



**POLITECHNIKA
GDAŃSKA**

Wydział Inżynierii
Mechanicznej
i Okrętownictwa



WYDZIAŁ INŻYNIERII
MECHANICZNEJ
I OKRĘTOWNICTWA

Imię i nazwisko autora rozprawy: Anna Milewska
Dyscyplina naukowa: Inżynieria Mechaniczna

ROZPRAWA DOKTORSKA

Tytuł rozprawy w języku polskim: *Metoda neuronowego wyznaczania przestrzennych pól przepływów w przydźwiękowych i naddźwiękowych kanałach łopatkowych turbin parowych*

Tytuł rozprawy w języku angielskim: *A neural method for spatial flow fields determination in transonic and supersonic steam turbine blade channels*

Promotor	
dr hab. inż. Jerzy Głuch, prof. PG	

Gdańsk, rok 2022



OŚWIADCZENIE

Autor rozprawy doktorskiej: Anna Milewska

Ja, niżej podpisany(a), wyrażam zgodę/~~nie wyrażam zgody*~~ na bezpłatne korzystanie z mojej rozprawy doktorskiej zatytułowanej:

*Metoda neuronowego wyznaczania przestrzennych pól przepływów
w przydźwiękowych i naddźwiękowych kanałach łopatkowych turbin parowych*
do celów naukowych lub dydaktycznych.¹

Gdańsk, dnia 10.03.2022 r.

.....
podpis doktoranta

Świadomy(a) odpowiedzialności karnej z tytułu naruszenia przepisów ustawy z dnia 4 lutego 1994 r. o prawie autorskim i prawach pokrewnych (Dz. U. z 2006 r., nr 90, poz. 631) i konsekwencji dyscyplinarnych określonych w ustawie Prawo o szkolnictwie wyższym (Dz. U. z 2012 r., poz. 572 z późn. zm.),² a także odpowiedzialności cywilno-prawnej oświadczam, że przedkładana rozprawa doktorska została napisana przeze mnie samodzielnie.

Oświadczam, że treść rozprawy opracowana została na podstawie wyników badań prowadzonych pod kierunkiem i w ściślejszej współpracy z promotorem dr hab. inż. Jerzym Głuchem, prof. PG.

Niniejsza rozprawa doktorska nie była wcześniej podstawą żadnej innej urzędowej procedury związanej z nadaniem stopnia doktora.

Wszystkie informacje umieszczone w ww. rozprawie uzyskane ze źródeł pisanych i elektronicznych, zostały udokumentowane w wykazie literatury odpowiednimi odnośnikami zgodnie z art. 34 ustawy o prawie autorskim i prawach pokrewnych.

Potwierdzam zgodność niniejszej wersji pracy doktorskiej z załączoną wersją elektroniczną.

Gdańsk, dnia 10.03.2022 r.

.....
podpis doktoranta

Ja, niżej podpisany(a), wyrażam zgodę/~~nie wyrażam zgody*~~ na umieszczenie ww. rozprawy doktorskiej w wersji elektronicznej w otwartym, cyfrowym repozytorium instytucjonalnym Politechniki Gdańskiej, Pomorskiej Bibliotece Cyfrowej oraz poddawania jej procesom weryfikacji i ochrony przed przywłaszczeniem jej autorstwa.

Gdańsk, dnia 10.03.2022 r.

.....
podpis doktoranta

*) niepotrzebne skreślić

¹ Zarządzenie Rektora Politechniki Gdańskiej nr 34/2009 z 9 listopada 2009 r., załącznik nr 8 do instrukcji archiwalnej PG.

² Ustawa z dnia 27 lipca 2005 r. Prawo o szkolnictwie wyższym: Rozdział 7 Odpowiedzialność dyscyplinarna doktorantów, Art. 226.





OPIS ROZPRAWY DOKTORSKIEJ

Autor rozprawy doktorskiej: Anna Milewska

Tytuł rozprawy doktorskiej w języku polskim: *Metoda neuronowego wyznaczania przestrzennych pól przepływów w przydźwiękowych i naddźwiękowych kanałach łopatkowych turbin parowych*

Tytuł rozprawy w języku angielskim: *A neural method for spatial flow fields determination in transonic and supersonic steam turbine blade channels*

Język rozprawy doktorskiej: język polski

Promotor rozprawy doktorskiej: dr hab. inż. Jerzy Głuch, prof. PG

Data obrony:

Słowa kluczowe rozprawy doktorskiej w języku polskim:

turbina parowa, przepływ okołodźwiękowy, model numeryczny, uczenie maszynowe, sieć neuronowa, uczenie głębokie

Słowa kluczowe rozprawy doktorskiej w języku angielskim:

steam turbine, transonic flow, numerical model, machine learning, neural network, deep learning

Streszczenie rozprawy w języku polskim:

Niniejsza rozprawa doktorska została poświęcona opracowaniu metody neuronowego wyznaczania przestrzennych pól przepływów w okołodźwiękowych kanałach łopatkowych turbin parowych. Obiektem badań naukowych przedstawionych w kolejnych rozdziałach są dwa ostatnie stopnie części niskoprężnej turbozespołu 18K370 z wylotem ND-37.

Pierwszym etapem badań była budowa numerycznego modelu przepływu pary mokrej przez analizowany układ łopatkowy. Warunki brzegowe zadano na podstawie wyników specjalistycznych pomiarów wewnątrz kadłuba turbiny przeprowadzonych przez Diagnostyka Maszyn Sp. z o.o. w jednej z polskich elektrowni, dzięki czemu wyniki obliczeń numerycznych można było potraktować jako specyficzne dane eksperymentalne do dalszych badań. Kolejnym krokiem było stworzenie bazy danych referencyjnych. W tym celu wykorzystano numeryczny model obliczeniowy bloku parowego o mocy 370 MW, utworzony w programie DIAGAR. Model został dostosowany do wyników pomiarów bloku energetycznego, dla pełnego pola pracy turbiny. Dalsze badania przeprowadzono przy użyciu języka programowania Python 3.7. Zbudowano szereg symulatorów przepływu pary na średnicy podziałowej analizowanego układu łopatkowego, bazując na powszechnie stosowanych modelach uczenia maszynowego. Kolejnym etapem była budowa neuronowego modelu przepływu dwuwymiarowego. Przyjęto strukturę sieci neuronowej w postaci perceptronu wielowarstwowego i przeanalizowano ją pod kątem liczby warstw ukrytych, liczby neuronów w poszczególnych warstwach, wielkości podzbioru danych treningowych wykorzystywanego do uczenia modelu neuronowego w pojedynczym kroku (ang. batch size) oraz liczby epok. Na bazie wybranej struktury neuronowego modelu przepływu na średnicy podziałowej stworzono symulator przestrzennego przepływu pary mokrej przez analizowany układ łopatkowy. Użyteczność zbudowanego symulatora neuronowego zobrazowano na przykładzie wybranego rzeczywistego kanału przepływowego turbiny parowej dużej mocy, przy uwzględnieniu dostępnych pomiarów obiegu oraz specjalistycznych pomiarów wewnętrznych turbiny.





**POLITECHNIKA
GDAŃSKA**

Wydział Inżynierii
Mechanicznej
i Okrętownictwa



WYDZIAŁ INŻYNIERII
MECHANICZNEJ
I OKRĘTOWNICTWA

Streszczenie rozprawy w języku angielskim:

In this Ph.D. thesis, a neural method for spatial flow fields determination in transonic steam turbine blade channels is presented. The last two stages of the 18K370 steam turbine with the ND-37 outlet are the subject of research.

Initially, a CFD model of wet steam flow through the analysed blade channel was created. The boundary conditions have been set based on the turbine internal measurements taken by Diagnostyka Maszyn in one of the Polish power plants, which has enabled the results of the numerical calculations to be considered as the specific experimental data for further research. The next step was to create the reference database. The numerical computational model of a 370 MW steam unit, prepared in the DIAGAR program, has been used for this purpose. The model has been tuned to the steam unit measurements, for the full turbine working area. For further research Python 3.7 programming language has been used. A number of simulators of steam flow at the analysed blade channel pitch diameter have been created, based on commonly used machine learning models. Subsequently, the neural model of two-dimensional flow has been created. Multilayer perceptron has been chosen for the neural network structure. The number of hidden layers, number of neurons in each layer, batch size, and number of epochs have been studied. A three-dimensional neural simulator of wet steam flow through the analysed turbine blading has been designed based on the neural model at the turbine pitch diameter. Practical application of the designed neural simulator has been illustrated with the chosen real flow channel of the large power steam turbine, including available measurements of the steam cycle and the specific turbine internal measurements.

Pragnę serdecznie podziękować wszystkim osobom, które przyczyniły się do powstania niniejszej rozprawy.

W pierwszej kolejności chciałabym podziękować mojemu promotorowi dr inż. Jerzemu Głuchowi za wspaniałą opiekę merytoryczną, wsparcie na każdym etapie powstawania niniejszej pracy oraz cierpliwość.

Prof. dr hab. inż. Andrzejowi Gardzilewiczowi dziękuję za udostępnienie wyników specjalistycznych pomiarów przeprowadzonych przez spółkę Diagnostyka Maszyn, a dr hab. inż. Jerzemu Świrydczukowi za udostępnienie danych geometrycznych.

Kolegom z Instytutu Maszyn Przepływowych PAN: dr inż. Piotrowi Klonowiczowi, dr inż. Łukaszowi Witanowskiemu oraz dr inż. Romanowi Rusanov dziękuję za bezinteresowną pomoc przy obliczeniach CFD.

Vladimirowi Alekseichenko (założycielowi DataWorkshop), Maciejowi Zieniewiczowi oraz Krzysztofowi Bork-Ceszłakowi z InfoShare Academy dziękuję za cenne wskazówki z zakresu uczenia maszynowego i głębokiego.

Specjalne podziękowania należą się również mojej Rodzinie, która mnie bezustannie wspierała i wykazała się nieskończonymi pokładami wyrozumiałości.

Dziękuję!

mgr inż. Anna Milewska

Niniejsza rozprawa doktorska zawiera wyniki obliczeń CFD przeprowadzonych w ramach licencji na oprogramowanie ANSYS TurboGrid 18.0 oraz ANSYS CFX 18.0 udzielonej przez Centrum Informatyczne Trójmiejskiej Akademickiej Sieci Komputerowej (CI TASK), dla potrzeb realizacji grantu obliczeniowego pt. „Metoda neuronowego wyznaczania przestrzennych pól przepływów w przydźwiękowych i naddźwiękowych kanałach łopatkowych turbin parowych”.

WYKAZ WAŻNIEJSZYCH OZNACZEŃ I SKRÓTÓW

- H – głębokość sondowania
- M_R – moment działający na łopatkę wirnikową
- MSE – błąd średniokwadratowy (ang. Mean Squarred Error)
- N – moc generowana przez analizowany układ łopatkowy
- NP – niskoprężny
- P – ciśnienie statyczne
- P_c – ciśnienie całkowite
- p_k – ciśnienie końcowe
- R1 – wieniec wirnikowy przedostatniego stopnia analizowanego kanału przepływowego
- R2 – wieniec wirnikowy ostatniego stopnia analizowanego kanału przepływowego
- R^2 – współczynnik determinacji
- SP – średnioprężny
- SSN – sztuczna sieć neuronowa
- S1 – wieniec kierowniczy przedostatniego stopnia analizowanego kanału przepływowego
- S2 – wieniec kierowniczy ostatniego stopnia analizowanego kanału przepływowego
- WP – wysokoprężny
- y^+ – bezwymiarowa odległość od ściany
- z_R – liczba łopatek tworzących wieniec wirnikowy
- δ – błąd względny
- η – sprawność analizowanego kanału przepływowego
- ω – prędkość kątowna wieńców wirnikowych
- 1D – jednowymiarowy
- 2D – dwuwymiarowy
- 3D – trójwymiarowy

Spis treści

1. WSTĘP	2
2. MOTYWACJA, CEL PRACY I HIERARCHIA TWORZENIA METODY	7
3. NUMERYCZNY MODEL POMIAROWY	10
3.1. Modelowany układ łopatkowy	10
3.3. Warunki brzegowe	18
3.4. Symulacja przepływu pary mokrej przez analizowany kanał łopatkowy	25
4. SYMULATOR NEURONOWY	31
4.1. Baza danych referencyjnych	31
4.2. Zbiór treningowy, walidacyjny oraz testowy	34
4.3. Uczenie maszynowe	36
4.4. Neuronowy symulator przepływu pary mokrej przez analizowany układ łopatkowy	40
4.4.1. Symulator przepływu pary na średnicy podziałowej	40
4.4.2. Symulator przepływu pary w całej przestrzeni analizowanego kanału łopatkowego	54
4.4.3. Wpływ entropii statycznej na dokładność symulatora neuronowego	56
5. ROLA METODY DLA DIAGNOSTYKI CIEPLNO-PRZEPŁYWOWEJ	59
6. PODSUMOWANIE	62
WYKAZ LITERATURY	68
ZAŁĄCZNIKI	73
SPIS RYSUNKÓW	89
SPIS TABEL	92

1. WSTĘP

Eksploatacja urządzeń technicznych wymaga wszechstronnego nadzoru nad ich pracą. Jednym z najważniejszych elementów funkcjonalnych zapewniających ten nadzór są różnorodne procedury diagnostyczne. Istotną rolę pełnią w nich zaawansowane modele matematyczne i fizyczne, które wymagają skorelowania ze specyficznymi zadaniami wypełnianymi przez poszczególne rodzaje narzędzi diagnostycznych. Stąd, w ostatnich latach, nastąpił gwałtowny rozwój wspomnianych modeli, a metody diagnostyki technicznej znalazły poczesne miejsce wśród systemów eksploatacyjnych w różnych działach produkcyjnych gospodarki narodowej, [1]. Na szczególną uwagę zasługują rozmaite systemy energetyczne – obsługiwane również diagnostycznie, [2][3]. Spośród systemów diagnostycznych w energetyce należy natomiast wyróżnić układy diagnostyki ciepłno-przepływowej, [4].

Głównym zadaniem ciepłno-przepływowej diagnostyki złożonych obiektów energetycznych jest utrzymywanie ich w stanie wysokiej i możliwie stałej sprawności, [5][6]. Przykładem takich obiektów są elektrowniane bloki parowe, będące przedmiotem rozważań niniejszej rozprawy. Ich sprawność ulega pogorszeniu w wyniku ciągłej i na ogół powolnej degradacji wymiarów geometrycznych poszczególnych urządzeń składowych. Przywróceniu poprawnej sprawności służą natomiast remonty dokonywane w trakcie eksploatacji, po ich wcześniejszym ekonomicznym uzasadnieniu. Zakres remontu oraz spodziewana poprawa charakterystyk sprawnościowych prognozowane są na bazie detekcji, lokalizacji oraz identyfikacji przyczyn nieefektywnej pracy analizowanego obiektu [7].

Wymienione zadania diagnostyki ciepłno-przepływowej są realizowane w trzech wspomnianych wyżej etapach. Pierwszym z nich jest detekcja uszkodzenia, która wymaga określenia symptomów niesprawnej pracy – odchyłek mierzonych wartości ocenianych parametrów od ich wartości wzorcowych. Wartość symptomu większa od niepewności pomiarowej świadczy o wystąpieniu degradacji, [6]. Jako stan referencyjny (in. wzorzec sprawnej pracy) przyjmuje się stan pracy bloku przy wszystkich poprawnych, tzn. niezdegradowanych eksploatacyjnie charakterystykach, odpowiadających stanowi nowej maszyny lub maszyny bezpośrednio po remoncie, [7]. Określenie wzorca poprawnej pracy polega na wyznaczeniu rozkładów parametrów ciepłno-przepływowych (strumieni mas, ciśnień, temperatur) w funkcji parametrów obciążenia bloku, jego struktury oraz parametrów geometrycznych poszczególnych urządzeń składowych. W tym celu wykorzystuje się stacjonarne modele obliczeniowe obiektów energetycznych, dostrojone do wyników wiarygodnych uśrednionych pomiarów dokonanych w szerokim zakresie obciążeń bloku. Z tego krótkiego opisu wynika ważna rola metod i modeli matematycznych w diagnostyce.

Model matematyczny obiektu energetycznego stanowi związek pomiędzy jego parametrami zależnymi a parametrami niezależnymi oraz geometrią poszczególnych aparatów. Wejście modelu stanowią zmienne niezależne obiektu w postaci m. in. wartości mierzonych parametrów ciepłno-przepływowych górnego i dolnego źródła ciepła (kotła i kondensatora),

opisujące stan obciążenia obiektu oraz stan otoczenia. Parametrami wyjścia są natomiast rozkłady mierzalnych parametrów ciepłno-przepływowych wewnątrz struktury obiektu oraz charakterystyki obiektu i jego urządzeń składowych – zmienne zależne, [7].

Przykładem systemu diagnostycznego pozwalającego na określenie stanu referencyjnego oraz aktualnego stanu bloku energetycznego jest numeryczny program obliczeniowy DIAGAR, [8][9][10]. Program ten umożliwia wykonywanie zarówno obliczeń bilansowych, jak i diagnostycznych. Obliczenia diagnostyczne są długotrwałe. Wykorzystują wyniki obliczeń bilansowych do wyznaczania stanu referencyjnego oraz stanu bieżącego. Długotrwałość obliczeń diagnostycznych wymaga prowadzenia ich w trybie offline, czyli w trybie poza czasem rzeczywistym. Niestety i tak trwają zbyt długo, by obsługa programu była wygodna dla diagnosty – pomimo stosowanych wcześniej różnych zabiegów przyspieszających. Warto zaznaczyć, że program DIAGAR korzysta – dla wybranych nielicznych modułów – z metod sztucznych sieci neuronowych (SSN), jako jednego z elementów sztucznej inteligencji systemu, [11]. Informacje na temat innych systemów diagnostycznych, budowanych według podobnych procedur, można znaleźć między innymi w [7][12][13][14][15][16][17].

Model bloku parowego zastosowany w programie DIAGAR charakteryzuje się budową modułową, która umożliwia odtworzenie struktury bloku energetycznego oraz pozwala na uwzględnienie zjawisk fizycznych w relatywnie prosty sposób. Poszczególne moduły stanowią modele obliczeniowe urządzeń składowych analizowanego obiektu, takich jak grupy stopni turbinowych, wymienniki ciepła, pompy, itp. Obliczenia wykonywane w ramach każdego z modułów mogą bazować na różnych metodach numerycznych. Istnieje również możliwość wykorzystania różnych metod dla potrzeb ciepłno-przepływowych obliczeń tego samego urządzenia. Modułowość programu DIAGAR ułatwia zatem udoskonalanie stosowanych metod numerycznych oraz implementację nowych rozwiązań. Jednym z nich mogłyby być metody obliczeń przestrzennych. Ich zastosowanie prowadzi jednak do znaczącego wydłużenia czasu obliczeń obiegu. Efekt ten można zniwelować zastępując pełne metody numeryczne zbudowanymi na ich podstawie symulatorami neuronowymi, dzięki czemu czas trwania obliczeń powróci do wartości akceptowalnych.

W programie obliczeniowym DIAGAR wykorzystano głównie jednowymiarowe (1D) metody obliczeniowe bilansów masowych i energetycznych, a w niektórych przypadkach – uproszczone metody dwuwymiarowe (2D). Metody 1D umożliwiają wystarczająco szybkie wykonanie obliczeń diagnostycznych, bazują jednak na uśrednionych charakterystykach przepływowych, co skutkuje uproszczeniem wielu zjawisk fizycznych, [4][7]. Dotyczy to zwłaszcza układu przepływowego kadłuba niskoprężnego (NP), który charakteryzuje się znacznymi długościami łopatek turbinowych o skomplikowanym kształcie, wynikającym z konieczności ich skręcania. Z tego powodu główne analizy diagnostyczne w programie DIAGAR wykonywano dla kadłubów: wysokoprężnego (WP), średnioprężnego (SP) oraz wymienników. W obszarze NP napotymano znaczne trudności podczas dostrajania programu do wiarygodnych pomiarów w ramach jednowymiarowych modeli obliczeniowych, [4][5]. Rozwój systemu wymaga więc zastosowania modeli przestrzennych.

Na dokładniejsze odwzorowanie zjawisk zachodzących w modelowanym obiekcie pozwalają pełne metody trójwymiarowe w postaci obliczeń numerycznych. Wymagają one jednak określenia wartości brzegowych dla zmiennych warunków pracy analizowanego turbosespołu energetycznego. Zmiany obciążenia skutkują zmianami strumieni mas poboru pary do układu regeneracji ciepła. Dotyczy to zarówno diagnostycznego procesu obliczeniowego, jak i procesu obliczeń stanu referencyjnego (dla poprawnej, niezdegradowanej geometrii). W pierwszej kolejności należy więc utworzyć dokładny model przestrzennych obliczeń referencyjnych, a zdobyte doświadczenie wykorzystać później przy obliczeniach diagnostycznych. Wartości zmiennych niezależnych, stanowiące wartości brzegowe dla obliczeń numerycznych, można określić m. in. poprzez symulacyjne obliczenia bilansowe analizowanego obiegu cieplnego, przeprowadzone np. w programie DIAGAR. Współpraca z obliczeniami typu 1D jest więc nieodzowna.

Na podstawie doświadczeń z wykorzystaniem numerycznych metod obliczeniowych można stwierdzić, że ich czas obliczeń jest bardzo długi i zależy od parametrów dyskretyzacji geometrii modelowanego obiektu. Obliczenia numeryczne charakteryzują się jednak wysoką dokładnością i są powszechnie wykorzystywane w przeróżnych procesach projektowych i optymalizacyjnych – w tym: w procesach projektowania oraz optymalizacji wirnikowych maszyn przepływowych, [18][19][20][21]. Dysponując chociażby częściowymi pomiarami można zweryfikować poprawność przestrzennych metod numerycznych dla konkretnego przypadku, [22]. W sytuacji braku możliwości pozyskania danych eksperymentalnych, wyniki obliczeń przestrzennych można zatem traktować jako swoisty pomiar numeryczny. Dotyczy to m. in. rozkładów parametrów cieplno-przepływowych wewnątrz kanałów łopatkowych turbin parowych, które nie są mierzalne w trakcie normalnej eksploatacji.

Długotrwały proces obliczeniowy stanowi znaczną przeszkodę w wykorzystaniu symulacji numerycznych na potrzeby obliczeń diagnostycznych, nawet przy wyznaczaniu stanu referencyjnego. Przyspieszenie obliczeń można osiągnąć poprzez zastąpienie modeli numerycznych poprawnie przygotowanymi symulatorami neuronowymi, [23][24]. Odpowiednio wytrenowana sieć neuronowa stanowi wówczas aproksymator funkcji, której argumentami są współrzędne geometryczne analizowanego układu łopatkowego oraz warunki brzegowe, a odpowiedzią – rozkłady wybranych parametrów cieplno-przepływowych.

Sieci neuronowe [25][26][27] znajdują obecnie coraz szersze zastosowanie. Są wykorzystywane m. in. do rozpoznawania obrazów, w tym np. znaków drogowych dla potrzeb sterowania autonomicznymi pojazdami. Za ich pomocą można stworzyć graczy, którzy z łatwością pokonają pasjonatów gier takich jak Go (model AlphaGo), czy poker (model Libratus). Umożliwiają również przetwarzanie języka naturalnego, analizę EKG, itd., [28]. Coraz częściej sięgają po nie także naukowcy poszukujący rozwiązań dla potrzeb cieplno-przepływowej diagnostyki maszyn wirnikowych.

Zbadano m. in. zdolność klasyfikatora neuronowego do identyfikacji niesprawnych urządzeń składowych obiegu cieplnego bloku parowego o mocy 200 MW, [7]. Badania skupiały się na skutkach degradacji urządzeń mających najistotniejszy wpływ na sprawność przemian energetycznych – grup stopni turbinowych oraz wymienników regeneracyjnych. Zadaniem modelu było wykrywanie pojedynczych i wielokrotnych usterek wybranych aparatów (w tym także aparatów o niepełnych danych pomiarowych) oraz rozpoznanie przyczyny degradacji spośród: degradacji uszczelnień skrzynek dyszowych kadłubów wysoko- i średnioprężnego (WP i SP), uszczelnień zewnętrznych WP i SP, degradacji powierzchni układu przepływowego grup stopni, ich krawędzi spływu i uszczelnień oraz degradacji czujnika temperatury w pierwszym upuście regeneracyjnym. Porównano model w postaci jednej sieci globalnej z modelem składającym się z wielu sieci lokalnych.

Sieci neuronowe zostały także wykorzystane do odtwarzania dynamiki fluktuacji wybranych parametrów cieplno-przepływowych (ciśnienia oraz temperatury zmierzonych w upuście regeneracyjnym) na podstawie wielkości uznanych za zmienne niezależne modelu, z punktu widzenia realizacji samego procesu przemian energetycznych, [7]. Zmienne niezależne ograniczono do zmiennych charakteryzujących realizowane zapotrzebowanie (obciążenie bloku) oraz parametrów otoczenia, pomijając nastawy poszczególnych regulatorów. Każdemu rozważanemu parametrowi cieplno-przepływowemu analizowanego obiegu odpowiadała jedna sieć neuronowa.

Przeanalizowano również możliwości wykorzystania sztucznych sieci neuronowych do projektowania wieńców łopatkowych w stopniach turbinowych, w tym łopatek ostatnich stopni turbin kondensacyjnych kształtowanych przestrzennie, [6][29] [30]. Stworzono bazę charakterystyk geometrycznych i przepływowych palisad turbinowych w oparciu o wyniki obliczeń numerycznych przeprowadzonych w programie FlowER, dla różnych parametrów geometrycznych. Zadaniem modelu neuronowego było wyznaczanie przestrzennych rozkładów wybranych parametrów cieplno-przepływowych (entalpii i prędkości), umożliwiających ocenę jakości przepływu czynnika przez projektowany układ łopatkowy.

Modele neuronowe posłużyły też do określania rozkładów wybranych parametrów przepływowych w kanałach łopatkowych turbin parowych. Analizowano zarówno przepływ poddźwiękowy w pierwszych stopniach części wysokoprężnej [6][23][24][31], jak i przepływ naddźwiękowy w ostatnich stopniach turbinowych, któremu towarzyszy powstawanie skośnej fali uderzeniowej, [6][32][33]. W pierwszym przypadku utworzono osobny model neuronowy dla każdego z rozpatrywanych parametrów przepływowych, a każdej objętości skończonej modelu numerycznego odpowiadała osobna sieć neuronowa. Odmienne podejście zastosowano dla przepływu naddźwiękowego. Kanał przepływowy podzielono na podobszary, wyodrębniając te, w których występują fale uderzeniowe i zastosowano różne sieci neuronowe w zależności od charakteru przepływu w danym obszarze (poddźwiękowy / naddźwiękowy).

Dla potrzeb predykcji pól przepływu wokół profili aerodynamicznych zastosowano konwolucyjne sieci neuronowe (ang. Convolutional Neural Network, CNN), które automatycznie wykrywają najistotniejsze cechy obrazu (w tym przypadku: rozkładu parametrów przepływu), przy minimalnym nadzorze twórcy modelu neuronowego, [34]. Zadaniem modelu było określenie rozkładów prędkości i ciśnienia dla nieznanymi warunków przepływu oraz geometrii, na podstawie zaszumionego obrazu opływającego obiektu. Oceniano wpływ kształtu profilu lotniczego, kąta natarcia oraz liczby Reynoldsa na siły aerodynamiczne i rozkłady wybranych parametrów przepływu.

Sieci neuronowe wykorzystano również do rekonstrukcji pola przepływu w dyszy, opływu skrzydła M6 oraz problemu Riemanna z przemieszczającą się falą uderzeniową, [35]. Przyjęto model w postaci perceptronu wielowarstwowego o nie więcej niż 3 warstwach ukrytych, który wykazał się dobrą zdolnością rekonstrukcji fal uderzeniowych.

2. MOTYWACJA, CEL PRACY I HIERARCHIA TWORZENIA METODY

Występowanie przepływu naddźwiękowego jest zjawiskiem charakterystycznym dla ostatnich stopni części niskoprężnych turbin parowych dużej mocy, które pracują w obszarze pary mokrej, [36][37][38][39]. Znaczne wymiary kanału przepływowego oraz skomplikowana konstrukcja ostatnich stopni powodują silne zróżnicowanie rozkładów wartości poszczególnych parametrów cieplno-przepływowych wzdłuż promienia turbiny, [40]. Przekroje profili łopatek turbinowych zmieniają się wzdłuż ich wysokości – zarówno w wieńcach kierowniczych, jak i wirnikowych. Co więcej, w przepływie pojawiają się skośne fale uderzeniowe, [32][41]. Wszystko to sprawia, że zarówno pomiar parametrów cieplno-przepływowych wewnątrz turbinowych kanałów NP (być może poszerzony i realny w przyszłości) oraz modelowanie przepływu pary mokrej przez okołodźwiękowe kanały łopatkowe turbin parowych są poważnym wyzwaniem, [42].

Pomocne w pokonaniu wspomnianych trudności mogą być dostępne obecnie wyniki pomiarów elektrownianych bloków parowych, przeprowadzone w warunkach zmiennych obciążeń, a także wyniki specjalistycznych pomiarów wewnątrz różnych kadłubów NP wykonane przez spółkę Diagnostyka Maszyn. Wsparciem podczas ustalania warunków brzegowych dla numerycznych modeli 3D, a dalej dla neuronowych symulatorów przepływu, może być również dostępny program diagnostyczny DIAGAR, którego część bilansową można w relatywnie prosty sposób dostroić do wiarygodnych wyników pomiarów.

Przywołane w poprzednim rozdziale niekorzystne właściwości numerycznych przestrzennych algorytmów obliczeń przepływowych, polegające na zbyt długich czasach obliczeniowych dla zastosowań diagnostycznych, motywują do poszukiwań równie precyzyjnych, lecz szybszych metod. Wśród nich uwagę zwracają metody sztucznych sieci neuronowych (SSN). Po dłuższym treningu otrzymuje się procedurę neuronową działającą bardzo szybko. Ma ona jednak oczywistą wadę – nie uwzględnia zależności fizycznych. Dlatego twórca konkretnej SSN musi precyzyjnie określić założenia i zakres stosowalności sieci, zwykle na podstawie wyników wybranego modelu fizycznego lub wiarygodnych pomiarów. Takie podejście umożliwia zastępowanie modeli fizycznych odpowiednio wytrenowanymi SSN.

Przedstawione powyżej wyzwania stały się motywacją do podjęcia badań nad możliwością stworzenia metody prowadzącej do zbudowania neuronowego modelu obliczeniowego okołodźwiękowych pól parametrów przepływowych w turbinach parowych.

Celem niniejszej rozprawy doktorskiej jest stworzenie neuronowego symulatora okołodźwiękowego przepływu pary w kanałach łopatkowych turbin parowych. Budowany model ma być tak skonstruowany, by był pomocny w rozwiązywaniu zadań diagnostyki cieplno-przepływowej i możliwy do zaimplementowania bezpośrednio w modułach obliczeniowych stopni turbinowych w programach działających podobnie do programu DIAGAR, w tym w programach diagnostycznych.

Zadaniem symulatora jest wyznaczenie stanu referencyjnego dla układu łopatkowego pracującego w obszarach okołodźwiękowych, przy poprawnej, czyli niezdegradowanej geometrii. Parametry geometryczne występujące w modelu odpowiadają więc geometrii projektowej. Zmieniają się natomiast obciążenie oraz warunki otoczenia i to one powodują zmiany w polu przepływu. Obszar stosowalności modelu ma odpowiadać polu eksploatacji turbiny, co na ogół oznacza zakres mocy od 50% do 105% mocy projektowej, przy utrzymaniu parametrów dolotowych pary w przedziałach bezpieczeństwa wyznaczonych przez producentów kotła i turbiny. Parametry odlotowe zależą od warunków środowiskowych, w tym przede wszystkim od warunków chłodzenia skraplacza.

Określenie stanu referencyjnego jest elementem niezbędnym do wykonania pierwszego zadania diagnostyki – operacji zwanej detekcją wystąpienia degradacji eksploatacyjnej. Tworzony model ma umożliwić określenie wzorcowych parametrów termodynamiczno-przepływowych zarówno dla tych miejsc w kanale przepływowym, które są dostępne pomiarowo, jak i tych, które są pomiarowo niedostępne. Wyznaczenie różnic parametrów aktualnego stanu pracy maszyny wobec parametrów stanu referencyjnego będzie jednoznaczne z określeniem symptomów jej niesprawnej pracy.

Modelowanie, obliczenia i analizy przedstawione w kolejnych rozdziałach niniejszej rozprawy zostały zilustrowane na przykładzie dwóch ostatnich stopni części niskoprężnej turbozespołu 18K370 z wylotem ND-37, pracujących w warunkach okołodźwiękowych.

Metoda analizy przepływu pary mokrej przez ostatnie stopnie turbiny parowej dużej mocy – prowadząca ostatecznie do stworzenia modelu neuronowego – studiowana jest w niniejszej rozprawie poprzez symulacje numeryczne prowadzone przy pomocy modeli dostrojonych do posiadanych danych eksperymentalnych. **Poniżej przedstawiono hierarchię wykonywanych zadań.**

1. Wybór i analiza geometrii rozpatrywanego układu przepływowego.
2. Budowa numerycznego przestrzennego modelu przepływu pary mokrej przez analizowany układ łopatkowy.

Pierwszym etapem budowy modelu jest utworzenie numerycznej siatki analizowanego kanału przepływowego w programie ANSYS Turbogrid 18.0. Gęstość siatki jest określana na podstawie analizy dokładności otrzymywanych wartości mocy i sprawności modelowanego układu łopatkowego oraz wartości bezwymiarowej odległości od ściany – tzw. parametru y^+ – dla poszczególnych wieńców łopatkowych. Warunki brzegowe zadane są w postaci rozkładów ciśnienia i temperatury na wlocie oraz wylocie z modelowanego kanału przepływowego, na podstawie wyników pomiarów przeprowadzonych przez spółkę Diagnostyka Maszyn w jednej z polskich elektrowni. Otrzymane rozkłady parametrów cieplno-przepływowych są podstawą do porównań z wartościami rzeczywistymi.

3. Stworzenie bazy danych referencyjnych.

W przypadku prezentowanych badań dane referencyjne są pozyskiwane przy użyciu numerycznego modelu obliczeniowego bloku parowego o mocy 370 MW, utworzonego w programie DIAGAR. Zmiana obciążenia analizowanego turbozespołu rozpatrywana jest w zakresie 57% ÷ 105%, a zmiana ciśnienia końcowego – w przedziale 4÷10 kPa, [43]. Model bloku parowego dostrajany jest do 49 kombinacji obciążenia i ciśnienia końcowego. Otrzymane wartości ciśnień i temperatur na wlocie oraz wylocie z dwóch ostatnich stopni części niskoprężnej są wprowadzane do modelu numerycznego w postaci warunków brzegowych. Numeryczne symulacje przepływu pary mokrej przez analizowany kanał łopatkowy przeprowadzane są dla każdego z 49 zestawów danych. Z uzyskanych rozkładów ciśnienia, temperatury i liczby Macha tworzona jest baza danych referencyjnych. Wstępna analiza danych dokonywana jest przy użyciu języka programowania Python 3.7. Podział danych pomiędzy zbiór treningowy, walidacyjny oraz testowy odbywa się w sposób losowy.

4. Optymalizacja neuronowego symulatora przepływu na średnicy podziałowej.

Kolejnym etapem jest określenie struktury sieci neuronowej oraz jej optymalizacja. Dla potrzeb prezentowanych badań przyjęto strukturę sieci neuronowej w postaci perceptronu wielowarstwowego i przeanalizowano ją pod kątem liczby warstw ukrytych, liczby neuronów w poszczególnych warstwach, wielkości podzbioru danych treningowych wykorzystywanego do uczenia modelu neuronowego w pojedynczym kroku (ang. batch size) oraz liczby epok.

5. Stworzenie neuronowego symulatora przepływu przestrzennego.

Neuronowy symulator przestrzennych rozkładów parametrów cieplno-przepływowych w analizowanym kanale łopatkowym tworzony jest na bazie wcześniej określonej struktury sieci neuronowej. Zaproponowano szereg rozwiązań prowadzących do uzyskania wysokiej dokładności tworzonego symulatora neuronowego. Przedstawiono również możliwości wykorzystania innych rozwiązań dla potrzeb wyznaczania przestrzennych rozkładów parametrów cieplno-przepływowych w kanałach łopatkowych turbin parowych.

Przedstawione w niniejszej rozprawie badania nad tworzeniem neuronowego symulatora przepływu odnoszą się do ogólnej metody jego budowy. Turbinowy układ łopatkowy jest tu przykładem. Struktura indywidualnego symulatora, zwłaszcza jego warstwy wejściowej i wyjściowej, jest inna dla każdej konfiguracji geometrycznej i warunków przepływowych. Z jednej strony zaprezentowana metoda budowy modelu może być zastosowana dla dowolnego urządzenia złożonej instalacji technicznej, pracującego w warunkach okołodźwiękowych, z drugiej jednak struktura samego symulatora neuronowego musi być każdorazowa dostosowana do modelowanego przypadku.

3. NUMERYCZNY MODEL POMIAROWY

Niniejsza rozprawa doktorska jest poświęcona modelowaniu przepływu pary mokrej w przydźwiękowych i naddźwiękowych kanałach łopatkowych turbin parowych. Jednym z powszechnie stosowanych układów łopatkowych, wpisujących się w to zagadnienie, są ostatnie stopnie części niskoprężnej turbozespołu 18K370 z wylotem ND-37, [44]. Obliczenia i analizy przedstawione w kolejnych rozdziałach, prowadzące do stworzenia metody neuronowego modelowania przepływu pary w warunkach okołodźwiękowych, zilustrowano na przykładzie dwóch ostatnich stopni wspomnianego układu przepływowego.

Podczas tworzenia neuronowego symulatora przepływu wykorzystano przestrzenne metody numeryczne. Jak już wcześniej wspomniano, metody te mogą być weryfikowane przez chociażby fragmentaryczne pomiary obiegu i wewnętrznych kanałów łopatkowych turbiny. W prezentowanym przypadku posłużono się zarówno wynikami pomiarów obiegu [43], jak i wynikami specjalistycznych pomiarów układu łopatkowego [44]. Dodatkowo uzupełniono je o wyniki obliczeń obiegu dostrojonego do wyników pomiarów analizowanego bloku energetycznego w warunkach zmiennych obciążeń, przeprowadzone przy użyciu programu DIAGAR, [8][9][10]. Wyniki tak zweryfikowanych obliczeń numerycznych mogą symulować parametry przepływu jeszcze obecnie niedostępne pomiarowo. Można je zatem traktować jako symulowane wyniki pomiarów przestrzennych i takie podejście zastosowano w niniejszej rozprawie. Podobnie postąpili autorzy Gardzilewicz, Świryczuk, Kurant w celu weryfikacji współczynników eksperymentalnych metod obliczeń przepływowych 1D turbinowych kanałów łopatkowych, [22].

3.1. Modelowany układ łopatkowy

Schemat struktury obiegu cieplnego turbiny parowej 18K370 zilustrowano na rysunku 3.2. Turbina jest podzielona na trzy kadłuby: kadłub wysokoprężny (WP), dwuprzepływową część średnioprężną (SP) oraz dwuprzepływową część niskoprężną (NP). Upusty regeneracyjne pobierane z poszczególnych kadłubów zasilają wymienniki regeneracyjne, których zadaniem jest wstępny podgrzew wody zasilającej. Analizowane stopnie turbinowe znajdują się pomiędzy upustami regeneracyjnymi kadłuba NP – stopień przedostatni znajduje się pomiędzy pierwszymi dwoma upustami, a stopień ostatni pomiędzy upustem drugim a wylotem. Widok przekroju kadłubów NP turbiny 18K370 przedstawiono na rys. 3.1.

3.2. Model geometryczny analizowanego kanału przepływowego

Geometryczny model analizowanego kanału przepływowego utworzono w oparciu o następujące informacje o poszczególnych wieńcach łopatkowych, [40][45]:


- współrzędne geometryczne punktów górnej i dolnej linii kanału przepływowego;
- liczbę łopatek tworzących wieńiec;

- wartości promieni determinujące położenie poszczególnych przekrojów profili łopatkowych;
- współrzędne geometryczne punktów tworzących poszczególne przekroje profili łopatkowych.


Liczbę łopatek oraz liczbę przekrojów profili łopatkowych tworzących poszczególne wieńce zestawiono w tabeli 3.1. Widok przekrojów poszczególnych profili łopatkowych przedstawiono na rys. 3.3. Rysunki 3.4 i 3.5 ilustrują geometrię kanału przepływowego analizowanego układu łopatkowego.

Tabela 3.1. Liczba łopatek oraz liczba przekrojów profili łopatkowych dla poszczególnych wieńców.


Wieniec	S1	R1	S2	R2
Liczba łopatek	60	61	48	53
Liczba przekrojów profili łopatkowych	9	9	9	13




Rys. 3.1. Widok przekroju kadłuba NP turbiny parowej 18K370, [46].




Rys. 3.2. Schemat struktury obiegu ciepłego turbiny parowej 18K370, [43].



Rys. 3.3. Widok przekrojów poszczególnych profili łopatkowych, na podstawie których odtworzono kształt łopatek analizowanego kanału przepływowego.



Rys. 3.4. Widok geometrii kanału przepływowego analizowanego układu łopatkowego.



Rys. 3.5. Widok z góry na geometrię kanału przepływowego analizowanego układu łopatkowego.

Numeryczno-pomiarowa analiza przestrzeni kanałów łopatkowych

Dyskretyzację analizowanego kanału przepływowego przeprowadzono w programie ANSYS Turbogrid 18.0. Objętość kanału podzielono na elementy heksahedralne (sześciścienne). Utworzono pięć siatek numerycznych o różnej gęstości. Liczba elementów najrzadszej siatki wyniosła około 400 tys., a najgęstszej około 5,85 mln. W każdym przypadku dopasowano rozmiar elementów – w tym przede wszystkim wysokość pierwszego elementu warstwy przyściennej – do gęstości siatki numerycznej tak, aby uzyskać pożądaną wartość współczynnika przyrostu kolejnych elementów. Zadbano również o to, aby wartości najistotniejszych parametrów siatki były zbliżone dla poszczególnych wieńców łopatkowych. Wartości najważniejszych parametrów utworzonych siatek geometrycznych zestawiono w tabeli 3.2.

Tabela 3.2. Zestawienie wybranych parametrów dla poszczególnych siatek numerycznych.

		S1	R1	S2	R2	
1	Liczba węzłów siatki	93 184	99 484	142 524	109 934	
	Liczba elementów siatki	85 312	91 278	131 705	101 232	409 527
	Wysokość pierwszego elementu	0,0106	0,0090	0,0099	0,0111	
	Współczynnik przyrostu elementów	1,558	1,571	1,578	1,581	
2	Liczba węzłów siatki	171 325	173 308	268 099	216 495	
	Liczba elementów siatki	159 392	161 244	251 480	202 796	774 912
	Wysokość pierwszego elementu	0,0079	0,0078	0,0078	0,0079	
	Współczynnik przyrostu elementów	1,526	1,523	1,525	1,531	
3	Liczba węzłów siatki	304 160	312 522	490 320	422 290	
	Liczba elementów siatki	286 611	294 626	465 394	401 112	1 447 743
	Wysokość pierwszego elementu	0,0055	0,0051	0,0056	0,0053	
	Współczynnik przyrostu elementów	1,495	1,492	1,486	1,491	
4	Liczba węzłów siatki	665 280	628 344	1 029 632	835 100	
	Liczba elementów siatki	636 000	599 748	988 848	801 504	3 026 100
	Wysokość pierwszego elementu	0,0034	0,0038	0,0038	0,0040	
	Współczynnik przyrostu elementów	1,378	1,371	1,373	1,379	
5	Liczba węzłów siatki	1 253 454	1 198 599	1 941 432	1 659 476	
	Liczba elementów siatki	1 209 108	1 155 048	1 879 605	1 606 668	5 850 429
	Wysokość pierwszego elementu	0,0023	0,0024	0,0026	0,0027	
	Współczynnik przyrostu elementów	1,306	1,306	1,305	1,308	

Następnie dokonano oceny wpływu gęstości utworzonych siatek na dokładność otrzymywanych wyników symulacji numerycznych. W tym celu przeprowadzono wstępne obliczenia numeryczne dla siatek o przedstawionej wyżej liczbie elementów. Spośród uzyskanych wyników, dla każdego z rozpatrywanych przypadków, odczytano sprawność analizowanego układu

łopatkowego oraz wartości momentów działających na łopatki poszczególnych wieńców wirnikowych. Znajomość momentów pozwoliła w prosty sposób oszacować moc generowaną przez analizowany układ łopatkowy, zgodnie z zależnością:

$$N = (z_{R1} * M_{R1} + z_{R2} * M_{R2}) \cdot \omega$$


gdzie:

- N – moc generowana przez analizowany układ łopatkowy;
- z_{R1}, z_{R2} – liczba łopatek tworzących poszczególne wieńce wirnikowe;
- M_{R1}, M_{R2} – momenty działające na łopatki wirnikowe poszczególnych wieńców;
- ω – prędkość kątowna wieńców wirnikowych.


Wartości sprawności, momentów działających na łopatki wirnikowe oraz uzyskane na ich podstawie wartości mocy zestawiono w tabeli 3.3 i zilustrowano na rysunkach 3.6 oraz 3.7.

Tabela 3.3. Zestawienie wybranych wielkości dla poszczególnych siatek numerycznych.

Nr siatki	η [-]	z_{R1} [-]	M_{R1} [N · m]	z_{R2} [-]	M_{R2} [N · m]	N [MW]
1	0,817	61	618,46	53	1005,13	28,59
2	0,822		620,45		1017,17	28,83
3	0,824		621,77		1020,11	28,90
4	0,828		623,10		1026,91	29,04
5	0,831		624,97		1026,05	29,06




Rys. 3.6. Wykres mocy analizowanego układu łopatkowego w funkcji liczby elementów siatki numerycznej.




Rys. 3.7. Wykres sprawności analizowanego układu łopatkowego w funkcji liczby elementów siatki numerycznej.

Najwyższe wartości sprawności oraz mocy analizowanego układu łopatkowego uzyskano dla siatki o największej gęstości. Należy jednak pamiętać, że wraz ze wzrostem liczby elementów siatki wydłuża się czas wykonywanych obliczeń numerycznych. Analizując tabelę 3.3 oraz rysunki 3.6 i 3.7 można zauważyć, że różnice w wartościach mocy oraz sprawności układu maleją dla siatek o większym zagęszczeniu. Koniecznym więc stał się wybór siatki o optymalnej gęstości.

W tym celu obliczono błąd względny sprawności oraz mocy układu, przyjmując jako wartości wzorcowe poszczególne wielkości odpowiadające siatce o największym zagęszczeniu. Otrzymane w ten sposób wykresy zilustrowano na rysunkach 3.8 i 3.9.



Rys. 3.8. Błąd względny sprawności analizowanego układu łopatkowego w funkcji liczby elementów siatki numerycznej.




Rys. 3.9. Błąd względny mocy analizowanego układu łopatkowego w funkcji liczby elementów siatki numerycznej.

Gęstości poszczególnych siatek numerycznych dobrano tak, aby każda kolejna siatka była około dwukrotnie gęstsza od poprzedniej (tabela 3.2). Przebiegi wykresów przedstawionych na rys. 3.8 i 3.9 potwierdzają zasadność zwiększania gęstości siatki numerycznej w celu podniesienia dokładności przeprowadzanych obliczeń. Istnieje jednak pewna granica, za którą dalsze zagęszczanie siatki nie powoduje istotnego wzrostu dokładności otrzymywanych wyników. Jak już wspomniano, należy mieć na uwadze nie tylko dokładność, ale również czas trwania obliczeń numerycznych.

Dla każdej z rozpatrywanych siatek numerycznych przeanalizowano również bezwymiarową odległość od ściany – tzw. parametr y^+ . Określono wartości średnie oraz wartości maksymalne występujące w poszczególnych wieńcach tworzących analizowany układ łopatkowy. Otrzymane wartości zestawiono na rysunku 3.10.

Podobnie, jak w przypadku sprawności oraz mocy analizowanych stopni turbinowych, różnice w wartościach parametru y^+ maleją wraz ze wzrostem gęstości siatki numerycznej. Dla siatek o największym zagęszczeniu elementów (nr 4 i 5, tabela 3.2) wartość maksymalna parametru y^+ w przedostatnim stopniu nie przekraczała 20, a w stopniu ostatnim 10. Wartości średnie spadły natomiast poniżej 10 w przedostatnim stopniu i poniżej 5 w stopniu ostatnim.

Ze względu na dostępną moc obliczeniową (Intel Core i7-8550U @ 1.80GHz, 16,0 GB RAM), dalsze zagęszczanie siatki numerycznej nie było możliwe. Wartości parametru y^+ uzyskane w poszczególnych wieńcach analizowanych stopni uznano za zadowalające dla potrzeb prowadzonych obliczeń i analiz. Siatkę numeryczną oznaczoną nr 4 (tabela 3.2) przyjęto jako optymalną zarówno pod względem gęstości (i związanym z nią czasem wykonywania obliczeń), jak i dokładności otrzymywanych wartości mocy oraz sprawności analizowanego układu łopatkowego. Dalsze obliczenia były przeprowadzane na siatce składającej się z około 3 milionów elementów.



Rys. 3.10. Wartości średnie oraz wartości maksymalne parametru y^+ dla poszczególnych wieńców tworzących analizowany układ łopatkowy.

3.3. Warunki brzegowe


Wartości parametrów termodynamicznych (ciśnienie i temperatur) na wlocie i wylocie analizowanego kanału przepływowego przyjęto na podstawie ciepłno-przepływowych pomiarów części niskoprężnych turbozespołów 18K370 z wylotami ND-37, przeprowadzonych przez spółkę Diagnostyka Maszyn w latach 1997 – 2005 na wybranych blokach dwóch polskich elektrowni, [44], [47].

Pomiary były realizowane za pomocą czujników ciśnienia i temperatury umieszczonych w przelotni, na wlocie do części NP, w przesuwnych sondach za poszczególnymi stopniami, w dyfuzorze wylotowym oraz kondensatorze, [47][48][49]. Sondy wprowadzano w trakcie normalnej pracy turbiny w gniazda zamontowane wcześniej podczas remontu (rys. 3.11). Umożliwiły one pomiar rozkładów ciśnień i temperatur wzdłuż promienia turbiny oraz kątów przepływu pary w płaszczyźnie merydionalnej i obwodowej.



Rys. 3.11. Widok końcówki sondy zamontowanej w przestrzeni pomiarowej za ostatnim stopniem analizowanej turbiny, [47].

Końcówkę pomiarową sondy (rys. 3.12) stanowił talerzyk, na którym umieszczono 4 ÷ 5 rurek Pitota, rozstawionych co 20°, umożliwiających pomiar ciśnienia całkowitego i określenie merydionalnego kąta przepływu pary. Dwa otwory w bocznych ściankach talerzyka pozwalały natomiast ocenić kąt napływu pary w płaszczyźnie obwodowej przy równoczesnym pomiarze ciśnienia statycznego. Pomiar temperatury całkowitej realizowano za pomocą miniaturowej termopary, umieszczonej w osłonie na końcu talerzyka.



Rys. 3.12. Widok końcówki sondy pomiarowej, [47].

Końcówki pomiarowe sond cechowano w warunkach laboratoryjnych, [47]. Otrzymane charakterystyki zapewniały ocenę ciśnień z dokładnością do $\pm 0,5\% \div 1\%$, a temperatur do $\pm 0,5^\circ$. Tak wysokie dokładności trudno było utrzymać podczas wykonywania pomiarów na rzeczywistym obiekcie. Przeprowadzone analizy wykazały, że błędy pomiarowe nie przekraczały jednak $\pm 2\%$ w ocenie ciśnień oraz $\pm 1^\circ$ w ocenie temperatur, w stosunku do warunków laboratoryjnych.

W celu przeprowadzenia symulacji numerycznych przepływu pary mokrej przez analizowany układ łopatkowy, niezbędna była znajomość następujących parametrów:

- ciśnienia całkowitego na wlocie do przedostatniego stopnia;
- temperatury całkowitej na wlocie do przedostatniego stopnia;
- ciśnienia statycznego na wylocie z ostatniego stopnia.

Pomiary wykonane przed spółkę Diagnostyka Maszyn obejmowały również m. in. ciśnienie i temperaturę na wlocie do ostatniego stopnia rozpatrywanego układu. Znajomość rzeczywistych wartości tych parametrów pozwoliła na weryfikację poprawności stworzonego modelu numerycznego.

W poniższych tabelach przedstawiono wartości ciśnień i temperatur:

- na wlocie do przedostatniego stopnia (tabela 3.4);
- na wlocie do ostatniego stopnia (tabela 3.5);
- na wylocie z ostatniego stopnia (tabela 3.6).

Tabela 3.4. Pomiary ciśnienia całkowitego i temperatury na wlocie do przedostatniego stopnia, dla poszczególnych głębokości sondowania, [44].

H [mm]	P _c [Pa]	T [K]
50	88 780	369,85
75	88 710	370,25
100	87 580	369,65
125	87 710	369,85
150	87 710	369,95
175	87 850	369,95
200	88 250	370,15
225	88 380	369,95
250	89 440	370,15
265	89 040	370,45
280	89 170	370,55
290	90 770	370,85
300	90 900	371,15

Tabela 3.5. Pomiary ciśnienia i temperatury na wlocie do ostatniego stopnia, dla poszczególnych głębokości sondowania, [44].


H [mm]	P _c [Pa]	P [Pa]	T [K]
80	37 950	35 160	347,25
150	37 820	35 730	347,45
200	37 820	36 180	347,25
300	37 820	36 130	346,55
400	37 950	36 260	346,55
450	37 950	36 260	346,95
500	38 090	35 790	347,25
525	53 880	38 360	348,05
545	50 690	37 720	356,55
565	41 140	36 050	351,55
575	39 020	36 620	349,45

Tabela 3.6. Pomiary ciśnienia i temperatury na wylocie z ostatniego stopnia, dla poszczególnych głębokości sondowania, [44].


H [mm]	P [Pa]	T [K]
25	8 900	319,15
100	8 820	317,75
150	8 780	317,35
200	8 620	317,25
300	8 620	316,75
400	8 820	319,45
500	8 820	319,65
600	8 910	319,15
700	9 220	319,95
800	9 750	321,25
850	9 790	321,25
875	9 430	320,75
900	10 630	322,85
925	12 930	326,55
950	9 180	318,15

Znajomość rzeczywistych wartości parametrów na różnych głębokościach kanału przepływowego umożliwiła zadanie warunków brzegowych w niestandardowy sposób – w postaci profili ciśnień i temperatur, a nie, jak to zwykle bywa, w postaci wartości uśrednionych. W każdym przypadku wysokość kanału przepływowego dla danego przekroju (wlotu lub wylotu) podzielono na przedziały zgodnie z głębokościami sondowania odpowiadającymi poszczególnym pomiarom. Na poniższych rysunkach zilustrowano zadane rozkłady warunków brzegowych w postaci:


- profilu ciśnienia całkowitego na wlocie do przedostatniego stopnia (rys. 3.13);
- profilu temperatury całkowitej na wlocie do przedostatniego stopnia (rys. 3.14);
- profilu ciśnienia statycznego na wylocie z ostatniego stopnia (rys. 3.15).



Rys. 3.13. Profil ciśnienia całkowitego zadany na wlocie do analizowanego kanału przepływowego.



Rys. 3.14. Profil temperatury całkowitej zadany na wlocie do analizowanego kanału przepływowego.




Rys. 3.15. Profil ciśnienia statycznego zadany na wylocie z analizowanego kanału przepływowego.


Jak już wspomniano wcześniej, numeryczne symulacje przepływu pary przez analizowany układ łopatkowy przeprowadzono dla siatki geometrycznej składającej się z około 3 milionów elementów (tabela 3.2). Symulacje przeprowadzono w programie ANSYS CFX 18.0. Zadano prędkość obrotową na poziomie 3000 obr./min. Jako czynnik roboczy przyjęto parę moką. Zastosowano model czynnika bazujący na międzynarodowych tablicach własności wody i pary wodnej IAPWS IF97 (ang. The International Association for the Properties of Water and Steam Industrial Formulation 1997), [50][51]. Jako model turbulencji przyjęto model k- ω SST (ang. Shear Stress Transport), który łączy w sobie zalety modeli turbulencji k- ϵ i k- ω , [52][53]. Pierwszy z nich dobrze modeluje turbulencje w przepływie swobodnym, natomiast drugi znacznie lepiej sprawdza się w modelowaniu przepływu turbulentnego w warstwie przyściennej. Wyniki przeprowadzonych obliczeń, umożliwiające weryfikację poprawności stworzonego modelu numerycznego, przedstawiono na poniższych rysunkach:

- rozkład ciśnienia na wlocie do ostatniego stopnia (rys. 3.16),
- rozkład temperatury na wlocie do ostatniego stopnia (rys. 3.17).

Otrzymane wartości ciśnienia i temperatury na wlocie do ostatniego stopnia analizowanego kanału przepływowego są zbliżone do rzeczywistych wartości tych parametrów uzyskanych na drodze pomiarów (tabela 3.5). Świadczy to o poprawności stworzonego modelu numerycznego. Różnice pomiędzy otrzymanymi wartościami a wartościami zmierzonymi, mogą wynikać m. in. z dokładności pomiarów rzeczywistych oraz uproszczeń obliczeń zastosowanych w poszczególnych elementach składowych numerycznego modelu przepływu pary mokrej przez analizowany układ łopatkowy – takich jak zastosowany model czynnika roboczego czy model turbulencji.



Rys. 3.16. Rozkład ciśnienia na wlocie do ostatniego stopnia.






Rys. 3.17. Rozkład temperatury na wlocie do ostatniego stopnia.


3.4. Symulacja przepływu pary mokrej przez analizowany kanał łopatkowy

Rozkłady wybranych parametrów cieplno-przepływowych, uzyskane na drodze symulacji przepływu pary mokrej przez dwa ostatnie stopnie turbiny 18K370 z wylotem ND-37, zilustrowano na rys. 3.18 – 3.20.


Rysunek 3.18 przedstawia rozkład liczby Macha w kanale przepływowym u wierzchołków łopatek, w 75% rozpiętości łopatek, w połowie rozpiętości łopatek oraz u stóp łopatek. W celu uwidocznienia obszarów zajmowanych przez fale uderzeniowe zilustrowano wartości liczby Macha odpowiadające przepływowi naddźwiękowemu – w przedziale od 1 do maksymalnej wartości występującej w analizowanym kanale przepływowym (około 1,87). Najwyższe wartości liczby Macha można zaobserwować w ostatnim stopniu – u stopy łopatki kierowniczej oraz przy wierzchołku łopatki wirnikowej. Mechanizm powstawania fali uderzeniowej w stopniu przedostatnim jest podobny – niewielka fala uderzeniowa pojawia się na krawędzi spływu łopatki kierowniczej, w jej dolnej części, oraz w górnej części łopatki wirnikowej. Trójwymiarowy widok obszaru układu łopatkowego zajmowanego przez przepływ naddźwiękowy zilustrowano na rys. 3.21.

Rysunki 3.19 i 3.20 ilustrują odpowiednio rozkład ciśnienia i temperatury w analizowanym kanale przepływowym u wierzchołków łopatek, w połowie rozpiętości łopatek oraz u stóp łopatek. Lokalne spadki zarówno ciśnienia, jak i temperatury, odpowiadają obszarom występowania fal uderzeniowych. Otrzymane rozkłady rozpatrywanych parametrów są zgodne z założeniami teoretycznymi i świadczą o poprawności stworzonego numerycznego modelu przepływu pary mokrej przez analizowany układ łopatkowy.







Rys. 3.18. Rozkład liczby Macha: a) przy wierzchołkach łopatek, b) w 75% rozpiętości łopatek, c) w połowie rozpiętości łopatek, d) w 25% rozpiętości łopatek, e) u stóp łopatek.



Rys. 3.19. Rozkład ciśnienia: a) przy wierzchołkach łopatek, b) w połowie rozpiętości łopatek, c) u stóp łopatek.



Rys. 3.20. Rozkład temperatury całkowitej: a) przy wierzchołkach łopatek, b) w połowie rozpiętości łopatek, c) u stóp łopatek.



Rys. 3.21. Widok obszaru zajmowanego przez przepływ naddźwiękowy w poszczególnych wieńcach analizowanych stopni turbinowych.

4. SYMULATOR NEURONOWY


Jednym z najważniejszych etapów budowy modelu neuronowego jest wydzielenie zbiorów danych treningowych, testowych oraz walidacyjnych. W przypadku tworzonego neuronowego symulatora przepływu pary mokrej przez analizowany układ łopatkowy należało najpierw stworzyć bazę danych, aby następnie móc ją podzielić na wspomniane zbiory.

4.1. Baza danych referencyjnych

Bazę danych referencyjnych dla modelu neuronowego utworzono na podstawie symulacji przepływu pary mokrej przez analizowane stopnie turbinowe, przeprowadzonych dla różnych warunków brzegowych odpowiadających zmiennemu obciążeniu turbiny. Wartości parametrów brzegowych dla poszczególnych symulacji numerycznych wyznaczono przy użyciu modelu obiegu utworzonego w programie DIAGAR, każdorazowo dostrajanego do wyników pomiarów analizowanego bloku energetycznego, [43]. Jak wspomniano we wprowadzeniu, numeryczny program obliczeniowy DIAGAR jest systemem diagnostycznym umożliwiającym określenie stanu referencyjnego oraz aktualnego stanu bloku energetycznego, [5][7]. Zastosowany w nim model bloku parowego charakteryzuje się budową modułową, która umożliwia odtworzenie struktury bloku energetycznego. Poszczególne moduły stanowią modele obliczeniowe urządzeń składowych analizowanego obiektu, [54].

Rysunek 4.1 przedstawia fragment numerycznego modelu obliczeniowego bloku parowego o mocy 370 MW, obejmujący analizowany kadłub NP. Schemat całego modelu numerycznego zamieszczono w załączniku 1. Moduły oznaczone nr 24 stanowią modele obliczeniowe grup stopni turbinowych. Moduły oznaczone nr 350 to upusty regeneracyjne. Pozostałe urządzenia widoczne na zilustrowanym fragmencie modelu to: dyfuzor pary (nr 491), skraplacz (nr 405), woda chłodząca (nr 501), pompa skroplin (nr 415) oraz wymienniki regeneracyjne (nr 420 i 450). Modele obliczeniowe analizowanych stopni turbinowych zawarte są w modułach oznaczonych nr 220 (stopień przedostatni) i 240 (stopień ostatni).

Wartości parametrów brzegowych dla poszczególnych symulacji numerycznych wyznaczono poprzez dostrojenie modelu analizowanego bloku energetycznego do 49 różnych kombinacji wartości obciążenia i ciśnienia końcowego (tabela 4.1), występujących w rzeczywistych warunkach eksploatacyjnych. Rozpatrywano zmianę obciążenia w zakresie od 210 MW do 390 MW, co przy mocy nominalnej wynoszącej 370 MW oznacza zmianę obciążenia w zakresie od około 57% do około 105%. Dla każdej z 7 wartości mocy uwzględniono 7 wartości ciśnienia końcowego w zakresie 4÷10 kPa. Otrzymane wartości parametrów brzegowych (ciśnienia i temperatury na wlocie oraz ciśnienia na wylocie z analizowanego układu łopatkowego), niezbędne do przeprowadzenia symulacji numerycznych dla każdej z 49 kombinacji pokrywających pole pracy bloku, zestawiono w tabeli 4.1.



Rys. 4.1. Widok fragmentu modelu numerycznego analizowanego obiegu ciepłego turbiny 370 MW, utworzonego w programie DIAGAR
(cały schemat numeryczny obiegu znajduje się w załączniku 1).

Tabela 4.1. Zestawienie wartości parametrów brzegowych dla rozpatrywanych wartości mocy i ciśnienia końcowego.

N_t [MW]	p_k [kPa]	P_{in} [Pa]	t_{in} [°C]	T_{in} [K]	p_{out} [Pa]
210	4	65645	120,85	394,00	4 121
	5	65 833	120,86	394,01	4 863
	6	66 016	120,87	394,02	5 829
	7	66 216	120,88	394,03	6 832
	8	66 439	120,89	394,04	7 858
	9	66 672	120,90	394,05	8 902
	10	66 931	120,91	394,06	9 984
240	4	72 793	118,01	391,16	4 373
	5	72 952	118,02	391,17	4 952
	6	73 146	118,03	391,18	5 818
	7	73 335	118,04	391,19	6 806
	8	73 535	118,05	391,20	7 822
	9	73 757	118,06	391,21	8 846
	10	74 001	118,07	391,22	9 890
270	4	81 069	118,44	391,59	4 705
	5	81 205	118,44	391,59	5 138
	6	81 404	118,45	391,60	5 864
	7	81 594	118,46	391,61	6 795
	8	81 788	118,47	391,62	7 783
	9	81 997	118,48	391,63	8 804
	10	82 217	118,50	391,65	9 826

300	4	87 199	115,90	389,05	4 830
	5	87 311	115,91	389,06	5 312
	6	87 517	115,92	389,07	5 934
	7	87 714	115,93	389,08	6 789
	8	87 906	115,94	389,09	7 771
	9	88 109	115,95	389,10	8 773
	10	88 324	115,96	389,11	9 796
330	4	95 049	116,32	389,47	4 995
	5	95 208	116,33	389,48	5 612
	6	95 346	116,34	389,49	6 103
	7	95 556	116,35	389,50	6 842
	8	95 753	116,36	389,51	7 761
	9	95 948	116,37	389,52	8 747
	10	96 155	116,38	389,53	9 752
360	4	97 303	106,17	379,32	5 059
	5	97 463	106,18	379,33	5 729
	6	97 603	106,19	379,34	6 171
	7	97 808	106,20	379,35	6 871
	8	98 007	106,21	379,36	7 756
	9	98 203	106,22	379,37	8 741
	10	98 409	106,23	379,38	9 744
390	4	104 943	106,63	379,78	5 222
	5	105 113	106,64	379,79	5 979
	6	105 260	106,65	379,80	6 429
	7	105 428	106,66	379,81	7 007
	8	105 634	106,67	379,82	7 791
	9	105 836	106,68	379,83	8 733
	10	106 034	106,69	379,84	9 718


Następnie – dla każdego z rozpatrywanych 49 przypadków – przeprowadzono numeryczne obliczenia przepływu pary mokrej przez analizowane stopnie turbinowe. Spośród otrzymanych wyników, dla każdego elementu numerycznej siatki obliczeniowej, wyeksportowano współrzędne geometryczne określające jego położenie oraz wartości rozpatrywanych parametrów cieplno-przepływowych: liczby Macha, ciśnienia oraz temperatury. Ostatecznie baza danych referencyjnych składała się z następujących danych:

- wartości ciśnienia całkowitego na wlocie do analizowanych stopni turbinowych;
- wartości temperatury całkowitej na wlocie;
- wartości ciśnienia statycznego na wylocie;

- trzech współrzędnych geometrycznych określających położenie poszczególnych punktów analizowanego kanału przepływowego (węzłów siatki numerycznej);
- wartości liczby Macha, ciśnienia oraz temperatury w każdym punkcie kanału uzyskane na drodze obliczeń numerycznych.

Liczba rekordów wyniosła 154 759 444, zatem baza danych referencyjnych miała postać macierzy o wymiarach 154 759 444 x 9.

Wstępną analizę danych oraz proces modelowania przeprowadzono przy użyciu języka programowania Python 3.7 oraz aplikacji Jupyter Notebook. Rysunek 4.2 przedstawia histogramy rozważanych parametrów cieplno-przepływowych: liczby Macha, ciśnienia oraz temperatury. Rozkład wartości liczby Macha świadczy o stosunkowo niewielkim obszarze kanału przepływowego zajmowanym przez przepływ naddźwiękowy, co zostało wcześniej zilustrowane na rys. 3.21. Histogram ciśnienia ukazuje przewagę wartości poniżej 50 kPa nad wartościami z przedziału 50 ÷ 100 kPa, natomiast rozkład temperatury świadczy o przewadze liczebnej wartości z zakresu 340 ÷ 350 K. W żadnym z przedstawionych rozkładów nie występują wartości odstające, które mogłyby negatywnie wpłynąć na proces tworzenia modelu neuronowego.



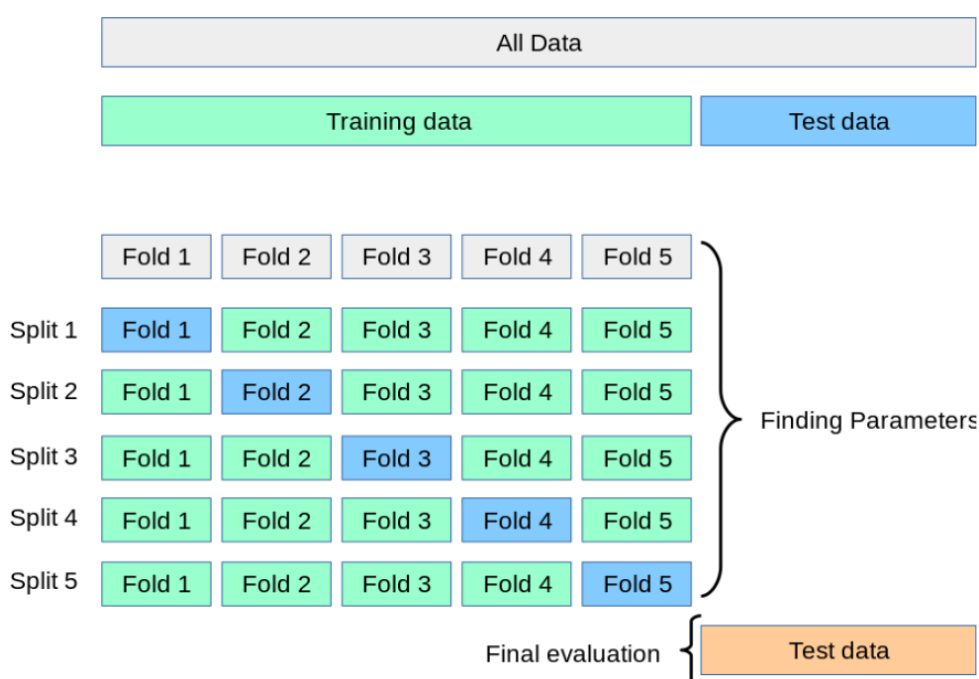
Rys. 4.2. Histogramy ilustrujące rozkłady rozważanych parametrów cieplno-przepływowych: liczby Macha, ciśnienia oraz temperatury.

Normalizację danych przeprowadzono przy użyciu narzędzia *MinMaxScaler*, sprowadzając zakresy poszczególnych zmiennych do przedziału $< 0, 1 >$. Zabieg ten ma na celu ustabilizowanie, a nawet przyspieszenie przebiegu procesu wstecznej propagacji błędów (ang. back propagation), [55].

4.2. Zbiór treningowy, walidacyjny oraz testowy

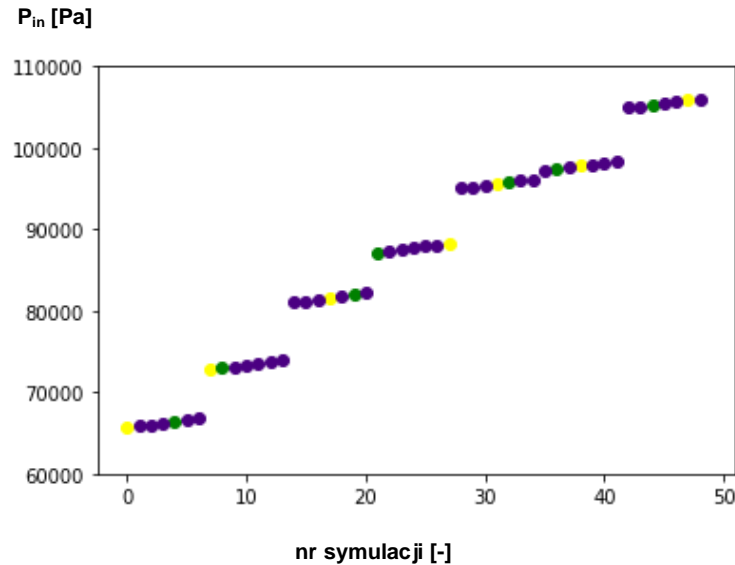
Jedną z najważniejszych cech modelu predykcyjnego jest umiejętność generalizacji, czyli zdolność modelu do poprawnej odpowiedzi na nieznanne wcześniej dane wejściowe. Model nie może być zatem trenowany i testowany na tych samym zbiorze danych. Takie podejście prowadzi do zbyt dużego dopasowania modelu do danych (ang. overfitting) i jest istotnym błędem metodologicznym, [56]. Ze zbioru danych należy wydzielić zbiory treningowy, walidacyjny oraz testowy. Zbiór walidacyjny jest wykorzystywany do wstępnej oceny dokładności modelu. Zbiór testowy – do oceny końcowej. Dzięki temu model nie ma możliwości dopasowania się do zbioru testowego, ponieważ jest on wykorzystywany jedynie w celu ostatecznej ewaluacji. Ocenie modelu podczas jego optymalizacji służy wyłącznie zbiór walidacyjny.

Wydzielenie zbiorów: walidacyjnego oraz testowego powoduje znaczne zmniejszenie liczby próbek wykorzystywanych do treningu modelu, co może skutkować uzależnieniem modelu od sposobu podziału próbek między poszczególne zbiory. Efekt ten można zniwelować dzięki zastosowaniu walidacji krzyżowej, [57]. Zbiór testowy nadal będzie stanowił odrębny zbiór danych, natomiast wydzielenie niezależnego zbioru walidacyjnego nie będzie już konieczne. Zbiór danych treningowych należy podzielić na k podzbiorów (ang. k -fold cross validation), wytrenować model k -krotnie na $k-1$ podzbiórach danych i przetestować na pozostałym podzbiórze – dla wszystkich możliwych kombinacji (rys. 4.3). Dzięki takiemu podejściu model „zobaczy” wszystkie dane treningowe, które będą jednocześnie stanowiły zbiór walidacyjny. Końcowym wynikiem walidacji krzyżowej będzie średnia wartość wyników uzyskanych przez model wytrenowany i wstępnie sprawdzony na poszczególnych kombinacjach zbiorów treningowego i walidacyjnego.



Rys. 4.3. Koncepcja walidacji krzyżowanej z podziałem zbioru danych treningowych na k podzbiorów (ang. k -fold cross validation), [57].

Spośród bazy danych referencyjnych, utworzonej na drodze obliczeń numerycznych, wydzielono zbiór danych treningowych, walidacyjnych oraz testowych. W bazie danych referencyjnych można wyróżnić 7 podzbiorów odpowiadających poszczególnym wartościom mocy analizowanego turbozespołu. W każdym podzbiórze można natomiast wyróżnić dane dla 7 symulacji – po jednej dla każdej z rozpatrywanych wartości ciśnienia końcowego. Zbiory: walidacyjny oraz testowy utworzono poprzez losowy wybór po jednej symulacji z każdego z siedmiu podzbiorów oraz połączenie odpowiadających im danych w jedną całość. Dane z pozostałych 35 symulacji stanowiły zbiór treningowy. Podział symulacji pomiędzy poszczególne zbiory zilustrowano na rysunku 4.4.



Rys. 4.4. Wartości ciśnienia wlotowego dla poszczególnych symulacji numerycznych (symulacje treningowe – kolor fioletowy ● , symulacje walidacyjne – kolor zielony ● , symulacje testowe – kolor żółty ●).

4.3. *Uczenie maszynowe*

Przed przystąpieniem do budowy modelu neuronowego sprawdzono, jak ze stworzoną bazą danych poradzą sobie wybrane, powszechnie stosowane, modele uczenia maszynowego (ang. machine learning):

- DecisionTreeRegressor;
- RandomForestRegressor;
- GradientBoostingRegressor;
- XGBRegressor;
- KNeighborsRegressor;
- RadiusNeighborsRegressor;
- SVR.

Bazę danych referencyjnych ograniczono do punktów położonych na średnicy podziałowej, sprowadzając tym samym pole przepływu do układu dwuwymiarowego. Dla każdego z powyższych modeli określono przestrzeń rozważanych hiperparametrów (zakresy poszczególnych parametrów modelu zadawanych przez użytkownika) – fragment kodu zamieszczono w załączniku 2 – i wykonano 30 iteracji prowadzących do znalezienia najbardziej optymalnej konfiguracji. Zadaniem modeli była predykcja rozkładu liczby Macha na średnicy podziałowej analizowanego kanału łopatkowego. Optymalizację przeprowadzono przy użyciu narzędzia hyperopt, bazującego na optymalizacji bayesowskiej, [58][59]. Jego działanie polega na próbach oszacowania optymalnych wartości parametrów w oparciu o wyniki dla wcześniejszych konfiguracji. Jako funkcję

celu przyjęto maksymalną wartość średnią wyników walidacji krzyżowej (przyjęto liczbę podzbiorów $k=5$), [57]. Metrykę sukcesu stanowił współczynnik determinacji R^2 (ang. coefficient of determination), [60].

Współczynnik determinacji R^2 pozwala oszacować dokładność dopasowania modelu w postaci równania regresji do danych treningowych, [60]. Przyjmuje on wartości z przedziału $(0, 1)$, zgodnie z zależnością:

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2},$$

gdzie:

n – liczba próbek;

y_i – wartość rzeczywista i -tej próbki;

\hat{y}_i – wartość przewidywana i -tej próbki;

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i.$$

Wartości bliskie 1 oznaczają, że za pomocą analizowanego modelu można dokonać predykcji zmiennej zależnej (w tym przypadku ciśnienia, temperatury oraz liczby Macha) na podstawie zmiennej niezależnej (parametrów wejściowych).

Pierwszym z zaproponowanych modeli uczenia maszynowego jest drzewo decyzyjne, którego główną zaletą jest jego prostota [61]. Drzewa decyzyjne mają jednak tendencję do zbytowego dopasowywania się do danych treningowych (ang. overfitting). Jednym ze sposobów na zwiększenie zdolności do generalizacji jest stworzenie modelu składającego się nie z jednego, a z wielu drzew decyzyjnych (tzw. RandomForest, [62]) oraz wytrenowanie ich za pomocą losowych próbek zbioru treningowego (ang. bootstrapping). Odpowiedzią modelu jest wówczas średnia wartość odpowiedzi poszczególnych drzew decyzyjnych, [63].

Kolejnym rozpatrywanym modelem jest GradientBoostingRegressor, [64]. Model ten, podobnie jak RandomForestRegressor, składa się z wielu drzew decyzyjnych. Poszczególne drzewa nie są jednak tworzone jednocześnie, a pojedynczo. Co więcej, każde kolejne drzewo dodawane do modelu musi być tak sparametryzowane, aby jego uwzględnienie poprawiało dokładność całego modelu. Innymi słowy, zadaniem tworzonego modelu jest podążanie w kierunku ujemnego gradientu funkcji kosztu – w przypadku regresji np. błędu średniokwadratowego (ang. MSE – Mean Squared Error), [65].

Pod nazwą XGBRegressor kryje się wyrażenie „Extreme Gradient Boosting”, [66]. W stosunku do swoich poprzedników, model ten posiada kolejne usprawnienia, dzięki którym wyróżnia się nie tylko dokładnością, ale również szybkością działania, [67]. Wprowadzone zostały m. in. wagi dla poszczególnych drzew decyzyjnych (ang. shrinkage lub learning rate). Zastosowano także regularyzację (L1 i L2) wag poszczególnych gałęzi drzew decyzyjnych, której zadaniem jest przeciwdziałanie zbyt niemu dopasowaniu się modelu do danych treningowych

(ang. overfitting). Polega ona na „karaniu” modelu za zbytne dopasowywanie się do danych poprzez dodanie dodatkowego wyrażenia do funkcji kosztu, [68]. Co więcej, podobnie jak w przypadku modelu RandomForest, podczas każdej iteracji model jest trenowany na losowo wybranych próbkach zbioru danych treningowych (ang. bootstrapping).

Modele KNeighborsRegressor i RadiusNeighborsRegressor dokonują predykcji w oparciu o własności sąsiadujących próbek. Takie podejście okazało się nieskuteczne w przypadku stworzonej bazy danych referencyjnych. Końcowa wartość współczynnika determinacji wyniosła zaledwie 0,67. Wspomniane modele nie były brane pod uwagę w dalszych rozważaniach.

Ostatnim rozpatrywanym modelem jest SVR (ang. Support Vector Regression), [69]. Jego zadaniem jest wyznaczenie hiperpłaszczyzny zawierającej jak największą liczbę próbek zbioru danych. Model ten jest rzadko spotykany w przypadku regresji (znacznie częściej można spotkać jego odpowiednik do zadań klasyfikacji – SVM). Co więcej, nie sprawdza się w przypadku dużych zbiorów danych, ponieważ czas jego treningu jest silnie uzależniony od liczby próbek. W analizowanym przypadku czas treningu okazał się tak długi, że zrezygnowano z dalszych obliczeń przy użyciu tego modelu.

Czas trwania optymalizacji oraz maksymalną wartość współczynnika determinacji, jaką osiągnęły poszczególne modele, zestawiono w tabeli 4.2.

Tabela 4.2. Czas optymalizacji oraz maksymalna wartość współczynnika determinacji R^2 dla rozpatrywanych modeli uczenia maszynowego.


Nazwa modelu	Czas optymalizacji	R^2_{\max}
DecisionTreeRegressor	4 min 10 s	0,966
RandomForestRegressor	3 h 4 min 19 s	0,974
GradientBoostingRegressor	7 h 14 min 41 s	0,986
XGBRegressor	1 h 18 min 45 s	0,985

Najkrótszym czasem optymalizacji wykazało się drzewo decyzyjne. Jego maksymalna osiągnięta dokładność była jednak najniższa spośród wszystkich rozpatrywanych modeli. Najwyższą dokładność zaprezentowały modele GradientBoostingRegressor oraz XGBRegressor, przy czym czas optymalizacji modelu GradientBoostingRegressor był zdecydowanie dłuższy.

Uzyskane optymalne wartości parametrów wprowadzono do poszczególnych modeli i przeprowadzono trening oraz weryfikację na zbiorze testowym. Rysunek 4.5 stanowi zestawienie czasu trwania treningu (fit_time), czasu trwania testu (score_time) oraz wynik testu (test_score) – w postaci współczynnika determinacji R^2 – dla rozpatrywanych modeli. Tak, jak w przypadku procesu optymalizacji, najkrótszym czasem treningu wykazało się drzewo decyzyjne, a najdłuższym – GradientBoostingRegressor. Czas przeprowadzenia testu również był najkrótszy dla drzewa decyzyjnego, a najdłuższy dla modelu GradientBoostingRegressor. Niewiele krótszym

czasem testu wykazał się XGBRegressor (ok. 1,1 s). Wszystkie modele wykazały się wysoką dokładnością na zbiorze testowym ($R^2 > 0,95$), przy czym najwyższe wartości współczynnika determinacji osiągnęły modele XGBRegressor i GradientBoostingRegressor.


Biorąc pod uwagę przeanalizowane własności rozpatrywanych modeli uczenia maszynowego (czas treningu / optymalizacji, czas przeprowadzenia testu oraz wartość współczynnika determinacji osiągniętą na zbiorze testowym) uznano model XGBRegressor za najbardziej optymalny.



Rys. 4.5. Czas treningu (fit_time), czas testu (score_time) oraz wynik testu (test_score) dla rozpatrywanych modeli uczenia maszynowego.

W celu bardziej szczegółowej weryfikacji wyniku testu – wartości współczynnika determinacji osiągniętej na zbiorze testowym – przeprowadzono test wzdłuż osi turbiny. Jego zadaniem było zlokalizowanie obszarów kanału przepływowego, w których zaproponowany model wykazał się wysoką bądź niską dokładnością, (rys. 4.6).

Zbiór danych testowych posortowano po współrzędnej z, zgodnie z kierunkiem osi turbiny. Następnie otrzymany zbiór podzielono na 100 podzbiorów i w każdym z nich oszacowano dokładność modelu – wartość współczynnika determinacji R^2 . Najniższą dokładność modelu zaobserwowano na wylocie z analizowanego układu łopatkowego, gdzie przepływ czynnika roboczego jest bardzo złożony.



Rys. 4.6. Wynik testu wzdłuż osi turbiny – wartość współczynnika determinacji (R^2) osiągnięta przez model XGBRegressor na kolejnych podzbiórach zbioru testowego.

4.4. Neuronowy symulator przepływu pary mokrej przez analizowany układ łopatkowy


4.4.1. Symulator przepływu pary na średnicy podziałowej

Kolejnym krokiem w kierunku stworzenia neuronowego symulatora przepływu pary mokrej przez analizowane stopnie turbinowe była budowa neuronowego modelu przepływu na średnicy podziałowej. Przeanalizowano trzy wybrane struktury sieci neuronowej: perceptron jednowarstwowy oraz perceptron wielowarstwowy (ang. Multilayer Perceptron, MLP) z dwiema i trzema warstwami ukrytymi.

Warstwa wejściowa składała się z 6 neuronów, po jednym dla każdego parametru wejściowego, tj.:


- wartości ciśnienia całkowitego na wlocie do analizowanych stopni turbinowych,
- wartości temperatury całkowitej na wlocie,
- wartości ciśnienia statycznego na wylocie,
- trzech współrzędnych geometrycznych określających położenie poszczególnych punktów analizowanego kanału przepływowego (odpowiadających węzłom siatki numerycznej);

natomiast warstwa wyjściowa składała się z 3 neuronów – po jednym dla każdego rozpatrywanego parametru cieplno-przepływowego, tj.: ciśnienia, temperatury oraz liczby Macha, rys. 4.7.



Rys. 4.7. Schemat struktury tworzonego modelu neuronowego.

Jako funkcję aktywacji warstw ukrytych przyjęto funkcję ReLU (ang. Rectified Linear Unit), potocznie zwaną „funkcją rampy”, która przyjmuje wartość 0 dla ujemnych wartości argumentów, a dodatnie wartości argumentów odwzorowuje bez zmian (rys. 4.8). Przebieg funkcji ReLU jest znacznie mniej skomplikowany w stosunku do niegdyś powszechnie stosowanej sigmoidalnej funkcji aktywacji. Dzięki temu zmniejsza się ilość pamięci niezbędnej do przeprowadzenia obliczeń przy użyciu tworzonego modelu neuronowego. Co więcej, funkcja aktywacji ReLU pozwala zniwelować problem „znikającego gradientu”, [70].



Rys. 4.8. Funkcja aktywacji ReLU (ang. Rectified Linear Unit).

Rozważane struktury modelu neuronowego przeanalizowano pod kątem liczby neuronów w warstwach ukrytych oraz wielkości podzbioru danych treningowych wykorzystywanego do uczenia modelu neuronowego w pojedynczym kroku (ang. batch size).

Ze względu na dostępną moc obliczeniową liczbę neuronów w poszczególnych warstwach ukrytych przyjmowano w postaci liczb binarnych z następującego zbioru:

$$\{ 8 , 16 , 32 , 64 , 128 , 256 , 512 , 1024 \},$$

natomiast wielkość podzbioru danych treningowych ze zbioru:

$$\{ 512 , 1024 , 2048 , 4096 \}.$$

W przypadku perceptronu wielowarstwowego liczba neuronów w kolejnych warstwach ukrytych stanowiła dwukrotność liczby neuronów w warstwie poprzedniej. Poszczególne konfiguracje liczby neuronów w warstwach ukrytych dla perceptronu z dwiema warstwami ukrytymi wyglądały następująco:

$$\left\{ 8/16 , 16/32 , 32/64 , 64/128 , 128/256 , 256/512 , 512/1024 , 1024/2048 \right\},$$

a dla perceptronu trójwarstwowego:

$$\left\{ 8/16/32 , 16/32/64 , 32/64/128 , 64/128/256 , 128/256/512 , 256/512/1024 \right\}.$$

Funkcję kosztu (in. wewnętrzną metrykę modelu) stanowił błąd średniokwadratowy (ang. Mean Squared Error, MSE). Metrykę sukcesu (in. zewnętrzną metrykę modelu), służącą oszacowaniu dokładności modelu oraz umożliwiającą porównanie modeli o różnych parametrach,


stanowił współczynnik determinacji R^2 (ang. coefficient of determination). Zastosowano optymalizator Adam, bazujący na stochastycznym spadku wzdłuż gradientu (ang. stochastic gradient descent). W podstawowej konfiguracji algorytm ten przypisuje wszystkim wagom (parametrom) sieci jednakową stałą wartość kroku uczenia (ang. learning rate). W przypadku zastosowanego optymalizatora wartość kroku uczenia dobierana jest niezależnie dla każdej z wag w oparciu o momenty gradientów pierwszego i drugiego stopnia – stąd jego nazwa (ang. **adaptive moment estimation**). Optymalizator Adam charakteryzuje się wysoką wydajnością oraz niewielkimi wymaganiami odnośnie pamięci. W wielu przypadkach pozwala szybko osiągnąć dobre rezultaty, również dla dużych zbiorów danych, [71].

Fragment kodu przedstawiający budowę tworzonego modelu neuronowego zamieszczono w załączniku 3. Przebiegi krzywych uczenia – błędu średniokwadratowego (MSE) oraz współczynnika determinacji (R^2) dla zbioru treningowego i walidacyjnego, dla wszystkich rozpatrywanych konfiguracji modelu przepływu na średnicy podziałowej, zamieszczono w załączniku 4.

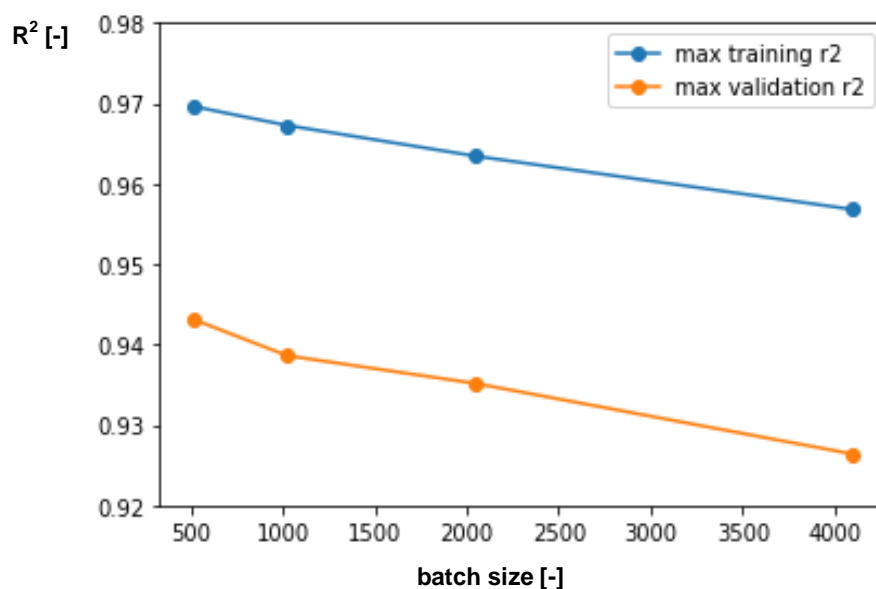
Rysunek 4.9 przedstawia wartość metryki sukcesu (R^2), osiągniętą przez model z jedną warstwą ukrytą, w funkcji liczby neuronów w warstwie ukrytej, dla poszczególnych wielkości podzbiorów danych treningowych. Wraz ze wzrostem liczby neuronów w warstwie ukrytej wzrasta dokładność modelu zarówno na zbiorze treningowym, jak i walidacyjnym. Maksymalne wartości współczynnika determinacji (R^2) dla poszczególnych wielkości podzbiorów treningowych zilustrowano na rys. 4.10. Wzrost liczebności podzbioru treningowego skutkuje pogorszeniem dokładności modelu.

Analogiczne przebiegi powyższych charakterystyk, dla modeli z dwiema i trzema warstwami ukrytymi, przedstawiono na rysunkach 4.11 – 4.14.


Najwyższą dokładnością wykazał się model z trzema warstwami ukrytymi o maksymalnych rozpatrywanych liczbach neuronów w poszczególnych warstwach (256 / 512 / 1024). Z uwagi na zaobserwowany spadek dokładności wspomnianego modelu na zbiorze walidacyjnym dla liczebności podzbioru danych treningowych (ang. batch size) wynoszącej 512 (rys. 4.13), przyjęto wielkość podzbioru danych treningowych równą 1024. Wykazano, że dodawanie kolejnych warstw ukrytych oraz zwiększanie liczby neuronów w poszczególnych warstwach skutkuje zwiększeniem dokładności modelu. Należy jednak pamiętać, że rozbudowa modelu wiąże się ze znacznym wzrostem liczby parametrów (wag) sieci, który prowadzi do znacznego wydłużenia czasu treningu oraz ewaluacji (rys. 4.15). Celem jest więc znalezienie optymalnej struktury modelu, która pozwoli na uzyskanie wystarczająco dokładnych wyników w jak najkrótszym czasie.




Rys. 4.9. Wartość metryki sukcesu (R^2) w funkcji liczby neuronów w warstwie ukrytej, dla poszczególnych wielkości podzbiorów danych treningowych – model z jedną warstwą ukrytą.




Rys. 4.10. Maksymalna wartość metryki sukcesu (R^2) w funkcji liczebności podzbioru danych treningowych – model z jedną warstwą ukrytą.




Rys. 4.11. Wartość metryki sukcesu (R^2) w funkcji liczby neuronów w pierwszej warstwie ukrytej, dla poszczególnych wielkości podzbiorów danych treningowych – model z dwiema warstwami ukrytymi.




Rys. 4.12. Maksymalna wartość metryki sukcesu (R^2) w funkcji liczebności podzbioru danych treningowych – model z dwiema warstwami ukrytymi.



Rys. 4.13. Wartość metryki sukcesu (R^2) w funkcji liczby neuronów w pierwszej warstwie ukrytej, dla poszczególnych wielkości podzbiorów danych treningowych – model z trzema warstwami ukrytymi.




Rys. 4.14. Maksymalna wartość metryki sukcesu (R^2) w funkcji liczebności podzbioru danych treningowych – model z trzema warstwami ukrytymi.



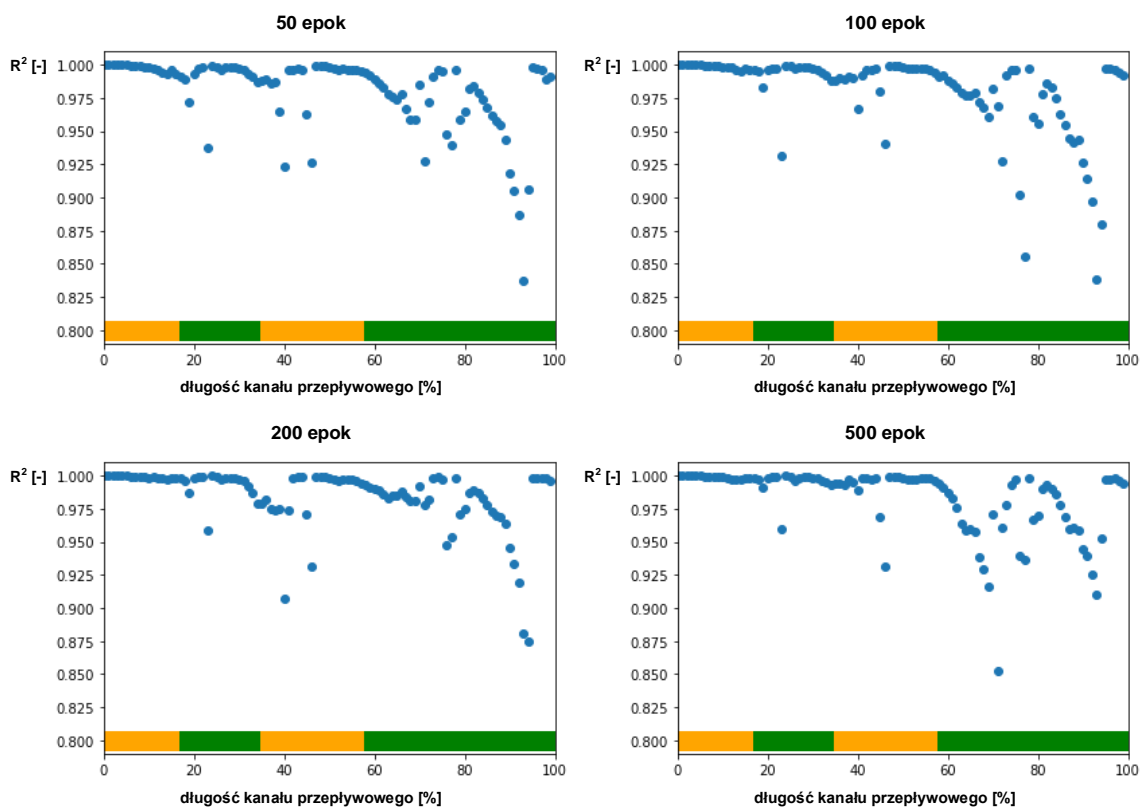
Rys. 4.15. Liczba parametrów (wag) w funkcji liczby neuronów w pierwszej warstwie ukrytej dla rozpatrywanych struktur modelu neuronowego.

Następnie zbadano wpływ liczby epok na dokładność modelu neuronowego o wybranej strukturze. Przeprowadzono trening dla 50, 100, 200 i 500 epok. Przebiegi poszczególnych krzywych uczenia – błędu średniokwadratowego (MSE) oraz współczynnika determinacji (R^2) dla zbioru treningowego i walidacyjnego, zilustrowano na rysunku 4.16. Wraz ze wzrostem liczby epok zwiększa się ogólna dokładność tworzonego modelu neuronowego.

Szczegółową analizę uzyskanych wyników przeprowadzono za pomocą testu wzdłuż osi turbiny (rys. 4.17), opisanego w poprzednim rozdziale. W celu ułatwienia interpretacji wyników, długość kanału przepływowego zajmowaną przez poszczególne wieńce łopatkowe oznaczono kolorami u dołu wykresów. Kolorem żółtym oznaczono wieńce kierownicze, a zielonym – wieńce wirnikowe.



Rys. 4.16. Krzywe uczenia wybranego neuronowego modelu przepływu na średnicy podziałowej – współczynnik determinacji (R^2) oraz błąd średniokwadratowy (MSE) – w zależności od liczby epok.



Rys. 4.17. Wynik testu wzdłuż osi turbiny – wartość współczynnika determinacji (R^2) osiągnięta przez neuronowy symulator przepływu na średnicy podziałowej dla poszczególnych liczb epok.


Uzyskane rozkłady dokładności tworzonego modelu neuronowego są zbliżone dla poszczególnych rozpatrywanych liczb epok. Największe spadki dokładności zaobserwowano w wieńcu wirnikowym ostatniego stopnia, a najmniejsze – w wieńcu kierowniczym stopnia przedostatniego. Szczegółowe wyniki testu wzdłuż osi turbiny zestawiono w tabeli 4.3.

Tabela 4.3. Zestawienie wyników testu wzdłuż turbiny dla wybranej struktury neuronowego modelu przepływu pary na średnicy podziałowej.

Liczba epok	50	100	200	500
R^2_{\min} [-]	0,8371	0,8387	0,8747	0,8528
R^2_{mean} [-]	0,9800	0,9801	0,9847	0,9829
R^2_{\max} [-]	0,9998	0,9999	0,9999	0,9999
Czas treningu	48 min 26 s	1h 37 min 13 s	3h 12 min 40 s	8 h 0 min 25 s
Czas testu	20,98 s	19,71 s	21,06 s	20,22 s


Najwyższą średnią wartością współczynnika determinacji R^2 wykazał się model trenowany przez 200 epok. Czas treningu poszczególnych modeli jest proporcjonalny do zadanej liczby epok. W przypadku 200 epok proces uczenia modelu trwał 3h 12 min 40 s. Czas ewaluacji modeli na zbiorze testowym wyniósł około 20 s.

Porównanie rzeczywistych rozkładów analizowanych parametrów ciepłno-przepływowych z rozkładami wygenerowanymi przez stworzony model neuronowy – dla wartości znormalizowanych – zilustrowano na rysunkach 4.18 – 4.24. Rysunek 4.18 przedstawia rozkład ciśnienia na średnicy podziałowej. Uzyskane rozkłady – rzeczywisty oraz prognozowany – są bardzo zbliżone. Największe różnice w otrzymanych wartościach ciśnienia zaobserwowano na krawędzi splotu łopatki wirnikowej ostatniego stopnia oraz w części wylotowej (rys. 4.19).




Rys. 4.18. Rzeczywisty oraz prognozowany rozkład ciśnienia na średnicy podziałowej analizowanego kanału przepływowego.


W przypadku rozkładu temperatury sytuacja jest analogiczna. Rozkład rzeczywisty i prognozowany są zbliżone (rys. 4.20), a największe różnice w wartościach temperatury występują na krawędzi splotu łopatki wirnikowej ostatniego stopnia (rys. 4.21).




Rys. 4.19. Rozkład błędu względnego dla prognozowanych wartości ciśnienia na średnicy podziałowej analizowanego kanału przepływowego, dla wartości błędu względnego nieprzekraczających 100%.



Rys. 4.20. Rzeczywisty oraz prognozowany rozkład temperatury na średnicy podziałowej analizowanego kanału przepływowego.




Rys. 4.21. Rozkład błędu względnego dla prognozowanych wartości temperatury na średnicy podziałowej analizowanego kanału przepływowego, dla wartości błędu względnego nieprzekraczających 100%.




Rys. 4.22. Rzeczywisty oraz prognozowany rozkład liczby Macha na średnicy podziałowej analizowanego kanału przepływowego.

Rzeczywisty rozkład liczby Macha i rozkład prognozowany również są do siebie zbliżone, (rys. 4.22). Największe różnice w wartościach liczby Macha są zlokalizowane na krawędziach poszczególnych łopatek oraz w obrębie płaszczyzn stanowiących połączenie sąsiadujących wieńców (rys. 4.23, 4.24).




Rys. 4.23. Rozkład błędów względnych dla prognozowanych wartości liczby Macha na średnicy podziałowej analizowanego kanału przepływowego, dla wartości błędów względnych nieprzekraczających 100%.



Rys. 4.24. Lokalizacja maksymalnych wartości błędów względnych (powyżej 100%) dla prognozowanych wartości liczby Macha na średnicy podziałowej analizowanego kanału przepływowego.

Na rysunku 4.25 przedstawiono histogramy błędów względnych rozpatrywanych parametrów cieplno-przepływowych (ciśnienia, temperatury i liczby Macha) dla wartości błędów nieprzekraczających 100%. Wartości wzorcowe stanowiły rozkłady poszczególnych parametrów wyznaczone na drodze obliczeń numerycznych, tworzące bazę danych referencyjnych. W przypadku ciśnienia i temperatury wartość błędów względnych w zdecydowanej większości punktów analizowanego kanału przepływowego jest bliska 0. Większe wartości błędów względnych, dochodzące do około 20%, wystąpiły dla rozkładu liczby Macha. Należy jednak pamiętać, że rozkład liczby Macha jest o wiele bardziej skomplikowany niż rozkład ciśnienia, czy temperatury, a w obszarach występowania fal uderzeniowych wartości tego parametru podlegają gwałtownym zmianom.



Rys. 4.25. Histogramy błędu względnego dla poszczególnych prognozowanych parametrów cieplno-przepływowych (ciśnienia, temperatury oraz liczby Macha) – wartości nieprzekraczające 100%.


4.4.2. Symulator przepływu pary w całej przestrzeni analizowanego kanału łopatkowego

Do stworzenia symulatora przestrzennego przepływu pary mokrej przez analizowany układ łopatkowy wykorzystano wybraną strukturę modelu przepływu na średnicy podziałowej. Liczebności poszczególnych zbiorów danych wyniosły odpowiednio:


- liczebność zbioru treningowego: 110 542 460;
- liczebność zbiorów walidacyjnego oraz testowego: 22 108 492.

Przeprowadzono trening modelu neuronowego w postaci perceptronu z trzema warstwami ukrytymi o liczbie neuronów odpowiednio: 256, 512 i 1024 dla 50 epok i liczebności podzbioru danych uczących (ang. batch size) wynoszącej 1024. Krzywe uczenia zilustrowana na rysunku 4.26. Trening symulatora przepływu przestrzennego trwał około 49 godzin, a predykcja na zbiorze testowym około 21 minut. Wartość współczynnika determinacji (R^2) osiągnięta przez model na zbiorze testowym wyniosła 0,98. Zbiór testowy zawierał wyniki obliczeń 7 symulacji numerycznych, stąd predykcja parametrów przepływu dla pojedynczego przypadku trwałaby około 3 minuty. Z punktu widzenia cieplno-przepływowej diagnostyki maszyn wirnikowych on-line jest to zdecydowanie zbyt długi czas predykcji modelu. Można go jednak łatwo skrócić, jeśli dysponuje się odpowiednio dużą mocą obliczeniową. Dłuższe czasy obliczeń są natomiast wystarczające dla potrzeb diagnostyki off-line, gdyż czas nie jest tu parametrem krytycznym, a sam proces diagnostyczny nie jest bezpośrednio związany z systemami bezpieczeństwa.

Na rysunku 4.27 przedstawiono wyniki testu wzdłuż osi turbiny. Kolorem żółtym oznaczono fragmenty kanału przepływowego zajmowane przez wieńce kierownicze, a zielonym przez wieńce wirnikowe. Podobnie, jak w przypadku modelu przepływu na średnicy podziałowej, największy spadek dokładności występuje na wylocie z analizowanego układu łopatkowego. Rozkład współczynnika determinacji (R^2) w pozostałych wieńcach jest jednak o wiele bardziej równomierny. Trening modelu dla pełnej objętości kanału przepływowego daje więc lepsze rezultaty, niż ograniczenie modelu do przestrzeni dwuwymiarowej.




Rys. 4.26. Krzywe uczenia neuronowego symulatora przepływu przestrzennego (od lewej): funkcja kosztu – błąd średniokwadratowy (ang. Mean Squared Error, MSE) oraz metryka sukcesu – współczynnik determinacji (R^2).



Rys. 4.27. Wynik testu wzdłuż osi turbiny – wartość współczynnika determinacji (R^2) osiągnięta przez neuronowy symulator przepływu przestrzennego na kolejnych podzbiórach zbioru testowego.

Histogramy błędów względnego rozpatrywanych parametrów cieplno-przepływowych (ciśnienia, temperatury oraz liczby Macha), dla wartości błędów nieprzekraczających 100%, zilustrowano na rys. 4.28. Poszczególne rozkłady błędów względnego – dla symulatorów przepływu 2D i 3D – są zbliżone.



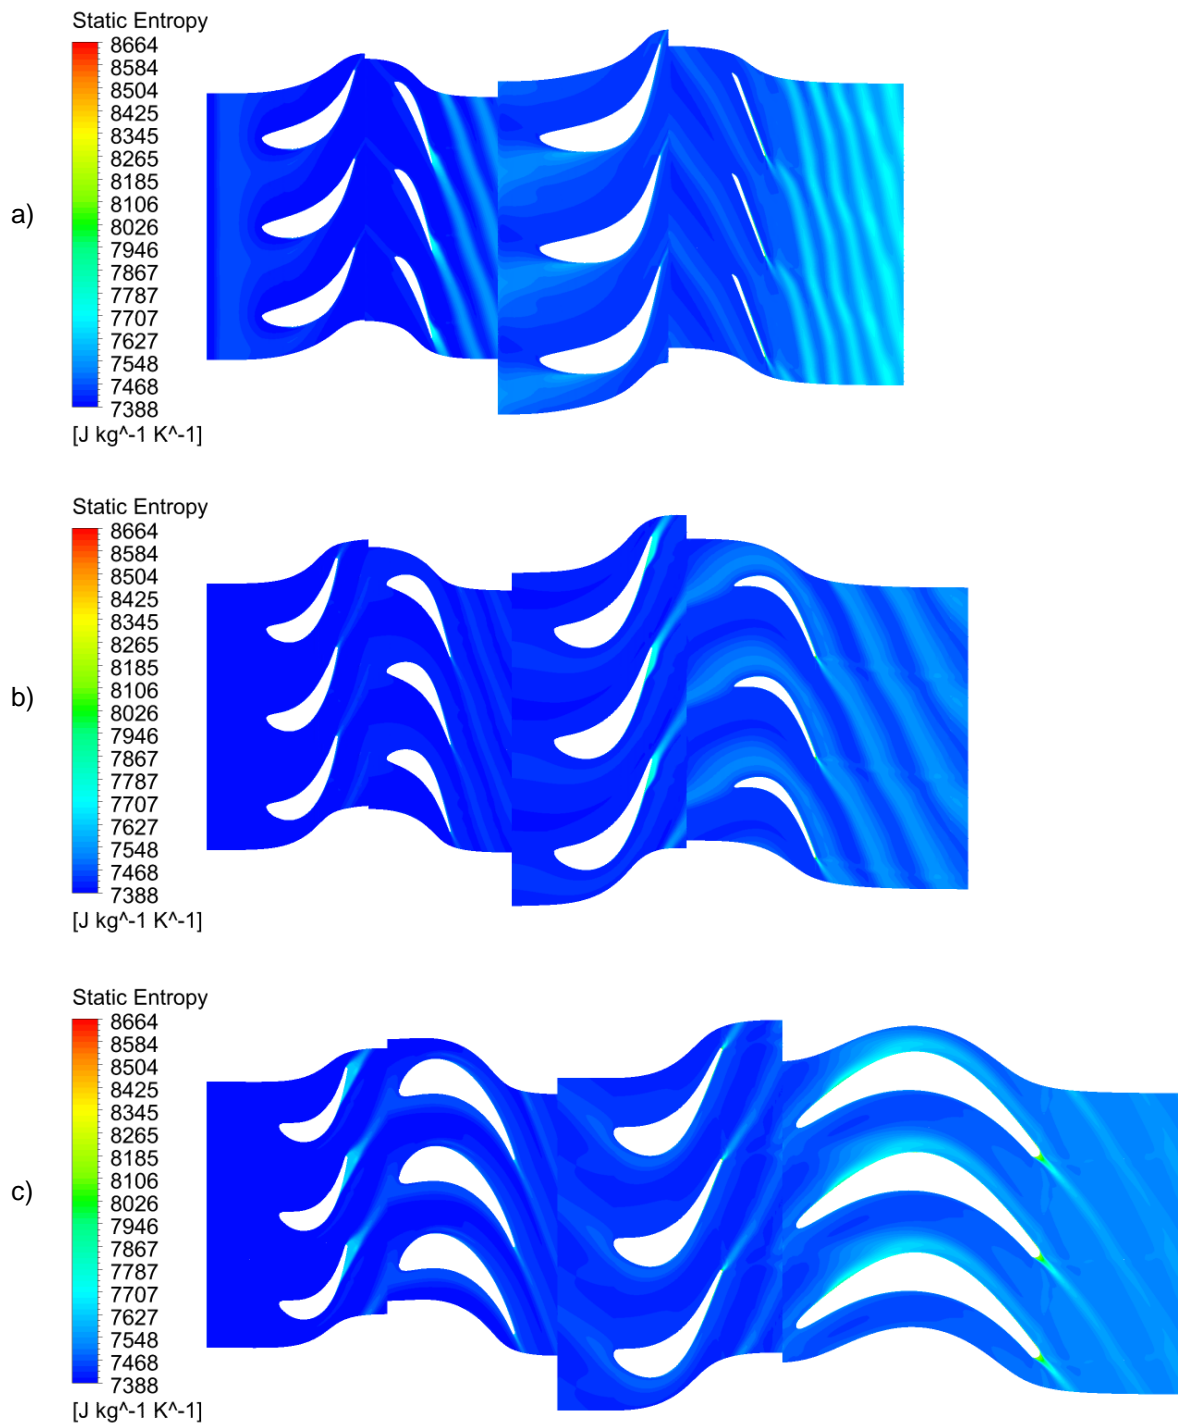
Rys. 4.28. Histogramy błędu względnego dla poszczególnych prognozowanych parametrów cieplno-przepływowych (ciśnienia, temperatury oraz liczby Macha) – wartości nieprzekraczające 100%.

4.4.3. Wpływ entropii statycznej na dokładność symulatora neuronowego

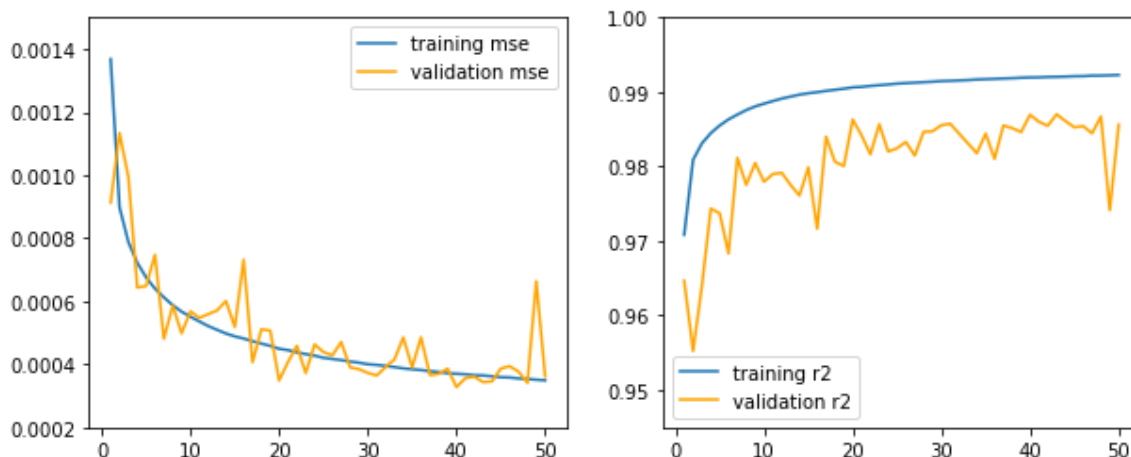
Ostatnim etapem analiz stworzonego neuronowego symulatora przestrzennego przepływu pary mokrej przez analizowany układ łopatkowy była ocena jego dokładności po rozszerzeniu zbioru rozpatrywanych parametrów cieplno-przepływowych – składającego się dotychczas z liczby Macha, ciśnienia i temperatury – o dodatkowy parametr w postaci entropii statycznej. Wymagało to modyfikacji bazy danych referencyjnych – uwzględnienia wartości entropii statycznej w poszczególnych punktach kanału przepływowego dla rozważanych warunków obciążenia bloku. Zmianie uległa również struktura modelu neuronowego. Dodano czwarty neuron w warstwie wyjściowej, zwiększając tym samym liczbę parametrów (wag) modelu neuronowego.

Na rys. 4.29 przedstawiono rozkłady entropii statycznej przy wierzchołkach łopatek, w połowie rozpiętości łopatek oraz u stóp łopatek. Obszary wzrostu entropii statycznej towarzyszą obszarom występowania nieciągłości przepływu. Uwidaczniają się na krawędziach splywu łopatek oraz na krawędzi ssącej u stopy łopatki wirnikowej ostatniego stopnia – w miejscach występowania zjawiska zwanego oderwaniem przepływu.

Trening neuronowego symulatora przepływu przestrzennego uwzględniającego entropię statyczną trwał około 7,5 doby. Krzywe uczenia zilustrowano na rys. 4.30. Wartość współczynnika determinacji (R^2) osiągnięta przez symulator na zbiorze testowym wyniosła 0,985.




Rys. 4.29. Rozkład entropii statycznej: a) przy wierzchołkach łopatek, b) w połowie rozpiętości łopatek, c) u stóp łopatek.



Rys. 4.30. Krzywe uczenia neuronowego symulatora przepływu przestrzennego uwzględniającego entropię statyczną (od lewej): funkcja kosztu – błąd średniokwadratowy (ang. Mean Squared Error, MSE) oraz metryka sukcesu – współczynnik determinacji (R^2).

Rys. 4.31 przedstawia wynik testu wzdłuż osi turbiny. Charakter rozkładu współczynnika determinacji jest podobny do wyników otrzymanych dla wcześniej zaprezentowanych modeli neuronowych. Dokładność modelu uwzględniającego entropię statyczną jest najniższa w ostatnim wieńcu analizowanego układu łopatkowego. Spadek dokładności jest jednak znacznie łagodniejszy, a sam rozkład bardziej równomierny. Rozszerzenie zbioru rozpatrywanych parametrów cieplno-przepływowych o kolejny parametr w postaci entropii statycznej wpływa zatem korzystnie na dokładność neuronowego modelu przepływu przestrzennego. Kosztem poprawy dokładności modelu jest wydłużenie czasu obliczeń, zwłaszcza podczas treningu modelu, związane ze wzrostem liczby wag modelu neuronowego (dodatkowy neuron w warstwie wyjściowej).



Rys. 4.31. Wynik testu wzdłuż osi turbiny – wartość współczynnika determinacji (R^2) osiągnięta przez neuronowy symulator przepływu przestrzennego uwzględniający entropię statyczną na kolejnych podziorach zbioru testowego.

5. ROLA METODY DLA DIAGNOSTYKI CIEPLNO-PRZEPLYWOWEJ


Pierwszym etapem cieplno-przepływowej diagnostyki maszyn wirnikowych jest detekcja niesprawności układu przepływowego. Jak już wcześniej wspomniano, poszukiwanie symptomów niesprawnej pracy polega na określaniu odchyłek mierzonych wartości parametrów od ich wartości referencyjnych (in. wzorcowych). Wartość różnicy większa od niepewności pomiarowej świadczy o wystąpieniu degradacji, [6].

Stworzony neuronowy symulator przepływu przestrzennego umożliwia wyznaczenie rozkładów rozpatrywanych parametrów (liczby Macha, ciśnienia, temperatury oraz entropii statycznej) w pełnym polu pracy analizowanej turbiny parowej. Można go zatem wykorzystać do określania stanów referencyjnych dla potrzeb pierwszego etapu diagnostyki cieplno-przepływowej. Spośród rozpatrywanych parametrów, z punktu widzenia procesu diagnostycznego, użyteczne są ciśnienie i temperatura. Uśrednione wartości tych parametrów w przestrzeniach międzystopniowych, określane na podstawie rozkładów wyznaczanych przez symulator, można porównywać z odpowiednio skorygowanymi wartościami ciśnienia i temperatury mierzonymi w komorach upustowych w trakcie eksploatacji turbiny.

Poniżej przedstawiono wyniki analizy użyteczności stworzonego symulatora do określania uśrednionych referencyjnych wartości ciśnienia i temperatury w przestrzeniach międzystopniowych. Rys. 5.1 ilustruje orientacyjny obszar kanału przepływowego uwzględniony w procesie analizy. Obszar ma kształt pierścienia o szerokości 2 cm i w przybliżeniu odpowiada przestrzeni pomiędzy analizowanymi stopniami turbinowymi, w której wprowadzano sondę podczas przeprowadzania rzeczywistych pomiarów opisanych w rozdziale 3 (tabela 3.5).

W tabeli 5.1 zestawiono uśrednione wartości ciśnienia i temperatury dla rozpatrywanych wartości ciśnienia wlotowego. Porównano uśrednione wartości poszczególnych parametrów wyznaczone na podstawie rozkładów uzyskanych na drodze symulacji numerycznych, traktowanych w tym przypadku jako wzorcowe, z wartościami wyznaczonymi na podstawie rozkładów prognozowanych przez stworzony symulator neuronowy. Dla każdej pary rzeczywistej i prognozowanej wartości danego parametru obliczono błąd względny.


Wyniki analizy wyznaczonych wartości uśrednionych zilustrowano również na rysunkach 5.2 oraz 5.3. W przypadku ciśnienia błąd względny wartości prognozowanej w stosunku do wartości rzeczywistej mieścił się w przedziale 0,7% ÷ 1,2%. Uśredniona wartość prognozowanej temperatury była obarczona znacznie niższym błędem, nieprzekraczającym 0,2 %. Zauważono także spadek wartości błędu względnego uśrednionej wartości temperatury wraz ze wzrostem wartości ciśnienia wlotowego. Zaprezentowane wyniki świadczą o możliwości wykorzystania prognozowanych rozkładów mierzalnych parametrów cieplno-przepływowych, określanych przez neuronowe symulatory przestrzennych przepływów pary mokrej w kanałach łopatkowych, do określania stanów referencyjnych w pierwszym etapie diagnostyki turbin parowych, jakim jest detekcja niesprawności układu przepływowego.




Rys. 5.1. Orientacyjny obszar analizowanego kanału przepływowego, dla którego przeprowadzono proces uśredniania (widok merydionalny).

Tabela 5.1. Zestawienie uśrednionych wartości ciśnienia i temperatury, wraz z wartościami błędów względnymi, dla poszczególnych wartości ciśnienia wlotowego.

P_{in} [Pa]	P_{real} [Pa]	P_{pred} [Pa]	δP [%]	T_{real} [K]	T_{pred} [K]	δT [%]
65645	28556	28763	0,72	343,60	344,30	0,20
72793	31759	32048	0,91	344,97	345,56	0,17
81594	35610	35905	0,83	347,28	347,69	0,12
88324	38581	38844	0,68	348,76	349,16	0,12
95556	41729	42093	0,87	350,47	350,90	0,12
97808	42583	43073	1,15	350,62	350,86	0,07
105836	46088	46456	0,80	352,51	352,80	0,08



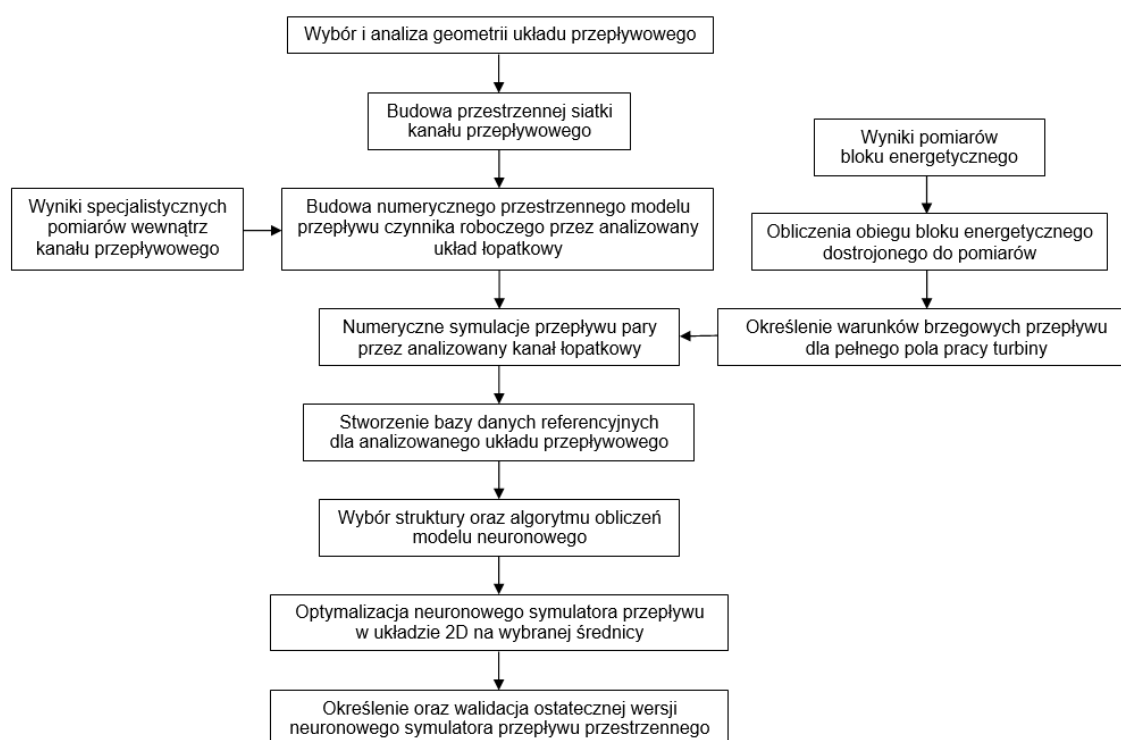
Rys. 5.2. Rzeczywiste oraz prognozowane wartości ciśnienia w przestrzeni międzystopniowej, dla poszczególnych wartości ciśnienia wlotowego.



Rys. 5.3. Rzeczywiste oraz prognozowane wartości ciśnienia w przestrzeni międzystopniowej, dla poszczególnych wartości ciśnienia wlotowego.

6. PODSUMOWANIE

Niniejsza rozprawa doktorska jest poświęcona opracowaniu metody modelowania przepływu pary mokrej w przydźwiękowych i naddźwiękowych kanałach łopatkowych turbin parowych. Celem przeprowadzonych analiz, procesów modelowania oraz obliczeń było stworzenie neuronowego symulatora okołodźwiękowego przepływu pary w wybranym reprezentatywnym układzie łopatkowym. Jak już wcześniej wspomniano, stworzona metoda ma charakter hierarchiczny. Przebieg prac wykonanych w ramach jej poszczególnych elementów i etapów, prowadzących do zbudowania neuronowego symulatora przestrzennego przepływu pary, zilustrowano na rys. 6.1 i opisano poniżej.



Rys. 6.1. Schemat hierarchii budowania neuronowego modelu obliczeniowego układu przepływowego.

1. Wybór i analiza geometrii rozpatrywanego układu przepływowego.

Występowanie przepływu naddźwiękowego jest zjawiskiem charakterystycznym dla ostatnich stopni turbin parowych dużej mocy, charakteryzujących się długimi łopatkami o skomplikowanej geometrii. Jako reprezentatywny turbinowy układ łopatkowy, spełniający te założenia, przyjęto dwa ostatnie stopnie części niskoprężnej turboszespołu 18K370 z wylotem ND-37. Wnioski płynące z przeprowadzonych badań obowiązują również dla innych układów, w których występuje przepływ naddźwiękowy.

2. Budowa numerycznego przestrzennego modelu przepływu pary mokrej przez analizowany układ łopatkowy.

Pierwszym etapem prac jest budowa numerycznego modelu przestrzennego przepływu pary mokrej przez analizowany układ łopatkowy, który zastępuje w proponowanej metodzie – obecnie jeszcze niedostępny – przestrzenny system pomiarowy, [22]. Trójwymiarowy model geometryczny kanału przepływowego utworzono w programie ANSYS Turbogrid 18.0. Następnie dokonano jego dyskretyzacji i utworzono 5 siatek numerycznych o różnym zagęszczeniu elementów (od około 400 tys. do prawie 6 mln). Analizę otrzymanych wariantów siatki numerycznej przeprowadzono pod kątem dokładności uzyskiwanych wartości mocy i sprawności modelowanego układu łopatkowego. Przeanalizowano również wartości bezwymiarowej odległości od ściany – tzw. parametru y^+ – dla poszczególnych wieńców łopatkowych. Uwzględniając wyniki przeprowadzonych analiz oraz dostępną moc obliczeniową, uznano siatkę o około 3 mln elementów za najbardziej optymalną.

Kolejnym krokiem jest zadanie warunków brzegowych w postaci ciśnienia całkowitego i temperatury całkowitej na wlocie do analizowanego układu łopatkowego oraz ciśnienia statycznego na wylocie. Poszczególne warunki brzegowe zadano w formie rozkładów wspomnianych parametrów, bazując na wynikach rzeczywistych pomiarów ciepłno-przepływowych przeprowadzonych przez spółkę Diagnostyka Maszyn w latach 1997 – 2005 na wybranych blokach dwóch polskich elektrowni, [44][48]. Następnie, w programie ANSYS CFX 18.0, przeprowadzono numeryczne symulacje przepływu pary mokrej przez modelowany kanał łopatkowy, a otrzymane wyniki porównano z rzeczywistymi pomiarami. Dzięki takiemu podejściu obliczenia numeryczne odnoszą się, przynajmniej w płaszczyznach pomiarowych, do rzeczywistych pomiarów przeprowadzonych na turbinach elektrownianych.

3. Stworzenie bazy danych referencyjnych.

Bazę danych referencyjnych stworzono przy wykorzystaniu numerycznego programu obliczeniowego DIAGAR. Model bloku parowego o mocy 370 MW (załącznik 1) dostrojono do 49 zestawów danych, stanowiących różne kombinacje wartości obciążenia turbiny i ciśnienia końcowego (tabela 4.1). Zmianę obciążenia w zakresie 57% ÷ 105% oraz ciśnienia końcowego w zakresie 4÷10 kPa określono na podstawie wartości występujących w sprawozdaniach pomiarowych, np. [43]. Uzyskane wartości ciśnień i temperatur na wlocie i wylocie z dwóch ostatnich stopni części niskoprężnej wprowadzono do numerycznego modelu analizowanego kanału przepływowego, określając tym samym wartości warunków brzegowych. Przeprowadzono 49 symulacji przepływu pary mokrej przez rozpatrywany układ łopatkowy. Otrzymane rozkłady ciśnienia, temperatury i liczby Macha stabilaryzowano, tworząc tym samym bazę danych referencyjnych o liczbie rekordów sięgającej niemal 150 milionów.

Następnym krokiem na drodze do stworzenia neuronowego symulatora przepływu pary przez analizowany układ łopatkowy jest wydzielenie spośród bazy danych referencyjnych zbioru treningowego, walidacyjnego oraz testowego. Podziału danych dokonano w sposób losowy, przypisując zbiorom: walidacyjnemu i testowemu dane z 7 losowo wybranych symulacji, po jednej

dla każdej rozpatrywanej wartości obciążenia analizowanego turbozespołu. Dane z pozostałych 35 symulacji utworzyły zbiór danych uczących. Potencjał informacji zawartych w bazie danych referencyjnych zbadano przy użyciu języka programowania Python 3.7 i biblioteki *scikit-learn*. Stworzono szereg symulatorów przepływu pary na średnicy podziałowej analizowanego układu łopatkowego, bazując na powszechnie stosowanych modelach uczenia maszynowego (ang. machine learning), tj.: *Decision Tree Regressor*, *Random Forest Regressor*, *Gradient Boosting Regressor*, czy *XGB Regressor*. Optymalizację poszczególnych modeli w zadanej przestrzeni hiperparametrów przeprowadzono przy użyciu narzędzia *hyoperopt*. Zastosowano walidację krzyżową. Z punktu widzenia dokładności oraz czasu ewaluacji, najlepszy okazał się model *XGB Regressor*, który osiągnął na zbiorze testowym wartość współczynnika determinacji (R^2) na poziomie 0,985 w czasie około 1,1 s.

4. Optymalizacja neuronowego symulatora przepływu na średnicy podziałowej.

Istotnym etapem jest stworzenie neuronowego symulatora przepływu pary na średnicy podziałowej analizowanego kanału łopatkowego. Przyjęto strukturę sieci neuronowej w postaci perceptronu wielowarstwowego, który – zgodnie z [35] – wykazuje dobre zdolności rekonstrukcji fal uderzeniowych. Strukturę modelu przeanalizowano pod kątem liczby warstw ukrytych (1, 2 lub 3), liczby neuronów w poszczególnych warstwach, wielkości podzbioru danych treningowych wykorzystywanego do uczenia modelu neuronowego w pojedynczym kroku (ang. batch size) oraz liczby epok. Przyjęto funkcję aktywacji warstw ukrytych w postaci funkcji ReLU (ang. Rectified Linear Unit) i zastosowano optymalizator Adam. Ostatecznie wybrano strukturę w postaci perceptronu wielowarstwowego z trzema warstwami ukrytymi o liczbie neuronów w poszczególnych warstwach odpowiednio 256 / 512 / 1024. Liczebność podzbioru danych uczących wynosiła 1024, a liczba epok 200. Stworzony symulator osiągnął średnią wartość współczynnika determinacji (R^2) na poziomie 0,9847 w czasie ok. 20 s. Najniższą dokładność dla wszystkich rozpatrywanych parametrów cieplno-przepływowych (ciśnienia, temperatury i liczby Macha) zaobserwowano na krawędzi spływu łopatki wirnikowej ostatniego stopnia oraz w części wylotowej. W przypadku liczby Macha spadek dokładności obejmował również krawędzie pozostałych łopatek oraz płaszczyzny stanowiące połączenie pomiędzy poszczególnymi wieńcami.

5. Stworzenie neuronowego symulatora przepływu przestrzennego.

Finalnym etapem jest stworzenie symulatora przestrzennego przepływu pary mokrej przez analizowany układ łopatkowy. W tym celu wykorzystano strukturę sieci neuronowej wybraną dla symulatora przepływu na średnicy podziałowej i przeprowadzono trening dla 50 epok. Stworzony symulator osiągnął na zbiorze testowym wartość współczynnika determinacji (R^2) na poziomie 0,98 w czasie około 21 minut. Rozszerzenie zbioru danych treningowych do przestrzeni trójwymiarowej poprawiło rozkład dokładności w kanale przepływowym, który stał się bardziej równomierny.

Zbadano również wpływ entropii statycznej na dokładność stworzonego symulatora. Efektem rozszerzenia zestawu wyznaczanych parametrów cieplno-przepływowych (liczby Macha, ciśnienia i temperatury) o kolejny parametr w postaci entropii statycznej była poprawa dokładności

symulatora, która uwidoczniła się zwłaszcza w najtrudniejszym – z punktu widzenia procesu modelowania – obszarze analizowanego kanału przepływowego, tj. na wylocie z ostatniego wieńca łopatkowego.

Celem przeprowadzonych analiz, procesów modelowania i obliczeń jest stworzenie neuronowego symulatora przestrzennego przepływu pary mokrej przez dwa ostatnie stopnie części niskoprężnej turbosespołu 18K370 z wylotem ND-37 przy wykorzystaniu przestrzennych obliczeń numerycznych dostrojonych do obecnie dostępnych wyników pomiarów – i cel ten został osiągnięty. Stworzony symulator umożliwia predykcję rozkładów rozpatrywanych parametrów cieplno-przepływowych (ciśnienia, temperatury, liczby Macha oraz entropii statycznej) w warunkach zmiennych obciążeń, a także identyfikację zjawisk zachodzących w analizowanym kanale przepływowym (w tym przede wszystkim zjawisko powstawania skośnej fali uderzeniowej).

Poprawę dokładności stworzonego symulatora neuronowego można uzyskać m. in. poprzez optymalizację:

- struktury sieci neuronowej (liczby warstw ukrytych i liczby neuronów w poszczególnych warstwach);
- podziału bazy danych referencyjnych pomiędzy poszczególne zbiory (treningowy, walidacyjny i testowy);
- wielkości podzbioru danych treningowych (ang. batch size);
- funkcji aktywacji warstw ukrytych;
- optymalizatora;
- funkcji kosztu i metryki sukcesu;
- liczby epok.

Zaproponowane zabiegi wiążą się jednak z ogromnymi nakładami mocy obliczeniowej, którymi nie dysponowano podczas prac nad niniejszą rozprawą doktorską.

Opracowana hierarchiczna metoda tworzenia neuronowych symulatorów przestrzennych przepływów pary ma charakter ogólny i może być stosowana również dla innych turbinowych układów łopatkowych. Poszczególne elementy metody oraz kolejność jej etapów powinny być zachowane dla każdego podobnego przypadku. Szczególne zadanie w budowie symulatora spełnia badanie właściwości SSN zarówno dla przepływu 2D, jak i 3D. Wstępne badanie w ramach modelowania przepływu na średnicy podziałowej analizowanego kanału łopatkowego ułatwia poszukiwanie optymalnej struktury neuronowego symulatora przepływu przestrzennego.

Symulator przygotowany według opracowanej metody może pełnić rolę narzędzia wyznaczającego parametry stanu referencyjnego dla potrzeb cieplno-przepływowej diagnostyki systemów przemysłowych, zwłaszcza bloków energetycznych. Parametry określone dla pełnego pola pracy turbiny, przy poprawnej niezdegradowanej geometrii kanału przepływowego, zostaną wówczas wykorzystane do poszukiwania symptomów niesprawnej pracy w pierwszym etapie diagnostyki – detekcji uszkodzenia lub degradacji.

Dalsze usprawnienia metody budowy neuronowych symulatorów przepływu mogłyby polegać np. na zastosowaniu walidacji krzyżowej, dzięki czemu wydzielenie osobnego zbioru danych walidacyjnych ze zbioru treningowego nie byłoby konieczne. Ciekawym rozwiązaniem byłoby również zastosowanie sieci konwolucyjnych do predykcji rozkładów parametrów cieplno-przepływowych w kanałach łopatkowych turbin parowych. Sieci konwolucyjne charakteryzują się dobrą zdolnością rozpoznawania lokalnych powiązań, które towarzyszą obszarom występowania skośnych fal uderzeniowych. Zastosowanie sieci konwolucyjnych wymaga jednak modyfikacji numerycznej siatki obliczeniowej kanału przepływowego. Stworzona siatka numeryczna musi być strukturalna, gdyż takiej właśnie wymagają modele oparte o sieci konwolucyjne. Wynika to z konieczności wprowadzania danych do modelu w postaci macierzy. Istnieje niebezpieczeństwo, że interpolacja rozkładów poszczególnych parametrów cieplno-przepływowych wiązałaby się z utratą części zawartych w nich informacji.

Należy również zwrócić uwagę na możliwości zastosowania powszechnie używanych modeli uczenia maszynowego (ang. machine learning), a w szczególności na model *XGB Regressor*, zaprezentowany w niniejszej pracy. Symulator przepływu pary mokrej na średnicy podziałowej analizowanego układu łopatkowego, stworzony na bazie modelu *XGB Regressor*, wykazał się dokładnością zbliżoną do dokładności symulatora neuronowego.

Podsumowując zakres prac przeprowadzonych w ramach niniejszej rozprawy doktorskiej, należy podkreślić zawarte w niej **oryginalne rezultaty**:

- **opracowana metoda neuronowego modelowania przepływów okołodźwiękowych** w różnych kanałach przepływowych, której użyteczność zobrazowano na przykładzie wybranego rzeczywistego kanału przepływowego turbiny parowej dużej mocy przy uwzględnieniu dostępnych pomiarów obiegu oraz wewnętrznych pomiarów turbiny;
- **trójwymiarowy numeryczny model przepływu pary mokrej przez dwa ostatnie stopnie części niskoprężnej turbosespołu 18K370 z wylotem ND-37**, stworzony w oparciu o wyniki rzeczywistych pomiarów przeprowadzonych przez spółkę Diagnostyka Maszyn, umożliwiający wyznaczanie przestrzennych pól parametrów cieplno-przepływowych w analizowanym kanale łopatkowym (ANSYS Turbogrid, CFX);
- **baza danych referencyjnych dla obiegu cieplnego turbosespołu 18K370** o liczbie rekordów sięgającej niemal 150 milionów, stworzona na podstawie trójwymiarowych rozkładów wybranych parametrów cieplno-przepływowych (ciśnienia, temperatury i liczby Macha), uwzględniająca zmianę obciążenia turbosespołu w zakresie 57% ÷ 105% mocy nominalnej oraz zmianę ciśnienia końcowego w zakresie 4÷10 kPa (DIAGAR, ANSYS CFX);
- symulatory przepływu pary mokrej na średnicy podziałowej rozpatrywanego turbinowego układu łopatkowego, bazujące na wybranych modelach uczenia maszynowego wraz ze skryptem umożliwiającym ich automatyczną optymalizację oraz dalszą rozbudowę (Python);

- **neuronowy symulator przepływu na średnicy podziałowej oraz neuronowy symulator przestrzennego przepływu pary mokrej przez dwa ostatnie stopnie części niskoprężnej turbosespołu 18K370 z wylotem ND-37** w postaci odpowiednio wytrenowanych perceptronów wielowarstwowych z trzema warstwami ukrytymi (Python);
- **przystosowanie działania neuronowego symulatora przepływów okołodźwiękowych w kanałach łopatkowych turbin parowych do pełnego pola pracy bloków energetycznych, a tym samym stworzenie możliwości zastosowania symulatora w diagnostyce ciepłno-przepływowej do detekcji niesprawności w układzie przepływowym turbiny.**

W nieco odleglejszej przyszłości można oczekiwać, że obserwowany rozwój narzędzi i metod pomiarowych doprowadzi do możliwości pozyskania wyników pomiarów zbliżonych do rozkładów parametrów ciepłno-przepływowych otrzymywanych na drodze przestrzennych obliczeń numerycznych układów przepływowych. Być może możliwości te będą ograniczone do układów modelowych, ale i tak będzie to znaczny postęp. Zaprezentowana metoda neuronowego modelowania przepływów okołodźwiękowych, po niezbędnych korektach, może być wtedy dostosowana do nowej sytuacji pomiarowej.

Neuronowe symulatory przepływu pary mokrej przez analizowany układ łopatkowy, stworzone w ramach niniejszej rozprawy, można zastosować dla geometrii innych kanałów łopatkowych turbin parowych. Dodatkowo otwiera się możliwość wykorzystania neuronowych symulatorów przepływu do badań nad poszukiwaniem degradacji geometrycznej elementów kanałów przepływowych. Wnioski płynące z wykonanych prac można wykorzystać również do tworzenia neuronowych symulatorów przepływu dla elementów instalacji przemysłu chemicznego, petrochemicznego, spożywczego i innych.

WYKAZ LITERATURY

- [1] J. Głuch, *Metoda diagnostyki ciepłno-przepływowej umożliwiająca rozpoznawanie miejsca i stopnia degradacji turbozespołów energetycznych*, Seria Monografie nr 81, Wydawnictwo Politechniki Gdańskiej, Gdańsk, 2007.
- [2] B. Żółtowski, Z. Ćwik, *Leksykon diagnostyki technicznej*, Wydawnictwo Uczelniane Akademii Techniczno-Rolniczej, Bydgoszcz, 1996.
- [3] B. Żółtowski, *Podstawy diagnostyki maszyn*, Wydawnictwo Uczelniane Akademii Techniczno-Rolniczej, Bydgoszcz, 1996.
- [4] A. Gardzilewicz, J. Głuch, M. Bogulicz, R. Walkowiak, M. Najwer, J. Kiebdój, *Experience in Application of Thermal Diagnostics in the Turow Power Station*, ASME Proceedings of the International Joint Power Generation Conference, Atlanta, pp. 371–378, 2003.
- [5] J. Krzyżanowski, J. Głuch, *Diagnostyka ciepłno-przepływowa obiektów energetycznych*, Wydawnictwo Instytutu Maszyn Przepływowych PAN, Gdańsk, 2004.
- [6] *O zastosowaniu neuronowych symulatorów przepływu przez kanały łopatkowe turbin do wyznaczania stanu referencyjnego w diagnostyce ciepłno-przepływowej*, praca zbiorowa pod red. J. Głucha, Wydawnictwo Politechniki Gdańskiej, Gdańsk, 2014.
- [7] *Ciepłno-przepływowe relacje diagnostyczne w ruchowych warunkach przemysłowych*, praca zbiorowa pod red. J. Głucha, Wydział Oceanotechniki i Okrętownictwa Politechniki Gdańskiej, Gdańsk, 2007.
- [8] A. Gardzilewicz, J. Głuch, M. Bogulicz, W. Uziębło, T. Jankowski, *Program diagnostyki ciepłno-przepływowej DIAGAR jako narzędzie prognozowania remontu aparatów składowych turbinowych obiegów energetycznych*, Materiały V Krajowej Konferencji Naukowo-Technicznej DIAGNOSTYKA PROCESÓW Przemysłowych DPP'2001, 17-19 wrzesień 2001, Łągów Lubuski, str. 459–462.
- [9] A. Gardzilewicz i inni, *System obliczeniowy obiegów cieplnych turbin*, Opracowania wewnętrzne IMP PAN, Gdańsk, 1985-1997.
- [10] A. Gardzilewicz, W. Uziębło, J. Głuch, M. Bogulicz, J. Topolski, *Modernizacja systemu obliczeniowego obiegów cieplnych turbin*, Opracowanie wewnętrzne IMP PAN Nr 267/98, Gdańsk, 1998.
- [11] J. Korbicz, J. M. Kościelny, Z. Kowalczyk, W. Cholewa, *Diagnostyka procesów. Modele, metody sztucznej inteligencji, zastosowania*, WNT, Warszawa, 2002.
- [12] J. Szumny, *Cyfrowy system automatyki ABB Procontrol P*, *Pomiary Automatyka Kontrola*, Nr 6/1998, str. 231-235.

- [13] J. M. Kościelny, D. Sędziak, K. Zakroczyński, *Badanie systemu DIAG w elektrociepłowni Siekierki*, Materiały II Krajowej Konferencji DIAGNOSTYKA PROCESÓW PRZEMYSŁOWYCH, 8-11 września 1997, Łagów, str. 105–110.
- [14] J. M. Kościelny, *System zaawansowanego monitorowania i diagnostyki AMandD*, Konferencja Diagnostyka Procesów Przemysłowych DPP'05, 12-14 września 2005, Rajgród, Pomiar Automatyka Kontrola Wydział Specjalny, Nr 9(2005), str. 157–159.
- [15] W. Cholewa, J. Kiciński, *DT-200-1. System diagnostyczny dla turbozespołów energetycznych o mocy 200 MW*, Wydawnictwo IMP, Gdańsk, 1998.
- [16] L. Byczkowska-Lipińska, A. Wosiak, *Projekt inteligentnego systemu diagnostyki wibroakustycznej*, Materiały V Konferencji Diagnostyka Procesów Przemysłowych DPP'2003, 15-17 września 2003, Władysławowo, str. 515–518.
- [17] C. Basztura, *Komputerowe systemy diagnostyki akustycznej*, PWN, Warszawa, 1996.
- [18] A. Rusanov, R. Rusanov, P. Lampart, *Designing and updating the flow part of axial and radial-axial turbines through mathematical modeling*, Open Engineering, vol. 5, no. 1, pp. 399–410, 2015, doi: 10.1515/eng-2015-0047.
- [19] P. Lampart, S. Yershov, A. Rusanov, *Increasing flow efficiency of high-pressure and low-pressure steam turbine stages from numerical optimization of 3D blading*, Engineering Optimization, vol. 37, no. 2, pp. 145–166, 2005, doi: 10.1080/03052150512331315497.
- [20] P. Lampart, S. Yershov, *3D shape optimisation of turbomachinery blading*, Task Quarterly, vol. 1, no. 1, pp. 113–125, 2002.
- [21] P. Lampart, *Badania aerodynamiki układów łopatkowych turbin z wykorzystaniem metod obliczeniowych mechaniki płynów*, IMP PAN, Gdańsk, 2006.
- [22] A. Gardzilewicz, J. Świryczuk, B. Kurant, *Stage flow losses in steam turbine design*, Systems Journal of Transdisciplinary Systems Science, vol. 1, no. 11, pp. 161–172, 2006.
- [23] A. Butterweck, J. Głuch, *Accuracy Investigations of Turbine Blading Neural Models Applied to Thermal and Flow Diagnostics*, Advanced and Intelligent Computations in Diagnosis and Control, Springer International Publishing, 2016, pp. 267–274.
- [24] A. Butterweck, J. Głuch, *Neural network simulator's application to reference performance determination of turbine blading in the heat-flow diagnostics*, Intelligent Systems in Technical and Medical Diagnostics, Springer Berlin Heidelberg, 2013, pp. 137–147.
- [25] J. Korbicz, A. Obuchowicz, D. Uciński, *Sztuczne sieci neuronowe: podstawy i zastosowania*, Akademicka Oficyna Wydawnicza PLJ, Warszawa, 1994.
- [26] R. Tadeusiewicz, *Sieci neuronowe*, 2 ed., Akademicka Oficyna Wydawnicza RM, Warszawa, 1993.


- [27] T. Masters, *Sieci neuronowe w praktyce: programowanie w języku C++*, Wydawnictwo Naukowo-Techniczne, Warszawa, 1996.
- [28] V. Alekseichenko, *Materiały szkoleniowe do kursu Practical Machine Learning (Deep Learning)*, Data Workshop, 2020.
- [29] K. Kosowski, K. Tucki, A. Kosowski, *Turbine stage design aided by artificial intelligence methods*, Expert Systems with Applications, vol. 36, no. 9(2009), pp. 11536–11542, doi: 10.1016/j.eswa.2009.03.053.
- [30] K. Kosowski, K. Tucki, A. Kosowski, *Application of Artificial Neural Networks in Investigations of Steam Turbine Cascades*, Journal of Turbomachinery, vol. 132(2010), no. 1, pp. 1–5, doi: 10.1115/1.3103923.
- [31] A. Butterweck, *Obtaining fluid flow pattern for turbine stage with neural model*, Journal of Polish CIMEEAC, vol. 14(2019), no. 1/5, pp. 45–50.
- [32] A. Grzymkowska, N. Szewczuk, *Modelowanie przepływu pary przez okołodźwiękowe wieńce turbinowe z użyciem sztucznych sieci neuronowych*, Mechanik, Nr 7(2016), str. 698–699, doi: 10.17814/mechanik.2016.7.132.
- [33] J. Głuch, *O zastosowaniu sieci neuronalnych do obliczeń cieplno-przepływowych*, Zeszyty Naukowe. Ciepłne Maszyny Przepływowe. Turbomachinery, Łódź, vol. 1(2000), Nr 117, str. 35–40.
- [34] S. Bhatnagar, Y. Afshar, S. Pan, K. Duraisamy, S. Kaushik, *Prediction of aerodynamic flow fields using convolutional neural networks*, Computational Mechanics, vol. 64(2019), no. 2, pp. 525–545, doi: 10.1007/s00466-019-01740-0.
- [35] J. Yu, J. S. Hesthaven, *Flowfield reconstruction method using artificial neural network*, AIAA Journal, vol. 57(2019), no. 2, pp. 482–498, doi: 10.2514/1.J057108.
- [36] S. Dykas, *Numerical Calculation of the Steam Condensing Flow*, TASK Quarterly, vol. 5(2001), no. 4, pp. 519–535.
- [37] M. Majkut, S. Dykas, M. Strozik, K. Smółka, *Experimental and numerical study on condensation in transonic steam flow*, Open Engineering, vol. 5(2015), no. 1, pp. 293–298, doi: 10.1515/eng-2015-0035.
- [38] S. Dykas, W. Wróblewski, *Two-fluid model for prediction of wet steam transonic flow*, International Journal of Heat and Mass Transfer, vol. 60(2013), no. 1, pp. 88–94, doi: 10.1016/j.ijheatmasstransfer.2012.12.024.
- [39] W. Wróblewski, S. Dykas, A. Gepert, *Steam condensing flow modeling in turbine channels*, International Journal of Multiphase Flow, vol. 35(2009), no. 6, pp. 498–506, doi: 10.1016/j.ijmultiphaseflow.2009.02.020.

- [40] M. Szymaniak, J. Świryczuk, J. Głuch, *Analiza profili kierowniczych wieńców turbinowych ze skośną falą uderzeniową w aspekcie zastosowania w obliczeniach sieci neuronowych*, Oprac. nr 26/12/PB, Wydział Oceanotechniki i Okrętownictwa Politechniki Gdańskiej, 2012.
- [41] A. Grzymkowska, *Detekcja fal uderzeniowych w układach łopatkowych części niskoprężnych turbin parowych*, Mechanik, Nr 7(2015), str. 245–252, doi: 10.17814/mechanik.2015.7.236.
- [42] W. Wróblewski, S. Dykas, A. Gardzilewicz, M. Kolovratnik, *Numerical and Experimental Investigations of Steam Condensation in LP Part of a Large Power Turbine*, Journal of Fluids Engineering, vol. 131(2009), no. 4, doi: 10.1115/1.3089544.
- [43] G. ENERGOPOMIAR, *Sprawozdanie z pomiarów gwarancyjnych i eksploatacyjnych bloku nr 2 w Elektrowni Opole*, Opracowanie nr 202/ZC/2003, Gliwice, 2003.
- [44] J. Świryczuk, A. Gardzilewicz, R. Kwidziński, *Obliczenia cieplno-przepływowe części NP turbiny 18K370, Blok nr 4 w Elektrowni Opole*, Opracowanie nr 18/05, Diagnostyka Maszyn Sp. z o. o., Gdańsk, 2005.
- [45] P. Lampart, J. Świryczuk, A. Gardzilewicz, S. Yershov, A. Rusanov, *FLOWER Instrukcja obsługi pakietu*, Opracowanie nr 19/2000, Diagnostyka Maszyn Sp. z o. o., Gdańsk, 2000.
- [46] K. Kosowski et al., *Steam and Gas Turbines. Power Plants*, Alstom, France-Switzerland-United Kingdom-Poland, 2007.
- [47] A. Gardzilewicz, O. Uziębło, S. Marcinkowski, *Przygotowanie eksperymentalnych danych termodynamiczno-przepływowych dla obliczeń fluttera ostatniego stopnia turbiny 18K-370 z wylotem ND-37*, Opracowanie nr 20/2013, Diagnostyka Maszyn Sp. z o. o., Gdańsk, 2013.
- [48] A. Gardzilewicz, *Evaluating the efficiency of low pressure part of steam turbines based on probing measurements*, Transactions of the Institute of Fluid-Flow Machinery, vol. 135 (2017), pp. 41–56.
- [49] A. Gardzilewicz, M. Kolovratnik, W. Wróblewski, S. Marcinkowski, V. Petr, S. Dykas, *Experimental and theoretical investigation of steam condensation in LP part of a large power turbine*, Proceedings of the 7th European Conference on Turbomachinery: Fluid Dynamics and Thermodynamics, Athens, 2007.
- [50] Oficjalna strona IAPWS: <http://www.iapws.org/relguide/IF97-Rev.html>.
- [51] W. Wagner et al., *The IAPWS Industrial Formulation 1997 for the Thermodynamic Properties of Water and Steam*, Journal of Engineering for Gas Turbines and Power-transactions of The Asme, vol. 122(2000), no. 1, pp. 150–184, doi: 10.1115/1.483186.
- [52] F. R. Menter, M. Kuntz, R. Langtry, *Ten Years of Industrial Experience with the SST Turbulence Model Turbulence heat and mass transfer*, Turbulence, Heat and Mass Transfer 4, vol. 4(2003), pp. 625–632.
- [53] F. R. Menter, *Two-equation eddy-viscosity turbulence models for engineering applications*, AIAA Journal, vol. 32(1994), no. 8, pp. 1598–1605, doi: 10.2514/3.12149.

- [54] A. Grzymkowska, J. Głuch, A. Gardzilewicz, *Numeryczny model obliczeniowy obiegu turbiny klasy 300 MW*, *Mechanik*, Nr 7(2015), pp. 253–260, doi: 10.17814/mechanik.2015.7.237. 72
- [55] MinMaxScaler: <https://towardsdatascience.com/everything-you-need-to-know-about-min-max-normalization-in-python-b79592732b79>.
- [56] Overfitting: <https://www.ibm.com/cloud/learn/overfitting>.
- [57] Cross validation - documentation: https://scikit-learn.org/stable/modules/cross_validation.html.
- [58] Hyperopt - documentation: <http://hyperopt.github.io/hyperopt/>.
- [59] Bayesian hyperparameter optimization: <https://towardsdatascience.com/a-conceptual-explanation-of-bayesian-model-based-hyperparameter-optimization-for-machine-learning-b8172278050f>.
- [60] R2 score - documentation: https://scikit-learn.org/stable/modules/model_evaluation.html#r2-score.
- [61] Decision tree: <https://towardsdatascience.com/decision-trees-explained-3ec41632ceb6>.
- [62] RandomForestRegressor - documentation: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestRegressor.html>.
- [63] Random forest: <https://towardsdatascience.com/random-forest-explained-7eae084f3ebe>.
- [64] GradientBoostingRegressor - documentation: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.GradientBoostingRegressor.html>.
- [65] Gradient boosting: <https://machinelearningmastery.com/gentle-introduction-gradient-boosting-algorithm-machine-learning/>.
- [66] XGBRegressor - documentation: https://xgboost.readthedocs.io/en/latest/python/python_api.html.
- [67] XGBoost: <https://machinelearningmastery.com/gentle-introduction-xgboost-applied-machine-learning/>.
- [68] Regularization L1 i L2: <https://towardsdatascience.com/l1-and-l2-regularization-methods-ce25e7fc831c>.
- [69] SVR: <https://towardsdatascience.com/unlocking-the-true-power-of-support-vector-regression-847fd123a4a0>.
- [70] ReLU activation function: <https://machinelearningmastery.com/rectified-linear-activation-function-for-deep-learning-neural-networks/>.
- [71] Optimizer Adam: <https://machinelearningmastery.com/adam-optimization-algorithm-for-deep-learning/>.

ZAŁĄCZNIKI

Załącznik 1. Schemat numerycznego modelu obliczeniowego bloku parowego o mocy 370 MW.



Załącznik 2. Fragment kodu przedstawiający przestrzeń hiperparametrów określoną dla każdego z rozważanych modeli uczeni maszynowego.

```
models = {}

models['names'] = [
    # 'DecisionTreeRegressor',
    'GradientBoostingRegressor',
    # 'KNeighborsRegressor',
    # 'RadiusNeighborsRegressor',
    # 'RandomForestRegressor',
    # 'SVR',
    # 'XGBRegressor',
]

models['raw'] = [
    # DecisionTreeRegressor,
    GradientBoostingRegressor,
    # KNeighborsRegressor,
    # RadiusNeighborsRegressor,
    # RandomForestRegressor,
    # SVR,
    # XGBRegressor,
]

models['params'] = [
    # {
    #     'max_depth':      hp.choice('max_depth',      np.arange(5, 16, 1, dtype=int)),
    #     'random_state':  random_state,
    # },

    {
        'loss':          hp.choice('loss',          ['ls', 'huber']),
        'learning_rate': hp.choice('learning_rate', np.arange(0.05, 0.31, 0.05)),
        'max_depth':    hp.choice('max_depth',    np.arange(5, 16, 1, dtype=int)),
        'subsample':    hp.quniform('subsample',    0.5, 1, 0.05),
        'n_estimators': hp.choice('n_estimators',  np.arange(50, 100, 10)),
        'random_state': random_state,
    },

    # {
    #     'algorithm':      hp.choice('algorithm',      ['ball_tree', 'kd_tree']),
    #     'n_jobs': -1,
    # },

    # {
    #     'algorithm':      hp.choice('algorithm',      ['ball_tree', 'kd_tree']),
    #     'n_jobs': -1,
    # },
]
```

```

# {
#   'max_depth':      hp.choice('max_depth',      np.arange(5, 16, 1, dtype=int)),
#   'n_estimators':  hp.choice('n_estimators',  np.arange(50, 100, 10)),
#   'random_state':  random_state,
#   'n_jobs': -1,
# },

# {
#   'kernel':        hp.choice('kernel',        ['poly', 'rbf', 'sigmoid']),
#   'degree':        hp.choice('degree',        [3, 4, 5]),
#   'C':             hp.quniform('C',           0.5, 1, 0.05),
# },

# {
#   'learning_rate': hp.choice('learning_rate', np.arange(0.05, 0.31, 0.05)),
#   'max_depth':     hp.choice('max_depth',     np.arange(5, 16, 1, dtype=int)),
#   'subsample':     hp.quniform('subsample',   0.5, 1, 0.05),
#   'colsample_bytree': hp.quniform('colsample_bytree', 0.5, 1, 0.05),
#   'n_estimators':  hp.choice('n_estimators',  np.arange(50, 100, 10)),
#   'random_state':  random_state,
#   'objective':     'reg:squarederror',
#   'seed': seed,
#   'n_jobs': -1,
# },

]

```

Załącznik 3. Fragment kodu przedstawiający strukturę oraz algorytm obliczeń modelu neuronowego.

```
def get_mlp():

    def r2(y_true, y_pred):
        SS_res = tf.reduce_sum(tf.square(tf.subtract(y_true, y_pred)))
        SS_tot = tf.reduce_sum(tf.square(tf.subtract(y_true, tf.reduce_mean(y_true))))
        return tf.subtract(1., tf.divide(SS_res,SS_tot))

    mlp = Sequential([
        Dense(n, input_dim=X_train.shape[1], activation='relu'),
        Dense(2*n, activation='relu'),
        Dense(4*n, activation='relu'),
        Dense(3)
    ])

    mlp.compile(loss='mse', optimizer='adam', metrics=['mae', r2])


    return mlp
```

Załącznik 4. Krzywe uczenia rozpatrywanych konfiguracji neuronowego modelu przepływu pary na średnicy podziałowej analizowanego układu łopatkowego.

Wartość funkcji kosztu (MSE) oraz metryki sukcesu (R2) w funkcji liczby epok, dla poszczególnych liczb neuronów w warstwie ukrytej.

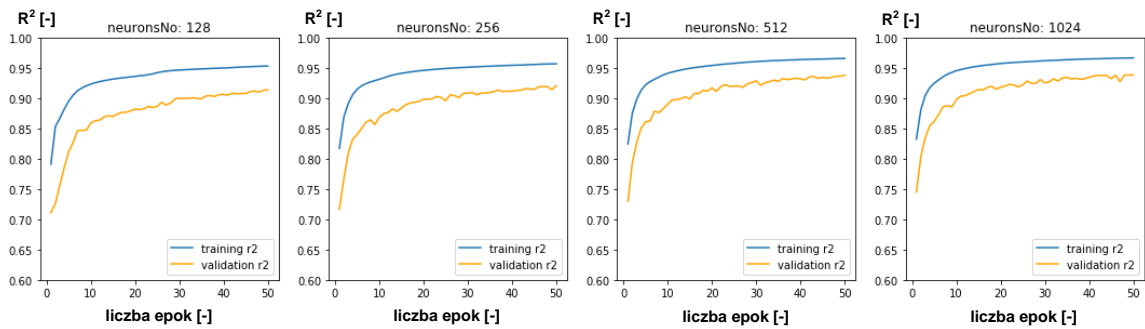



Liczba warstw ukrytych: 1

Batch size: 512




Liczba warstw ukrytych: 1

Batch size: 1024







Liczba warstw ukrytych: 1

Batch size: 2048







Liczba warstw ukrytych: 1

Batch size: 4096






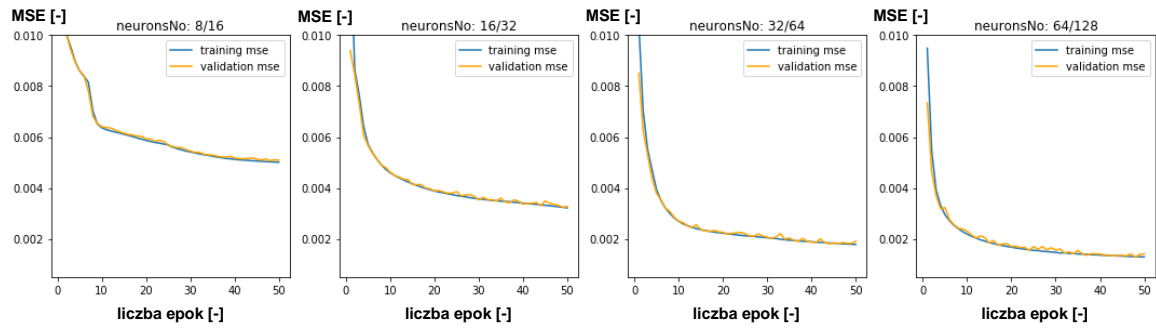
Liczba warstw ukrytych: 2

Batch size: 512




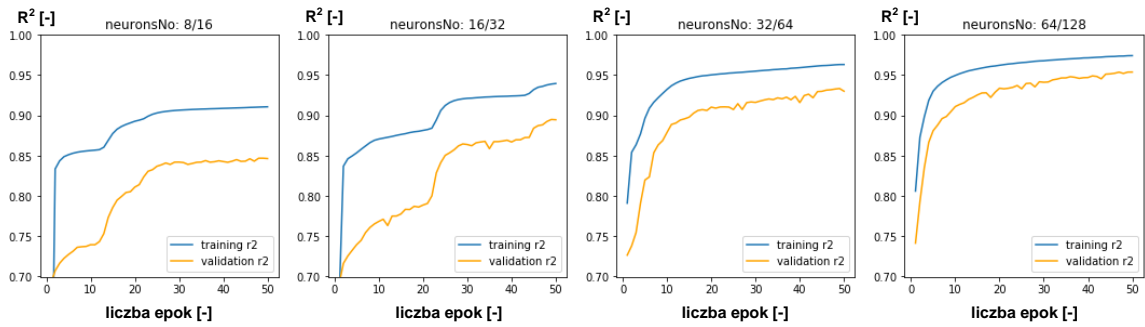


Liczba warstw ukrytych: 2

Batch size: 1024




Liczba warstw ukrytych: 2

Batch size: 2048







Liczba warstw ukrytych: 2

Batch size: 4096















Liczba warstw ukrytych: 3

Batch size: 512







Liczba warstw ukrytych: 3

Batch size: 1024







Liczba warstw ukrytych: 3

Batch size: 2048



Liczba warstw ukrytych: 3

Batch size: 4096



SPIS RYSUNKÓW

Rys. 3.1. Widok przekroju kadłuba NP turbiny parowej 18K370, [46].	11
Rys. 3.2. Schemat struktury obiegu cieplnego turbiny parowej 18K370, [43].....	12
Rys. 3.3. Widok przekrojów poszczególnych profili łopatkowych, na podstawie których odtworzono kształt łopatek analizowanego kanału przepływowego.	13
Rys. 3.4. Widok geometrii kanału przepływowego analizowanego układu łopatkowego.	13
Rys. 3.5. Widok z góry na geometrię kanału przepływowego analizowanego układu łopatkowego.	13
Rys. 3.6. Wykres mocy analizowanego układu łopatkowego w funkcji liczby elementów siatki numerycznej.	15
Rys. 3.7. Wykres sprawności analizowanego układu łopatkowego w funkcji liczby elementów siatki numerycznej.....	16
Rys. 3.8. Błąd względny sprawności analizowanego układu łopatkowego w funkcji liczby elementów siatki numerycznej.	16
Rys. 3.9. Błąd względny mocy analizowanego układu łopatkowego w funkcji liczby elementów siatki numerycznej.	17
Rys. 3.10. Wartości średnie oraz wartości maksymalne parametru $y+$ dla poszczególnych wieńców tworzących analizowany układ łopatkowy.	18
Rys. 3.11. Widok końcówki sondy zamontowanej w przestrzeni pomiarowej za ostatnim stopniem analizowanej turbiny, [47].	19
Rys. 3.12. Widok końcówki sondy pomiarowej, [47].	19
Rys. 3.13. Profil ciśnienia całkowitego zadany na wlocie do analizowanego kanału przepływowego.	22
Rys. 3.14. Profil temperatury całkowitej zadany na wlocie do analizowanego kanału przepływowego.	23
Rys. 3.15. Profil ciśnienia statycznego zadany na wylocie z analizowanego kanału przepływowego.	23
Rys. 3.16. Rozkład ciśnienia na wlocie do ostatniego stopnia.	24
Rys. 3.17. Rozkład temperatury na wlocie do ostatniego stopnia.....	25
Rys. 3.18. Rozkład liczby Macha: a) przy wierzchołkach łopatek, b) w 75% rozpiętości łopatek, c) w połowie rozpiętości łopatek, d) w 25% rozpiętości łopatek, e) u stóp łopatek.	27
Rys. 3.19. Rozkład ciśnienia: a) przy wierzchołkach łopatek, b) w połowie rozpiętości łopatek, c) u stóp łopatek.	28
Rys. 3.20. Rozkład temperatury całkowitej: a) przy wierzchołkach łopatek, b) w połowie rozpiętości łopatek, c) u stóp łopatek.	29
Rys. 3.21. Widok obszaru zajmowanego przez przepływ naddźwiękowy w poszczególnych wieńcach analizowanych stopni turbinowych.	30
Rys. 4.1. Widok fragmentu modelu numerycznego analizowanego obiegu cieplnego turbiny 370 MW, utworzonego w programie DIAGAR (cały schemat numeryczny obiegu znajduje się w załączniku 1).	32

Rys. 4.2. Histogramy ilustrujące rozkłady rozważanych parametrów ciepło-przepływowych: liczby Macha, ciśnienia oraz temperatury.	34
Rys. 4.3. Koncepcja walidacji krzyżowanej z podziałem zbioru danych treningowych na k podzbiorów (ang. k-fold cross validation), [57].	35
Rys. 4.4. Wartości ciśnienia wlotowego dla poszczególnych symulacji numerycznych	36
Rys. 4.5. Czas treningu (fit_time), czas testu (score_time) oraz wynik testu (test_score) dla rozpatrywanych modeli uczenia maszynowego.	39
Rys. 4.6. Wynik testu wzdłuż osi turbiny – wartość współczynnika determinacji (R_2) osiągnięta przez model XGBRegressor na kolejnych podziorach zbioru testowego.....	40
Rys. 4.7. Schemat struktury tworzonego modelu neuronowego.	41
Rys. 4.8. Funkcja aktywacji ReLU (ang. Rectified Linear Unit).....	42
Rys. 4.9. Wartość metryki sukcesu (R_2) w funkcji liczby neuronów w warstwie ukrytej, dla poszczególnych wielkości podzbiorów danych treningowych – model z jedną warstwą ukrytą.	44
Rys. 4.10. Maksymalna wartość metryki sukcesu (R_2) w funkcji liczebności podzbioru danych treningowych – model z jedną warstwą ukrytą.	44
Rys. 4.11. Wartość metryki sukcesu (R_2) w funkcji liczby neuronów w pierwszej warstwie ukrytej, dla poszczególnych wielkości podzbiorów danych treningowych – model z dwiema warstwami ukrytymi.	45
Rys. 4.12. Maksymalna wartość metryki sukcesu (R_2) w funkcji liczebności podzbioru danych treningowych – model z dwiema warstwami ukrytymi.	45
Rys. 4.13. Wartość metryki sukcesu (R_2) w funkcji liczby neuronów w pierwszej warstwie ukrytej, dla poszczególnych wielkości podzbiorów danych treningowych – model z trzema warstwami ukrytymi.	46
Rys. 4.14. Maksymalna wartość metryki sukcesu (R_2) w funkcji liczebności podzbioru danych treningowych – model z trzema warstwami ukrytymi.	46
Rys. 4.15. Liczba parametrów (wag) w funkcji liczby neuronów w pierwszej warstwie ukrytej dla rozpatrywanych struktur modelu neuronowego.	47
Rys. 4.16. Krzywe uczenia wybranego neuronowego modelu przepływu na średnicy podziałowej – współczynnik determinacji (R_2) oraz błąd średniokwadratowy (MSE) – w zależności od liczby epok.	48
Rys. 4.17. Wynik testu wzdłuż osi turbiny – wartość współczynnika determinacji (R_2) osiągnięta przez neuronowy symulator przepływu na średnicy podziałowej dla poszczególnych liczb epok.	49
Rys. 4.18. Rzeczywisty oraz prognozowany rozkład ciśnienia na średnicy podziałowej analizowanego kanału przepływowego.	50
Rys. 4.19. Rozkład błędu względnego dla prognozowanych wartości ciśnienia na średnicy podziałowej analizowanego kanału przepływowego, dla wartości błędu względnego nieprzekraczających 100%.	51
Rys. 4.20. Rzeczywisty oraz prognozowany rozkład temperatury na średnicy podziałowej analizowanego kanału przepływowego.	51

Rys. 4.21. Rozkład błędu względnego dla prognozowanych wartości temperatury na średnicy podziałowej analizowanego kanału przepływowego, dla wartości błędu względnego nieprzekraczających 100%.	52
Rys. 4.22. Rzeczywisty oraz prognozowany rozkład liczby Macha na średnicy podziałowej analizowanego kanału przepływowego.	52
Rys. 4.23. Rozkład błędu względnego dla prognozowanych wartości liczby Macha na średnicy podziałowej analizowanego kanału przepływowego, dla wartości błędu względnego nieprzekraczających 100%.	53
Rys. 4.24. Lokalizacja maksymalnych wartości błędu względnego (powyżej 100%) dla prognozowanych wartości liczby Macha na średnicy podziałowej analizowanego kanału przepływowego.	53
Rys. 4.25. Histogramy błędu względnego dla poszczególnych prognozowanych parametrów cieplno-przepływowych (ciśnienia, temperatury oraz liczby Macha) – wartości nieprzekraczające 100%.	54
Rys. 4.26. Krzywe uczenia neuronowego symulatora przepływu przestrzennego (od lewej): funkcja kosztu – błąd średniokwadratowy (ang. Mean Squared Error, MSE) oraz metryka sukcesu – współczynnik determinacji (R_2).	55
Rys. 4.27. Wynik testu wzdłuż osi turbiny – wartość współczynnika determinacji (R_2) osiągnięta przez neuronowy symulator przepływu przestrzennego na kolejnych podzbiorach zbioru testowego.	55
Rys. 4.28. Histogramy błędu względnego dla poszczególnych prognozowanych parametrów cieplno-przepływowych (ciśnienia, temperatury oraz liczby Macha) – wartości nieprzekraczające 100%.	56
Rys. 4.29. Rozkład entropii statycznej: a) przy wierzchołkach łopatek, b) w połowie rozpiętości łopatek, c) u stóp łopatek.	57
Rys. 4.30. Krzywe uczenia neuronowego symulatora przepływu przestrzennego uwzględniającego entropię statyczną (od lewej): funkcja kosztu – błąd średniokwadratowy (ang. Mean Squared Error, MSE) oraz metryka sukcesu – współczynnik determinacji (R_2).	58
Rys. 4.31. Wynik testu wzdłuż osi turbiny – wartość współczynnika determinacji (R_2) osiągnięta przez neuronowy symulator przepływu przestrzennego uwzględniający entropię statyczną na kolejnych podzbiorach zbioru testowego.	58
Rys. 5.1. Orientacyjny obszar analizowanego kanału przepływowego, dla którego przeprowadzono proces uśredniania (widok merydionalny).	60
Rys. 5.2. Rzeczywiste oraz prognozowane wartości ciśnienia w przestrzeni międzystopniowej, dla poszczególnych wartości ciśnienia wlotowego.	61
Rys. 5.3. Rzeczywiste oraz prognozowane wartości ciśnienia w przestrzeni międzystopniowej, dla poszczególnych wartości ciśnienia wlotowego.	61
Rys. 6.1. Schemat hierarchii budowania neuronowego modelu obliczeniowego układu przepływowego.	62

SPIS TABEL

Tabela 3.1. Liczba łopatek oraz liczba przekrojów profili łopatkowych dla poszczególnych wieńców.	11
Tabela 3.2. Zestawienie wybranych parametrów dla poszczególnych siatek numerycznych.	14
Tabela 3.3. Zestawienie wybranych wielkości dla poszczególnych siatek numerycznych.	15
Tabela 3.4. Pomiary ciśnienia całkowitego i temperatury na wlocie do przedostatniego stopnia, dla poszczególnych głębokości sondowania, [24].	20
Tabela 3.5. Pomiary ciśnienia i temperatury na wlocie do ostatniego stopnia, dla poszczególnych głębokości sondowania, [24].	21
Tabela 3.6. Pomiary ciśnienia i temperatury na wylocie z ostatniego stopnia, dla poszczególnych głębokości sondowania, [44].	21
Tabela 4.1. Zestawienie wartości parametrów brzegowych dla rozpatrywanych wartości mocy i ciśnienia końcowego.	32
Tabela 4.2. Czas optymalizacji oraz maksymalna wartość współczynnika determinacji R2 dla rozpatrywanych modeli uczenia maszynowego.	38
Tabela 4.3. Zestawienie wyników testu wzdłuż turbiny dla wybranej struktury neuronowego modelu przepływu pary na średnicy podziałowej.	49
Tabela 5.1. Zestawienie uśrednionych wartości ciśnienia i temperatury, wraz z wartościami błędu względnego, dla poszczególnych wartości ciśnienia wlotowego.	60