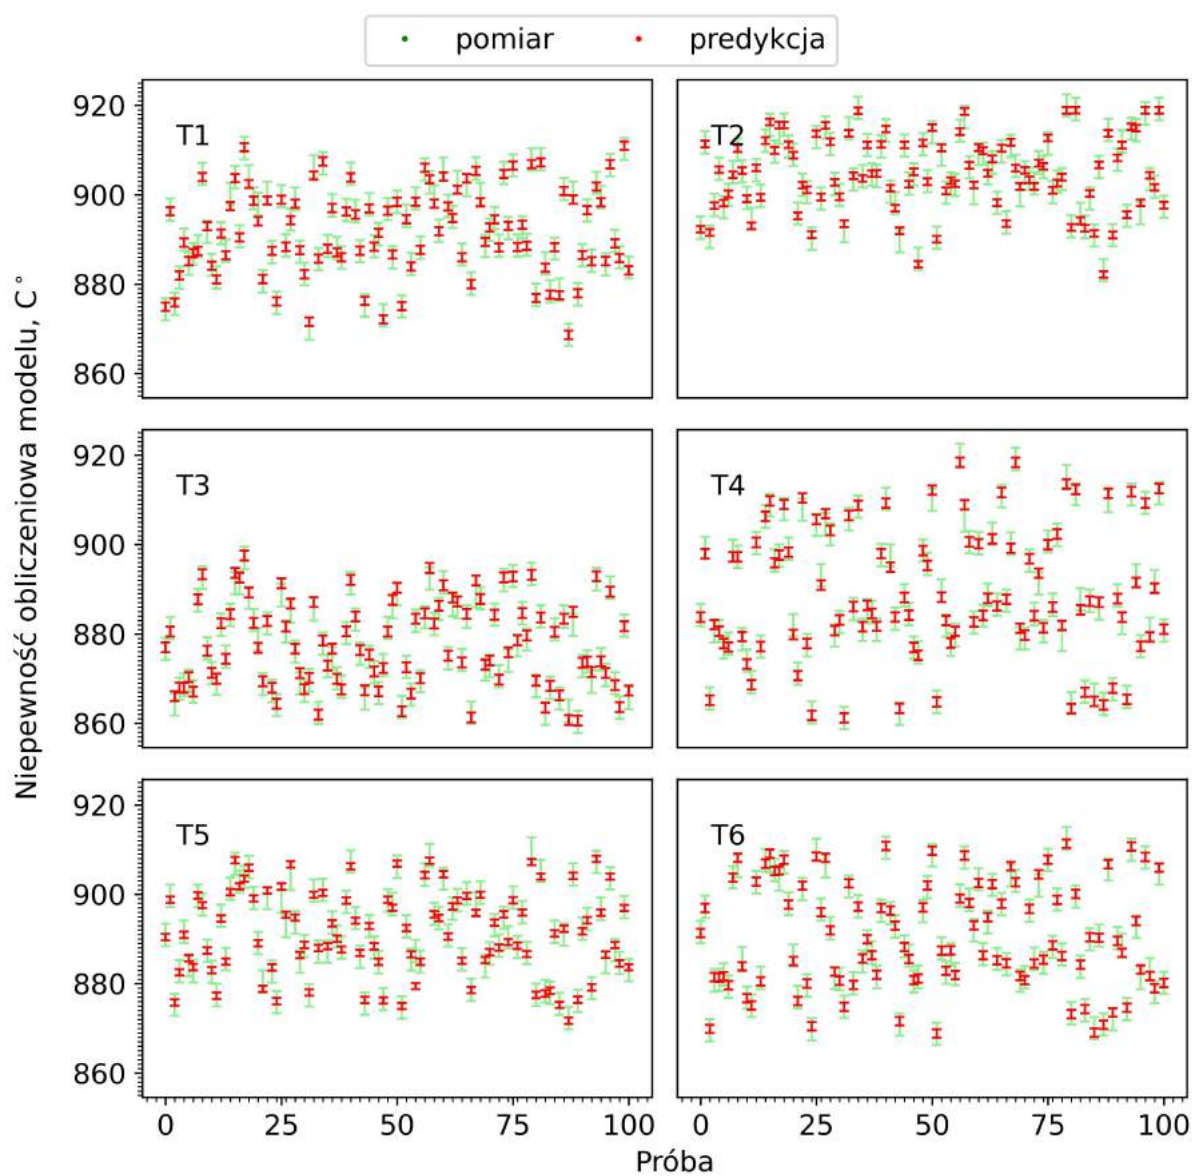
	T1	T2	T3	T4	T5	T6
Błąd średniokwadratowy MSE, Rów. (2.1)	0.92	0.74	1.1	1.06	0.71	0.94
współczynnik determinacji $R^2$ , Rów. (2.2)	0.99	0.99	0.99	0.99	0.99	0.99
Średni błąd względny, %, Rów. (2.4)	0.08	0.07	0.09	0.09	0.07	0.08
Odchylenie standardowe $\sigma$ , K, Rów. (2.5)	0.92	0.83	1	1.03	0.84	0.96



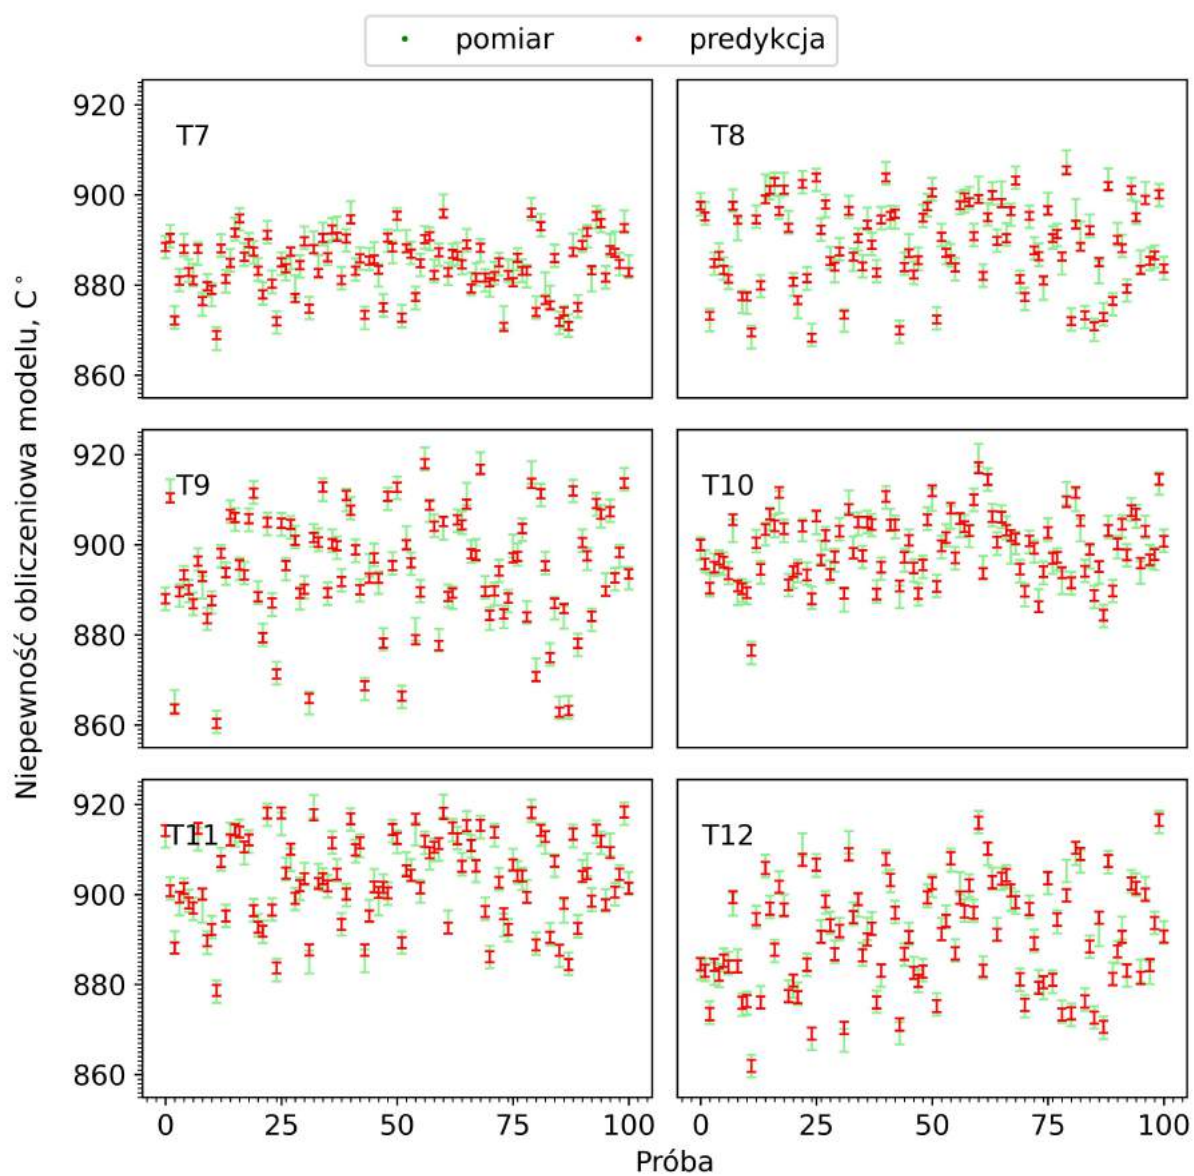
Tabela 2.8

Obliczony błąd modelu do predykcji temperatury T7÷T12

	T7	T8	T9	T10	T11	T12
Błąd średnio- kwadratowy MSE, Rów. (2.1)	0.9	0.88	1.03	1.18	1.22	1.35
współczynnik determinacji $R^2$ , Rów. (2.2)	0.98	0.99	0.99	0.98	0.99	0.99
Średni błąd względny, %, Rów. (2.4)	0.08	0.08	0.08	0.09	0.09	0.1
Odchylenie standardowe $\sigma$ , K, Rów. (2.5)	0.93	0.91	1.01	1.06	1.08	1.16



Rys. 2.16. Niepewność pomiarowa graniczna dla temperatur T1÷T6. Pomiary rzeczywiste temperatur kolor zielony, pomiary obliczone kolor czerwony



Rys. 2.17. Niepewność pomiarowa graniczna dla temperatur T7÷T12. Pomiary rzeczywiste temperatur kolor zielony, pomiary obliczone kolor czerwony

## 2.4. Testy obiektowe

Gotowy model do predykcji temperatury bardzo dobrze sprawdzał się w teorii. Uśrednione wyniki obliczonej przez model temperatury wskazywały na bardzo mały błąd obliczeń. Kolejnym etapem była weryfikacja, czy istnieje rzeczywista możliwość kontrolowanej zmiany temperatury na ruszcie analizowanego kotła fluidalnego, poprzez kontrolowaną zmianę parametrów eksploatacyjnych kotła. Podczas normalnej pracy bloku energetycznego przeprowadzono testy ruchowe, które polegały na zmianie parametrów eksploatacyjnych kotła. W wyniku zmiany parametrów, zmianie ulegała również temperatura na ruszcie kotła. Celem tych testów, była obserwacja, temperatura obliczona przez model dla nowych parametrów kotła będzie zgodna z rzeczywistą temperaturą.

Aby przeprowadzić test, należało spełnić dwa warunki: po pierwsze zmiany parametrów nie mogą doprowadzić do awarii kotła, po drugie testy nie mogą zakłócać bieżącej wydajności kotła, czyli nie mogą wpłynąć na produkcję energii elektrycznej i ciepłej bloku energetycznego, zgodnej z aktualnym zapotrzebowaniem Krajowego Systemu Energetycznego (KSE). Nie jest to proste zadanie, ponieważ praktycznie każda zmiana parametrów kotła wpływa na jego wydajność, co w efekcie zmienia produkcję energii elektrycznej i ciepłej. Dodatkowym utrudnieniem był fakt, że zmiany parametrów kotła mogły być wykonane tylko i wyłącznie w trybie ręcznym przez operatora kotła, co powodowało, że proces zmiany był czasochłonny i wymagał dużej kontroli wszystkich parametrów ruchowych bloku energetycznego.

Pierwsze testy na obiekcie rozpoczęto w listopadzie 2020 roku. Przebieg testów był następujący: z systemu *DCS* pobrano parametry kotła (48 danych wejściowych do sieci neuronowych + 12 temperatur na ruszcie kotła). Przygotowany wcześniej algorytm w oprogramowaniu *Python* sumował dostarczaną ilość paliwa do kotła, a następnie zmieniał dostarczaną ilość paliwa do poszczególnych podajników, tak aby zachować całkowitą ilość węgla. Nowe wydajności podajników paliwa (CF) zastąpiły wartości pobrane z systemu *DCS*. Tak przygotowane zestawy danych zostały wprowadzone do modeli do predykcji temperatury. Na podstawie częściowo zmienionych danych modele predykcyjne obliczyły teoretyczną temperaturę  $T1 \div T12$  na ruszcie kotła fluidalnego.

Na początku testów, próby zmiany parametrów dotyczyły zmiany ilości dostarczanego węgla przez poszczególne podajniki węgla (czyli zmiany rozkładu dostarczanego węgla). Nowy rozkład paliwa do poszczególnych podajników został przekazany do operatora kotła fluidalnego, który w trybie ręcznym miał ustawić wydajność poszczególnych podajników na ustalonym poziomie. Aby utrzymać produkcję pary z kotła na niezmienionym poziomie, automatyka regulacji paliwa wyłączana była stopniowo, w miarę doregulowania przez operatora ręcznie ilości węgla do poszczególnych podajników (CF).

W trakcie testów okazało się, że ręczna zmiana rozkładu paliwa na poszczególne podajniki węgla trwa za długo, poza tym zmiana ilości paliwa na którymkolwiek z podajników węgla natychmiast powoduje korektę paliwa na pozostałych podajnikach - regulator kotła monitoruje sumaryczną ilość dostarczanego węgla i dodaje/zdejmuje niedostatek/nadmiar paliwa na pozostałe podajniki pracujące jeszcze w automatyce.

Po kilku nieudanych próbach przeprowadzenia testów, zmieniono podejście. Z uwagi na brak możliwości automatycznej zmiany ilości paliwa do podajników, testy obiektowe ograniczono do zmiany ilości powietrza wtórnego dostarczanego przez palniki rozpałkowe (OB). Zmiana ta jest dużo prostsza do realizacji w trybie ręcznym, jednak spodziewano się, że przyniesie dużo mniejszy efekt w postaci zmiany temperatury na ruszcie kotła. Zmodyfikowano przygotowany wcześniej algorytm w *Python*: z systemu *DCS* pobrano parametry kotła (48 danych wejściowych do sieci neuronowych oraz 12 temperatur na ruszcie kotła). Algorytm zmienił rozkład powietrza wtórnego dostarczanego do palników rozpałkowych, przy zachowaniu całkowitej ilości powietrza wtórnego dostarczanego do kotła. Nowe wartości ilości powietrza (OB) zastąpiły wartości pobrane z systemu *DCS*. Za pomocą tak przygotowanych nowych zestawów danych wejściowych, modele predycyjne obliczyły teoretyczne temperatury T1÷T12 na ruszcie kotła fluidalnego. Nowe dane zostały przekazane do operatora, który w trybie ręcznym zmienił ilość powietrza wtórnego do każdego z palników zgodnie z dostarczonym zestawem danych. Dzięki takiej zmianie podejścia, udało się zrealizować testy.

Testy obiektowe wykonano dwukrotnie w trakcie ustabilizowanej pracy analizowanego kotła fluidalnego. Bieżąca eksploatacja różni się od danych testowych - analizowany kocioł fluidalny nie posiada systemu monitorującego w sposób ciągły jakości dostarczanego węgla do komory paleniskowej. Ponieważ model do predykcji temperatury nie jest wprost powiązany z jakością paliwa, duża zmienność dostarczanego paliwa mocno wpływa na dokładność obliczeń sieci neuronowych. Jednorazowe wyniki predykcji temperatury mogą się różnić od wartości rzeczywistych.

Problemem zmienności paliwa rozwiązano w następujący sposób: bezpośrednio przed rozpoczęciem testów pobrano dane wejściowe do modelu do predykcji za okres 30 min pracy bloku. Da tych danych obliczono wartość temperatury, a następnie porównano z pomiarami rzeczywistymi temperatury. Następnie dla każdej temperatury obliczono wartość średnią błędu bezwzględnego (zgodnie z Rów. (2.6)). Wyniki w postaci funkcji gęstości rozkładu prawdopodobieństwa błędu bezwzględnego obliczonej temperatury zaprezentowano na Rys. 2.18,2.20. Wartość średnia błędu  $\overline{\Delta T}$  różnicy dla każdej temperatury T1÷T12 posłużyła do skorygowania wartości temperatury obliczonej przez model (Tab. 2.10,2.13).

Obliczenia temperatury przez model predykcijny dla zmienionej wartości rozkładu powietrza wtórnego powtórzono dla kilku różnych rozkładów. Z otrzymanych wyników

wybrano jeden z wariantów nowego rozkładu powietrza, dla którego obliczone temperatury przez sieć neuronową różniły się od temperatur rzeczywistych. Nowy rozkład powietrza wtórnego został przekazany do operatora kotła.

Operator kotła w trybie ręcznym wykonał zmiany ilości powietrza (Tab. 2.11,2.14) dostarczanego przez poszczególne palniki rozpałkowe do komory paleniskowej. Ponieważ zmiany wykonywane były ręcznie, zmiana parametrów była czasochłonna i trwała około 15 min. Zmiany wykonywane były ostrożnie, tak aby nie zakłócić pracy analizowanego kotła. Po 5 min od zakończenia ręcznej zmiany ilość powietrza do palników i ustabilizowaniu się parametrów w kotle, odczytano wartość temperatury T1÷T12 na ruszcie kotła. Temperatury rzeczywiste T1÷T12 porównano z wartościami obliczonymi przez sieci neuronowe. Po zakończeniu testu, operator przywrócił automatyczną pracę regulatora odpowiadającego za sterowanie ilością powietrza wtórnego. Wyniki testów zestawiono w Tab. 2.12,2.15.

Tabela 2.9

Parametry wejściowe do sieci neuronowej podczas testów obiektowych

Parametry kotła	Test 1	Test 2
ilość powietrza pierwotnego, kg/s	228.9	254.8
ilość powietrza wtórnego, kg/s	133.0	129.0
przepływ pary z kotła, kg/s	346.5	355.7
temperatura powietrza pierwotnego, °C	290	290
temperatura powietrza wtórnego °C	298	298
sumaryczna ilość paliwa, kg/s	53.8	55.2

### 2.4.1. Pierwszy test na obiekcie

Pierwszy test na obiekcie zmiany ilość powietrza wtórnego dostarczanego do komory paleniskowej przez palniki olejowe i monitorowania zmiany temperatury na ruszcie kotła przeprowadzono 2 grudnia 2020r. Zgodnie opisaną wcześniej procedurą, w trakcie ustabilizowanej pracy bloku energetycznego z systemu pobrano 48 parametrów wejściowych służących do obliczenia przez model temperatury na ruszcie analizowanego kotła. Pobrano dane z okresu 30 minut poprzedzających rozpoczęcie testów. Dane wprowadzono do modeli predykcyjnych i obliczono teoretyczną temperaturę  $T1 \div T12$ . Dla otrzymanych wartości obliczono średnią wartość błędu bezwzględnego  $\overline{\Delta T}$  (Rów. (2.6)).


Obliczoną wartość błędu dla temperatur  $T1 \div T12$  zestawiono w Tab. 2.10. Otrzymane wyniki błędu dla pomiarów temperatury zlokalizowanych w przedniej części kotła ( $T1 \div T6$ ) są na znacznie niższym poziomie niż dla tylnej części kotła ( $T7 \div T12$ ). Wytlumaczeniem tego zjawiska może być fakt, tuż przed rozpoczęciem testów obiektowych, jeden z podajników paliwa zabudowany w tylnej części komory paleniskowej uległ uszkodzeniu, co niewątpliwie wpłynęło na końcowy wynik obliczeń temperatury na ruszcie analizowanego kotła.

Tabela 2.10

Średni błąd bezwzględny  $\overline{\Delta T}$  (Rów. (2.6)) dla temperatury  $T1 \div T12$

	Wartość średnia błędu bezwzględnego $\overline{\Delta T}$ , K
T1	-1.87
T2	-1.30
T3	-0.32
T4	2.63
T5	-5.35
T6	-3.97
T7	-4.35
T8	-11.31
T9	-1.33
T10	-7.58
T11	-4.59
T12	-4.06

W kolejnym etapie obliczono nowy rozkład powietrza wtórnego dostarczanego przez palniki rozpałkowe przez przygotowany algorytm. Na podstawie nowego rozkładu powietrza, modele do predykcji obliczyły teoretyczne temperatury  $T1 \div T12$  dla nowych,



Rys. 2.18. Funkcja gęstości rozkładu prawdopodobieństwa błęd bezwzględnych dla temperatur T1÷T12

zmienionych parametrów kotła fluidalnego. Wybrano jeden z kilku wariantów nowego rozkładu powietrza wtórnego, dla którego temperatury znacząco różniły się od aktualnie panujących w komorze paleniskowej. Wartości przepływu powietrza do poszczególnych palników zostały przekazane do Operatora kotła, który rozpoczął ręczną zmianę ilość powietrza. Obliczona wartość powietrza dla poszczególnych palników zestawiono w Tab. 2.11.


Tabela 2.11

Ilość powietrza wtórnego do palników rozpałkowych OB1÷OB10

	Wartość początkowa m <sup>3</sup> /s	Wartość końcowa m <sup>3</sup> /s
OB1	2.01	1.31
OB2	1.98	1.22
OB3	3.02	3.60
OB4	3.12	3.03
OB5	3.03	3.90
OB6	2.01	2.82
OB7	1.97	2.06
OB8	3.03	2.94
OB9	3.06	3.52
OB10	3.09	2.49



Przez cały czas trwania testów monitorowano zmianę wartości temperatury T1÷T12. Zmiany ilości powietrza wtórnego wprowadzone przez operatora kotła zaprezentowano na Rys. 2.19 (po lewej). Przerywaną pionową linią zaznaczono moment rozpoczęcia zmiany ilości powietrza wtórnego (zielona linia) oraz zakończenia zmiany ilości powietrza wtórnego (czerwona linia) wprowadzanych do komory paleniskowej przez poszczególne palniki olejowe. Zmiany temperatury w trakcie zmiany rozkładu powietrza wtórnego zaprezentowano na Rys. 2.19 (po prawej).



Rys. 2.19. Zmiana ilość powietrza wtórnego dostarczanego do kotła przez palniki OB1÷OB10 (po lewej), oraz temperatury T1÷T12 (po prawej) w trakcie testu

Po zakończeniu ręcznej zmiany ilości powietrza wtórnego dla każdego z palników rozpałkowych i ustabilizowaniu się parametrów, z systemu *DCS* odczytano wartość mierzonej temperatury T1÷T12 na ruszcie kotła. Otrzymane wartości porównano z wartościami temperatury obliczonej przez model do predykcji. Wyniki zaprezentowano w Tab. 2.12.

Otrzymane wartości temperatury po zmianie rozkładu powietrza wtórnego wskazują na dużą zgodność z zmierzoną wartością temperatury. Duże różnice pomiędzy wartością zmierzoną temperatury a wartością obliczoną występują dla temperatur mierzonych w tylnej części kotła T10÷T12. Różnice wystąpiły z dwóch powodów. Po pierwsze z uwagi na zbyt długi czas trwania testów - od momentu odczytania parametrów kotła z *DCS*

do ręcznej zmiany ilość powietrza minęło prawie 30 minut. W tym czasie, mimo prawie stałej wydajności kotła występują ciągle fluktuacje zmiany pozostałych parametrów (np. ilość węgla). Po drugie z uszkodzenia jednego z podajników węgla (CF33) który uległ uszkodzeniu w dniu testu i nie był eksploatowany.

Tabela 2.12

Temperatury T1÷T12 w trakcie testu

	Rzeczywista temperatura początkowa $t_{\text{pocztkowa,DCS}}, ^\circ\text{C}$	Obliczona temperatura przed model $t_{\text{pred}}, ^\circ\text{C}$	Rzeczywista temperatura końcowa $t_{\text{kocowa,DCS}}, ^\circ\text{C}$	Obliczona różnica temperatury $ t_{\text{pred}} - t_{\text{kocowa,DCS}} , \text{K}$
T1	900.1	897.0	897.6	0.6
T2	909.6	904.1	910.7	6.6
T3	881.0	878.1	879.2	1.1
T4	884.4	880.6	888.3	7.7
T5	892.6	891.9	892.9	1.0
T6	890.7	887.7	889.8	2.1
T7	892.6	891.1	887.8	3.3
T8	899.2	904.1	895.2	8.9
T9	898.8	896.2	894.8	1.4
T10	911.3	914.5	906.5	8.0
T11	914.2	919.3	911.1	8.2
T12	902.2	907.0	900.8	6.2

Szacuje się, że brak jednego z podajników węgla miał duży wpływ na dokładność otrzymanych wyników. Na etapie przygotowywania danych do nauki sieci neuronowych, dane były starannie filtrowane pod kątem minimalnej ilość paliwa dostarczanego przez podajniki (ustawiona minimalna wartość paliwa 1 kg/s). Rzeczywista wartość 0 kg/s w dniu testów dla jednego z podajników węgla wpłynęła na dokładność obliczeń temperatury przez sieć neuronową.

Pomimo problemów eksploatacyjnych z jednym z podajników węgla, zmiana temperatury na ruszcie zgodnie z wartościami obliczonymi przez model na skutek zmiany rozkładu powietrza wtórnego, potwierdza, że istnieje rzeczywista możliwość wpływu na temperaturę poprzez kontrolowaną zmianę parametrów kotła.

## 2.4.2. Drugi test na obiekcie

Wyłączenie z eksploatacji jednego z podajników węgla wymusiło konieczność powtórzenia procesu uczenia sieci neuronowych. Przygotowano nowe dane ruchowe, które uwzględniały możliwość postoju poszczególnych podajników węgla. Dla nowych danych powtórzono proces nauki modeli do predykcji temperatury. Po przygotowaniu nowego zestawu modeli do predykcji rozpoczęto drugi test kontrolowanej zmiany temperatury w kotle, poprzez zmianę parametrów ruchowych kotła fluidalnego, który przeprowadzono w dniu 5 grudnia 2020r.

Analogicznie jak w trakcie pierwszego testu, w trakcie ustabilizowanej pracy analizowanego kotła fluidalnego z systemu pobrano 48 parametrów wejściowych wykorzystywanych do predykcji temperatury. Dane pobrano za okres 30 minut poprzedzający rozpoczęcie testów. Dla tych danych obliczono teoretyczną temperaturę na ruszcie kotła T1÷T12 oraz średnią wartość błędu bezwzględnego  $\overline{\Delta T}$  (Rów. (2.6)) dla aktualnych warunków pracy kotła.

Obliczoną wartość błędu dla temperatur T1÷T12 zestawiono w Tab. 2.13.


Tabela 2.13

Średni błąd bezwzględny  $\overline{\Delta T}$  (Rów. (2.6)) dla temperatury T1÷T12

	Wartość średnia błędu bezwzględnego $\overline{\Delta T}$ , K
T1	2.10
T2	2.26
T3	-0.27
T4	5.73
T5	-2.93
T6	-3.89
T7	-5.52
T8	-1.01
T9	10.47
T10	-2.84
T11	0.97
T12	1.20

Tak jak podczas pierwszego testu, kolejnym krokiem było obliczenie nowego rozkładu powietrza wtórnego dostarczanego przez palniki rozpałkowe przez przygotowany algorytm, oraz obliczenie teoretycznych temperatur T1÷T12 dla nowych parametrów kotła fluidalnego. Tym razem również z wariantów obliczonych przez sieć neuronową

wybrano jeden z wariantów, dla którego temperatury znacząco różniły się od aktualnie panujących w komorze paleniskowej. Wartości przepływu powietrza do poszczególnych palników zostały przekazane do Operatora kotła, który rozpoczął ręczną zmianę ilość powietrza. Obliczona wartość powietrza dla poszczególnych palników zaprezentowano w Tab. 2.14.



Rys. 2.20. Funkcja gęstości rozkładu prawdopodobieństwa błęd bezwzględnych dla temperatur T1÷T12


Tabela 2.14

Ilość powietrza wtórnego do palników rozpałkowych OB1÷OB10

	Wartość początkowa m <sup>3</sup> /s	Wartość końcowa m <sup>3</sup> /s
OB1	1.98	1.42
OB2	2.04	2.88
OB3	2.59	2.74
OB4	2.78	2.01
OB5	2.61	1.98
OB6	2.00	1.87
OB7	2.00	2.75
OB8	2.62	1.37
OB9	2.67	1.76
OB10	2.62	3.16

Przez cały czas trwania testów monitorowano zmianę temperatury T1÷T12. Zmiany ilości powietrza wtórnego wprowadzone przez operatora kotła zaprezen-

wano na Rys. 2.21 (po lewej). Przerwaną pionową linią zaznaczono moment rozpoczęcia ręcznej zmiany ilości powietrza wtórnego (zielona linia) oraz zakończenia zmiany ilości powietrza wtórnego (czerwona linia) wprowadzanych do komory paleniskowej przez poszczególne palniki olejowe. Zmiany temperatury w trakcie zmiany rozkładu powietrza wtórnego zaprezentowano na Rys. 2.19 (po prawej).



Rys. 2.21. Zmiana ilość powietrza wtórnego dostarczanego do kotła przez palniki OB1÷OB10 (po lewej), oraz temperatury T1÷T12 (po prawej) w trakcie testu

Po wprowadzeniu nowych wartości powietrza dla każdego z palników rozpałkowych i ustabilizowaniu się parametrów, z systemu *DCS* odczytano wartość zmierzonej temperatury T1÷T12. Wartości rzeczywiste porównano z wartościami temperatury obliczonymi przez model do predykcji, a wyniki zestawiono w Tab. 2.15.

Porównanie wartości zmierzonej temperatury na ruszcie kotła z wartością obliczoną przez model predykcynny, widać bardzo dużą zgodność wyników. Po douczeniu sieci neuronowych o nowe dane, uwzględniające możliwość postoju podajników węgla nastąpiła znaczna poprawa otrzymanych wyników.

Podobnie jak w trakcie pierwszego dnia testów występujące różnice pomiędzy temperaturą rzeczywistą a obliczoną przez model predykcynny wystąpiły z uwagi na długi czas od chwili odczytania parametrów z *DCS* do przekazanie ich do Operatora w celu ręcznej zmiany (około 25 minut). Pomimo tak długiego czasu, występuje duża zgodność

otrzymanych wyników temperatury, potwierdza możliwości kontroli rozkładu temperatury na ruszcie analizowanego kotła fluidalnego poprzez zmianę parametrów ruchowych kotła.

Porównując wynik błędu bezwzględnego dla danych z pierwszego dnia testów (Tab. 2.10) a drugiego (Tab. 2.13) , widać, że uwzględnienie w danych do nauki modelu możliwości postoju podajników znacznie poprawiły dokładność obliczeń temperatury przez sieć neuronową.

Tabela 2.15

Temperatury T1÷T12 w trakcie testu

	Rzeczywista temperatura początkowa $t_{pocztkowa,DCS}, ^\circ C$	Obliczona temperatura przed model $t_{pred}, ^\circ C$	Rzeczywista temperatura końcowa $t_{kocowa,DCS}, ^\circ C$	Obliczona różnica temperatury $ t_{pred} - t_{kocowa,DCS} , K$
T1	905.1	906.9	908.7	1.8
T2	915.5	917.0	918.3	1.3
T3	894.0	891.5	894.0	2.5
T4	881.3	884.0	888.6	4.67
T5	896.8	901.1	901.3	0.2
T6	892.5	893.2	895.6	2.4
T7	889.3	890.9	891.7	0.8
T8	888.6	895.1	893.6	1.5
T9	887.7	896.3	894.8	1.5
T10	907.9	913.5	913.6	0.1
T11	911.0	915.6	915.6	0.0
T12	899.1	895.2	906.3	11.1

Przeprowadzone testy obiektowe potwierdziły, że możliwa jest kontrolowana zamiana temperatury na ruszcie analizowanego kotła fluidalnego poprzez zmianę jego parametrów ruchowych. W trakcie testów rozkład powietrza wtórnego zmieniany był pod kątem uzyskanie temperatur na ruszcie innych niż wyjściowe, tak aby możliwe było zaobserwowanie zmian temperatury. Wymuszone zmiany temperatury zrealizowane były tylko poprzez zmianę rozkładu powietrza wtórnego wprowadzanego do palników rozpałkowych. Możliwość zmiany rozkładu węgla dostarczanego do podajników paliwa znacząco zwiększyłaby możliwy zakres zmian temperatury, a tym samym lepszego wyrównania rozkładu temperatury w przekroju poprzecznym komory paleniskowej.

Docelowo, przygotowany algorytm w *Python* na podstawie danych ruchowych szuka nowego rozkładu powietrza wtórnego i węgla, dla którego obliczony rozkład temperatur  $T1 \div T12$  będzie wyrównany. Kod źródłowy w języku *Python* który został użyty do zmiany rozkładu paliwa i powietrza wtórnego zaprezentowany jest w Załączniku B, C.

Jednoczesna zmiana rozkładu powietrza wtórnego i paliwa do kotła zwiększy możliwość wpływu na końcową temperaturę na ruszcie kotła. Co ważne, wszystkie wykonywane zmiany nie zakłócają pracy kotła fluidalnego, a tym samym nie wpływają na bieżącą wydajność kotła fluidalnego.





### 3

## Obliczenia numeryczne

Celem pracy jest stworzenie modelu, umożliwiającego optymalizację pracy analizowanego kotła fluidalnego pod kątem obniżenia erozji powierzchni ogrzewalnych w strefie przejściowej komory paleniskowej analizowanego kotła, powyżej linii zakończenia obmuza. Parametry ruchowe kotła fluidalnego, takie jak rozkład dostarczanego paliwa czy powietrza do komory, przeliczane są pod kątem otrzymania wyrównanej temperatury w całym przekroju poprzecznym kotła na wysokości 250 mm powyżej rusztu (Rys. 1.1). Efektem tego, będzie ograniczenie występowania dużych wahań erozji rur ekranowych.

Podczas eksploatacji kotła fluidalnego temperatura mierzona na ruszcie kotła fluidalnego zależna jest między innymi od wydajności kotła, jakości i ilości dostarczanego paliwa (składu chemicznego, granulacja paliwa itp.) czy ilości dostarczanego powietrza. System nadzorujący pracę bloku (NSAB) ustala wymaganą ilość dostarczanego paliwa i powietrza na podstawie aktualnego zapotrzebowania na moc cieplną kotła.

Regulator wartości zadanej przepływu węgla jest elementem podrzędnym regulatora bloku (obciążenia kotła) UMC (ang. Unit Master Controller) oraz głównego regulatora ilości paliwa, który stanowi centralny punkt sterowania dla wszystkich podajników. Wymagana ilość węgla zostaje proporcjonalnie rozdzielona do podajników paliwa, zgodnie z nastawą dokonaną przez Operatora kotła lub realizowana automatycznie w zależności od sygnału zapotrzebowania na paliwo. Podczas pracy w warunkach normalnych paliwo rozprowadzane jest równomiernie na prawą i lewą stronę kotła (po 50%), a prawie równomierny przepływ paliwa do każdego z punktów podawania realizowany jest przez 14 dozowników ślimakowych. W przypadku zakłóceń pracy na którejkolwiek z czterech linii podawania paliwa, linia zlokalizowana po tej samej stronie przejmuje 30÷40 obciążenia, a podajniki po stronie przeciwnej wyrównają zapotrzebowanie na węgiel. W przypadku zakłóceń pracy na którymkolwiek z 14 podajników węgla, linia znajdująca się po tej samej stronie wyrówna bilans. Regulator wartości zadanej przepływu węgla jest nadrzędny wobec regulatora wartości zadanej powietrza do spalania i generuje wartość zadaną dla regulatora powietrza do kotła. Główny regulator dopływu powietrza stanowi centralny punkt sterowania przepływem wszystkich rodzajów powietrza i odpowiada za utrzymywanie określonej wartości całkowitej przepływu w zależności od wartości zadanej przez główny regulator kotła. Regulator przepływu powietrza pierwotnego steruje kierownicami wlotowymi wentylatorów powietrza pierwotnego i utrzymuje natężenie przepływu zgodnie z wartością zadaną z głównego regulatora powietrza. Strumień

powietrza wtórnego doprowadzany przez wentylatory powietrza wtórnego jest rozdzielony do dysz powietrza wtórnego oraz do palników rozruchowych. Przepływy do poszczególnych dysz są regulowane indywidualnie za pomocą klap regulacyjnych. System powietrza wtórnego został zaprojektowany tak, dzięki stopniowemu spalaniu spełnić wymagania dotyczące emisji analizowanego kotła.

Wymagany nadmiar powietrza do spalania regulowany zgodnie ze zmierzoną zawartością tlenu w spalinach. Zawartość tlenu w spalinach reguluje się ilością powietrza wtórnego. Prawidłowa ilość powietrza do kotła jest wtedy, gdy wartość nadmiaru  $O_2$  utrzymuje się na poziomie 3.0 %. Regulator powietrza zapewnia odpowiednią ilość powietrza do fluidyzacji złoża w kotle oraz do procesu spalania całkowitego. Regulator przepływu utrzymuje przepływ powietrza wtórnego na poziomie wartości zadanej, korygowanej przez Operatora kotła. W trybie automatycznym regulator przepływu utrzymuje wartość zadaną przez operatora, w trybie kaskadowym regulator przepływu powietrza wtórnego automatycznie ustawia wartość zadaną przez sterownik nadrzędny. Zadaniem regulatora przepływu powietrza wtórnego do palników rozruchowych jest utrzymanie przepływu powietrza wtórnego do każdego palnika rozruchowego na poziomie równym wartości zadanej bez względu na jakiegokolwiek zmiany w przepływie do innych palników i dysz.

System nadzorujący pracę bloku (NSAB) nie ma w swoich logikach optymalizacji rozkładu paliwa na poszczególne podajniki pod kątem rozkładu temperatury na ruszcie kotła. Opracowany w ramach pracy model predykcyjny wykorzystujący uczenie maszynowe pozwala obliczyć, dla jakiego rozkładu węgla i powietrza wtórnego do poszczególnych podajników uzyska się równomierny rozkład temperatury na wysokości 250 mm nad rusztem (Rys. 1.6).


Aby potwierdzić, że równomierny rozkład temperatury na ruszcie komory paleniskowej wpływa na zmniejszenie intensywności erozji rur ekranowych parownika powyżej linii zakończenia obmurza, wykonano obliczenia bazujące na numerycznej mechanice płynów *CFD*. Do obliczeń wykorzystano jedną z dostępnych technik obliczeniowych jaką jest hybrydowy model Euler-Lagrange (HEL) [8]. Obliczenia wykonano wykorzystując komercyjne oprogramowanie Ansys<sup>®</sup>Fluent Code (Release 2020 R2).

### 3.1. Model numeryczny analizowanego kotła fluidalnego

Do obliczeń przepływowych wykorzystano opracowany w ramach projektu POIR.01.01.01-00-1253/19-0 numeryczny model analizowanego kotła fluidalnego. Opracowany model odzwierciedla rzeczywistą geometrię kotła fluidalnego. Gabaryty analizowanego kotła oraz skomplikowany kształt (separatory oktagonalne, kanały powrotne cyrkulowanego materiału, przegrzewacze pary świeżej i wtórnej itp.) wymusiły przyjęcie

pewnych ograniczeń i zawężenie modelu numerycznego do komory paleniskowej. Uprościło to obliczenia, jednocześnie zmniejszając zapotrzebowanie na moc obliczeniową do wykonania obliczeń numerycznych.

Z uwagi na przyjęte ograniczenia, geometria opracowanego modelu numerycznego nie obejmuje ośmiu zabudowanych separatorów oktagonalnych, separujących cząstki stałe ze spalin opuszczających komorę paleniskową (zaznaczone na szaro na Rys. 3.1 (a)) oraz kanałów powrotnych cyrkulowanego materiału wraz z komorami zewnętrznymi przegrzewaczy pary. Funkcja recyrkulacji cząstek poprzez separatory i zewnętrzne przegrzewacze pary do komory paleniskowej realizowana jest poprzez wykorzystanie funkcji zdefiniowanych w kodzie źródłowym użytkownika UDF (ang. User defined function). Ideę recyrkulacji zaprezentowano na Rys. 3.1 (b). Zdefiniowana funkcja zlicza udział fazy stałej opuszczającej domenę obliczeniową przez każde z okien wylotowych spalin (Rys. 3.1 (b), zielony) na koniec każdego kroku obliczeniowego. Obliczona ilość cząstek stałych wprowadzana jest do domeny obliczeniowej przez odpowiednie wloty z komór zewnętrznych przegrzewaczy pary (Rys. 1.3, kolor żółty) w następnym kroku obliczeniowym. Przyjęta procedura recyrkulacji umożliwia zachowanie stałej masy cząstek w modelowanym kotle fluidalnym. Działanie tak zdefiniowanej funkcji szczegółowo opisuje Adamczyk [6].



Rys. 3.1. Geometria analizowanego kotła fluidalnego (a-lewa) oraz geometria modelu numerycznego z wprowadzonymi modyfikacjami (b-prawa)

Geometria dolnej części komory paleniskowej modelu została odwzorowana zgodnie z Rys. 1.3. Wszystkie wloty do komory paleniskowej mają swoje odzwierciedlenie w modelu numerycznym kotła. Przekrój wlotów do komory paleniskowej został uproszczony i przetransponowany z okrągłego na kwadratowy, co umożliwiło wykonanie wysokiej jakości sześciociennej siatki numerycznej komory paleniskowej.

Powietrze pierwotne wprowadzane jest do komory paleniskowej równomiernie przez 7802 dysz powietrza pierwotnego zabudowanych w dnie analizowanego kotła (patrz Rys. 1.2). W przyjętej geometrii modelu numerycznego, ruszt komory paleniskowej reprezentowany jest przez powierzchnie płaską, przez którą wprowadzane jest powietrze pierwotne do komory paleniskowej (warunkiem brzegowym jest prędkość powietrza (Rys. 3.1 (b), niebieskie strzałki). Ponieważ w analizowanym kotle fluidalnym przepływ powietrza pierwotnego jest równomierny w całym przekroju poprzecznym leja komory paleniskowej [31] takie uproszczenie jest akceptowalne.

Kolejnym uproszczeniem modelu numerycznego było zastąpienie powierzchni ogrzewalnych komory paleniskowej przez powierzchnie płaskie. Uproszczenie to nie wpływa na jakość wykonanych obliczeń numerycznych - średni element siatki modelu numerycznego ma wymiar 0.252 m i jest kilkukrotnie większy od wymiaru rur zabudowanych w komorze paleniskowej (rury ekranowe mają średnicę zewnętrzną  $\phi$  31.8 mm i 38 mm). Geometria modelu numerycznego nie uwzględnia opatentowanego przez producenta kotła rozwiązania jakim jest odgięcie rur ekranowych (Rys. 1.11), które ogranicza erozyjne oddziaływanie materiału złoża na rury parownika w strefie zakończenia obmurza w dolnej części komory paleniskowej. Odzwierciedlenie tego odgięcia rur ekranowych oraz rzeczywistej geometrii rur parownika wiązało by się z znacznym zagęszczeniem siatki numerycznej, co znacznie wydłużyłoby czas obliczeń przepływowych, jednocześnie nie wpływając na jakość wykonanych obliczeń, tym bardziej, że obliczenia dotyczą obliczeń zachodzącego zjawiska erozji powyżej odgięcia rur ekranowych.

Przyjęte uproszczenia geometrii modelu numerycznego analizowanego kotła są akceptowalne, ponieważ obliczenia erozji rur ekranowych nie mają charakteru obliczeń bezwzględnych rzeczywistych wartości ubytku materiału rur, a charakter porównawczy, dla określenia wpływu parametrów eksploatacyjnych analizowanego kotła fluidalnego na intensywność erozji.

### 3.1.1. Siatka numeryczna modelu

Trójwymiarowy numeryczny model kotła fluidalnego ma rzeczywiste wymiary komory paleniskowej analizowanego kotła i odzwierciedla rzeczywistą geometrię komory paleniskowej. Model powstał przy wykorzystaniu oprogramowania Ansys®DesignModeler.

Geometria modelu numerycznego analizowanego kotła, ma następujące wymiary:

- wysokość komory paleniskowej 47.88 m,
- długość komory paleniskowej 27.64 m,
- szerokość dna dyszowego/komory paleniskowej 5.36 m/10.61 m.

Siatka numeryczna modelu została wykonana przy wykorzystaniu środowiska Ansys® Meshing. W trakcie tworzenia siatki numerycznej, model kotła został podzielony na mniejsze bryły, co umożliwiło wykonanie ciągłej i strukturalnej siatki numerycznej. Siatka numeryczna ciągła, czyli konformalna (ang. conformal mesh) oznacza, że miejsce przecięcia któregośkolwiek z dwóch elementów, takich jak powierzchnia, krawędź, czy wierzchołek jest częścią obu tych elementów, a współdzielony element jest tylko jeden i jest współdzielony w całości. Rozwiązanie to eliminuje konieczność wykonywania interpolacji w obrębie siatki numerycznej podczas wykonywania obliczeń numerycznych. Siatka strukturalna oznacza, że każdy z wewnętrznych węzłów otoczony jest przez tę samą liczbę elementów oraz występuje identyczny podział topologii wzdłuż kierunków w przestrzeni. Zmniejsza to liczbę objętości skończonych, co przekłada się na krótszy czas obliczeń numerycznych oraz na lepsze parametry zbieżności i dokładności obliczeń numerycznych.

Gotowa siatka numeryczna modelu analizowanego kotła fluidalnego składa się z 816407 sześciokątnych elementów (ang. hexahedral). Parametry opisujące jakość uzyskanej siatki numerycznej są następujące:

- *element quality* – średnia: 0.75 (min: 0.23, max: 1.00),
- *skewness* – średnia: 0.05 (min: 0.0, max: 0.73),
- *aspect ratio* – średnia: 2.15 (min: 1.00, max: 6.60).

### 3.2. Przyjęty model matematyczny

Złożony charakter przepływu fazy ciągłej i rozproszonej w złożach fluidalnych sprawia, modelowanie tych zjawisk jest jednym z trudniejszych zadań w modelowaniu procesów przepływowych. Modelowanie procesu przemysłowego w pełnej skali analizowanego kotła z dużym udziałem cząstek stałych, wymagało zastosowania modelu gęstej fazy dyspersyjnej DDPM (ang. Dense Discrete Phase Model). Model ten jest przykładem techniki obliczeniowej hybrydowej metody Eulera-Lagrange'a (HEL). Faza stała traktowana jest jako faza ciągła, co umożliwia odzwierciedlenie rzeczywistego rozkładu średnic cząstek w złożu. W podejściu Eulera-Lagrange'a faza ciągła opisana jest poprzez uśrednione w czasie równania Navier'a-Stokes'a, a faza rozproszona reprezentowana jest przez tzw. parcele, czyli punkty reprezentujące grupy o określonej ilości cząstek o tych samych parametrach fizycznych i poruszających się po tej samej trajektorii. Grupowanie cząstek w

parcele umożliwia analizę układów wielkoskalowych, z bardzo dużą ilością cząstek, dlatego wykorzystywany jest często do symulacji przepływów procesów fluidyzacji w kotłach [7, 48, 25, 32].

Podstawowe parametry przyjętego modelu przepływu wielofazowego w Ansys®Fluent zestawiono w Tab. 3.1.

Tabela 3.1

Parametry modelu matematycznego	
Lepkość granularna	Gidaspow [18]
Lepkość objętościowa	Lun [26]
Lepkość granularna w granicy tarcia	Schaeffer [38]
Ciśnienie tarcia	w oparciu o KTGF [10]
Moduł tarcia	derived [10]
Granica tarcia	0.61
Granica upakowania	0.63
Temperatura granularna	algebraic equation [10]
Ciśnienie fazy stałej	Lun [26]
Prawdopodobieństwo kolizji	Lun [26]
Moduł elastyczności	derived [10]
Model oporu	Gidaspow, [18]
Współczynnik restytucji	0.9
Kąt tarcia	30°

Równanie ruchu w układzie Lagrange'a rozwiązywane jest dla wszystkich grup ziaren. Zachodzące wzajemne interakcje pomiędzy fazą ciągłą i rozproszoną, oraz pomiędzy ziarnami w fazie rozproszonej opisane są dodatkowymi modelami, dobranymi do analizowanego zjawiska. Przyjęty model matematyczny uwzględnia interakcje zachodzące pomiędzy cząstkami poprzez odwołanie do kinetycznej teorii przepływu granularnego KTGF (ang. Kinetic theory of granular flow) [17, 27]. Gaz traktowany jest jako ciągły, nieściśliwy płyn i przedstawiany jest w układzie odniesienia Eulera. Równania zachowania masy i pędu dla fazy gazowej  $f$  zaprezentowano poniżej:

$$\frac{\partial}{\partial t} (\varepsilon_f \rho_f) + \nabla \cdot (\varepsilon_f \rho_f \mathbf{u}_f) = 0 \quad (3.1)$$

$$\frac{\partial}{\partial t} (\varepsilon_f \rho_f \mathbf{u}_f) + \nabla \cdot (\varepsilon_f \rho_f \mathbf{u}_f \mathbf{u}_f) = -\varepsilon_f \nabla p + \nabla \cdot \boldsymbol{\tau}_f + \varepsilon_f \rho_f \mathbf{g} + K_D (\mathbf{u}_s - \mathbf{u}_f) + S_{\text{mom}} \quad (3.2)$$

gdzie  $\varepsilon$  jest udziałem objętościowym,  $\rho$  jest gęstością,  $\mathbf{u}$  jest wektorem prędkości,  $p$  to ciśnienie,  $\tau_f$  jest tensorem naprężenia płynu,  $\mathbf{g}$  to wektor przyspieszenia ziemskiego,  $s$  definiuje fazę stałą,  $K_D$  określa współczynnik definiujący wymianę pędu między fazami, indeksy  $f$  i  $s$  definiują odpowiednio fazę ciągłą płynu/gazu oraz dyspersyjną/stałą,  $S_D$ ,  $S_{\text{mom}}$ , określają wymianę masy i pędu pomiędzy fazą ciągłą i dyspersyjną. Do modelowania turbulencji wykorzystano model  $k-\varepsilon$  z opcją *mixture* dla przepływów wielofazowych [10].

Równania ciągłości i pędu fazy stałej nie są rozwiązywane w układzie Eulera. Właściwości cząstek Lagrange'a odwzorowane są na siatce Eulera, gdzie obliczana jest średnia prędkość cząstek oraz ich udział objętościowy w każdym elemencie siatki obliczeniowej. Zbiór równań dla fazy ciągłej uzupełniony jest równaniem ruchu cząstek, wyznaczającym zmianę ich prędkości wskutek działania sił, i przyjmuje postać [9, 42]:

$$\frac{d\mathbf{u}_p}{dt} = F_D(\mathbf{u}_g - \mathbf{u}_p) + \frac{\mathbf{g}(\rho_p - \rho_g)}{\rho_p} - \frac{\nabla p}{\rho_p} - \frac{\nabla \cdot \sigma_s}{\rho_p} \quad (3.3)$$

gdzie  $\sigma_s$  definiuje naprężenia występujące w fazie stałej powstające w wyniku kolizji dla modelu HEL w oparciu o kinetyczną teorię przepływu granularnego [14, 17, 27],  $F_D(\mathbf{u}_f - \mathbf{u}_p)$  determinuje zmianę prędkości cząstki na skutek działania siły oporu. Prędkość i położenie cząstek zależą od obliczonej siły kolizji  $\frac{\nabla \cdot \sigma_s}{\rho_p}$ , która wyznaczana jest w oparciu o udział objętościowy fazy stałej w danej komórce obliczeniowej [4].

Główną wadą używania hybrydowego modelu Euler-Lagrange do symulacji wieloskalowych kotłów z cyrkulacyjnym złożem jest długi czas obliczeń numerycznych. Czas ten wydłuża się, wraz ze wzrostem stopnia złożoności modelu matematycznego oraz zwiększaniem ilości elementów siatki. Z uwagi na ogromny koszt obliczeniowy, przyjęty model matematyczny nie uwzględnia równania energii oraz równania reakcji chemicznych. Ponieważ w kotłach z cyrkulacyjnym złożem fluidalnym temperatura w całej objętości jest mocno wyrównana i dla ustalonych warunków pracy występuje mała zmienność temperatury w czasie, takie uproszczenie jest uzasadnione. Spadek temperatury w dolnej części komory paleniskowej jest efektem wprowadzania do tej strefy powietrza pierwotnego oraz wtórnego, którego temperatura jest znacznie niższa niż temperatura spalin - temperatura powietrza poniżej 300 °C gdy temperatura spalin w analizowanym kotle powyżej 850 °C.

Występujący spadek gęstości gazu na skutek obniżenia temperatury wpływa na występujące interakcje międzyfazowe. Dlatego gęstość gazu wyznaczana jest na podstawie zdefiniowanego profilu temperatury z wykorzystaniem funkcji użytkownika. Do obliczeń gęstości fazy gazowej przyjęto rzeczywisty profil zmiany temperatury wzdłuż wysokości komory paleniskowej kotła fluidalnego dla określonego obciążenia kotła. Pozwoliło to uwzględnić wpływ gęstości fazy gazowej na obliczoną prędkość fazy stałej. Masa materiału stałego w komorze paleniskowej została obliczona na podstawie rzeczywistego profilu ciśnienia statycznego analizowanego kotła fluidalnego.

Obliczenia numeryczne CFD zostały podzielone na dwa etapy. W pierwszym etapie kocioł napełniany jest materiałem stałym, zgodnie z zdefiniowanym rozkładem wielkości ziarna. Przyjęty rozkład zestawiono w Tab 3.2.

Tabela 3.2

Parametry materiału złoża

	Wartość
Całkowita ilość materiału	174 000, kg/s
Średnica minimalna	$6.3 \times 10^{-5}$ , m
Średnica maksymalna	0.002, m
Średnia średnica	0.0003, m
Rozkład średnic cząstek	Rosin-Rammler-Logarithmic [45]

Proces napełniania kotła materiałem złoża kontynuowany jest do momentu osiągnięcia wartości ciśnienia statycznego, które odpowiada wartości rzeczywistej ciśnienia zmierzonym w analizowanym kotle. Aby utrzymać wymaganą ilość cyrkulującego materiału, uruchamiana jest procedura recyrkulacji materiału złoża poprzez zdefiniowaną funkcję użytkownika, w trakcie której monitorowane jest ciśnienie w komorze paleniskowej. Przyjęty czas obliczeniowy dla pierwszego etapu ustalono na 30 s, co jest wystarczającym czasem do ustabilizowania warunków przepływowych w kotle. W trakcie pierwszego etapu monitorowana jest wartość ciśnienia w komorze paleniskowej oraz cyrkulująca masa w konturze obliczeniowym kotła.

Po ustabilizowaniu warunków przepływowych, następuje etap drugi, dla którego ustalono czas obliczeń na 100 s symulacji pracy kotła. W tym etapie uruchomiane zostaje uśrednianie w czasie zmiennych, takich jak udziały objętościowe faz, składowe prędkości faz oraz ciśnienie. W trakcie tego etapu włączone zostają obliczenia erozji powierzchni ogrzewalnych kotła fluidalnego. Obliczana erozja powierzchni ogrzewalnych sumowana jest przez cały czas prowadzenia obliczeń etapu drugiego. Po zakończeniu obliczeń, sumaryczna erozja jest pobrana do pliku w celu przeprowadzanie analizy ubytku erozyjnego dla poszczególnych lokalizacji w komorze paleniskowej analizowanego kotła.



### 3.3. Walidacja modelu


Walidacja przyjętego modelu przepływu wielofazowego została wykonana w oparciu o dane z okresu eksploatacji analizowanego kotła, które porównano z wynikami obliczeń numerycznych. Do walidacji przyjęto porównanie zmierzonego i obliczonego profilu ciśnienia wzdłuż wysokości analizowanego kotła fluidalnego dla 100 % obciążenia. Rzeczywiste pomiary ciśnienia wykonane były w 10 punktach pomiarowych. Lokalizację rzeczywistych pomiarów ciśnienia zaprezentowano na Rys. 3.2.

Porównanie wartości zmierzonej i obliczonej ciśnienia w komorze paleniskowej kotła fluidalnego dla 100 % zaprezentowano na Rys. 3.3. Niebieskie punkty na Rys. 3.3 to zmierzone wartości ciśnienia statycznego, a czerwona przerywana linia to obliczona wartość ciśnienia statycznego. Widoczna jest duża zgodność wyników pomiarów z wartością obliczeń numerycznych. Największa rozbieżność pomiędzy wartościami rzeczywistymi a obliczeniami ciśnienia występują w dolnym części komory paleniskowej kotła. Różnice te spowodowane są dużą koncentracją materiału złoża, która silnie wpływa na ciśnienie statyczne. Obliczona największa wartość różnicy ciśnienia wynosi około 1100 Pa, tuż nad rusztem komory paleniskowej na wysokości 0.2 m. Różnica pomiędzy pomiarami rzeczywistymi ciśnienia a obliczeniami może wynikać z przyjętych uproszczeń geometrii modelu oraz przyjętych założeń dotyczących wzajemnych interakcji pomiędzy fazą stałą i gazową.


### 3.4. Obliczenia erozji

Jak wskazano wcześniej, główną wadą kotłów fluidalnych jest intensywna erozja powierzchni ogrzewalnych w wyniku procesu fluidyzacji [11, 12]. Erozja to ubytek grubości ścianek powierzchni ogrzewalnych w wyniku kontaktu z cyrkulującymi cząsteczkami stałymi materiału złoża. Intensywność zachodzącego zjawiska erozji zależy od takich czynników jak prędkość cząsteczek, kąt zderzenia cząsteczki z powierzchnią ogrzewalną, właściwości fizyczne cząsteczek (rozmiar, kształt, twardość, struktura) [46, 23] oraz właściwości powierzchni ogrzewalnych (twardość oraz micro-struktura) [22]. Do obliczenia erozji rur parownika w analizowanym kotle fluidalnym, wykorzystano zaimplementowaną funkcję w oprogramowaniu Ansys<sup>®</sup>Fluent. Według badań [44, 35] poziom erozji może być opisany za pomocą równania (3.4):

$$R_{erosion} = \sum_{p=1}^{N_{par}} \frac{\dot{m}_p C(d_p) f(\alpha) v_p^n}{A_{face}} \quad (3.4)$$



Rys. 3.2. Lokalizacja pomiarów ciśnienia wykorzystanych do walidacji modelu numerycznego analizowanego kotła fluidalnego



Rys. 3.3. Wartość ciśnienia statycznego dla pełnej wydajności kotła

gdzie  $N_{par}$  definiuje numer komórki (grupy cząstek) uderzających w powierzchnię,  $\dot{m}_p$  definiuje przepływ masowy cząstek,  $C(d_p)$  definiuje średnicę cząstki,  $v_p$  definiuje prędkość


zderzenia,  $n$  definiuje wykładnik prędkości,  $A_{face}$  definiuje powierzchnię obszaru,  $f(\alpha)$  definiuje funkcję wpływu ( $\alpha$  określa kąt zderzenia).

Wartość erozji zgodnie z Rów. (3.4) obliczono dla stali, do obliczeń przyjęto współczynnik  $C(d_p)$  równy  $2 \cdot 10^9$  oraz  $n$  równy 2.6 [19].

Funkcja wpływu  $f(\alpha)$ , została zaimplementowana do modelu CFD, i obliczona jest zgodnie z równaniem [16]:

$$f(\alpha) = \begin{cases} \sin(2\alpha) - 3\sin^2(\alpha) & : \alpha \in \langle 0^\circ, 18.5^\circ \rangle \\ \cos^2(\alpha)/3 & : \alpha \in \langle 18.5^\circ, 90^\circ \rangle \end{cases} \quad (3.5)$$

Zgodnie z Rów. (3.5) funkcja wpływu największą wartość osiąga dla cząsteczki zderzającej się z powierzchnią ogrzewalną pod kątem około  $20^\circ$ . Graficzną postać funkcji wpływu  $f(\alpha)$  zaprezentowano na Rys. 3.4.



Rys. 3.4. Wartość funkcji wpływu  $f(\alpha)$  w zależności od kąta uderzenia cząsteczki  $\alpha$

Rozdział 2.3 opisuje opracowany model do predykcji temperatury na ruszcie komory paleniskowej analizowanego kotła fluidalnego. Umożliwia zmianę rozkładu temperatury w przekroju kotła, poprzez zmianę rozkładu paliwa i powietrza doprowadzanego do kotła. Aby zweryfikować, czy wyrównanie rozkładu temperatury na ruszcie komory paleniskowej wpływa na erozję ścian ekranowych w komorze paleniskowej wykonano obliczenia numeryczne dla dwóch różnych okresów pracy kotła, dla których obliczono wartość erozji powierzchni ogrzewalnych. Obliczenia wykonano przy różnych stanach pracy analizowanego kotła, pracującego odpowiednio z wydajnością 93.6 i 95.9% maksymalnej wydajności kotła. Podstawowe parametry eksploatacyjne dla których wykonano obliczenia numeryczne zestawiono w Tab. 3.3.


Wybrane do obliczeń okresy pracy kotła różniły się rozkładem temperatury mierzonej nad rusztem kotła na wysokości 250 mm powyżej rusztu (rozmeszczenie

termopar na Rys. 1.6). Wartość temperatury T1÷T12 dla obu analizowanych przypadków zaprezentowano na Rys. 3.5.

Tabela 3.3

Parametry ruchowe kotła fluidalnego dla analizowanych przykładów

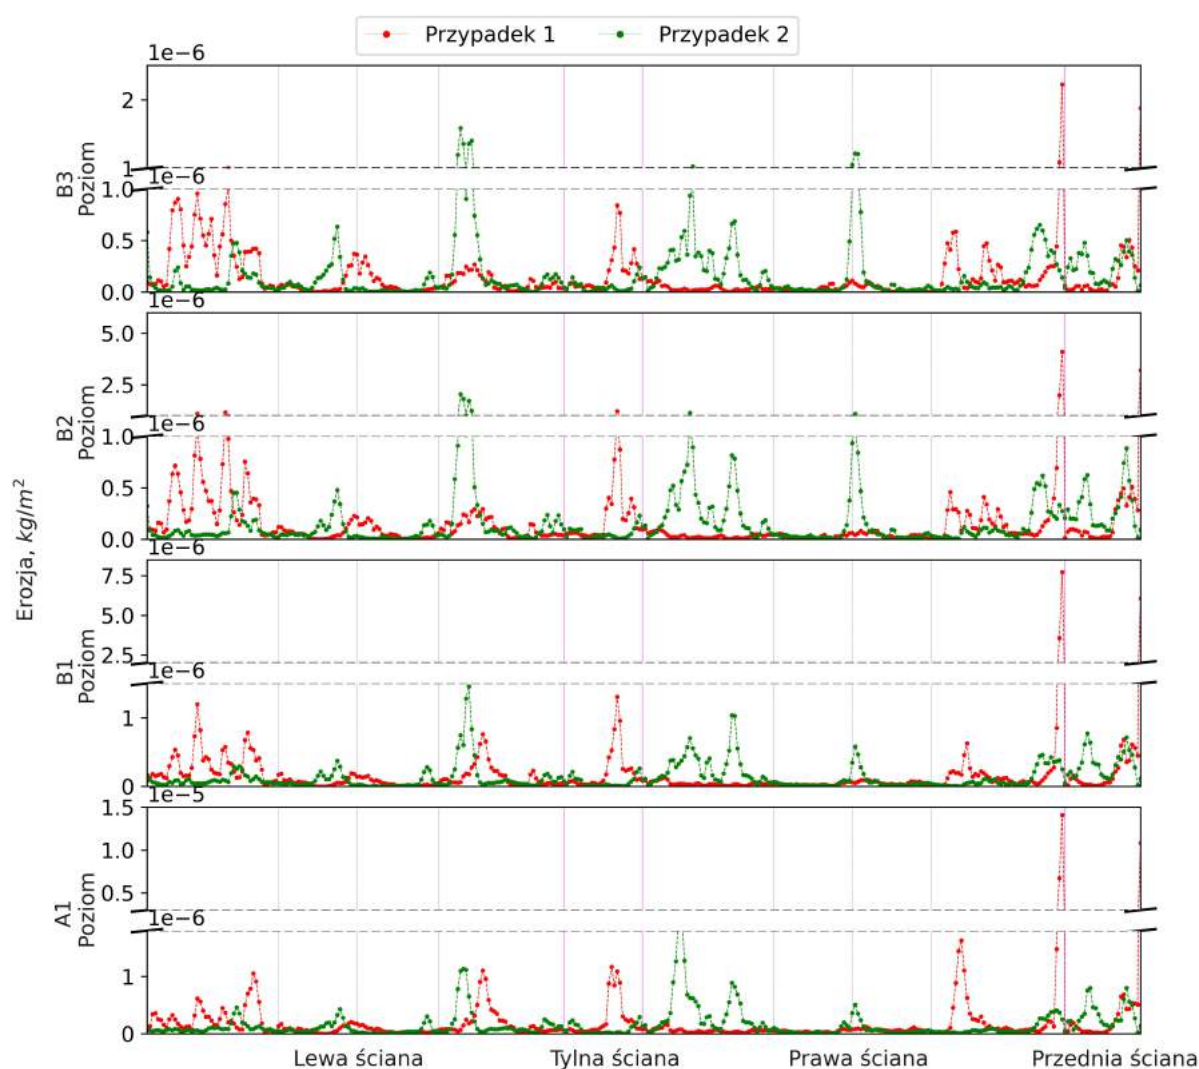
Parametry kotła	Przypadek 1	Przypadek 2
Wydajność kotła, kg/s	338.7	346.5
Ilość powietrza pierwotnego, kg/s	242.45	227.90
Ilość powietrza wtórnego, kg/s	125.8	132.6
Temperatura powietrza pierwotnego, °C	290	290
Temperatura powietrza wtórnego, °C	298	298
Ilość paliwa, kg/s	50.3	53.7



Rys. 3.5. Rozkład temperatury dla Przypadku 1 i 2 na wysokości 250 mm.

W pierwszym etapie obliczeń przepływowych sprawdzono, czy model numeryczny reaguje na zmianę parametrów wejściowych, czyli czy obliczona erozja powierzchni ogrzewalnych różni się w zależności od wprowadzonych danych wejściowych do modelu. Odczytane z systemu *DCS* dane wprowadzono do modelu numerycznego. Zgodnie z wcześniej opisaną procedurą obliczenia rozpoczęto od procesu napełnienia kotła materiałem, który kontynuowany jest do osiągnięcia stabilnej wartości ciśnienia statycznego, równej

rzeczywistej wartości ciśnienia w analizowanym kotle. Po 30 s obliczeń w trakcie których ustabilizowały się warunki przepływowe, włączono w czasie uśrednianie zmiennych wraz z włączeniem obliczenia erozji powierzchni ogrzewalnych kotła fluidalnego. Czas trwania obliczeń ustalono na 100 s symulacji pracy kotła. Końcowy wynik obliczeń zaprezentowano dla obu liczonych przypadków. Kluczowym obszarem dla którego dążymy do obniżenia erozji w komorze paleniskowej są rury ekranowe zlokalizowane nad linią zakończenia obmurza (wysokość około 9 m nad rusztem kotła). Wynik obliczeń numerycznych dla 4 poziomów pomiarowych w kotle A1÷B3 pobrano z Ansys®Fluent. Graficznie wyniki zaprezentowano na Rys. 3.6. Widać, że obliczona wartość erozji znacząco różni się pomiędzy analizowanymi przypadkami pracy kotła. Wskazuje to, że przygotowany model numeryczny reaguje prawidłowo na zadaną zmianę parametrów wejściowych.



Rys. 3.6. Obliczona wartość erozji po 100 s symulacji pracy kotła na czterech poziomach diagnostycznych B3÷A1


### 3.4.1. Przypadek 1

Po upewnieniu, się, że model numeryczny reaguje prawidłowo na zmianę parametrów, przestąpiono do kolejnego kroku obliczeń.

Dla pierwszego z analizowanych przypadków przeliczono nowe dwa warianty rozkładu paliwa oraz powietrza wtórnego dostarczanego do kotła fluidalnego. Przygotowany algorytm w *Python* przy pomocy modeli do predykcji temperatury zmienił ilość paliwa dostarczanego do każdego z podajników węgla oraz powietrza wtórnego dostarczanego przez palniki rozpałkowe, tak aby w efekcie otrzymać:

- wyrównany rozkład temperatury na ruszcie kotła (poziom +250mm, Rys. 1.6) - przypadek 1a (czerwony),
- odmienny rozkład temperatury na ruszcie kotła - przypadek 1b (zielony).

Pozostałe parametry ruchowe kotła nie uległy zmianom. Obliczone temperatury dla nowego rozkładu paliwa i powietrza wtórnego zaprezentowano na Rys. 3.7. Kolor niebieski reprezentuje zmierzoną wartość temperatury T1÷T12 na ruszcie kotła, kolor czerwony i zielony reprezentuje odpowiednio wartości obliczonej temperatury dla wyrównanego oraz odmiennego rozkładu temperatury na ruszcie, zgodnie w wynikami obliczeń sieci neuronowych.



Rys. 3.7. Temperatury T1÷T12 dla pierwszego przypadku

Obliczone przez model predykcyjny wartości węgla dla każdego z podajników paliwa oraz ilość powietrza wtórnego dostarczanego przez palniki do analizowanego

kotła zestawiono odpowiednio w Tab. 3.4 Tab. 3.5. Wartości te zestawiono dla trzech przypadków: ruchowego (przypadek 1) oraz przypadków obliczonych przez algorytm przy pomocy sieci neuronowych.

Tabela 3.4

Ilość paliwa do podajników węgla (CF) dla pierwszego Przypadku

	Przypadek 1a, kg/s wyrównany rozkład temperatury	Przypadek 1b, kg/s odmienny rozkład temperatury	Przypadek 1, kg/s parametry ruchowe kotła
CF12	3.64	2.85	2.99
CF13	4.20	4.78	2.31
CF14	2.55	3.15	4.63
CF22	2.14	3.05	4.63
CF23	3.72	4.33	4.63
CF24	3.65	5.51	3.10
CF25	3.97	3.26	2.40
CF32	3.88	3.09	4.04
CF33	3.90	4.15	3.78
CF34	3.79	4.00	4.36
CF35	3.28	3.36	4.36
CF42	4.26	3.40	4.36
CF43	4.43	3.85	2.38
CF44	2.86	1.49	2.32

Obliczone przez model predykcyjny wartości paliwa i powietrza wtórnego zostały wprowadzone jako wartości wejściowe do modelu numerycznego analizowanego kotła. Dla przygotowanych danych wykonano obliczenia erozji powierzchni ogrzewalnych dla przypadku z wyrównanym i odmiennym rozkładem temperatury. Tak jak poprzednio, po 30 s obliczeń i ustabilizowaniu się warunków przepływowych, włączono uśrednianie zmiennych wraz z włączeniem obliczenia erozji powierzchni ogrzewalnych kotła fluidalnego. Czas trwania obliczeń ustalono na 100 s symulacji pracy kotła.

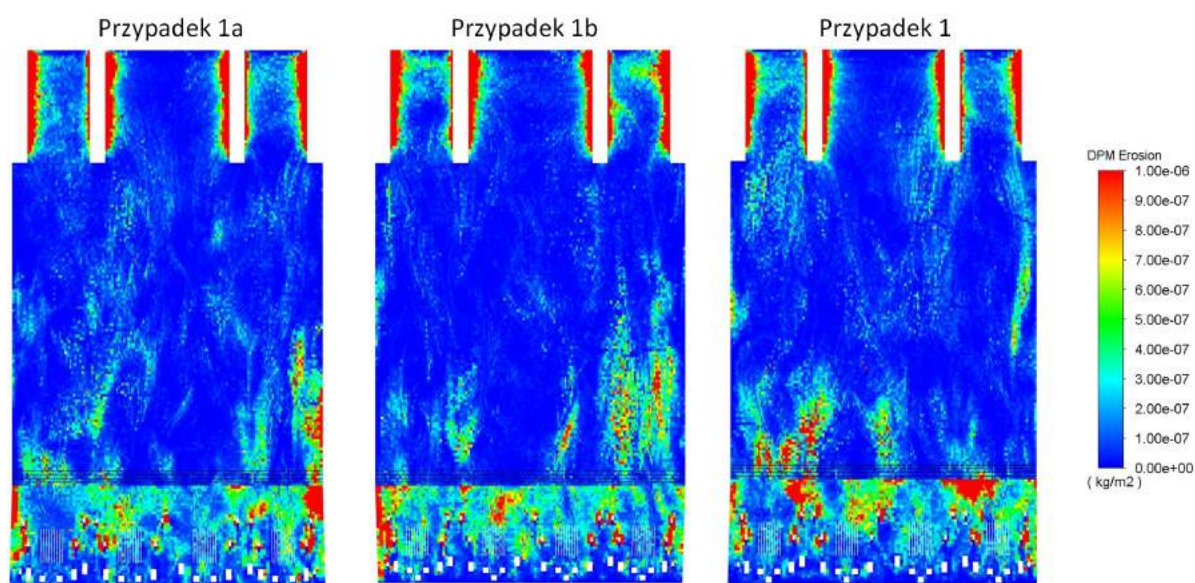
Wyniki obliczeń erozji ścian bocznych analizowanego kotła w Ansys®Fluent zaprezentowano w postaci graficznej na Rys. 3.8,3.9. Wyraźnie widać różnicę w obliczonej erozji w zależności od zmiany rozkładu paliwa i powietrza wtórnego podawanego do kotła.

Aby lepiej zobaczyć różnice w poziomie erozji, dla kluczowego rejonu kotła (powyżej odgięcia rur ekranowych nad linią zakończenia obmurza) z Ansys®Fluent pobrano

Tabela 3.5

Ilość powietrza wtórnego do palników rozpałkowych (OB) dla pierwszego  
Przypadku

	Przypadek 1a, kg/s wyrównany rozkład temperatury	Przypadek 1b, kg/s odmienny rozkład temperatury	Przypadek 1, kg/s parametry operacyjne kotła
OB01	1.54	3.83	2.55
OB02	2.01	3.82	2.55
OB03	2.16	1.51	3.36
OB04	4.49	3.80	3.36
OB05	3.42	4.63	3.36
OB06	3.15	2.24	2.56
OB07	3.80	2.10	2.61
OB08	4.19	2.08	3.36
OB09	3.56	3.49	3.35
OB10	2.14	2.97	3.36

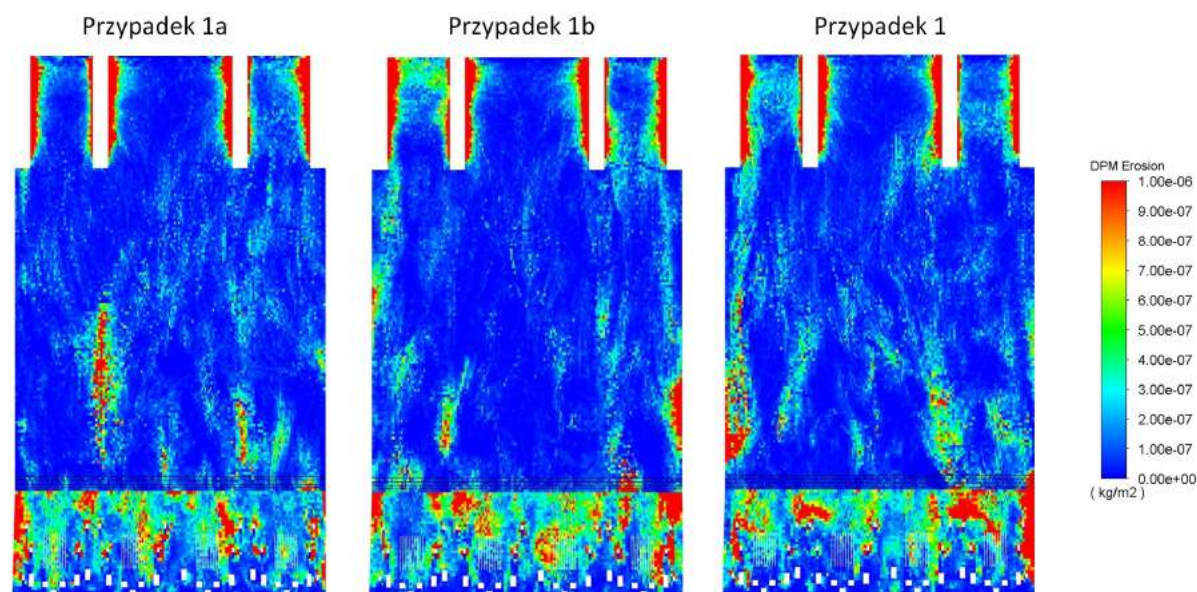


Rys. 3.8. Obliczona erozja na lewej ścianie analizowanego kotła po 100 s obliczeń

wartości liczbowe obliczonej erozji, a wyniki dla czterech poziomów pomiarowych  $A1 \div B3$  dla wszystkich czterech ścian kotła zaprezentowano na Rys. 3.10.

Obliczona wartość erozji wskazuje na znaczące różnice dla każdego z obliczonych wariantów. Analiza wyników wskazuje, że najbardziej korzystny dla pracy analizowanego





Rys. 3.9. Obliczona erozja na prawej ścianie analizowanego kotła po 100 s obliczeń

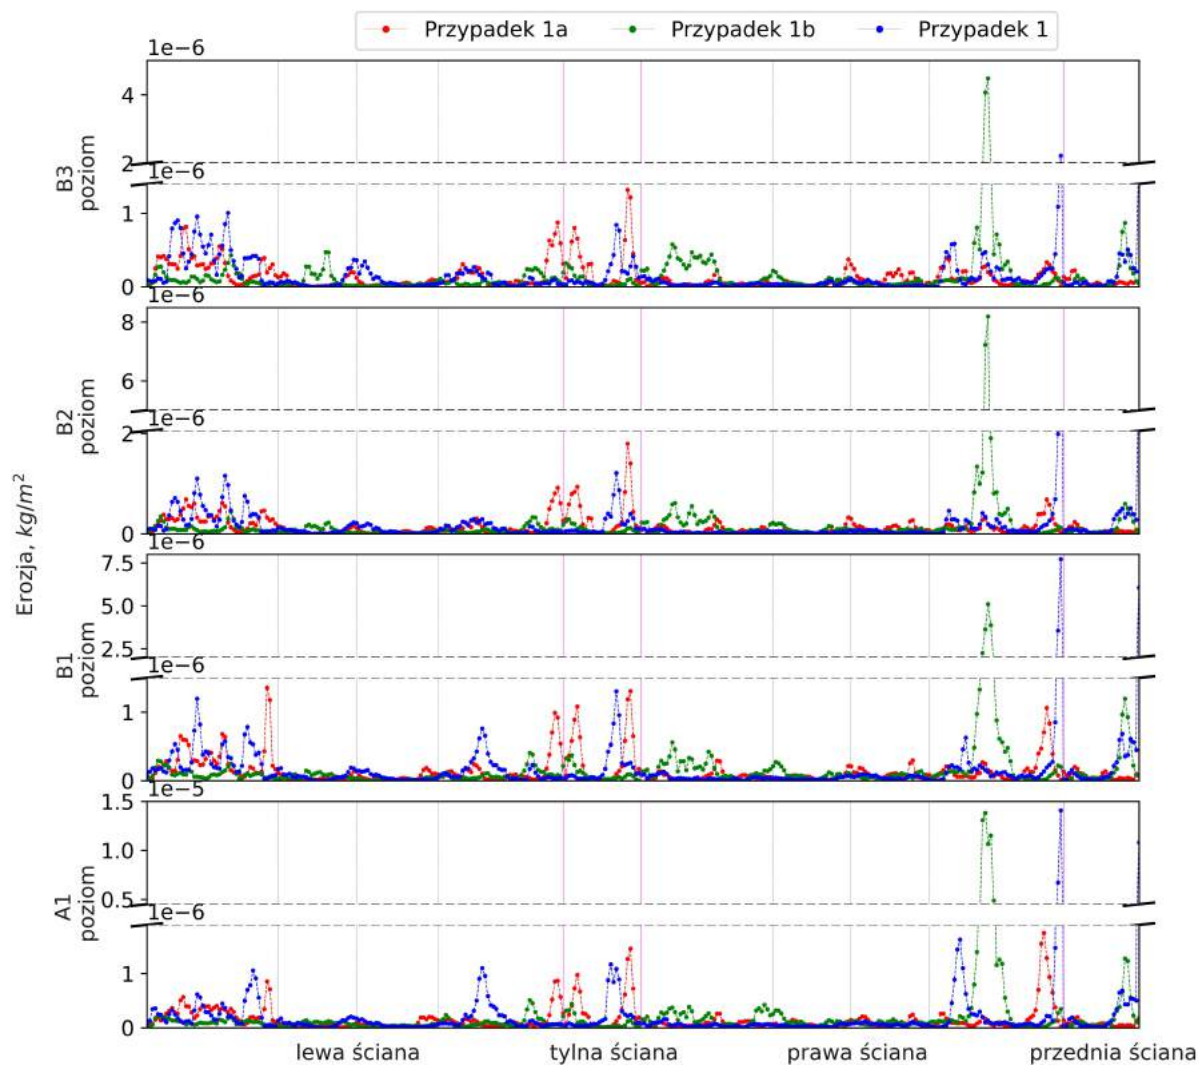
kotła pod kątem erozji powierzchni ogrzewalnych to przypadek 1a (Rys. 3.10, czerwony kolor). Jest to wariant dla którego za pomocą modelu do predykcji temperatury zmieniono rozkład węgla i powietrza wtórnego, tak aby otrzymać wyrównany rozkład temperatury  $T1 \div T12$  na ruszcie kotła.

Przypadek 1b, dla którego za pomocą modelu do predykcji temperatury zmieniono rozkład węgla i powietrza wtórnego pod kątem otrzymania odmiennego rozkładu temperatury  $T1 \div T12$  na ruszcie kotła (Rys. 3.7, kolor zielony) jest przypadkiem najmniej korzystnym pod kątem intensywności erozji powyżej zakończenia obmurza w komorze paleniskowej. Widoczny jest bardzo duży wzrost obliczonej erozji w prawym przednim narożu kotła. Jest to bardzo niekorzystna sytuacja, która przy dłuższej pracy może szybko doprowadzić do uszkodzenia rur parownika.

Przypadek 1 (niebieski kolor) to przypadek z rozkładem paliwa i powietrza wtórnego, który został pobrany z systemu *DCS*. Jest to mniej korzystny przypadek pod kątem zjawiska erozji niż przypadek 1a, a na poziomie diagnostycznym B1 obliczona maksymalna wartość erozji przewyższa obliczoną erozję dla przypadku 1B.

Dla otrzymanych wyników erozji obliczonych w Ansys®Fluent dla każdego z czterech analizowanych poziomów pomiarowych A1÷B3 obliczono wartość odchylenia standardowego  $\sigma$  oraz całkowitą erozję dla każdego z analizowanych poziomów. Wartość odchylenia dla każdego z poziomów A1÷B3 zestawiono w Tab. 3.6, całkowitą erozję jako sumę obliczonych erozji zestawiono w Tab. 3.12, a obliczoną wartość maksymalną erozji w Tab. 3.8. Wyniki obliczeń dla pierwszego przypadku potwierdzają, że wyrównanie rozkładu temperatury w przekroju poprzecznym komory paleniskowej analizowanego

kotła ogranicza intensywność erozji rur ekranowych powyżej linii zakończenia obmurza ogniowego.



Rys. 3.10. Obliczona erozja dla czterech ścian komory paleniskowej na poziomach pomiarowych A1 ÷ B3

Tabela 3.6

Wartość odchylenia standardowego  $\sigma$  erozji na poziomach A1÷B3

	Przypadek 1a, kg/m <sup>2</sup> wyrównany rozkład temperatury	Przypadek 1b,kg/m <sup>2</sup> odmienny rozkład temperatury	Przypadek 1, kg/m <sup>2</sup> parametry operacyjne kotła
B3	1.7e-07	3.6e-07	2.4e-07
B2	2e-07	6e-07	3.4e-07
B1	2.1e-07	4.3e-07	5.7e-07
A1	2.2e-07	1.33e-06	1.02e-06

Tabela 3.7

Całkowita erozja dla każdego z poziomów A1÷B3

	Przypadek 1a, kg/m <sup>2</sup> wyrównany rozkład temperatury	Przypadek 1b,kg/m <sup>2</sup> odmienny rozkład temperatury	Przypadek 1, kg/m <sup>2</sup> parametry operacyjne kotła
B3	4.7e-05	5e-05	5.3e-05
B2	5e-05	5.8e-05	5.6e-05
B1	5e-05	5.8e-05	6.5e-05
A1	5.3e-05	0.000103	8.8e-05

Tabela 3.8


Maksymalna wartość erozji obliczonej na poziomach pomiarowych A1÷B3

	Przypadek 1a, kg/m <sup>2</sup> wyrównany rozkład temperatury	Przypadek 1b,kg/m <sup>2</sup> odmienny rozkład temperatury	Przypadek 1, kg/m <sup>2</sup> parametry operacyjne kotła
B3	1.32e-06	4.48e-06	2.22e-06
B2	1.79e-06	8.19e-06	4.1e-06
B1	1.36e-06	5.1e-06	7.73e-06
A1	1.75e-06	1.381e-05	1.407e-05

### 3.4.2. Przypadek 2

Analogicznie jak dla przypadku pierwszego, również dla drugiego przypadku przeliczono dwa warianty rozkładu paliwa oraz powietrza wtórnego dostarczanego do kotła fluidalnego. Przygotowany algorytm w *Python* zmienił ilość paliwa dostarczanego do każdego z podajnika węgla oraz powietrza wtórnego dostarczanego przez palniki rozpałkowe, tak aby w efekcie otrzymać dwa, różniące się rozkłady temperatury na ruszcie kotła - wyrównany oraz odmienny.

Obliczone temperatury przez model do predykcji dla zmienionego rozkładu paliwa oraz powietrza wtórnego zaprezentowano na Rys. 3.11. Kolor niebieski reprezentuje zmierzoną wartość temperatury T1÷T12 na ruszcie kotła, kolor czerwony i zielony reprezentuje odpowiednio wartości obliczonej temperatury dla wyrównanego oraz odmiennego rozkładu temperatury na ruszcie.



Rys. 3.11. Temperatury T1÷T12 dla drugiego przypadku

Obliczone przez model predykcyjny wartości paliwa dla każdego z podajników paliwa oraz powietrza wtórnego dostarczanego przez palniki do analizowanego kotła zestawiono odpowiednio w Tab. 3.9 Tab. 3.10. Wartości w tabeli zestawiono dla przypadku ruchowego (przypadek 2) oraz przypadków obliczonych przez model do predykcji temperatury.

Ponownie, jak dla pierwszego przykładu, nowe wartości paliwa i powietrza zostały wprowadzone jako wartości wejściowe do modelu numerycznego analizowanego kotła. Obliczenia numeryczne wykonano dla każdego z wariantów rozkładu temperatury na ruszcie kotła fluidalnego. Tak jak poprzednio, po 30 s obliczeń i ustabilizowaniu warunków

Tabela 3.9

Ilość paliwa do podajników węgla (CF) dla drugiego Przypadku

	Przypadek 1a, kg/s wyrównany rozkład temperatury	Przypadek 1b, kg/s odmienny rozkład temperatury	Przypadek 1, kg/s parametry ruchowe kotła
CF12	3.12	4.63	2.70
CF13	.82	5.11	2.70
CF14	3.69	2.01	4.78
CF22	2.47	3.86	5.08
CF23	3.83	5.72	4.81
CF24	4.23	4.15	3.86
CF25	2.17	2.76	3.48
CF32	5.75	4.21	5.01
CF33	0.86	0.40	4.86
CF34	3.66	4.36	0.00
CF35	3.11	2.70	5.54
CF42	5.37	4.93	4.59
CF43	6.33	5.94	3.33
CF44	3.32	2.95	3.05

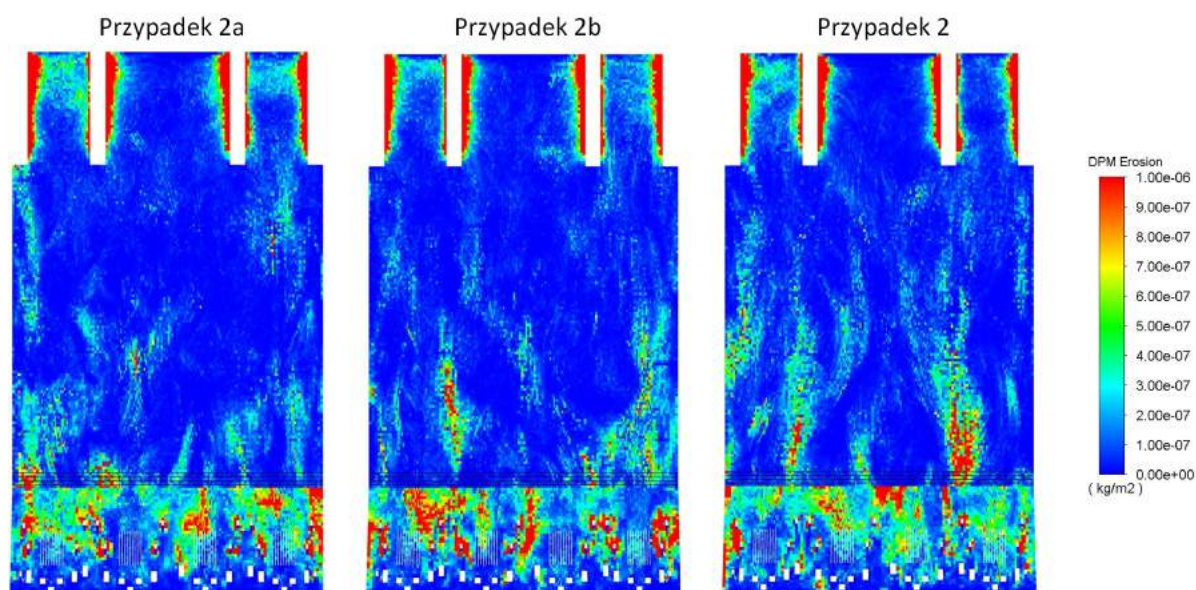
Tabela 3.10

Ilość powietrza wtórnego do palników rozpałkowych (OB) dla drugiego Przypadku

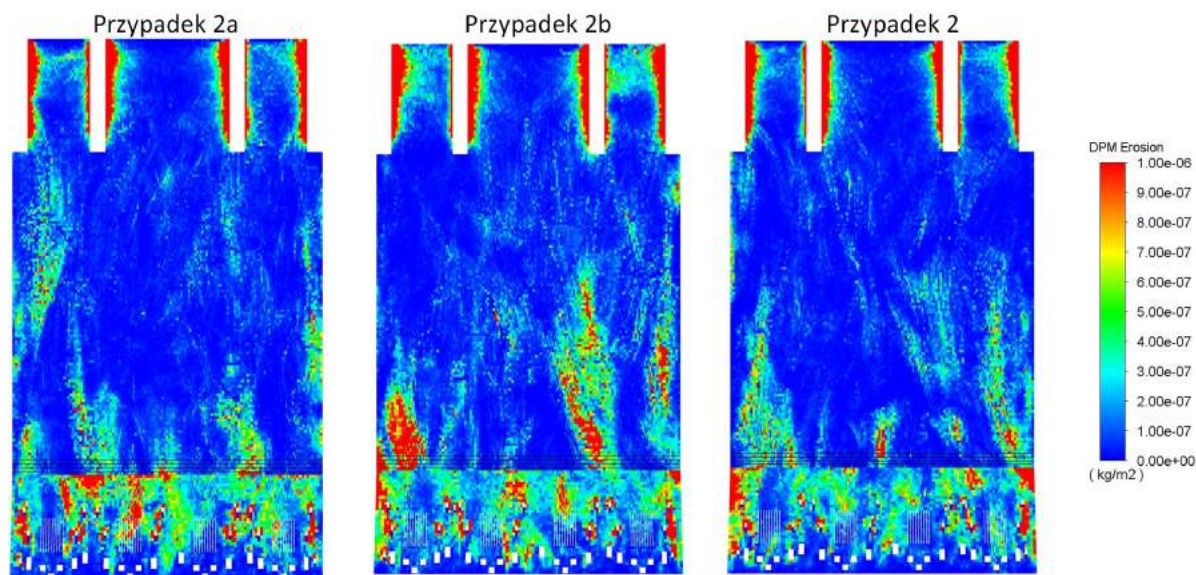
	Przypadek 1a, kg/s wyrównany rozkład temperatury	Przypadek 1b,kg/s odmienny rozkład temperatury	Przypadek 1, kg/s parametry operacyjne kotła
OB01	2.21	1.83	2.57
OB02	2.26	2.84	2.55
OB03	5.03	5.01	4.12
OB04	2.99	3.71	4.08
OB05	3.96	4.10	4.13
OB06	3.18	1.35	2.52
OB07	3.28	2.78	2.58
OB08	4.52	4.92	4.11
OB09	3.28	3.11	4.17
OB10	4.25	5.31	4.13

przyptywowych w kotle, włączono uśrednianie danych oraz obliczenia erozji powierzchni ogrzewalnych. Przyjęty czas obliczeń przyjęto analogicznie jak dla pierwszego przykładu i ustawiono na 100 s symulacji pracy kotła.

Wyniki obliczeń erozji ścian bocznych analizowanego kotła w Ansys®Fluent zaprezentowano w postaci graficznej na Rys. 3.12,3.13. Ponownie widać dużą różnicę w intensywności erozji dla każdego z trzech wariantów rozkładu temperatury na ruszcie kotła.



Rys. 3.12. Obliczona erozja na lewej ścianie analizowanego kotła po 100 s obliczeń



Rys. 3.13. Obliczona erozja na prawej ścianie analizowanego kotła po 100 s obliczeń

Dla lepszego zobrazowania różnic w erozji dla kluczowego rejonu kotła (powyżej odgięcia rur ekranowych nad linią zakończenia obmurza) z Ansys®Fluent pobrano wartości liczbowe obliczonej erozji. Wyniki dla czterech poziomów pomiarowych  $A1 \div B3$  dla wszystkich czterech ścian kotła zaprezentowano na Rys. 3.14.

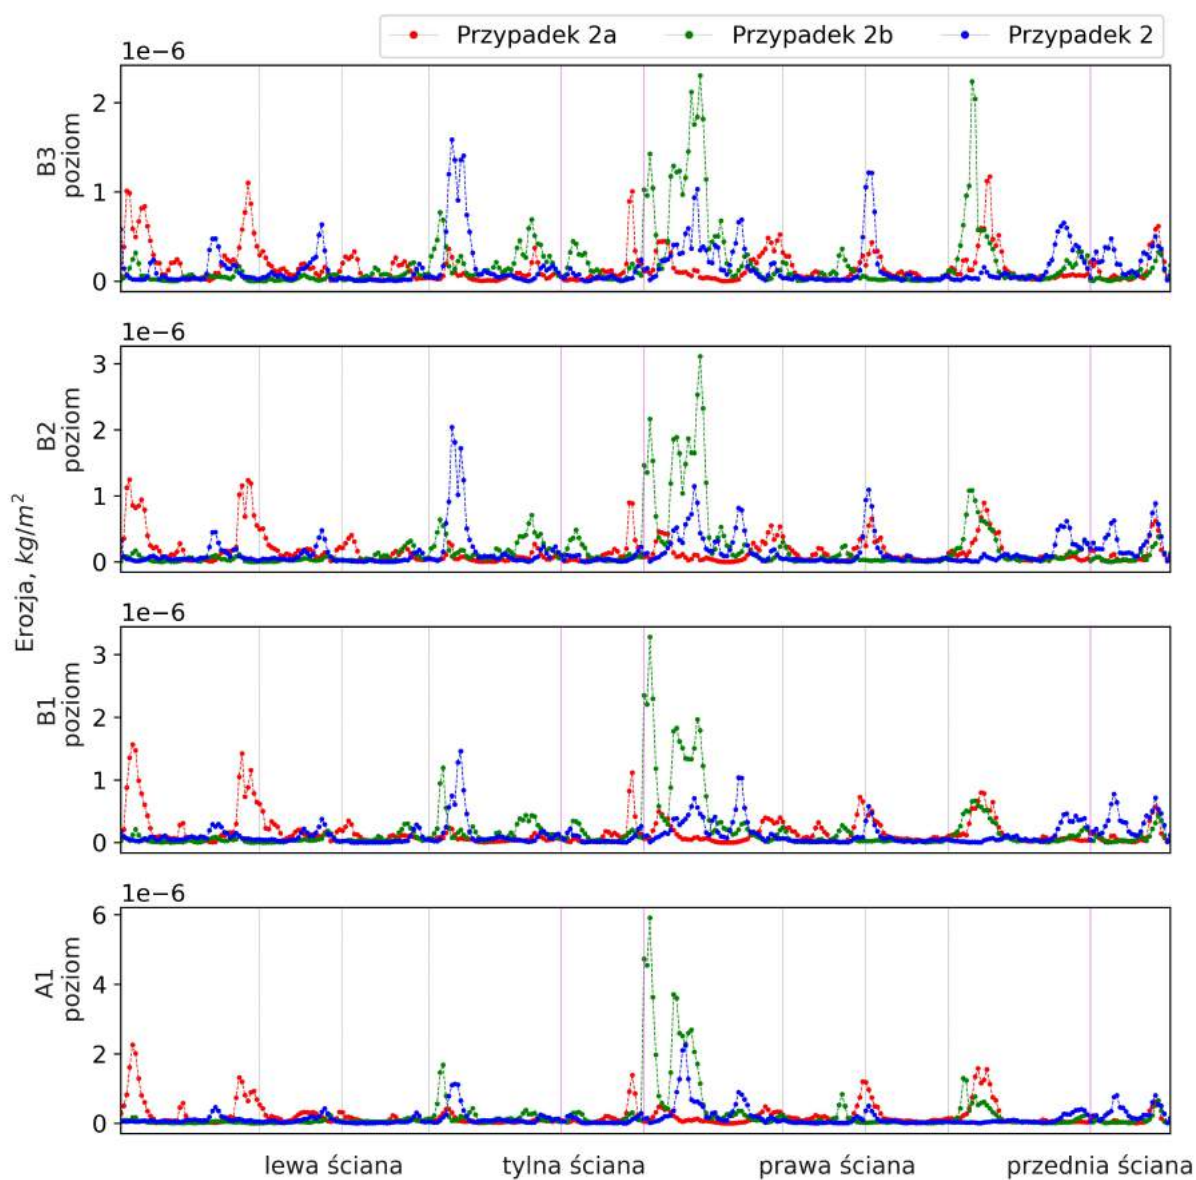
Podobnie jak dla pierwszego przypadku, również dla drugiego przypadku obliczona wartość erozji wykazuje znaczne różnice dla każdego z obliczonych wariantów. Analiza otrzymanych wartości wskazuje, że najbardziej korzystny dla pracy analizowanego kotła pod względem erozji powierzchni ogrzewalnych to przypadek 1a (Rys. 3.14, czerwony kolor), czyli wariant dla sieci neuronowej dobrała nowy rozkład węgla i powietrza wtórnego aby otrzymać wyrównany rozkład temperatury  $T1 \div T12$ .

Przypadek 1b (zielony kolor), dla którego rozkład węgla i powietrza wtórnego dobrano pod kątem otrzymania odmiennego rozkładu temperatury  $T1 \div T12$  na ruszcie kotła (Rys. 3.11, kolor zielony) jest przypadkiem najmniej korzystnym pod kątem intensywności erozji powyżej zakończenia obmurza w komorze paleniskowej. Widoczne są duże miejscowe ubytki materiału na prawej ścianie kotła.

Przypadek 1 (niebieski kolor) to przypadek z niezmiennym rozkładem paliwa i powietrza wtórnego. W tym przypadku, obliczona wartość erozji dla powierzchni ogrzewalnych jest zbliżona do przypadku 2a.

Obliczoną w Ansys®Fluent wartość erozji dla czterech poziomów pomiarowych  $A1 \div B3$  obliczono wartość odchylenia standardowego  $\sigma$ , całkowitą erozję oraz obliczoną maksymalną wartość erozji. Wartość odchylenia dla każdego z poziomów  $A1 \div B3$  zestawiono w Tab. 3.11. Całkowitą erozję jako sumę obliczonych erozji zestawiono w Tab. 3.12, a obliczoną wartość maksymalną erozji w Tab. 3.13. Porównując wyniki dla przypadku 2 (bazowego) oraz przypadku 2a można zauważyć, że obliczona wartość odchylenia standardowego dla przypadku z wyrównanym rozkładem temperatury na ruszcie dla poziomu pomiarowego B3, natomiast na pozostałych poziomach pomiarowych  $B2 \div A1$  wahania erozji są mniejsze dla przypadku 2. Podobnie prezentują się wyniki obliczonej sumarycznej erozji na każdym z poziomów pomiarowych. Porównanie wartości obliczonej maksymalnej erozji dla każdego z poziomów pomiarowych wskazuje, że zdecydowanie korzystniejszym przypadkiem dla eksploatacji analizowanego kotła fluidalnego jest przypadek 2a. Obliczona wartość maksymalnej erozji dla poziomów B3 oraz B2 jest o 40% mniejsza niż dla przypadku bazowego 2. Taki wynik obliczeń jest uzasadniony, ponieważ rozkład temperatur rzeczywistych dla przypadku 2 (Rys. 3.11, kolor niebieski) oraz obliczonych dla przypadku 2a (Rys. 3.11, kolor czerwony) jest podobny. Jest to sytuacja, w której rzeczywisty rozkład temperatury na ruszcie analizowanego kotła był zbliżony do optymalnego rozkładu temperatur.

Podobnie jak dla przypadku pierwszego, wyniki obliczeń dla drugiego przypadku potwierdzają, że wyrównanie rozkładu temperatury w przekroju poprzecznym komory



Rys. 3.14. Obliczona erozja dla czterech ścian komory paleniskowej na poziomach pomiarowych  $A1 \div B3$

paleniskowej analizowanego kotła ogranicza intensywność erozji rur ekranowych powyżej linii zakończenia obmurza ogniotrwałego.



Tabela 3.11

Wartość odchylenia standardowego  $\sigma$  erozji na poziomach A1÷B3

	Przypadek 2a, kg/m <sup>2</sup> wyrównany rozkład temperatury	Przypadek 2b,kg/m <sup>2</sup> odmienny rozkład temperatury	Przypadek 2, kg/m <sup>2</sup> parametry operacyjne kotła
B3	2e-07	3.6e-07	2.4e-07
B2	2.2e-07	4e-07	2.6e-07
B1	2.4e-07	3.9e-07	1.9e-07
A1	3.2e-07	6.7e-07	2.6e-07

Tabela 3.12

Całkowita erozja dla każdego z poziomów A1÷B3

	Przypadek 2a, kg/m <sup>2</sup> wyrównany rozkład temperatury	Przypadek 2b,kg/m <sup>2</sup> odmienny rozkład temperatury	Przypadek 2, kg/m <sup>2</sup> parametry operacyjne kotła
B3	5.7e-05	7.1e-05	5.7e-05
B2	5.9e-05	7.2e-05	5.7e-05
B1	6e-05	6.8e-05	5e-05
A1	7.5e-05	9.1e-05	5.6e-05

Tabela 3.13

Maksymalna wartość obliczonej na poziomach pomiarowych A1÷B3

	Przypadek 2a, kg/m <sup>2</sup> wyrównany rozkład temperatury	Przypadek 2b,kg/m <sup>2</sup> odmienny rozkład temperatury	Przypadek 2, kg/m <sup>2</sup> parametry operacyjne kotła
B3	1.17e-06	2.3e-06	1.59e-06
B2	1.24e-06	3.11e-06	2.04e-06
B1	1.57e-06	3.28e-06	1.46e-06
A1	2.26e-06	5.91e-06	2.23e-06



## Podsumowanie

W ramach niniejszej pracy opracowano model numeryczny działający w oparciu o algorytm uczenia maszynowego, który pozwala na predykcję temperatury mierzonej na wysokości 250 mm nad rusztem analizowanego kotła fluidalnego. Temperatura na ruszcie analizowanego kotła monitorowana jest przez dwanaście zabudowanych termopar. W założeniu, obliczenie temperatury na ruszcie kotła na podstawie parametrów ruchowych kotła, takich jak rozkład paliwa oraz powietrza dostarczanego do komory paleniskowej, pozwala na optymalizację tych parametrów pod kątem otrzymanego rozkładu temperatury na ruszcie. Równomierny rozkład temperatury ogranicza występowanie niekorzystnych dla żywotności rur ekranowych lokalnych obszarów o bardzo dużej intensywności erozji.

W początkowym etapie prac, po analizie występujących awarii w analizowanym kotle (po stronie ciśnieniowej) założono, że występowanie lokalnych obszarów o dużej erozji powierzchni ogrzewalnych w komorze paleniskowej zależy od parametrów ruchowych kotła, w tym od rozkładu temperatury na ruszcie kotła. Na rozkład temperatury na ruszcie wpływa wiele czynników, takich jak ilość i jakość (parametry fizyko-chemiczne) dostarczanego paliwa, rozkład paliwa na poszczególne palniki oraz ilość dostarczanego powietrza i jego rozkład na poszczególne dysze.

Pierwszym problemem który próbowano rozwiązać, było opracowanie wiarygodnej metody na wyrównanie temperatury w przekroju poprzecznym analizowanego kotła oraz ustalenie czy istnieje realna możliwość kontrolowanej zmiany temperatury w komorze paleniskowej. Do rozwiązania zagadnienia wykorzystano coraz bardziej otaczającą nas w codziennej rzeczywistości tzw. „sztuczną inteligencję”, a konkretnie algorytmy uczenia maszynowego. Za pomocą funkcji zaimplementowanych w bibliotekach oprogramowania „Python”, zbudowano model do predykcji temperatury  $T1 \div T12$  w komorze paleniskowej (Rys. 1.6). Żmudne i czasochłonne obliczenia związane z nauką różnych konfiguracji sieci neuronowych powtarzano przez setki godzin, w poszukiwaniu dokładnego modelu do predykcji temperatury. Poświęcony czas zaowocował znalezieniem modelu do predykcji, którego błąd średniokwadratowy wynosi około  $1^\circ \text{C}$  dla poszczególnych temperatur  $T1 \div T12$  (obliczony błąd zestawiony w Tab. 2.7,2.8).

Predykcja temperatury na ruszcie to za mało - potrzebna była możliwość kierunkowej zmiany temperatury bez zakłócenia pracy analizowanego kotła, a co za tym idzie całego bloku energetycznego. W tym celu opracowano kod w *Python*, który umożliwia zmianę rozkładu powietrza wtórnego dostarczanego do poszczególnych palników olejowych

(OB) oraz węgla do poszczególnych podajników węgla (CF) (Rys. 1.3). Dzięki tym zmianom możliwe jest otrzymanie wyrównanego rozkładu temperatury na ruszcie kotła. Kod obliczeniowy działa w pętli - każdorazowo obliczone przez model temperatury porównywane są z wcześniej przeliczonymi przypadkami, poszukując rozkładu parametrów o najmniejszym błędzie *MSE* dla obliczonych temperatur  $T1 \div T12$ .

Ponieważ opracowany model do predykcji w teorii działał poprawnie, konieczne były testy ruchowe analizowanego kotła. Niestety nie jest to proste zadanie. Testy mogą być przeprowadzone w trakcie pracy kotła gdzie priorytetem jest utrzymanie bieżącej produkcji energii elektrycznej i cieplnej, zgodnie z zakontraktowanymi wielkościami. Do wykonania testów na obiekcie przymierzano się kilkakrotnie. Aby możliwe było ich wykonanie, konieczna była stabilna praca kotła, ponieważ wszystkie zmiany parametrów ruchowych musiały być wprowadzone ręcznie przez Operatora kotła.

W początkowej fazie testów zadano zmianę rozkładu węgla na poszczególne podajniki węgla - niestety testy nie zostały zrealizowane pomyślnie. Ręczna zmiana ilości paliwa dla każdego z 14 podajników, przy załączonym układzie regulacji okazała się niemożliwa. Zmiana ilości węgla na którymkolwiek z podajników skutkowałą zmianą sumarycznej ilości węgla (wyliczanego przez system regulacji na podstawie zaszytych logik producenta kotła) co prowadziło to korekty na pozostałych palnikach. Przyniosło to nawet efekt w postaci zablokowania jednego z podajników, który został zbyt mocno obciążony przez układ automatycznej regulacji. Po kilku nieudanych próbach zmiany ilości węgla na poszczególne podajniki dalsze testy ręcznej zmiany rozkładu węgla przerwano.

W kolejnej fazie testów zmiany parametrów ruchowych ograniczono do zmiany rozkładu powietrza wtórnego dostarczanego przez palniki olejowe kotła (OB). W tym przypadku nie było obaw, że przełączenie regulatorów powietrza wtórnego w tryb ręczny przyniesie efekt w postaci problemów eksploatacyjno-remontowych, w tym z ewentualnym zakłóceniem produkcji energii. Testy zrealizowano pomyślnie. Zebrane w trakcie testów dane potwierdziły, że zmiana rozkładu powietrza wtórnego wpływa na rozkład temperatury, ale co najbardziej cenne, że zmiana temperatury na ruszcie analizowanego kotła przebiega zgodnie z obliczeniami modelu predykcyjnego (Tab. 2.12,2.15).

W przyszłości, w przypadku wdrożenia koncepcji na analizowanym kotle fluidalnym i zautomatyzowaniu procesu zmiany parametrów, efekt zmiany temperatury będzie wielokrotnie większy, poprzez automatyczną zmianę rozkładu węgla dla poszczególnych podajników.

Po pomyślnych wynikach zrealizowanych testów, kolejnym krokiem była potwierdzenie, że wyrównanie rozkładu temperatury w przekroju poprzecznym kotła fluidalnego wpływa na intensywność erozji powierzchni ekranowych. Do wykonania obliczeń przepływowych wykorzystano stworzony w ramach projektu POIR.01.01.01-00-1253/19-00 mo-

delu cyfrowy analizowanego kotła fluidalnego. Korzystając z opracowanego modelu numerycznego CFD, wykonano obliczenia erozji powierzchni ścian komory paleniskowej dla różnych rozkładów węgla oraz powietrza dostarczanego do dolnej części komory paleniskowej kotła fluidalnego. Obliczenia powtórzono dla dwóch różnych stanów pracy kotła. Każdorazowo dla tej samej wydajności kotła wykonano obliczenia erozji dla trzech przypadków: dla ruchowych parametrów kotła oraz dla dwóch wariantów z zmienionym rozkładem węgla i powietrza wtórnego zgodnie z wartościami obliczonymi za pomocą modelu predykcyjnego.

Wyniki obliczeń numerycznych potwierdzają, że postawione na samym początku założenia, że na erozję powierzchni ogrzewalnych powyżej linii zakończenia obmurza duży wpływ mają parametry ruchowe kotła, w tym nierównomierny rozkład temperatury na ruszcie kotła.

Wyniki obliczeń dowodzą, że optymalizacja pracy kotła pod kątem wyrównania rozkładu temperatury wpływa na znaczące obniżenie występowania lokalnych obszarów o dużej erozji (Rys. 3.10,3.14). Wyniki obliczeń pozwalają wnioskować, że przedstawiona koncepcja jest jednym ze sposobów obniżenia erozji w analizowanym kotle fluidalnym, i przekłada się na zwiększenie dyspozycyjności analizowanego kotła.

Aktualnie rury ekranowe w analizowanych kotle zabezpieczone są powłokami odpornymi na erozję (do wysokości 7m powyżej odgięcia rur nad linią zakończenia obmurza). Wydłuża to możliwość bezpiecznej eksploatacji analizowanego kotła. Zaproponowana metoda jest metodą pierwotną, która umożliwia ograniczanie intensywności erozji w komorze paleniskowej, a zwłaszcza wyeliminowanie miejscowych obszarów o dużej erozji bez znaczących nakładów.

Dzięki temu, w co autor wierzy, po zaimplementowaniu do systemu sterowania kotłem stworzonego w ramach pracy narzędzia możliwe będzie wydłużenie bezpiecznej eksploatacji kotła (zwłaszcza w sezonie zimowym) oraz oszacowanie możliwego czasu eksploatacji na podstawie średniej wartości ubytku erozyjnego. Pozwoli to na prowadzenie odpowiedzialnej polityki remontowej, zabezpieczając jednocześnie interes ekonomiczny przedsiębiorstwa oraz potrzeby społeczne - niezakłócone dostawy energii cieplnej do okolicznych domostw.

## Bibliografia

- [1] Metrics and scoring: quantifying the quality of predictions, [dostęp:05.04.2022] <https://scikit-learn.org/stable/modules/modevaluation.html#mean-squared-error>.
- [2] PN-EN ISO 19809:2019-08 Badania nieniszczące - Ultradźwiękowe pomiary grubości. Polski Komitet Normalizacyjny 2019.
- [3] Decyzja Wykonawcza Komisji (UE) 2021/2326. Dziennik Urzędowy Unii Europejskiej 31 grudzień 2021.
- [4] Adamczyk W.: Modele przepływów wielofazowych z wykorzystaniem dostępnych technik obliczeniowych. Wydawnictwo Politechniki Śląskiej 2021.
- [5] Adamczyk W., Werle S., Ryfa A.: Application of the computational method for predicting NO<sub>x</sub> reduction within large scale coal-fired boiler. „Thermal Engineering”, 73, 2014, p. 343–350.
- [6] Adamczyk W., Kozolub P., Kruczek G., Pilorz M., Klimanek A., Czakiert T., Węcel G.: Numerical approach for modeling particle transport phenomena in a closed loop of a circulating fluidized bed. „Particuology”, 29, 2016, p. 69–79.
- [7] Adamczyk W., Myöhänen K., Hartge E.U., Ritvanen J., Klimanek A., Hyppänen T., Białecki R.: Generation of data sets for semi-empirical models of circulated fluidized bed boilers using hybrid euler-lagrange technique. „Energy”, 143, 2018, p. 219–240.
- [8] Adamczyk W.P.: Application of the Numerical Techniques for Modelling Fluidization Process Within Industrial Scale Boilers. „Archives of Computational Methods in Engineering”, 24, 2017, p. 669–702.
- [9] Andrews M., O'Rourke P.: The Multifluid Particle-in-Cell (MP-PIC) Method for dense particulate flows. „International Journal of Multiphase Flow”, 22(2), 1996, p. 379–402.
- [10] ANSYS, Inc.: ANSYS FLUENT 2020 (R2) Documentation 2011. Software documentation.
- [11] Arjunwadkar A., Basu P., Acharya B.: A review of some operation and maintenance issues of cfb boilers. „Applied Thermal Engineering”, 102, 2016, p. 672–694.

- [12] Basu P.: *Circulating Fluidized Bed Boilers*. Springer 2015.
- [13] Bis Z.: *Kotły fluidalne Teoria i praktyka*. Wydawnictwo Politechniki Częstochowskiej 2010.
- [14] Chapman S., Cowling T.: *The mathematical theory of non-uniform gases*. Cambridge Univ. Press, Cambridge, 3rd ed., 1970.
- [15] Diaz G., Sen M., Yang K., McClain R.: Dynamic prediction and control of heat exchangers using artificial neural networks. „*International Journal of Heat and Mass Transfer*”, 44, 2001, p. 1671–1679.
- [16] Finnie I.: Erosion of surfaces by solid particles. „*Wear*”, 3(2), 1960, p. 87–103.
- [17] Gidaspow D.: *Multiphase flow and fluidization*. Academic Press, Boston, MA 1994.
- [18] Gidaspow D., R. Bezburuah, J. Ding: Hydrodynamics of circulating fluidized beds, kinetic theory approach. „*In Fluidization VII, Proceedings of the 7th Engineering Foundation Conference on Fluidization*”, p. 75–82, 1992, p. 75–82.
- [19] Haugen K., Kvernfold ., Ronold A., Sandberg R.: Sand erosion of wear-resistant materials: Erosion in choke valves. „*Wear*”, 186-187, 1995, p. 179–188. 8th International Conference on Erosion by Liquid and Solid Impact.
- [20] Hernik B., Zabłocki W., Żelazko O., Latacz G.: Numerical research on the impact of changes in the configuration and the location of the over fire air nozzles on the combustion process in the ultra-supercritical BP 680 boiler. „*Process Safety and Environmental Protection*”, 125, 2019, p. 129–142.
- [21] Iliyas S., Elshafei M., Habib M., Adeniran A.: RBF neuralnetworkinferentialsensor-forprocess emission monitoring. „*Control EngineeringPractice*”, 21, 2013, p. 962–970.
- [22] Javaheria V., Portera D., Kuokkalab V.T.: Slurry erosion of steel – review of tests, mechanisms and materials. „*Wear*”, 408-409, 2018, p. 248–273. ], issn = , doi = <https://doi.org/10.1016/j.matpr.2021.03.441>,.
- [23] Jindal C., Sidhu B.S., Kumar P., Sidhu H.S.: Performance of hardfaced/heat treated materials under solid particle erosion: A systematic literature review. ], issn = , doi = <https://doi.org/10.1016/j.matpr.2021.03.441>,.
- [24] Lia K., Thompson S., Peng J.: Modelling and prediction of NO<sub>x</sub> emission in a coal-fired power generation plant. „*Control Engineering Practice*”, 12, 2004, p. 707–723.

- [25] Liu Q., Zhong W., Yu A.: Oxy-fuel combustion behaviors in a fluidized bed: A combined experimental and numerical study. „Powder Technology”, 349, 2019, p. 40–51.
- [26] Lun C., Savage S., Jeffrey D., Chepurnyi N.: Kinetic theories for granular flow: inelastic particles in couette flow and slightly inelastic particles in a general flow field. „Journal Fluid Mechanics”, 140, 1984, p. 223–256.
- [27] Lun C., Savage S., Jeffrey D., Chepurnyi N.: Kinetic theories for granular flow: inelastic particles in couette flow and slightly inelastic particles in a general flow field. „Journal Fluid Mechanics”, 140, 1984, p. 223–256.
- [28] Lv Y., Hong F., Yang T., Fang F., Liu J.: A dynamic model for the bed temperature prediction of circulating fluidized bed boilers based on least squares support vector machine with real operational data. „Energy”, 124, 2017, p. 284–294.
- [29] Lv Y., Liu J., Yang T., Zeng D.: A novel least squares support vector machine ensemble model for NOx emission prediction of a coal-fired boiler. „Energy”, 55, 2013, p. 319–329.
- [30] McCulloch W., Pitts W.: A logical calculus of the ideas immanent in nervous activity. „The bulletin of mathematical biophysics”, 5, 1943, p. 115–133.
- [31] Mirek P.: Ocena efektu modernizacji rusztu powietrza kotła CFB-1300. „Politechnika Częstochowska, Katedra Zaawansowanych Technologii Energetycznych”, 05.2020.
- [32] Muhammad A., Zhang N., Wang W.: Cfd simulations of a full-loop cfb reactor using coarse-grained eulerian–lagrangian dense discrete phase model: Effects of modeling parameters. „Powder Technology”, 354, 2019, p. 615–629.
- [33] Natale F.D., Nigro R.: An experimental procedure to estimate tube erosion rates in bubbling fluidised beds. „Powder Technology”, 287, 2016, p. 96–107.
- [34] Pearson K.: Mathematical Contributions to the Theory of Evolution. III. Regression, Heredity and Panmixia. Philosophical Transactions of the Royal Society of London 1896.
- [35] Raask E.: Tube erosion by ash impaction. „Wear”, 13(4), 1969, p. 301–315.
- [36] Romeo L., Garetta R.: Hybrid System for fouling control in biomass boilers. „Engineering Applications of Artificial Intelligence”, 19, 2006, p. 915–925.
- [37] Rosenblatt F.: The perceptron: A probabilistic model for information storage and organization in the brain. „Psychological Review”, 65, 1958, p. 386–408.



- [38] Schaeffer D.: Instability in the evolution equations describing incompressible granular flow. „J. Diff. Eq.”, 66, 1987, p. 19–55.
- [39] Si F., Romero C., Yao Z., Schuster E., Xu Z., Morey R., Liebowitz B.: Optimization of coal-fired boiler SCRs based on modified support vector machine models and genetic algorithms. „Fuel”, 88, 2009, p. 806–816.
- [40] Smrekar J., M.Assadi, M.Fast, I.Kustrin, S.Dec: Development of artificial neural network model for a coal-fired boiler using real plant data. „Energy”, 34, 2009, p. 144–152.
- [41] Smrekar J., Potocnik P., Senegacnik A.: Multi-step-ahead prediction of NOx emissions for a coal-based boiler. „Energy”, 106, 2013, p. 89–99.
- [42] Srekanth P., Syamlal M., O’Brien T.: Computational gas-solids flows and reacting systems: theory, methods and practice. Engineering science reference ed., 2012.
- [43] Szentannai P.: Mathematical modeling and model-based optimum control of circulating fluidized bed combustors. „periodica polytechnica”, 2011.
- [44] Tilly G.: Erosion caused by impact of solid particles, [in:] Scott D., (ed.), Wear, vol. 13 of Treatise on Materials Science Technology. Elsevier 1979, p. 287–319.
- [45] Vesilind P.: The rosin-rammler particle size distribution. „Resource Recovery and Conservation”, 5, 1980, p. 275–277.
- [46] Wang B.: Chromium–titanium carbide cermet coating for elevated temperature erosion protection in fluidized bed combustion boilers. „Wear”, 225-229, 1999, p. 502–509.
- [47] Xu M., Azevedo J.L.T.: Modeling of a front wall fired utility boiler for different operating conditions. „Computer Methods in Applied Mechanics and Engineering”, 190(28).
- [48] Zhang Y., Zhang M., Zhu S., Huang Y., Deng B., Gao X., Jiang X., Lyu J., Yang H.: Mechanism analysis of gas solid flow non-uniformity problem of 330 mw cfb boiler. „Chemical Engineering Research and Design”, 145, 2019, p. 258–267.

## Strony WWW

- [49] 7 Types of Activation Functions in Neural Network, [dostep:01.03.2022]  
<https://www.analyticssteps.com/blogs/7-types-activation-functions-neural-network>.

- 
- [50] A Complete Guide to Adam and RMSprop Optimizer, [dostęp:17.03.2022] [https://medium.com/analytics-vidhya/a-complete-guide-to-adam-and-rmsprop-optimizer-75f4502d83be: :text=RMSprop](https://medium.com/analytics-vidhya/a-complete-guide-to-adam-and-rmsprop-optimizer-75f4502d83be#:text=RMSprop)
- [51] Adam Optimization Algorithm, [dostęp:28.02.2022] <https://towardsdatascience.com/adam-optimization-algorithm-1cdc9b12724a>.
- [52] Adam Optimizer, [dostęp:28.02.2022] <https://keras.io/api/optimizers/adam/>.
- [53] Adam — latest trends in deep learning optimization, [dostęp:28.02.2022] <https://towardsdatascience.com/adam-latest-trends-in-deep-learning-optimization-6be9a291375c>.
- [54] ANSYS® ANSYS, [dostęp: 31.01.2022] <https://www.ansys.com>.
- [55] Batch normalization: Theory and how to use it with Tensorflow, [dostęp:01.03.2022] <https://towardsdatascience.com/batch-normalization-theory-and-how-to-use-it-with-tensorflow-1892ca0173ad>.
- [56] Choosing the right estimator, [dostęp:28.02.2022] <https://scikit-learn.org/stable/tutorial/machinelearningmap/index.html>.
- [57] Circulating Fluidized Bed (CFB) Boiler Tube Erosion, [dostęp:11.04.2022] <https://integratedglobal.com/industries/circulating-fluidized-bed-cfb-boiler-tube-erosion/>.
- [58] Colab, [dostęp:22.03.2022] <https://colab.research.google.com/notebooks/intro.ipynb>.
- [59] GE Digital, [dostęp:05.04.2022] <https://www.ge.com/digital/iiot-platform>.
- [60] Google AI, [dostęp:22.03.2022] <https://www.ai.google.com>.
- [61] IBM Maximo Application Suite, [dostęp:05.04.2022] <https://www.ibm.com/pl-pl/products/maximo>.
- [62] Machine learning articles, machine learning error bias variance and irreducible error with python, [dostęp:01.03.2022] <https://github.com/christianversloot/machine-learning-articles/blob/main/machine-learning-error-bias-variance-and-irreducible-error-with-python.md>.
- [63] Metrics and scoring: quantifying the quality of predictions, [dostęp:05.04.2022] <https://scikit-learn.org/stable/modules/modevaluation.html#mean-squared-error>.

- [64] Model Parameters and Hyperparameters in Machine Learning — What is the difference?, [dostęp:28.02.2022] <https://towardsdatascience.com/model-parameters-and-hyperparameters-in-machine-learning-what-is-the-difference-702d30970f6>.
- [65] NVidia, [dostęp:22.03.2022] <https://www.nvidia.com>.
- [66] Optimizers, [dostęp:22.03.2022] <https://keras.io/api/optimizers/available-optimizers>.
- [67] OPTUNA: A Flexible, Efficient and Scalable Hyperparameter Optimization Framework, [dostęp:23.03.2022] <https://towardsdatascience.com/optuna-a-flexible-efficient-and-scalable-hyperparameter-optimization-framework-d26bc7a23fff>.
- [68] Poznaj swojego Asystenta Google, [dostęp:05.04.2022] <https://assistant.google.com/intl/plpl/>.
- [69] Python Open Source, [dostęp:31.01.2022] <https://www.python.org>.
- [70] Sieci neuronowe, [dostęp:29.03.2022] <https://www.ibm.com/pl-pl/cloud/learn/neural-networks>.
- [71] Struktura produkcji energii elektrycznej, <https://www.rynekelektryczny.pl/produkcja-energii-elektrycznej-w-polsce/>.
- [72] Tensorflow, [dostęp:31.01.2022] <https://www.tensorflow.org>.
- [73] Train Test Split, [dostęp:28.02.2022] [https://scikit-learn.org/stable/modules/generated/sklearn.model\\_selection.train\\_test\\_split.html](https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.train_test_split.html).
- [74] Transformacja sektora elektroenergetycznego w Polsce Wydzielenie wytwórczych aktywów węglowych ze spółek z udziałem Skarbu Państwa, <https://www.gov.pl/web/aktywa-panstwowe/program-transformacji-sektora-elektroenergetycznego>.
- [75] Understanding Learning Rate in Machine Learning , [dostęp:01.03.2022] <https://www.mygreatlearning.com/blog/understanding-learning-rate-in-machine-learning/>.
- [76] Weight Initialization for Deep Learning Neural Networks, [dostęp:01.03.2022] <https://machinelearningmastery.com/weight-initialization-for-deep-learning-neural-networks/>.
- [77] Współczynnik determinacji R-kwadrat, [dostęp:05.04.2022] <https://www.naukowiec.org/wiedza/statystyka/wspolczynnik-determinacji736.html>.

- [78] Zielony Zwrot Taurona, <https://www.tauron.pl/tauron/o-tauronie/tauron-dla-otoczenia/zielony-zwrot>.
- [79] : Obwieszczenie Ministra Klimatu i Środowiska z dnia 2 marca 2021 r. w sprawie polityki energetycznej państwa do 2040 r. „Monitor Polski”, 264, 2021.

## A

# Kod źródłowy modelu do predykcji temperatury na ruszcie analizowanego kotła fluidalnego

Zaprezentowany kod posłużył do nauki modelu do predykcji temperatury T1÷T12 na ruszcie analizowanego kotła fluidalnego przy wykorzystaniu oprogramowania typu Open-Source *Python* [69].

```
1 # -*- coding: utf-8 -*-
2
3 #wczytanie bibliotek:
4 import numpy as np
5 from sklearn.model_selection import train_test_split
6 from sklearn.preprocessing import StandardScaler
7 from tensorflow import keras
8 from tensorflow.keras import regularizers
9 from tensorflow.keras.optimizers import Adam
10 from tensorflow.keras import backend as K
11 from tensorflow.keras.layers import (
12     Dense,
13     Dropout,
14     BatchNormalization)
15
16 class AIModelKeras(object):          #utworzenie klasy
17
18     def __init__(self):
19         print("AI models class...")
20
21     def ModelKeras(self,X,y,ProbeNumber,CountCol):
22
23         dataload = np.load('Dane.npz')
24         dataload.files
25         X_train = dataload['X_train']
26         X_validate = dataload['X_validate']
27
28 # hyperparametry sieci neuronowej:
29     optimizer = 'Adam(lr=lr)'
30     batch_size = 32
31     activation = 'tanh'
32     kernel = 'glorot_uniform'
33     bias = 'zeros'
```

```
34     unit = 128
35     lr = 0.001
36
37 # nauka 12 modeli do predykcji temperatury:
38 for i in range(12):
39     ScaleFactorMean = np.zeros((ProbeNumber, CountCol))
40     ScaleFactorSTD = np.zeros((ProbeNumber, CountCol))
41
42     y_train = dataload['y_train']
43     y_validate = dataload['y_validate']
44     y_train = y_train[:, i]
45     y_validate = y_validate[:, i]
46     sc = StandardScaler().fit(X_train)
47     X_train_std = sc.transform(X_train)
48     X_validate_std = sc.transform(X_validate)
49     ScaleFactorMean[i, :] = sc.mean_
50     ScaleFactorSTD[i, :] = sc.scale_
51     print(ScaleFactorMean)
52     print(ScaleFactorSTD)
53     print('Labels counts in y: {:d}'.format(np.size(y[:, 0])))
54     print('Labels counts in y_train: {:d}'.format(np.size(
y_train)))
55     print('Labels counts in y_validate: {:d}'.format(np.size(
y_validate)))
56
57     K.clear_session()
58
59     model = keras.models.Sequential(name="main")
60
61     model.add(
62         keras.layers.Dense(
63             units=unit,
64             input_shape=(np.size(X[0, :]),),
65             kernel_initializer=kernel,
66             bias_initializer=bias,
67             activation=activation,
68             name="input")
69
70     model.add(BatchNormalization())
71
72     model.add(
73         keras.layers.Dense(
74             units=unit,
75             kernel_initializer=kernel,
76             bias_initializer=bias,
77             activation=activation,
```

```
78         kernel_regularizer=regularizers.l2(0.001),
79         name="hidden1"))
80
81     model.add(
82         keras.layers.Dense(
83             units=unit,
84             kernel_initializer=kernel,
85             bias_initializer=bias,
86             activation=activation,
87             kernel_regularizer=regularizers.l2(0.001),
88             name="hidden2"))
89
90     model.add(
91         keras.layers.Dense(
92             units=unit,
93             kernel_initializer=kernel,
94             bias_initializer=bias,
95             activation=activation,
96             kernel_regularizer=regularizers.l2(0.001),
97             name="hidden3"))
98
99     model.add(
100         keras.layers.Dense(
101             units=unit,
102             kernel_initializer=kernel,
103             bias_initializer=bias,
104             activation=activation,
105             kernel_regularizer=regularizers.l2(0.001),
106             name="hidden4"))
107
108     model.add(
109         keras.layers.Dense(
110             units=1,
111             name="output"))
112
113     model.compile(optimizer=eval(optimizer),
114                 loss="mean_squared_error")
115
116     model.summary()
117
118     early_stopping = keras.callbacks.EarlyStopping(
119         monitor="val_loss",
120         min_delta=0.0001,
121         patience=50,
122         verbose=1,
123         mode="auto",
```

```
124         baseline=None,
125         restore_best_weights=False)
126
127         results = model.fit(X_train_std, y_train,
128                             validation_data=(X_validate_std,
y_validate),
129                                     epochs=500,
130                                     batch_size = batch_size,
131                                     verbose=1, callbacks=[early_stopping],
132                                     use_multiprocessing=True)
133
134         name = 'model_T'
135         FileName = name + str(i) + '.h5'
136 # zapis modelu do pliku:
137         model.save(FileName)
```



## B

# Kod źródłowy obliczający błąd średniokwadratowy rozkładu temperatury na ruszcie analizowanego kotła fluidalnego

Zaprezentowany kod posłużył do obliczenia wartości błędu średniokwadratowego rozkładu temperatury  $T1 \div T12$  na ruszcie analizowanego kotła fluidalnego dla zmienionego rozkładu paliwa i powietrza wtórnego przy wykorzystaniu oprogramowania typu Open-Source *Python* [69].

```
1 # -*- coding: utf-8 -*-
2
3 #wczytanie bibliotek:
4 import numpy as np
5 import pandas as pd
6 import random
7 import AlgorytmClass as AC          #klasa
8
9 Al = AC.AlgorytmZmiana()
10
11 pathModel = './model/'             #sciezka dostepu do modelu
12 modelName = 'model_T'              #nazwa modelu
13 xDCSName = 'xDCS.xlsx'             #dane wejsciowe z systemu
14 yDCSName = 'yDCS.xlsx'             #temperatura z systemu
15 labelBaseFile = 'labels.xlsx'      #plik z nazwami kolumn
16 row = 50                            #numer wiersz z wybranymi danymi do
    obliczen
17
18 Al.SetParameters(pathModel = pathModel,
19                  modelName = modelName,
20                  xDCSName = xDCSName,
21                  yDCSName = yDCSName,
22                  labelBaseFile = labelBaseFile,
23                  row = row)         #wczytanie danych do klasy
24 Al.StartInitialParameters()        #wczytanie modelu do obliczen
    temperatury
25
26 mse_min = 20                        #ustawiona wartosc bledu
    sredniokwadratowego
27 licznik = 0                          #wartosc licznika obliczen
```

```

28
29 while True:
30     try:
31         mse = Al.StartAlgorytm(licznik)           # obliczenie wartosci
MSE
32         licznik +=1                             # dla obliczonego
roz[U+FFFD]u temperatur
33         print('numer p[U+FFFD] ',licznik)
34         if (mse < mse_min) or licznik == 100:  #warunek zakonczenia
obliczen
35             break
36
37     except StopIteration:
38         break
39
40 wyniki = Al.ReturnTableScore()                 #wczytanie otrzymanych
wartosci

```



```

27         labelBaseFile,
28         row):                                     # wczytanie danych
29     self.pathModel = pathModel
30     self.modelName = modelName
31     self.xDCSName = xDCSName
32     self.yDCSName = yDCSName
33     self.row = row
34     self.labelBaseFile = labelBaseFile
35
36     def StartInitialParameters(self):             # inicjalizacja parametrow
37         self.LoadDataLabels()
38         self.LoadScaleFactors()
39         self.LoadModel()
40         self.LoadXYParameters()
41         self.CreateYPredTable()
42
43     def LoadDataLabels(self):                     # wczytanie z pliku
44     naglowkow kolumn dla danych
45         self.labelBase = labelBase = pd.read_excel(self.labelBaseFile)
46         labels = labelBase.columns.tolist()
47         self.Xlabels = labels[0:48]
48         self.ylabels = labels[48:60]
49
50     def LoadScaleFactors(self):                   # wczytanie danych do
51     standaryzacji
52         ReadFile = np.load(self.pathModel + 'ScaleFactors.npz')
53         self.ScaleFactorMean = ReadFile['SFM']
54         self.ScaleFactorSTD = ReadFile['SFS']
55
56     def LoadModel(self):                          # wczytanie modeli do
57     predykcji danych
58         loaded_model = []
59         for i in range(12):
60             FileName = self.pathModel + self.modelName + str(i) + '.h5'
61             print('loading: ', self.pathModel + self.modelName + str(i)
62 + '.h5')
63             model = load_model(FileName)
64             loaded_model.append(model)
65
66         self.loaded_model = loaded_model
67
68     def LoadXYParameters(self):                   # wczytanie danych
69     wej[U+FFFD]ciowych z DCS
70         File = self.pathModel + self.xDCSName
71         xDCS = pd.read_excel(File)
72         xDCS = xDCS.values

```

```

68     xDCS = xDCS[self.row,:]
69     Input0 = xDCS[0:2]
70     self.Input0 = Input0
71     Input2 =xDCS[16:26]
72     self.Input2 = Input2
73     Input4 =xDCS[36:48]
74     self.Input4 = Input4
75     File = self.pathModel + self.yDCSName
76     yDCS = pd.read_excel(File)
77     yDCS = yDCS.values
78     yDCS = yDCS[self.row,:]
79
80     self.xDCS = xDCS
81     self.yDCS = yDCS
82     self.SBair = xDCS[26:36] * 100
83     self.SBair = self.SBair.astype('int')
84     self.SBairGen = np.zeros(10)
85     self.Coal = xDCS[2:16] * 100
86     self.Coal = self.Coal.astype('int')
87     self.CoalGen = np.zeros(14)
88
89     def CreateYPredTable(self):                # utworzenie tablicy z
wynikami
90         self.yPred = np.zeros(np.size(self.yDCS))
91
92     def StartAlgorytm(self,count):            # uruchomienie obliczen
rozkladu temperatury
93         self.count = count
94         self.SetPredictionInputs()
95         self.TemperaturePrediction()
96         self.CalculateMse()
97         self.WriteTableScore(count)
98
99         return self.mse
100
101     def SetPredictionInputs(self):            # zmiana rozkladu paliwa
oraz powietrza wtornego
102         while True:
103             try:
104                 self.SetCoalGenerator()
105                 if np.sum(self.CoalGen) == np.sum(self.Coal):
106                     break
107             except StopIteration:
108                 break
109         Input1 = self.CoalGen
110         for i in range(14):

```

```

111         Input1[i] = Input1[i] / 100
112
113     while True:
114         try:
115             self.SetSBairGenerator()
116             if np.sum(self.SBairGen) == np.sum(self.SBair):
117                 break
118         except StopIteration:
119             break
120     Input3 = self.SBairGen
121     for i in range(10):
122         Input3[i] = Input3[i] / 100
123
124     Input = list(self.Input0) + list(Input1) + list(self.Input2) +
list(Input3)+ list(self.Input4)
125     self.Input3 = Input3
126     self.Input1 = Input1
127     self.Input = Input
128
129     def SetSBairGenerator(self):                # zmiana wartosci powietrza
wtornego
130         for i in range(10):
131             self.SBairGen[i] = random.randint(self.SBair[i] - 150, self.
SBair[i] + 150)
132
133     def SetCoalGenerator(self):                # zmiana wartosci paliwa
134         for i in range(14):
135             self.CoalGen[i] = random.randint(self.Coal[i] - 150, self.
Coal[i] + 150)
136
137     def TemperaturePrediction(self):          # obliczanie rozkladu
temperatury
138                                             # dla zmienionych danych
wejsciwych
139         for i,model in enumerate(self.loaded_model):
140             Input_std = (self.Input-self.ScaleFactorMean[i])/self.
ScaleFactorSTD[i]
141             self.yPred[i] = model.predict(np.reshape(Input_std,(1,-1)))
142             self.yPred = np.round(self.yPred,1)
143
144     def CalculateMse(self):                    # obliczenie bledu
sredniokwadratowego
145         mse_mean = np.zeros(12)
146         for i in range(12):
147             mse_mean[i] = np.mean(self.yPred)
148         mse = mean_squared_error(mse_mean,self.yPred)

```

```
149     self.mse = mse
150
151     return self.mse
152
153     def WriteTableScore(self, count):          # zapis wyników do tablicy
154         self.table_score.loc[count, 'temperatura'] = np.round(self.yPred
155         ,1)
156         self.table_score.loc[count, 'paliwo'] = np.round(self.CoalGen,2)
157         self.table_score.loc[count, 'powietrze'] = np.round(self.SBairGen
158         ,2)
159         self.table_score.loc[count, 'wejścia'] = np.round(self.Input,2)
160         self.table_score.loc[count, 'mean'] = np.round(np.mean(self.yPred
161         ),2)
162         self.table_score.loc[count, 'std'] = np.round(np.std(self.yPred)
163         ,2)
164         self.table_score.loc[count, 'mse'] = np.round(self.mse,2)
165
166     def ReturnTableScore(self):              # zwrot wyników
167         return self.table_score
```

# **OPTIMALIZACJA PRACY KOTŁA FLUIDALNEGO UWZGLĘDNIAJĄCA ZUŻYCIE EROZYJNE, ZWIĘKSZAJĄCA DYSPOZYCYJNOŚĆ JEDNOSTKI W ASPEKCIE UCIEPŁOWNIENIA BLOKU ENERGETYCZNEGO**

## **Streszczenie**

Energetyka w Polsce oparta jest o paliwa kopalne. Duży odsetek pracujących jednostek energetycznych to bloki energetyczne oddane do eksploatacji w ubiegłym wieku, których odbiega od nowoczesnych bloków węglowych oddanych do eksploatacji po 2000 roku. Wzrastające wymagania emisji zanieczyszczeń wobec energetyki konwencjonalnej, w tym ciągły wzrost ceny uprawnień do emisji CO<sub>2</sub>, sprawia, że kluczowa dla energetyki jest bieżąca eksploatacja nowoczesnych bloków a wysokiej sprawności wytwarzania energii elektrycznej.

Rozprawa dotyczy pracy jednego z najnowocześniejszych bloków energetycznych oddanych do eksploatacji w 2009 roku. W 2019 roku zmodernizowano turbozespół bloku energetycznego, umożliwiając oprócz produkcji energii elektrycznej równoczesną produkcję ciepła, które dostarczane jest do okolicznych mieszkańców. Wymusza to niezawodną pracę tej jednostki przez cały okres grzewczy, tak aby nie zakłócić dostaw energii cieplnej do okolicznych miast.

W rozprawie zaprezentowano nowatorskie podejście ograniczające zjawisko erozji powierzchni ogrzewalnych w kotłach fluidalnych. Wykorzystując nowoczesne techniki obliczeniowe, jakimi są uczenie maszynowe opracowano model sieci neuronowej, zdolnej do obliczenia temperatury na ruszcie kotła fluidalnego. Opracowany model predykcyjny umożliwia kontrolę temperatury na dnie dyszowym komory paleniskowej poprzez zmianę parametrów ruchowych kotła (paliwa i powietrza wtórnego). Algorytm umożliwia zmianę tych parametrów, bez zakłócenia wydajności analizowanego kotła fluidalnego, tak aby wyrównać temperaturę w przekroju poprzecznym komory paleniskowej.

Efektym wyrównania temperatury na ruszcie analizowanego kotła jest ograniczenie intensywności erozji rur ekranowych w najbardziej newralgicznym obszarze, powyżej linii zakończenia obmurza w leju komory paleniskowej. Rzeczywisty wpływ wyrównania temperatury, został sprawdzony przy wykorzystaniu modelowania numerycznego przyprływu wielofazowego.

Rozprawa prezentuje szczegółowy opis od opracowania właściwego modelu do predykcji temperatury i jego walidacji, poprzez zmianę parametrów ruchowych kotła aż do obliczenia erozji dla rzeczywistych przypadków ruchowych analizowanego kotła



---

fluidalnego. Zaprezentowana koncepcja może zostać stosunkowo łatwo zaimplementowana do systemu sterowania kotłem, bez znaczących nakładów finansowych.

# OPTIMIZATION OF THE FLUID BED BOILER OPERATED IN HEATING MODE TO INCREASE ITS AVAILABILITY BY TAKING INTO ACCOUNT THE EROSION PROCESS OF THE COMBUSTION CHAMBER

## Abstract

The power industry in Poland is based on fossil fuels. Most of them have been working since the last century, and their efficiency is much less than modern power units that were commissioned after the 2000 year. Still increasing requirements for emissions towards conventional power units, including the continuous increase in the price of CO<sub>2</sub> emission rights, make the operation of modern high-efficiency power units necessary.

The thesis concerns the operation of one of the most modern power units commissioned in 2009. In 2019, the turbine of the power unit was modernized, which made it possible to produce simultaneously heat and electricity. This modernization requires reliable operation throughout the entire heating period, so as not to disturb the heat supply to nearby cities.

The thesis presents an innovative approach to limiting the erosion of heating surfaces in fluidized bed boilers. Using modern computational techniques, such as machine learning, a neural network model was developed to calculate the temperature on the fluidized bed boiler grid. The developed predictive model makes it possible to control the temperature at the grid by changing the operating boiler parameters such as fuel and secondary air flow. The developed algorithm makes it possible to change these parameters without disturbing the fluidized bed boiler production to uniform the temperature in the cross-section of the furnace.

The uniform temperature on the grid reduces the erosion intensity of the water wall tubes in the most sensitive area, just above the refractory ends in the lower parts of the combustion chamber. The effect of temperature uniform on erosion intensity was verified using the numerical modeling technique.

The thesis presents a detailed description of the optimization from the development of the temperature prediction model and its validation, through changing the boiler operating parameters, to erosion calculation for the real operational of the analyzed fluidized bed boiler. The concept can be relatively easily implemented into the boiler control system, without large financial outlays.