



Konrad Gromaszek

Zaawansowane techniki sterowania procesem spalania pyłu węglowego

MONOGRAFIE

Lublin 2019

Zaawansowane techniki sterowania procesem spalania pyłu węglowego

Monografie – Politechnika Lubelska



Politechnika Lubelska
Wydział Elektrotechniki i Informatyki
ul. Nadbystrzycka 38A
20-618 Lublin

Konrad Gromaszek

Zaawansowane techniki sterowania procesem spalania pyłu węglowego



Wydawnictwo Politechniki Lubelskiej
Lublin 2019

Recenzent:

prof. dr hab. inż. Wojciech Mitkowski, Akademia Górniczo-Hutnicza

Publikacja wydana za zgodą Rektora Politechniki Lubelskiej

© Copyright by Politechnika Lubelska 2019

ISBN: 978-83-7947-359-5

Wydawca: Wydawnictwo Politechniki Lubelskiej

www.biblioteka.pollub.pl/wydawnictwa

ul. Nadbystrzycka 36C, 20-618 Lublin

tel. (81) 538-46-59

Druk: TOP Agencja Reklamowa Agnieszka Łuczak

www.agencjatorp.pl

Elektroniczna wersja książki dostępna w Bibliotece Cyfrowej PL www.bc.pollub.pl

Nakład: 50 egz.

Spis treści

1. Wstęp	11
2. Stan wiedzy w dyscyplinie sterowania złożonymi procesami przemysłowymi	15
2.1 Klasyczne techniki projektowania regulatorów	16
2.2 Nowoczesne techniki sterowania i regulacji automatycznej	18
2.3 Sterowanie predykcyjne z modelem	20
2.4 Niepewność układu sterowania	23
2.5 Studium przypadku na przykładzie procesu spalania w kotle węglowym	24
3. Spalanie w energetyce	29
3.1 Charakterystyka procesu spalania	29
3.2 Stechiometria procesów spalania paliw	32
3.3 Spalanie w kotłach pyłowych	39
3.4 Prawa fizyczne w procesach elektrociepłowni na paliwa kopalne	41
3.5 Bilans cieplny	45
3.6 Bilans masy	47
4. Spalanie w kotłach pyłowych	51
5. Modelowanie i symulacja elementów instalacji współspalania pyłu węglowego i biomasy	61
5.1 Opracowanie modelu sterowania kotłem	62
5.2 Modelowanie komory spalania	65
6. Wykorzystanie sztucznych sieci neuronowych oraz głębokich sieci neuronowych w modelowaniu procesu spalania	67
6.1 Sztuczne sieci neuronowe	67
6.2 Głębokie uczenie	69
7. Suboptymalna struktura sterowania obiektem złożonym (na przykładzie procesu spalania)	81
7.1 Proekologiczne sterowanie procesem spalania pyłu węglowego	82
7.2 Stanowisko badawcze	82
7.3 Wykorzystanie przetwarzania obrazu w procesie spalania pyłu węglowego i biomasy	84

7.4 Diagnostyka procesu spalania z użyciem metod optycznych oraz sztucznej inteligencji	86
8. Sterowanie kotłem pyłowym z wykorzystaniem asymetrycznych sztucznych sieci neuronowych.....	95
8.1 Koncepcja modelowania spalania w kotle węglowym z wykorzystaniem asymetrycznej SSN.....	97
8.2 Zastosowanie asymetrycznej SSN do optymalnego sterowania kotłem pyłowym.....	100
9. Odporne sterowanie adaptacyjne procesem współspalania biomasy.....	103
9.1 Modele procesu, niepewność i sterowanie odporne	104
9.2 Odporne sterowanie współspalaniem węgla z biomasą	108
10. Zastosowanie hybrydowych struktur sieci neuronowych do modelowania i sterowania procesem spalania pyłu węglowego.....	119
10.1 Hybrydowy model EWT-LSTM-RELM-IEWT	123
10.2 Struktura długiej pamięci krótkotrwałej (LSTM)	126
10.3 Algorytm RELM	127
11. Podsumowanie	131
Literatura.....	135

Oznaczenia i akronimy

- $x, y, u, \dots$ – zmienne (także stałe) skalarne lub wektorowe
 $n_x, n_y, n_u, \dots$ – wymiary wektorów, np. $n_x = \dim x$
 $\mathbf{A}, \mathbf{B}, \mathbf{K}, \dots$ – macierze rzeczywiste lub wektorowe
 $x^T, \mathbf{A}^T, \dots$ – transpozycja wektora x , transpozycja macierzy $\mathbf{A}$
 $g(\cdot)$ – funkcje skalarne lub wektorowe
 $g'(x)$ – pochodna funkcji g w punkcie x , gdzie:

$$\left\{ \begin{array}{l} \text{dla } g: \mathbb{R}^n \rightarrow \mathbb{R}, g'(x) = \left[\frac{\partial g_1(x)}{\partial x_1} \dots \frac{\partial g_1(x)}{\partial x_n} \right] \\ \text{dla } g: \mathbb{R}^n \rightarrow \mathbb{R}^m, g'(x) = \begin{bmatrix} \frac{\partial g_1(x)}{\partial x_1} & \dots & \frac{\partial g_1(x)}{\partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial g_m(x)}{\partial x_1} & \dots & \frac{\partial g_m(x)}{\partial x_n} \end{bmatrix} \end{array} \right.$$

- $x, y, u, \dots$ – zmienne (także stałe) skalarne lub wektorowe

Akronimy

- ANN – Artificial Neural Networks
 ARMAX – Auto-Regressive Moving Average with eXogenous input
 ARX – Auto-Regressive with eXogenous input
 BFGSNN – Broyden Fletcher Gold-farb Shanno Neural Network
 BM – Boltzmann Machine
 BMS – Burner Management System
 BPCS – Basic Process Control System,
 BPNN – Back Propagation Neural Network
 BPTT – Backpropagation through time
 CCS – Coordinated Control System
 CFD – Computational Fluid Dynamics
 CGA – Conventional Genetic Algorithm
 CNN – Convolutional Neural Network
 COA – Crisscross Optimization Algorithm
 DARE – Discrete-Time Algebraic Riccati Equation
 DBN – Deep Belief Networks
 DCS – Distributed Control System

DL	– Deep Learning
DMC	– Dynamic Matrix Control
DMP	– Deep Multilayer Perceptrons
DNN	– Deep Neural Networks
DSN	– Deep Stacking Networks
EA	– Evolutional Algorithms
EEMD	– Ensemble Empirical Mode Decomposition
ELM	– Extreme Learning Machine
ENN	– Elmann Neural Network
FD	– Forced Draft fan
FFBPNN	– Feed Forward Back Propagation Neural Network
GARCH	– Generalized Auto Regressive Conditionally Heteroscedastic
GP	– Genetic Programming
GPC	– Generalized Predictive Control
GRNN	– Generalized Regression Neural Network
i.i.d.	– independent and identically distributed
ID	– Inducted Draft fan
IoT	– Internet of Things
LMI	– Linear Matrix Inequalities
LQG	– Linear Quadratic Gaussian
LQR	– Linear Quadratic Regulator
LSTM	– Long Short-Term Memory
LSVM	– Least Square Support Vector Machine
LTI	– Linear Time Invariant
MAE	– Mean Absolute Error
MAPE	– Mean Absolute Percentage Error
MFA	– Mamdani Fuzzy Approximation
MIMO	– Multi-Input Multi-Output
MLP	– Multi Layer Perceptron
MPC	– Model Predictive Control
MPCS	– Model Predictive Control with State Equations
MU	– Multiplicative Units
NARX	– Nonlinear Auto-Regressive with eXogenous input
OCF	– Optimal Control Problem
OFA	– OverFire Air
PCA	– Principal Component Analysis
PID	– Proportional-Integral-Derivative

PLC	– Programmable Logic Controller
QDMC	– Quadratic Dynamic Matrix Control
QGA	– Quantum Genetic Algorithm
QP	– Quadratic Programming
RAC	– Robust Adaptive Control
RAS	– Robustly Asymptotically Stabilizable
RBF	– Radial Basis Function
RBM	– Restricted Boltzmann Machine
RCLF	– Robust Control Lyapunov Function
RELM	– Regularized Extreme Learning Machine
RGUAS	– Robustly Globally Uniformly Asymptotically Stabilizable
RMSE	– Root Mean Square Error
RTRL	– Real-Time Recurrent Learning
SA	– Simulated Annealing
SAGA	– Simulated Annealing Genetic Algorithm
SCADA	– Supervisory Control And Data Acquisition
SCR	– Selective Catalytic Reduction
SDE	– Standard Deviation of Error
SISO	– Single-Input Single-Output
SMPC	– Stochastic Model Predictive Control
SSA	– Singular Spectrum Analysis
SVM	– Support Vector Machine
SVR	– Support Vector Regression,
TSFA	– Takagi-Sugeno Fuzzy Approximator
VMD	– Variational Mode Decomposition
WPD	– Wavelet Packet Decomposition
WT	– Wavelet Transform

Wstęp

Energia jest niezbędna ludziom dla zaspokajania ich potrzeb bytowych, przy produkcji dóbr materialnych oraz świadczeniu różnego typu usług. Używa się jej pod różnymi postaciami. Energię, jej nośniki i źródła rozróżnia się, stosując odpowiednie kryteria klasyfikacji.

Spalanie paliw kopalnych stanowi najważniejsze źródło energii wykorzystywane przez człowieka. Biorąc pod uwagę efekt skali, ze względu na emisję do atmosfery dużych ilości gazów spalinowych i pyłu prowadzi to do postępującego zanieczyszczenia środowiska [119]. Z jednej strony światowe trendy dążą do zmniejszenia emisji dwutlenku siarki i tlenków azotu. Z drugiej zaś strony, zakłada się, że w horyzoncie najbliższych dekad, węgiel i inne paliwa kopalne nadal będzie mieć pozycję dominującą.

Liczne eksperymenty i analizy procesu spalania doprowadziły do rozwoju nowych technologii, które są kompromisem pomiędzy kosztami realizacji oraz efektywnością. Większość rozwiązań przyjmuje formę innowacji produktowej, w postaci odpowiedniej konstrukcji palników oraz modernizacji elementów składowych obiektów wytwarzania energii. Ważny obszar zwiększenia efektywności obiektów energetyki zawodowej stanowi możliwość użycia zaawansowanych metod diagnostyki i sterowania.

W skali przemysłowej, proces spalania pyłu węglowego występuje przede wszystkim w kotłach energetycznych. Jest on optymalizowany w celu uzyskania pożądanego celu sterowania. Ze względu na zmienność warunków pracy kotła, duże opóźnienia i trudności w pomiarach parametrów procesu, diagnostyka i sterowanie takim obiektem staje się zagadnieniem bardzo złożonym.

Procesowi spalania, który w istocie jest przebiegającą w gwałtowny sposób reakcją utleniania, towarzyszy wydzielanie ciepła i światła. Jest on skojarzony ze zjawiskami transportu reagentów i produktów. Obserwowalną strefą, gdzie zachodzą wspomniane zjawiska, określa się płomieniem, który może być wykorzystywany jako bezpośrednie źródło informacji o procesie spalania.

Zauważalny jest brak dostępnych metod szybkiego pomiaru parametrów procesu spalania, świadczących o jakości jego przebiegu. Akceptowalne opóźnienia wnoszą metody akustyczne lub optyczne. Ze względu na ich nieinwazyjność, pojawia się możliwość uzyskania dodatkowej, praktycznie nieopóźnionej, przestrzennie selektywnej informacji o procesie spalania. Głównym problemem podczas eksploatacji czujników optycznych jest możliwość zanieczyszczenia układu optycznego. Niezbędny zatem jest taki dobór konstrukcji urządzenia optycznego do odbierania sygnału pochodzącego z płomienia, aby zminimalizować ryzyko zabrudzenia [55, 245, 249]. Poza problemami, takimi jak zanieczyszczenie układu optycznego, powodujące spadek mocy docierającej do fotodetektora, krytyczne znaczenie mają zakłócenia, pochodzące od sąsiednich palników oraz wpływ promieniowania ścian komory spalania. Większość obecnych rozwiązań wykorzystuje informację związaną z fluktuacjami jasności płomieni. Jest to analiza w czasie i przestrzeni składowej zmiennej sygnału

uzyskanej z fotodetektora. W tym celu wykorzystuje się częstotliwościowe i czasowo-częstotliwościowe metody analizy sygnałów, tj.: transformatę Fouriera, krótkoczasową transformatę Fouriera, transformatę falkową, metody prognozowania szeregów czasowych [9]. Pozwala to na zaawansowaną analizę procesu spalania. Uwzględnienie informacji przestrzennej pozwala nie tylko na wykrywanie zaniku płomienia [84], ale także do detekcji zmian przebiegu procesu spalania w obrębie pojedynczego palnika. Jest to szczególnie ważne ze względu na optymalizację procesu w obrębie całego kotła.

Normy emisji gazów cieplarnianych powodują konieczność zmian obecnie używanych systemów sterowania. Stosowane systemy diagnostyczne muszą być uzupełnione o skuteczne pozyskiwanie takich informacji. Potrzeba zapewnienia niniejszych surowych wymagań doprowadziła do powstania wielu programów badawczych, realizowanych na świecie. Podczas opracowywania skutecznego układu sterowania procesem spalania należy wziąć pod uwagę nie tylko koszty procesu, ale także koszty związane z emisją zanieczyszczeń. Wymaga to zastosowania nowoczesnych rozwiązań technicznych, które utrzymują w optymalnych warunkach procesy spalania, w tym także, w szczególności algorytmy sztucznej inteligencji oraz systemy eksperckie [199]. Klasyczne sieci neuronowe zostały wykorzystane do monitorowania emisji kotłów [4, 5, 219, 246], jak również do prognozowania emisji gazów cieplarnianych.

Zagadnienie sterowania złożonymi procesami często opisuje się w kontekście odpowiednich warstw modelu hierarchicznego [106, 223]. Na najniższej z nich znajduje się sam proces. Zrozumienie mechanizmów przebiegu procesu ma fundamentalne znaczenie dla opracowania dobrego sterowania. O ile inżynier automatyk, zajmujący się sterowaniem nie potrzebuje poziomu wiedzy projektanta procesów, to znajomość sposobu funkcjonowania danego procesu, jego kluczowych celów operacyjnych i podstawowych wskaźników ekonomicznych wydają się być znaczące. W jednej z kluczowych dziedzin, jego wiedza musi przewyższać umiejętności inżyniera procesu, który przede wszystkim potrzebuje zrozumienia zachowań stacjonarnych, określanych jako stany ustalone (ang. *steady states*). Inżynier automatyk musi ponadto rozumieć dynamikę procesu (ang. *process dynamics*). Kolejny obszar stanowi poziom oprzyrządowania (ang. *instrumentation layer*), uwzględniający urządzenia pomiarowe, zawory regulacyjne oraz inne akulatory. Warstwa ta stanowi domenę techników oraz inżynierów oprzyrządowania. Jednak inżynier automatyk powinien także znać funkcjonowanie oprzyrządowania, głównie związanego ze sterowaniem, tak aby rozpoznać problem wynikający z pomiaru, czy nieprawidłowo pracującego urządzenia wykonawczego (np. zaworu). Niezwykle ważna jest tu umiejętność diagnozowania problemów i świadomość dokładności, jak i dynamicznego zachowania poszczególnych urządzeń instalacji. Powyżej obszaru oprzyrządowania znajduje się poziom rozproszonego systemu sterowania (DCS, ang. *distributed control system*)

Praca niniejsza obejmuje rozwiązania, które znalazły już potwierdzenie podczas wykonanych eksperymentów i symulacji. Znaczna część wyników pomiarów, weryfikujących zastosowane metody, zostały przedstawione po raz pierwszy.

Głównym celem pracy jest dokonanie analizy uwarunkowań oraz opracowanie algorytmu sterowania kotłem pyłowym, wykorzystującego współspalanie biomasy. Cel ten zostanie osiągnięty poprzez realizację i symulacyjną weryfikację zaproponowanych algorytmów.

Zastosowanie wszystkich wymienionych elementów umożliwia bowiem zwiększenie efektywności spalania, przy jednoczesnym zachowaniu narzuconych wymogów ekonomiczno-ekologicznych. Prezentowane w pracy algorytmy adaptacyjne, sztuczne sieci neuronowe oraz głębokie, jak i próba hybrydyzacji wskazanych metod, przybliżają do osiągnięcia postawionego celu.

Praca niniejsza składa się z jedenastu rozdziałów, z których pierwszy stanowi wstęp. W kolejnym rozdziale zaprezentowano stan wiedzy w dyscyplinie sterowania złożonymi procesami przemysłowymi. Rozdział trzeci pracy, charakteryzuje proces spalania w energetyce ze szczególnym uwzględnieniem specyfiki paliwa, jakim jest węgiel kamienny. W rozdziale czwartym omówiono spalanie w kotłach pyłowych. Rozdział piąty przedstawia modelowanie i symulację podsystemów układu energetyki wykorzystującego współspalanie pyłu węglowego i biomasy.

W rozdziale szóstym omówiono wykorzystanie sztucznych sieci neuronowych oraz głębokich sieci neuronowych w modelowaniu procesu spalania. Rozdział siódmy omawia suboptymalną strukturę sterowania spalaniem w kotle energetycznym. W rozdziale ósmym użyto asymetryczne sztuczne sieci neuronowe. Sterowanie odporne omówiono w rozdziale dziewiątym. Rozdział dziesiąty to zastosowanie hybrydowych struktur sieci neuronowych do modelowania i sterowania procesem spalania pyłu węglowego. Pracę zamyka podsumowanie.

2. Stan wiedzy w dyscyplinie sterowania złożonymi procesami przemysłowymi

Na podstawie [14, 15, 17, 20, 102, 160] historia automatyki dzielona jest na następujące okresy: wczesny okres (do 1900 roku), okres przedklasyczny (1900–1940), okres klasyczny (1935–1960) i okres nowoczesny (po 1955 roku). Urządzenia zawierające mechanizmy sterujące zdarzało się ludziom konstruować nawet w bardzo odległych czasach. Potrzeba konstruowania takich rozwiązań nasiliła się z nadejściem rewolucji przemysłowej i dalszym rozwojem techniki w XX wieku. Początkowo były to projekty bazujące na doświadczeniu i intuicji inżynierskiej. Jednak z czasem, znaczenia nabrały analizy teoretyczne, które nie były powszechnie znane, mimo swych początków już w XIX wieku. Z czasem wypracowano szereg klasycznych metod projektowania układów regulacji, które od około 1960 roku były uzupełniane i częściowo wypierane przez nowoczesną teorię sterowania. Nieocenioną podporą teorii z tego zakresu stała się, rozwijana równolegle technika komputerowa, na początku analogowa, a następnie cyfrowa.

W XIX wieku, podczas rewolucji przemysłowej w Wielkiej Brytanii, opracowano technologie mechanizacji produkcji tekstyliów i narzędzi oraz innych przedmiotów. Przemysł stał się ważnym społecznie sektorem. Procesy produkcji i transportu stopniowo wykonywane były przez maszyny. Jako technologie przemysłowe rozwijane były sterowanie procesów przemysłowych i automatyzacja, określane anglojęzycznym terminem – *Industrial Control and Automation*. W latach osiemdziesiątych ubiegłego wieku, przemysłowe systemy sterowania obejmowały jedynie systemy nadzoru i gromadzenia danych (ang. *Supervisory Control And Data Acquisition*, SCADA) oraz programowalne sterowniki logiczne (ang. *Programmable Logic Controller*, PLC). W miarę rozwoju mikroprocesorów i programowalnych układów scalonych w latach dziewięćdziesiątych do przemysłowych systemów sterowania zaczęto wprowadzać komputery. *Skomputeryzowane systemy sterowania* są szybkie i wydajne, a tym samym posiadają coraz więcej zastosowań w wielu gałęziach przemysłu, takich jak energetyka, wodociągi, przemysł naftowy i gazowniczy, chemiczny, transport i produkcja. *Skomputeryzowane systemy sterowania* różnią się od komputerowych systemów sterowania. W komputerowym systemie sterowania komputer bierze udział w nadzorze niezależnym od kontrolowanych obiektów. W przeciwieństwie do tego skomputeryzowany system sterowania obejmuje sprzęt i oprogramowanie do kontrolowanego układu, tworząc jednolity system. W celu różnicowania, w skomputeryzowanych systemach sterowania stosuje się termin „wbudowana kontrola” (ang. *embedded control*).

Istnieją dwa ważne typy systemów wbudowanych, obejmując sterowanie w czasie rzeczywistym (ang. *real-time control*) i sterowanie rozproszone (ang. *distributed control*). Rozszerzyły one znacząco zakres zastosowania sterowania w przemyśle. Obecnie sterowanie w czasie rzeczywistym i rozproszone stały się dominującą koncepcją kontroli i ważnym elementem

szerokiej gamy systemów, od przyrządów medycznych w szpitalach po systemy satelitarne.

Najnowsze trendy dodatkowo obejmują:

- zastosowania sztucznych sieci neuronowych, bazujących na dostępie do bardzo dużych zbiorów danych tzw. Big Data, realizowane w formie metod tzw. głębokiego uczenia (ang. *deep learning*).
- wykorzystanie powszechności dostępu do sieci Internet przyniosło rozwiązania określane zbiorczo Internetem rzeczy (ang. *Internet of Things, IoT*), który w zastosowaniach przemysłowych posiada zbiorczą nazwę Przemysł 4.0 (ang. *Industry 4.0*), jako następstwo czwartej rewolucji przemysłowej (po jego elektryfikacji, mechanizacji i automatyzacji).
- dążenie do tworzenia bezobsługowych systemów i całych linii produkcyjnych, bazujących na założeniach Przemysłu 4.0 (ang. *Industry 4.0*), przejawia się we wdrażaniu rozwiązań nazywanych „Cyfrowym bliźniakiem” (ang. *Digital Tween*). Polegają one na opracowaniu cyfrowych modeli układów, np. linii produkcyjnych za pomocą narzędzi CAD/CAM, pozwalających na optymalizację, szczegółową diagnostykę i analizę utrzymania ruchu.
- użycie metod rozszerzonej rzeczywistości (ang. *Augmented Reality*) wraz z rozwiązaniami Digital Tween, to kolejny krok w kierunku autonomicznych układów przemysłowych z precyzyjnym dostępem do aktualnego stanu układu, wraz z możliwością jego szybkiej korekty lub naprawy w zdalny sposób.
- zastosowanie zrównoważonej gospodarki zasobami, stanowi o możliwościach zarządzania i sterowania małoseryjną produkcją wszelkich dóbr, dopasowanych do indywidualnych potrzeb klienta z uwzględnieniem cyklu odzyskiwania zasobów (ang. *recycling*), przy zachowaniu ich bardzo wysokiej jakości i krótkim czasie wytwarzania.

Syntetyczny przegląd stanu wiedzy na temat nowoczesnych metod sterowania zamieszczono w kolejnych podrozdziałach.

2.1. Klasyczne techniki projektowania regulatorów

Uogólniając, istnieją dwa zasadnicze sposoby sterowania: sterowanie w układzie otwartym i sterowanie w układzie zamkniętym (czyli w układzie ze sprzężeniem zwrotnym). Regulacja oznacza drugi z wymienionych sposobów, jest więc pojęciem węższym od pojęcia sterowania. W celu otrzymania tzw. zamkniętego układu sterowania, czyli układu regulacji, należy zamknąć pętlę oddziaływań, tzn. uzależnić sterowanie od skutków, jakie to sterowanie wywołuje. Połączenie wielkości regulowanej, zamykające pętlę regulacji, nazywa się sprzężeniem zwrotnym. Wprowadzenie sygnału reprezentującego wielkość regulowaną do urządzenia sterującego zmniejsza zależność obiektu od zakłóceń, ponieważ kontrola skutków sterowania umożliwia bieżące korygowanie tego sterowania. Jest to podstawowa zaleta regulacji – możliwość osiągnięcia właściwego celu mimo oddziaływania zakłóceń. Stąd, potrzebne jest porówny-

wanie postawionego celu z aktualnie obserwowanym wynikiem sterowania i przystosowanie tego sterowania do ewentualnie dostrzeżonych odchyłń realizacji celu.

Chociaż regulacja nie musi być automatyczna, to większość układów koncentruje się na niej. W układzie automatycznej regulacji (UAR), operacje wykonuje samoczynnie regulator, czyli urządzenie sterujące obiektem na podstawie danych pomiarowych pobieranych z odpowiednich czujników zainstalowanych w obiekcie. Regulator powinien również otrzymać sygnał reprezentujący cel sterowania, jak np. wartość temperatury, która ma być utrzymywana w kotle.

Klasyczne techniki projektowania regulatorów obejmują:

- użycie członów korekcyjnych pierwszego rzędu,
- metodę przesuwania biegunów (ang. *pole placement / shifting*),
- metodę kryterium liniowo-kwadratowym (LQ) i kryterium H_2 ,
- metodę wielomianową.

Projektowanie przy użyciu członów korekcyjnych pierwszego rzędu obejmuje opracowanie modelu układu zamkniętego i modelu układu otwartego, do których odnosiły się te projekty. Ze względu na fakt, że metoda ta nie gwarantuje odporności układu na nieuniknione niedokładności obiektu nominalnego, dlatego wymaga przeprowadzenia wielu badań symulacyjnych, potwierdzających jej przydatność w konkretnym projekcie.

Metoda przesuwania biegunów, pozwala na umieszczenie biegunów układu zamkniętego w dowolnych punktach lewej półpłaszczyzny zmiennej zespolonej s oraz znalezienie odpowiedniej macierzy sprzężenia zwrotnego, używając formuły Ackermanna [162]. Przesunięcie biegunów odbywa się kosztem energii sterowania, dostarczanej przez sygnał sterujący. Niekiedy koszt (wielkość) sygnału sterującego jest zbyt duży, aby mógł być zaakceptowany, dlatego rozwinięciem metody jest wprowadzenie tzw. obserwatora stanu obiektu. Zakładając regulator $u = K \cdot x$, przy czym x nie jest wielkością mierzoną, dlatego buduje się obserwator (np. Luenbergera), który na podstawie pomiaru u i y generuje estymatę stanu z dążącą do x przy czasie t zmierzającym do nieskończoności; $\lim_{t \rightarrow \infty} (z \rightarrow x)$.

W przypadku projektowania regulatorów metodą z kwadratowym wskaźnikiem jakości (LQ) poszukiwane jest minimum funkcyjonału kwadratowego przy opisie w przestrzeni stanów za pomocą równań liniowych. Stała się ona wyjściem dla metody LQG (ang. *linear quadratic gaussian*), uwzględniającej macierze wariancji zakłóceń działających na obiekt, pozwalającej na synteze regulatorów dla sygnałów stochastycznych. Następnym rozwojem metody jest podejście do opisu zakłóceń z wykorzystaniem minimalizacji normy H_2 . Przez odpowiednie filtrowanie sygnału (w ogólności: wektora sygnałów) definiującego normę H_2 , projektant może osiągnąć żądane właściwości układu zamkniętego.

Metoda wielomianowa polega na rozwiązywaniu równania, w którym wielkościami znanymi oraz wielkościami poszukiwanymi są wielomiany zmiennej s (w dziedzinie ciągłej) lub zmiennej z (w dziedzinie dyskretniej). Jest ona rozszerzalna na układy wielowymiarowe (ang. *multiple inputs multiple outputs*, MIMO) i posiada wiele modyfikacji.

2.2. Nowoczesne techniki sterowania i regulacji automatycznej

Ze względu na fakt, że nowoczesne obiekty sterowania, z wieloma wejściami i wyjściami stawały się coraz bardziej złożone, to ich opis wymagał coraz większej liczby równań. Klasyczna teoria sterowania, która stosuje tylko modele z jednym wejściem i wyjściem, stała się bezsilna przy podejściu do układów o wielu wejściach i wyjściach (MIMO).

Lata 60. XX przyniosły rozwój nowoczesnej teorii sterowania, umożliwiającą poradzenie sobie ze wzmagającą się złożonością nowoczesnych obiektów i dużych wymagań w zakresie dokładności, wagi czy kosztów, zarówno w zastosowaniach wojskowych, kosmicznych czy przemysłowych. Pomimo wielu zalet, nowoczesna teoria sterowania wykazywała jednak pewne braki. Gwarancja odpowiedniego działania, otrzymywana przy rozwiązywaniu równań macierzowych, oznaczała, że często można było zaprojektować system sterowania, który działa w tylko teorii. Ponadto, projektant pozbawiony był intuicyjnego wglądu w problem sterowania, z jakim pracował. W przypadku metod częstotliwościowych klasycznej teorii sterowania, często bazowały one na inżynierskiej intuicji. Kolejny problemem jaki towarzyszył nowoczesnemu projektowaniu układów regulacji polegał na braku jakiegokolwiek kompensacji dynamiki. Narażało to nowoczesnie zaprojektowany system na brak odporności w przypadku działania zakłóceń, wystąpienia nagłej dynamiki (nieuwzględnionej w modelu) czy wystąpienia szumu pomiarowego. Warto zaznaczyć, że określanie odporności jest naturalnym elementem metod częstotliwościowych, które posługują się takimi pojęciami, jak zapas amplitudy i zapas fazy.

Propagatorem wykorzystywania metod klasycznych w układach wielowymiarowych był Isaac M. Horowitz. Jego ilościowa teoria sprzężenia zwrotnego pozwoliła na projektowanie układów odpornych z użyciem wykresów Nicholasa. W 1981 roku ukazały się artykuły [42, 43, 196], których autorami byli Doyle, Stein oraz Safonov, Laub i Hartmann. Stanowią one rozszerzenie pracy [182] i ukazują istotność wykresów wartości osobliwych względem częstotliwości przy projektowaniu odpornych układów wielowymiarowych. Umożliwiły one projektowanie za pomocą metod nowoczesnej teorii sterowania przy użyciu wielu klasycznych metod w dziedzinie częstotliwości. Podejście takie badane było w kontekście sterowania samolotami i procesami przemysłowymi przez Athansa [146, 243] i innych teoretyków. W wyniku fuzji powstała nowa teoria sterowania, która łączy zalety metod klasycznych z najlepszymi własnościami metod nowoczesnych. Przegląd nowoczesnych metod projektowania układów odpornych przedstawił Dorato w pracy [41].

Fundamentalne prace z zakresu teorii sterowania optymalnego powstały w latach 50. i 60. XX wieku. Natomiast w latach 70. i 80. XX nastąpił dalszy rozwój teorii w zakresie sterowania stochastycznego, odpornego i adaptacyjnego. Jest to okres opracowania i rozwoju teorii sterowania predykcyjnego.

Zasadniczą własnością odróżniającą algorytmy sterowania predykcyjnego (występującego w literaturze także jako regulacja predykcyjna) od innych, tradycyjnych metod (częstotliwościowych czy zmiennych stanu) jest możliwość uwzględnienia ograniczeń nałożonych na wielkości sterowane i sterujące w trakcie projektowania regulatora (kontrolera). Pierwsze zastosowania tego podejścia miały miejsce w przemyśle chemicznym i petrochemicznym. W latach 80. XX wieku popularność algorytmów sterowania predykcyjnego znacznie wzrosła tak, że na początku XXI wieku stały się one najczęściej stosowanymi algorytmami automatycznej regulacji procesów przemysłowych.

Idea wielokrotnego wyznaczania sterowania w oparciu o rozwiązanie problemu optymalizacji dynamicznej była znana od 1967 roku. W pracy [123] Lee i Markus zauważyli, że „jedną z technik wyznaczania regulatora na podstawie wiedzy o rozwiązaniach problemu sterowania optymalnego jest pomiar aktualnego stanu obiektu i bardzo szybkie wyznaczenie rozwiązania optymalnego. Pierwsza część tego rozwiązania jest używana do sterowania obiektem, po czym dokonuje się ponownego pomiaru stanu procesu i rozwiązuje problem sterowania optymalnego z nowym warunkiem początkowym”. Z drugiej strony już Kalman w pracach [94, 95] z 1960 roku zauważył, że optymalność nie zawsze pociąga za sobą stabilność.

Problemy sterowania optymalnego można rozwiązywać wykorzystując warunki konieczne optymalności w przestrzeni sterowań, wyrażone przez zasadę maksimum Pontriagina [8], bądź też stosując metodę programowania dynamicznego Bellmana [123].

Pierwszy sposób prowadzi do wyznaczenia sterowania optymalnego jako funkcji czasu, przy zadanym warunku początkowym. Metoda programowania dynamicznego pozwala wyznaczyć optymalne sprzężenie zwrotne, na podstawie rozwiązania równania Hamiltona-Jacobiego-Bellmana (HJB) [7]. Metoda programowania dynamicznego wydaje się bardziej atrakcyjna, ponieważ równanie HJB rozwiązywane jest tylko raz na etapie projektowania regulatora. Niemniej jednak, znalezienie rozwiązania równania HJB w przypadku systemów nieliniowych jest praktycznie niemożliwe, z wyjątkiem szczególnych przypadków, kiedy HJB jest nieliniowym równaniem różniczkowym cząstkowym pierwszego rzędu.

Znacznie prostsze jest cykliczne rozwiązywanie zadania sterowania optymalnego ze skończonym horyzontem, przy aktualnie wyznaczonym, na podstawie pomiarów, warunku początkowym. Obecnie, sterowanie predykcyjne wydaje się być jedną z niewielu skutecznych w praktyce metod sterowania systemami nieliniowymi przy ograniczeniach sterowania i stanu.

Pierwsze praktyczne implementacje algorytmów predykcyjnych MPC (ang. *Model Predictive Control*) dla systemów opisywanych liniowymi

równaniami różnicowymi pojawiły się w latach 70. Jednym z pierwszych algorytmów regulacji predykcyjnej był algorytm DMC (ang. *Dynamic Matrix Control*) opracowany jeszcze w latach 70. jednak jego wadą było traktowanie ograniczeń w sposób przybliżony. II generację sterowania predykcyjnego (z lat 80.) stanowiły algorytmy QDMC (ang. *Quadratic Dynamic Matrix Control*) oraz algorytmy GPC (*Generalized Predictive Control*). Kolejnym krokiem było opracowanie na przełomie lat 80. i 90. algorytmów z modelem obiektu w postaci zmiennych stanu MPCs (ang. *Model Predictive Control with State Equations*). Powyższe algorytmy skonstruowano przy założeniu liniowości. Algorytmy dla układów nieliniowych powstały dopiero w latach 90. Kolejne dekady przynoszą modyfikacje zaproponowanych rozwiązań z zastosowaniem różnych typów modeli.

W pracy [70] z 2017 roku zaproponowano stochastyczne MPC (ang. *Stochastic Model Predictive Control*, SMPC), które dostarcza probabilistyczną strukturę dla układów MPC, charakteryzujących się stochastyczną niepewnością. Kluczową cechą podejścia SMPC jest uwzględnienie przypadkowych ograniczeń, które umożliwiają systematyczny kompromis między możliwą do osiągnięcia wydajnością sterowania a prawdopodobieństwem naruszenia ograniczeń stanu w warunkach stochastycznych.

2.3. Sterowanie predykcyjne z modelem

Model Predictive Control (MPC), znany również pod hasłem sterowania z przesuwным horyzontem (ang. *receding-horizon control*), znajduje zastosowanie w zaawansowanej kontroli systemów o wielu zmiennych z ograniczeniami stanów i wejść sterujących [156, 157, 165]. Dobrze uwarunkowane zastosowania MPC obejmują sterowanie procesów chemicznych [50, 186], kontrolę klimatu budynku [152, 173, 254], usieciowione systemy sterowania [90, 203], sterowanie nadążne pojazdu po ścieżce [47, 48].

Macierz jednostkowa o wymiarze $\mathbb{R}^{n \times n}$, oznaczona jako I_n . $M > 0$ ($M \geq 0$) oznacza macierz dodatnio określoną (dodatnio półokreśloną). v_k określa wartość zmiennej v w czasie k , z $v_{k+i|k}$, określając wartość v w przyszłości $k + i$ przewidywane od czasu k . p_v określa rozkład prawdopodobieństwa zmiennej v (tj. $v \sim p_v$). $Pr[A]$ i $E[v]$ oznaczają odpowiednio prawdopodobieństwo zdarzenia A i wartość oczekiwaną zmiennej losowej v . $Pr_k[A]$ i $E_k[v]$ oznaczają, że zarówno prawdopodobieństwo, jak i wartość oczekiwana są uwarunkowane informacjami systemowymi dostępnymi w czasie k .

Poniżej przedstawiono podstawy matematyczne MPC. Można rozważyć liniowy system niezmienny (ang. *linear time-invariant*, LTI) w formie dyskretnej:

$$\begin{cases} x_{k+1} = Ax_k + Bu_k, \\ y_k = Cx_k \end{cases}, \quad (2.1)$$

gdzie: $x_k \in \mathbb{R}^{n_x}$, $u_k \in \mathbb{R}^{n_u}$, $y_k \in \mathbb{R}^{n_y}$ określają stan, wejście sterujące oraz mieralne wyjście w momencie próbkowania k , przy czym $A \in \mathbb{R}^{n_x \times n_x}$, $B \in \mathbb{R}^{n_x \times n_u}$ i $C \in \mathbb{R}^{n_y \times n_x}$ stanowią macierze opisu w przestrzeni stanów. Dla znanego stanu x_k MPC dokonuje rozwiązania problemu sterowania optymalnego (ang. *optimal control problem*, OCP) dla każdego czasu próbkowania k .

$$\begin{aligned} & \min_{\mathbf{u}} J_N(x_k, \mathbf{u}) \\ \text{z uwzględnieniem: } & \begin{cases} x_{k+i+1|k} = Ax_{k+i+1|k} + Bu_{k+i+1|k} \\ Hx_{k+i+1|k} \leq h \\ Du_{k+i+1|k} \leq d \\ i = 0, 1, \dots, N-1 \\ x_{k|k} = x_k \end{cases}, \end{aligned} \quad (2.2)$$

gdzie N stanowi horyzont predykcji, natomiast $k+i|k$ określa wartość zmiennej w (przyszłym) czasie $k+i$, wyznaczonej na podstawie wiedzy o układzie w chwili k . Z kolei $H \in \mathbb{R}^{n_s \times n_x}$ oraz $D \in \mathbb{R}^{n_i \times n_u}$ są odpowiednio macierzami ograniczeń stanu oraz sygnałów wejściowych, z $h \in \mathbb{R}^{n_s}$ oraz $d \in \mathbb{R}^{n_i}$ oznaczające odpowiednio wartości ograniczeń stanu n_s i ograniczeń wejściowych n_i . W tym przypadku funkcja kosztu, zwykle jest wybierana jako koszt regularyzacji dla stanu wyjściowego i wartości wejściowej dążącej do zera, i wynosi:

$$J_N(x_k, \mathbf{u}) = \sum_{i=0}^{N-1} (x_{k+i|k}^T Q_x x_{k+i|k} + u_{k+i|k}^T R_u u_{k+i|k}) + x_{k+N|k}^T Q_N x_{k+N|k} \quad (2.3)$$

gdzie: $\mathbf{u} := \{u_{k|k}, u_{k+1|k}, \dots, u_{k+N-1|k}\}$ stanowi sekwencję sterowań, natomiast $Q_x \geq 0$, $R_u > 0$ i $Q_N \geq 0$ to macierze wagowe.

Warto zauważyć, że funkcję kosztu, daną równaniem (2.3) można zmodyfikować, nakładając karę na szybkość zmian sterowań postaci: $\Delta u_{k+i|k} = u_{k+i|k} - u_{k+i-1|k}$. Ze względu na liniowość nałożonych ograniczeń (pierwsze trzy zależności w układzie 2.2), funkcja kosztu $J_N(x_k, \mathbf{u})$ jest kwadratowa a macierze wag są dodatnio (pół-) określone (można to zbadać w oparciu o kryterium Sylwestera), wówczas rozwiązanie problemu sterowania optymalnego OCP (2.2) sprowadza się do zagadnienia wypukłego programowania kwadratowego (ang. *quadratic programming*, QP). Z kolei na podstawie [169] można stwierdzić, że problem optymalizacji tego typu ma zawsze unikalne minimum i można go skutecznie rozwiązać przy użyciu standardowych technik.

Minimalizator dla (2.2) w czasie próbkowania k jest sekwencją kontrolną otwartej pętli $u^*(x_k)$. Ze względu na to, że OCP (2.2) jest rozwiązywany z wykorzystaniem sterowania z przesuwym horyzontem, tylko pierwszy element optymalnej wejściowej sekwencji sterującej, $u_{k|k}^*(x_k)$, zostanie użyty w układzie. Zatem, w każdym momencie algorytm MPC oblicza ukryte prawo kontroli sprzężeń $u_k = \kappa_N(x_k)$, gdzie:

$$\kappa_N(x_k) = u_{k|k}^*(x_k) \quad (2.4)$$

jest wyznaczane przez rozwiązanie (2.2).

W przypadku braku ograniczeń na stan i wejścia (sygnały wejściowe), rozwiązanie dla OCP (2.2) przyjmuje postać liniowego kontrolera ze sprzężeniem zwrotnym $u_{k+i|k} = -K_i x_{k+i|k}$, znanego powszechnie, jako liniowy regulator kwadratowy (ang. *linear quadratic regulator*, LQR). Zróżnicowane w czasie wzmocnienie sprzężenia zwrotnego K_i opisuje zależność (2.5):

$$K_i = (R_u + B^T P_{i+1} B)^{-1} B^T P_{i+1} A. \quad (2.5)$$

Stąd, LQR stanowi optymalny kontroler dla układu liniowego (2.1) przy łagodnych założeniach i skutkuje stabilną dynamiką dla układu regulacji (po zamknięciu pętli sprzężenia zwrotnego) $x_{k+i} = (A - BK_k) x_k$.

Na podstawie [103,198,223], do dalszej analizy, niezbędne jest wprowadzenie algebraicznej macierzy Riccatiego P . Korzystając z własności, że dla dowolnego czasu i , macierz $P_i = P_i^T \geq 0$ w zależności (2.5) jest obliczana (wstecznie w czasie) poprzez iterację dyskretnego równania Riccatiego:

$$P_{i-1} = Q_x + A^T P_i A - A^T P_i B (R_u + B^T P_i B)^{-1} B^T P_i A, \quad (2.6)$$

począwszy od $P_N = Q_N$. W ogólności, macierz P_i szybko zmierza do wartości stanu ustalonego P , co z kolei prowadzi do stałego wzmocnienia K już po kilku iteracjach. W stanie ustalonym P nie zależy od interwału (kroku) i . W rezultacie, wyrażenie (2.6) można zapisać jako dyskretne w czasie algebraiczne równanie Riccatiego (ang. *discrete-time algebraic Riccati equation*, DARE).

$$P = (A - BK)^T P (A - BK) + Q_x + K^T R_u K, \quad (2.7)$$

które można wyprowadzić z (2.6), stosując formułę Shermana-Morrisona-Woodbury do odwracania (inwersji) macierzy.

W przypadku użycia prawa sterowania $u_k = -K x_k$, dla układu (2.2), macierz Riccatiego P ma następującą własność:

$$\sum_{k=0}^{\infty} (x_k^T Q_x x_k + u_k^T R_u u_k) = \sum_{k=0}^{\infty} x_k^T (Q_x + K^T R_u K) x_k = x_0^T P x_0. \quad (2.8)$$

To z kolei implikuje, że przy ustalaniu $Q_N = P_N = P$ w (2.3), terminalny koszt $x_{k+N|k}^T P x_{k+N|k}$ przechwytyje koszt od $k = N$ do $k = \infty$, przy założeniu, że $u_{k+i|k} = -K x_{k+i|k}$ dla $i \geq N$. Taka zależność jest znana jako paradygmat dualny (ang. *dual-mode paradigm*) [156], który odnosi się do trybu $0 \leq i < N$,

w którym dane wejściowe są dowolnymi zmiennymi decyzyjnymi poza ustalonym horyzontem N a tryb $i \geq N$, w którym sprzężenie od stanu w prawie sterowania jest używane ponad kolejnym nieskończonym horyzontem.

Idea dualnego trybu MPC (ang. *dual-mode MPC*) polega na tym, że dopóki N jest wystarczająco duże, $x_{k+i|k}$ dla wszystkich $i \geq N$, będzie wystarczająco blisko początku, aby ograniczenia nie były aktywne. Kiedy ograniczenia są nieaktywne, prawo LQR $x_{k+i|k} = -Kx_{k+i|k}$ stanowi sterowanie optymalne. Dla wartości z przedziału $0 \leq i \leq N - 1$, dane wejściowe $u_{k+i|k}$ są zmiennymi decyzyjnymi, które minimalizują koszt (2.3) tak, aby przewidywane stany i wejścia były wykonalne (prawdopodobne) w odniesieniu do ograniczeń $Hx_{k+i+1|k} \leq h$ oraz $Du_{k+i+1|k} \leq d$ z układu (2.2). Dlatego przyjęcie założenia $Q_N = P$ oznacza, że $u_{k+i|k} = -Kx_{k+i|k}$ dla $i \geq N$ i umożliwia optymalizację w nieskończonym horyzoncie [229].

2.4. Niepewność układu sterowania

W systemie (2.1) zakłada się, że stan x_k ewoluuje w sposób deterministyczny oraz brak błędów w pomiarze stanu y_k . W praktyce jednak wiedza na temat dynamiki systemu jest niepewna. Niepewność systemu na ogół objawia się w kategoriach niepewnej struktury i / lub parametrów modelu, niepewnych warunków początkowych, niezmiernych zakłóceń i błędu pomiaru. Powszechnym sposobem włączenia niepewności do opisu systemu (2.1) jest zmodyfikowanie modelu do postaci:

$$\begin{cases} x_{k+1} = Ax_k + Bu_k + Gw_k \\ y_k = Cx_k + v_k \end{cases}, \quad (2.9)$$

gdzie $w_k \in \mathbb{R}^{n_w}$ oraz $v_k \in \mathbb{R}^{n_v}$ oznaczają odpowiednio zakłócenia układu i szum pomiarowy, a $G \in \mathbb{R}^{n_x \times n_w}$ modeluje wpływ w_k na stan układu. Przy czym, zakłócenia w_k mogą być postrzegane jako zmienne, które wychwytyują połączony efekt niepewności modelu i zaburzeń egzogenicznych na zmianę stanu. Kiedy zakłócenia i szum pomiarowy są opisane jako zmienne losowe, (2.9) staje się stochastycznym modelem dynamiki układu.

Oznacza to, że chociaż prawdziwy/rzeczywisty układ (2.1) ewoluuje deterministycznie, postrzegana dynamika systemu jest opisana w sposób probabilistyczny. Należy zauważyć, że ta koncepcja kontrastuje z posiadaniem układu, który jest z natury stochastyczny, ponieważ system naturalnie wykazuje przypadkowe zachowanie, jak na przykład z powodu ruchów Browna.

Chociaż stochastyczne metody sterowania optymalnego kontroli mogą być przyjęte dla systemów naturalnie stochastycznych, dyskusję w tym zakresie należy ograniczyć do problemu niepewności układu probabilistycznego, opartego na stochastycznym modelu systemu (2.7). Dlatego też dalej zakłada się, że w_k i v_k są to ciągi niezależnych i identycznie rozdzielonych zmiennych (ang. *independent and identically distributed, i.i.d.*) o znanym rozkładzie

prawdopodobieństwa odpowiednio p_w i p_v , spełniających warunki: $E[w_k w_k^T] = Q_w$, $E[v_k v_k^T] = Q_v$ i $E[w_k v_k^T] = 0$.

Kiedy model stochastyczny (2.9) jest używany do opisanie dynamiki niepewnego układu, OCP (2.2) musi zostać zmodyfikowany, aby uwzględnić probabilistyczny charakter prognoz modelu. Koszt $J_N(x_k, \mathbf{u})$ stanie się losową wielkością, którą należy zastąpić pewną statystyką, taką jak oczekiwana wartość $E_k[J_N(x_k, \mathbf{u})]$. Warunkowa wartość oczekiwana $E_k[J_N(x_k, \mathbf{u})]$ opiera się na informacji pomiarowej używanej do dedukcji stanu systemu (tj. poprzez estymację stanu w przypadku braku kompletnych pomiarów stanu), których znajomość jest wymagana do zainicjowania OCP (2.2) dla każdego czasu próbkowania k . Podobnie, ograniczenia stanu muszą zostać zastąpione, aby odzwierciedlić fakt, że stan jest zmienną stochastyczną ze względu na niepewność układu.

W najprostszej formie ograniczenia stanu przyjmują postać ograniczeń typu oczekiwania (ang. *expectation-type constraints*):

$$E_k[Hx_{k+i+1|k}] \leq h, i = 0, 1, \dots, N-1. \quad (2.10)$$

Alternatywnie, aby uwzględnić probabilistyczną naturę stanu, ograniczenia szans mogą być zdefiniowane jako:

$$Pr_k[[H_j x_{k+i+1|k} \leq h_j] \geq 1 - \beta_j, i = 0, 1, \dots, N-1, j = 1, 2, \dots, n_s, \quad (2.11)$$

gdzie H_j jest rzędem j macierzy H , h_j jest elementem j wektora h , a $\beta_j \in (0,1)$ jest predefiniowanym parametrem, określającym dopuszczalne prawdopodobieństwo naruszenia ograniczenia stanu j . Metoda działania takiego regulatora zostanie przedstawiona na przykładzie prognozowania emisji NO_x w procesie spalania.

2.5. Studium przypadku na przykładzie procesu spalania w kotle węglowym

Większość współczesnych prac badawczych w zakresie technik spalania węgla koncentruje się na całkowitym spalaniu tego paliwa oraz minimalizacji emisji szkodliwych substancji. W celu ograniczenia zanieczyszczenia środowiska, wiele krajów wprowadziło ograniczenia emisji tlenków azotu (ang. *nitrogen oxides*, NO_x). Kraje zrzeszone w Unii Europejskiej do roku 2016, dla bloków powyżej 500 MWe dopuszczały emisje do 500 mg NO/Nm^3 . Z kolei, od 2016 roku wynoszą one 200mg NO/Nm^3 [19, 190, 264].

W odpowiedzi, opracowane zostały metody pozwalające na sprostanie przyjętym wytycznym. W starszych instalacjach, upowszechniono palniki niskoemisyjne oraz modyfikacje układów powietrza wtórnego (ang. *over-fire air*, OFA), recyrkulacji spalin (ang. *flue gas recirculation*) oraz dopalania (ang. *reburning*). Niemniej jednak, od 2016 roku jednostki na paliwa kopalne powinny posiadać także układ DeNOx, jak na przykład instalację z podawaniem

amoniaku (*Selective Catalytic Reduction*, SCR). Rozwiązania te pozwalają na obniżenie emisji NO_x ze względu na pochłanianie przez amoniak w układach DeNO_x, a degradacja absorbentów aminowych następuje w układach wychwytywania CO_2 [51].

Optymalizacja procesu pod względem minimalizacji emisji oraz poprawy efektywności w jednostkach opalanych węglem odgrywa istotną rolę w ograniczaniu kosztów obsługi i konserwacji (ang. *operational & maintance*, O&M). Kotły w blokach energetycznych posiadają systemy SCADA (ang. *Supervisory Control and Data Acquisition*), dostarczające informacje o pracy elementów układu. Można zatem przyjąć założenie, że posiadając odpowiedni model do prognozowania emisji NO_x , istnieje możliwość redukcji niepożądanych, szkodliwych substancji. Wybrane przykłady [189, 260] dowodzą, że optymalizacja procesu spalania z uwzględnieniem redukcji emisji NO_x może stanowić nową, efektywną grupę metod dla układów opalanych węglem. Prawidłowe dopasowanie parametrów pracy układu może być prognozowane z wykorzystaniem różnych modeli, uwzględniających regresje liniową, sztuczne sieci neuronowe, logikę rozmytą, systemy eksperckie itp. W związku z tym, odpowiedni model dla celów prognozowania NO_x na podstawie różnych parametrów operacyjnych stanowi jeden z najistotniejszych elementów w schemacie optymalizacji.

Modele analityczne NO_x uwzględniają dynamikę spalania, zjawiska transportu ciepła, reakcje chemiczne przemian azotu, jakość węgla itp. Na podstawie opisanej w ten sposób dynamiki modeli NO_x można uwzględnić skomplikowane, wzajemnie zależne procesy, na które wpływa wiele zmiennych. Przegląd modeli analitycznych NO_x dostępny jest w pracy [72]. Warto jednak zauważyć, że ze względu na złożoność, opracowanie dokładnego modelu analitycznego, umożliwiającego pracę on-line w układzie diagnostyki i sterowania nie jest możliwe. Model powinien z jednej strony jak najdokładniej odwzorowywać zjawisko lub proces, z drugiej zaś strony – powinien być jak najmniej złożony obliczeniowo, prosty. Stąd we współczesnych badaniach i opracowaniach na pierwsze miejsce wysuwają się modele oparte na danych, rekompensując ułomności modeli analitycznych. Ich przegląd opisuje praca [96]. Wśród publikacji z tego zakresu, modele emisji NO_x w dużych kotłach opalanych węglem wykorzystują metody sztucznych sieci neuronowych [25, 67, 92, 189, 260, 261], regresję wektorów nośnych (maszyna wektorów wpierających [86], (ang. *support vector regression*, SVR) [208, 209, 257, 262] oraz modele typu black-box oraz gray-box [131].

Ponadto, w zakresie modelowania NO_x , obserwuje się trendy zaawansowanego modelowania nieliniowego z użyciem SVR oraz sztucznych sieci neuronowych. Praca [206] omawia zastosowanie rekurencyjnej sztucznej sieci neuronowej do modelowania emisji NO_x w celu uwzględnienia nieliniowości oraz dynamiki kotła. Co więcej, wskazuje ona zalety modelu dynamicznego w porównaniu ze statycznym, chociaż przedstawione badania dowodzą, że w relatywnie krótkim czasie model dynamiczny znacznie się pogorszył.

Prognozowanie emisji NO_x dla dużego bloku energetycznego z wykorzystaniem sztucznych sieci neuronowych omówiono w [261]. Przeprowadzono tu badania z zakresu wpływu parametrów układu OFA, powietrza wtórnego, nachylenia dysz oraz własności węgla przy różnych obciążeniach na charakterystykę emisji NO_x . Podobne badania, wykorzystujące podejście oparte na modelach regresji liniowej oraz regresji wektorów wspierających (ang. *support vector regression*, *SVR*) dostępne są w [262]. Z kolei w [212] porównano trzy modele prognozujące emisje NO_x , obejmujące podejście typu gray-box, ARX oraz NARX. Model gray-box zawierał wiedzę „a priori” w zakresie podstawowych elementów uzyskanych na podstawie identyfikacji modelu. Przy czym, podejście takie uwzględniono również podczas opracowania modeli ARX i NARX. Wykazano zbliżone własności wszystkich modeli przy predykcji krótkookresowej. Model typu gray-box przewyższał pozostałe przy prognozowaniu długookresowym. Artykuł [161] zawiera rezultaty badań symulacyjnych sterowania z modelem NO_x z wykorzystaniem klasycznego regulatora PID oraz MPC.

Większość publikacji dotyczących modelowania NO_x nie zawiera dokładnych informacji odnośnie wykorzystanych danych w modelowaniu. Przy czym, częstotliwość próbkowania i resampling ma istotny wpływ na uzyskiwane wyniki. Ponadto większość badań obejmuje tylko podstawowe zmienne powstawania NO_x , np. przepływy paliwa, kąty nachylenia dysz powietrza do spalania i komory spalania, gdzie można zaobserwować niezmienną dynamikę procesu.

Różnice pomiędzy modelami mogą wynikać z warunków, które nie są bezpośrednio związane ze spalaniem, ale mogą mieć na nie znaczący wpływ. Niektóre z typowych przyczyn dotyczą zmiennej jakości paliwa, jego wartości opałowej, zawartości wilgoci, sposobu chłodzenia młynów węglowych, zatykania młynów, uzupełniającego dopalania, znacznych zmian właściwości wody zasilającej i chłodzenia przegrzanej pary itp., które mogą zmieniać się w czasie. Czynniki te bezpośrednio, jak i pośrednio wpływają na temperaturę i właściwości spalania, powodując, że powstawanie NO_x zależy nie tylko od zmiennych początkowych. Zjawiska te można uchwycić za pomocą pomiarów, np. właściwości pary, temperatury na ścieżce spalin itp., które są łatwo dostępne, a zatem mogą być wykorzystane do poprawy prognoz emisji NO_x .

Z kolei w pracy [212] zamieszczono badania z zakresu wielokrokowej predykcji w przód, z uwzględnieniem modeli liniowych oraz nieliniowych. Wyniki oparte na strukturze modelu ARX pokazują, że same podstawowe zmienne nie wystarczają do dokładnych prognoz NO_x .

Natomiast, wydajność modelu, znacznie poprawia dodanie zmiennych, pośrednio wpływających na powstawanie NO_x . Interesujące, że w przypadku prac z zakresu szeroko pojętej inteligencji obliczeniowej (ang. *computational intelligence*) do ograniczenia nieskorelowanych zmiennych, w pracach [112, 114, 206] używano statystycznych metod analizy czynnikowej, ze szczególnym uwzględnieniem analizy głównych składowych (ang. *principal component analysis*, PCA).

Warto zaznaczyć, że metody sztucznych sieci neuronowych, dzięki dobrym własnościom linearyzacji, były także stosowane do modelowania emisji NO_x dla systemów spalania.

Wiele rodzajów SSN, w tym sieci neuronowe ze wsteczną propagacją (ang. *back propagation neural network*, BPNN) [83, 114, 261], struktury z radialną funkcją bazową (ang. *radial basis function*, RBF) [93, 98] i sieci regresyjne (ang. *generalized regression neural network*, GRNN) [258], znalazło swoje zastosowanie w modelowaniu emisji NO_x dla kotłów węglowych. W pracach [58, 251], wykazano przewagę modeli SSN nad konwencjonalnymi metodami regresji i innymi metodami, opartymi na złożonych obliczeniach procesów spalania techniką obliczeniowej dynamiki płynów (ang. *computational fluid dynamics*, CFD). Jednak modele SSN mają pewne nieodwracalne słabości, w tym potrzeby dotyczące licznych parametrów kontrolnych, trudności w uzyskaniu stabilnego rozwiązania i niebezpieczeństwa przeuczenia, wymagające nakładanie odpowiednich ograniczeń w celu ich praktycznego zastosowania [145]. Co więcej, modele SSN są wrażliwe na ilość i reprezentatywność (jakość) dostępnych danych. Dla zbyt małego zbioru danych klasyczne modele sztucznych sieci neuronowych narażały na trudności. W rezultacie, oczekuje się, że modele SSN będą stanowić dobre narzędzie w dziedzinie modelowania emisji NO_x .

W odpowiedzi na ułomności klasycznych sztucznych sieci neuronowych, w grupie metod obliczeń inteligentnych (powszechnie nazywanych także metodami inteligencji obliczeniowej) [86] zaproponowano podejście SVR. Za cel przyjęto zapewnienie lepszych rozwiązań dla problemów silnie nieliniowych [65, 77, 150]. Znalazło ono dość rozległe zastosowania, w tym: predykcja obciążenia elektrycznego [76] i prognozowanie pogody [179]. Przy czym, w pracach [241, 257, 263] modelowano emisję NO_x z kotłów węglowych i zaobserwowano lepszą zgodność między prognozowanymi i zmierzonymi stężeniami emisji NO_x . SVR ma zdolność modelowania wysoce nieliniowych zależności pomiędzy wielością parametrów pracy kotła i jego stężeniami emisji NO_x .

Warto zauważyć, że na potrzeby zastosowań on-line pożądane są izochroniczne (uwarunkowane czasowo) algorytmy optymalizacji gwarantujące jednocześnie odpowiednią jakość i szybkość dla dużej ilości parametrów. Stąd, w pracach [28, 77, 208, 241] użyto heurystyczne metody optymalizacyjne. Zabieg ten miał na celu niwelację ograniczeń konwencjonalnych algorytmów optymalizacji.

Jednym z typowych przedstawicieli algorytmów ewolucyjnych (ang. *evolutional algorithms*, EA) jest konwencjonalny algorytm genetyczny (ang. *conventional genetic algorithm* CGA), stanowiący technikę losowego wyszukiwania, symulującą ewolucję biologiczną i transfer genetyczny [197]. CGA generuje początkowe osobniki za pomocą binarnego kodowania i odnawia je poprzez selekcję, krzyżowanie i mutację. Wraz z ewolucją generacji, jednostki wysokiej jakości zostają zachowane, a te o niskiej jakości są eliminowane.

Ze względu na to, że CGA jest równoległym algorytmem, może uwzględniać jednocześnie wiele punktów w przestrzeni wyszukiwania. W rezultacie zmniejsza się prawdopodobieństwo utknięcia w minimum lokalnym. Z tego względu CGA jest predystynowany do optymalizacji procesu spalania. W literaturze [67, 257, 263] zastosowano to podejście do optymalizacji parametrów pracy kotłów użytkowych, a w [35, 89] – silników spalinowych.

Z kolei, rezultaty badań użycia konwencjonalnych algorytmów genetycznych do optymalizacji emisji NO_x w komorach spalania zamieszczono w [101, 232]. Pomimo wielu zalet, podejście CGA jest krytykowane za pewne widoczne ułomności, jak na przykład problem przedwczesnej konwergencji. Stąd w pracy [241] zaproponowano użycie jego modyfikacji w postaci kwantowego algorytmu genetycznego (ang. *quantum genetic algorithm*, QGA) oraz algorytm genetyczny z symulowanym wyżarzaniem (ang. *simulated annealing genetic algorithm*, SAGA). Pierwszy z nich, QGA bazuje na założeniach budowy komputerów kwantowych, w których do opisu układu fizycznego stosuje się mechanikę kwantową w celu rozwiązania określonego problemu obliczeniowego. Jednostkę obliczeniową stanowi tzw. kubit (ang. *qubit*), będący superpozycją wartości zera i jedynki. Stąd kwantowy rejestr m kubitów może równocześnie reprezentować 2^m wartości. Analogicznie, w metodzie QGA w miejsce chromosomów CGA zastosowano reprezentację rejestru kwantowego, co z kolei umożliwia reprezentację jako superpozycję wszystkich możliwych stanów.

Z kolei algorytm SAGA, stanowi rozwinięcie klasycznego algorytmu genetycznego o probabilistyczną technikę przybliżania globalnego optimum funkcji, nazywaną symulowanym wyżarzaniem (ang. *simulated annealing*, SA). W przypadku problemów, w których znalezienie przybliżonego optimum globalnego jest ważniejsze niż znalezienie precyzyjnego optimum lokalnego w ustalonym czasie, symulowane wyżarzanie może stanowić bardzo efektywne podejście. Stąd SAGA zastępuje stany mikro przejść symulowanego algorytmu wyżarzania z genetycznym krzyżowaniem i mutacją konwencjonalnego algorytmu genetycznego. Badania z zakresu modelowania emisji NO_x z wykorzystaniem CGA, QGA oraz SAGA w zadanym czasie wykazały przewagę algorytmów genetycznych z symulowanym wyżarzaniem. Stosunkowo nową grupę metod optymalizacyjnych stanowią głębokie sieci neuronowe.

3. Spalanie w energetyce

Procesy spalania pełnią fundamentalną rolę w rozwoju przemysłu. Około 90% obecnie zużywanej energii pochodzi ze spalania paliw, głównie paliw kopalnych. Stopniowe wprowadzanie odnawialnych źródeł energii, pojawienie się nowych technologii oraz wytyczonych trendów w zakresie zrównoważonej energetyki ma tą sytuację diametralnie zmienić. Niemniej jednak, wiele wskazuje, że paliwa kopalne w najbliższej przyszłości będą nadal stanowić główne źródło energii. Proces spalania jest złożony oraz podlega wpływowi znacznej liczby czynników warunkujących stacjonarność (bądź niestacjonarność) jego przebiegu. W celu zapewnienia odpowiedniego algorytmu sterowania procesem spalania pyłu węglowego, w dalszej kolejności przedstawione zostaną najistotniejsze informacje dotyczące paliw. Z kolei, ze względu na rozległość zagadnienia, opis procesu, metod monitorowania i diagnostyki ograniczono do spalania węgla (i współspalania z biomasą) w kotłach energetycznych z palnikami pyłowymi. Obszerne ujęcie zagadnień związanych ze spalaniem można znaleźć między innymi w pozycjach [37, 113, 191, 211, 233].

3.1. Charakterystyka procesu spalania

Na podstawie [221], paliwo jest to substancja chemiczna celowo wykorzystywana w procesie spalania, w celu wytworzenia ciepła, pracy mechanicznej (silniki spalinowe) lub bezpośrednio energii elektrycznej (ogniwa paliwowe). Ciepło może zostać zagospodarowane do ogrzewania lub wytwarzania energii elektrycznej w obiegach termodynamicznych. Paliwo obejmuje substancję palną oraz tzw. balast. Substancje palne to związki chemiczne, głównie takich pierwiastków jak węgiel i wodór, a w przypadku biomasy także i tlenu. Pozostałe składniki stanowią balast i są to na ogół: związki azotu, siarki, żelaza, fosforu, wapnia i inne tworzące tzw. substancję mineralną oraz woda i dwutlenek węgla (CO_2 , nazwa systematyczna: ditlenek węgla lub tlenek węgla (IV)).

Paliwa są klasyfikowane z uwzględnieniem różnych kryteriów, wśród nich:

- stan skupienia: stałe, ciekłe i gazowe;
- wartość opałowa: wysokokaloryczne, średniokaloryczne i niskokaloryczne;
- pochodzenie: naturalne i sztuczne (syntetyczne);
- zależność od obiegu w przyrodzie: odnawialne (biomasa) i nieodnawialne;
- zależność od stosunku pierwiastków wodoru do węgla, h/c .

Paliwa naturalne są to głównie kopaliny (ang. *fossil fuels*) pochodzenia organicznego, stanowiące podstawowe źródło energii pierwotnej pochodzenia antropogenicznego.

Przeważająca większość całkowitej energii pierwotnej pozyskiwanej przez człowieka pochodzi ze spalania paliw naturalnych. Należy zaznaczyć, że procesy spalania stanowią także główne źródło antropogenicznej emisji szkodliwych substancji. W konsekwencji, z procesów spalania pochodzi około 75% emisji NO_x , SO_2 i CO , 60% emisji pyłów i praktycznie 100% emisji CO_2 . Stosowane są zatem środki zaradcze, związane z doskonaleniem procesów spalania,

oczyszczaniem paliwa i stosowaniem nowych alternatywnych technologii wytwarzania energii. Ich celem jest oszczędne, efektywne i bezkonfliktowe użytkowanie paliw.

Formy występowania paliw stałych (pochodzenia węglowego)

Antracyt, węgiel kamienny, węgiel brunatny, torf i drewno są to naturalne paliwa stałe. Ponadto, do sztucznych paliw stałych zalicza się koks i półkoks. Węgiel kamienny i brunatny odgrywają główną rolę jako paliwa energetyczne. Na podstawie hipotezy Kreulena, węgle są to naturalne paliwa stałe utworzone przez powolny rozkład chemiczny dużych ilości substancji, głównie roślinnych [115]. Obecnie przyjmuje się również, że glony, plankton i zwierzęta o wyższym stopniu rozwoju mogły dostarczać surowca do powstawania węgla. Istnieje genetyczny związek między naturalnymi paliwami stałymi, według którego najmłodszym paliwem jest drewno, starszym jest torf, a następnie węgiel brunatny, węgiel kamienny i antracyt. Analogiczny związek występuje w przypadku węgla pochodzenia zwierzęcego: sapropel przechodzi w sapropelit, a ten dalej w węgle sapropelowe i łupki bitumiczne. Istnieje również prawidłowość, że im starsze paliwo, tym większy stopień uwęglenia i mniejsza zawartość części lotnych. Na podstawie analizy technicznej, paliwo składa się z trzech części: substancji organicznej paliwa, substancji mineralnej i wody (wilgoci).

Substancja organiczna palna stanowi mieszaninę różnych związków chemicznych kilku pierwiastków, takich jak węgiel, wodór, tlen, azot i siarka oraz śladowych ilości fosforu. Substancja ta jest wynikiem przemian biochemicznych i geotermicznych, które rozwinęły makrocząsteczkowy charakter substancji początkowych. Substancja mineralna, występująca w bardzo zmiennej ilości (od 2 do 60%), jest niejednorodną mieszaniną różnych związków chemicznych domieszanych z zewnątrz (np. przez wiatr, osadzonych przez wodę lub w wyniku obsunięcia pokładu). Poza głównymi pierwiastkami (Si, Al, Fe, Ca, Mg) zawiera znaczne ilości tzw. pierwiastków śladowych, takich jak: Be, B, Se, Cd, Ni, Zn, Ga, Ge, As, Y, Mo, Sb, Pb, Ag, Au, Rh, Pt, Pd [80,221]. Substancja mineralna po spaleniu stanowi popiół lub żużel. Jest ona balastem paliwa stałego. Drugim balastem jest wilgoć paliwa. Wilgoć całkowita (5–60%) składa się z wilgoci przemijającej, pochodzenia przypadkowego (np. z opadów atmosferycznych) oraz z wilgoci higroskopijnej, związanej fizykochemicznie z substancją węglową. Ważnym, chociaż niepożądanym składnikiem paliwa jest siarka występująca w węglu w ilości 0,1-5%. Głównym związkiem siarki w polskich węglach jest piryt (FeS_2). Ponadto siarka występuje w postaci siarczanów (CaSO_4 , MgSO_4 , FeSO_4) lub związkach organicznych [172, 221].

Jakość paliwa węglowego / Ocena jakości węgla

Ocenę jakości węgla dokonuje się przez klasyfikację. W polskiej klasyfikacji węgla wyróżnia się typy, klasy i sortymenty. Według typów paliwa dzieli się na pięć grup według stopnia uwęglenia z wykorzystaniem dwucyfrowego

wskaźnika, w którym pierwsza cyfra oznacza przynależność do grupy, a druga miejsce w danej grupie. Podstawą klasyfikacji węgla kamiennego jest jego przydatność technologiczna. W energetyce i ciepłownictwie stosowane są węgle 31 i 32 oraz częściowo 33 i 38. Klasy węgla energetycznych (31, 32, 33) uwzględniają zawartość popiołu i wartość opałową [181]. Sortymenty węgla kamiennego (kostka, orzech, groszek, drobny, miał, pył i muł) są ujęte w normie [180], a podstawę jej podziału stanowią wymiary kawałków węgla [221]. Warto zaznaczyć, że węgiel wydobyty z kopalni podlega przeróbkom mechaniczno-chemicznym. Obejmują one procesy sortowania, wzbogacania, suszenia, mieszania, brykietowania, impregnacji. Chemiczne procesy energetyczne utylizacji węgla to spalanie, zgazowanie i odgazowanie oraz wytłewanie. Inne procesy chemicznej utylizacji węgla to: utlenianie łagodne, uwodornienie i ekstrakcja [88, 108].

Ogólna charakterystyka paliw kopalnych stosowanych w przemysłowych procesach spalania

Węgiel kamienny jest podstawowym paliwem energetycznym w Polsce wydobywanym w kopalniach głębinowych. W kotłach pyłowych używa się węgla 31, 32 i częściowo 33. Są to węgle płomienne, gazowe i gazowo-płomienne, niespiekające się, z pylistym lotnym popiołem. W kotłach rusztowych spala się głównie węgiel gazowo-płomienny 32 słabo się spiekający.

Węgiel brunatny jest paliwem pośrednim między węglem kamiennym a torfem; charakteryzuje się dużą zmiennością parametrów. Wydobywany jest w kopalniach odkrywkowych. W przypadku węgla brunatnego zawartość wilgoci i substancji mineralnych może się znacząco zmieniać. Z kolei, zakres zmienności wartości opałowej obejmuje 6,2–21 MJ/kg, przy zawartości substancji mineralnej w stanie suchym $A < 40\%$.

Torf jest paliwem kopalnym, pośrednim pomiędzy węglem brunatnym a drewnem. W stanie świeżym zawiera do 90% wody. W stanie powietrzno-suchym zawiera około 25% wilgoci, a jego wartość opałowa wynosi 11–16 MJ/kg. Torf nie ma znaczenia przemysłowego.

Łupek bitumiczny należy do sapropelitów. Z wyglądu przypomina węgiel brunatny, niemniej zawiera dużo substancji bitumicznych. Jest dobrym surowcem do wytłewania i ekstrakcji. Zawiera podstawowe pierwiastki: C, H, O, S i N oraz stosunkowo dużo Cl.

Biomasa definiowana jest jako stałe lub ciekłe substancje pochodzenia roślinnego lub zwierzęcego, które ulegają biodegradacji [194]. Pochodzi z produktów, odpadów i pozostałości z produkcji rolnej oraz leśnej, a także z przemysłu przetwarzającego ich produkty oraz części pozostałych odpadów, które ulegają biodegradacji. Znaczenie biomasy wynika z faktu, że jest ona jednym z głównych rodzajów odnawialnych źródeł energii (OZE). W warunkach polskich biomasa stała, w mniejszym stopniu energia wiatrowa i słoneczna oferują największe możliwości wykorzystania. Biomase można podzielić na dwie grupy: *energetyczne surowce pierwotne* (drewno, słoma, osady ściekowe, odpady


składowiskowe) oraz *energetyczne surowce przetworzone* (biopaliwa, biogaz, etanol, metanol i estry oleju rzepakowego oraz makulatura).

Większość biomasy jest pochodzenia roślinnego i została wytworzona w procesie fotosyntezy, zachodzącej pod wpływem energii słonecznej [104, 221]. Spośród wymienionych, w Polsce największe znaczenie mają słoma i drewno. Skład elementarny różnych gatunków słomy jest bardzo podobny, ponieważ głównym jej budulcem jest celuloza. Do zalet słomy zalicza się: wysoką dostępność, wysoką wartość opałową i małą zawartość siarki. Z kolei za podstawowe ograniczenia tego rodzaju biomasy uznaje się: duże rozproszenie, małą gęstość, zmienną zawartość wilgoci, dużą zawartość chloru (0,4–0,8%), niska temperatura mięknięcia i topnienia popiołu, łatwopalność, niejednorodność i stosunkowo duża zawartość substancji mineralnych. Potencjał produkcyjny słomy (zbożowej i traw) określany jest na poziomie 25 mln Mg (co jest równoważne około 12,5 mln Mg węgla). W zakresie biomasy z drewna, skład różnych gatunków drewna jest podobny ze względu na fakt, że podstawowy budulec drewna to celuloza i lignina [104, 221]. Do zalet drewna należy: mała zawartość substancji mineralnych (popiół), wysoka temperatura mięknięcia popiołu ($> 1200\text{ }^{\circ}\text{C}$), mała zawartość siarki i azotu. Drewno jest z natury higroskopijne i w stanie powietrzno-suchym zawiera 15–20% wilgoci. Wówczas wartość opałowa drewna wynosi 19–22 MJ/kg. Drewno opałowe występuje w postaci: drewna, kory, liści, igieł drewna kominkowego, zrębków, trocin, brykietów, granulek, pyłu.

3.2. Stechiometria procesów spalania paliw

Spalaniem określa się egzotermiczną reakcję chemiczną paliwa z utleniaczem. Spalanie w urządzeniach technicznych jest realizowane w sposób kontrolowany przez odbiór ciepła lub pracy. Paliwo oprócz substancji palnej może zawierać balast (substancję mineralną, wilgoć, azot). Wielkości dotyczące substratów oznacza się górnym indeksem prim, a produktów – indeksem bis.

W celu uzyskania maksymalnej ilości ciepła w procesie spalania dąży się do jego spalania całkowitego i zupełnego. Paliwo zostanie spalone całkowicie, gdy w produktach spalania nie występują gazowe substancje palne. Pomimo dążenia do spalania całkowitego i zupełnego, w produktach spalania mogą wystąpić gazowe i stałe substancje palne (koksik lotny, węgiel (pierwiastek) w żużlu, sadza) co prowadzi do obniżenia ilości ciepła użytecznego oraz w przypadku ich wprowadzenia do otoczenia stanowi jego negatywne obciążenie. Współczesne techniki spalania paliw powinny zapewniać całkowite i zupełne wypalenie paliwa przy minimalnej emisji zanieczyszczeń do środowiska. Głównymi palnymi składnikami paliw są: węgiel, wodór, siarka oraz ich związki chemiczne. Obliczenie zapotrzebowania na tlen do całkowitego i zupełnego spalania paliwa możliwe jest na podstawie równań stechiometrycznych reakcji spalania:



W reakcjach tych, niezależnie od rodzaju paliwa (stałe, ciekłe, gazowe) zawsze na 1 mol pierwiastka węgla i siarki jest potrzebny 1 mol tlenu (O_2), a na 1 mol wodoru (H_2) jest potrzebne $\frac{1}{2}$ mola tlenu (O_2).

Dla substancji palnej zawierającej: pierwiastkowy węgiel w liczbie n_c moli na jednostkę paliwa, wodór (przeliczony na H_2) w ilości n_{H_2} oraz siarkę w ilości n_s na jednostkę paliwa można obliczyć zapotrzebowanie na tlen. Jeżeli substancja palna zawiera w sobie tlen, to ilość tlenu potrzebnego do całkowitego i zupełnego spalania tego paliwa jest odpowiednio mniejsza. Ilość tlenu (O_2) obliczana jest na podstawie równania [221,224]:

$$n_{O_2min} = n_c + n_s + \frac{1}{2}n_{H_2} - n_{O_2}, \frac{\text{kmol } O_2}{\text{jednostka paliwa}}. \quad (3.2)$$

Znając udział molowy tlenu w powietrzu ($= 0,21$), wyznacza się następnie minimalne zapotrzebowanie na powietrze:

$$n_{amin} = \frac{n_{O_2min}}{0,21}, \frac{\text{kmol } O_2}{\text{jednostka paliwa}}. \quad (3.3)$$

W rezultacie nieodpowiedniego zmieszania paliwa z tlenem, może dojść do niezupełnego spalania. Przeciwdziała się temu przez doprowadzenie tlenu (lub powietrza) z pewnym nadmiarem. Stosunek rzeczywiście doprowadzonej ilości powietrza n'_a do minimalnej ilości niezbędnej dla uzyskania spalania całkowitego i zupełnego jest równy stosunkowi rzeczywiście doprowadzonej ilości tlenu n'_{O_2}

do ilości minimalnej, niezbędnej i nosi nazwę *stosunku nadmiaru powietrza* (lub tlenu), tj.:

$$\lambda = \frac{n'_a}{n_{amin}} = \frac{n'_{O_2}}{n_{O_2min}}. \quad (3.4)$$

Wartość λ jest zależna od rodzaju paliwa ze względu na różną zdolność paliw do mieszania z tlenem. Orientacyjne stosuje się następujące wartości tego parametru dla poszczególnych rodzajów paliw:

- paliwa gazowe $\lambda = 1,05 \div 1,1$,
- pył węglowy i paliwa ciekłe $\lambda = 1,1 \div 1,3$,
- węgiel kawałkowy, spalany na ruszcie $\lambda = 1,3 \div 1,6$.

W przypadku paliw gazowych, ich skład określa się podając udziały molowe poszczególnych składników paliwa. Suma udziałów objętościowych suchego paliwa gazowego jest równa jedności:

$$H_2 + CO + CH_4 + C_2H_2 + C_2H_4 + C_2H_6 + O_2 + N_2 + CO_2 = 1. \quad (3.5)$$

Liczbę moli pierwiastków węgla, wodoru, tlenu i azotu w 1 kmol suchego paliwa gazowego określają równania (3.5 - 3.8):

$$n_C = CO + CH_4 + \sum mC_mH_n + CO_2, \frac{\text{kmol C}}{\text{kmol paliwa gaz.}}. \quad (3.6)$$

$$n_{H_2} = H_2 + 2CH_4 + \frac{1}{2} \sum mC_mH_n, \frac{\text{kmol H}_2}{\text{kmol paliwa gaz.}}. \quad (3.7)$$

$$n_{O_2} = \frac{1}{2}CO + CO_2 + O_2, \frac{\text{kmol O}_2}{\text{kmol paliwa gaz.}}. \quad (3.8)$$

$$n_{N_2} = N_2, \frac{\text{kmol N}_2}{\text{kmol paliwa gaz.}}. \quad (3.9)$$


Dla paliwa gazowego, które nie jest suche, w zależności (3.8) należy dodatkowo uwzględnić wodór, a w równaniu (3.9) tlen z wilgoci zawartej w gazie.

Skład chemiczny paliw stałych i ciekłych podaje się za pomocą udziałów masowych pierwiastków węgla, wodoru, siarki, tlenu, azotu oraz balastu popiołu (A) i wilgoci (W), gdzie suma tych udziałów równa jest jedności:

$$C + H + S + O + N + A + W = 1 \quad (3.10)$$

Należy podkreślić zróżnicowane konwencje podawania składu masowego paliw. Bardzo często podaje się paliwa w stanie analitycznym (gdzie wilgoć w paliwie znajduje się w równowadze z wilgocią atmosferyczną), oznaczanym górnym indeksem (a). Ponadto, podawane są także składy paliwa w stanie suchym (*d* lub *wf*) bądź suchym i bezpopiołowym (*daf* lub *waf*).

Sposób określania wyników analizy węgla i produktów jego rozkładu bez dostępu powietrza w temperaturze 850°C przedstawiono na rysunku 3.1 [221, 225, 226]:



Rys. 3.1. Analiza węgla i produkty rozkładu bez dostępu powietrza w temperaturze 850°C.

Liczbę moli pierwiastkowego węgla, siarki, wodoru, tlenu i azotu w paliwie można obliczyć na podstawie ich udziałów masowych w paliwie oraz zawartości w nim wilgoci:

$$\left\{ \begin{array}{l} n_C = \frac{C}{12}, \frac{\text{kmol C}}{\text{kg paliwa}} \\ n_S = \frac{S}{32}, \frac{\text{kmol H}_2}{\text{kg paliwa}} \\ n_{H_2} = \frac{H}{2} + \frac{W}{18}, \frac{\text{kmol H}_2}{\text{kg paliwa}} \\ n_{O_2} = \frac{O}{32} + \frac{W}{2 \cdot 18}, \frac{\text{kmol O}_2}{\text{kg paliwa}} \\ n_{N_2} = \frac{N}{28}, \frac{\text{kmol N}_2}{\text{kg paliwa}} \end{array} \right. \quad (3.11)$$

Skład spalin po całkowitym spalaniu paliwa

Spaliny po całkowitym spalaniu paliwa zawierają dwutlenek węgla, dwutlenek siarki, wodę, tlen nadmiarowy i azot. Liczby moli tych składników spalin

odniesione do jednostki paliwa, którą dla paliw stałych jest zwykle 1 kg określają następujące równania:

$$\left\{ \begin{array}{l} n''_{CO_2} = n_C, \frac{\text{kmol } CO_2}{\text{kg paliwa}} \\ n''_{SO_2} = n_S, \frac{\text{kmol } SO_2}{\text{kg paliwa}} \\ n''_{H_2O} = n_{H_2} + n'_a X'_{za}, \frac{\text{kmol } H_2O}{\text{kg paliwa}}, \\ n''_{O_2} = (\lambda - 1)n_{O_2min}, \frac{\text{kmol } O_2}{\text{kg paliwa}} \\ n''_{N_2} = n_{N_2} + 0,79n'_a, \frac{\text{kmol } N_2}{\text{kg paliwa}} \end{array} \right. \quad (3.12)$$

gdzie X'_{za} oznacza molowy stopień zawilżenia powietrza doprowadzonego do procesu spalania, wyrażony w kmol H_2O /kmol powietrza suchego. Suma powyższych składników spalin określa liczbę moli spalin wilgotnych, wytworzonych w procesie spalania [144,175]:

$$n''_S = n''_{CO_2} + n''_{SO_2} + n''_{O_2} + n''_{N_2} + n''_{H_2O}, \frac{\text{kmol spalin}}{\text{jednostka paliwa}}. \quad (3.13)$$

Ze względu na możliwość kondensacji pary wodnej w trakcie ochładzania spalin, wygodnie operować ilością spalin suchych [175,230]:

$$n''_{SS} = n''_S - n''_{H_2O} = n''_{CO_2} + n''_{SO_2} + n''_{O_2} + n''_{N_2}, \frac{\text{kmol spalin}}{\text{jednostka paliwa}}. \quad (3.14)$$

Skład spalin określa się na ogół przez podanie udziałów molowych (objętościowych) jego składników. Dla spalin wilgotnych udziały molowe oznacza się symbolem chemicznym składnika w nawiasie okrągłym, a dla spalin suchych (otrzymanych po kondensacji H_2O) – w nawiasie kwadratowym.

Spalanie niecałkowite i niezupełne

Podczas spalania paliw często występuje zjawisko spalania niezupełnego, niecałkowitego lub obydwa jednocześnie. Główną tego przyczyną jest źle zaprojektowany na potrzeby konkretnego paliwa układ palnik-komora spalania [221]. Usunięcie tych negatywnych objawów wymaga przede wszystkim określenia rzeczywistego stosunku nadmiaru powietrza. Jest to utrudnione ze względu na zasysanie niekontrolowanego powietrza z otoczenia lub wybijanie spalin. Ponadto część niespalonego węgla z paliwa może opuścić palenisko w stanie stałym w postaci żużla, lotnego koksiku lub sadzy. W przypadku wystąpienia w gazowych produktach spalania, tlenku węgla, metanu lub wodoru należy opisać skład spalin suchych następującą zależnością:

$$[CO_2] + [CO] + [CH_4] + [H_2] + [O_2] + [N_2] + [SO_2] = 1. \quad (3.15)$$

Dla stopnia niecałkowitego spalania węgla elementarnego x , który w paliwie znajdował się w ilości n_C na jednostkę paliwa można zapisać bilans pierwiastka węgla w postaci:

$$(1 - x)n_C = n''_{SS}([CO_2] + [CO] + [CH_4]). \quad (3.16)$$

Równanie (3.16) pozwala na wyznaczenie rzeczywistej liczby moli powstałych spalin suchych n''_{SS} na jednostkę paliwa. Wobec tego molową ilość pary wodnej oblicza się z bilansu wodoru w paliwie n_{H_2} :

$$n_{H_2O} = n_{H_2} + X'_{za}n'_a - n''_{SS}([H_2] + 2[CH_4]). \quad (3.17)$$

Z kolei rzeczywisty stosunek nadmiaru powietrza określa się na podstawie bilansu pierwiastka azotu:

$$n_{N_2} + 0,79n'_a = n''_{SS}([N_2]). \quad (3.18)$$

Po przekształceniu otrzymuje się wyrażenie:

$$\lambda = \frac{n''_{SS}[N_2] - n_{N_2}}{0,79n_{a \min}}. \quad (3.19)$$

Udział $[CO_2]$ w spalinach suchych jest często wykorzystywany do kontroli procesów spalania. Największa wartość tego udziału jest otrzymywana dla spalania całkowitego (czyli $x = 0$) i zupełnego ($[CO] = 0$), bez powietrza nadmiarowego ($\lambda = 1$). Zatem, największy udział $[CO_2]$ stanowi wielkość charakteryzującą paliwo, oznaczaną k_{max} :

$$k_{max} = [CO_2]_{\lambda=1, [CO]=0, \lambda=1}. \quad (3.20)$$

Jego procentowa wartość odpowiednio wynosi: dla koksu 20,6; dla węgla kamiennego – 18,8; dla węgla brunatnego – 18,2; dla mazutu – 16,1.

Ciepło spalania i wartość opałowa paliw

Reakcje spalania są egzotermiczne. Ilość ciepła odprowadzanego z komory zależy od temperatury spalin. Dla adiabatycznej komory spalania otrzymuje się najwyższą temperaturę spalin, podczas gdy ze wzrostem ciepła odprowadzonego temperatura spalin maleje. Na potrzeby określenia ilości ciepła uzyskiwanego w wyniku spalania paliwa, wprowadza się jednoznacznie określony stan termodynamiczny spalin. Powszechnie przyjęto określać efekty cieplne spalania paliw dla temperatury spalin równej temperaturze substratów. Ze względu na fakt powstawania wody w trakcie spalania, to podczas ochładzania spalin może ona ulec częściowej lub całkowitej kondensacji, wprowadzając element niejedno-znaczności w wartość mierzonego efektu cieplnego spalania paliwa. Stąd, w charakterystyce paliw stosuje się pojęcia:

- **Wartość opałowa W_d** (dawniej: dolna wartość opałowa) jest to ilość ciepła, otrzymana po całkowitym i zupełnym spalaniu jednostki paliwa (1kg lub

1mol) i ochłodzeniu produktów do temperatury substratów, przy zachowaniu wody w spalinach w stanie gazowym.

- **Ciepło spalania W_g** (dawniej: górna wartość opałowa) jest to ilość ciepła jaką otrzymuje się po całkowitym i zupełnym spaleniu jednostki paliwa (1kg lub 1mol) i ochłodzeniu produktów do temperatury substratów, po wykropleniu wody ze spalin.

Należy podkreślić, że ciepło reakcji spalania paliwa dla procesu izobarycznego i izochorycznego nie są sobie równe. Ciepło spalania jest większe od wartości opałowej o ciepło kondensacji ze spalin według zależności:

$$W_g = W_d + n''_{H_2O} \Delta h_p, \quad (3.21)$$

gdzie Δh_p to entalpia parowania w temperaturze, w której wyznaczana jest wartość opałowa lub ciepło spalania, odniesione do 1 kmol wody. Dla paliw niezawierających związków wodoru wartość opałowa jest równa ciepłu spalania.

Wartość opałową i ciepło spalania podaje się standardowej temperatury T_n (najczęściej równe 25°C, 20°C, 18°C), zestawianej w tablicach.

Dla paliw stałych istnieje szereg zależności, pozwalających na obliczenie wartości opałowej na podstawie ich składu. W pracy [155] przedstawiono wyrażenie na wartość opałową stałego paliwa suchego w temperaturze $T_n = 25^\circ\text{C}$:

$$W_{dn} = 34095 C + 132298 H + 6848 S + 1531 A - 1196 (O + N), \quad (3.22)$$

określające wartość opałową w kJ/kg węgla suchego, w którym skład paliwa w stanie suchym należy wstawić w masowym ułamku dziesiętnym (A – stanowi zawartość popiołu).

Wartość opałową paliwa suchego można obliczyć, znając w nim zawartość wilgoci W .

$$W_{dn,suche} = \frac{W_d + \Delta h_p W}{1 - W}, \quad (3.23)$$

Iloczyn $\Delta h_p W$ oznacza ilość ciepła zużytego na odparowanie wilgoci zawartej w paliwie. Podobnie dla ciepła spalania można zapisać zależność:

$$W_{g,suche} = \frac{W_g}{1 - W}, \quad (3.24)$$

Zależność wartości opałowej paliwa względem temperatury określa równanie:

$$\frac{dW_d}{dT} = \sum_i n'_i c_{pi} - \sum_k n''_k c_{pk}, \quad (3.25)$$


w którym indeks i oznacza składniki substratów, k – produktów spalania. Liczbę moli tych składników określa się za pomocą równania stechiometrycznego reakcji spalania paliwa.

3.3. Spalanie w kotłach pyłowych

Jedną z najważniejszych technik spalania stanowi spalanie w kotłach pyłowych. Wynika to z elastyczności tego rodzaju palenisk, różnych typów spalanego węgla, jak i duży zakres mocy bloków energetycznych z kotłami pyłowymi. W paleniskach pyłowych spala się węgiel zmielony, a jego rozdrobnienie określa się pozostałością na sitach o oczkach 90 i 200 μm . W przypadku polskich węgla zaleca się zawartość ziaren $R_{90}=25-30\%$ oraz $R_{200} < 3\%$. Przy czym R_n wskazuje procentowy udział masowy cząstek pyłu pozostałych na sicie z otworami o rozmiarze n , w mikrometrach.

Pył węglowy dostarczany jest do kotła pneumatycznie pyłoprzewodami i wdmuchiwany do paleniska palnikami pyłowymi. Spalanie cząstek węgla w palenisku odbywa się wewnątrz kotła. Wyptywający z palnika pyłowego strumień mieszanki pyłowo-powietrznej miesza się z gorącymi spalinami w palenisku, następuje zapłon cząsteczek węgla i formuje się strumień pyłowy.

Umownie można wyróżnić w płomieniu pyłowym następujące odcinki: początkowy, zasadniczy i dopalania, co przedstawiono na rysunku 3.2.



Rys. 3.2. Schemat struktury płomienia pyłowego

Na odcinku początkowym następuje odgazowanie cząstek węgla i częściowe spalanie części lotnych (piroliza), dlatego ma on zasadnicze znaczenie dla stabilności płomienia pyłowego. Pył węglowy spalany jest głównie na odcinku zasadniczym i tam też powstaje większość zanieczyszczeń. Wypalenie pozostałości koksowej, a więc zawartość części palnych w popiele lotnym, zależy przede wszystkim od warunków spalania w końcowej części płomienia (głównie od temperatury i udziału tlenu w spalinach). Przyjmuje się, że poza odcinkiem początkowym, proces spalania cząstek węgla w płomieniu pyłowym odbywa się bez wzajemnych oddziaływań.

Spalanie pyłu węglowego to złożony, trójwymiarowy, ciepło-przepływowy proces, w którym występuje wiele sprzężonych ze sobą zjawisk fizycznych

i chemicznych. Z powodu trudnych warunków, panujących w palenisku pyłowym ich diagnoza jest ograniczona. Stąd, projektowanie nowych rozwiązań palenisk czy modernizacja istniejących kotłów obarczona jest ryzykiem. Jednym ze sposobów zmniejszenia tego ryzyka jest zastosowanie modelowania, obejmujące podejścia oparte na modelowaniu fizycznym i matematycznym.

Modelowanie fizyczne polega na opracowaniu modeli fizycznych na zasadach prawdopodobieństwa, których działanie pozwala wnioskować o obiekcie. Istotną rolę odgrywają tu tzw. liczby kryterialne [88], wśród nich: Reynoldsa (Re), Eulera (Eu), Frouda (Fr), Prandtla (Pr), Schmidta (Sch), Nusselta (Nu), Damkoehlera (Da), Arrheniusa (Ar) i inne. Odzwierciedlają one znaczenie aerodynamiki, przekazywania ciepła i dyfuzji oraz kinetyki chemicznej w spalaniu.

W odniesieniu do spalania pyłu węglowego praktyczne zastosowanie znalazły dwa sposoby modelowania fizycznego:

- modelowanie gorące, polegające na zmianie skali lub na odwzorowaniu częściowym,
- modelowanie izotermiczne.

Ze względu na trudność jednoczesnego zachowania wielu liczb kryterialnych przy zmianie skali płomienia modele gorące są stosowane rzadko. Bardziej popularne są modele częściowe, ograniczone do wydzielonego fragmentu obiektu lub interesującego aspektu procesu.

Techniki modelowania izotermicznego płomieni rozwinięto w celu badania aerodynamiki palenisk [88,221]. Czynnikiem przepływającym w tych modelach jest powietrze, co umożliwia wizualizację przepływów, pomiary rozkładów prędkości, jak również wnioskowanie o szybkości mieszania w palenisku. Podstawą tego podejścia jest założenie o „automodelowym” charakterze strumieni silnie turbulentnych ($Re \geq 10^4$), implikujące podobieństwo rozkładów pędu, temperatury i koncentracji [12,221]. Duża prędkość przepływu umożliwia marginalizowanie wyporu hydrodynamicznego i ruchu wzajemnego fazy gazowej i cząstek pyłu. Z kolei, trudności w modelu izotermicznym sprawia uwzględnienie zmian pędu, wynikających z różnicy gęstości wywołanej temperaturą płomienia.

Obecnie rola modelowania fizycznego znacząco zmalała, dzięki rozwojowi tańszych i bardziej elastycznych metod modelowania numerycznego. Niemniej jednak modelowanie fizyczne stosuje się do weryfikacji założeń nowych rozwiązań czy projektów w instalacjach pilotowych lub demonstracyjnych.

Metody modelowania numerycznego spalania pyłu węglowego stanowią ważne narzędzie projektowania palenisk pyłowych. Podstawę numerycznego modelowania procesów spalania pełnią opisujące je modele matematyczne.


Modele spalania pyłu węglowego muszą uwzględniać wiele złożonych, równocześnie zachodzących, w różnym stopniu oddziałujących na siebie procesów, rozpatrywanych w dwu- lub trójwymiarowej przestrzeni. Należą do nich przede wszystkim aerodynamika przepływu i turbulencja, ruch cząstek, przekazywanie ciepła oraz kinetyka chemiczna reagowania gazów i ciała stałego. Ponadto, model powinien umożliwiać przewidywanie procesów ubocznych, jak np. powstawanie zanieczyszczeń.

3.4. Prawa fizyczne w procesach elektrociepłowni na paliwa kopalne

Proces spalania w elektrociepłowniach opalanych węglem jest bardzo złożony i obejmuje reakcje chemiczne, przepływy ciepła oraz szlakowanie.

Systematyczna analiza procesu spalania w kotłach węglowych ujawnia trzy główne czynniki wpływające na sprawność kotła. Po pierwsze, wysoki poziom szlakowania i zanieczyszczenia mogą znacznie ograniczyć szybkość przenikania ciepła przez płaszcz wodny, przegrzewacz lub inny sprzęt do wymiany ciepła. Ograniczenie żużlowania i gromadzenia się zanieczyszczeń może poprawić efektywność spalania. Po drugie, jeśli temperatura lub objętość gazu wylotowego jest zbyt wysoka, więcej ciepła zostanie utracone przez gazy wylotowe. Zatem, kontrola temperatury i objętości gazu wylotowego może pomóc w osiągnięciu wysokiej wydajności. Wreszcie, niespalony gaz lub duży udział niedopału węglowego stanowi kolejny, negatywny czynnik, wpływający na sprawność kotła. Zmniejszenie udziału niedopału może skutecznie poprawić wydajność spalania w kotle. Ma na to wpływ skład mieszanki paliwowo-powietrznej, ale także i sposób jej doprowadzania do kotła. Węgiel o określonych właściwościach dostarczany jest do młyna, skąd (sproszkowany) pył węglowy wdmuchiwany jest do komory kotła za pośrednictwem dysz palników. W palnikach następuje mieszanie pyłu węglowego z powietrzem pierwotnym.

Na rysunku 3.3 przedstawiono schemat procesu spalania w elektrociepłowni opalanej węglem.



Rys. 3.3. Schemat procesu spalania w elektrociepłowni opalanej węglem (liczby przypisane do strzałek stanowią oznaczenia punktów pomiarowych, których charakterystykę zawarto w tekście) [144]

W punkcie pomiarowym (1) oraz (2) mierzy się odpowiednio: ilość węgla dostarczanego do młyna, oraz ilość powietrza pierwotnego. Wydatek paliwa to ilość węgla w jednostce czasu i mierzony jest w punkcie (3). Pomiar szybkości przepływu mieszaniny powietrza i pyłu węglowego realizowany jest w punkcie (4). Temperaturę mieszaniny węgla i powietrza można zmierzyć w punkcie (5).

Objętość podawanego powietrza określa się w punkcie (6). Wszystkie parametry wejściowe kotła mogą być regulowane i dostrajane w systemie sterowania, bezpośrednio, np. w sterowniku PLC lub z wykorzystaniem rozproszonego układu sterowania (ang. *Distributed Control System*, DCS).

Palniki, zainstalowane w ścianie kotła dostarczają mieszaninę paliwa i powietrza pierwotnego. Z kolei, powietrze wtórne, mierzone w punkcie (7) jest stosowane do dopalania części paliwa, które nie spaliło się w warunkach redukcyjnych w niskoemisyjnym palenisku pyłowym. Przy odpowiedniej regulacji kąta nachylenia palnika w palenisku kotła można uformować pożądane zawirowania. Efektywność rozwiązania zależy od rozmieszczenia dysz, szybkości wypływu powietrza, efektywności wymieszania powietrza ze spalinami i czasu przebywania. Docelowo, większość ciepła przenika na powierzchnię płaszcza wodnego i przegrzewacze. Jednocześnie następuje przekazywanie ciepła na powierzchni przenoszenia ciepła wszystkich urządzeń wewnątrz kotła. Podczas procesu konwekcji zachodzącej wewnątrz kotła, gaz spalinowy transportuje pozostałe ciepło przez komin na zewnątrz.

Para nasycona, która jest ogrzewana w kotle, napędza turbinę z wysoką entalpią ze względu na parametry: wysoką temperaturę i ciśnienie. Punkty pomiarowe (8) i (9) mogą mierzyć charakterystykę pary nasyconej w przegrzewaczach pierwotnych i wtórnych. Nagrzewnica, ekonomizer i podgrzewacz powietrza są zainstalowane w kanale spalin, aby odzyskać część energii z ciepła odpadowego (resztkowego). Temperaturę i ciśnienie pary w nagrzewnicy można zmierzyć w punktach (10) i (11). Temperaturę wody zasilającej w ekonomizerze mierzy się w punktach (12) i (13). Temperaturę powietrza pierwotnego wewnątrz nagrzewnicy można zmierzyć w punktach (14) i (15). Gaz resztkowy wydmuchuje się przez komin, a temperaturę i ciśnienie gazu wylotowego można zmierzyć w punkcie (16). Wentylator z wymuszonym ciągiem (FD) i wentylator indukowany (ID) utrzymują prawidłowy ciąg wewnątrz kotła. Moc wentylatorów mierzy się w punktach (17) i (18). Warto zaznaczyć, że przedstawiony schemat obejmuje uproszczony przebieg procesu spalania w kotle pyłowym.

Przewodność cieplna, konwekcja i promieniowanie

Przepływ ciepła z uwzględnieniem przewodności cieplnej, konwekcji oraz promieniowania występuje w różnych sekcjach paleniska. W centralnej części komory spalania następuje wymiana ciepła z metalową powierzchnią ściennego orurowania wodnorurkowego z promieniowania cieplnego, pochodzącego od płomieni spalanej mieszanki pyłu węglowego. Następnie ciepło przenosi się na stronę wodną metalowych rur przez przewodzenie i może ono być pochłonięte przez przepływającą wodę lub mieszaninę pary i wody przez przewodzenie i konwekcję. W ścieżce spalin ciepło jest przenoszone na metalową powierzchnię przegrzewacza lub podgrzewacza. Następnie ciepło może być pochłonięte przez konwekcję. Wreszcie para wewnątrz rur przegrzewacza

lub podgrzewacza może pochłaniać ciepło przez przewodzenie i konwekcję. Klasę rozwiązań opisuje zależność:

$$\frac{\partial x}{\partial t}(\rho E) + \nabla(v(\rho E + p)) = \nabla(k_{\text{eff}}\nabla T - \sum_j h_j \vec{J}_j + (\tau_{\text{eff}} \cdot \vec{v}) + S_h), \quad (3.26)$$

gdzie E stanowi energię, ρ jest gęstością, p ciśnieniem, v prędkością, k_{eff} efektywną (skuteczną) przewodnością cieplną, J_j stanowi strumień dyfuzyjny związków chemicznych j , h_j to entalpia związków chemicznych j , τ_{eff} oznacza współczynnik lepkości przewodu spalinyowego (ang. *flue*), oraz termin S_h określa ilość ciepła pochodzącego z reakcji chemicznej i dowolnego innego zdefiniowanego źródła ciepła. Zakłada się, że wszystkie te funkcje wykorzystane w równaniu 3.26 mają pochodne odpowiednich rzędów a warunki początkowe i brzegowe zależą od stanu procesu na podstawie [221].

W równaniu 3.26 przenoszenie energii w wyniku przewodzenia jest zdefiniowane w następujący sposób:

$$q_{\text{cond}} = k_{\text{eff}}\nabla T. \quad (3.27)$$

Transfer energii w wyniku dyfuzji definiowany jest jako:

$$q_{\text{diff}} = \sum_j h_j \vec{J}_j. \quad (3.28)$$

Transfer energii z uwagi na rozproszenie lepkościowe jest zdefiniowany jako:

$$q_{\text{diss}} = \tau_{\text{eff}} \cdot \vec{v}. \quad (3.29)$$

Ponadto, w równaniu 3.26:

$$E = h - \frac{p}{\rho} + \frac{v^2}{2}, \quad (3.30)$$

gdzie entalpia wrażliwa h jest określona dla idealnego gazu jako:

$$h = -\sum_j \gamma_j h_j. \quad (3.31)$$

W równaniu 3.31, γ_j stanowi frakcję masową związków chemicznych j oraz

$$h_j = \int_{T_{\text{ref}}}^T c_{pj} dT, \quad (3.32)$$

przy czym $T_{\text{ref}} = 298,15$ K oraz c_{pj} stanowi określoną wartość pojemności cieplnej związków chemicznych j . Spalanie pyłu węglowego jest procesem nieadiabatycznym, wstępnie niemieszanym oraz całkowita entalpia tworzy energię, wyrażoną w modelu jako:

$$\frac{\partial y}{\partial x}(\rho H) + \nabla(v(\rho \vec{v} H)) = \nabla\left(\frac{k_t}{c_p} \nabla H + S_h\right), \quad (3.33)$$

gdzie ρ jest natężeniem, p jest ciśnieniem, v jest prędkością, k_t jest przewodnictwem spalin w turbulentnym spalaniu, a c_p jest określoną szybkością przenikania ciepła.

W równaniu 3.33 całkowita entalpia H jest zdefiniowana jako:

$$H = \sum_j \gamma_j H_j, \quad (3.34)$$

gdzie γ_j jest frakcją masową związków j , przy czym:

$$H_j = \int_{T_{\text{ref}}}^T c_{pj} dT + h_j^0(T_{\text{ref}}), \quad (3.35)$$

gdzie $h_j^0(T_{\text{ref}})$ jest entalpią formującą związki chemiczne j w temperaturze odniesienia T_{ref} .

Ponadto, w równaniu 3.33 źródło energii reakcji chemicznej S_h jest definiowane jako:

$$S_h = - \sum_j \frac{h_j^0}{M_j} R_j, \quad (3.36)$$

gdzie h_j^0 stanowi entalpię tworzenia substratów j , R_j jest wielkością wolumetryczną tworzenia związków chemicznych j , a M_j jest masą cząsteczkową związków j . W ściankach metalowych rur z wodą, przegrzewacza i podgrzewacza, równanie energii podaje się jako [3, 163]:

$$\frac{\partial}{\partial x}(\rho h) + \nabla(\rho \vec{v} h) = \nabla(k \nabla T) + S_h, \quad (3.37)$$

gdzie ρ jest gęstością, h entalpią, k przewodnością, T temperaturą i S_h objętościowym (wolumetrycznym) źródłem ciepła.

Współczynnik przenikania promieniowania dla materiału pochłaniającego, emitującego i rozpraszającego w pozycji r w kierunku s jest podany jako [3, 24, 144, 202, 230]:

$$\frac{dI(\vec{r}, \vec{s})}{ds} + (a + \sigma_s)I(\vec{r}, \vec{s}) = an^2 \frac{\sigma T^4}{\pi} + \frac{\sigma_s}{4\pi} \int_0^{4\pi} I(\vec{r}, \vec{s}') \phi(\vec{s}, \vec{s}') d\Omega', \quad (3.38)$$

gdzie $\vec{r}$ jest wektorem położenia, $\vec{s}$ wektorem kierunkowym, $\vec{s}'$ wektorem rozproszenia kierunkowego, s długością ścieżki, a współczynnikiem absorpcji, n współczynnikiem załamania, σ_s współczynnikiem rozproszenia, σ stałą Stefana-Boltzmanna ($5,66 \cdot 10^{-8} \text{ W} \cdot \text{m}^{-2} \cdot \text{K}^{-4}$), I to natężenie (intensywność) promieniowania, które zależy od położenia $\vec{r}$ i kierunku $\vec{s}$, T to lokalna temperatura, a ϕ stanowi funkcję fazy i Ω' kąt bryłowy.

W celu symulacji procesu promieniowania cieplnego wewnątrz kotła, w badaniach wykorzystuje się sprzężenie energetyczne i model dyskretny (DO) na podstawie [11, 144]. W modelu tym uwzględniono równanie 3.38 w kierunku $\vec{s}$ jako równanie pola.

Zatem, jest ono zapisane jako:

$$\begin{aligned} & \nabla \cdot (I(\vec{r}, \vec{s})\vec{s}) + (a + \sigma_s)I(\vec{r}, \vec{s}) = \\ & = an^2 \frac{\sigma T^4}{\pi} + \frac{\sigma_s}{4\pi} \int_0^{4\pi} I(\vec{r}, \vec{s}) \delta I(\vec{s}, \vec{s}') d\Omega', \end{aligned} \quad (3.39)$$

Równanie energii po scałkowaniu po objętości można uzyskać model sprzężenia pomiędzy energią [3,24,36,144,230]. Wówczas, model przyjmuje postać:

$$\sum_{j=1}^N \mu_{ij}^T T_i - \beta_i^T T_i = \alpha_i^T \sum_{k=1}^L I_i^k \omega_k - S_i^T + S_i^h, \quad (3.40)$$

gdzie $\alpha_i^T = k\Delta V^i$, $\beta_i^T = 16k\sigma T_i^4 \Delta V_i$, k to współczynnik absorpcji oraz ΔV stanowi objętość kontrolną. Współczynnik μ_{ij}^T oraz parametry źródła S_i^h wynikają z dyskretyzacji warunków konwekcji i dyfuzji.

Badania skupiają się na optymalizacji procesu spalania węgla, w którym pył węglowy i tlen z powietrza wchodzi do strefy reakcyjnej w oddzielnych strumieniach. W porównaniu z układem, w którym substraty są mieszane na poziomie molekularnym przed reakcją, spalanie pyłu węglowego jest układem bez wstępnego mieszania, dlatego w dalszych pracach zastosowano model (bez mieszania – tzw. *nonpremixed*), na podstawie [3, 11, 24, 144, 234].

Podstawą modelu jest to, że chwilowy stan termochemiczny pyłu jest związany z zachowaną skalarną ilością określaną jako frakcja mieszanki (ang. *mixture fraction*) f , która jest definiowana jako [3, 144, 210]:

$$f = \frac{z_i - z_{iox}}{z_{ifuel} - z_{iox}}, \quad (3.41)$$

gdzie z_i jest ułamkiem masowym dla i -tego elementu. Indeks dolny *ox* oznacza wartość strumienia utleniacza na wlocie, a indeks dolny *fuel* oznacza wartość strumienia paliwa na wlocie. Równanie transportu dla frakcji mieszanki na podstawie [3, 144, 163, 230] określono jako:

$$\frac{\partial}{\partial t}(\rho \bar{f}) + \nabla(\rho \vec{v} \bar{f}) = \nabla \left(\frac{\mu_t}{\sigma_t} \nabla \bar{f} \right) + S_m, \quad (3.42)$$

gdzie ρ jest gęstością, $\bar{f}$ jest średnią frakcją mieszanki, $\vec{v}$ jest prędkością lokalną, μ_t jest lepkością turbulentną, stała $\sigma_t = 0,85$, a stała S_m jest spowodowana wyłącznie przenoszeniem masy do fazy gazowej z cząstki pyłu węglowego.

3.5. Bilans ciepły

Ciepło jest energią, która podczas spalania jest wytwarzana i rozchodzi się różnymi drogami. W fizyce energia jest definiowana jako zdolność do wykonania pracy i wyrażona w dżulach [J]. Z kolei ciepło spalania pokazuje potencjalną ilość energii możliwej do wydzielenia podczas spalania jednostki masy danego paliwa. Wiadomo też, że o tej ilości ostatecznie zdecyduje

dostępność tlenu potrzebnego do reakcji spalania. Bilans cieplny procesu spalania w kotle można opisać równaniem 3.43:

$$Q_1 + Q_2 + Q_3 + Q_4 + Q_5 + Q_6 = 100\%, \quad (3.43)$$

gdzie: Q_1 jest ciepłem pochłanianym przez wodę i parę wewnątrz naściennego orurowania, a dalej z wodą jest przenoszone przez przegrzewacz, podgrzewacz i ekonomizer. Zawiera również ciepło odzyskane z podgrzewacza wstępnego, gdzie zimne powietrze pochłania ciepło resztkowych gazów spalinowych. Zwykle Q_1 stanowi 75% -90% całego bilansu. Jednak żużel (tzw. szlaka) gromadzący się na powierzchni przenoszenia ciepła może poważnie wpływać na ilość ciepła Q_1 . Zwiększone szlakowanie na powierzchni elementów i urządzeń do wymiany ciepła może znacznie zmniejszyć promieniowanie cieplne, odbierane z płomienia kuli ognia (centrum zawirowania grupy płomieni). Ponadto, wzmożone szlakowanie może zwiększyć blokadę w przejściu ze spalin i zmniejszyć konwekcję, w której ciepło może szybko dokonywać konwekcji na inne urządzenia przenoszące ciepło z powierzchni kuli ognia. Co więcej, szlakowanie zwiększa zużycie energii przez wentylatory wymuszone (ang. *forced draft fan*, FD) i wentylatory indukcyjne (ang. *inducted draft fan*, ID), co wpływa na obniżenie ogólnej sprawności elektrowni.

Żużel osadza się na ścianach kotła, głównie w sekcji największego promieniowania. Ze względu na dużą lepkość wytwarza warstwę cieczy. Zanieczyszczenia powstają w wyniku skroplonych składników. Q_2 to ciepło przenoszone przez spaliny wylotowe, które zawierają parę wodną, tlen, azot, dwutlenek węgla i powstałe gazy przenoszące resztkowe ciepło do atmosfery. Wyższa temperatura i większa objętość gazu wylotowego mogą powodować więcej strat ciepła resztkowego z paleniska kotła. Z drugiej strony zbyt niska temperatura gazu wylotowego może powodować zwiększoną korozję chemiczną na powierzchni urządzeń do wymiany ciepła zainstalowanych w pobliżu ujścia spalin. W pracy [144] zaproponowano rozwiązanie, w którym podejmuje się próby utrzymania dokładnej wartości temperatury i objętości gazów wylotowych poprzez kontrolę zawirowanego położenia (kuli ognia), szybkości spalin i nadmiaru powietrza. Q_3 to ciepło zawarte w łatwopalnych gazach, takich jak CO, H₂ i CH₄, które niespalone są emitowane wraz z gazami spalinowymi. W pracy [144] poprzez kontrolę prędkości, temperatury i ilości mieszaniny pierwotnego powietrza i pyłu węglowego, a także prędkości, ilości i ciśnienia powietrza wtórnego w celu utrzymania całkowitego spalania dostosowuje się położenie i temperaturę kuli ognistej. Q_4 jest ciepłem zawartym w węglu, który jest traconie wraz z niedopałem i żużlem opuszczającym kocioł. Proponowane rozwiązanie w pracy [144] stara się utrzymać mieszaninę pyłu węglowego i powietrza dłużej w położeniu paleniska oraz zachować odpowiednią temperaturę kuli ogniowej poprzez kontrolowanie prędkości zawirowań, ilości przepływu paliwa w pyłoprzewodach je doprowadzających, a także usytuowanie palników. Q_5 stanowi straty ciepła na zewnątrz kotła. Zwykle można je zmniejszyć, poprawiając warunki izolacji na zewnątrz kotła. Ma ono wartość o wiele mniejszą

niż odpowiednio Q_2 , Q_3 i Q_4 . Z kolei, Q_6 to ciepło przenoszone przez żużel, opuszczający wnętrze kotła przez jego dolną część; jest ono znacznie mniejsze niż odpowiednio Q_2 , Q_3 i Q_4 .

Dzięki odpowiedniej kontroli powiązanych parametrów wejściowych istnieje możliwość utrzymania optymalnego procesu spalania, między innymi dzięki skutecznej minimalizacji strat cieplnych określonych przez zmienne Q_2 , Q_3 i Q_4 . Z kolei, utrzymanie maksymalnego promieniowania cieplnego (konwekcji) z zawirowanych płomieni i jednoczesna minimalizacja gromadzenia się żużla i zanieczyszczeń należy do skutecznych metod maksymalizacji ciepła Q_1 . Zatem, w ich rezultacie, sprawność spalania kotła może zostać poprawiona jednocześnie w dwóch obszarach.

3.6. Bilans masy

Równania różniczkowe w pracy [175] posłużyły do opracowania zintegrowanego modelu procesu spalania w elektrowni opalanej węglem. Ma on charakter uproszczony dla założenia, że uwzględniane są pochodne zmiennych, przy braku pochodnych przestrzennych. Przegrzane gazy spalinowe są traktowane jako gazy idealne. Model bazuje na podstawach fizycznych termodynamiki w następujący sposób.

Bilans cieplny przegrzewacza, podgrzewacza, orurowania z wymiennikiem wodnym i ekonomizera w modelu podano jako:

$$Q_{in} + w_{in}h_{in} = w_{ou}h_{ou} + V \frac{d}{dt}(\rho h_{ou}), \quad (3.44)$$

gdzie Q_{in} stanowi ciepło wejściowe (J/s), w_{in} przepływ masy wlotowej (kg/s), h_{in} entalpia właściwa dla wlotów (ang. *inlet-specific enthalpy*) (J/kg), w_{ou} przepływ masy wylotowej (kg/s), przy czym h_{ou} entalpia właściwa dla wylotu (ang. *outlet-specific enthalpy*) (J/kg), ρ gęstość właściwa (kg/m³) i V objętość (m³).

Bilans masy jest podany w modelu jako:

$$w_{in} - w_{ou} = \frac{d}{dt}(\rho V). \quad (3.45)$$

Oznaczenia zmiennych w równaniu (3.45) są analogiczne jak w równaniu (3.44).

Równanie promieniowania cieplnego w modelu pochodzi z prawa Stefana-Boltzmanna, danego zależnością:

$$Q = K\theta w_g T_g^4 \frac{1}{\rho_g}, \quad (3.46)$$

gdzie: Q oznacza przepływ ciepła z promieniowania płomienia spalania (J/s), K jest współczynnikiem ($K = 0,18$), θ jest współczynnikiem kąta nachylenia strumienia paliwa z palnika (w rad, takim, że $0 < \theta < 1$), w_g to przepływ substancji wchodzących do spalania (kg/s), T_g temperatura spalin (K) i ρ_g to gęstość gazu spalinowego (kg/m³).

Równanie przenikania ciepła z gazów spalinowych do powierzchni orurowania kotła podano jako:

$$Q = Kw_g^{0,6}(T_g - T_m), \quad (3.47)$$

gdzie T_m jest temperaturą powierzchni metalowych rurek wymiennika ciepła, podobnie jak dla przegrzewaczy i podgrzewaczy (K). Definicje pozostałych zmiennych są takie same jak w równaniu 3.46. Zakłada się turbulentny przepływ spalin gazowych.

Równanie przenikania ciepła z powierzchni rur metalowych do pary wodnej jest podane jako:

$$Q = Kw_s^{0,8}(T_m - T_s), \quad (3.48)$$


gdzie T_s jest temperaturą pary (K), a definicje pozostałych zmiennych są takie same jak w równaniu 3.47. W modelu przyjęto turbulentny przepływ pary.

Ograniczeniem modelu jest brak możliwości użycia go do rozwiązywania problemów związanych ze szlakowaniem i spalaniem w kotle, ponieważ nie uwzględniono w nim żużlowania (szlakowania). Ponadto, w modelu nie uwzględniono pochodnych przestrzennych. Na przykład model ten nie może być użyty do identyfikacji rozkładu żużla w kotle, ponieważ szlakowanie ma przestrzennie rozmieszczenie na powierzchni wymiany ciepła orurowania wodnego kotła.

Turbulentny przepływ gazu spalinowego i przepływ pary

Szlakowanie występuje w promieniującej części kotła węglowego o wysokiej temperaturze i zwykle jest związane z pewnym stopniem topnienia popiołu [130,144]. W kotłach zakładów energetyki zawodowej opalanych węglem może wystąpić szlaka na orurowaniu wodnym na ścianach kotła oraz na kilku pierwszych rzędach rur przegrzewacza. Aerodynamika gazów spalinowych w procesie spalania może unosić cząstki popiołu w pobliże przenikania ciepła, a cząstki popiołu mogą przechodzić przez obszar graniczny dzięki bezwładności.

Rysunek 3.4 przedstawia obszar graniczny L_{right} , znajdujący się w pobliżu prawej strony kotła [144].



Rys. 3.4. Schemat procesu spalania i szlakowania w kotle pyłowym z palnikami naściennymi

Cząstki popiołu mogą przylegać do powierzchni rur wodnych, jeśli te cząstki lub powierzchnia są wystarczająco „lepkie”, aby pokonać energię kinetyczną nadlatujących cząstek i zapobiec ich odbijaniu od powierzchni przenoszenia ciepła [130]. Dlatego utrzymanie odpowiedniej temperatury na granicy kotła i zapobieganie stopieniu unoszonych cząstek może zmniejszyć szlakowanie. W pracy [144], w oparciu o te mechanizmy przekazywania ciepła, reakcji chemicznych i szlakowania zaproponowano nowy sposób na poprawienie wydajności kotła w elektrowniach węglowych i ograniczenie powstawania żużla.


4. Spalanie w kotłach pyłowych

Pojęcie kotłów energetycznych dotyczy najczęściej urządzeń służących do wytwarzania pary w elektrowniach i elektrociepłowniach. W przypadku Polski, dotyczy w większości kotłów pyłowych granulacyjnych, opalanych węglem kamiennym lub brunatnym o wydajności od około 30 do 460 kg/s. Grupę tę uzupełniają również nowsze rozwiązania z cyrkulacyjną warstwą fluidalną. Ponadto, udział w produkcji energii dla celów ciepłowniczych mają kotły rusztowe. Znacznie rzadziej występują kotły opalane gazem (ziemnym lub koksowniczym) oraz paliwami ciekłymi [183].

Kotły opalane węglem stanowią znaczącą grupę najpopularniejszych rozwiązań, stosowanych w jednostkach energetyki zawodowej w Polsce, jak i na świecie. Początkowo wynikało to z faktu obliczania całkowitego kosztu eksploatacji i lokalizacji elektrowni w odniesieniu do źródeł energii. Ponadto, węgiel jest paliwem dogodnym do transportu. Niemniej jednak, nowe wymagania w zakresie ochrony środowiska i zrównoważonej energetyki sprawiają, że koszty spalania węgla są wyższe ze względu na koszty i utrzymanie urządzeń do monitorowania i kontroli zanieczyszczeń [49]. Znaczna część kotłów, zainstalowanych w Polsce pracuje ponad 25 lat. Zatem, zakładany czas ich eksploatacji będzie dobiegał końca. W konsekwencji, dalsze działanie tych rozwiązań jest utożsamiane z pogorszeniem się ich sprawności i niezawodności, a w rezultacie zwiększeniem kosztów użytkowania. Należy je zastąpić jednostkami nowymi, niemniej jest to drogie przedsięwzięcie. Lepsze rozwiązanie jest przeprowadzenie ich modernizacji przy zapewnieniu obecnie wymaganych wskaźników eksploatacyjnych, jak i spełnieniu norm w zakresie ochrony środowiska. Co istotne, w kotłach opalanych węglem występują problemy, których nie mają kotły opalane gazem i olejem. Oprócz wspólnych zagrożeń, związanych ze spalaniem paliw stałych, ciekłych i gazowych, należy wziąć pod uwagę inne zagrożenia, związane z fizycznymi właściwościami węgla kamiennego, w tym wartości opałowej w MJ/kg według klasyfikacji UNECE (a w literaturze anglojęzycznej – *British Thermal Unit/ Pound, BTU/lb*), uwzględniane na etapie projektowania systemów spalania [66,168]. Zasobniki węglowe i inne zamknięte pomieszczenia muszą być zaprojektowane w taki sposób, aby zapobiec gromadzeniu się metanu, wspólnej przyczyny wybuchów oraz możliwości samoistnego spalania, powodując pożary w stosie węgla.

Kotły pyłowe (ang. *pulverized coal fired boilers*) są jednymi z najczęstszych instalacji, stosowanych w zakładach użytkowych, ponieważ stanowią znaczące ulepszenie względem klasycznych kotłów paleniskowych (ang. *stoker fired boilers*). Wynika to z dynamiki prędkości spalania w odpowiedzi na zmiany zapotrzebowania niż w przypadku kotłów paleniskowych czy kotłów ze złożem fluidalnym (ang. *fluid bed boilers*). Z drugiej zaś strony, wymagane jest w nich więcej urządzeń mechanicznych do uzyskania pyłu węglowego (młyny węglowe), które z kolei nie są potrzebne w kotłach paleniskowych.

Na rysunku 4.1 podano schemat układu dostarczania paliwa w bezpośrednio opalanym kotle pyłowym (ang. *direct fired pulverized coal boiler*).




Rys. 4.1. Schemat układu dostarczania paliwa w bezpośrednio opalanym kotle pyłowym

Jest to przykład uproszczony, nieuwzględniający np. układu odcinania paliwa. Układ taki powinien być zaprojektowany do pracy ciągłej, ponieważ w trakcie rozruchu, wygaszania czy awarii kotła, mogą wystąpić eksplozje i pożary.

Alternatywny schemat, przedstawiony na rysunku 4.2, uwzględnia dodatkowo układy sterowania palnikiem (ang. *burner management system*, BMS) oraz podstawowy układ sterowania (ang. *basic process control system*, BPCS), mimo że podstawowa jego logika działania nie uległa zmianie.


Ilość i sposób rozmieszczenia grup palników są określone przez producenta kotła. W przypadku braku korelacji pomiędzy poszczególnymi palnikami roboczymi, może nastąpić utrata płomienia. Jest to sytuacja niekorzystna i wprowadza czynnik zagrożenia. Zatem, powinny istnieć automatyczne mechanizmy temu przeciwdziałające. Dotyczy to także zapobiegania osadzaniu się pyłu węglowego w pyłoprzewodach palnika oraz niekontrolowanego zapłonu paliwa. Realizowane jest to przez równoważenie wydajności palników w grupie i sterowanie prędkością powietrza pierwotnego. Niniejsza wartość prędkości powietrza pierwotnego jest ustalona przez producenta kotła i weryfikowana

testami. W przypadkach awaryjnych, gdy poziom powietrza transportowego nie może być utrzymany – system sterowania uwzględnia dodatkowo zabezpieczenie temperaturowe (patrz rysunek 4.2). Temperatura mieszaniny powietrza i węgla opuszczająca palnik utrzymywana jest w granicach określonych przez producenta, odpowiednio dla rodzaju węgla. Z kolei sam proces ogrzewania węgla usuwa z niego wilgoć i poprawia sprawność kotła.



Rys. 4.2. Schemat układu dostarczania paliwa w kotle pyłowym z systemami sterowania palnikami BMS

Rysunek 4.3 przedstawia poglądowy schemat sterowania układem z kotłem pyłowym. Posiada on krzyżowe ograniczenie (ang. *cross limiting/lead lag*), ponieważ wprowadzono opóźnienie, wykorzystywane w celu utrzymania właściwego stosunku mieszanki paliwowo-powietrznej. Warto podkreślić, że kotły pyłowe są bardziej złożone niż pokazano na schemacie. Wynika to z ich specyficznych parametrów, między innymi takich jak liczba palników i przepustowość.



Rys. 4.3. Schemat klasycznego układu sterowania kotłem pyłowym [57]

Niemniej jednak, mimo istniejących różnic technicznych, strategia sterowania jest na ogół zbliżona. Podobnie jak w większości rozwiązań komercyjnych, w klasycznych układach wykorzystuje się sterowanie różniczkujące (ang. *derivative control*), oparte na ciśnieniu wyjściowym kotła (ang. *boiler drum pressure*). Wówczas, działanie różniczkujące oparte jest na zmiennej procesu, a nie na uchybie. Wynika to stąd, że cyfrowa wersja algorytmu PID działa tak, że wywołuje duże niepożądane piki przy zmianie wartości zadanej. W przypadku stałej wartości zadanej, zmiany zmiennej procesowej będą analogiczne do zmian uchybu. Dlatego też taka modyfikacja, nie wprowadza dużych zmian pod względem sposobu, w jaki regulator odpowiada na zakłócenia procesu. Działanie zmodyfikowanego regulatora PID (znanego też jako regulator PI-D – tzn. różniczka działa tylko na zmienną procesu) można wówczas opisać wzorem:


$$MV(t) = k_r \left(\varepsilon(t) + \frac{1}{T_i} \int_0^t \varepsilon(\tau) d\tau + T_d \frac{d}{dt} PV(t) \right), \quad (4.1)$$

gdzie: k_r to wzmocnienie regulatora PID, T_i – czas zdwojenia członu całkującego, T_d – czas wyprzedzenia członu różniczkującego, $\varepsilon(t)$ to uchyb regulacji $MV(t)$ oznacza zmienną mierzoną a $PV(t)$, zmienną procesu.

Tego rodzaju sygnał sterujący w tzw. *sprężeniu w przód* (ang. *feedforward*) zapewnia lepszą odpowiedź czasową na sygnał wejściowy, opisujący podawanie paliwa. W jej rezultacie pojawia się tzw. czas martwy (ang. *dead time*) pomiędzy zmianą zapotrzebowania a zmianą szybkości podawania węgla.

Przepływ pary również stanowi sygnał sprzężony w przód, wpływający na ciśnienie na wyjściu kotła i może poprawiać jakość sterowania.

Ponadto, jako parametry procesu wykorzystuje się sterowanie prędkością oraz położeniem przepustnicy (ang. *damper*) wentylatora FD (rysunek 4.4).



Rys. 4.4. Zależności nadmiaru tlenu oraz tlenku węgla dla różnych obciążeń kotła [57]

Zwiększa to efektywność regulacji przepływu powietrza, związaną z sygnałem z wyjścia analizatora O_2 . Niektóre systemy regulacji dodatkowo uwzględniają sygnały z pomiarów substancji palnych (ang. *combustibles*). Przy czym należy zaznaczyć, że takie sterowanie wnosi ryzyka, ze względu na ograniczony zakres potencjalnego sterowania i zbyt wolny (długi) czas reakcji analizatorów substancji palnych względem dynamiki procesu.

Zasobnik węgla i podajnik

Zasobnik surowca dostarcza węgiel do podajnika. Z kolei, podajnik dostarcza węgiel do młyna, który rozdrabnia węgiel na drobny proszek (tzw. miał/pył węglowy).

Sterowanie procesem spalania w dużym uogólnieniu można sprowadzić do sterowania parametrami wejściowymi w postaci prędkości podawania paliwa i powietrza roboczego. Do transportu pyłu węglowego wykorzystuje się powietrze pierwotne. Gorące powietrze pierwotne usuwa część balastu w postaci wilgoci z węgla i dostarcza powietrze do komory spalania. Ze względów bezpieczeństwa należy zapobiegać gromadzeniu się pyłu węglowego w kanałach powietrznych

oraz przeciwdziałać ewentualnemu cofnięciu się gazów z kotła do palników i instalacji.

Popularną grupę kotłów energetycznych stanowią wodnorurkowe kotły opromieniowane z opalaniem pyłem węglowym paleniskiem komorowym. Do komory spalania za pomocą palników dostarczana jest mieszanka pyłowo-powietrzna i powietrze wtórne. W jej wnętrzu, ulegają zapłonowi i spaleniu, niesione w przepływie cząstki pyłu węglowego. W tradycyjnych rozwiązaniach na paliwo kopalne, paleniska kotłowe były projektowane na tzw. paliwo projektowe [107], którego charakterystyczne parametry (m.in. udział substancji mineralnej, udział części lotnych, podatność przemiałowa i charakterystyka szlakowania) uwzględniane były w urządzeniach i konstrukcji kotła. Wymogi ekologiczne, w tym współspalanie biomasy, stwarza nowe problemy związane z zapewnieniem odpowiedniej jakości spalania.

Okres spalania mieszanki pyłowo-powietrznej w komorze paleniskowej kotła dzielony jest na trzy etapy:

- suszenie, odgazowanie i zapłon cząstek węglowych (0,2–0,3 s),
- intensywne spalanie mieszanki pyłowo-powietrznej (0,5–1,5 s) na drodze 1,5 m z wytworzeniem jądra płomienia o temperaturze 1500–1600 °C,
- dopalanie grubych cząstek węgla i schładzanie spalin w czasie 1–3 s na długości 2/3 komory spalania.

Charakterystyczną cechą różniącą płomień pyłowy od płomienia gazowego czy rozpylonego oleju jest brak możliwości jego istnienia w otwartej przestrzeni. Jest to spowodowane znacznie mniejszą prędkością propagacji turbulentnego płomienia pyłowego (2–3 m/s) od prędkości wypływu mieszanki z palnika (12–20 m/s). Stabilność płomienia pyłowego w technice kotłowej zapewniana jest głównie przez recyrkulację gorących spalin. W zależności od rodzaju zastosowanych palników; recyrkulacja wewnętrzna dla palników wirowych oraz recyrkulacja zewnętrzna, w przypadku palników strumieniowych. Palniki wirowe zalecane są do kotłów pyłowych mniejszej i średniej wydajności, w których na wypalenie węgla ma wpływ wczesny zapłon i stabilizacja płomienia. W przypadku kotłów dużej wydajności bardziej istotne są czynniki wpływające na tzw. aerodynamikę paleniska kotłowego, jak: geometria komory paleniskowej, konfiguracja palników i prędkość strumieni wprowadzanych do paleniska.

Typowe komory paleniskowe kotłów pyłowych mają przekrój kwadratowy, prostokątny, sześciokątny lub ośmiokątny. Ściany komory paleniskowej tych kotłów tworzą blisko siebie ułożone rury parownika, tzw. ekrany [107, 176]. Ekrany odbierają ciepło od płomienia poprzez promieniowanie, skąd pochodzi nazwa *kocioł opromieniowany*. Warto zaznaczyć, że za zapewnienie stabilności płomienia pyłowego oraz odpowiednie wypalenie paliwa odpowiedzialne jest palenisko kotłowe.

Paleniska pyłowe dzieli się ze względu na sposób:

- umieszczenia palników:
 - z palnikami naściennymi,
 - z palnikami stropowymi,
 - z palnikami narożnymi,
- mieszania powietrza:
 - wirowe (mocowane naściennie),
 - strumieniowe (mocowane narożnie lub tangencjalnie i stropowo).

We współczesnych kotłach pyłowych dominują dwa rodzaje palenisk z suchym odprowadzaniem żużlu: z palnikami wirowymi, mocowanymi naściennie oraz z palnikami strumieniowymi, mocowanymi narożnie lub tangencjalnie.

Palniki wirowe są rozmieszczane na ścianie przedniej, naprzeciwlegle na ścianie przedniej i tylnej kotła oraz naprzeciwlegle na wszystkich ścianach kotła. Niepożądanymi konsekwencjami umieszczania palników wirowych na ścianie przedniej kotła są trudności z zapłonem oraz zwiększone żużłowanie ściany tylnej [107, 226]. Rozmieszczenie naprzeciwległe umożliwia pewny zapłon, intensywne spalanie, mniejsze żużłowanie i bardziej równomierny rozptył płomieni w komorze paleniskowej, umożliwiające efektywniejsze przekazywanie ciepła. Ograniczenie (zmniejszenie) niedopału zapewnia mieszanie strumieni z wielu palników, a wzajemne oddziaływanie zawirowanych płomieni zapewnia stabilność spalania.

W praktyce wykorzystywane są również własności aerodynamiki palenisk tangencjalnych, gdzie palniki strumieniowe mocowane są na trzech lub czterech poziomach narożnie lub tangencjalnie. Podejście takie pozwala na kształtowanie wiru z wykorzystaniem strumieni mieszanki pyłowo-powietrznej oraz powietrza wtórnego, wprowadzanego do paleniska kotłowego mimośrodowo względem jego osi. Ze względu na specyfikę konstrukcji palników strumieniowych, powietrze wtórne wpływa między dyszami mieszanki pyłowo-powietrznej jako niezawirowane. W konsekwencji płomień z takich palników jest znacznie dłuższy niż z palników wirowych. Dodatkowo, podsysanie spalin z otoczenia i intensywne przekazywanie ciepła z wydłużonego płomienia pyłowego obniżają jego temperaturę. Zatem, tangencjalny układ paleniska zapewnia stabilność płomienia poprzez zjawisko wzajemnego podtrzymywania się spalania przez stykające się płomienie pyłowe. Wypełniający palenisko centralny wir stabilizuje przepływ spalin i intensyfikuje przekazywanie ciepła. Cechy palenisk pyłowych naściennych i tangencjalnych zestawiono w tabeli 4.1

Tabela 4.1. Porównanie cech palenisk pyłowych

	Palenisko pyłowe z naściennym mocowaniem palników wirowych	Palenisko pyłowe typu tangencjalnego
Zalety	– Stabilny płomień z pojedynczego palnika, – Pewny zapłon mieszanki pyłowej, – Szybkie mieszanie pyłu węglowego z powietrzem wtórnym, – Znaczne wypalenie w pobliżu palnika, – Możliwość stabilnej pracy kotła ze zmniejszonym obciążeniem.	– Dobre mieszanie ze spalinami w komorze paleniskowej, – Łatwe stopniowanie powietrza, – Zapewnienie ochrony parownika przed korozją wysokotemperaturową, – Wyrównana temperatura spalin na wylocie z komory paleniskowej.
Wady	– Trudności z zapłonem, – Intensywne żużłowanie tylnej ściany kotła.	– Skłonność do żużłowania – Mniejsza intensywność spalania względem czołowego rozmieszczenia palników.
Rodzaj paliwa	– Węgiel kamienny	– Węgiel brunatny i płomienny węgiel kamienny

W konwencjonalnych paleniskach pyłowych węgiel kamienny spala się przy wartości współczynnika $\lambda = 1,2 \div 1,25$, natomiast brunatny – z nadmiarem powietrza większym o 10÷15%. Objętościowe obciążenie cieplne kotłów pyłowych zawiera się w zakresie 120÷185 kW/m³, natomiast temperatura w palenisku pyłowym zależy od typu spalanego paliwa i dla węgla brunatnego wynosi 1200÷1250 °C, a dla kamiennego – 1400÷1650°C [107].

Inżynieria sterowania (ang. *Control Engineering*) w nowoczesnych systemach technologicznych odgrywa fundamentalną rolę. Wraz z dostępem do nowoczesnych technologii, obejmujących digitalizację i metody sztucznej inteligencji wchodzi w nowy wymiar rozwiązań. Korzyści z układów sterowania w przemyśle mogą być wielorakie, w tym: poprawa jakości produktu, zwiększenie efektywności energetycznej (obniżenie zużycia energii), minimalizacja odpadów, podniesienie poziomu bezpieczeństwa czy redukcja emitowanych zanieczyszczeń. Warto jednak zaznaczyć, że zaawansowane aspekty z zakresu inżynierii sterowania wymagają dobrych podstaw matematycznych, opisujących takie cechy układu jak dynamika, stabilność, jakość sterowania oraz obserwowalność, sterowalność czy krzepkość. Na podstawie [40, 46, 61, 162] sukces układu (systemu) sterowania zależy od następujących czynników: posiadania wystarczającego rozumienia sterowanego systemu oraz posiadania wiedzy z zakresu podstawowych pojęć: sygnałów, systemów, teorii sterowania, struktur, algorytmów itp. Z kolei, do wyznaczników i ograniczeń projektu systemu sterowania procesem przemysłowym należą wymogi opłacalności ekonomicznej, jakości, bezpieczeństwa, wpływu na środowisko itp. Można zauważyć, że stanowi

on rezultat współpracy ekspertów z różnych dziedzin od technologii procesu, IT, mechaniki, oprzyrządowania i pomiarów czy sterowania. Przy czym każdy ze specjalistów widzi proces z innej (zwykle własnej) perspektywy. Zatem projektant układu (systemu) sterowania powinien reprezentować podejście holistyczne (całościowe), integrujące inne punkty widzenia. Warto również podkreślić rolę kosztów w projekcie układu sterowania. W projektach niekomercyjnych (badawczych i edukacyjnych) często nie stanowią czynnika pierwszoplanowego. Niemniej jednak, w przypadku rozwiązań komercyjnych jest to jeden z kluczowych czynników pomyślnego wdrożenia. Do niedawna w przypadku podsystemów, będących elementami większych układów stosowano rozwiązania jak najprostsze, umożliwiające szybką interwencję: przeprogramowanie, pracę w trybie ręcznym lub wymianę sterownika. Duża dynamika rozwoju i złożoności współczesnych technologii przesunęła ciężar jakościowy do symulacji, szybkiego przeprogramowania układu z wykorzystaniem tzw. „cyfrowych bliźniaków” oraz przez zapewnienie rozwiązań modułarnych i redundantnych.

Algorytm sterowania (na ogół zapisany w sterowniku lub kontrolerze) podejmuje decyzje o realizacji pewnych zadań (celu) sterowania, na podstawie informacji zebranych z otoczenia.

Do zadań stawianych systemowi sterowania należą: śledzenie trajektorii wektora wejściowego sygnału referencyjnego, redukcja wpływu niepożądanych warunków (obejmujące niwelację zakłóceń niemierzalnych oraz niewrażliwość na zmiany parametrów obiektu), zapewnienie parametrów jakości sterowania.

Dodatkowo, dla rozwiązań przemysłowych, stawiane są wymagania inżynierskie względem układu sterowania. Zalicza się do nich koszty opracowania i wdrożenia układu sterowania, złożoność obliczeniowa (na ogół związana z doбором sterownika dla którego nie zostaną przekroczone wymagania pracy w czasie rzeczywistym), wykonalność (wymagania sprzętowe zastosowania sterownika), niezawodność (zapewnienie ciągłości pracy układu), utrzymanie i konserwacja, adaptowalność (rozumiana jako skalowalność na inne układy), modyfikowalność (otwartość systemu na wprowadzanie nowych funkcji), zrozumiałość (klarowność ogólnych mechanizmów funkcjonowania układu), zgodność z polityką firmy (oparta na analizie ryzyka) [46, 162].

W pracy podjęto próbę opracowania algorytmu sterowania procesem spalania z uwzględnieniem powyższych czynników z wykorzystaniem wybranych metod, rozwiązań i technologii.


Zaproponowane rozwiązania zweryfikowano przy pomocy narzędzi obliczeniowych i symulacyjnych z wykorzystaniem danych pomiarowych z rzeczywistych obiektów zarejestrowanych przez zespół badawczy Instytutu Elektroniki i Technik Informacyjnych Politechniki Lubelskiej.

5. Modelowanie i symulacja elementów instalacji współspalania pyłu węglowego i biomasy

W nowoczesnej elektrowni, automatyzacji podlega znacząca liczba działań kontrolnych, potrzebnych do obsługi procesu. Do zalet automatyzacji należy redukcja błędów ludzkich w utrzymaniu instalacji, ze względu na potrzebę zapewnienia większego bezpieczeństwa personelu, zmniejszenie liczby operatorów potrzebnych do obsługi instalacji w celu obniżenia kosztów pracy. Zautomatyzowane układy zapewniają większą dokładność i szybkość reakcji na zmiany punktu pracy. Uogólniając, istnieją dwie podstawowe funkcje kontrolne, używane w układach: sterowanie włączaniem i wyłączaniem oraz sterowanie modulacją. Pierwsze z nich jest określane jako sterowanie cyfrowe, sterowanie dyskretnie lub sterowanie sekwencyjne. Sterowanie modulacją nazywa się kontrolą analogową, regulacją ciągłą lub regulacją w pętli zamkniętej. W układach automatyki oba te rodzaje sterowania uzupełniają się wzajemnie i są niezbędne dla prawidłowego funkcjonowania zakładu. W gruncie rzeczy, dzięki aparatowi matematycznemu, komputeryzacji, nowym rodzajom czujników i metod pomiarowych pozyskuje się duże ilości danych o poszczególnych stanach oraz elementach procesu i opracowuje nowe algorytmy i techniki, których celem jest szybkie, precyzyjne, a przede wszystkim bezpieczne sterowanie obiektem.

Proces spalania jest bardzo złożony, nieliniowy o dużej dynamice. Stąd w praktycznych algorytmach diagnostyki i sterowania pożądane są modele szczegółowe oraz jednocześnie niezłożone obliczeniowo. Opracowanie modelu holistycznego (całościowego) tak skomplikowanego zjawiska stanowi bardzo trudne wyzwanie. Z tego powodu, na ogół dokonuje się podziału na modele mniejsze, opisujące pewne podukłady czy moduły ze względu na realizowane funkcje czy konkretne zadania. Niewątpliwą zaletą modularności jest uproszczenie analizy i walidacji zaproponowanych rozwiązań.

Na rysunku 5.1 przedstawiono uogólniony schemat blokowy układu z kotłem pyłowym, z uwzględnieniem jego poszczególnych podsystemów.



Rys. 5.1. Uogólniony schemat blokowy układu z kotłem pyłowym


Instalacje energetyki składają się z wielu podsystemów obejmujących: dostarczanie paliwa, wody, układ sterowania kotłem (komorą spalania), system bezpieczeństwa kotła (komory spalania), układ wytwarzania pary, układ turbiny i układ generatora.

Punktem wyjścia dla opracowania klasycznych modeli matematycznych jest opis zjawisk fizycznych i fizyko-chemicznych danego układu z użyciem zasady zachowania energii, bilansu cieplnego czy równowagi masowej [127].

W pracy skoncentrowano się głównie na podsystemie optymalizacji spalania w kotle i sterowania kotłem. Przy opracowaniu modeli matematycznych wykorzystano opisy podstawowych zjawisk fizycznych jak zasada zachowania energii, zachowania momentu, zachowania masy. Ponadto, dodatkowo użyto alternatywne metody, uwzględniające sztuczne sieci neuronowe i sieci głębokie (gęste). Do modelowania wykorzystano popularne narzędzia symulacyjne w postaci platformy MATLAB/Simulink oraz język Python (wraz z bibliotekami numpy, pandas, Keras i TensorFlow). Oprogramowanie to jest używane powszechnie i stosowane zarówno w analizach przemysłowych, jak i badaniach naukowych.

5.1. Opracowanie modelu sterowania kotłem

Schemat blokowy kotła z paleniskiem, parownikiem, (ang. *riser/vaporizer/evaporator*), walczakiem (ang. *drum*), przegrzewaczem (ang. *superheater*), i dozownikiem (ang. *attemparator*), i podgrzewaczem (ang. *reheater*) z parametrami wejściowymi i wyjściowymi połączonymi w pętle procesu układu kotła przedstawiono na rysunku 5.2 [144, 175].



Rys. 5.2. Schemat blokowy układu sterowania układem spalania z kotłem pyłowym

Palenisko, określane również komorą spalania dostarcza ciepło do układu przekazywania ciepła. Czas, temperatura oraz przebieg turbulentny stanowią trzy główne parametry, niezbędne do tego, aby spalanie pyłu węglowego mogło zachodzić w palenisku kotła ze zrównoważonym ciągiem.

Na rysunku 5.3. zamieszczono model paleniska, uwzględniającego następujące równania, sygnały wejściowe, parametry, stany oraz sygnały wyjściowe:

$$\left\{ \begin{array}{l} h_{EG} = \frac{x_{F1}}{\rho_{EG}} \\ T_g = \frac{h_{EG} - h_{ref}}{c_{pg}} + T_{ref} \\ w_{EG} = k_F p_G \\ Q_{ir} = \theta k V_F \sigma T_g^4 \\ Q_{is} = (1 - \theta) k V_F \sigma T_g^4 \\ Q_{gs} = Q_{is} + k_s w_{EG}^4 (T_g - T_{st}) \\ T_{gr} = T_g + \frac{1}{c_{gs} w_{EG}} (Q_{is} - Q_{gs}) \\ Q_{rs} = k_{rs} w_{EG}^{0.6} (T_{ge} - T_{rh}) \\ Q_{es} = k_{es} w_{EG}^{0.6} (T_{ge} - T_{et}) \\ T_{g1} = T_{ge} - \frac{1}{c_{gs} w_{EG}} Q_{es} \\ y = 100(w_A + \gamma_{WG} - w_F R_S) \frac{1}{w_F R_S} \end{array} \right. , \quad (5.1)$$

Przy czym równania różniczkowe:

$$\left\{ \begin{array}{l} \frac{d}{dt} x_{F1} = \frac{1}{V_F} [C_F w_F + h_A w_A + h_G w_G - Q_{ir} - Q_{is} - w_{EG} R_S \left(1 + \frac{\gamma}{100}\right) h_{EG}] \\ \frac{d}{dt} \rho_{EG} = \frac{1}{V_F} [w_F + w_A + w_G - w_{EG}] \end{array} \right. , \quad (5.2)$$

gdzie sygnały wejściowe to odpowiednio:

w_F – przepływ paliwa do paleniska [kg/s],

w_A – przepływ powietrza do powierzchni [kg/s],

h_G – entalpia spalin z turbiny parowej [J/kg],

w_G – przepływ spalin z turbiny parowej [kg/s],

θ – współczynnik kąta nachylenia [$0 < \theta < 1$] rad,

T_{st} – temperatura elementów metalowych przegrzewacza (superheater) [K],

T_{rh} – temperatura elementów metalowych podgrzewacza (reheater) [K],

T_{et} – temperatura elementów metalowych ekonomizera [K],

h_A – entalpia powietrza wejściowego [J/kg].

Parametry:

k – współczynnik wzmocnienia,

k_F – współczynnik tarcia [$\text{m}\cdot\text{s}$],

K_{gs} – eksperymentalny współczynnik przenikania ciepła do przegrzewacza (superheater) [$\text{J}/(\text{kg}\cdot\text{K})$],

c_{gs} – wydajność cieplna gazu spalania [$\text{J}\cdot\text{s}/(\text{kg}\cdot\text{K})$],

k_{rs} – eksperymentalny współczynnik przenikania ciepła do podgrzewacza (reheater) [$\text{J}/(\text{kg}\cdot\text{K})$],

V_F – pojemność komory spalania [m^3],

C_F – wartość kaloryczna paliwa [J/kg],

R_s – stechiometryczny stosunek powietrze / paliwo (λ),

γ – zawartość świeżego powietrza w spalinach z turbiny parowej,

k_{es} – eksperymentalny współczynnik przenikania ciepła do ekonomizera [$\text{J}/(\text{kg}\cdot\text{K})$].

Stany:

$X_{F1} h_{EG} \times \rho_{EG}$ [J/m^3],

ρ_{EG} gęstość spalin z kotła [kg/m^3].

Wyjścia:

Q_{ir} – ciepło przekazywane do pionów (risers) [J/s],

Q_{is} – ciepło przenoszone przez promieniowanie do przegrzewacza (superheater) [J/s],

Q_{rs} – ciepło przekazywane do podgrzewacza (reheater) [J/s],

Q_{es} – ciepło przekazywane do ekonomizera (economizer) [J/s],

p_G – ciśnienie powietrza w kotle [Pa],

Q_{gs} – całkowite ciepło przekazane do przegrzewacza (superheater) [J/s],

h_{EG} – entalpia spalin z kotła [J/s],

w_{EG} – masowy przepływ spalin z kotła [kg/s],


T_g – temperatura gazu w przegrzewaczu (superheater) [K],

T_{g1} – temperatura spalin w kotle [K],

y – procent nadmiaru powietrza [%].

Na jego podstawie opracowano ogólny model sterowania kotłem z wykorzystaniem oprogramowania MATLAB/Simulink [144].

Na rysunku 5.3 przedstawiono bloki reprezentujące poszczególne podukłady modelu elektrowni opalanej węglem.




Rys. 5.3. Zintegrowany model procesu spalania w elektrowni opalanej węglem w programie Simulink, środowiska MATLAB [144]

Poszczególne podukłady opracowano w oparciu o równania matematyczne, opisujące zależności fizyczne opisujące funkcjonowanie kotłów [175].

5.2. Modelowanie komory spalania

Palenisko (ang. *furnance*), określane również komorą spalania (ang. *combustion chamber*), uwalnia energię z paliwa w postaci ciepła, będącą początkiem układu przenoszenia ciepła. Czas, temperatura i turbulencje (zawirowania) to trzy główne parametry potrzebne do spalania. Ponadto, w komorze spalania należy utrzymać ujemne podciśnienie, podczas sterowania kotłem [136, 144].

Rysunek 5.4 przedstawia opracowany model komory spalania, uwzględniający równania, sygnały wejściowe, parametry, stany i sygnały wyjściowe wskazano w pracy [175].



Rys. 5.4. Schemat lokalnych pętli sterowania kotłem i powiązane wejścia i wyjścia.

6. Wykorzystanie sztucznych sieci neuronowych oraz głębokich sieci neuronowych w modelowaniu procesu spalania

W dobie ustawicznego rozwoju komputeryzacji, naturalną konsekwencją jest rosnąca ilość danych, zawartych w nich informacji oraz poszukiwanie wśród nich złożonych zależności. Niedosięgniętą protoplastą tego rodzaju systemów cyfrowych jest biologiczny mózg. Próby odtwarzania zasad jego funkcjonowania zawarto w grupie algorytmów nazywanych *sztucznymi sieciami neuronowymi SSN* (ang. *Artificial Neural Networks, ANN*) [45, 54, 105, 106, 170, 177, 178, 220]. Pierwsze ich implementacje znalazły zastosowania w analizie danych, z kolei każda kolejna generacja umożliwia rozwiązywanie coraz to bardziej złożone problemy.

Ze względu na silne nieliniowości, złożoność oraz dużą dynamikę procesu spalania w praktycznych algorytmach diagnostyki i sterowania pożądane są modele szczegółowe oraz jednocześnie niezłożone obliczeniowo. Metody heurystyczne, pozwalają na efektywne znajdowanie rozwiązań przybliżonych, na podstawie których później wylicza się ostateczny rezultat. Ograniczeniem tych rozwiązań jest brak pośredniej wiedzy o stanie (wnętrzu) modelu oraz brak wiedzy o odpowiedzi modelu neuronowego dla niestandardowego zakresu sygnałów wejściowych.


Sztuczne sieci neuronowe stosowano w algorytmach przemysłowych między innymi w pracach: [6, 105, 106, 113, 211, 220].

Dynamiczny rozwój algorytmów głębokiego uczenia doprowadził do nowych prób wykorzystania sieci neuronowych w różnych obszarach. Rezultaty w zakresie analizy danych są obiecujące i skupiają uwagę wielu grup badawczych [1, 36, 60, 62–64, 120, 153, 171].

6.1. Sztuczne sieci neuronowe

Szereg problemów badawczych i inżynierskich, w tym rozpoznawanie twarzy, mowy, przetwarzanie cech języka naturalnego nie można rozwiązać z zadowalającą skutecznością przy pomocy algorytmów algebraicznych. Te klasy problemów nie sprawiają trudności biologicznemu mózgowi człowieka. Sztuczne sieci neuronowe imitują jego działanie, poczynając od struktury neuronu, który jako podstawowa jednostka obliczeniowa otrzymuje sygnał wejściowy od dendrytów i wytwarza sygnał wyjściowy, wysyłając go pojedynczym aksonem. Poprzez synapsy, akson jest podłączony do dendrytów kolejnych neuronów mając możliwość przekazywania sygnału dalej. Intensywność jaką każda synapsa przekazuje sygnał ma charakter zmienny i jest przyswajalna podczas uczenia. Wszystkie sygnały przekazane przez dendryty do neuronu są sumowane wewnątrz komórki. Jeśli suma jest większa od pewnego progu, to do aksonu wysyłany jest impuls elektryczny. Zakładając, że dokładny czas poszczególnych impulsów jest nieistotny i korzystając tylko z częstotliwości ich generowania, można modelować ten sygnał statyczną funkcją aktywacji [99].

Na rysunku 6.1 zamieszczono budowę pojedynczego neuronu oraz jego model matematyczny.



Rys. 6.1. Schemat poglądowy budowy sztucznego neuronu

Ten wzorec działania neuronu formalizuje zależność (6.1):

$$y = f\left(\sum_{i=1}^N w_i u_i - \theta\right), \quad (6.1)$$

gdzie: sygnał wyjściowy neuronu y jest ważoną sumą N sygnałów wejściowych u_i oraz progu aktywacji (ang. *bias*) θ , przekształconą przez funkcję aktywacji f .

Sieci neuronowe są modelowane jako kolekcje neuronów połączonych w acykliczny graf skierowany. Wyjścia części neuronów stają się wejściami kolejnych neuronów, zazwyczaj zorganizowanych w oddzielne warstwy. Każda warstwa jest w pełni połączona z sąsiadującymi, tzn. każdy neuron z danej warstwy jest połączony z każdym neuronem warstw sąsiadujących, ale nie jest połączony z żadnym neuronem własnej warstwy. Neurony z warstwy wejściowej rozdzielają jedynie sygnały wejściowe do warstwy ukrytej, bez ich przetwarzania. Oznaczając wartość połączenia synaptycznego pomiędzy i -tym neuronem a j -tym z następnej warstwy jako w_{ij} i stosując model neuronu (6.1) można zapisać:

$$\forall 1 \leq k \leq K \quad y_k = f_k\left[\sum_{j=1}^H w_{jk} f_j\left(\sum_{i=1}^P w_{ij} u_i - \theta_j\right) - \theta_k\right], \quad (6.2)$$

gdzie $-\theta_k$ stanowią wagi dla wejść o stałej wartości równej 1, a f_k są funkcjami aktywacji.

Sieć, w której występują wszystkie możliwe połączenia określana jest *siecią w pełni połączoną*. Często nie wszystkie połączenia występują w sieci (posiadają wagi zerowe). Do takiej sytuacji prowadzi *oczyszczanie sieci*.

Wprowadzając notację $w_{0j} = -\theta_j$, $u_0 = 1$, oraz przyjmując, że $j \rightarrow k$ oznacza indeksy neuronów połączonych do neuronu o indeksie k , wówczas (6.2) daje się zapisać jako:

$$\forall 1 \leq k \leq K \quad y_k = f_k\left[\sum_{j \rightarrow k} w_{jk} f_j\left(\sum_{i \rightarrow j} w_{ij} u_i\right)\right]. \quad (6.3)$$

Dowolna funkcja ciągła może być aproksymowana w sensie jednostajnym na zwartym zbiorze przez nierekurencyjną sieć neuronową z jedną warstwą ukrytą. Wynika to z twierdzenia o uniwersalnym aproksymatorze [1, 124] bazującym na twierdzeniu Stone’a–Weierstassa [167, 177], który opisuje zależność:

$$\forall u \in \mathbb{K} |g(u) - f_{NN}(u)| < \epsilon, \quad (6.4)$$

gdzie $g: \mathbb{R}^P \rightarrow \mathbb{R}$, $\mathbb{K} \in \mathbb{R}^P$, a $f_{NN}(u)$ reprezentuje sieć neuronową z jedną warstwą ukrytą i sigmoidalną funkcją aktywacji oraz liniową funkcją aktywacji w warstwie wyjściowej.

Zwyczajowo nazywa się taką sieć perceptronem wielowarstwowym (ang. *Multi Layer Perceptron, MLP*). Warstwy sztucznej sieci neuronowej dzieli się na:


- wejściową – przechowującą dane dostarczone do sieci,
- ukrytą – przetwarzającą informacje,
- wyjściową – przechowującą wyniki sieci.

W literaturze [45, 105, 170, 177, 220] termin sieć n -warstwowa oznacza sztuczną sieć neuronową o n warstwach ukrytych. Zanim sztuczna sieć neuronowa będzie mogła realizować określone zadania, wcześniej należy ją do tego przygotować, stosując wybrane algorytmy uczenia.

6.2. Głębokie uczenie

Głębokie uczenie (ang. *deep learning*) jest działem uczenia maszynowego, związanym z algorytmami modelującymi abstrakcje wysokich poziomów w dostępnych danych, korzystając z wielu warstw nieliniowych transformacji. Z założenia kolejne poziomy tworzą hierarchię cech od najmniej do najbardziej abstrakcyjnych.

Głębokie sieci neuronowe (ang. *Deep Neural Networks*) są najbardziej popularną grupą algorytmów głębokiego uczenia (rysunek 6.2) [60].



Rys. 6.2. Model ilustrujący głęboką sieć neuronową o dużej liczbie warstw

Miara najdłuższej ścieżki pomiędzy neuronem wejściowym a wyjściowym definiuje *głębokość architektury sieci neuronowej*. W sieciach przesyłających sygnał w przód (ang. *feedforward*) przekłada się to wprost na liczbę warstw. Nie istnieje graniczna liczba warstw, od której można nazwać sieć głęboką. Uważa się, że sieć posiadająca powyżej dwóch warstw ukrytych jest już siecią głęboką, jednak wraz z rozwojem coraz większych sieci ta granica może zostać przesunięta.

Większość problemów, do rozwiązywania których stosuje się uczenie maszynowe posiada hierarchiczne struktury danych. Struktury te można opisać przy pomocy sieci jednowarstwowej, co dowodzi twierdzenie o uniwersalnej aproksymacji, jednak płaska reprezentacja nie jest ani zwięzła, ani łatwa do nauczenia [79].

Głębokie sieci neuronowe, inspirowane działaniem mózgu, starają się nauczyć struktury danych, co znacznie ułatwia wnioskowanie. Kolejne warstwy rozpoznają coraz bardziej złożone obiekty, bazując na abstrakcji reprezentowanej przez poprzednie warstwy. Nie znaczy to jednak, że głębokie sieci neuronowe można zastosować do rozwiązania każdego problemu. Atutem głębokich sieci neuronowych jest także automatyczna ekstrakcja cech. W klasycznych algorytmach uczenia maszynowego, zespół ekspertów w danej dziedzinie zastosowania algorytmu musiał określić metodę wydobywającą najbardziej informatywne oraz nieredundantne cechy posiadanych danych. Dopiero wówczas, bazując na tych informacjach, przeprowadzano uczenie algorytmu. Głębokie sieci neuronowe potrafią nauczyć się wybierać najistotniejsze cechy danych bez udziału ekspertów. Mimo, że koncepcje głębokich sieci neuronowych opracowano w latach siedemdziesiątych ubiegłego wieku, na ich obecne upowszechnienie miały wpływ takie czynniki jak zwiększenie mocy obliczeniowej współczesnych komputerów (CPU i GPU), upowszechnienie Internetu, niwelacja problemów przetrenowania oraz zanikającego gradientu. Ważną rolę odegrały również prace Yanna LeCuna na temat sieci konwolucyjnych [121] oraz pomysł Geoffreya Hinton na wstępne uczenie, tzw. pretrenowanie (ang. *pre-training*) [73] głębokich sieci neuronowych przy użyciu Ograniczonych Maszyn Boltzmanna (ang. *Restricted Boltzmann machine, RBM*) [75]. Ustawicznie rośnie liczba prac badawczych jej dotyczących, owocując coraz skuteczniejszymi metodami treningu (uczenia), dla coraz większych modeli.

Uczenie głębokich sieci neuronowych

Sztuczna sieć neuronowa może wykonywać określone zadanie pod warunkiem, że zostanie wcześniej wytrenowana. W tym celu należy najpierw wyznaczyć funkcję kosztu reprezentującą popełnione przez nią błędy. Następnie, uczenie (trening) sieci polega na minimalizacji błędów metodami gradientowymi optymalizacji statycznej. W ramach uczenia maszynowego można wyróżnić kilka form nauki, zależnie czy sieć ma nauczyć się wnioskować na podstawie opisanych danych, czy też wnioskować bazując na ukrytej strukturze danych

nieetykietowanych. Dzieli się je na uczenie nadzorowane (ang. *supervised learning*) i nienadzorowane (ang. *unsupervised learning*). W pierwszym przypadku pożądany rezultat treningu jest dostarczany wraz z danymi wejściowymi, a wyznaczony błąd pomiędzy uzyskanym i docelowym rezultatem pozwala wyliczyć korektę do zaktualizowania jej wag. Podczas uczenia nienadzorowanego, sztucznej sieci neuronowej podawane są wyłącznie dane wejściowe, a sieć sama musi odkryć strukturę dostarczonych danych. Istotne są wówczas informacje pozwalające zrozumieć rozkład danych wejściowych jak najniższym kosztem. Za odrzucanie nieistotnych informacji w tego typu algorytmach odpowiadają tzw. wąskie gardła (ang. *bottleneck*).

Modyfikację uczenia nadzorowanego, w której zamiast docelowych danych wyjściowych sieć otrzymuje wskaźnik jakości dla otrzymanego rozwiązania, określa się mianem uczenia ze wzmocnieniem (ang. *reinforcement learning*). W trakcie uczenia wykorzystuje się funkcję kosztu (ang. *loss function*), która określa miarę błędów popełnionych przez sieć. Często, dla zadań regresji liniowej, koszt opisywany jest średnią kwadratów różnic (ang. *mean square error*) między pożądanymi rezultatami oraz wnioskowanymi przez sieć. Z kolei zadania klasyfikacji dyskretnej wykorzystują średnią entropii krzyżowej (ang. *cross entropy*). Ponadto obydwa podejścia posiadają modyfikacje, stosujące sumy w miejsce średnich.

Wśród terminów związanych z uczeniem sztucznych sieci neuronowych odgrywa uogólnioną regułą delta oraz wsteczna propagacja błędu. Reguła delta to opis zastosowania metody gradientu prostego do aktualizacji wag i odpowiednio progu aktywacji j -tego neuronu:

$$w_{ij} \rightarrow w'_{ij} = w_{ij} - \eta \frac{\partial \mathcal{L}}{\partial w_{ij}}, \quad \theta_j \rightarrow \theta'_j = \theta_j - \eta \frac{\partial \mathcal{L}}{\partial \theta_j}, \quad (6.5)$$

gdzie η określana jest współczynnikiem uczenia (ang. *learning rate*), a jej wartość ma wpływ na zbieżność optymalizacji (minimalizacji) i powinna być odpowiednio dobrana do architektury sieci.

Reguła delta korzysta z funkcji kosztu jako miary błędu popełnianego przez neuron. Jest to istotne w przypadku sieci jednowarstwowej lub ostatniej warstwy sieci wielowarstwowej. Dla sieci wielowarstwowej należy określić jaki wpływ miał dany neuron na otrzymany błąd. Służy do tego algorytm wstecznej propagacji (ang. *backpropagation*), w ramach którego błąd otrzymany w warstwie ostatniej jest przenoszony (propaguje) do warstw wcześniejszych. Przy zachowaniu reguły aktualizacji wag (patrz zależność 6.5), pochodna cząstkowa $\frac{\partial \mathcal{L}}{\partial w_{ij}}$ jest określana przez regułę łańcuchową pochodnych funkcji złożonych [1, 170]. W rezultacie, na podstawie reguły delta wyznaczana jest zmiana wag warstwy ostatniej, a następnie obliczany jest wpływ przedostatniej warstwy na błędne wagi warstwy ostatniej. Na ich podstawie aktualizowane są wagi warstwy przedostatniej oraz odpowiednio wcześniejszych, aż do obliczenia korekty wag warstwy pierwszej.

Przy bardzo dużych zbiorach danych treningowych, wyliczenie wartości funkcji kosztu i na tej podstawie aktualizacje wag sieci z użyciem klasycznej metody gradientu prostego (ang. *batch gradient descent*) jest mało efektywne. Powstały zatem modyfikacje, wśród których należy wyróżnić *Stochastic Gradient Descent (SGD)* oraz *Mini-Batch Gradient Descent*. Pierwsza z nich estymuje gradient wyłącznie na podstawie jednego przykładu ze zbioru treningowego, a druga – na podstawie małego zbioru treningowego. Drugie rozwiązanie jest stabilniejsze. Przy czym w obydwu wariantach kluczowy jest wybór podzbioru w sposób losowy. Usprawnieniem metod gradientu jest uwzględnienie w bieżącej – ostatniej dokonanej zmiany wagi. Jest to tzw. *reguła momentum*, która ma bezpośredni wpływ na stabilizowanie zbieżności minimalizacji, niwelując zjawisko zygzakowania [164,170]. Opisuje ją zależność:

$$\forall \zeta \in (0; 1) \Delta w'_{ij} = \eta \frac{\partial \mathcal{L}}{\partial w_{ij}} + \zeta \Delta w_{ij}, \quad (6.6)$$

gdzie parametr ζ stanowi intensywność wpływu momentum.

W procesie uczenia sztucznej sieci neuronowej wszystkie neurony otrzymują analogiczny wektor danych wejściowych, ale ze względu na inny zestaw wag – uzyskują różne wartości wyjściowe. Wykorzystuje się tu metodę łamania symetrii (ang. *breaking symmetry*), aby przeciwdziałać uzyskaniu mocno skorelowanych wartości na każdym neuronie danej warstwy. Bardzo ważne jest wylosowanie początkowych wartości wag z małego zakresu, takiego, aby złamać symetrię z jednej strony, ale także by nie doprowadzić sieci do stanu, którego trudno będzie ją oduczyć. Ma to kluczowe znaczenie w przypadku sieci głębokich, ponieważ intensywność sygnału maleje podczas przejść przez kolejne warstwy dla zbyt małych wag. Z kolei, dla zbyt dużych wag – intensywność sygnału rośnie przechodząc przez kolejne warstwy, co także zmniejsza jego przydatność. W pracach [20, 21] podjęto wnikliwą analizę efektywnego doboru początkowych wartości wag.

Trening sztucznej sieci neuronowej opisują własności, takie jak:

- **pojemność** (ang. *capacity*) – określająca możliwości modelowania przez sieć zależności występującej w danych;
- **niedotrenowanie** (ang. *underfitting*) – wskazująca, że użyto nieadekwatny model, o niewystarczającej pojemności do skomplikowanej struktury danych. Korygowana przez zwiększanie pojemności modelu;
- **przetrenowanie** (ang. *overfitting*) – dotyczy nadmiernego dopasowania modelu do danych treningowych, gdzie poza istotną strukturą przyswaja szum. Przeciwdziała temu zmniejszenie modelu oraz ograniczenie jego możliwości poprzez regularyzację.

Regularyzacja obejmuje grupę metod regulujących (ograniczających) pojemność sztucznych sieci neuronowych w trakcie treningu. Najbardziej powszechną formą jest regularyzacja **L2**. Dzięki dodaniu kary do funkcji kosztu, wagi o większej wartości od pozostałych stają się bardziej równomiernie rozłożone. Podejście regularyzacji **L1** sprawia, że neurony korzystają wyłącznie

z najistotniejszych wejść i uniezależniając od szumu w pozostałych. W przypadku, gdy współczynnik uczenia jest zbyt duży, tzw. „eksplozji wag” przeciwdziała regularyzacja **max-norm**. Wyznacza ona górną granicę wartości wektora wag każdego neuronu, a następnie, jeżeli wartość graniczna zostaje przekroczona – skaluje ten wektor w dół.

Bardzo skuteczną techniką regularyzacji jest **dropout**, która dzięki nakładaniu binarnej maski na wartości wyjściowe każdej warstwy, umożliwia losowe pomijanie pewnych neuronów w trakcie treningu [74] :

$$y'_n = \frac{r_n * y_n}{p}, \quad (6.7)$$

gdzie: y_n – wektor wyjść dla części p neuronów warstwy poddanej treningowi, r_n – maska binarna, inna dla każdej warstwy i generowana przy każdej propagacji wprzód wyznaczana, zgodnie z:

$$r_n \sim \text{Bernoulli}(p). \quad (6.8)$$

Metoda *dropout* pozwala prezentować te same informacje kolejnym warstwom w różnych formach, usprawniając wnioskowanie. Alternatywnie, można ją traktować jako szum dołączony do informacji na wszystkich warstwach sieci, która zachowuje tylko istotne informacje, nie zdegradowane przez szum.

W trakcie treningu sztucznej sieci neuronowej wsteczna propagacja błędów zależy od gradientu funkcji aktywacji. Jego zbyt mała wartość ogranicza propagację i ostatecznie prowadzi do zanikomych zmian w wagach neuronów warstw początkowych. Ze względu na fakt, że neurony wyższych warstw wnioskuje na podstawie warstw niższych, to trening całej sieci jest bezcelowy, jeżeli te drugie nie potrafią się nauczyć. Stanowi to problem *zanikającego gradientu* i aby go uniknąć stosuje się nienadzorowany trening wstępny. Stosując algorytm zachłanny, każda z warstw ukrytych podlega treningowi. Nie aktualizuje się wag w już przetrenowanych warstwach. Pozwala to na uzyskanie lepszego dopasowania względem losowej inicjalizacji. Opcjonalnie, wykorzystuje się dotrenowanie (ang. *finetuning*) wag zainicjalizowanych przez pre-trening do rozwiązania konkretnego problemu. Chociaż w przypadku ograniczonych zbiorów danych nadal stosuje się pre-trening, to dla bardzo dużych ilości danych rezygnuje się z fazy trenowania wstępnego, wykorzystując regularyzację dropout oraz funkcje aktywacji ReLU.

Dobór funkcji aktywacji ma istotny wpływ na przebieg uczenia sztucznej sieci neuronowej. Jej rola polega na określeniu w jakim stopniu dany neuron jest pobudzany docierającymi do niego wartościami.

Podstawowe funkcje aktywacji zestawiono w tabeli 6.1.

Tabela 6.1. Zestawienie wybranych funkcji aktywacji sztucznych sieci neuronowych

Funkcja aktywacji	Opis matematyczny	Charakterystyka
liniowa	$f(x) = ax$	Najprostsza funkcja, powoduje niestabilną zbieżność modelu podczas nauki. Nieodpowiednia dla sieci wielowarstwowych.
progowa	$f(x) = \begin{cases} a, & x \geq 0 \\ 0, & x < 0 \end{cases}$	Nieciągłość i zerowy gradient ogranicza możliwości uczenia modelu.
sigmoidalna	$f(x) = \sigma(x) = (1 + e^{-x})^{-1}$	Popularna w klasycznych SSN. Stanowi ciągłe przybliżenie funkcji progowej. Dla zbyt dużych wag początkowych większość neuronów nasycą się i nie uczą. Implikuje zjawisko zygzakowania podczas optymalizacji modelu.
tangens hiperboliczny	$f(x) = \tanh(x) = 2\sigma(x) - 1$	Jest przeskalowaną funkcją sigmoidalną, korygując koncentrację wokół zera wyjścia neuronów o tej funkcji aktywacji.
Softplus	$f(x) = \sum_{i=1}^{\infty} \frac{1}{1 + e^{-(x-i+0,5)}} \approx \ln(1 + e^x)$	Stanowi aproksymację wielu sigmoid przesuniętych względem siebie na osi OX.

Tabela 6.2 (c.d.). Zestawienie wybranych funkcji aktywacji sztucznych sieci neuronowych

Funkcja aktywacji	Opis matematyczny	Charakterystyka
ReLU	$f(x) = \max(0, x)$	<i>Rectified Linear Units</i> stanowią przybliżenie funkcji Softplus przez proste progowanie w zerze. Zagrożenie metody polega na nieodwracalnym zerowaniu wag neuronu. Problem ten ogranicza się małą wartością współczynnika uczenia.
Leaky ReLU	$f(x) = \max(ax, x)$	Zmodyfikowana wersja ReLU o małym, dodatnim gradiencie ($a \approx 0,01$), pozwalającym opuścić stan nieodwracalny z ReLU.
Softmax	$f(x)_j = \frac{e^{x_j}}{\sum_{k=1}^K e^{x_k}}, j = 1 \dots K$	Znormalizowana funkcja wykładnicza, która jest uogólnieniem funkcji sigmoidalnej. Transponuje K – wymiarowy wektor wartości rzeczywistych do K - wymiarowego wektora wartości z przedziału $(0; 1)$, którego wartości sumują się do 1. Wartość $f(x)_j$ reprezentuje prawdopodobieństwo przynależenia wartości wejściowej do klasy j .

Głębokie sieci neuronowe (ang. *Deep Neural Networks, DNN*) mogą być różnego typu. Do najpopularniejszej grupy należą **głębokie MLP** (ang. *Deep Multilayer Perceptrons, DMP*), z wieloma warstwami ukrytymi.

Głębokie sieci przekonań (ang. *Deep Belief Networks, DBN*) stanowią probabilistyczne modele generatywne, składające się z wielu stochastycznych warstw zawierających ukryte zmienne. Najwyższe dwie warstwy zawierają nieskierowane (dwukierunkowe), symetryczne połączenia pomiędzy ich neuronami. Niższe warstwy mają połączenia z wyższą warstwą.

Maszyna Boltzmanna (ang. *Boltzmann machine, BM*) stanowią sieci dwuwarstwowe o symetrycznych połączeniach pomiędzy neuronami tych warstw.

Restrykcyjna Maszyna Boltzmanna (ang. *Restricted Boltzmann Machine, RBM*) to specjalny rodzaj maszyny Boltzmanna, zawierającej warstwę widocznych węzłów oraz warstwę węzłów ukrytych.

Sieci głębokich stert (ang. *Deep Stacking Networks, DSN*) wykorzystują zarówno dane wejściowe, jak i wyjściowe do dalszej adaptacji w kolejnych warstwach sterty sieci. Specyficzne w nich jest to, że poszczególne podsieci na stercie sieci uczone są osobno.

Zastosowania głębokich sieci neuronowych

W pracy [167] zaproponowano i uzasadniono użycie statycznych i dynamicznych sztucznych sieci neuronowych w przód (ang. *feedforward*) i rekurencyjnych na potrzeby identyfikacji i sterowania nieliniowych układów niskiego rzędu oraz z ograniczonym wyjściem. Parametry sieci były dostrajane z wykorzystaniem algorytmu dynamicznej wstecznej propagacji (ang. *dynamic back-propagation*). Główną wadą tego podejścia było założenie, że tego rodzaju sieci były stabilne, a utworzone przez nie modele były sterowalne, obserwowalne i identyfikowalne.

Z kolei, w pracy [166] wykazano, że sztuczne sieci neuronowe były szczególnie efektywne przy identyfikacji i sterowaniu wielowymiarowych, złożonych układów dynamicznych wysokiego rzędu.

W pracy [237] podjęto próbę połączenia statycznej sieci ze sprzężeniem w przód oraz dynamicznej, rekurencyjnej do postaci modelu Hammersteina. Celem takiego podejścia było opracowanie zautomatyzowanej identyfikacji dla nieznanego modelu. Główny ciężar tego rozwiązania sprowadzono do ostrożnego doboru wag początkowych i progów, co z kolei wykazano w pracy [250]. W rezultacie, dzięki uniknięciu problemu nasyconych warstw aktywacji uzyskano lepszą zbieżność (w porównaniu z losową inicjalizacją parametrów sieci).

Odpowiednio optymalizowana funkcja kosztu odwzorowuje funkcje niskowymiarowe na przestrzeń wyjściową. Czas i wysiłek poświęcony na staranny dobór wag inicjalizacji (między innymi z użyciem takich metod jak symulowane wyżarzanie czy algorytmy genetyczne) w gruncie rzeczy komplikują i utrudniają trening sieci. Co więcej, wbrew założeniom utrudniają uogólnianie przygotowanych struktur na nowe zestawy danych, ponieważ najlepsze wagi początkowe muszą być dobierane odrębnie dla każdego nowego problemu. Podobnie, w rekurencyjnych sztucznych sieciach neuronowych, czasowa zależność parametrów sieci, obliczanych na podstawie poprzednich macierzy wag, powoduje wzrost gradientów lub ich zanikanie, proporcjonalnie do wykładnika liczby poprzednich kroków czasowych [16]. Nasycenie neuronów w warstwie ukrytej także znacząco wydłuża czas treningu.

Samoorganizujące się sztuczne sieci neuronowe zaproponowane przez LeCuna [121], w połączeniu z głębokimi architekturami, pozwalają na określenie wewnętrznej struktury, odpowiednie dla zadania estymacji nieliniowej (uczenia się). LeCun wykazał, że tradycyjne metody projektowania (ang. *hand-coded*) cech dla systemów rozpoznawania można zastąpić treningiem modułów z inteligentnymi składnikami (ang. *component-wise modules*), które razem współpracują w celu optymalizacji globalnego kryterium wydajności.

Rekurencyjne sieci neuronowe (RNN) są modelowane na podstawie zachowania występujących w naturze wielu komórek z pamięcią o adresowalnej treści (ang. *content-addressable memory*), zdolną do przechwytywania całej sekwencji informacji, podanej w formie fragmentów. Podczas gdy sieci „w przód” uruchamiają swoje neurony w jednym kierunku, RNN wykorzystują silne sprzężenie zwrotne $U \rightleftharpoons H \rightleftharpoons Y \rightleftharpoons U$ tak, że sygnały mogą przepływać asynchronicznie między węzłami, nawet gdy sygnał węzła jest opóźniony. Architektura prostej RNN jest podobna do architektury MLP, z wyjątkiem istnienia samoindukcji neuronów w warstwie (warstwach) ukrytej (patrz rysunek 6.2).

RNNs modelują nieliniowe układy dynamiczne, których dynamika przestrzeni fazowej jest określona przez znaczną liczbę lokalnie stabilnych węzłów, do których jest stosowany [78]. Ukryte węzły $h = (h_1, \dots, h_N)$ i węzły wyjściowe $y = (y_1, \dots, y_N)$ są określone przez zapętlenia wśród równań:

$$\begin{aligned} h_k &= \mathcal{H}(W_{uh}u_k + W_{hh}h_{k-1} + b_h) \\ y_k &= W_{hy}h_k + b_y \end{aligned} \quad (6.9)$$


Dla $k = 1 \dots N$, gdzie W oznacza macierze wag, b reprezentuje wektoryzowane progi, a $\mathcal{H}$ jest funkcją warstwy ukrytej, danej jako operator Hadamarda.

Kryterium straty stanowi skumulowaną stratę w każdym kroku, a gradienty są obliczane przez propagację wsteczną w czasie (ang. *backpropagation through time*, BPTT [195, 242]), przy czym parametry są aktualizowane po ukończeniu pełnej sekwencji przejść w przód i wstecz lub rekurencyjnym uczeniem w tzw. *czasie rzeczywistym* (ang. *real-time recurrent learning*, RTRL).

Podczas długoterminowego zapamiętywania kontekstu, gradienty RNN mogą stać się trudne do usunięcia, ponieważ wykorzystują one swoje sprzężenia zwrotne do zapamiętania struktury ostatnich wejść (pamięć krótkotrwała w porównaniu z pamięcią długoterminową). Podobnie, propagujące wstecznie sygnały błędów w czasie mogą mieć wysokie wartości (powodując oscylacje wag) lub zanikać (utrudniając wyznaczanie wag wolno zmiennych) o zasięgu w jakim ewolucja w czasie propagowanych wstecznie błędów zależy expotencjalnie od rozmiaru wag [16, 34].

W pracy [34] zaproponowano rozwiązanie *długiej pamięci krótkotrwałej* (ang. *Long Short Term Memory*, LSTM), które uogólniając, odcina gradienty w sieci, wszędzie, gdzie jest to nieszkodliwe, jednocześnie wymuszając ciągłe przepływy błędów poprzez tzw. *constant error carousels* ciągłe karuzele błędów w specjalnych jednostkach multiplikatywnych (ang. *multiplicative units*, MU). Stały przepływ błędów jest regulowany przez nieliniowe MU, które uczą się otwierać lub zamykać bramki w komórce.

Dlatego LSTM przybliżają informacje długoterminowe ze znacznymi opóźnieniami, szybciej rozwiązując algorytmy RNN.



Rys. 6.3. Model bloku struktury Long Short-Term Memory (LSTM):
a) uproszczony, b) szczegółowy

Dla komórki LSTM z N jednostkami pamięci, za każdym razem (dla każdego interwału czasowego), ewolucja ich parametrów określana jest następująco:

$$\begin{cases} i_t = \sigma(W_{ui}u_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_{ii}) \\ f_t = \sigma(W_{uf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_{if}) \\ z_t = \tanh(W_{uc}u_t + W_{hc}h_{t-1} + b_c) \\ c_t = f_t \odot c_{t-1} + i_t \odot z_t \\ o_t = \sigma(W_{uo}u_t + W_{ho}h_{t-1} + W_{co}c_{t-1} + b_{io}) \\ h_t = o_t \odot \tanh(c_t) \end{cases}, \quad (6.10)$$

gdzie terminy W_{uq} i W_{hq} są odpowiednio prostokątnymi macierzami sygnałów wejść i kwadratowymi rekurencyjnymi macierzami wag, W_{cq} są szczelinowymi wektorami wagowymi (ang. *peephole weight vectors*) od komórki do każdej z bramek (patrz rysunek 6.3), σ określa sigmoidalne funkcje aktywacji (stosowane adekwatnie do elementów), a równania i_t , f_t i o_t oznaczają odpowiednio bramki wejściowe, zapominania i wyjściowe; z_t jest wejściem do komórki c_t . Wyjście komórki LSTM stanowi o_t , a $\odot$ oznaczają punktowe iloczyny wektorowe. Warunki początkowe dla bramek są inicjowane dużymi wartościami na początku treningu, aby umożliwić uczenie się w długim okresie [171, 217]. Bramka zapominania (ang. *forget gate*) ułatwia resetowanie stanu LSTM, podczas gdy połączenia szczelinowe (ang. *peephole connections*) z komórki do bramek umożliwiają dokładne uczenie w czasie.

7. Suboptymalna struktura sterowania obiektem złożonym (na przykładzie procesu spalania)

Ze względu na zaporowe (wysokie) koszty inwestycyjne na wdrażanie rozwiązań opartych na metodach wtórnych, mogą sobie pozwolić wyłącznie nieliczni producenci energii.

Przy wytwarzaniu energii opartym głównie na spalaniu węgla kamiennego, brunatnego oraz współspalaniu biomasy, dużo uwagi poświęca się metodom pierwotnym. Szacunki mówią, że innowacyjne technologie oparte na metodach pierwotnych pozwolą spełnić rygory emisyjne (w ramach dyrektyw IIPC – *Integrated Pollution Prevention and Control* oraz LCP – *Large Combustion Plants*) przy połowie kosztów odpowiadających metodom redukcji katalitycznej [201].

Do istotnego aspektu ekologicznego, przeciwwagę stanowią obciążenia związane z kosztami oraz trudności i opóźnienia w uzyskiwaniu pozwoleń również w kontekście nowych inwestycji. Zatem istotnym zagadnieniem w obliczu zaistniałej sytuacji jest stosunkowo niedroga redukcja tlenków azotu (NO_x). Liczne publikacje [107, 108, 201], konferencje i sympozja naukowe, poruszają problemy niskoemisyjnych technik spalania.

Złożoność, nieliniowość procesu spalania, występujące opóźnienia i zakłócenia oraz kwestie bezpieczeństwa większość dyskutowanych i wdrażanych rozwiązań ma przeważnie charakter modernizacyjny. Zgodnie z [108], podstawowe środki jakie ma do dyspozycji konstruktor niskoemisyjnych systemów spalania ograniczają się do: obniżania temperatury spalania, rozdziału powietrza, stopniowanie paliwa (aerodynamika spalania i reburning) oraz uwzględnienie redukujących właściwości bogatego płomienia.

Systemy łączące technologie oraz różnego rodzaju procesy technologiczne stwarzają korzystne warunki, wynikające ze zmniejszonej emisji CO_2 , odpowiedzialnej za globalne ocieplenie klimatu. Spośród wszystkich paliw kopalnych, podczas spalania występuje emisja CO_2 . W celu niwelacji (ograniczania) niepożądanych emisji stosowane są również nowoczesne technologie takiej, jak:

- spalanie wysokotemperaturowe,
- spalanie w obecności tlenu,
- odzysk ciepła (kaskady ciepła i wykorzystanie ciepła niskotemperaturowego),
- spalanie katalityczne.

Metody te jednak są możliwe do realizacji praktycznie wyłącznie w nowych, specjalnie projektowanych obiektach i instalacjach.

W pracujących obiektach, dotychczasowe modernizacje, wykorzystują zaawansowane technologie, związane z zastosowaniem nowej generacji palników niskoemisyjnych oraz stopniowaniem powietrza w ramach systemów OFA. Alternatywą lub uzupełnieniem niniejszych usprawnień technologicznych mogą być technologie wspierające (optymalizujące) sterowanie procesem.

7.1. Proekologiczne sterowanie procesem spalania pyłu węglowego

Możliwość oceny jakości spalania według [107] jest bardzo ważna dla właściwej pracy kotła energetycznego. W przypadku spalania w warstwach przepływowych istotny wpływ na jego przebieg mają: reakcje chemiczne, efektywność przekazywania ciepła, stabilność płomienia oraz powstawania NO_x i CO. Źródła literaturowe [107,108,244] podają, że największy wpływ na formowanie aerodynamiki spalania mają palniki oraz rodzaj i sposób podawania paliwa.

Niskoemisyjne palniki pyłowe wykorzystują redukcyjne właściwości bogatego płomienia pyłowego przez organizację stref spalania podstechiometrycznego z wykorzystaniem stopniowania powietrza lub stopniowanie paliwa. Z kolei stopniowanie powietrza lub paliwa w palnikach pyłowych może pogorszyć stabilność spalania i zwiększyć stratę niedopału.

Uwzględniając te czynniki oraz istotne aspekty ekologiczne, zarysowuje się potrzeba opracowania systemu sterowania procesem spalania, który będzie optymalizował pracę kotła na podstawie informacji uzyskanych z konwencjonalnego oprzyrządowania oraz uwzględni innowacyjne techniki pozwalające na ocenę jakości procesu.


Od strony technologicznej, istotnym parametrem jest zapewnienie stabilności płomienia oraz wykrywania stanów awaryjnych. Stąd, układ sterowania powinien być uzupełniony o informację diagnostyczną o płomieniu z wykorzystaniem technologii wizyjnych lub sond światłowodowych. Równie istotne znaczenie mają ilościowe informacje odnośnie stężeń tlenków azotu, tlenków węgla oraz dwutlenku siarki w celu spełnienia ograniczeń normatywnych.

Trudny w określeniu, ale przynoszący cenną informację o parametrach wejściowych procesu jest ciągły pomiar przepływu pyłu w pyłoprzewodach. Podobnie, ale na wyjściu procesu, kluczowe byłoby pozyskanie informacji w trybie on-line na temat zawartości części palnych w popiele i żużlu (zwłaszcza zawartości węgla organicznego).

Niewątpliwie pozyskanie tego rodzaju informacji wymaga z jednej strony możliwości przeprowadzenia pomiarów na rzeczywistym obiekcie. Natomiast z drugiej strony – wykorzystania kosztownej aparatury pomiarowej.

7.2. Stanowisko badawcze

Badania przeprowadzono na stanowisku doświadczalnym Instytutu Energetyki w Warszawie do badań procesu spalania o mocy cieplnej 0,5 MW z wykorzystaniem palnika pyłowego. Schemat stanowiska w konfiguracji do badania procesu współspalania przedstawiono na rysunku 7.1.



Rys. 7.1. Schemat ilustrujący stanowisko do badania procesów spalania


Główny element stanowiska stanowi cylindryczna komora spalania, której wewnętrzna część wyłożona jest materiałem izolacyjnym, a zewnętrzna chłodzona jest powietrzem. Przednia ściana komory spalania jest chłodzona wodą. W osi ściany przedniej zainstalowano palnik pyłowy. Do wygrzania stanowiska oraz zapalenia paliwa pyłowego użyto pomocniczy palnik olejowy, instalowany w osi palnika pyłowego lub w płycie czołowej (zależnie od konstrukcji palnika pyłowego). Do palnika pyłowego doprowadzone jest powietrze pierwotne w ilości 250 m³N/h oraz wtórne – do 500 m³N/h.

Przygotowane paliwo pyłowe, obejmujące zmielony węgiel oraz biomasę lub ich mieszaninę zasypywane jest do bunkra paliwowego, skąd podajnik dostarcza je do linii powietrza pierwotnego.

Układ umożliwia prowadzenie badań procesów spalania dla zróżnicowanych parametrów. Jego niewątpliwą zaletą jest bardzo dobre opomiarowanie, w tym elastyczna instalacja różnego rodzaju czujników, co w przypadku obiektów przemysłowych jest trudne bądź niekiedy wręcz niemożliwe.

Do komory spalania może być doprowadzone powietrze dopalające przez trzy dysze OFA (ang. *OverFire Air*), z niezależnie regulowanymi wydatkami i temperaturami powietrza.

Na rysunku 7.2 przedstawiono komorę spalania z zainstalowanym oprzyrządowaniem.



Rys. 7.2. Stanowisko do badania procesów spalania o mocy 0,5MW (a) lewa strona komory, (b) prawa strona z zainstalowanym optycznym oprzyrządowaniem pomiarowym

Stanowisko badawcze wyposażone jest w system kontrolno-pomiarowy, umożliwiającą wizualizację i rejestrację wielu parametrów pracy stanowiska, w tym: przepływy czynników, temperatury i ciśnienia w różnych częściach instalacji oraz skład spalin.


7.3. Wykorzystanie przetwarzania obrazu w procesie spalania pyłu węglowego i biomasy

Emitowane przez płomień promieniowanie jest odbiciem zachodzących w procesie spalania reakcji chemicznych i procesów fizycznych. Optyczne metody diagnostyczne, oprócz akustycznych, [71, 215, 231] należą do najważniejszych metod, które w bezinwazyjny sposób pozwalają na otrzymanie praktycznie nieopóźnionej i dodatkowo selektywnej przestrzennej informacji o zachodzącym procesie spalania. Na podstawie widma emisyjnego płomieni, w zakresie promieniowania widzialnego, możliwe jest m.in. określenie wartości stosunku powietrze-paliwo, ilości wydzielanego ciepła i temperatury [148, 192].

Wśród metod optycznych, szczególnego znaczenia nabierają metody wykorzystujące przetwarzanie obrazu. Pozorne nieruchome położenie płomienia jest wynikiem równowagi dynamicznej pomiędzy lokalną prędkością propagacji płomienia a prędkością napływającej mieszanki paliwowej [82, 87]. Zmiana położenia frontu płomienia w przestrzeni, postrzegana jako zmiana kształtu płomienia, jest wynikiem zakłócenia tej równowagi. Pozwala to przyjąć, że kształt płomienia może być wskaźnikiem stanu procesu spalania, zachodzącego w określonych warunkach [10, 82].

Testy spalania mieszany pyłu węglowego i biomasy zostały przeprowadzone na stanowisku pomiarowym, omówionym w rozdziale 7.2. Obraz płomienia


z wnętrza komory spalania przekazywany był na zewnątrz dzięki boroskopowi wyposażonemu w odpowiedni system chłodzenia. Boroskop umieszczono pod kątem 45 stopni względem osi palnika w taki sposób, aby analizowany obraz obejmował obszar płomienia w bezpośrednim sąsiedztwie palnika. Podczas testów zmieniano warunki stechiometryczne, w jakich zachodził proces spalania dzięki regulacji wydatku powietrza wtórnego. Powodowało to dodatkowo zmiany prędkości wylotu mieszanki pyłowo-powietrznej doprowadzając do stanu bliskiego zanikowi płomienia. W zarejestrowanych w 256 odcieniach szarości obrazach, wyodrębniono obszar płomienia na podstawie amplitudy poszczególnych pikseli. Przy czym, rozpatrywany piksel w obrazie należy do obszaru płomienia, jeżeli jego amplituda jest nie mniejsza od 64. Zostało to ustalone w trakcie eksperymentu na podstawie progowania metodą Otsu. Przykładowe obrazy zarejestrowane w trakcie przeprowadzanych testów pokazano na rysunku 7.3.



Rys. 7.3. Przykładowe obrazy, zarejestrowane podczas testów spalania

Analiza obrazu polegała na wyznaczeniu prostych wskaźników geometrycznych, które mogą być wyznaczane w czasie rzeczywistym

z prędkością rzędu 50 obrazów/s. Rozpatrywano pole powierzchni płomienia rozumianego jako suma wszystkich pikseli należących do obszaru płomienia oraz długość konturu tak wyznaczonego obszaru. Zmiany omawianych parametrów przedstawiono odpowiednio na rysunku 7.4.



Rys. 7.4. Zmiany pola powierzchni płomienia: a) oraz długości konturu płomienia, b) dla stabilnego i niestabilnego przebiegu procesu spalania

W pierwszej fazie testu, proces spalania przebiegał stabilnie, a pole powierzchni płomienia ulegało wahaniom wokół wartości średniej, która przy założonej wartości progowej obszaru i warunkach akwizycji obrazu, wynosiła ok. 30000 pikseli. Zmniejszenie stosunku powietrze-paliwo powoduje zmniejszenie wartości średniej pola powierzchni płomienia. W drugiej fazie testu, zwiększenie wydatku powietrza wtórnego powoduje pojawienie się stanu spalania niestabilnego, objawiającego się spadkiem jasności płomienia i wzrostem jego pulsacji. Towarzyszy temu spadek średniej wartości pola powierzchni płomienia, nawet do zera (obszar płomienia nie istnieje). Jednocześnie można stwierdzić zwiększenie rozrzutu pola płomienia wokół jej wartości średniej.

Charakter zmian tego parametru jest bardzo podobny jak w przypadku dyskutowanego wcześniej pola powierzchni płomienia. Wzrost stosunku powietrze-paliwo wiąże się ze spadkiem wartości długości konturu płomienia.


7.4. Diagnostyka procesu spalania z użyciem metod optycznych oraz sztucznej inteligencji

Najpopularniejsza obecnie metoda ograniczenia emisji NO_x poprzez zmianę organizacji procesu spalania, pociąga za sobą negatywne skutki dla eksploatacji kotła. Najważniejsze z nich to: zwiększona emisja CO, większe straty niedopału, korozja parownika, zwiększenie zużycia a także niestabilność płomienia. Zjawiska te są niepożądane lub wręcz niebezpieczne dla kotła i ograniczają możliwą do osiągnięcia redukcję NO_x . W celu zminimalizowania tych zjawisk, niezbędny jest odpowiedni system monitoringu i sterowania. Najbardziej zaawansowane systemy automatycznej regulacji pracy paleniskowych kotłów pyłowych w sprzężeniu zwrotnym uwzględniają większą ilość parametrów, np. oddzielnie przepływy powietrza do poszczególnych palników i dysz OFA, obciążenia młynów czy sygnały z dodatkowych analizatorów gazów spalinowych takich jak NO_x , CO, czy SO_2 . Jednak, ponieważ to indywidualny nadmiar powietrza decyduje o ilości NO_x generowanych w węglowym kotle energetycznym [85, 107], najkorzystniejsza byłaby regulacja procesu spalania w pojedynczym palniku. Brak jest jednakże dotychczas metody, która umożliwiałaby pomiar parametrów wyjściowych, np. emisji tlenków azotu czy tlenku węgla, pojedynczego palnika pracującego w kotle, lub chociaż obiektywną ocenę jakości jego pracy. Niezbędne jest zatem określenie metody, która umożliwiałaby przynajmniej estymację tych parametrów. Umożliwia to światłowodowy układ monitorowania płomienia opracowany w Katedrze Elektroniki Politechniki Lubelskiej (obecnie Instytut Elektroniki i Technik Informacyjnych).

Pierwsze prace miały na celu opracowanie systemu umożliwiającego parametryczną ocenę jakości pracy palnika pyłowego. Jako parametr wybrano zawartość tlenków azotu w spalinach, ponieważ jest on głównym parametrem oceny ilości emitowanych zanieczyszczeń. Na podstawie badań korelacji pomiędzy sygnałem optycznym z układu monitorowania płomienia a wybranym parametrem procesu spalania określono strefę płomienia, z której informacja jest najbardziej wrażliwa na zmiany proporcji mieszanki. Następnie, sygnał z tej strefy

poddano analizie w celu otrzymania dwóch wielkości: miary intensywności płomienia oraz miary częstotliwości migotania płomienia. Ze względu na silnie nieliniowy charakter zależności i brak analitycznego modelu płomienia turbulentnego do estymacji zostały użyte sieci neuronowe. W trakcie badań błąd neuronowego estymatora emisji tlenków azotu na podstawie pomiarów optycznych dla żadnej z próbek nie przekracza 10%, a jego wartość średnia wynosi około 3%.

Optyczno-neuronowy system do estymacji parametrów spalania zastosowano w układzie regulacji stabilizującym emisję tlenków azotu z pojedynczego palnika. Na rysunku 7.5 pokazano wyniki badań symulacyjnych – porównanie odpowiedzi układu regulacji pracującego na podstawie sygnału z analizatora gazów (linia niebieska) i na podstawie sygnałów z sondy optycznej (linia czerwona). Ze względów analitycznych sygnały wyjściowe zostały zsynchronizowane tak, aby zlikwidować opóźnienie wnoszone przez analizator gazów



Rys. 7.5. Porównanie odpowiedzi obiektu dla NPC przy różnym sposobie uzyskiwania informacji zwrotnej o wielkości emisji tlenków azotu [249]

Warto zaznaczyć, że przy odpowiednich wartościach parametrów regulatora w układzie z sondą światłowodową i neuronowym estymatorem emisji, można osiągnąć czas ustalania się odpowiedzi rzędu 20 okresów próbkowania. Jest to wartość porównywalna z możliwą do osiągnięcia w układzie z analizatorem gazowym. Zaletą tego rozwiązania jest możliwość objęcia pętlą sterowania pojedynczego palnika, a także o wiele krótszy czas reakcji układu na zakłócenie, czyli krótszy czas utrzymywania się pełnej wartości zakłócenia na wyjściu, co oznacza mniejszą ilość wyemitowanych zanieczyszczeń. Czas opóźnienia układu regulacji z sondą optyczną (zaznaczony na rysunku jako „A”) nie jest większy od 2 okresów próbkowania. Czas ten w przypadku tradycyjnego rozwiązania (zaznaczony na rysunku jako „B”) zależy głównie od opóźnienia układu pomiarowego. W przypadku dużych obiektów, np. kotłów energetycznych w elektrowniach, w zależności od zastosowanych analizatorów opóźnienie może

dochodzić nawet do kilkuset sekund. W takim przypadku układ z analizatorem gazowym w ciągu czasu opóźnienia nie będzie zdolny wykryć zwiększonej emisji. Spowoduje to bardzo długi czas utrzymywania się zwiększonej emisji, co zostało pokazane na rysunku 7.5 linią przerywaną; „C” oznacza czas opóźnienia pomiędzy powstaniem zwiększonej emisji a jej wykryciem przez analizatory gazów [10]. Testy laboratoryjne wykonane dla palnika gazowego wykazały, że optyczny estymator parametrów spalania w połączeniu z regulatorem rozmytym wykazuje dobre właściwości adaptowania się do zmiennych warunków pracy i paliw, utrzymując emisje NO_x i CO poniżej wymaganych poziomów, pomimo znacznej złożoności rozpatrywanego zadania. Wstępne rezultaty w warunkach zmiennego składu paliwa wykazują, że jest możliwa estymacja parametrów spalania jedynie na podstawie pomiaru parametrów optycznych płomienia, bez znajomości składu spalanych gazów.

Podsumowując należy stwierdzić, że nowoczesne metody uzyskiwania informacji o jakości spalania (np. wielkości emisji CO i NO_x) w połączeniu z metodami regulacji pozwalają na zmniejszenie emisji szkodliwych gazów do atmosfery, a także na efektywne wykorzystanie paliw zaliczanych do grupy odnawialnych źródeł energii.

Model przykładowego rozwiązania

Przeprowadzenie identyfikacji parametrów modelu procesu spalania dla pojedynczego palnika niskoemisyjnego stanowi istotny element syntezy nadrzędnego układu sterowania, który będzie uwzględniał informacje diagnostyczne, w tym te pochodzące z optycznego układu monitorowania płomienia. W celu opracowania modelu matematycznego procesu realizowanego przy pomocy pojedynczego palnika niskoemisyjnego, pomiary przeprowadzono na stanowisku badawczym IEN (patrz rozdział 7.2). Eksperymenty obejmowały stabilizację punktu pracy stanowiska laboratoryjnego przy zróżnicowanych mocach, zróżnicowanych typach paliwa (uwzględniających węgiel oraz biomasę) oraz wymiennych trzech typach palników niskoemisyjnych (o odmiennych kątach łopatek). Pomiary zmiennych procesowych wykonane były z częstotliwością 1 Hz. Do zarejestrowanych wielkości należą wielopunktowe pomiary stężeń gazów spalin (NO_x , O_2 , CO, CO_2), pomiary temperatur, ciśnień i przepływów oraz poziomy wysterowania wentylatorów powietrza. Pomiary optyczne, dotyczące płomienia, wykonane były z częstotliwością 1 kHz.

Wstępny etap prac obejmował analizę wybranych, zarejestrowanych wielkości wejściowych i wyjściowych. Na potrzeby syntezy modeli wielowymiarowych (MIMO) określono wektory sygnałów wejściowych, opisujących ilościowo odpowiednio przepływ powietrza wtórnego, wydatek paliwa oraz wektory sygnałów wyjściowych opisujących odpowiednio stężenia NO_x , CO oraz temperaturę spalin, rejestrowane w pierwszym punkcie pomiarowym.

Podzielono dane na zbiory treningowe oraz testowe, stosując podział odpowiednio 70% i 30%. Korzystając z pakietu *System Identification Toolbox* przeprowadzono identyfikację parametrów dla modeli parametrycznych w przestrzeni stanu danych układem [218]:

$$\begin{cases} (t + Ts) = \mathbf{A}x(t) + \mathbf{B}u(t) + \mathbf{K}e(t) \\ y(t) = \mathbf{C}x(t) + \mathbf{D}u(t) + e(t) \end{cases} \quad (7.1)$$


w określonych punktach pracy (trzy wartości mocy cieplnej, stabilizacja temperatur, jednorodne paliwo). Dobór rzędu modelu miał charakter empiryczny. W większości przypadków przyjmował on wartość z przedziału $<3, 11>$. Rezultaty dopasowania (w sensie MSE, wyrażonej procentowo) zamieszczono w tabeli 7.1.

Tabela 7.1. Wartości błędu średniokwadratowego podczas identyfikacji poszczególnych modeli parametrycznych pierwszego i drugiego stopnia

Zb. testowy	Modele 1					
	P1		P2		P3	
	D1M1 4s11	D1M1 4s6	D2M1 4s6	D2M1 4s5	D3M1 4s3	D3M1 4s4
D1	64,77	59,89	58,51	57,98	56,92	58,65
D2	47,28	57,48	60,25	59,42	55,51	56,49
D3	62,65	64,84	63,41	64,12	66,81	70,25
Zb. testowy	Modele 2					
	P1		P2		P3	
	D1M2 4s10	D1M2 4s3	D2M2 4s4	D2M2 4s10	D3M2 4s10	D3M2 4s6
D1	64,58	62,62	61,67	59,77	54,33	54,96
D2	67,23	66,22	71,14	73,33	59,12	58,65
D3	53,06	55,39	53,74	53,14	54,47	52,35


Badany obiekt złożony potraktowano jako układ o strukturze szeregowej. Zatem wyjścia modeli na pierwszym poziomie stanowią wejścia dla modeli drugiego poziomu (określonych w tabeli 1 jako Modele 2) i opisują zależności pomiędzy stężeniami NO_x, CO, temperaturą spalin w komorze oraz analogicznymi wielkościami w odpowiednim punkcie pomiarowym.

Na rysunku 7.6 przedstawiono odpowiedzi skokowe modeli P1 na wymuszenie skokiem jednostkowym.




Rys. 7.6. Charakterystyki odpowiedzi modeli P1 na wymuszenie skokiem jednostkowym

Na rysunku 7.7 przedstawiono odpowiedzi skokowe modeli P2 na wymuszenie skokiem jednostkowym.



Rys. 7.7. Charakterystyki odpowiedzi modeli P2 na wymuszenie skokiem jednostkowym

Na rysunku 7.8 przedstawiono odpowiedzi skokowe modeli P3 na wymuszenie skokiem jednostkowym.




Rys. 7.8. Charakterystyki odpowiedzi modeli P3 na wymuszenie skokiem jednostkowym

Do dalszych analiz wybrano modele na poziomie 60% dopasowania w sensie MSE.

Symulacyjna weryfikacja modeli


W celu przetestowania wiarygodności uzyskanych modeli, wykorzystując narzędzia z platformy Matlab/Simulink zaprojektowano kontroler MPC. Zostało to przedstawione na rysunku 7.9.



Rys. 7.9. Projektowanie i dostrajanie kontrolera MPC

Pozwala on na wprowadzenie ograniczeń na sygnały wyjściowe i sterujące, sygnałów zakłóceń oraz ustalenie horyzontów predykcji i sterowania. Zatem oferuje możliwość sprawdzenia modeli w kontekście ograniczeń normatywnych (np. co do emisji NO_x).

Widoczny na rysunku 7.10 diagram Simulink'a, z opracowanym modelem systemu sterowania procesem uwzględnia możliwość przełączania w tryb pracy ręcznej oraz automatycznej



Rys. 7.10. Diagram Simulink badanego układu sterowania

Zastosowany w układzie kontroler MPC minimalizuje różnice pomiędzy wartościami wielkości regulowanych $y(k+p|k)$ przewidywanymi w chwili k na przyszłą chwilę $k+p$ (in. przyszłe wartości w chwili $k+p$ są wyznaczone na podstawie wartości w chwili k), a wartościami zadanymi dla tych wyjść $y_{zad}(k+p|k)$ na horyzoncie predykcji N ($p = 1, 2, \dots, N$). Minimalizacja różnic jest rozumiana w sensie określonego kryterium jakości. W kolejnej chwili $k+1$ następuje nowy pomiar sygnału wyjściowego obiektu i cała procedura jest powtarzana z takim samym horyzontem predykcji N . Stosowana jest więc zasada przesuwającego horyzontu (określana także mianem sterowania repetycyjnego). W algorytmie predykcyjnym zakłada się, że po upływie tzw. horyzontu sterowania N_u (zwykle $N_u < N$) przyrost sygnału sterującego wynosi 0.


Funkcja kryterialna, w ogólnym przypadku dana jest zależnością:

$$J(k) = \sum_{p=N_1}^N \|y_{zad}(k+p|k) - y(k+p|k)\|_{\Psi(p)}^2 + \sum_{p=0}^u \|\Delta u(k+p|k)\|_{\Lambda(p)}^2, \quad (7.2)$$

gdzie: $\Delta u(k+p|k)$ – wektor przyrostów sterowań, $\Psi(p) \geq 0$ – macierz współczynników wagowych składowych wektora uchybów prognozowanych


na chwilę $k + p$. (najczęściej m. diagonalna) oraz $\Lambda(p) \geq 0$ – macierz, gdzie: $y_{zad}(k + p|k)$ – wektor wartości zadanych, $y(k + p|k)$ – wektor wielkości regulowanych, współczynników wagowych, składowych wektora przyrostów sterowania prognozowanych na chwilę $k + p$. Gdy $\Lambda(p) = \lambda I$ to, $\lambda \geq 0$ określa wagę tłumienia zmienności sterowania w stosunku do redukcji uchybów regulacji [223].

W ramach przeprowadzonych testów, uwzględniających ograniczenia co do norm emisji NO_x (300 ppm) najlepsze rezultaty w sensie NRMSE uzyskano dla modeli niskoemisyjnego palnika pierwszego (D1M1_4s6) oraz trzeciego (D3M1_4s3).



Rys. 7.11. Porównanie odpowiedzi modeli P1 dla testowych danych z procesu spalania

W przypadku modeli P2 spełnienie ograniczeń emisji było osiągnięte przy występujących oscylacjach (D2M1_4s5), a przypadku (D2M1_4s6) – zakończone niepowodzeniem. Konfiguracja szeregową przyniosła najlepsze rezultaty w połączeniu strukturami modeli (D2M2_4s4 oraz D2M2_4s10).



Rys. 7.12. Porównanie odpowiedzi modeli P1 dla testowych danych z procesu spalania

Na podstawie przedstawionych charakterystyk odpowiedzi na testowe sygnały wejściowe z rzeczywistego procesu obserwuje się stosunkowo duże rozbieżności pomiędzy poszczególnymi modelami.

Wymogi normatywne co do emisji NO_x , CO i SO_2 stają się coraz bardziej restrykcyjne. W związku z potrzebą optymalnego sterowania procesem spalania z użyciem technik niskoemisyjnych omówiono warunki opracowania systemu sterowania procesem spalania oraz stworzenia algorytmu optymalizacji pracy kotła na podstawie informacji uzyskanych z konwencjonalnego oprzyrządowania oraz uwzględnienie innowacyjnych technik pozwalających na ocenę jakości procesu.

8. Sterowanie kotłem pyłowym z wykorzystaniem asymetrycznych sztucznych sieci neuronowych

W porównaniu ze znaczną inercją oraz opóźnieniem, wnoszonym przez sterowanie temperaturą oraz ciśnieniem pary i wody, poziomem wody, zmienno-czasowe oraz zmienno-położeniowe charakterystyki wydają się bardziej oczywiste podczas transportu paliwa, dystrybucji powietrza technicznego oraz procedur samego spalania w kotle. Dzięki zastosowaniu klasycznych Sztucznych Sieci Neuronowych (SSN) uzyskano wyjątkowe zalety w powiązanych badaniach [31, 213] oraz zastosowaniach [4, 6, 259, 18, 29, 32, 184, 187, 188, 193, 235], gdzie szereg praktycznych doświadczeń także wskazuje wiele kluczowych problemów zastosowania ANN do modelowania kotła.

Złożone procedury spalania w kotle obejmują dużą liczbę parametrów wejściowych, które prowadzą do dużej skali modeli SSN, których trenowanie i aktualizacja wymagają ogromnych ilości próbek (znaczących rozmiarów zbioru uczące). Niemniej, jednak odpowiednie próbki są trudne do pozyskania ze względu na dużą zmienność jakości paliwa (węgla oraz biomasy), obciążenia czy też kombinacji palników wykorzystywanych w podczas pracy obiektu. Wszystko to sprawia, że bezpośrednie zastosowanie modelowania SSN wymaga miesięcy ręcznego debugowania, a wydajność samego modelu szybko maleje przez ustawiczne wprowadzanie ograniczeń w procedurach samouczenia się dla pętli automatycznej regulacji.

Zastosowania modelowania konwencjonalnych sztucznych sieci neuronowych są bardzo rozległe, niemniej specyficzna struktura, jak i prawa fizyczne układu kotła uniemożliwiają konwersję w prosty sposób do opisu modelem SSN. Liczba neuronów w warstwie ukrytej jest trudna do określenia, a modelowanie procesu jest złożone, czasochłonne oraz wykazuje niski wskaźnik uczenia.


Klasyczne struktury SSN pochłaniają wiele zasobów ze względu na duże różnice w korelacji pomiędzy wejściami modelowanego kotła. Natomiast, ze względu na ograniczoną liczbę próbek, potencjalny trening kończy się błędem.

Dalej zaproponowano inteligentny model sterowania spalaniem kotłów elektrowni opartych na asymetrycznej strukturze SSN, w odniesieniu do powyższych problemów, w których struktura modelu SSN jest dostosowywana do charakterystyki spalania kotła energetycznego w rzeczywistej elektrowni.

Spalanie w kotłach przemysłowych ma wiele cech, takich jak: wielowymiarowość (MIMO), duże bezwładności, nieliniowości i silne sprzężenia wewnętrzne, ze względu na złożoność fizycznych i chemicznych reakcji zachodzących w dużej przestrzeni. Zostało ono uznane za jeden z najtrudniejszych obiektów w inżynierii cieplnej. Co prawda, dowiedziono, że SSN dobrze radzą sobie z odwzorowaniem wszelkich relacji nieliniowych, stąd zainteresowanie modelowaniem spalania w kotłach [29, 31, 213]. Jednak, w przypadku energetyki zawodowej, za sterowanie procesem spalania w kotle odpowiada skoordynowany system sterowania (ang. *Coordinated Control System*, CCS). W zakresie wielkości sterowanych, oprócz paliwa i jego dystrybucji w palnikach,

kontrolowane są: ilość zimnego i gorącego powietrza w młynach węglowych, ilość powietrza wtórnego i jego dystrybucja, ilość powietrza ogrzanego, sumaryczna ilość tlenu, ciśnienie, rozdrobnienie węgla przez dynamiczne oddzielanie cyklonów itd. są regulowane w trybie online. Parametry należy kontrolować w celu zapewnienia bezpieczeństwa kotła, jego stabilności, zapewnienia celów ekonomicznych i środowiskowych w zakresie zmian warunków pracy przy jednostkowym obciążeniu, węgla, temperatury otoczenia, wilgotności i innych warunków kotłów energetycznych. Wydajność spalania w kotłach i emisja NO_x są zwykle wybierane jako główny parametr wyjściowy sterowania modelem SSN.

Efektywność spalania w kotłach i emisja NO_x są zwykle wybierane jako główne parametry funkcji celu w sterowaniu z modelem SSN. Model neuronowy umożliwia odwzorowanie zależności pomiędzy parametrami sterowania i wyjściami dla różnych warunków pracy, dzięki temu algorytm sterowania może zostać wykorzystany w roli systemu doradczego dla operatora lub bezpośrednio w sterowaniu procesem spalania w kotle. Schemat blokowy takiego rozwiązania pokazano na rysunku 8.1.



Rys. 8.1. Struktura typowego układu sterowania kotłem, z wykorzystaniem sztucznych sieci neuronowych

Złożoność strukturalna i nieliniowość modelu spalania w kotle są bardzo duże. W porównaniu do idealnych warunków brzegowych modelowania, modelowanie kotła w krajowej elektrowni ma następujące kluczowe problemy:

- Zakład energetyki zawodowej, podłączony do sieci często narażony jest na duże, częste i szybkie zmiany obciążenia wymaganego przez Krajową Dystrybucję Mocy, wpływające na sterowanie procesem jej wytwarzania. W takiej sytuacji, zależności pomiędzy wszystkimi wejściami i wyjściami są obciążone niepewnością. Dochodzi często do zmiany współczynników w modelu. Występują wówczas trudności w zgromadzeniu odpowiednich danych dla stabilnych warunków, z wystarczająco długim czasem na opracowanie i aktualizację modelu.

- Zmiany jakości paliwa – węgla, w tym jego wartości opałowej, zawartości popiołu, substancji lotnych, wilgoci itd., są często bardzo duże. Z kolei znaczący wpływ parametrów paliwa na proces spalania może bezpośrednio prowadzić do niepożądanego wpływu na stabilność i zniweczenie prac związanych z przygotowaniem modelu.
- Zmiany jakości węgla, warunków pracy młynów węglowych lub ręczna interwencja w proces mogą spowodować znaczącą zmianę w podawaniu paliwa do palników, przy zadanym obciążeniu. To z kolei sprawia, że obciążenie przestaje być kluczowym parametrem warunków spalania. Znacząca zmiana w używanej dystrybucji paliwa w palniku zwykle wymaga odrębnych modeli, aby uniknąć awarii podczas mapowania relacji wejść-wyjść układu.
- Warto podkreślić, że rozdział paliwa do poszczególnych palników w kotle odbywa się w większości instalacji w sposób nierównomierny, przy pomocy klap mechanicznych. W rezultacie, w takich instalacjach bardzo trudne jest zapewnienie takiego samego spalania w poszczególnych palnikach. Pożądana jest możliwość niezależnego sterowania każdym z palników, której warunkiem koniecznym jest pomiar paliwa w pyłoprzewodach (przed każdym z palników).


Powyższe kluczowe problemy wymagają bezpośredniego spojrzenia na model sterowania procesem spalania w kotle, a także są przyczynami trudności, które występują w układach sterowania tym procesem z użyciem sztucznych sieci neuronowych.

Modelowanie warunków pracy danego kotła może być czasochłonne i wymaga żmudnego, ręcznego doboru określonych wektorów wejść i/lub wyjść celem uzyskania stabilnego układu sterowania.

8.1. Koncepcja modelowania spalania w kotle węglowym z wykorzystaniem asymetrycznej SSN

W pierwszej kolejności, zasadna jest zmiana podejścia do modelowania procesu spalania w kotle węglowym przy pomocy klasycznej SSN. Na podstawie przeprowadzonej analizy czynników wpływających na spalanie pyłu węglowego w kotle, zauważono, że podciśnienie, zawartość tlenu oraz obciążenie stanowią kompleksowe parametry charakteryzujące spalanie w kotle. Określono je jako wejścia globalne. Powietrze wtórne, wydajność każdego z młynów węglowych, objętość powietrza pierwotnego, dodatkowo wpływają na proces spalania w kotle, są zdefiniowane jako lokalne wejścia modelu. Wyłonione w ten sposób silne zależności uwzględniono w strukturze modelu SSN, a słabe pominięto. Ma to na celu optymalizację struktury modelu i poprawę efektywności jego uczenia się.

Na rysunku 8.2 przedstawiono schemat czterowarstwowej struktury SSN, zawierającej dwie ukryte warstwy.



Rys. 8.2. Model spalania w kotle, oparty na asymetrycznej strukturze sztucznej sieci neuronowej

Pierwsza ukryta warstwa ustanawia relacje z odpowiednimi węzłami warstwy wejściowej zgodnie z różnymi charakterystykami globalnych wejść. Węzły wejściowe są powiązane z ukrytymi węzłami w grupy, jednocześnie będąc niezależnymi dla węzłów należących do innych grup. Związek między nimi realizowany jest w drugiej warstwie ukrytej. W analogiczny sposób wejścia globalne są grupowane w celu utworzenia takiej samej hierarchicznej struktury, jak wejścia lokalne. Wszystkie węzły pierwszej warstwy ukrytej są powiązane odpowiednio z węzłami drugiej warstwy ukrytej.

Warstwa wyjściowa modelu jest określana na podstawie wyjściowych parametrów modelowania. Każda grupa wejść lokalnych koncentruje się na dopasowywaniu relacji między palnikami a związanymi z nimi parametrami, a funkcje neuronów są przyjmowane z powodu ich fizycznego podobieństwa (na przykład, ilość i temperatura powietrza pierwotnego na palnik w stosunku do mocy palnika lub współczynnik rozdziału pyłu węglowego). Udział palników w wynikach modelu można dostosować za pomocą drugiej ukrytej warstwy. Zapewnia to właściwe mapowania z wyjściami. Jest to szczególnie istotne w przypadku, gdy ilość doprowadzanego do palników węgla zmniejsza do niskiego poziomu lub nawet przestaje podawać paliwo. Istotne jest, aby model neuronowy uwzględniał prawidłowe reakcje na sytuacje awaryjne. W przeciw-

nym razie może dojść do niekorzystnych lub fatalnych skutków po jego implementacji, mimo przeprowadzenia poprawnych procedur treningowych.

Zagrożenie to wynika z problemu rozdziału pyłu węglowego w układzie podawania paliwa w kotle. Dzięki odpowiedniej konstrukcji, próbuje się zapewnić równomierny rozdział doprowadzanego paliwa do każdego z palników. Jest ono doprowadzane do grupy palników w rezultacie ustawiania położenia przepustnic (tzw. klap). Niemniej jednak, równomierny rozdział paliwa w praktyce bywa trudny do osiągnięcia i poszczególne palniki w danej grupie pracują z różnym obciążeniem (wydajnością). Niezależne sterowanie każdym z palników wydaje się rozwiązaniem tego problemu. Informacja o ilości pyłu węglowego podawanego do danego palnika pozwoli na efektywną optymalizację procesu spalania.

W związku z tym, wyjścia neuronów pierwszej warstwy ukrytej dla palników nie są obliczane na podstawie wzoru (8.1), ale sprzężone z względnym podawaniem węgla lub względnym wskaźnikiem podawania węgla przez grupę palnika. Neurony pierwszej ukrytej warstwy odpowiadają wpływowi lokalnych wejść każdej grupy palników. Jest to wyznaczane na podstawie zależności (8.2).

$$y = f\left(\sum_{i=1}^N w_i u_i + b\right). \quad (8.1)$$

$$y = f\left(\sum_{i=1}^N w_i u_i u_p + b\right), \quad (8.2)$$

gdzie f jest funkcją aktywacji neuronów, taką jak np. funkcja progowa, funkcja liniowa itp., w jest wagą ostatniej warstwy wyjścia neuronu, u jest górną warstwą wyjścia neuronu, b jest progiem aktywacji neuronu, u_p opisuje współczynnik wydajności grupy palników lub prędkość podawania paliwa.

W tym przypadku na wyjście pierwszego neuronu warstwy ukrytej, odpowiadającego lokalnym wpływom grupy palników wpływają zmiany sygnałów wejściowych, ale także obciążenie grupy palników. Oznacza to, że zmniejszone obciążenie względne grupy palników osłabi jej wpływ na charakterystykę spalania całego kotła przez ograniczenie aktywności odpowiednich neuronów wyjściowych modelu. W konsekwencji, nawet jeśli kluczowe wskaźniki przekroczą ich nominalne zakresy – nie wpłynię to negatywnie na odpowiedź modelu. W ten sposób istnieje możliwość modelowania różnych kombinacji w jednolitej strukturze SSN. Zabieg ten ogranicza liczbę parametrów względem rozwiązań stosowanych w klasycznych symetrycznych sztucznych sieci neuronowych (MLP) o tym samym rozmiarze.

Za wartość dodaną zaproponowanego rozwiązania można uznać możliwość ograniczenia zbiorów uczących przy jednoczesnym zwiększeniu odporności modelu na niepożądane zmiany parametrów fizycznych procesu. Zatem można przyjąć, że pośrednio uwzględni ono także zmiany jakości węgla.

8.2. Zastosowanie asymetrycznej SSN do optymalnego sterowania kotłem pyłowym

Opracowanie klasycznego modelu matematycznego procesu spalania w kotle jest bardzo trudne. Na podstawie prac [29, 31, 213] weryfikację zaproponowanego podejścia przeprowadzono na grupie 60 zbiorów testowych pozyskanych typowego testu obciążenia kotła nadkrytycznego o mocy cieplej 500 MW opalanego węglem, odpowiednio dla 75% obciążenia. Utworzono 30 zbiorów treningowych, natomiast pozostałe posłużyły jako zbiory testowe. Na podstawie analizy statystycznej, uznaje się, że ze względu na liczebność zbiorów ich podział spełnia warunek wystarczający uzyskania prawidłowego modelu.

Tabela 8.1. Parametry asymetrycznej sztucznej sieci neuronowej do sterowania kotłem pyłowym

Parametr	Wartość
Węzły wejść globalnych	8
Węzły wyjść lokalnych	4x3
Pierwsza ukryta warstwa z węzłami globalnymi	8
Pierwsza ukryta warstwa z węzłami palników	3x3
Węzły drugiej warstwy ukrytej	7
Węzły warstwy wyjściowej	1

Na podstawie parametrów zawartych w tabeli 8.1 podjęto trenowanie i testowanie zaproponowanej struktury asymetrycznej sztucznej sieci neuronowej (patrz rysunek 8.2).


W odniesieniu do tabeli 8.1, dla ośmiu wejść globalnych przypisano parametry wektorów wejściowych. Obejmowały one: obciążenie, objętość powietrza z dysz OFA frontowej oraz tylnej ściany kotła, wartość podciśnienia w kotle, kaloryczność paliwa (węgla), oraz udział popiołu lotnego oraz jego wilgotność. Cztery wejścia o oddziaływaniu lokalnym obejmują: prędkość podawania węgla, wartość parametru lambda, temperaturę powietrza pierwotnego.

Do realizacji modelu przyjęto parametr opisujący relacje węgiel-powietrze, zamiast powietrze-węgiel. Jest to działanie celowe, ponieważ niweluje dzielenie przez zero w przypadku braku lub awarii rozdziału podawania pyłu węglowego do palników.

Powyższe parametry zastosowano w strukturze asymetrycznej SSN, zawierającej 160 połączeń. Wagi wyjść neuronów o oddziaływaniu globalnym wynosiły zawsze 1, podobnie jak dla neuronów pierwszej warstwy ukrytej.

Dla porównania, zastosowano także model z klasyczną siecią MLP. W tym przypadku ilość połączeń neuronowych wynosi 820. Co warto podkreślić, dla każdej grupy palników, należy uwzględnić odrębne modele. W rezultacie sumaryczne parametry takiego rozwiązania zwiększają się 30–40 krotnie. Dodatkowym utrudnieniem może być potrzeba zwiększenia ilości zbiorów uczących i testujących względem zaproponowanego modelu sieci asymetrycznej.

Porównanie wyników treningu dla proponowanego i klasycznego modelu ANN przedstawiono na rysunku 8.3.



Rys. 8.3. Porównanie efektywności uczenia asymetrycznej i klasycznej sztucznej sieci neuronowej

Do porównania rozwiązań użyto 10 rund. Wyniki testu z maksymalną i minimalną wydajnością uznano za pomyślne lub nie. W jednej rundzie jest 20 procedur treningowych i testowych. Na rysunku 8.3 pokazano, że wskaźnik powodzenia (ang. *success rate*) asymetrycznego modelu SSN jest średnio zawsze wyższy o około 20–30% w porównaniu do klasycznej sieci MLP.

Opierając się na powyższym rozwiązaniu opracowano symulacyjny model optymalnego sterowania procesem spalania jak na rysunku 8.1. Umożliwia on sterowanie ilością powietrza wtórnego dla w kotła nadkrytycznego. Na podstawie przeprowadzonych analiz system sterowania procesem spalania oparty na proponowanym modelu pozwala na poprawę średniej wydajności kotła o 0,20% dla typowych warunków obciążenia. Potwierdza to skuteczność stosowania struktur asymetrycznych.

W porównaniu z klasycznym modelem SSN, proponowane rozwiązanie ma mniej rozbudowaną strukturę, lepszy wskaźnik skuteczności uczenia (wytrenowania) i potencjał do zastosowania w praktyce.

9. Odporne sterowanie adaptacyjne procesem współspalania biomasy

Głównym paliwem stosowanym w energetyce jest nadal węgiel. Ze względu na jego zmniejszające się zasoby oraz towarzyszące im emisje szkodliwych produktów spalania, nieustannie trwają prace nad zmianą tego stanu. W tym celu opracowano szereg technik, zwiększających efektywność spalania takich jak np.: stopniowanie powietrza roboczego (ang. *air staging*), redukcja NO_x metodą reburningu oraz układy zawracania spalin (ang. *flue gas circulation*) [128]. Warto podkreślić, że w metoda reburningu polega na doprowadzaniu paliwa do komory spalania do dwóch stref spalania: pierwszej, gdzie spalane jest paliwo pierwotne oraz drugiej strefy, gdzie częściowi spala się paliwo dodatkowe, wytwarzając atmosferę redukującą [68, 249]. Ma to szczególne znaczenie w obliczu niskoemisyjnych technik współspalania węgla i biomasy, gdzie kosztem dostosowania się wymogów emisyjnych jest bezpośredni wpływ na stabilność (efektywność) procesu spalania oraz pośrednie oddziaływanie na wzrost korozji oraz szlakowanie kotła [69]. Te niepożądane efekty mogą być ograniczone dzięki precyzyjnemu sterowaniu z zastosowaniem dodatkowej informacji o procesie [112]. Należy podkreślić, że wydajność procesu spalania zależy od szeregu czynników, w tym niezależnych i zależnych od sposobu jego prowadzenia. W celu minimalizacji termicznego powstawania rodników NO_x większość technik niskoemisyjnych obejmuje zawirowania w strefie spalania. W celu zagwarantowania efektywnego i jednocześnie przyjaznego środowiska spalania niezbędne jest posiadanie aktualnej i pewnej informacji o jego przebiegu. Podstawowa wiedza, opiera się na sygnałach pomiarowych z wejścia i wyjścia układu spalania oraz jego stanu. Jednak, przy uwzględnieniu bardzo dużej dynamiki zjawisk towarzyszących spalaniu należy przyjąć, że informacje te są opóźnione i uśrednione.

Spośród dostępnych metod diagnostycznych, większość okazuje się bardzo kosztowna lub wręcz niemożliwa do realizacji w warunkach przemysłowych. Ich ciekawą alternatywę stanowią metody optyczne i akustyczne. W ramach pierwszej grupy, promieniowanie emitowane przez płomień (jądro płomienia) stanowi odzwierciedlenie zmian, związanych z przemianami chemicznymi i fizycznymi, zachodzących w procesie spalania. Można zatem przyjąć, że takie podejście pozwala uzyskać dodatkową, bieżącą (nieopóźnioną) oraz selektywną przestrzennie informację diagnostyczną o zachodzącym procesie spalania. Jako warunek konieczny niniejszego rozwiązania należy przyjąć założenie, że stabilna i nieruchoma pozycja płomienia odpowiada równowadze dynamicznej, obejmującej lokalną prędkość rozprzestrzeniania się płomienia oraz prędkość nadchodzącej mieszaniny paliwowej. Pozwala to założyć, że kształt płomienia może być wskaźnikiem procesu spalania, występującym w określonych warunkach.

W rezultacie, uzyskuje się zależność pomiędzy parametrami, opisującymi zmiany płomienia oraz temperaturą gazów wyjściowych z komory spalania (kotła). O ile klasyczne pomiary zmian wartości temperatury mają charakter inercyjny, to uwzględnienie sygnałów optycznych umożliwi szybką i bezpieczną reakcję kontrolera. Zasadne jest tu wykorzystanie odpornego sterowania adaptacyjnego (ang. *Robust Adaptive Control*). Konstrukcja sterownika adaptacyjnego wymaga opracowania modeli referencyjnych układu. Problem stanowi znalezienie kompromisu pomiędzy prostotą modelu a jego dokładnością.

9.1. Modele procesu, niepewność i sterowanie odporne

Bardzo duża złożoność otaczającego świata sprawia, że precyzyjny opis (odzworowanie) rzeczywistych procesów nawet z użyciem zaawansowanych modeli matematycznych staje się trudne. Stąd, wprowadza się uproszczenia oraz uogólnienia modeli. Jest to szczególnie istotne przy projektowaniu sterowania (i regulacji), gdzie kompromis pomiędzy prostotą struktury modelu i jego dokładnością warunkuje w dużej mierze możliwość jego zastosowania w układach czasu rzeczywistego. W związku z powyższym matematyczne modele sterowania mogą opisywać dynamikę procesu, jedynie w ograniczony i przybliżony sposób.

Większość współczesnych technik sterowania wymaga modelu kontrolowanego obiektu, posiadającego stałą strukturę oraz parametry ustalane na etapie jego projektowania. Z jednej strony, posiadając dokładny opis układu (i pomijając zakłócenia zewnętrzne) można założyć, że proces mógłby być z powodzeniem sterowany w układzie otwartym (wł. z otwartą pętlą ujemnego sprzężenia zwrotnego). Niemniej jednak, ujemne sprzężenie zwrotne od wyjścia modelu jest istotne, biorąc pod uwagę zakłócenia zewnętrzne oraz niedokładności modelu, występujące w większości układów rzeczywistych. Zatem przedmiotem regulacji odpornej (ang. *robust control*) jest zaprojektowanie regulatorów (kontrolerów), które pozwalają układowi zachować stabilność i wydajność pomimo występowania niedokładności modelowania i/lub niepewności. Oczywiście można stwierdzić, że już samo wykorzystanie sprzężenia zwrotnego uwzględnia niedokładności modelu. Niemniej jednak, termin *regulacja odporna* (*krzepka*) na podstawie [21, 151, 156, 161] stosuje się do opisu układów wyraźnie uwzględniających rozbieżności pomiędzy modelem a procesami rzeczywistymi.

W zależności od techniki używanej do projektowania kontrolerów, istnieją różne podejścia do modelowania niepewności. Najbardziej rozbudowanymi technikami są niepewność odpowiedzi częstotliwościowej i niepewność parametryczna transmitancji. Większość przypadków zakłada, że obiekt sterowania może być dokładnie opisany przez jeden z modeli należących do pewnej rodziny. Oznacza to, że jeśli rodzina modeli składa się z modeli liniowych, obiekt sterowania ma również liniowy charakter. W przypadku sterowania predykcyjnego (ang. *Model Predictive Control*, MPC) można zdefiniować niepewności dotyczące możliwości predykcji modelu. Niepewność częstotliwościowa opisywana jest na ogół przez pasmo wokół nominalnej

odpowiedzi częstotliwościowej. Zakłada się, że odpowiedź częstotliwościowa obiektu zawiera się w tym paśmie. Z kolei, w przypadku niepewności parametrycznych, przyjmuje się, że każdy współczynnik funkcji przenoszenia jest ograniczony przez granicę niepewności. Zakłada się wówczas, że taki obiekt posiada funkcję przenoszenia z parametrami w ramach ustalonej niepewności. Przyjmuje się założenie, że obiekt jest liniowy z charakterystyką częstotliwościową w zakresie niepewności dla pierwszego przypadku i jest tego samego rzędu, co rodzina modeli dla przypadku niepewności parametrycznej. W sterowaniu MPC, modele są używane do przewidywania przyszłych trajektorii. Odpowiednim sposobem opisanie niepewności w tym kontekście wydaje się być model (lub zestaw modeli), który zamiast generować przyszłą trajektorię, może również generować pasmo trajektorii, w którym proces trajektorii zostanie uwzględniony, gdy zastosowane zostanie to samo wejście pomimo niepewności. W przypadku dostępności dobrego modelu procesu pasmo to jest wąskie, a poziom niepewności jest niski.

Najbardziej ogólny sposób stawiania problemu w MPC dotyczy procesu, którego zachowanie jest podyktowane równaniem:

$$y(t+1) = f(y(t), \dots, y(t-n_y), u(t), \dots, u(t-n_u), z(t), \dots, z(t-n_z), \psi), \quad (9.1)$$

gdzie: $y(t) \in \mathbf{Y}$ i $u(t) \in \mathbf{U}$ są wektorami n i m wyjść i wejść, $\psi \in \mathbf{\Psi}$ jest wektorem parametrów, prawdopodobnie nieznanymi, i $z(t) \in \mathbf{Z}$ jest wektorem możliwych zmiennych losowych.

Biorąc pod uwagę, że model lub rodzina modeli, dla procesu opisanego przez:

$$\hat{y}(t+1) = \hat{f}(y(t), \dots, y(t-n_{na}), u(t), \dots, u(t-n_{nb}), \theta), \quad (9.2)$$

gdzie $\hat{y}(t+1)$ jest prognozą wektora wyjściowego dla chwili $t+1$ generowanego przez model, $\hat{f}$ jest funkcją wektorową, zwykle uproszczeniem f , n_{na} i n_{nb} to liczba przeszłych sygnałów wyjść i wejść branych pod uwagę przez model, natomiast $\theta \in \mathbf{\Theta}$ stanowi wektor niepewności obiektu. Zmienne, które wpływają na dynamikę obiektu sterowania, nie są uwzględniane bezpośrednio w modelu z powodu niezbędnych uproszczeń lub z innych powodów są reprezentowane przez $z(t)$.

Dynamika obiektu sterowania w (9.1) jest całkowicie opisana przez rodzinę modeli (9.2), jeśli dla dowolnego $y(t), \dots, y(t-n_y) \in \mathbf{Y}$, $u(t), \dots, u(t-n_u) \in \mathbf{U}$, $z(t), \dots, z(t-n_z) \in \mathbf{Z}$ i $\psi \in \mathbf{\Psi}$, istnieje wektor parametrów $\theta \in \mathbf{\Theta}$ taki, że:

$$\begin{aligned} f(y(t), \dots, y(t-n_y), u(t), \dots, u(t-n_u), z(t), \dots, z(t-n_z), \psi) = \\ = \hat{f}(y(t), \dots, y(t-n_{na}), u(t), \dots, u(t-n_{nb}), \theta), \end{aligned} \quad (9.3)$$

Sposób określania parametru niepewności θ i jego domeny zależy głównie od struktury f i $\hat{f}$ oraz od stopnia pewności co do modelu. Oto najbardziej popularne struktury podejść MPC [21]:

- ograniczanie *niepewności odpowiedzi impulsowej* – odpowiednie, przy nieliniowym obiekcie sterowania i liniowych modelach (uzyskiwana przy różnych reżimach operacyjnych), więc obiekt jest opisany przez kombinację liniową q znanych, niezależnych od czasu, stabilnych liniowych modeli o nieznanych wagach θ_j .
- *macierzowy opis niepewności częstkowej* – często wykorzystuje opis w przestrzeni stanów, a każdy z wpisów macierzy transferu charakteryzuje się statycznym wzmocnieniem, stałą czasową i czasem martwym. Granice współczynników macierzy $A(z-1)$ i $B(z-1)$ można uzyskać na podstawie wzmocnienia i stałych czasowych. Niepewność związana z czasem martwym jest jednak trudna do określenia. Jeżeli przedział niepewności dotyczący czasu martwego jest mniejszy, nie trzeba zmieniać czystego opóźnienia w modelu dyskretnym. Częstkowy czas opóźnienia może być modelowany z wykorzystaniem aproksymacji Pade’go, a granica niepewności tych współczynników obliczona na podstawie niepewności czasu martwego. Nie jest to optymalne rozwiązanie, zwłaszcza dla aplikacji działających w czasie rzeczywistym ze względu na rozwiązywanie problemów typu min-max. Z kolei, gdy niepewność dotyczy tylko wielomianowej macierzy B , równanie predykcji jest afiniczną funkcją parametru niepewności, a wynikowy problem min-max jest mniej kosztowny obliczeniowo.
- *niepewności globalne* – przy założeniu, że wszystkie błędy modelowania ulegają globalizacji w wektorze parametrów, proces może być przybliżony za pomocą modelu liniowego w tym sensie, że wszystkie trajektorie zostaną uwzględnione w pasmach zależnych od $\theta(t)$. Jeśli zmienne procesowe są ograniczone, globalne niepewności również są ograniczone.

Podstawowym celem sterowania predykcyjnego jest obliczenie przyszłych sekwencji sterowań $u(t), u(t+1), \dots, u(t+N_u)$ w taki sposób, aby optymalne j krokowe prognozy wprzód $y(t+j|t)$ były prowadzone w pobliżu $(t+j)$ dla horyzontu predykcji. Sposób, w jaki system zbliża się do pożądaných trajektorii, określa funkcja J , która zależy od obecnych i przyszłych sygnałów sterujących i niepewności. Zwykle, w przypadku stochastycznego typu niepewności, minimalizacja funkcji J dla najbardziej pożądanęj sytuacji zakłada, że wyznaczone, przyszłe trajektorie będą stanowiły przyszłe oczekiwane trajektorie. W przypadku, gdy ograniczone niepewności są rozpatrywane *explicit*, można obliczyć granice trajektorii predykcyjnych i uzyskać bardziej niezawodne sterowanie, gdy kontroler zminimalizuje funkcję celu dla najgorszej sytuacji, rozwiązując zależność:

$$\min_{u \in U} \max_{\theta \in \Theta} J(u, \theta). \quad (9.4)$$

Minimalizowana funkcja stanowi maksimum normy, która określa zgodność danych wyjściowych procesu z wyznaczonymi trajektoriami referencyjnymi. W tym celu można stosować różne typy norm, np. kwadratową funkcję kosztu [13], normę ∞ - ∞ [23] lub 1-norm [2]. W przypadku kwadratowej funkcji kosztu dla każdej wartości u , używany jest hesjan (patrz [13]), który może być zapewniony jako dodatni. Oznacza to, że funkcja jest wypukła i nie istnieją żadne optymalne rozwiązania lokalne, poza optymalnym rozwiązaniem globalnym. Zatem, eliminuje się jeden z głównych problemów algorytmów programowania nieliniowego, czyli - obecność minimów lokalnych. Takie podejście może być zaporowe dla aplikacji czasu rzeczywistego (ang. *real-time*) z uwzględnieniem kosztownych czasowo długich horyzontów predykcji. Oczywiście, problem ten staje się jeszcze bardziej złożony, biorąc pod uwagę niepewność parametrów zarówno wejściowych, jak i wyjściowych.

Campo i Morari udowodnili, że zastosowanie normy ∞ - ∞ ogranicza problem min-max; ze względu na fakt, że wymaga on mniejszej liczby obliczeń i można go rozwiązać za pomocą standardowych algorytmów. Chociaż norma ∞ - ∞ wydaje się odpowiednia pod względem odporności, dotyczy ona tylko maksymalnego odchylenia, a pozostałe zachowania nie są w wyraźny sposób brane pod uwagę. Inne rodzaje norm są bardziej odpowiednie do określenia wydajności pomiarowej. W pracy [2] wykazano, że tę metodę można rozszerzyć na normę l_1 (ang. 1-norm).

Odporność poprzez nakładanie ograniczeń. W celu zagwarantowania odporności w algorytmie MPC nakłada się warunki stabilności dla wszystkich możliwych realizacji niepewności [156]. Kluczowymi składnikami stabilizującego MPC są zbiór końcowy (ang. *terminal set*) i koszt terminalny (ang. *terminal cost*). Stan końcowy (jest na końcu horyzontu predykcji) i wymaga osiągnięcia stanu ustalonego. Powiązany koszt końcowy dołączany jest do funkcji kosztu. Odporny MPC polega na znalezieniu wektora przyszłych sterowań, tak aby zminimalizować funkcję celu (w tym koszt końcowy spełniający warunki stabilności [9]) oraz wymusić osiągnięcie regionu końcowego dla wszystkich możliwych wartości niepewności, co opisuje zależność (9.5):

$$\min_{u \in U} J(x(t), u) \quad \theta \quad \text{przy czym: } \forall_{\theta \in \Theta} \begin{cases} \mathbf{R}u \leq \mathbf{r} + \mathbf{V}x(t) \\ x(t+N) \in \Omega_T \end{cases}, \quad (9.5)$$

gdzie końcowy zbiór Ω_T jest definiowany przez wielotyp $\Omega_T \{x: R_T x \leq r_T\}$. Nierówność $\mathbf{R}u \leq \mathbf{r} + \mathbf{V}x(t)$ zawiera ograniczenia. Jeśli istnieją ograniczenia na wyjściu procesowym i / lub stanie, wektor $\mathbf{r}$ jest funkcją afiniczną niepewności θ .

W ogólności, procesy przemysłowe są nieliniowe, ale większość układów MPC opiera się na wykorzystaniu modeli liniowych. Wynika to z powodu stosunkowo łatwej identyfikacji modelu liniowego na podstawie danych procesowych.

Modele liniowe zapewniają dobre wyniki, gdy instalacja pracuje w pobliżu punktu pracy. W urządzeniach MPC celem jest raczej utrzymanie procesu wokół stanu stacjonarnego, a nie dokonywanie częstych zmian z jednego punktu pracy do drugiego. Zatem, precyzyjny model liniowy jest wystarczający w większości

przypadków. Z kolei zastosowanie modelu liniowego wraz z kwadratową funkcją celu powoduje powstanie problemu wypukłego, którego rozwiązanie jest dobrze zbadane i wdrożone w wielu produktach komercyjnych. Istnienie algorytmów, które mogą zagwarantować rozwiązanie konwergentne w czasie krótszym niż czas próbkowania, ma kluczowe znaczenie, szczególnie w złożonych procesach (z dużą liczbą zmiennych).

Niemniej jednak, dynamiczna odpowiedź z liniowych kontrolerów nie jest akceptowalna w przypadku procesów o szerokim zakresie nieliniowości. Pomimo faktu, że w wielu sytuacjach proces będzie działał w sąsiedztwie stanu ustalonego, a zatem liniowa reprezentacja wydaje się być odpowiednia, to mogą zaistnieć nieprzewidziane (normalnie nie występujące) sytuacje. Istnieją procesy, dla których konsekwencje nieliniowości będą poważne i mające istotny wpływ na stabilność po zamknięciu pętli sprzężenia zwrotnego, że niewystarczające będzie zastosowanie modelu liniowego.

9.2. Odporne sterowanie współpalaniem węgla z biomasą

Projektowanie kontrolerów stabilizujących dla układów nieliniowych o znanych oraz nieznanach parametrach znacznie się rozwinęło w ciągu ostatnich kilku dekad. Uwzględnia ono techniki projektowania, takie jak: *adaptive feedback linearization* [22, 48, 200], *adaptive backstepping* [117, 205], odporne funkcje Lapunowa (CLF i RCLF) [52, 134, 214, 228], *nonlinear damping and swapping* [116, 118] oraz *switching adaptive control* [109, 110]. Mają one zastosowanie do sterowników globalnie stabilizujących dla jednoweściowych układów linearyzowanych z pojedynczym sprzężonym wejściem (ang. *single input feedback linearizable systems*) [22, 116, 118] oraz układów sprzężenia zwrotnego parametrycznego (ang. *parametric-strict-feedback systems*) [97, 205]. Mimo tych osiągnięć, problem sterowania adaptacyjnego szeroką klasą układów nieliniowych wciąż pozostaje aktualny. Procedura przedstawiona w pracy [111] do projektowania odpornych kontrolerów adaptacyjnych dla dużej klasy wielowymiarowych systemów nieliniowych z egzogennymi (zewnętrznymi) ograniczonymi zakłóceniami wejściowymi skutkuje podejściem, które łączy w sobie teorię funkcji Lapunowa i przełączającego kontrolera adaptacyjnego. Takie podejście pozwala przezwyciężyć problem obliczania prawa kontroli w przypadku, w którym estymowany model staje się niekontrolowalny.

Istotne jest, aby prawo sterowania zależało od estymat pochodnej Lie'go $L_g V$, która zależy zarówno od pól wektorowych układu, jak i od odpornego sterowania z funkcją Lapunowa (ang. *robust control Lyapunov function*, RCLF) V .

Klasę układów (systemów), dla których proponowane podejście znajduje zastosowanie, można scharakteryzować za pomocą następującego założenia: $L_g V$ zależy liniowo od nieznanymi stałych parametrów, gdzie g określa pole wektora wejściowego, a V jest CLF (RCLF) układu.

W przeciwieństwie do klasycznego podejścia adaptacyjnego, w którym prawo sterowania zależy od estymacji pól wektorowych układu, w przedstawianym

przypadku zależy ono od estymat RCLF [111]. $L_g V$ zależy zarówno od pól wektorów układu, jak i od funkcji V , będącą RCLF.

Z jednej strony główną zaletą takiego podejścia jest to, że nierówności Lapunowa związane z błędami oszacowania parametrów i pochodną czasową RCLF są stosunkowo łatwe w obsłudze. Z drugiej zaś strony, zaprojektowane kontrolery w dużym stopniu zależą od znajomości $L_g V$. Przy uwzględnieniu adaptacyjnych wersji takich kontrolerów istnieje ryzyko niepowodzenia polegające na tym, że oszacowanie $L_g V$ może mieć inny znak w określonych czasach niż rzeczywisty $L_g V$. Podobnie, jeżeli oszacowanie $L_g V$ jest bliskie zeru, to na przykład rzeczywiste $L_g V$ nie jest. Takie rozbieżności implikują niekontrolowalność estymowanego modelu, nawet jeśli rzeczywisty model taki nie jest.

Dzięki zastosowaniu sterowania z przełączaniem można zniwelować powyższe problemy. Jest ono zmodyfikowaną wersją prawa sterowania, przedstawioną w pracy [109]. Umożliwia ono w przybliżeniu na przełączanie pomiędzy dwoma kontrolerami adaptacyjnymi, które mają następujące właściwości: (1) oba kontrolery zachowują się w przybliżeniu tak samo w przypadku braku adaptacji i (2) gdy jeden z tych kontrolerów przestaje być użyteczny, wówczas drugi jest możliwy do zastosowania.

Proponowane podejście jest istotne, ponieważ z punktu widzenia postawionego zadania umożliwia ona projektowanie globalnie stabilizujących kontrolerów dla szerszej klasy instalacji niż *multi-input feedback linearizable systems* oraz *parametric-pure-feedback systems*, które mogą być wyrażone jako:

$$\dot{x} = Fx + G[\vartheta_1^T l_0(x) + \vartheta_2^T l_1(x)]u, \quad (9.6)$$

gdzie $x \in \mathbf{R}^n$ i $u \in \mathbf{R}^m$ oznaczają wektory stanu i sterowań, F , G , ϑ_i , $\vartheta_i = 1, 2$ są stałymi nieznanymi macierzami, a l_0 , l_1 są ciągłymi funkcjami macierzowymi, niesingularnymi dla wszystkich elementów wektora stanu układu x .

Istniejące projekty adaptacyjne gwarantują stabilność [10–12] dla zamkniętej pętli sprzężenia wyłącznie, gdy stałe macierze G , ϑ_2 są znane.

Dla układu parametrycznego z tzw. czystym sprzężeniem zwrotnym (ang. *parametric-pure-feedback system*), opisanego zależnościami:

$$\begin{aligned} \dot{x}_1 &= x_{i+1} + \theta^T f_i(x_i, \dots, x_{i+1}) & 1 \leq i \leq n-1 \\ \dot{x}_n &= \theta^T f_n + [\theta^T g_{n2}(x) + g_{n1}(x)]u' \end{aligned} \quad (9.7)$$

gdzie θ jest wektorem o nieznanach stałych parametrach, x oznacza wektor stanu układu i f_i , g_{ni} są funkcjami ciągłymi. Globalne procedury stabilności przedstawione w [97, 118, 205] gwarantują globalną stabilność tylko wtedy, gdy pole wektora wejściowego $\theta^T g_{n2}(x) + g_{n1}(x)$ jest niezależne od θ , a funkcje f_i są niezależne od x_{i+1} .

W celu sformułowania problemu rozważa się nieliniowy układ postaci:

$$\dot{x} = f(x) + g(x)u + g_w(x)w, \quad (9.8)$$

gdzie $x \in \mathbf{R}^n$, $u \in \mathbf{R}^m$ i $w \in \mathbf{R}^k$ oznaczają odpowiednio wektory stanu, sterowań i zakłóceń, natomiast f , g , g_w są polami wektorów w sensie C^1 o odpowiednich wymiarach. Przyjęto założenie, że wektor zakłóceń w jest ograniczony. Celem sterowania jest znalezienie wejścia sterującego u w funkcji x tak, aby wszystkie sygnały w pętli zamkniętej były ograniczone i $x \rightarrow 0$ oraz $t \rightarrow \infty$. Skoro $w(t) \neq 0$, $t \geq 0$ przyjmuje się, że jest dowolną nieznaną ograniczoną funkcją ciągłą czasu. Układ (9.8) jest odporny i asymptotycznie stabilizowalny (ang. *robustly asymptotically stabilizable*, RAS), gdy istnieje prawo sterowania $u = k(x)$, gdzie k jest odpowiednim sprzężeniem zwrotnym, takim, że rozwiązania w zamkniętej pętli sprzężenia zwrotnego są odporne i globalnie jednolicie asymptotycznie stabilizowane (ang. *robustly globally uniformly asymptotically stabilizable*, RGUAS), na podstawie definicje podanych w [52, 135].

Inne podejścia włączają metody sztucznej inteligencji w celu zagwarantowania odpornego sterowania adaptacyjnego dla układów nieliniowych MIMO. Kontrolery FL posiadają znaczący potencjał w zastosowaniach do układów złożonych lub posiadających nieadekwatne modele. Badania dotyczące sterowania rozmytego niepewnych układów nieliniowych rozpoczęli Wang i Mendel w [238, 239]. Według [238], możliwe jest znalezienie prawa sterowania, które zapewni stabilność układu automatycznej regulacji. Chiu [30] zaproponował uniwersalny rozmyty aproksymator do niwelowania wpływu ujemnego sprzężenia zwrotnego (ang. *universal fuzzy approximator for feedback cancellation*), gwarantujący stabilność w oparciu o drugą metodę Lapunowa.

W przypadku, gdy układ sterowania składa się z przestrajalnych zbiorów rozmytych, podejście to nazywane jest rozmytą aproksymacją Mamdani'ego (ang. *Mamdani Fuzzy Approximation*, MFA). Niemniej, na podstawie [27, 125] kontroler MFA jest rozszerzany do odpornego kontrolera adaptacyjnego, ale aby osiągnąć zadowalające przybliżenie, często wymaga to zastosowania dużej liczby reguł rozmytych. Sposoby rozwiązania tego problemu zawarto w [59, 227, 252], gdzie uwzględnia się rozmyty aproksymator Takagi-Sugeno (ang. *Takagi-Sugeno Fuzzy Approximator*, TSFA).

Jak wykazano w [53, 129, 255], w przypadku wielowymiarowych układów MIMO należy wprowadzić odwracalną rozmytą macierz wejściową (ang. *invertible fuzzy approximated input matrix*). Co więcej, niektóre przykłady łączenia sterowania rozmytego i adaptacyjnego można znaleźć w [59, 174]. Z kolei, przykłady odpornych rozmytych układów sterowania adaptacyjnego z gwarantowaną wydajnością sterowania w przestrzeni H_∞ dla określonej klasy nieliniowych systemów MIMO przedstawiono w [26, 132].

Sterowanie procesem współspalania z wykorzystaniem informacji optycznych na podstawie obrazu płomienia

Testy spalania zostały przeprowadzone na stanowisku badawczym IEN (patrz rozdział 7.2). Niskoemisyjny palnik NO_x zamontowany poziomo na przedniej ścianie komory o średnicy 0,1 m. Stanowisko posiada wszystkie niezbędne układy dostarczania paliwa: powietrza pierwotnego i wtórnego, węgla i oleju. Przygotowany wcześniej sproszkowany węgiel był składowany do bunkra i dostarczany podajnikiem. W przypadku udziału biomasy, pył węglowy po przejściu przez podajnik był mieszany ze słomą.

Po obu stronach komory spalania znajdują się otwory inspekcyjne, pozwalające na podgląd przebiegu procesu spalania oraz zapewniają możliwość akwizycji obrazu. W ramach przeprowadzonych badań w pobliżu dyszy palnika umieszczono szybką kamerę z przetwornikiem CMOS. Kamera umożliwiła rejestrację obrazu w rozdzielczości 1280 x 1024 pikseli, z szybkością 500 klatek na sekundę. Do rejestracji obrazów płomienia z wnętrza komory spalania wykorzystano boroskop o długości 0,7 m. Układ optyczny był chłodzony płaszczem wodnym, natomiast w celu uniknięcia zanieczyszczenia soczewek sondy zastosowano przedmuch oczyszczonym powietrzem. Zabieg ten istotny z punktu widzenia rejestracji, wprowadza drobne zakłócenia w obszarze spalania w pobliżu palnika.

Przebieg eksperymentu wymagał odpowiedniego przygotowania, dlatego badanie było podzielone na kilka etapów. Wstępnie, komora spalania została rozgrzana z wykorzystaniem paliwa w postaci oleju. Po osiągnięciu odpowiedniego poziomu temperatur, zasilanie olejem zostało uzupełnione, o dostarczanie do palnika węgla z powietrzem pierwotnym. Kolejna faza to wyłączenie zasilania olejem i wprowadzenie mieszanki węgla i biomasy. Współczynnik nadmiaru powietrza był określany przez przepływ powietrza wtórnego [44].

W trakcie prowadzonych badań założono dziewięć wariantów, w których moc cieplną (P_{th}) i współczynnik nadmiaru powietrza (λ) ustalono niezależnie dla znanej zawartości biomasy. Należy zauważyć, że λ zdefiniowano jako iloraz masy powietrza do spalania 1 kg paliwa do masy stechiometrycznego powietrza.


Pomiary zostały zrealizowane dla trzech wartości mocy cieplnej (250 kW, 300 kW i 400 kW) na wyjściu obiektu i określonych wartości współczynnika nadmiaru powietrza λ , równych odpowiednio 0,65, 0,75 i 0,85. Ponadto, testy obejmowały dwie mieszanki paliwowe zawierające odpowiednio 10% i 20% udział biomasy (w postaci słomy). W badaniach przyjęto, stacjonarność parametrów właściwości fizycznych biomasy (np. rozmiar cząstek, naturalna wilgotność itd.), jak również wszystkie parametry akwizycji obrazów (takie jak liczba klatek na sekundę, przyrost kamery i czas ekspozycji) pozostały niezmiennione.

Dla przeprowadzonych pomiarów podjęto próbę określenia pewnych parametrów optycznych płomienia w perspektywie użycia ich do diagnostyki oraz sterowania procesem spalania.

Przyjęto założenie, że ze względu na potrzebę opracowania algorytmu sterowania online, amplitudę pikseli obrazu ograniczono do zakresu 0–255 przez konwersję do 8-bitowej skali szarości. Obszar płomienia w każdej ramce uzyskanej sekwencji obrazu został określony na podstawie amplitudy piksela, aby odróżnić płomień o wiele jaśniejszy niż jakiekolwiek inne zarejestrowane obiekty w polu widzenia boroskopu. Zatem, suma wszystkich pikseli zawartych w jasnym obszarze wyznaczała obszar płomienia. Współrzędne centrum pola płomienia (x, y) obliczano jako wartość średnia odpowiednio współrzędnych linii lub kolumn wszystkich pikseli obszaru płomienia. Długość konturu płomienia została zdefiniowana jako suma wszystkich pikseli obwiedni, przy założeniu, że odległość między dwoma sąsiednimi punktami konturu równoległymi do osi współrzędnych ma wartość 1.

Zmiany powierzchni płomienia uzyskane dla mieszanek paliw o zawartości 10% i 20% biomasy uzyskanych dla różnych wartości mocy cieplnej i współczynnika nadmiaru powietrza przedstawiono odpowiednio na rysunkach 9.1 i 9.2. Każdy stan spalania określony przez zbiór stałych wartości P_{th} , λ i biomasy był reprezentowany przez 2000 obrazów.


Podniesienie mocy cieplnej obiektu spalania powoduje zwiększenie obszaru płomienia, jak pokazano na rysunkach 9.1a i 9.2a.



Rys. 9.1. Obszar płomienia (a), długość konturu (b) i współrzędne centrum pola płomienia (c i d) uzyskane dla różnych stanów procesu spalania – węgiel z 10% zawartością biomasy

Wzrost obciążenia termicznego wpływa również na współrzędne centrum obszaru płomienia, zwłaszcza współrzędną x dla węgla z 10% biomasy, co wskazuje, że odległość między czołem płomienia i dyszą palnika wzrasta

(rysunek 9.1c). W przypadku innej testowanej mieszanki paliwa pozycja płomienia była bardziej stabilna (rysunek 9.2c i 9.2d).



Rys. 9.2. Obszar płomienia (a), długość konturu (b) i współrzędne centrum pola płomienia (c i d) uzyskane dla różnych stanów procesu spalania – węgiel z 20% zawartością biomasy

Małe wartości dla pola płomienia i długości konturu oraz nagłe spadki współrzędnych strefy środkowej płomienia obserwowane dla $P_{th}=250$ kW i $\lambda=0,85$ wskazują na problemy ze stabilnością, które wystąpiły podczas testów spalania.

Kolejnym ważnym czynnikiem jest zmienność omawianych parametrów płomienia, które zostały obliczone dla każdego stanu spalania. Ilość nadmiaru współczynnika powietrza znacząco wpływa na proces spalania. Jednak średnia wartość pola płomienia ma różne zależności od λ dla różnych wartości mocy cieplnej. Dla $P_{th} = 400$ kW obszar płomienia zmniejsza się, gdy zwiększa się współczynnik nadmiaru powietrza dla mieszanek paliwowych z 10% i 20% biomasy.

Zmienność długości konturu płomienia jest prawie taka sama, jak w przypadku obszaru płomienia. Zmiany położenia środka płomienia są różne dla badanych wariantów. Dla zawartości biomasy równej 20% standardowe odchylenie omawianego parametru jest większe, zwłaszcza dla większej wartości mocy λ i mocy cieplnej. Porównując średnie wartości pola płomienia dla tego samego współczynnika nadmiaru powietrza, można było zaobserwować, że obszar płomienia jest większy dla mieszanek paliw o wyższej zawartości biomasy. Jest tak dlatego, że biomasa zawiera bardziej lotną zawartość w porównaniu do węgla.

Badania wykazały, że możliwe niestabilne spalanie opiera się na parametrach optycznych (np. polu powierzchni płomienia, długości konturu i współrzędnych środka płomienia), podobnie jak wyższe współczynniki nadmiaru powietrza, niezależnie od mocy cieplnej. Dla większego udziału biomasy zaobserwowano nagłe zmiany omawianych parametrów. Oznacza to niestabilne spalanie.

Sposób definiowania obszaru płomienia wpływa bezpośrednio na uzyskane wartości parametrów ilościowych obszaru płomienia i jego długości konturu. Montaż kamery prostopadłe do osi palnika pozwala na oszacowanie istotnych informacji o stanie procesu spalania [38, 147, 149, 207]. Były to odległość między palnikiem a punktem zapłonu płomienia [149, 216] oraz kąt rozproszenia płomienia. W praktyce przemysłowej dla kotłów energetycznych na pełną skalę, trudno jest zainstalować kamerę blisko palnika, ponieważ wiąże się ona z zakłóceniami w osłonie kotła. Dlatego też przetestowano alternatywną konfigurację kamery.

Proces współspalania zapewnia niezawodną kontrolę adaptacyjną z wykorzystaniem sygnałów optycznych. Dla prawidłowej pracy kotła krytyczna jest możliwość oceny jakości spalania [107]. Strumień spalania w warstwach wpływa na szybkość reakcji chemicznych, wydajność wymiany ciepła, stabilność płomienia i generowanie NO_x i CO. Według źródeł [68, 107, 108, 247] kluczowe znaczenie ma typ palnika, rodzaj paliwa i metoda kontroli wpływu na powstawanie aerodynamiki spalania.

Niskoemisyjne palniki wykorzystują właściwości redukujące wzbogaconego płomienia poprzez organizację podstechiometrycznych stref spalania za pomocą stopniowania powietrza lub paliwa. Należy jednak zauważyć, że warunki nadmiaru pyłu węglowego mogą ulec pogorszeniu, co prowadzi do zwiększenia straty niedopału. Zapewniając stabilność płomienia i stany uszkodzeń, wykrywanie wydaje się być najważniejszym parametrem z technologicznego punktu widzenia. Wpłynęło to na wykorzystanie technologii wideo i sond światłowodowych do uzupełnienia informacji diagnostycznych o płomieniu w systemie sterowania. Aby zapewnić ograniczenia emisji w trybie on-line, równie ważne są informacje ilościowe dotyczące stężenia tlenków azotu (NO_x), tlenków węgla (CO) i dwutlenku siarki (SO_2). Oprócz znaczenia stanu procesu, odrębny problem stanowi odpowiedni dobór parametrów, wybór i rozmieszczenie urządzeń pomiarowych w tak trudnych warunkach przemysłowych.

Zmiana organizacji procesu współspalania jest najbardziej popularną metodą redukcji emisji NO_x . Powoduje to jednak negatywne konsekwencje dla pracy kotła. Powoduje to wzrost strat niedopału, zwiększoną emisję CO, wzmożone zużycie, korozję parownika i niestabilność płomienia.

Z uwagi na to, że zjawiska te są niepożądane lub nawet niebezpieczne dla kotła, bardzo trudno jest osiągnąć redukcję NO_x na odpowiednim poziomie. Wprowadzenie odpowiedniego systemu monitorowania i kontroli może być rozwiązaniem problemu. Zaawansowane układy kontroli spalania wprowadzają dodatkowe modyfikacje konstrukcyjne i sygnały w postaci oddzielnego

przepływu powietrza do poszczególnych palników, dysz OFA i obciążenia młyna lub dodatkowych sygnałów z analizatorów spalin, takich jak NO_x , CO i SO_2 .

Z uwagi na to, że nadwyżka powietrza determinuje ilość NO_x wytwarzanego w energii kotła węglowego [68, 107], korzystna byłaby kontrola procesu spalania w jednym palniku.

Proces spalania zachodzący w reakcjach chemicznych i procesach fizycznych może być odbijany przez promieniowanie emitowane przez płomień. W obecnym stanie techniki, nieopóźnione i selektywne przestrzennie dodatkowe informacje o trwającym procesie spalania mogą być dostarczane nieinwazyjnie tylko z wykorzystaniem optycznych lub akustycznych metod diagnostycznych. Możliwe jest uwzględnienie określenia stosunku powietrza do paliwa, ilości wydzielanego ciepła i temperatury w zakresie spektrum płomieni w emisji widzialnej. Podejście oparte na przetwarzaniu obrazu wydaje się szczególnie ważne, ponieważ pozorna pozycja płomienia jest wynikiem dynamicznej równowagi między lokalną prędkością propagacji płomienia i prędkością wchodzącej mieszanki paliwowej. Na tej podstawie przyjmuje się, że zmiany pozycji przedniej płomienia mogą być wskaźnikiem tej rychłej nieuchronności odkształcenia, występującego w określonych warunkach [71, 100, 148, 192].

Potencjalny problem złożonych układów sterowania, na przykład procesu spalania, jest trudny (a zatem nie jest pełny) mierzący wielkości fizykochemiczne. W proponowanym rozwiązaniu klasyczne podejście jest uzupełniane informacją o płomieniu na podstawie wybranych parametrów obrazu, zarejestrowanych szybko kamerą.

W rezultacie analizy, uwidocznił się związek pomiędzy parametrami opisującymi zmiany płomienia i temperaturę gazów wydechowych w komorze lub ilość przepływu powietrza we wtórnym współczynniku. Tak więc, jeśli temperatura powoli się zmienia, mając charakter obojętny, można użyć syntezy kontrolnej szybkiego obrazu (w rzeczywistości parametru lub grupy parametrów obrazu).

Powietrze pierwotne służy głównie do dostarczania pyłu węglowego do dyszy palnika, natomiast powietrze wtórne służy do regulacji. Parametry wejściowe, takie jak ilość paliwa w postaci mieszaniny węgiel-biomasa i przepływy powietrza, były kilkakrotnie zmieniane podczas testów w celu utworzenia różnych stanów spalania.


Z powodu niepełnej wiedzy obiektu kontrolnego lub jego szybkich zmian w działaniu, kontrola adaptacyjna wydaje się rozsądnym podejściem. Nieliniowa autoregresyjna sieć z wejściami egzogennymi (NARX) stanowi rekurencyjną, dynamiczną sieć, z połączeniami zwrotnymi obejmującymi kilka warstw sieci. Model NARX oparty na liniowym modelu ARX, jest powszechnie stosowany w modelowaniu szeregów czasowych. W równaniu modelu NARX każda kolejna wartość zaleźnego sygnału wyjściowego wyznaczana względem poprzednich wartości wektora sygnału wyjściowego i poprzednich wartości niezależnego (egzogennego) sygnału wejściowego. Model NARX można zaimplementować za pomocą sieci neuronowej wprzód (ang. *feedforward*) w celu przybliżenia

określonej funkcji. Taka implementacja pozwala również na wektorowy model ARX, w którym dane wejściowe i wyjściowe mogą być wielowymiarowe.

Dane wyjściowe sieci NARX można uznać za estymatę wyjść modelowanego, nieliniowego systemu dynamicznego. Dane wyjściowe są przekazywane do wejścia sieci neuronowej dzięki sprzężeniu zwrotnemu w ramach standardowej architektury NARX. W związku z faktem, że aktualne wyjście jest dostępne podczas treningu sieci, możliwe jest stworzenie architektury szeregowo-równoległej (patrz [100]), w której używane jest wyjście z układu rzeczywistego, zamiast uzyskanej wartości estymowanej. Niestandardową architekturą używaną do dalszych analiz jest układ sterowania adaptacyjnego z modelem (MRAC). Taka architektura sterowania ma dwie podsieci. Jedna podsieć to model kontrolowanej instalacji, a druga podsieć – to kontroler.

Wytrenowany model NARX, może być użyty do utworzenia systemu MRAC i włączenia go do struktury regulatora w układzie. Wymaga to dodania połączeń pętli zwrotnych. Aby system MRAC z zamkniętą pętlą odpowiadał w taki sam sposób, jak model referencyjny (wykorzystywany do generowania danych), wagi z wytrenowanej sieci modelu instalacji powinny zostać umieszczone w odpowiedniej lokalizacji systemu MRAC. Następnie, aby uzyskać początkowe wejście o wartości zerowej, masy wyjściowe sieci sterownika zostały ustawione na zero. Szkolenie systemu MRAC trwało znacznie dłużej niż szkolenie modelu zakładu NARX w związku z faktem, że sieć jest powtarzalna i zastosowano dynamiczną propagację wsteczną. Po przeszkoleniu sieci przetestowano ją, wprowadzając dane testowe do sieci MRAC.


Zaprojektowano i porównano dwa systemy MRAC. Pierwszy z nich wykorzystywał zbiór wektorów wejściowych, opartych na klasycznych pomiarach procesu, który odpowiednio ilościowo opisuje przepływ powietrza wtórnego, ilość paliwa i wektory opisujące odpowiednio temperaturę powietrza w komorze, zapisane w pierwszym punkcie pomiarowym. Drugi schemat wykorzystywał sygnał sterowania wtórnym przepływem powietrza i wybrane deskryptory obszaru płomienia, wyznaczone w oparciu o metodę Otsu i długość konturu. Na rysunku 9.3 przedstawiono reakcję systemu na wejściową wartość zadaną układu w obu przypadkach: z klasycznymi pomiarami (a) i po zastosowaniu pomiarów optycznych w postaci wektora długości konturu dla deskryptora płomienia (b). Wyniki symulacji pokazane na rysunku 9.3 świadczą o tym, że wyjście modelu urządzenia podąża za wejściem referencyjnym z poprawną krytycznie tłumioną odpowiedzią, nawet jeśli sekwencja wejściowa nie była taka sama jak sekwencja wejściowa w danych treningowych. Reakcja w stanie stacjonarnym nie jest doskonała na każdym etapie, ale można to poprawić, stosując większy zestaw treningowy i być może bardziej ukryte neurony. Z otrzymanych wyników zaproponowanego adaptacyjnego algorytmu sterowania można wywnioskować, że ograniczenia nałożone na wartości sygnałów sterowania zapewniają stabilizację przebiegu procesu. Niemniej jednak, będą one stanowić dla niego ograniczenie, gdy nagle zmiany parametrów systemu będą wymagały gwałtownych reakcji układu sterowania.



Rys. 9.3. Odpowiedź układu sterowania kotłem pyłowym wykorzystującego (a) wektor danych wejściowych (b) dane wejściowe rozszerzoną o informację optyczną

Jak wspomniano wcześniej, nakładanie ograniczeń może być sposobem na zagwarantowanie solidności. Analizowany system sterowania został oceniony przez symulację nagłej skokowej zmiany żądania obciążenia.

Ten test powiela krytyczną sytuację, która ma miejsce, gdy wystąpi nieoczekiwana zmiana mocy i ilości rodników NO_x . Wyniki przedstawiono na rysunku 9.4.



Rys. 9.4. Odpowiedź kontrolera MIMO na nagłą zmianę obciążenia mocy w odniesieniu do zależności między stężeniami NO_x , CO i temperaturą spalin w komorze spalania

Ograniczenia są spełnione, ponieważ algorytm sprawdził wszystkie możliwe wartości niepewności. Obszar płomienia przez wielu jest używany jako jeden z głównych wskaźników stanu procesu spalania [38, 112, 147, 154, 207, 216]. Dlatego można go oszacować na serii obrazów oraz używać ze względu na szybki dostęp do informacji (w idealnym przypadku w systemach czasu rzeczywistego).

10. Zastosowanie hybrydowych struktur sieci neuronowych do modelowania i sterowania procesem spalania pyłu węglowego

Sieci wielowarstwowe są używane do identyfikacji i sterowania zarówno statycznych jak i dynamicznych układów nieliniowych [166, 167, 171], podczas gdy sieci rekurencyjne używane są jako pamięci asocjacyjne do rozwiązywania zagadnień optymalizacji szeregów czasowych [63, 217] oraz dynamicznej identyfikacji i sterowania układów nieliniowych [39, 122]. Z kolei sieci konwolucyjne mają duże zasługi w obszarze rozpoznawania wzorców, zadaniach klasyfikacji oraz przetwarzaniu obrazów [74, 121, 171].

W przypadku liniowych układów LTI (ang. *Linear Time Invariant*) o nieznanym parametrach, metody adaptacyjnej identyfikacji i sterowania zostały stosunkowo dobrze rozpoznane i udokumentowane. Co więcej, pozwalają dowiedzieć globalną stabilność tego rodzaju układów. Z kolei, jako uniwersalne aproksymatory, sztuczne sieci neuronowe, w przeciągu ostatnich trzech dekad angażowano do modelowania różnego rodzaju zjawisk nieliniowych. Należy zwrócić szczególną uwagę na trzy klasy tych rozwiązań: 1) perceptrony wielowarstwowe (ang. *multilayer perceptron, MLP*), 2) rekurencyjne sieci neuronowe (ang. *recurrent neural networks*), 3) sieci konwolucyjne (ang. *convolutional neural networks*).

Dalej podjęto próbę rozwiązania problemu identyfikacji i sterowania silnie nieliniowego zjawiska, jakim jest proces spalania pyłu węglowego i biomasy. Jego dynamika jest zbyt złożona do zamodelowania ograniczoną liczbą równań (różniczkowych).

Do przeprowadzenia badań, uwzględniono trzy wybrane struktury głębokich sieci neuronowych: MLP, prostą sieć rekurencyjną oraz komórki LSTM (ang. *Long Short Term Memory*).

Do zademonstrowania możliwości aplikacyjnych zaproponowanych metod badania przeprowadzono na danych, pochodzących z pomiarów przeprowadzonych w komorze spalania.

Celem identyfikacji procesu (także nieliniowego) jest znalezienie jednorodnej matematycznej reprezentacji na podstawie danych sygnałów wejść i wyjść. Na ogół model identyfikowanego układu może być wyrażony operatorem F z przestrzeni sygnałów wejść $\mathbb{U}$ na przestrzeń wyjść $\mathbb{Y}$, a celem jest znalezienie takiego F' , które spełnia narzucone wymagania. Należy zaznaczyć, że o ile statyczne sztuczne sieci neuronowe w ogólności mapują $\mathbb{U} \in \mathbb{R}^n$ na wyjście $\mathbb{Y} \in \mathbb{R}^m$, podczas gdy ich dynamiczne struktury, odwzorowują sygnały wejściowe $\mathbb{U}$ w zwartą przestrzeń wyjść $\mathbb{Y}$, dla której przyjęto założenie, że jest ograniczone do całkowalnych funkcji Lebesgue dla zamkniętego przedziału $[0, T]$ lub jednostronnie otwartego przedziału $[0, \infty)$. Zgodnie z teorią Stone-Weierstrassa, istnieje ciągła funkcja F , na ograniczonej, zwartej przestrzeni wejść

w obszarze $[a, b] \subset \mathbb{U}$, taka, że dla dowolnego $\varepsilon > 0$, istnieje funkcja $f \in F$, taka, że dla każdego $u \in \mathbb{U}$ obowiązuje zależność: $|Fu - fu| < \varepsilon$.

Zastosowania głębokich sieci neuronowych do zadań klasteryzacji i innych obszarów uczenia maszynowego jest dosyć powszechne. Ciekawą alternatywą wydaje się wykorzystanie odmiany rekurencyjnej sieci LSTM (ang. *Long Short Term Memory*) do identyfikacji i sterowania układem dynamicznym. LSTM stanowi obecnie jedną z najpopularniejszych struktur głębokich sieci neuronowych. Zostały one zdefiniowane przez Schmidhubera w [204], a ich najistotniejszą cechą jest unikanie zanikającego gradientu (ang. *vanishing gradient*), dzięki trzem bramkom: zapominania, wejściowej i wyjściowej. Przy ich pomocy pamięć o stanach przeszłych (historycznych) może być wydajnie kontrolowana. LSTM znajduje szerokie zastosowanie głównie w obszarze rozpoznawania mowy czy języka naturalnego. Można postawić pytanie o zasadność wyboru tej struktury algorytmów głębokiego uczenia. D argumentów przemawiających za rozwiązaniem należy zaliczyć ograniczenie problemu zanikającego gradientu oraz potencjalne możliwości odwzorowania dynamiki układu.

W złożonych procesach energetycznych możliwości precyzyjnego prognozowania parametrów mają bardzo istotne znaczenie. Spektrum możliwości zastosowania różnych rodzajów modeli jest szerokie, niemniej można je z grubsza podzielić na modele fizyczne, statystyczne, modele heurystyczne (stosujące przeważnie metody sztucznej inteligencji) oraz modele hybrydowe [240]. Modele fizyczne [256] opierają się na równaniach zasad zachowania energii, masy itp., ale uzyskanie określonych rezultatów wymaga dużej wiedzy o modelowanym obiekcie czy procesie i wiąże się z wyliczeniem bardzo dużej liczby iteracji. Modele statystyczne, których przykładem może być ARIMA (ang. *AutoRegressive Moving Average*) są konstruowane w oparciu o rezultaty identyfikacji parametrycznej, estymacji parametrów modelu [126]. Obarczone są one jednak ułomnością względem nieliniowych zależności, szczególnie złożonych obiektów/procesów [185]. Zdolność modelowania nieliniowości posiadają modele, wykorzystujące metody sztucznej inteligencji, cieszące się ostatnio znaczącym zainteresowaniem [137]. Ze względu na szczególnie niestabilne charakterystyki procesu spalania, wykorzystanie pojedynczych modeli AI, na ogół wiąże się z ich utknięciem w lokalnych minimach. Sprowadza je do zastosowań suboptymalnych. Wyklucza uzyskanie satysfakcjonującej wydajności modelu w zadaniach diagnostyki i sterowania. Niemniej, w celu niwelowania tych ograniczeń coraz odważniej stosuje się rozwiązania hybrydowe [222]. Najnowsze trendy wykazują dwa główne nurty budowy modeli hybrydowych. Jeden z nich stanowi złożenie kilku predyktorów, gdzie ich rezultaty prognozowania stanowią złożenie w celu uzyskania końcowej predykcji. Za przykład mogą tu posłużyć: FFBPNN (ang. *Feed Forward Back Propagation Neural Network*), BPNN (ang. *Back Propagation Neural Network*), BFGSNN (ang. *Broyden Fletcher Gold-farb Shanno Neural Network*), które zastosowano jako predyktory, a rezultaty prognozowania łączono przy pomocy metod GP

(ang. *Genetic Programming*). Inny rodzaj modeli hybrydowych koncentruje się na przetwarzaniu danych, w których wykorzystuje się wybrane metody dekompozycji do podziału sumarycznych parametrów procesu spalania na podwarstwy (ang. *sub-layers*). Wówczas każda z podwarstw jest prognozowana przez własny predyktor, a uzyskane rezultaty pozwalają na rekonstrukcję ostatecznego wyniku prognozowania [140]. Dowodem upowszechnienia tych metod może być znacząca liczba publikacji z tego zakresu, w ostatnich latach [140, 141].

Dekompozycja sygnału informacji wyjściowej stanowi istotny element tworzenia modelu hybrydowego. W pracy [143] wskazano użycie różnych algorytmów dekompozycyjnych, stosowanych w modelowaniu hybrydowym. Interesującą propozycję zastosowania modeli hybrydowych z wykorzystaniem transformaty falkowej (ang. *Wavelet Transform*, WT), SSA (ang. *Singular Spectrum Analysis*, SSA) oraz sieci Elmana ENN (ang. *Elman Neural Network*, ENN) przedstawiono w [253]. W pracy tej, zarejestrowane, oryginalne serie prędkości wiatru zdekomponowano na podzbiory różnych podpasów częstotliwości, gdzie podzbiór serii najwyższych częstotliwości poddano algorytmowi SSA. Uzyskane wyniki dowiodły, że proces dekompozycji znacznie poprawił dokładność prognozowania w ramach pojedynczego modelu. W pracy [158] opracowano model z zastosowaniem pakietowej transformaty falkowej – WPD (ang. *Wavelet Packet Decomposition*), COA (ang. *Crisscross Optimization Algorithm*) oraz sieci z propagacją wsteczną BPNN. Z kolei, zastosowanie transformaty curvelet do analizy obrazu płomienia oraz opracowanie klasyfikatora zaproponowano w [33, 248]

W porównaniu z konwencjonalnymi technikami sztucznych sieci neuronowych metody głębokiego uczenia (ang. *Deep Learning*, DL) pozwalają uzyskać niedostępne wprost głębokie bądź ukryte zależności na podstawie przetwarzanych sygnałów. Metody głębokiego uczenia dowiodły uzyskania wielu obiecujących rezultatów, między innymi w obszarze widzenia maszynowego oraz przetwarzaniu mowy [120]. Obiecujące rezultaty wskazanych metod stanowiły zachętę do ich implementacji w sterowaniu procesem spalania pyłu węglowego.

Dla przykładu, w pracy [236] opracowano probabilistyczny model prognozowania mocy wiatru na bazie transformaty falkowej (WT) oraz głębokiej sieci konwolucyjnej CNN (ang. *Convolutional Neural Network*), gdzie oryginalne sygnały mocy wiatru zdekomponowano na kilka podwarstw z użyciem WT. Z kolei głęboka sieć konwolucyjna została użyta do nauczania nieliniowych cech, występujących w każdej z tych podwarstw. W rezultacie uzyskano satysfakcjonującą efektywność prognozowania sygnałów. Z kolei, w pracy [142] zastosowano model z wielokrokowym prognozowaniem prędkości wiatru. W tym podejściu dokonano dekompozycji oryginalnych danych na podwarstwy, a następnie dla każdej z nich przeprowadzono SSA (ang. *Singular Spectrum Analysis*) w celu uzyskania informacji o trendach. ELM wykorzystano do przewidywania podwarstw niskoczęstotliwościowych, a sieć LSTM użyto do przewidywania podwarstw o wysokiej częstotliwości. Wyniki eksperymental-

ne wskazywały, że proponowany model miał najlepsze wyniki prognozowania wielostopniowego względem porównywanych innych ośmiu modeli.

W celu uzyskania lepszej dokładności prognozowania prędkości wiatru i siły wiatru, w modelach hybrydowych wykorzystano pewne metody korekcji błędów [222]. W pracy [133] zaproponował kombinowaną strukturę, w której SVM (ang. *Support Vector Machine*) został użyty do przewidywania oryginalnych serii siły wiatru, SVM i ELM (ang. *Extreme Learning Machine*) wykorzystywano do prognozowania błędu predykcji modelu SVM. Wyniki eksperymentu pokazały, że proponowana struktura prognozowania błędów może znacznie poprawić dokładność prognozowania siły wiatru. Jiang i in. zaproponował [91] model hybrydowy, w którym średnia zerowa prędkość wiatru została zdekomponowana przez EEMD (ang. *Ensemble Empirical Mode Decomposition*), wybrane pod-warstwy zostały przewidziane przez LSSVM, pierwotne wyniki prognozowania zostały obliczone poprzez zsumowanie przewidywanych podwarstw, LSSVM (ang. *Least Square Support Vector Machine*) i Model GARCH (ang. *Generalized Auto Regressive Conditionally Heteroscedastic*) został wykorzystany do przewidywania serii błędów. Wyniki badania pokazały, że technika modelowania błędów była korzystna dla poprawy wyników prognozowania. Poza tym zostały zrealizowane pewne algorytmy korygujące dane zewnętrzne w celu dalszej poprawy dokładności prognozowania. W pracy [159], dane odstające zostały wykryte i skorygowane zgodnie z sąsiadującymi punktami danych.

W [138] prognozowane podserie zostały połączone z oryginalnymi podseriami, natomiast WT zastosowano do odfiltrowania odstających danych. Wyniki eksperymentalne wykazały, że zaproponowane rozwiązanie odfiltrowywania danych odstających jest korzystna dla poprawy dokładności prognozowania. W badaniach zaproponowano nowy hybrydowy model oparty na powyższej strukturze hybrydowej.

Model hybrydowy jest skonstruowany w następujący sposób:

- EWT wykorzystuje się do dekompozycji pierwotnych serii pomiarów na kilka podwarstw,
- sieć LSTM użyto do przewidywania każdej podwarstwy,
- zadaniem sieci RELM jest modelowanie serii błędów każdej zdekomponowanej podwarstwy,
- IEWT użyto do rekonstrukcji w celu odtworzenia przewidywanych podwarstw i filtrowania wartości odstających.

Na podstawie [212] wykorzystano hybrydowy EWT dekomponujący wstępne przetwarzanie sygnału i strukturę przetwarzania końcowego opartą na rekonstrukcji IEWT. EWT jako stosunkowo nowa technika przetwarzania sygnałów, jest wykorzystywana do adaptacyjnego przekształcania oryginalnych sygnałów na kilka pod warstw w procesie wstępnego przetwarzania. Ponadto, IEWT jest ponownie wykorzystywany do korygowania wartości odstających w procesie przetwarzania końcowego. Skuteczność proponowanej struktury jest weryfikowana za pomocą kilku eksperymentów symulacyjnych. Dodatkowo,

proponowana struktura przetwarzania wstępnego i przetwarzania końcowego może zostać uogólniona na inne algorytmy przetwarzania sygnałów, takie jak WPD (ang. *Wavelet Packet Decomposition*), VMD (ang. *Variational Mode Decomposition*) [44], itp.

Dodatkowo, zastosowano sieć LSTM, która jest jedną z najpopularniejszych metod głębokiego uczenia do analizy sekwencji. Potencjał prognostyczny sieci LSTM zostanie przeanalizowano w całości jako pojedynczy model prognostyczny lub hybrydowy w różnych algorytmach łączących architektury. Rzeczywiste wyniki sieci LSTM dla wieloetapowego prognozowania procesu spalania zostaną określone i zbadane.


W badaniu zaproponowano hybrydowy predyktor oparty na modelowaniu błędu. W predyktorze hybrydowym sieć LSTM jest wykorzystywana jako główny predyktor; a sieć RELM, która jest popularną techniką uczenia maszynowego, jest wykorzystywana jako podrzędny predyktor do modelowania serii błędów prognozowania, pochodzących z wbudowanej sieci LSTM. Dotychczas metody modelowania błędów używano do poprawy wydajności modeli ARIMA, ELM i LSSVM, więc sprawdzenie czy wyniki prognozowania sieci LSTM i współpracy z RELM wydaje się interesujące. Połączenie sieci LSTM i sieci RELM nie było prezentowane w analizowanym obszarze. W szczególności będzie on również zintegrowany z dekompozycją EWT struktury rekonstrukcyjnej IEWT.

W odróżnieniu od innych, hybrydowych metod prognozowania, bazujących na głębokim uczeniu, poza parametrem dokładności prognozowania, uwzględniono obciążenie obliczeniowe ze względu na własności LSTM.

Do weryfikacji efektywności zaproponowanych rozwiązań użyto różne modele, uśrednionych szeregach czasowych wybranych wielkości mierzonych parametrów. Wydajność poszczególnych modeli oceniano w różnych przedziałach prognozowania.

10.1. Hybrydowy model EWT-LSTM-RELM-IEWT


Procedurę konstrukcyjną hybrydowego modelu EWT-LSTM-RELM-IEWT pokazano na rysunku 10.1.



Rys. 10.1. Etapy tworzenia modelu hybrydowego

Szczegółowe opisy objaśniono następująco:

1. Pierwotne dane pomiarowe są dekomponowane na szereg podwarstw przez algorytm EWT.
2. Podwarstwy są podzielone na dwa zbiory treningowe. Każdy zbiór danych wykorzystywany jest do konstruowania macierzy wejściowych i wyjściowych zgodnie z metodą wielokrokowego prognozowania wprzód (ang. *multi-step ahead forecasting*, patrz rysunek 10.2).



Rys. 10.2. Schemat prognozowania wielokrokowego użytego w rozwiązaniu

3. Modele LSTM są zbudowane w oparciu o pierwszy zbiór treningowy i służą prognozowania zdekomponowanych szeregów danych wejściowych. Są one następnie weryfikowane na drugim zbiorze testowym. Szereg wartości błędów prognozowania drugiego zbioru treningowego wyznacza się szeregi prognozowane od oryginalnych podzbiorów.
4. Modele RETM są konstruowane w oparciu o szeregi wartości błędów modelu drugiego zbioru treningowego do przewidywania błędów prognozowania modeli LSTM.
5. Modele LSTM i modele RELM są łączone w celu uzyskania połączonych modeli prognozowania i następnie są sprawdzane na zestawie testowym, w celu uzyskania wyniku prognozowania dla każdej wyznaczonej uprzednio podwarstwy.
6. Dane prognostyczne każdej odrębnej podwarstwy są następnie łączone z odpowiednią oryginalną podwarstwą. Segmenty widma Fouriera z pierwotnej serii danych pomiarowych stosuje się do wyznaczenia filtrów pasmowych. Algorytm IEWT jest wykorzystywany do rekonstrukcji złożonych podwarstw i uzyskania ostatecznych wyników prognozowania.
7. W badaniu uwzględniono prognozowanie wprzód z horyzontem jednokrokowym i 5-krokowym. W celu weryfikacji efektywności prognozowania prędkości wiatru w zaproponowanym modelu hybrydowym EWT-LSTM-RELM-IEWT, uwzględniono siedem różnych modeli prognostycznych. Zastosowane modele obejmowały: pojedynczy model ze wsteczną propagacją sygnału BP (ang. *Back Propagation*), pojedynczy model RELM, pojedynczy model LSTM, hybrydowy model LSTM-RELM, hybrydowy model EWT-LSTM, hybrydowy model EWT-LSTM-IEWT i hybrydowy model EWT-LSTM-RELM.

Empiryczna Transformata Falkowa – EWT

Empirical Wavelet Transform (EWT) zaproponowana przez Jerome'a Gilles [56] jest nowatorską techniką przetwarzania sygnałów, konstruuje falki zgodnie z widmem analizowanego sygnału. Na podstawie pracy [56], EWT można zrealizować w następujący sposób:

- stosując przekształcenie Fouriera analizowanego sygnału podzielonego na N sąsiednich segmentów zgodnie z algorytmem 1.
- empiryczne skalowanie funkcji i wyznaczenie empirycznych falek odpowiednio według algorytmów na podstawie wzorów (10.1) i (10.2).
- obliczenie współczynników aproksymacji i szczegółowości zgodnie z zależnościami (10.3) i (10.4).

$$\hat{\Phi}_n(\omega) = \begin{cases} 1 & \text{dla } |\omega| \leq (1 - \gamma)\omega_n \\ \cos \left[\frac{\pi}{2} \beta \left(\frac{1}{2\gamma\omega_n} (|\omega| - (1 - \gamma)\omega_n) \right) \right] & \text{dla } (1 - \gamma)\omega_n \leq |\omega| - (1 - \gamma)\omega_n, \\ 0 & \text{w przeciwnym razie} \end{cases} \quad (10.1)$$

$$\hat{\Psi}_n(\omega) = \begin{cases} 1 & \text{jeżeli } (1 + \gamma)\omega_n \leq |\omega| \leq (1 - \gamma)\omega_{n+1} \\ \cos \left[\frac{\pi}{2} \beta \left(\frac{1}{2\gamma\omega_{n+1}} (|\omega| - (1 - \gamma)\omega_{n+1}) \right) \right] & \text{jeżeli } (1 - \gamma)\omega_{n+1} \leq |\omega| \leq (1 + \gamma)\omega_{n+1} \\ \sin \left[\frac{\pi}{2} \beta \left(\frac{1}{2\gamma\omega_n} (|\omega| - (1 - \gamma)\omega_n) \right) \right] & \text{jeżeli } (1 - \gamma)\omega_n \leq |\omega| \leq (1 + \gamma)\omega_n \\ 0 & \text{w przeciwnym razie} \end{cases} \quad (10.2)$$

$$w_f^\varepsilon(0, t) = \langle f, \phi_1 \rangle = \int f(\tau) \overline{\phi_1(\tau - 1)} d\tau = (\hat{f}(\omega) \overline{\phi_1(\omega)})^\wedge, \quad (10.3)$$

$$w_f^\varepsilon(n, t) = \langle f, \varphi_n \rangle = \int f(\tau) \overline{\varphi_n(\tau - 1)} d\tau = (\hat{f}(\omega) \overline{\varphi_n(\omega)})^\wedge, \quad (10.4)$$

Dodatkowo, istnieją pewne ograniczenia, aby zachować efektywność podanego algorytmu. Na przykład współczynnik γ w zależnościach (10.1) i (10.2) jest ograniczony do małej wartości $\gamma < \min_n \frac{(\omega_{n+1} - \omega_n)}{(\omega_{n+1} + \omega_n)}$ aby zapewnić empiryczną funkcję skalowania oraz by empiryczne falki stanowiły wąską ramkę przestrzeni $L^2(R)$. Z kolei współczynnik $\beta(x)$ jest definiowany jako $\beta(x) = x^4(35 - 74x + 73x^2 - 18x^3)$. Na podstawie [22] odwrotna empiryczna transformata falkowa może być wyliczona w oparciu o równanie (10.5):

$$f(t) = w_f^\varepsilon(0, t) * \phi_1(0, t) + \sum_{n=1}^N w_f^\varepsilon(n, t) * \psi_n(t) = \left(\hat{w}_f^\varepsilon(0, \omega) \hat{\phi}_1(\omega) + \sum_{n=1}^N \hat{w}_f^\varepsilon(n, \omega) \hat{\psi}_n(\omega) \right) \quad (10.5)$$

Odwrotna empiryczna transformacja falkowa jest wykorzystywana w pracy do korygowania wartości odstających szeregu prognozowania. W tym celu segmenty widmowe trenowanych szeregów są wykorzystywane jako oszacowania połączonych szeregów, które łączą szeregi wytrenowane z szeregami prognoz.

10.2. Struktura długiej pamięci krótkotrwalej (LSTM)

Sieć LSTM, którą zaproponowali Hochreiter i Schmidhuber [204] w 1997 r. jest specjalną wersją struktury rekurencyjnej RNN (ang. *Recurrent Neural Network*) w ramach sztucznych sieci neuronowych. Komórki pamięci są głównymi komponentami sieci LSTM, które odróżniają ją od konwencjonalnego RNN. Jak opisano w [60, 62], istnieją trzy rodzaje jednostek multiplikatywnych: brama wejściowa, brama wyjściowa i bramka zapominania w komórkach pamięci. Bramki te aktualizują stan komórek pamięci w następujący sposób [139]: (a) dane wejściowe są mnożone przez wyjście bramki wejściowej w celu określenia nowej informacji, która może być akumulowana w komórce; (b) dane wyjściowe do sieci są mnożone przez aktywację bramki wyjściowej w celu obliczenia informacji, które mogą być propagowane do sieci; (c) poprzednie stany komórek są mnożone przez aktywację bramki zapominania, w celu określenia, czy należy zapomnieć ostatni (dotychczasowy) stan komórki.

Zgodnie z pracą [64], wektor M wymiarowy x^t definiowany jest jako wektor wejściowy w czasie t ; liczba komórek LSTM jest ustawiona na N ; $\omega_z, \omega_i, \omega_f, \omega_o \in \mathbb{R}^{N \times M}$ stanowią wagi wejść, $r_z, r_i, r_f, r_o \in \mathbb{R}^{N \times M}$ to bieżące wagi, $p_i, p_f, p_o \in \mathbb{R}^N$ to tak zwane wagi peephole [42] oraz $b_z, b_i, b_f, b_o \in \mathbb{R}^N$ stanowią progi aktywacji. Przekazanie informacji w przód sieci LSTM można zdefiniować w następujący sposób:

$$z^t = g(\omega_z x^t + r_z y^{t-1} + b_z), \quad (10.6)$$

$$i^t = \sigma(\omega_i x^t + r_i y^{t-1} + p_i \cdot c^{t-1} + b_i), \quad (10.7)$$

$$f^t = \sigma(\omega_f x^t + r_f y^{t-1} + p_f \cdot c^{t-1} + b_f), \quad (10.8)$$

$$c^t = z^t \cdot i^t + c^{t-1} \cdot f^t, \quad (10.9)$$

$$o^t = \sigma(\omega_o x^t + r_o y^{t-1} + p_o \cdot c^t + b_o), \quad (10.10)$$

$$y^t = h(c^t) \cdot o^t. \quad (10.11)$$

gdzie z^t stanowi sygnał aktywacji wejścia bloku, i^t to aktywacja bramki wejściowej, f^t stanowi sygnał aktywacji bramki zapominania, c^t opisuje stan komórki w czasie t . Ponadto $g(x)$, $\sigma(x)$ oraz $h(x)$ są funkcjami aktywacji. Z kolei do aktywacji bramki aktywacji użyto funkcji sigmoidalnej $\sigma(x) = 1/(1 + e^{-x})$, natomiast do aktywacji bloku wejścia oraz wyjścia zastosowano funkcję tangensa hiperbolicznego $g(x) = h(x) = \tanh(x)$.

10.3. Algorytm RELM

ELM (ang. *Extreme Learning Machine*) stanowi nowatorski algorytm uczenia sieci z pojedynczą warstwą ukrytą. RELM (ang. *Regularized Extreme Learning Machine*), pobiera normy wag wejściowych dla funkcji kary i stanowi ulepszoną wersję ELM. Realizację algorytmu przedstawiono poniżej:

Wejścia sieci są mapowane na przestrzeń cech pierwszej warstwy wejściowej:

$$M = \begin{bmatrix} m(a_1, b_1, x_1) & \dots & m(a_L, b_L, x_a) \\ \vdots & m(a_L, b_L, x_a) & \vdots \\ m(a_1, b_1, x_N) & \dots & (a_L, b_L, x_a) \end{bmatrix}. \quad (10.15)$$

W ramach której N - wymiarowy wektor $[x_1, x_2, \dots, x_N]^T$ stanowi wejście tej sieci, z kolei L to liczba ukrytych węzłów, $m(a, b, x)$ to funkcja mapująca z wejściowymi parametrami postaci a i b . Przy czym funkcja gaussowska uwzględniona jest jako $m(a, b, x) = e^{-b\|x-a\|^2}$.

Zmapowany zbiór cech jest mnożony przez wagi wyjść, w celu uzyskania $y(x) = M\beta$, gdzie β określa wagi wyjściowe macierzy, natomiast C to współczynnik regularyzacji.

Wartość β wyznaczana jest jako rozwiązanie problemu nieograniczonej optymalizacji, danej zależnością:

$$\min_{\beta \in \mathbb{R}^{L \times m}} \xi_{RELM} = \frac{1}{2} \|\beta\|^2 + \frac{C}{2} \sum_{i=1}^N \|Y - M\beta\|^2, \quad (10.16)$$

gdzie Y stanowi macierz docelową danych uczących, zgodnie z [81], natomiast rozwiązanie β może być opisane jako:

$$\beta^* = \begin{cases} \left(M^T M + \frac{I}{C} \right)^{-1} M^T Y & N > L \\ M^T \left(M^T M + \frac{I}{C} \right)^{-1} Y & N < L \end{cases}, \quad (10.17)$$

gdzie I to L wymiarowa macierz jednostkowa.

W celu zapewnienia efektywnego porównania zaproponowanych modeli, uwzględniono różne wskaźniki oceny wydajności. Należą do nich: średni błąd bezwzględny – MAE (ang. *Mean Absolute Error*), średni procentowy błąd bezwzględny – MAPE (ang. *Mean Absolute Percentage Error*), odchylenie standardowe – SDE (ang. *Standard Deviation of Error*), oraz średni błąd kwadratowy – RMSE (ang. *Root Mean Square Error*). Mogą być one definiowane jako:

$$MAE = (\sum_{t=1}^N |x(t) - \hat{x}(t)|) / N, \quad (10.18)$$

$$MAPE = (\sum_{t=1}^N |(x(t) - \hat{x}(t)/x(t))|) / N, \quad (10.19)$$

$$RMSE = \sqrt{(\sum_{t=1}^N [x(t) - \hat{x}(t)]^2) / N} \quad (10.20)$$

$$SDE = \sqrt{\left(\sum_{t=1}^N [x(t) - \hat{x}(t) - \sum_{t=1}^N (x(t) - \hat{x}(t))/N]^2\right) / N} \quad (10.21)$$


gdzie $x(t)$ reprezentuje wartości zmierzone, $\hat{x}(t)$ – wartości prognozowane, a N jest liczbą $x(t)$.

Średnie wartości omówionych wskaźników, określających dokładność modelu względem wybranej serii danych zestawiono w tabeli 10.1.

Tabela 10.1. Wyznaczone średnie wartości błędów dla różnych modeli prognostycznych procesu spalania, wyznaczone dla wybranej serii danych.

Model	MAE	MAPE	RMSE	SDE
BP	19,508	14,9713	24,071	24,89
RELM	20,053	18,1343	25,631	25,614
LSTM	20,598	21,2973	27,191	26,338
LSTM-RELM	21,143	24,4603	28,751	27,062
EWT-LSTM	9,688	8,6233	13,412	11,226
EWT-LSTM-IEWT	8,323	7,3863	10,634	10,634
EWT-LSTM-RELM	2,478	2,9493	4,532	4,381
EWT-LSTM-RELM-IEWT	1,432	1,2123	1,927	1,631

Z kolei na rysunku 10.3 zamieszczono wykres radarowy dla wyznaczonych wskaźników oceny wydajności modelowania.



Rys. 10.3. Wykres radarowy wskaźników dokładności modeli

W badaniu uwzględniono prognozowanie wprzód z horyzontem pięciokrokowym. Na podstawie przeprowadzonych analiz można stwierdzić, że najlepsze rezultaty modelowania szeregów czasowych procesu spalania uzyskano z wykorzystaniem metody hybrydowej EWT-LSTM-RELM-IEWT.

Najmniej atrakcyjny w tym zestawieniu okazał się pojedynczy model ze wsteczną propagacją sygnału BP (ang. *Back Propagation*). *Regularized Extreme Learning Mashine* (RELM) samodzielnie czy też w połączeniu z modelem LSTM zapewniły wartości średnie RMSE i SDE praktycznie o rząd wielkości większe.

Algorytm IEWT wykorzystano do rekonstrukcji złożonych podwarstw i uzyskania ostatecznych wyników prognozowania.

Mimo stosunkowo dużej złożoności obliczeniowej, hybrydyzacja modeli do celów prognozowania złożonych procesów wydaje się kierunkiem słusznym.

11. Podsumowanie

Spalanie, w szczególności prowadzone w warunkach przemysłowych, należy do grupy procesów technologicznych o bardzo dużej złożoności. Wynika to ze specyfiki zjawisk, towarzyszących temu procesowi, jak i trudnych warunków pracy układu, w którym jest realizowany, włączając w to ograniczenia dostępności w zakresie pomiarów, diagnostyki i sterowania.

Na podstawie przeglądu literatury oraz własnych dokonań analityczno-badawczych autora można stwierdzić, iż przeprowadzona w niniejszej rozprawie systemowa analiza zaawansowanych technik sterowania spalaniem pyłu węglowego ma charakter innowacyjny lub nie została opublikowana. W pracy zaproponowano wykorzystanie sterowania adaptacyjnego z różnymi referencyjnymi modelami prognostycznymi.

Dominującym nurtem omawianych zagadnień jest klasa algorytmów adaptacyjnych z modelem referencyjnym – Model Predictive Control. W rozdziale drugim zamieszczono charakterystykę stanu wiedzy z zakresu sterowania złożonymi procesami. Wychodząc od klasycznych technik projektowania regulatorów, po sterowanie predykcyjne, autor postawił przed sobą zadanie przedstawienia technik sterowania, które są stosunkowo dobrze ugruntowane w praktyce przemysłowej i posiadają potencjał dla pozytywnej weryfikacji praktycznej. Wynika ona z zastosowań tej klasy algorytmów głównie w przemyśle chemicznym i petrochemicznym. Stanowią one stosunkowo prostą w projektowaniu i przekonującą technikę umożliwiającą implementację złożonych modeli wielowymiarowych. Algorytmy te są koherentne zarówno dla modeli liniowych, jak i nieliniowych.

Warto podkreślić, że w omawianym podejściu, w sposób bezpośredni uwzględniane są ograniczenia sygnałów sterujących, jak i wielkości wyjściowych. Wygenerowane sterowania uwzględniają również interakcje wewnętrzne w obiekcie, dzięki bezpośredniemu wykorzystaniu modelu, co zostało zaproponowane do sterowania procesem spalania pyłu węglowego i współspalania z biomasą. Przy obecnym poziomie techniki wydaje się, że algorytmy te mogą być stosowane zarówno w układach sterowania nadrzędnego, jak i w podstawowych pętlach warstwy regulacji bezpośredniej.

W rozdziale trzecim zostało omówione spalanie w kotłach energetycznych. Przedstawiono najistotniejsze informacje dotyczące paliw stałych. Opis procesu, metod monitorowania i diagnostyki ograniczono do charakterystyki procesu spalania węgla (i współspalania z biomasą) w kotłach energetycznych z palnikami pyłowymi. Podkreśla się w nim spektrum czynników mających istotny wpływ na przebieg procesu, jego niejednorodność oraz stabilność przebiegu. Omówiono tu zjawiska fizyczne, występujące w procesach energetycznych w kotłach na paliwa stałe. Stanowi to punkt wyjścia do syntezy uproszczonego, matematycznego modelu procesu spalania w kotle opromieniowanym.

Rozdział czwarty poświęcony jest spalaniu w kotłach pyłowych. Omawiane są tu zastosowania i wymogi wybranych podukładów kotła, jak również

konstrukcyjne czynniki zapewniające odpowiednią jakość spalania. Celem tej części pracy było przedstawienie technicznych problemów z zapewnianiem pożądanego podawania paliwa pyłowego oraz zagrożeń z nich wynikających, jak i charakterystyki etapów spalania mieszanki pyłowo-powietrznej w komorze. Są one uzupełnione o opis mechanizmów i rozwiązań technicznych, głównie konstrukcyjnych, zapewniających niwelowanie wybranych problemów, jak np. przez rozmieszczenie czy konstrukcje palników. Wskazuje się najistotniejsze wymagania względem układu sterowania.

Kolejny rozdział charakteryzuje modelowanie układu sterowania kotłem pyłowym ze szczególnym uwzględnieniem komory spalania. W oparciu o przedstawione równania matematyczne, główne parametry, niezbędne do tego, aby spalanie pyłu węglowego mogło zachodzić w kotle ze zrównoważonym ciągiem przedstawiono uproszczony model matematyczny komory spalania. Uwzględnia on klasyczne metody regulacji z użyciem regulatora PID.

Z uwagi na ograniczenia realizacji sterowania z wykorzystaniem uogólnionych modeli matematycznych do silnie nieliniowego procesu o dużej dynamice, w rozdziale szóstym wskazano możliwości wykorzystania sztucznych sieci neuronowych w modelowaniu procesu spalania w kotle pyłowym. W możliwie syntetyczny sposób starano się przedstawić przejście od klasycznych sztucznych sieci neuronowych do współczesnych zastosowań struktur i metod głębokiego uczenia. Zrezygnowano tu z omawiania zagadnień ważnych, choć znajdujących się na etapie bardziej badań i poszukiwań. Dlatego w rozdziale skupiono się na wybranym rozwiązaniu długiej pamięci krótkotrwałej LSTM, jako istotny przypadek rekurencyjnych sieci neuronowych. Struktury te są modelowane na podstawie zachowań, występujących w naturze komórek z pamięcią o adresowalnej treści. Wpisują się one w trendy współczesnych rozwiązań sztucznej inteligencji, że tradycyjne metody projektowania można zastąpić treningiem współpracujących modułów z inteligentnymi składnikami w celu optymalizacji globalnego kryterium wydajności.

Rozdział siódmy zawiera koncepcję proekologicznego sterowania procesem spalania pyłu węglowego w badawczym stanowisku komory spalania z wykorzystaniem dodatkowych, informacji optycznych.

Analiza obrazu polegała na wyznaczeniu prostych wskaźników geometrycznych zarejestrowanych obrazów obszaru płomienia: pole powierzchni oraz długość jego konturu. Uzyskane rezultaty wykazały możliwość estymacji parametrów spalania na podstawie rejestrowanych obrazów. Stąd, informacja z optycznego układu diagnostycznego, dotycząca zmian położenia płomienia w przeprowadzonych badaniach symulacyjnych została użyta do sterowania prognostycznego z modelem, utrzymując emisję NO_x poniżej narzuconych poziomów. Takie podejście, pomimo że posiada suboptymalny charakter ze względu na zmienność paliwa oraz innych czynników, zachęciło autora do dalszych badań z użyciem alternatywnych modeli. W konsekwencji, w rozdziale ósmym monografii omówiono modelowanie asymetrycznej, rekurencyjnej sztucznej sieci neuronowej do sterowania kotłem pyłowym.

Zaproponowaną strukturę zestawiono z wynikami uzyskanymi dla klasycznej sieci MLP.

W rozdziale dziewiątym poruszono zagadnienia niepewności i sterowania odpornego. Przytoczone wyniki badań symulacyjnych sterowania procesem spalania w strukturze MRAC z modelem NARX, zaimplementowanego w postaci sztucznej sieci neuronowej. Zaprojektowano i porównano dwa systemy MRAC. Pierwszy z nich wykorzystywał nieoptyczny, oparty na pomiarach zbiór wektorów wejściowych, odpowiednio ilościowo opisuje przepływ powietrza wtórnego, koszt paliwa i wektory opisujące odpowiednio temperaturę powietrza w komorze, zapisane w pierwszym punkcie pomiarowym. Drugi schemat wykorzystywał sygnał sterowania przepływem powietrza wtórnego i wybrane deskryptory kształtu płomienia.

Metody hybrydowych struktur sztucznych sieci neuronowych do modelowania i sterowania procesem spalania pyłu węglowego zostały omówione w rozdziale dziewiątym. Do przeprowadzenia badań, uwzględniono trzy wybrane struktury głębokich sieci neuronowych: MLP, prostą sieć rekurencyjną oraz komórki LSTM. Do opracowania jednolitego modelu hybrydowego zastosowanie algorytm wykorzystano hybrydowy EWT, dekomponujący wstępne przetwarzanie sygnału i strukturę przetwarzania końcowego opartą na rekonstrukcji IEWT. Z kolei sieć LSTM użyto do przewidywania każdej podwarstwy. Dodatkowo, w podejściu hybrydowym sieć LSTM jest wykorzystywana jako główny predyktor a sieć RELM, która jest popularną techniką uczenia maszynowego, została użyta jako predyktor podrzędny do modelowania serii błędów prognozowania, pochodzących z wbudowanej sieci LSTM.

Proces spalania, jak to już wcześniej wspomniano, w szczególności prowadzony w warunkach przemysłowych, cechuje się bardzo dużą złożonością. Wynika to z charakteru zjawisk, towarzyszących procesowi, jak i utrudnionych warunków pomiarowych, obejmujących niedostępność określonych wielkości oraz wpływ wysokiej temperatury, wibracji i zapylenia na urządzenia pomiarowe oraz rejestrujące. Problematyka omawiana w niniejszej pracy, niezależnie od trendów w zakresie spalania pyłu węglowego w energetyce zawodowej, porusza szereg zagadnień intensywnie rozwijanych wielu prac badawczych. Podjęto w niej próbę sterowania jednym z najtrudniejszych procesów z wykorzystaniem metod analitycznych po heurystycznych oraz hybrydowych. Przeprowadzone badania wpisują się w kierunki poszukiwania algorytmów dla procesów nieliniowych, które będą niezawodne numerycznie, odporne, jak i przede wszystkim umożliwią spełnienie ograniczeń technologicznych w warunkach niepewności.

Do oryginalnych osiągnięć autora można zaliczyć:

- Uczestnictwo w realizacji badań procesu spalania na obiektach przemysłowych, jak również na stanowisku laboratoryjnym.
- Weryfikacja poprawności i przygotowanie danych do analiz z wykorzystaniem narzędzi analitycznych i symulacyjnych.
- Opracowanie oryginalnych modeli procesu przeznaczonych do sterowania.

- Wykorzystanie optycznych sygnałów diagnostycznych w algorytmie sterowania procesem spalania do prognozowania emisji NO_x oraz optymalizacji pracy kotła.
- Przygotowanie struktur algorytmów sterowania z modelem referencyjnym, w tym zastosowaniem modeli głębokiego, w szczególności z zastosowaniem pamięci długiej krótkotrwałej (LSTM).
- Przeprowadzenie dyskusji na temat odpornego sterowania procesem spalania.
- Podjęcie tematu zastosowania hybrydowych struktur głębokich rekurencyjnych sieci neuronowych, obejmujących EWT-LSTM-RELM-IEWT do modelowania i sterowania procesem spalania pyłu węglowego.

Przedstawione w niniejszej pracy wyniki badań i analiz nie wyczerpują problemów związanych ze sterowaniem procesem spalania. Doskonalenia wymagają kwestie dynamiki spalania z bardziej szczegółową analizą parametryczną stabilności, jak i warunków występowania turbulencji. W układzie sterowania można uwzględnić inne sygnały optyczne, w tym barwę płomienia oraz rozszerzenie metod hybrydowych o zastosowanie algorytmów rozmytych. W przekonaniu autora zaawansowane algorytmy sterowania będą nadal rozwijane oraz stosowane w szerokim zakresie nie tylko w instalacjach przemysłowych. Można zaryzykować stwierdzenie, że będą się przesuwać w kierunku hybrydyzacji metod sztucznej inteligencji z innymi podejściami.

Literatura

- [1] Abadi, M., Agarwal, A., Barham, P., Brevdo, E., et al., TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems 2016.
- [2] Alwright, J.C., *Advances in model-based predictive control, chapter on min-max Model-Based Predictive Control*, 1994.
- [3] Ansys, I., *ANSYS FLUENT theory guide*, vol. 15317, 2011.
- [4] Arabas J., Domanski P. D., S.K., Praktyczne aspekty modelowania i optymalizacji procesów przemysłowych, *PAK* 1998, 6, 195–202.
- [5] Arabas, J., Białobrzeski, L., Chomiak, T., Domański, P.D., et al., Pulverized Coal Fired Boiler Optimization and NO_x Control using Neural Networks and Fuzzy Logic. *AspenWorld'97* 1997.
- [6] Arabas, J., Białobrzeski, L., Domański, P.D., Świrski, K., in: *Mmar '98*, 1998, 521–526.
- [7] Arnold, W.I., *Metody matematyczne mechaniki klasycznej*, PWN, Warszawa 1981.
- [8] Aschepkov, L.T., Dolgy, D. V., Kim, T., Agarwal, R.P., *Optimal Control*, Consultants Bureau, New York 2016.
- [9] Baek, W.B., Lee, S.J., Baeg, S.Y., Cho, C.H., in: *Ind. Electron. 2001. Proceedings. ISIE 2001. IEEE Int. Symp.*, vol. 2, 2001, 928–931.
- [10] Ballester, J., Hernández, R., Sanz, A., Smolarz, A., et al., Chemiluminescence monitoring in premixed flames of natural gas and its blends with hydrogen. *Proc. Combust. Inst.* 2009, 32 II, 2983–2991.
- [11] Baukal, C.E., Gershtein, V., Li, X.J., *Computational Fluid Dynamics in Industrial Combustion*, CRC Press, New York 2000.
- [12] Baum, M.M., Street, P.J., Predicting the Combustion Behavior of Coal Particles. *Combust. Sci. Tech.* 1971, 231–243.
- [13] Bazarra, M., Sherali, H., Shetty, C., *Nonlinear programming: Theory and algorithms*, Wiley, 2013.
- [14] Benett, S., *A History of Control Engineering 1930-1955*, Peter Peregrinus, 1993.
- [15] Benett, S., Fuller, A.T., *A History of Control Engineering 1800–1930*. Peter Peregrinus, 1979.
- [16] Bengio, Y., Simard, P., Frasconi, P., Learning Long-Term Dependencies with Gradient Descent is Difficult. *IEEE Trans. Neural Networks* 1994, 5, 157–166.
- [17] Bissell, C.C., in: Springer (Ed.), *Springer Handb. Autom.*, 2009, 53–69.
- [18] Booth, R.C., Roland, W.B., in: *Dyn. Model. Control Appl. Ind. Work. 1998. IEEE Ind. Appl. 1998*, 1998, 1–6.
- [19] Bris, T. Le, Cadavid, F., Caillat, S., Pietrzyk, S., et al., Coal combustion modelling of large power plant , for NO_x abatement. *Fuel* 2007, 86, 2213–2220.
- [20] Brzózka, J., in: *Regul. i układy Autom.*, Wydawnictwo Mikom, Warszawa 2004.

- [21] Camacho, E.F., Bordons, C., *Model Predictive control*, 2007.
- [22] Cambion, G., Bastin, G., Indirect adaptive state feedback control of linearly parameterized nonlinear systems. *Int. J. Adapt. Control Signal Process.* 1990, 4, 45–358.
- [23] Campo, P.J., Morari, M., in: *Proc. 1987 Am. Control Conf.*, 1987, 1021–1026.
- [24] Cengel, A.Y., Boles, A.M., *Thermal Dynamics—An Engineering Approach. 7th Ed. SI units* 2011, 689–833.
- [25] Chan, C.W., Huang, G.H., Artificial intelligence for management and control of pollution minimization and mitigation processes. *Eng. Appl. Artif. Intell.* 2003, 16, 75–90.
- [26] Chang, Y., Chen, B., Robust tracking designs for both holonomic and non-holonomic constrained mechanical systems: adaptive fuzzy approach. *IEEE Trans. Fuzzy Syst.* 2000, 8, 46–66.
- [27] Chen, B., Sen, Lee, C.H., Chang, Y.C., H_∞ tracking design of uncertain nonlinear SISO systems: Adaptive fuzzy approach. *IEEE Trans. Fuzzy Syst.* 1996, 4, 32–43.
- [28] Chen, L.Y., Hong, W.C., Panigrahi, B.K., Wei, S.Y., in: *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 7076 LNCS, Springer-Verlag, 2011, 248–256.
- [29] Chen, X., Gao, L., Zhou, J., Gao, H., et al., Boiler combustion control model of large-scale col-fired power plant with asymmertric artificial neural networks, *2017 IEEE 2nd Inf. Technol. Networking, Electron. Autom. Control Conf.*, 2017, 980–983.
- [30] Chiu, C., Robust adaptive control of uncertain MIMO non-linear systems — feedforward Takagi – Sugeno fuzzy approximation based approach. *IEEE Proceedings Control Theory Appl.* 2005, 152, 157–164.
- [31] Chu, J.Z., Shieh, S.S., Jang, S.S., Chien, C.I., et al., Constrained optimization of combustion in a simulated coal-fired boiler using artificial neural network model and information analysis. *Fuel* 2003, 82, 693–703.
- [32] Chunlai, B., Jingfei, Z., Combustion Optimization of Power Plant Boilers Based on RBF Neural Network Model. *Power Equip.* 2013, 27, 97–100.
- [33] Ciężczyk, S., Ławicki, T., Miaskowski, A., The curvelet transform application to the analysis of data received from GPR technique. *Elektron. IR ELEKTROTECHNIKA* 2013, 19, 99–102.
- [34] Computation, N., Long Short-term Memory. *Neural Comput.* 2016, 9, 1735–1780.
- [35] Cruz-Peragón, F., Jiménez-Espadafor, F.J., A genetic algorithm for determining cylinder pressure in internal combustion engines. *Energy Fuels* 2007, 21, 2600e7.
- [36] D’Errico, G., Prediction of the combustion process and emission formation of a bi-fuel s.i. engine. *Energy Convers. Manag.* 2008, 49, 3116–3128.

- [37] Demayo, T.N., McDonell, V.G., Samuelsen, G.S., Robust active control of combustion stability and emissions performance in natural gas-fired industrial burner a fuel-staged. *Int. Symp. Combust. Abstr. Accept. Pap.* 2002, 121.
- [38] Demirbaş, A., Sustainable cofiring of biomass with coal. *Energy Convers. Manag.* 2003, 44, 1465–1479.
- [39] Dinh, H., Bhasin, S., Dixon, W.E., in: *49th IEEE Conf. Decis. Control*, 2010, 5536–5541.
- [40] Domański, P.D., Lewandowski, J., Świrski, K., in: *VIII Konf. Kotłowa '98*, 1998, p. Vol.1, 165–182.
- [41] Dorato, P., *Robust Control*, Published for the IEEE Communications Society by the IEEE Press, New York 1987.
- [42] Doyle, J., Stein, G., in: *IEEE Trans. Autom. Control*, vol. 24, 1979, 607–611.
- [43] Doyle, J.C., Stein, G., in: *IEEE Trans. Autom. Control. AC-26; Feb. 1981*, 1981.
- [44] Dragomiretskiy, K., Zosso, D., Variational mode decomposition. *IEEE Trans. Signal Process.* 2014, 62, 531–544.
- [45] Duch, W., Dobosz, K., in: Tadeusiewicz R, Korbicz J, Rutkowski L, Duch W (Eds.), *Sieci neuronowe w inżynierii Biomed.*, EXIT, Warszawa 2013, 637–666.
- [46] Duzinkiewicz, K., *Zintegrowane sterowanie systemami zaopatrzenia w wodę pitną*, Uczelniane Wydawnictwa Naukowo-Dydaktyczne AGH, 2005., Kraków 2005.
- [47] Falcone, P., Tufo, M., Borrelli, F., Asgari, J., Tseng, H.E., in: *2007 46th IEEE Conf. Decis. Control*, New Orleans, LA 2007, 2980–2985.
- [48] Faulwasser, T., Kern, B., Findeisen, R., in: *Proc. IEEE Conf. Decis. Control*, Shanghai, P.R. China 2009, 8642–8647.
- [49] Flynn, D., *Thermal Power Plant Simulation and Control*, IET, The Institution of Engineering and Technology, Michael Faraday House, Six Hills Way, Stevenage SG1 2AY, UK 2003.
- [50] Forbes, M.G., Patwardhan, R.S., Hamadah, H., Gopaluni, R.B., in: *IFAC-PapersOnLine*, vol. 48, Whistler, Canada 2015, 531–538.
- [51] Fostås, B., Gangstad, A., Nenseter, B., Pedersen, S., et al., Effects of NO_x in the flue gas degradation of MEA. *Energy Procedia* 2011, 4, 1566–1573.
- [52] Freeman, R.A., Kokotovic, P. V., Inverse Optimality in Robust Stabilization. *SIAM J. Control Optim.* 1996, 34, 1365–1391.
- [53] Gao, Y., Er, M.J., in: Da R (Ed.), *Analysis*, World Scientific, Gent 2002, 1–5.
- [54] Garcia-Romero, D., McCree, A., in: *Proc. Annu. Conf. Int. Speech Commun. Assoc. INTERSPEECH*, vol. 2015–Janua, 2015, 1141–1145.
- [55] Gibbins, J., Lin, Y.M., Bowden, S., Cameron, S., Video observations of full-size pulverised coal flames. *Combust. Sci. Technol.* 2001, 162, 263–280.

- [56] Gilles, J., Empirical wavelet transform. *IEEE Trans. Signal Process.* 2013, 61, 3999–4010.
- [57] Gilman, J., *Boiler control systems engineering*, ISA – The Instrumentation, Systems and Automation Society, New York 2005.
- [58] Gobbato, P., Masi, M., Toffolo, A., Lazzaretto, A., Tanzini, G., Calculation of the flow field and NO_x emissions of a gas turbine combustor by a coarse computational fluid dynamics model. *Energy* 2012, 45, 445–455.
- [59] Golea, N., Golea, A., Kadjoudj, M., Fuzzy approximation-based model reference adaptive control of nonlinear systems. *Proc. IEEE Conf. Control Appl.* 2003, 836–840.
- [60] Goodfellow, I., Bengio, Y., Courville, A., *Deep learning*, vol. 13, MIT Press, 2017.
- [61] Górecki, H., *Optymalizacja i sterowanie systemów dynamicznych*, Uczelniane Wydawnictwa Naukowo-Dydaktyczne AGH, Kraków 2006.
- [62] Graves, A., Schmidhuber, J., Framewise Phoneme Classification with Bidirectional {LSTM} Networks. *Proc. Int. Jt. Conf. Neural Networks IJCNN 2005* 2005, 18, 602–610.
- [63] Graves, A., Mohamed, A., Hinton, G., in: *EEE Int. Conf. Acoust. Speech Signal Process.*, 2013, 6645–6649.
- [64] Greff, K., Srivastava, R., Koutnik, J., Steunebrink, B., Schmidhuber, J., LSTM: a search space odyssey. *IEEE Trans. Neural Networks Learn. Syst.* 2017, 28, 2222–2232.
- [65] Guo, M.L., Li, D.J., Du, C. Ben, Jia, Z.H., et al., *Prediction of the busy traffic in holidays based on GA-SVR*, vol. 169 AISC, Springer, Berlin Heidelberg 2012.
- [66] Hajdo, S., Klich, J., Polak, K., Właściwości węgla niskogatunkowych w podziemnym zgazowaniu węgla. *Górnictwo i Geoinżynieria* 2011, 35, 87–93.
- [67] Hao, Z., Kefa, C., Jianbo, M., Combining neural network and genetic algorithms to optimize low NO_x pulverized coal combustion. *Fuel* 2001, 80, 2163–2169.
- [68] Hardy, T., Kordylewski, W., Zacharczuk, W., Golec, T., Świątkowski, B., Reburning węglem brunatnym w kotłach pyłowych opalanych węglem kamiennym. *Aktual. Probl. budowy i Eksploat. kotł. Międzynarodowa X Konf. Kotłowa, Szczyrk, 17-20 października 2006. T. 1. Gliwice* 2006, 1, 293–301.
- [69] Hein, K.R.G., Bemtgen, J.M., EU clean coal technology - Co-combustion of coal and biomass. *Fuel Process. Technol.* 1998, 54, 159–169.
- [70] Heirung, T.A.N., Paulson, J.A., O’Leary, J., Mesbah, A., Stochastic model predictive control — how does it work? *Comput. Chem. Eng.* 2017.
- [71] Hii N.C., Tan C.K., Alex Z., S. Chong, W.J., in: *7th INFUB*, American Society of Mechanical Engineers, Rio Tinto 2006, 326–338.

- [72] Hill, S.C., Smoot, L.D., Modeling of nitrogen oxides formation and destruction in combustion systems. *Prog. Energy Combust. Sci.* 2000, 26, 417–458.
- [73] Hinton, G., Deep Belief Nets 2007, 1–100.
- [74] Hinton, G., Deng, L., Yu, D., Dahl, G., et al., in: *IEEE Signal Process. Mag.*, vol. 29, 2012, 82–97.
- [75] Hinton, G.E., To recognize shapes, first learn to generate images. *Prog. Brain Res.* 2007, 165, 535–547.
- [76] Hong, W., Electric load forecasting by seasonal recurrent SVR (support vector regression) with chaotic artificial bee colony algorithm. *Energy* 2011, 36, 5568–5578.
- [77] Hong, W.C., Dong, Y., Lai, C.Y., Chen, L.Y., Wei, S.Y., SVR with hybrid chaotic immune algorithm for seasonal load demand forecasting. *Energies* 2011, 4, 960–977.
- [78] Hopfield, J.J., Neural networks and physical systems with emergent collective computational abilities. *Proc. Natl. Acad. Sci.* 1982, 79, 2554–2558.
- [79] Hornik, K., Stinchcombe, M., White, H., Multilayer feedforward networks are universal approximators. *Neural Networks* 1989, 2, 359–366.
- [80] Hu, Y.Q., Kobayashi, N., Hasatani, M., Effects of coal properties on recycled-NO_x reduction in coal combustion with O₂ recycled flue gas. *Energy Convers. Manag.* 2003, 44, 2331–2340.
- [81] Huang, G., Huang, G. Bin, Song, S., You, K., Trends in extreme learning machines: A review. *Neural Networks* 2015, 61, 32–48.
- [82] Huang, Y., Yan, Y., Transient two-dimensional temperature measurement of open flames by dual-spectral image analysis. *Trans. Inst. Meas. Control* 2000, 22, 371–384.
- [83] Ilamathi, P., Selladurai, V., Balamurugan, K., Sathyanathan, V.T., ANN-GA approach for predictive modeling and optimization of NO_x emission in a tangentially fired boiler. *Clean Technol. Environ. Policy* 2013, 15, 125–131.
- [84] Isermann, R., Balle, P., Terminology in the field of supervision, fault detection and diagnosis. *IFAC Comm. SAFEPROCESS* 1996.
- [85] Janiszowski, K., *Identyfikacja modeli parametrycznych w przykładach*, EXIT, 2002.
- [86] Jankowski, N., *Ontogeniczne sieci neuronowe. O sieciach zmieniających swoją strukturę.*, 2003.
- [87] Jarosiński, J., *Techniki czystego spalania*, Wydawnictwo Naukowo-Techniczne, 1996.
- [88] Jasieńko, S., *Chemia i fizyka węgla*, Oficyna Wydawnicza Politechniki Wrocławskiej, 1995.
- [89] Jeong, S., Obayashi, S., Minemura, Y., Application of hybrid evolutionary algorithms to low exhaust emission diesel engine design. *Eng. Optim.* 2008, 40, 1–16.

- [90] Jia, D., Krogh, B.H., Talukdar, S., Distributed model predictive control. *IEEE Control Syst. Mag.* 2002, 22, 44–52.
- [91] Jiang, Y., Huang, G., Short-term wind speed prediction: Hybrid of ensemble empirical mode decomposition, feature selection and error correction. *Energy Convers. Manag.* 2017, 144, 340–350.
- [92] John, D.S., Samuelsen, S., Optimal , Active Control of Oxides of Nitrogen (NO_x) Emissions From a Natural Gas-Fired Burner Using a Simple Genetic Algorithm. *Proc. 1995 IEEE Conf. Control Appl.* 1995, 121–134.
- [93] Jun, W., Youtong, Z., Qinghui, X., Xiaoliang, D., in: *Meas. Technol. Mechatronics Autom. (ICMTMA), 2010 Int. Conf.*, vol. 2, 2010, 792–795.
- [94] Kalman, R.E., Bertram, J.E., Control System Analysis and Design Via the “Second Method” of Lyapunov: II–Discrete-Time Systems. *J. Basic Eng.* 1960, 82, 394–400.
- [95] Kalman, R.E., Bucy, R.S., New Results in Linear Filtering and Prediction Theory. *J. Basic Eng.* 1961, 83, 95.
- [96] Kalogirou, S.A., Artificial intelligence for the modeling and control of combustion processes: a review. *Prog Energy Combust* 2003, 29, 515–566.
- [97] Kanellakopoulos, I., Kokotovic, P., Morse, A., Systematic design of adaptive controllers for feedback linearizable systems. *IEEE Trans. Autom. Control* 1991, 36, 1241–1253.
- [98] Karonis, D., Lois, E., Zannikos, F., Alexandridis, A., Sarimveis, H., A Neural Network Approach for the Correlation of Exhaust Emissions from a Diesel Engine with Diesel Fuel Properties. *Energy & Fuels* 2003, 17, 1259–1265.
- [99] Karpathy, A., Cs231n convolutional neural networks for visual recognition. *Neural networks* 2016, 1.
- [100] Kauranen, P., Andersson-Engels, S., Svanberg, S., Spatial mapping of flame radical emission using a spectroscopic multi-colour imaging system. *Appl. Phys. B Photophysics Laser Chem.* 1991, 53, 260–264.
- [101] Khaniki, V.L., Mehdizadeh, N.S., Applying of genetic algorithm for optimizing methane combustion reactions. *Eng Comput* 2010, 27, 464–484.
- [102] Kheir, N., Åström, K., Auslander, D., Cheok, K., et al., Control systems engineering education. *Automatica* 1996, 32, 147–166.
- [103] Kleinman, D.L., On an Iterative Technique for Riccati Equation Computations. *IEEE Trans. Automat. Contr.* 1968, 13, 114–115.
- [104] Kobayashi, H., Howard, J.B., Sarofim, A.F., Coal devolatilization at high temperatures. *Symp. Combust.* 1977, 16, 411–425.
- [105] Korbicz, J., Sztuczne sieci neuronowe i ich zastosowanie w elektrotechnice i energetyce. *Prz. Elektrotechniczny* 2009, 85, 194–200.
- [106] Korbicz, J., Kościelny, J., Kowalczyk, Z., Cholewa, W., *Diagnostyka procesów*, Wydawnictwa Naukowo-Techniczne, 2002.

- [107] Kordylewski, W., Bulewicz, E., Dyjakon, A., Hardy, T., et al., *Spalanie i Paliwa*, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2008.
- [108] Kordylewski, W., *Niskoemisyjne techniki spalania w energetyce*, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2000.
- [109] Kosmatopoulos, E., Ioannou, P., A switching adaptive controller for feedback linearizable systems. *IEEE Trans. Automat. Contr.* 1999, 44, 742–750.
- [110] Kosmatopoulos, E.B., Universal stabilization using control Lyapunov functions, adaptive derivative feedback, and neural network approximators. *IEEE Trans. Syst. Man, Cybern. Part B Cybern.* 1998, 28, 472–477.
- [111] Kosmatopoulos, E.B., Ioannou, P.A., Robust switching adaptive control of multi-input nonlinear systems. *IEEE Trans. Automat. Contr.* 2002, 47, 610–624.
- [112] Kotyra, A., Wójcik, W., Golec, T., in: Pawłowski L., Dudzińska M., Pawłowski A (Eds.), *Environ. Eng. III*, CRC Press, 2010, 575–579.
- [113] Kotyra, A., *Diagnostyka procesu spalania pyłu węglowego z wykorzystaniem metod przetwarzania obrazu*, Wydawnictwo Politechniki Lubelskiej, Lublin 2010.
- [114] Krabicka, J., Lu, G., Yan, Y., Profiling and characterization of flame radicals by combining spectroscopic imaging and neural network techniques. *IEEE Trans. Instrum. Meas.* 2011, 60, 1854–1860.
- [115] Kreulen, D., in: *Elem. coal Chem.*, 1948, 5–36.
- [116] Krstic, M., Kanellakopoulos, I., Kokotovic, P., *Nonlinear and Adaptive Control*, vol. 281, Wiley, New York 2003.
- [117] Krstic, M., Kokotovic, P., Kanellakopoulos, I., *Nonlinear and Adaptive Control*, vol. 281, New York 2003.
- [118] Krstic, M., Kokotovic, P. V., Adaptive Nonlinear Design with Controller-Identifier Separation and Swapping. *IEEE Trans. Automat. Contr.* 1995, 40, 426–440.
- [119] Kucowski, J., Laudyn, D., Przekwas, M., in: *Mater. Konf. „Spalanie węgla '99”*, WNT, Warszawa 1997, p. 484.
- [120] Laengkvist, M., Karlsson, L., Loutfi, A., A review of unsupervised feature learning and deep learning for time-series modeling. *Prepr. Submitt. to Pattern Recognit. Lett.* 2014, 42, 11–24.
- [121] LeCun Y., Bottou L., Bengio Y., H.P., Gradient-based learning applied to document recognition. *Proc. IEEE* 1998, 86, 2278–2324.
- [122] LeCun, Y., Bottou, L., Bengio, Y., Haffner, P., Gradient Based Learning Applied to Document Recognition. *Proc. IEEE* 1998, 86, 2278–2324.
- [123] Lee, E., Markus, L., *Foundations of optimal control theory*, vol. 3, Krieger Pub Co, New York 1967.

- [124] Lee, H., Pham, P.T., Largman, Y., Ng, A.Y., Unsupervised feature learning for audio classification using convolutional deep belief networks. *Nips* 2009, 9, 1096–1104.
- [125] Lee, H., Tomizuka, M., Robust adaptive control using a universal approximator for SISO nonlinear systems. *IEEE Trans. Fuzzy Syst.* 2000, 8, 95–106.
- [126] Lei, M., Shiyan, L., Chuanwen, J., Hongling, L., Yan, Z., A review on the forecasting of wind speed and generated power. *Renew. Sustain. Energy Rev.* 2009, 13, 915–920.
- [127] Lhner, R., Applied Computational Fluid Dynamics Techniques: An Introduction Based on Finite Element Methods. *J. Fluid Mech.* 2001, 1, 375–376.
- [128] Li, Z, Q., Jin, Y., Numerical simulation of pulverized coal combustion and NO formation. *Chem. Eng. Sci.* 2003, 58, 5161–5171.
- [129] Li, H., Tong, S., A hybrid adaptive fuzzy control for a class of nonlinear MIMO systems. *IEEE Trans. Fuzzy Syst.* 2003, 11, 24–34.
- [130] Li, J.Q., Liu, J.Z., Niu, Y.G., Niu, C.L., in: *Tencon 2004 - 2004 Ieee Reg. 10 Conf. Vols a-D, Proc.*, 2004, D589–D592.
- [131] Li, K., Thompson, S., Wieringa, P., Peng, J., Duan, G., Neural networks and genetic algorithms can support human supervisory control to reduce fossil fuel power plant emissions. *Cogn. Technol. Work* 2003, 5, 107–126.
- [132] Lian, K., Chiu, C., Liu, P., Semi-decentralized adaptive fuzzy control for co-operative multirobot systems with H 1 motion/ internal force tracking performance. *IEEE Trans. Syst. Man. Cybern.* 2002, 32, 269–280.
- [133] Liang, Z., Liang, J., Wang, C., Dong, X., Miao, X., Short-term wind power combined forecasting based on error forecast correction. *Energy Convers. Manag.* 2016, 119, 215–226.
- [134] Lin, Y., Sontag, E., Control Lyapunov universal formulae for restricted inputs. *Theory Adv. Technol.* 1995, 10, 1981–2004.
- [135] Lin, Y., Sontag, E.D., Wang, Y., A Smooth Converse Lyapunov Theorem for Robust Stability. *SIAM J. Control Optim.* 1996, 34, 124–160.
- [136] Liu, C., Lin, J., Niu, Y., Liang, W., Nonlinear boiler model of 300 MW power unit for system dynamic performance studies. *ISIE 2001. 2001 IEEE Int. Symp. Ind. Electron. Proc. (Cat. No.01TH8570)* 2001, 2, 1296–1300.
- [137] Liu, D., Wang, J., Wang, H., Short-term wind speed forecasting based on spectral clustering and optimised echo state networks. *Renew. Energy* 2015, 78, 599–608.
- [138] Liu, H., Duan, Z., Han, F. ze, Li, Y. fei, Big multi-step wind speed forecasting model based on secondary decomposition, ensemble method and error correction algorithm. *Energy Convers. Manag.* 2018, 156, 525–541.

- [139] Liu, H., Mi, X. wei, Li, Y. fei, Wind speed forecasting method based on deep learning strategy using empirical wavelet transform, long short term memory neural network and Elman neural network. *Energy Convers. Manag.* 2018, 156, 498–514.
- [140] Liu, H., Mi, X., Li, Y., An experimental investigation of three new hybrid wind speed forecasting models using multi-decomposing strategy and ELM algorithm. *Renew. Energy* 2018, 123, 694–705.
- [141] Liu, H., Mi, X., Li, Y., Comparison of two new intelligent wind speed forecasting approaches based on Wavelet Packet Decomposition, Complete Ensemble Empirical Mode Decomposition with Adaptive Noise and Artificial Neural Networks. *Energy Convers. Manag.* 2018, 155, 188–200.
- [142] Liu, H., Mi, X., Li, Y., Smart multi-step deep learning model for wind speed forecasting based on variational mode decomposition, singular spectrum analysis, LSTM network and ELM. *Energy Convers. Manag.* 2018, 159, 54–64.
- [143] Liu, H., Wu, H., Li, Y., Smart wind speed forecasting using EWT decomposition, GWO evolutionary optimization, RELM learning and IEWT reconstruction. *Energy Convers. Manag.* 2018, 161, 266–283.
- [144] Liu, X., Bansal, R.C., *Thermal power plants: modelling, control and efficiency improvement*, 2016.
- [145] Lopes, C., Perdigão, F., Event detection by HMM, SVM and ANN: A comparative study. *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)* 2008, 5190 LNAI, 1–10.
- [146] Lopez-Toledo, A.A., Athans, M., *On the design of optimal input signals in system identification. [of linear systems with unknown random parameters]*, Rotterdam 1974.
- [147] Lu, G., Gilabert, G., Yan, Y., Vision based monitoring and characterisation of combustion flames. *J. Phys. Conf. Ser.* 2005, 15, 194–200.
- [148] Lu, G., Yan, Y., Cornwell, S., Riley, G., Temperature profiling of pulverised coal flames using multi-colour pyrometric and digital imaging techniques, *2005 IEEE Instrumentation and Meas. Technol. Conf. Proc.*, vol. 3, Ottawa 2005, 1658–1662.
- [149] Lu, G., Yan, Y., Cornwell, S., Whitehouse, M., Riley, G., Impact of co-firing coal and biomass on flame characteristics and stability. *Fuel* 2008, 87, 1133–1140.
- [150] Lu, Y., Roychowdhury, V., Parallel randomized sampling for support vector machine (SVM) and support vector regression (SVR). *Knowl. Inf. Syst.* 2008, 14, 233–247.
- [151] Lunze, J., *Robust Multivariable Feedback Control **, vol. 27, Prentice-Hall, 1991.
- [152] Ma, Y., Matusko, J., Borrelli, F., Stochastic Model Predictive Control for Building HVAC Systems: Complexity and Conservatism. *IEEE Trans. Control Syst. Technol.* 2014, 23, 1–1.

- [153] Makrem, B.J., Imen, J., Kais, O., in: *2016 7th Int. Conf. Sci. Electron. Technol. Inf. Telecommun. SETIT 2016*, 2017, 355–360.
- [154] Marques, J.S., Jorge, P.M., *Visual inspection of a combustion process in a thermoelectric plant*, vol. 80, Elsevier, 2000.
- [155] Mason, M., Gandhi, K., Formulas for calculating the caloric value of coal and coal chars: development, test and uses. *Fuel Process. Technol.* 1940, 235–245.
- [156] Mayne, D.Q., Rawlings, J.B., Rao, C. V, Scokaert, P.O., Constrained model predictive control: Stability and optimality. *Automatica* 2000, 36, 789–814.
- [157] Mayne, D., Robust and stochastic model predictive control: Are we going in the right direction? *Annu. Rev. Control* 2016, 41, 184–192.
- [158] Meng, A., Ge, J., Yin, H., Chen, S., Wind speed forecasting based on wavelet packet decomposition and artificial neural networks trained by crisscross optimization algorithm. *Energy Convers. Manag.* 2016, 114, 75–88.
- [159] Mi, X. wei, Liu, H., Li, Y. fei, Wind speed forecasting method using wavelet, extreme learning machine and outlier correction algorithm. *Energy Convers. Manag.* 2017, 151, 709–722.
- [160] Michel, A.N., Stability: The Common Thread in the Evolution of Feedback Control. *IEEE Control Syst.* 1996, 16, 50–60.
- [161] Minhajullah, S., Ferik, S. El, Elshafei, M., Habib, M.A., in: *Int. Multi-Conference Syst. Signals Devices*, 2012, 1–6.
- [162] Mitkowski, W., *Równania macierzowe i ich zastosowania*, Wydawnictwo AGH, Kraków 2012.
- [163] Moaveni, S., *Finite element analysis: theory and application with ANSYS*, Prentice Hall, New Jersey 2007.
- [164] Moller, M., Efficient Training of Feed-Forward Neural Networks. University of Aarhus, 1997.
- [165] Morari, M., Lee, J.H., Model predictive control: past, present and future. *Comput. Chem. Eng.* 1999, 23, 667–682.
- [166] Narendra, K.S., Parthasarathy, K., Neural networks and dynamical systems. *Int. J. Approx. Reason.* 1992, 6, 109–131.
- [167] Narendra, K.S., Parthasarathy, K., Identification and control of dynamical systems using neural networks. *IEEE Trans. Neural Netw.* 1990, 1, 4–27.
- [168] Nieć, M., Międzynarodowe klasyfikacje zasobów złóż kopalin. *Górnictwo i Geoinżynieria* 2010, 3, 33–49.
- [169] Nocedal, J., Springer, S.J.W., *Numerical Optimization*, New York 1999.
- [170] Odrzywołek, K., Gałka, J., Wykorzystanie Głębokich Sieci Neuronowych w Weryfikacji Mówcy. Akademia Górniczo-Hutnicza, 2016.
- [171] Ogunmolu, O., Gu, X., Jiang, S., Gans, N., Nonlinear Systems Identification Using Deep Dynamic Neural Networks 2016.
- [172] Okazaki, K., Ando, T., NO(x) reduction mechanism in coal combustion with recycled CO₂. *Energy* 1997, 22, 207–215.

- [173] Oldewurtel, F., Parisio, A., Jones, C.N., Use of model predictive control and weather forecasts for energy efficient.pdf. *Energy Build.* 2012, 45, 15–27.
- [174] Ordóñez, R., Passino, K., Stable multi-input multi-output adaptive fuzzy/neural control. *IEEE Trans. Fuzzy Syst.* 1999, 7, 345–353.
- [175] Ordys, A.W., Pike, A.W., Johnson, M.A., Katebi, R.M., Grimble, M.J., *Modelling and Simulation of Power Generation Plants*, Springer–Verlag, 1994.
- [176] Orłowski, P., Dobrzański, W., Szwarc, E., *Kotły parowe: konstrukcja i obliczenia*, Wydawnictwa Naukowo-Techniczne, Warszawa 1979.
- [177] Osowski, S., *Sieci neuronowe do przetwarzania informacji*, Oficyna Wydawnicza Politechniki Warszawskiej, 2006.
- [178] Osowski, S., Sztuczne sieci neuronowe - Podstawowe struktury sieciowe i algorytmy uczące. *Przegląd Elektrotechniczny* 2009, 85, 1–8.
- [179] Patil, M.S.B., Patil, M.B.K., Support Vector Machine for Wind Speed Prediction. *Renew Energ* 2015, 29, 939–947.
- [180] PN-71/C97012, *Oleje opałowe smołowe*.
- [181] PN-82/G-97002, *Klasyfikacja węgla według typów*.
- [182] Postlethwaite, I., MacFarlane, A.G.J., *A Complex variable approach to the analysis of linear multivariable feedback systems*, vol. 12, Springer-Verlag, Berlin 1979.
- [183] Pronobis, M., *Modernizacja kotłów energetycznych*, WNT, Warszawa 2017.
- [184] Qi-Sheng, X.U., Sheng-Qi, L., Quan-Li, T.X.Z., Optimizing Combustion System for the Boiler Based on Neural Network and Genetic Algorithm. *Autom. Instrum.* 2014, 29, 30–32.
- [185] Qin, M., Li, Z., Du, Z., Red tide time series forecasting by combining ARIMA and deep belief network. *Knowledge-Based Syst.* 2017, 125, 39–52.
- [186] Qin, S.J., Badgwell, T.A., A survey of industrial model predictive control technology. *Control Eng. Pract.* 2003, 11, 733–764.
- [187] Qing-Cai, C., De-Xin, G., Fang, L., Design of Boiler Combustion Optimization System Based on Neural Network and Genetic Algorithm. *Tech. Autom. Appl.* 2016, 35, 10–14.
- [188] Qiong, Y., The Boiler Optimization Combustion Technology Based on Neural Network. *Energy Conserv. Technol.* 2014, 32, 255–260.
- [189] Radl, B., Neural networks prove effective at NOx reduction. *Mod. Power Syst.* 2000, 20, 59.
- [190] Ribeirete, A., Costa, M., Impact of the air staging on the performance of a pulverized coal fired furnace. *Proc. Combust. Inst.* 2009, 32 II, 2667–2673.

- [191] Rodríguez, F., Tova, E., Cortés, V., Caadas, L., OPTICOM: Advanced automatic monitoring system of local combustion conditions for improving boiler performance in PC power plants. *Fuel* 2002, 81, 637–645.
- [192] Romero, C., Li, X., Keyvan, S., Rossow, R., Spectrometer-based combustion monitoring for flame stoichiometry and temperature control. *Appl. Therm. Eng.* 2005, 25, 659–676.
- [193] Rongtian, X., Combined Application of Bayesian Neural Network and Genetic Algorithm in Boiler Combustion Optimization. *Power Equip.* 2016, 30, 85–87.
- [194] RP, M., *Rozporządzenie Ministra Gospodarki z 14.08.2008 w sprawie zakupu energii elektrycznej i ciepła wytworzonych w odnawialnych źródłach energii (OZE). Dz.U. nr. 156/2008 poz. 969*, 2008.
- [195] Rumelhart, D.E., Hinton, G.E., Williams, R.J., Learning reoresebtatuibs by back-propagating errors. *Nature* 1986, 320, 264–265.
- [196] Safonov, M.G., Laub, A.J., Hartmann, G.L., Feedback Properties of Multivariable Systems: The Role and Use of the Return Difference Matrix. *IEEE Trans. Automat. Contr.* 1981, 26, 47–65.
- [197] Sampson, J.R., *Adaptation in Natural and Artificial Systems*, vol. 18, MIT Press, 1976.
- [198] Sandell, N.R., On Newton's Method for Riccati Equation Solution. *IEEE Trans. Automat. Contr.* 1974, 19, 254–255.
- [199] Sanz A., Ballester J., Hernández R., C.L.M., Advanced monitoring industrial burners based on. *Fuel* 2008, 87, 1063–1075.
- [200] Sastry, S., Isidori, A., Adaptive control of linearizable systems. *IEEE Trans. Autom. Contr* 1989, 34, 405–412.
- [201] Savolainen, K., Heinolainen, E., Dernjatin, P., in: *Metod. pierwotne redukcji NOx w kotłach Energ. Szczyrk 28-29 kwietnia 2009*, TECH-EXPO, Szczyrk 2009, 45–52.
- [202] Sawicki, D., A quality factor of co-firing pulverized coal and biomass. *Przegląd Elektrotechniczny* 2016, 1, 142–145.
- [203] Scattolini, R., Architectures for distributed and hierarchical Model Predictive Control – A review. *J. Process Control* 2009, 19, 723–731.
- [204] Sepp, H., Schmidhuber, J., Long short-term memory. *Neural Comput.* 1997, 9, 1735–1780.
- [205] Seto, D., Baillieul, J., Adaptive Control of Nonlinear Systems with a Triangular Structure. *IEEE Trans. Automat. Contr.* 1994, 39, 1411–1428.
- [206] Shakil, M., Elshafei, M., Habib, M.A., Maleki, F.A., Soft sensor for NOx and O2 using dynamic neural networks. *Comput. Electr. Eng.* 2009, 35, 578–586.
- [207] Shaohua, M., in: *Proc. Int. Conf. Intell. Comput. ICIC 2007*, vol. 27, 2007, 528–535.

- [208] Si, F., Romero, C.E., Yao, Z., Schuster, E., et al., Optimization of coal-fired boiler SCRs based on modified support vector machine models and genetic algorithms. *Fuel* 2009, 88, 806–816.
- [209] Si, F., Romero, C.E., Yao, Z., Xu, Z., et al., A new approach for function approximation in boiler combustion optimization based on modified structural AOSVR. *Expert Syst. Appl.* 2009, 36, 8691–8704.
- [210] Sivathanu, Y.R., Faeth, G.M., Generalized state relationships for scalar properties in nonpremixed hydrocarbon/air flames. *Combust. Flame* 1990, 82, 211–230.
- [211] Smolarz, A., *Diagnostyka procesów spalania paliw gazowych, pyłu węglowego oraz mieszaniny pyłu węglowego i biomasy z wykorzystaniem metod optycznych*, Wydawnictwo Politechniki Lubelskiej, Lublin 2013.
- [212] Smrekar, J., Potočník, P., Senegačnik, A., Multi-step-ahead prediction of NO_x emissions for a coal-based boiler. *Appl. Energy* 2013, 106, 89–99.
- [213] Song Qing-Kun, L.I.Y.-S., Modeling of the Boiler Combustion System by RBF Neural Networks. *J. Harbin Univ. Sci. Technol.* 2016, 21, 89–92.
- [214] Sontag, E.D., A “universal” construction of Artstein’s theorem on nonlinear stabilization. *Syst. Control Lett.* 1989, 13, 117–123.
- [215] Strahle, W.C., Combustion noise. *Prog. Energy Combust. Sci.* 1978, 4, 157–176.
- [216] Su, S., Pohl, J., Holcombe, D., Hart, J., Techniques to determine ignition, flame stability and burnout of blended coals in p.f. power station boilers. *Prog. Energy Combust. Sci.* 2001 2001, 27, 79–98.
- [217] Sutskever, I., *Training Recurrent Neural Networks*, University of Toronto, 2013.
- [218] Świątek Jan, *Wybrane zagadnienia identyfikacji statycznych systemów złożonych*, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2009.
- [219] Świrski, K., Kalbarczyk, P., Sikorski, R., Arabas, J., Rozdział obciążeń w warunkach rynku energii – zagadnienie grafikowania. *Pbec 2001, Z.21* 2001, 12, 255–264.
- [220] Tadeusiewicz, R., *Sieci neuronowe*, Akademicka Oficyna Wydawnicza, RM, Warszawa 1993.
- [221] Taler, J., *Spalanie paliw*, Wydawnictwo Naukowe PWN, 2011.
- [222] Tascikaraoglu, A., Uzunoglu, M., A review of combined approaches for prediction of short-term wind speed and power. *Renew. Sustain. Energy Rev.* 2014, 34, 243–254.
- [223] Tatjewski, P., *Sterowanie zaawansowane obiektów przemysłowych. Struktury i algorytmy*, EXIT, 2002.
- [224] Tomeczek, J., *Termodynamika*, Wydawnictwo Politechniki Śląskiej, 1999.
- [225] Tomeczek J., *Coal Combustion*, Matlabar, Krieger 1994.
- [226] Tomeczek, J., *Spalanie węgla*, Wydawnictwo Politechniki Śląskiej, Gliwice 1992.

- [227] Tsay, D., Chung, H., Lee, C., The Adaptive Control of Nonlinear Systems Using the Sugeno-Type of Fuzzy Logic. *IEEE Trans. Fuzzy Syst.* 1999, 7, 225–229.
- [228] Tsinias, J., Sufficient Lyapunov-like conditions for stabilization. *Math. Control. Signals, Syst.* 2005, 2, 343–357.
- [229] Tsur, Y., Zemel, A., The infinite horizon dynamic optimization problem revisited: A simple method to determine equilibrium states. *Eur. J. Oper. Res.* 2001, 131, 482–490.
- [230] Tu, J., Yeoh, G., Liu, C., Computational Fluid Dynamics: A Practical Approach 2013.
- [231] Vaezi, V., Aldredge, R.C., Influences of acoustic instabilities on turbulent-flame propagation. *Exp. Therm. Fluid Sci.* 2000, 20, 162–169.
- [232] Varesi, K., Radan, A., A novel GA based technique for optimizing both the design and control parameters in parallel passenger hybrid cars. *Int. Rev. Electr. Eng.* 2011, 6, 1279–1286.
- [233] Venkatasubramanian, V., Rengaswamy, R., A review of process fault detection and diagnosis:: Part I: Quantitative model-based methods. *Comput. & Chem.* 2003, Computers, 293–311.
- [234] Versteeg, H.K., Malalasekera, W., An Introduction to Computational Fluid Dynamics-The Finite Volume Method. *Book* 2007, M, 517.
- [235] Wang, G., Zhang, Y., Adaptive Control Algorithm For Burning of Circulating Fluidized Bed Boiler Based on Optimized Fuzzy Neural Network. *Ind. Control Comput.* 2015, 28, 55–57.
- [236] Wang, H. zhi, Li, G. qiang, Wang, G. bing, Peng, J. chun, et al., Deep learning based ensemble approach for probabilistic wind power forecasting. *Appl. Energy* 2017, 188, 56–70.
- [237] Wang, J.S., Chen, Y.P., A fully automated recurrent neural network for unknown dynamic system identification and control. *IEEE Trans. Circuits Syst. I Regul. Pap.* 2006, 53, 1363–1372.
- [238] Wang, L.-X., *Adaptive Fuzzy Systems and Control: Design and Stability Analysis*, PTR Prentice Hall, New Jersey 1994.
- [239] Wang, L.-X., Mendel, J.M., Fuzzy basis function, universal approximation, and orthogonal least squares learning. *IEEE Trans. Neural Networks* 1992, 3, 807–813.
- [240] Wang, L.H., Lu, J., Guo, Z., H, L., Wang, J., Research and application of a combined model based on multi-objective optimization for multi-step ahead wind speed forecasting. *Renew. Energy* 2018, 124, 395–412.
- [241] Wei, Z., Li, X., Xu, L., Cheng, Y., Comparative study of computational intelligence approaches for NO_x reduction of coal-fired boiler. *Energy* 2013, 55, 683–692.
- [242] Werbos, P.J., Backpropagation through time: What it does and how to do it. *Proc. IEEE* 1990, 78, 1550–1560.
- [243] Willsky, A.S., Athans, M., *Control optimization, stabilization and computer algorithms for aircraft applications*, Cambridge 1982.

- [244] Wójcik, W., Kotyra, A., Golec, T., Gromaszek, K., Vision based monitoring of coal flames. *Przegląd Elektrotechniczny* 2008, 3, 241–243.
- [245] Wójcik, W., Kotyra, A., Smolarz, A., Gromaszek, K., Modern Methods of Monitoring and Controlling Combustion of Solid Fuels in Order to Reduce Its Environmental Impact. *Rocz. Ochr. Sr.* 2011, 13, 1559–1576.
- [246] Wójcik, W., in: *Conf. Proc. EUROSENSORS XI*, Warsaw 1997, 997–1000.
- [247] Wójcik, W., Kotyra, A., Wykorzystanie obrazu płomienia do oceny stabilności spalania mieszanin pyłu węglowego i biomasy. *Pomiary Autom. Kontrola* 2005, 3, 34–36.
- [248] Wójcik, W., Kotyra, A., Ławicki, T., Analiza obrazów współspalania pyłu węglowego i biomasy za pomocą transformaty curvelet. *Prz. Elektrotechniczny* 2013, 89, 314–316.
- [249] Wójcik, W., Kotyra, A., Smolarz, A., Gromaszek, K., Nowoczesne metody monitoringu i sterowania procesem spalania paliw stałych w celu zmniejszenia jego oddziaływania na środowisko naturalne. *Rocz. Ochr. Sr.* 2011, 13, 1559–1576.
- [250] Yam, J., Chow, T., Feedforward networks training speed enhancement by optimal initialization of the synaptic coefficients. *IEEE Trans. Neural Networks* 2001, 12, 430–434.
- [251] Yin, C., Rosendahl, L., Clausen, S., Hvid, S.L., Characterizing and modeling of an 88 MW grate-fired boiler burning wheat straw: Experience and lessons. *Energy* 2012, 41, 473–482.
- [252] Ying, H., Sufficient conditions on uniform approximation of multivariate functions by general Takagi-Sugeno fuzzy systems with linear rule consequent. *IEEE Trans. Syst. Man, Cybern. Part A Systems Humans*. 1998, 28, 515–520.
- [253] Yu, C., Li, Y., Zhang, M., An improved Wavelet Transform using Singular Spectrum Analysis for wind speed forecasting based on Elman Neural Network. *Energy Convers. Manag.* 2017, 148, 895–904.
- [254] Zhang, X., Grammatico, S., Schildbach, G., Goulart, P., Lygeros, J., in: *2014 Eur. Control Conf. ECC 2014*, Strasbourg, France 2014, 478–483.
- [255] Zhang, Y. a., Hu, Y. a., Lü, F.L., Comment: Robust adaptive sliding mode control using fuzzy modelling for a class of uncertain MIMO nonlinear systems. *IEE Proc. - Control Theory Appl.* 2004, 151, 522.
- [256] Zhao, J., Guo, Y., Xiao, X., Wang, J., et al., Multi-step wind speed and power forecasts based on a WRF simulation and an optimized association method. *Appl. Energy* 2017, 197, 183–202.
- [257] Zheng, L., Zhou, H., Cen, K., Wang, C., A comparative study of optimization algorithms for low NO_x combustion modification at a coal-fired utility boiler. *Expert Syst. Appl.* 2009, 36, 2780–2793.
- [258] Zheng, L.Z.L., Yu, S.Y.S., Yu, M.Y.M., in: *2nd IEEE Int. Conf. Bioinforma. Biomed. Eng.*, 2008, 1916–1919.

- [259] Zhi-Xin, W., De-Mei, B., Li-Ming, C., Zheng, Q., Multiobjective Neural Network Optimization for Boiler Combustion Systems. *Power Equip.* 2012, 26, 97–99.
- [260] Zhou, H., Cen, K., Fan, J., Multi-objective optimization of the coal combustion performance with artificial neural networks and genetic algorithms. *Int. J. Energy Res.* 2005, 29, 499–510.
- [261] Zhou, H., Cen, K., Fan, J., Modeling and optimization of the NO_x emission characteristics of a tangentially fired boiler with artificial neural networks. *Energy* 2004, 29, 167–183.
- [262] Zhou, H., Pei, J., Gang, L., Lin, C., Fa, K., Modeling NO_x emissions from coal-fired utility boilers using support vector regression with ant colony optimization. *Eng. Appl. Artif. Intell.* 2012, 25, 147–158.
- [263] Zhou, H., Zheng, L., Cen, K., Computational intelligence approach for NO_x emissions minimization in a coal-fired utility boiler. *Energy Convers. Manag.* 2010, 51, 580–586.
- [264] Directive 2010/75/EU of The European Parliament and of the Council of 24 November 2010 on industrial emissions (integrated pollution prevention and control) (Recast), <https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:02010L0075-20110106&from=LT>, EU 2010.

Summary

Advanced control techniques of pulverized coal combustion control

Combustion, in particular, conducted under industrial conditions, belongs to the group of very complex technological processes. It is due to the peculiarities of phenomena accompanying this process as well as the severe operating conditions of the system in which it is implemented, including the limitations of availability in the scope of measurements, diagnostics, and control.

Based on a review of the literature and the author's own analytical and research achievements, it can be concluded that the system analysis carried out in this dissertation, advanced techniques for pulverized coal combustion control is of an innovative nature or has not been published. The work proposes the use of adaptive control with different reference prognostic models.

The dominant trend of the discussed methods focuses on the class of adaptive algorithms with the reference model - Model Predictive Control. The presented state of art in the field of complex processes control, starting from the classic control design techniques to predictive control, put forward the author to consider control techniques that are relatively well-established in industrial practice and have the potential for positive, practical verification. They are relatively simple in design and allow the implementation of the complex multidimensional models. These algorithms are coherent for both linear and non-linear models. It implies attempts to use it to control the combustion process of coal dust and co-firing with biomass. The work addresses issues of uncertainty and robust control. Optical diagnostic signals were used in the combustion process control algorithm both for forecasting NO_x emissions and optimizing boiler operation. The quoted results of simulation tests of the combustion process control in the MRAC structure with the NARX model were implemented in the form of an artificial neural network. Two MRAC systems were designed and compared.

Methods of hybrid structures of artificial neural networks for modeling and pulverized coal combustion control were discussed. Three selected structures of deep neural networks: MLP, simple recursive network, and LSTM cells were included in the study. For the development of a single hybrid model, the algorithm used a hybrid EWT, decomposing the pre-processing of the signal and a post-processing structure based on the IEWT reconstruction. In turn, the LSTM network was used to predict each sublayer. Besides, in the hybrid approach, the LSTM network is used as the primary predictor and the RELM network, which is a favorite machine learning technique, was used as a sub-predictor for modeling a series of prediction errors from the built-in LSTM network.