

POLITECHNIKA WARSZAWSKA

DYSCYPLINA NAUKOWA INŻYNIERIA MECHANICZNA

DZIEDZINA NAUK INŻYNIERYJNO-TECHNICZNYCH

Rozprawa Doktorska

mgr inż. Alicja Okuniewska

**Metodyka diagnozowania przyczyn powstawania wad wyrobów
na podstawie zaawansowanego modelowania opartego na
dużych zbiorach danych**

Promotor:

Prof. Dr hab. inż. Marcin Andrzej Perzyk

WARSZAWA, 2023

Podziękowania

Pragnę złożyć serdeczne podziękowania Panu prof. dr hab. inż. Marcinowi Perzyk, za nieocenioną pomoc udzieloną w trakcie całego toku kształcenia oraz prowadzenia badań i przygotowywania pracy doktorskiej, za okazaną cierpliwość i wyrozumiałość. Szczególne podziękowania pragnę złożyć Panu Profesorowi za inspirację do zgłębiania nowych ciekawych zagadnień naukowych.

Chciałabym również wyrazić szczególną wdzięczność Panu dr Jackowi Kozłowskiemu, bez którego moja praca doktorska nie miałaby możliwości powstania. Dziękuję za przekazaną wiedzę oraz niezastąpioną pomoc w poszukiwaniu nowych rozwiązań problemów badawczych.

Chciałabym zadedykować niniejszą pracę mojej wspaniałej rodzinie. W ten sposób chciałabym docenić waszą pomoc i wsparcie. W szczególności dziękuję mojej Mamie za pomoc w wyborze drogi zawodowej oraz nigdy niegasnącą wiarę we mnie.

Streszczenie

Niniejsza rozprawa doktorska skupia się na zastosowaniu Sztucznych Sieci Neuronowych (SNN), Drzew Decyzyjnych (DT) oraz Maszyn Wektorów Wspierających (SVM) do diagnozowania przyczyn powstawania wad w wyrobach. Celem pracy jest sprawdzenie i wykazanie, że wymienione modele, których skuteczność została już wcześniej potwierdzona w różnych dziedzinach i zadaniach z powodzeniem można zastosować również w dziedzinie wytwarzania i zadaniach identyfikacji przyczyn powstawania wad wyrobów pochodzących z procesu odlewania ciśnieniowego, mimo jego wysokiego skomplikowania.

Rozprawa zawiera również opracowaną strategię odpytywania modeli zawierającą wielowymiarową optymalizację parametrów procesu dla maksymalnej i minimalnej wartości wady z wykorzystaniem metod gradientowych i ewolucyjnych. Tego typu zastosowane rozwiązanie umożliwiłoby w znacznym stopniu inżynierom procesów wytwórczych prawidłową identyfikację parametrów i ich określonych zakresów wartości, które wpływają na powstanie wady w produkcji.

Poza szczegółowym studium literaturowym tematyki Sztucznych Sieci Neuronowych, Maszyn Wektorów Wspierających oraz Drzew Decyzyjnych, rozprawa zawiera również wnikliwą analizę wrażliwości modeli na zmiany określonych parametrów. Analiza ta oraz wykonane na jej podstawie podsumowanie jest jednym z najbardziej wieloaspektowych zestawień tego typu przedstawionych w dotychczasowej literaturze przedmiotu.

Słowa kluczowe: Diagnoza wad, Metody Uczenia Maszynowego, Sztuczne Sieci Neuronowe, Drzewa Regresyjne, Maszyna Wektorów Wspierających, Optymalizacja Parametrów Procesu

Abstract

This dissertation focuses on the application of Artificial Neural Networks (SNN), Decision Trees (DT) and Support Vector Machines (SVM) for diagnosing the causes of defects in products. The aim of the work is to verify and demonstrate that the aforementioned models, whose effectiveness has already been confirmed in various fields and tasks, can be successfully applied also in the field of manufacturing and tasks of identifying the causes of defects in products originating from the die casting process, despite its high complexity.

The study also includes an elaborated strategy of model questioning containing multidimensional optimization of process parameters for maximum and minimum defect values using gradient and evolutionary methods. This type of applied solution would significantly enable manufacturing process engineers to correctly identify parameters and their specific value ranges that influence the formation of a defect in a product.

Moreover, apart from a detailed literature review of the topics of Artificial Neural Networks, Support Vector Machines and Decision Trees, the thesis also contains a deep analysis of the sensitivity of models to changes in the certain parameters. This analysis and the summary made on its basis is one of the most multi-faceted summaries of this kind presented in the literature so far.

Keywords: Product Defect Diagnosis, Machine Learning Tools, Artificial Neural Network, Regression Trees, Support Vector Machine, Optimization of Process Parameters

Spis treści

Spis treści	7
1. Wstęp	9
1.1. Motywacja i kontekst podjęcia badań	9
1.2. Cel i hipoteza pracy	13
1.3. Układ pracy	14
1.4. Powiązane publikacje i wystąpienia.....	15
2. Sztuczne Sieci Neuronowe	17
2.1. Historia Sztucznej Inteligencji	17
2.2. Historia modelowania wykorzystującego Sztuczne Sieci Neuronowe	23
2.3. Podstawowe informacje o Sztucznych Sieciach Neuronowych.....	26
2.4. Działanie Sztucznych Sieci Neuronowych.	32
2.5. Wybór struktury i rodzaju sieci neuronowych oraz sposobu ich uczenia.	35
2.6. Metodyka gromadzenia i przygotowania danych do zaawansowanego modelowania .	41
2.7. Przykłady zastosowania SSN w procesach wytwarzania.....	45
3. Drzewa decyzyjne	48
3.1. Wprowadzenie.....	48
3.2. Przykłady zastosowania DT w procesach wytwarzania.....	49
4. Maszyna wektorów wspierających	51
4.1. Wprowadzenie.....	51
4.2. Przykłady zastosowania SVM w procesach wytwarzania	53
5. Badania własne	56
5.1. Sformułowanie problemu.....	56
5.2. Przebieg badań	57
5.2.1. Wstępne przetwarzanie danych	57
5.2.1.1. Metodyka i wyniki badań.....	57
5.2.1.2. Wnioski	111
5.2.2. Podział danych na zbiory do badań i dyskretyzacja danych	115
5.2.2.1. Metodyka i wyniki badań.....	115
5.2.2.2. Wnioski	137
5.2.3. Analiza istotności zmiennych.....	137
5.2.3.1. Metodyka i wyniki badań.....	138
5.2.3.1. Wnioski	167
5.2.4. Zaawansowane modelowanie oparte na danych metodą SSN.....	168

5.2.4.1.	Metodyka i wyniki badań.....	168
5.2.4.2.	Wnioski	185
5.2.5.	Zaawansowane modelowanie oparte na danych metodą DT.....	187
5.2.5.1.	Metodyka i wyniki badań.....	187
5.2.5.2.	Wnioski	192
5.2.6.	Zaawansowane modelowanie oparte na danych metodą SVM	193
5.2.6.1.	Metodyka i wyniki badań.....	193
5.2.6.2.	Wnioski	197
5.2.7.	Badanie modelu w celu wielowymiarowej optymalizacji parametrów procesu	199
5.2.7.1.	Cel, metodyka i wyniki badań	199
5.2.7.2.	Omówienie wyników i wnioski	231
6.	Podsumowanie i wnioski ogólne	237
7.	Spis ilustracji.....	241
8.	Spis tabel.....	249
9.	Literatura	261

1. Wstęp

1.1. Motywacja i kontekst podjęcia badań

Rozwój technologii komputerowych, który miał miejsce w pierwszej dekadzie XXI wieku stworzył nowe możliwości do wykorzystania metod sztucznej inteligencji w wielu dziedzinach nauki. Na początku drugiej dekady XXI wieku wzrosło również znacznie zainteresowanie przetwarzaniem wielkich zbiorów danych oraz rozpoczęto rozwijanie zastosowań metod eksploracji danych i technik uczenia maszynowego w sektorze produkcji i wytwarzania. Stało się tak, gdyż w tym czasie pojawiła się nowa koncepcja tzw. „Przemysłu 4.0.”, która dotyczy optymalizacji sposobów pracy, określonej roli pracowników w przemyśle, nowych technologii oraz sposobów funkcjonowania danego tradycyjnego przedsiębiorstwa produkcyjnego w nowoczesnej rzeczywistości cyfrowej. Czwarta rewolucja przemysłowa cechuje się ogólną zdolnością do transformowania gospodarek, społeczeństw oraz miejsc pracy poprzez implementację oraz adaptację nowoczesnych technologii i nową organizację procesów oraz zarządzania produkcją. Daje ona możliwość uelastycznienia planów produkcyjnych, a co za tym idzie wzrostu opłacalności ekonomicznej, poprzez silne zorientowanie na klienta oraz na jego potrzeby. Historycznie pojęcie „Przemysł 4.0.” zostało pierwszy raz użyte w 2011 roku podczas targów w Hanowerze i dotyczyło ogółu strategii połączonych z wdrożeniem technik cyfrowych do tradycyjnego przemysłu. Transformacja cyfrowa przedsiębiorstwa przede wszystkim wymaga skutecznych narzędzi analitycznych, gdyż jest to długotrwały proces, wcześniej zaplanowany, odpowiednio obserwowany oraz stale ulepszany. Tego typu działanie daje możliwość zysku poprzez możliwość obniżania kosztów wytworzenia, czy też produkcji, wzrostu wydajności maszyn i ludzi oraz podnoszenia jakości wyrobów. Główne trudności wynikające z wdrożenia cyfryzacji a następnie digitalizacji w przedsiębiorstwach to wielkie ilości danych pochodzących z procesów oraz często niedostosowane linie produkcyjne (np. zawierające maszyny, które nie mogą generować danych). Dlatego też podstawą jest obecnie nastawienie przedsiębiorstw na przetwarzanie ogromnych ilości danych przy zastosowaniu zaawansowanych metod modelowania opartych na wspomnianych danych. Dlatego też Przemysł 4.0. związany jest z technikami analizy dużych zbiorów danych, tzw. Big Data, Sztuczną Inteligencją, uczeniem maszynowym i innymi. Dane stanowią swego rodzaju najcenniejszy surowiec czwartej rewolucji przemysłowej, gdyż od ich efektywnego

wykorzystania zależy cały rozwój przemysłu przyszłości. Przemysł przyszłości będą tworzyły inteligentne fabryki (tzw. smart factories), których koncepcja wpisuje się w realia czwartej rewolucji przemysłowej i oznacza daleko idącą integrację świata cyfrowego, digitalnego ze światem fizycznym. Główne cechy fabryki inteligentnej to jej elastyczność, czyli zdolność dostosowania produkcji do zmieniających się potrzeb klienta w sposób automatyczny, dzięki automatycznemu planowaniu oraz wyposażeniu umożliwiającemu szybkie przebrojenia, jednocześnie z nowoczesnym parkiem maszynowym zdolnym do monitorowania swojego stanu technicznego i reagowania np. samodzielny składaniem zleceń naprawy. Następną, ważną z punktu widzenia niniejszej rozprawy cechą fabryki inteligentnej jest jej elastyczność przejawiająca się przez sprawny system kontroli procesu celem diagnostyki wadliwych produktów ocenianych w czasie rzeczywistym. Kolejna cecha zdolność do podejmowania działań zanim wystąpi potencjalne zagrożenie. Tego typu koncepcja może wysnuwać cel albo wizję dla niniejszej rozprawy, aby podjąć się próby diagnostyki wady wyrobu jeszcze przed jej wystąpieniem celem zapobieżenia jej wystąpieniu. Następną cechą inteligentnej fabryki to jej zdolność do optymalizacji, poprzez zastosowanie zaawansowanych rozwiązań technologicznych oraz odpowiednią organizację pracy i ograniczanie ryzyka popełnienia błędu i minimalizację kosztów wytworzenia, co również stanowi wyzwanie niniejszej rozprawy, gdyż błędnie wytworzony produkt, czyli produkt z wadą to zbędny koszt materiałów, czas pracy maszyn, ludzi oraz koszt odpadu produkcyjnego, który należy wyeliminować. Inteligentna fabryka powinna być również transparentna, czyli gromadzić i analizować dane dotyczące przebiegu produkcji, jednocześnie zapewniając spójny i wiarygodny opis sytuacji obecnej w hali produkcyjnej albo na stanowisku produkcyjnym. Inteligentna fabryka powinna być również wysoce skomunikowana, czyli wszystkie maszyny, systemy informatyczne powinny być ze sobą połączone, co umożliwiałoby wymianę informacji między działami planowania, magazynu, produkcji i utrzymania ruchu [1].

W niniejszej rozprawie poddano analizie dane rzeczywiste, pochodzące z procesu odlewania ciśnieniowego występującego w jednej z odlewni. Wybrano tego typu dane ze względu na wysoką złożoność procesu odlewniczego. Procesy metalurgiczne a w tym procesy odlewnicze, w ogólnym rozumieniu stanowią dziedzinę techniki obejmującą wytwarzanie materiałów metalowych, mogących stanowić części maszyn lub przedmiotów przez wypełnianie odpowiednio przygotowanych form ciekłym metalem oraz ich kształtowanie. W pracy skupiono się na zagadnieniu jakości odlewów dla przemysłu motoryzacyjnego, a w szczególności na bardzo ważnej ich cesze, jaką jest szczelność odlewu. Wyznacza się ją w próbach wykonywanych na specjalnym stanowisku, gdzie określa się wielkość tzw. przecieku

(ang. leakage), czyli objętości cieczy poddanej ciśnieniu, jaka przeniknęła przez ścianki odlewu. Zbyt duża wartość przecieku oznacza wystąpienie nieszczelności odlewu, powodowanej najczęściej porowatością stopu będącej na ogół wynikiem zbyt porowatej struktury na przekroju ścianki, związanej najczęściej z procesem krzepnięcia.

Wspomniany już stopień złożoności oraz skomplikowania procesów odlewniczych przyczynia się do faktu, iż modelowanie oparte na danych z użyciem zaawansowanych równań matematycznych, które opisywałoby wszystkie zależności istotne z punktu widzenia procesu a dokładniej z punktu widzenia diagnostyki przyczyn powstawania wad wyrobów, byłoby niemożliwe lub po prostu zbyt czasochłonne. Procesy te są więc niezalgorytmizowane przez swoją złożoną naturę, lub charakter. Sprawia to, że procesy odlewnicze mogą zostać określone, z punktu widzenia nauki, jako czarna skrzynka, czyli proces możliwy do rozpatrzenia lub analizy tylko pod kątem wejść i wyjść, bez znanej charakterystyki i kompleksowej wiedzy, co dzieje się w jego wnętrzu. Złożoność tego problemu oraz zagadnień związanych z całym procesem wytwarzania sprawiły, iż zaistniała konieczność opracowania zbioru narzędzi celem zaawansowanego modelowania opartego na danych, a w szczególności wykorzystującego sztuczne sieci neuronowe, które obecnie wyparły tradycyjne i powszechnie stosowane narzędzia do statystycznego opisu procesu, czyli swego rodzaju modele matematyczne, a następnie drzewa decyzyjne, które są zdolne odwzorować dowolnie skomplikowane pojęcia oraz maszynę wektorów wspierających, wyróżniającą się stosunkowo wysoką skutecznością.

Systemy uczące się, oparte o modele, które nie uwzględniają natury fizycznej procesu, nazywane miękkimi, znajdują swoje zastosowanie w gromadzeniu i analizie danych przemysłowych. Techniki, które pozwalają odkrywać złożone zależności statystyczne dużych zbiorów danych, będące w stanie wykorzystać metody uczenia maszynowego, lub przedstawiać ich reprezentację w formie reguł logicznych np. sztucznych sieci neuronowych [2], [3], [4] nazywane są eksploracją danych (ang. Data Mining). Podczas ostatnich dwóch dekad można było zaobserwować znaczny przyrost badań wykorzystujących techniki eksploracji danych. Zastosowanie tych technik w procesach związanych z wytwarzaniem może pomóc w przewidywaniu prawdopodobieństwa wystąpienia awarii maszyn lub urządzeń, wykrywania przyczyn pogorszenia jakości wyrobu, przewidywania skutków zmian w procesie z jednoczesnym wskazaniem na optymalne parametry lub parametry krytyczne dla procesu. Dokładna charakterystyka zastosowań technik eksploracji danych oraz płynących z tego zastosowania korzyści, została zaprezentowana w pracach [5], [6]. Ogólny opis charakterystyki przykładów wykorzystania techniki eksploracji danych w sektorze produkcji i wytwarzania można znaleźć w publikacji o charakterze przeglądowym [7], [8], [9], [10].

Przedsiębiorstwo produkcyjne posiadające dostęp do danych pochodzących z procesu, wykorzystując metody opisane w niniejszej rozprawie, będzie mogło prognozować tendencję do występowania wady wyrobu. Jest to ważna i wartościowa funkcjonalność, ponieważ na przykładzie przedsiębiorstwa, z którego pochodzą dane rzeczywiste do badań, można stwierdzić, iż badanie jakości odlewu poprzez określenie wartości przecieku, to koszt stanowiący nawet 40% jednostkowego kosztu wytworzenia. Odnosząc się do tego faktu możliwość przewidywania wartości przecieku pozwoliłaby na zaniechanie (częściowe lub całkowite) kosztownych badań. Wynik badań byłby znaczący również dlatego, że przedsiębiorstwa produkcyjne obecnie kładą coraz większy nacisk na spełnienie oczekiwań klienta ostatecznego, czyli dostarczenie produktu o wysokiej jakości, w konkurencyjnych cenach oraz w pożądanym przez klienta czasie. W tym celu poszukuje się sposobów ciągłego doskonalenia procesów produkcyjnych, czyli wdrażania filozofii Kaizen (kai – „zmiana” oraz zen – „dobry”), która w dosłownym tłumaczeniu oznacza „zmianę na lepsze”, filozofię skupioną na ciągłym ulepszaniu. Kaizen jest podstawą w podejściu Lean Manufacturing. Lean Manufacturing to metodologia, która pozwala nie tylko na uzyskanie wymiernych wyników działalności firmy, ale dodatkowo wprowadza do niej kulturę sprzyjającą rozwojowi i dobrej komunikacji pomiędzy pracownikami. Podstawą metodologii Lean jest praca nad redukcją marnotrawstw (nadprodukcji, oczekiwania, transportu, zbędnej obróbki, zapasów, zbędnego ruchu i defektów). Produkcja tzw. defektów czyli ostatni z wyżej wymienionych z siedmiu typów marnotrawstw, powinna być zredukowana celem zmniejszenia kosztów materiałowych, kosztów utylizacji odpadów, kosztów energii, kosztów zatrudnienia, kosztów maszyn i narzędzi oraz optymalizacji stanów magazynowych, gdyż w przypadku braku defektów nie będzie potrzebny zwiększony zapas na pokrycie błędnych wyrobów produkcyjnych. Wszystkie z przywołanych argumentów umożliwiają stwierdzenie, iż właściwe wydobywanie wiedzy z gromadzonych danych z zastosowaniem metod zaawansowanego modelowania procesu może stanowić dla przedsiębiorstwa źródło wartościowych informacji.

Niniejsza rozprawa doktorska skupia się na określeniu, jaki sposób zaawansowanego modelowania opartego na dużych zbiorach danych, najlepiej odpowiada na potrzeby diagnozowania przyczyn wad wyrobów powstających podczas procesu odlewania wysokociśnieniowego. Dlatego też celem pracy jest stworzenie metodyki (zbioru zasad określającego metody), jako prezentacji całościowego postępowania celem diagnozowania przyczyn powstawania wad wyrobów na podstawie zaawansowanego modelowania opartego na dużych zbiorach danych (Big Data). Wspomniane pojęcie dużych zbiorów danych określanych jako Big Data, w tym przypadku używane jest, gdyż wykorzystywane dane są

stosunkowo duże jak na dane pochodzące z procesu produkcyjnego. Wykorzystanie dużych zbiorów danych do analiz oznacza brak konieczności badania mniejszych zbiorów określanych za pomocą różnych sposobów doboru próby, eliminując tym samym związane z tym błędy. Dane badane są różnorodne oraz umożliwiają zdobywanie nowych informacji i pozyskiwanie z nich wiedzy. W badaniach skupiono się na próbach przewidzenia danej wyjściowej jaką jest przeciek, którego wartość wskazuje na jakość produktu wyjściowego. Podczas badań zauważono szczególny problem badawczy powodujący trudność znalezienia skutecznej techniki zaawansowanego modelowania procesu, przez silne niezrównoważenie danych, gdyż z jednej strony dostępna jest duża ilość danych procesowych, z drugiej natomiast mała ilość danych o stanach krytycznych – mała reprezentacja niektórych krytycznych wartości, dodatkowo zauważono zmienność skuteczności stosowanych metod, powodującą dodatkową trudność wyboru najbardziej skutecznej techniki modelowania procesu, celem jego optymalizacji. Podczas badań zauważono również wysoką konieczność znalezienia i określenia wszystkich relacji między parametrami procesu produkcji i wytwarzania oraz ich wpływu na jakość produktu wytwarzanego.

Badania rozpoczęto od wskazania najbardziej istotnych zmiennych wejściowych, na podstawie wstępnego przetwarzania danych, które następnie utworzyły zbiory danych do badań użytych do uogólnionych modeli regresyjnych jakimi są sztuczne sieci neuronowe. W kolejnych etapach zastosowano również alternatywne modele oparte na danych, czyli metodę Drzew Decyzyjnych, z uwagi na ich diametralnie inny charakter oraz rozpowszechnienie w zastosowaniach przemysłowych i innych oraz Maszynę Wektorów Wspierających, z uwagi na aktualne trendy w modelowaniu opartym na danych. Następnie dla metody zapewniającej najlepsze wyniki, a więc dzięki zbudowanym modelom sztucznych sieci neuronowych wyznaczono parametry o najwyższym wpływie na powstanie wady wyrobu.

1.2. Cel i hipoteza pracy

Zarysowany dotychczas motyw przewodni odnoszący się do ogólnej hipotezy badawczej, którą zamierza udowodnić niniejsza rozprawa doktorska, w ramach realizacji tematyki doktoratu, zakłada, iż diagnozowanie przyczyn powstawania wad wyrobów wymaga zastosowania określonego zbioru metod zaawansowanego modelowania opartego na dużych zbiorach danych. Cele rozprawy można dodatkowo doprecyzować w formie dokładniejszych zadań, a więc:

- odpowiedzieć na pytanie, jakie metody eksploracji danych w sektorze produkcji i wytwarzania, mogą być z powodzeniem zastosowane w zadaniach diagnozowania przyczyn powstawania wad wyrobów, w szczególności mając na uwadze wysoki stopień skomplikowania danych dostępnych w dziedzinie wytwarzania odlewów ciśnieniowych,
- przeprowadzić skuteczny proces wstępnego przetwarzania danych celem przygotowania ich do zaawansowanego modelowania procesu,
- zaprezentować działanie modeli opartych na wybranych metodach zaawansowanego modelowania opartego na danych, w formie studium przypadku dla danych pochodzących z rzeczywistego procesu odlewania ciśnieniowego,
- przeanalizować wpływ zmian rodzaju i parametrów modelu na jego skuteczność,
- ocenić i wybrać najskuteczniejsze metody, celem stworzenia kompleksowej metodyki diagnozowania przyczyn powstawania wad wyrobów.

Takie rozwiązanie pozwoli na implementację nowego rodzaju algorytmów do diagnozowania przyczyn powstawania wad wyrobów, a następnie sterowania parametrami procesu, celem zapobieżenia powstawania wady.

1.3. Układ pracy

Rozprawa została podzielona na sześć rozdziałów. Rozdziały od drugiego do czwartego zawierają ogólne wprowadzenie teoretyczne połączone z przeglądem literatury. Natomiast opis oryginalnych prac badawczych przeprowadzonych w ramach niniejszej rozprawy doktorskiej został zawarty w rozdziale piątym.

Rozdział drugi stanowi ogólne wprowadzenie do zagadnienia sztucznych sieci neuronowych. Poza omówieniem funkcjonowania sztucznych sieci neuronowych i głównych założeń uczenia modeli opartych na dużych zbiorach danych, zawiera on przegląd najbardziej znaczących struktur, rodzajów i sposobów uczenia występujących w literaturze a także wybranych najnowszych koncepcji w zakresie konstruowania sztucznych sieci neuronowych.

Rozdział trzeci skupia się na tematyce drzew decyzyjnych. Szczególną uwagę poświęcono metodzie drzew regresyjnych. Tekst rozdziału opisuje historię powstania metody, podstawy teoretyczne oraz przegląd literaturowy zastosowań drzew regresyjnych w dziedzinie wytwarzania.

Rozdział czwarty zawiera rozbudowany opis metody maszyn wektorów wspierających. Rozpoczyna się od historii powstania metody, następnie zawiera uzasadnienie zastosowania jej w niniejszej rozprawie. Dodatkowo opisuje jej podstawy teoretyczne wraz z charakterystyką parametrów modelu.

Rozdział piąty przedstawia efekt prac badawczych związanych z wstępnym przetwarzaniem danych a następnie zastosowaniem metod sztucznych sieci neuronowych, drzew decyzyjnych i maszyny wektorów wspierających oraz wielowymiarowej optymalizacji parametrów procesu celem stworzenia metodologii skutecznego diagnozowania przyczyn powstawania wad wyrobów.

Rozdział szósty stanowi podsumowanie rozprawy doktorskiej oraz wnioski ogólne formułujące odpowiedzi na cele niniejszej rozprawy doktorskiej.

1.4. Powiązane publikacje i wystąpienia

Wyniki oryginalnych prac eksperymentalnych przeprowadzonych przez autora, których omówienie znajduje miejsce w niniejszej rozprawie, zostały przedstawione w następujących publikacjach i wystąpieniach konferencyjnych, seminariach:

- OKUNIEWSKA, Alicja, PERZYK, Marcin and KOZŁOWSKI, Jacek, 2021, Methodology for Diagnosing the Causes of Die-Casting Defects, Based on Advanced Big Data Modelling. Archives of Foundry Engineering. 2021. Vol. 21, no. 4, p. 103–109. DOI 10.24425/afe.2021.138687.
- OKUNIEWSKA, Alicja, Methods review of advanced data analysis tools, in process control and diagnosis. Piech K., ed. Zagadnienia Aktualne Poruszane Przez Młodych Naukowców, 17. Creativetime; 2020, p. 95-98.
- OKUNIEWSKA, Alicja, Current tools of data preparation in industrial manufacturing. Piech K., ed. Zagadnienia Aktualne Poruszane Przez Młodych Naukowców, 17. Creativetime; 2020, p. 92-94.
- 61 Międzynarodowa Konferencja Naukowa „Krzepnięcie i Krystalizacja Metali 2021”, 18-20.10.2021, temat wystąpienia: „Metodyka diagnozowania przyczyn powstawania wad odlewów ciśnieniowych na podstawie zaawansowanego modelowania opartego na dużych zbiorach danych”.
- Seminarium Neuromet 2021, pt. „Zaawansowanie sztucznej inteligencji w symulacji i sterowaniu procesami metalurgicznymi” 22.04.2021 r. temat wystąpienia: „Problematyka wyboru zmiennych do opracowania metodyki diagnozowania

przyczyn powstawania wad wyrobów na podstawie zaawansowanego modelowania opartego na dużych zbiorach danych”.

- Konferencja CreativeTime, pt. „Analiza zagadnienia, analiza wyników -wystąpienie młodego naukowca” edycja II, 01-02.04.2020, temat wystąpienia: „Methods review of advanced data analysis tools in proces control and diagnosis”.

Rozdział piąty zawiera ujednolicony i rozszerzony opis tych treści oraz dokładną analizę wyników eksperymentalnych.

2. Sztuczne Sieci Neuronowe


2.1. Historia Sztucznej Inteligencji

Opublikowany przez zespół Geoffreya Hinton z uniwersytetu w Toronto, w 2006 r. artykuł, dotyczący funkcjonowania i specyfiki sieci DBN [11] stanowił inspirację mającą na celu poprawić stan rzeczy. Tuż po wspomnianym artykule najpoczytniejsze czasopisma otrzymały liczne zgłoszenia publikacji poświęconych głębokiemu uczeniu się. Artykuły te podniosły znacznie wagę tematu widzenia komputerowego oraz możliwości i zastosowań uczenia maszynowego. Na wstępie rozprawy dokonano, więc przeglądu literatury dotyczącej metod zaawansowanego modelowania opartego na danych, stosowanych w sektorze produkcji i wytwarzania, wraz z jednoczesną oceną artykułów powstałych podczas ostatnich dwóch dekad.

Metody sztucznej inteligencji obecnie opierają swoje działania na wykorzystaniu zasad funkcjonowania ludzkiego mózgu, który jest w stanie szybko przetwarzać informacje, jest zdolny do prawidłowego działania w szybko zmieniającym się otoczeniu, posiada umiejętność przyswajania (uczenia się) i stosowania bardzo obszernej wiedzy, ma możliwość prawidłowego działania nawet przy uszkodzeniach jego struktury, oraz wykazuje umiejętność abstrakcyjnego myślenia i potrafi rozwiązywać wysoce skomplikowane problemy. Z czym nie do końca zgadzają się psycholodzy, którzy niestety z reguły nie traktują poważnie porównywania ludzkiego mózgu do komputera. Amerykański psycholog, naczelny redaktor czasopisma „Psychology Today”, założyciel Cambrige Center for Behavioral Studies, Robert Epstein, w jednym ze swoich artykułów zatytułowanym „Pusty Mózg. Twój mózg nie przetwarza informacji, nie odzyskuje wiedzy ani nie przechowuje wspomnień. Krótko mówiąc: Twój mózg nie jest komputerem” z 2016 roku, napisał, iż: „Badacze mózgu i psychologowie, choćby nie wiadomo jak się starali, nie znajdują w mózgu piątej symfonii Bethovena, słów, obrazów, reguł gramatyki, ani jakichkolwiek bodźców środowiskowych” [12]. Niestety stwierdzenie to a co więcej sam tytuł artykułu nie bierze pod uwagę zasady działania konwolucyjnych sieci neuronowych. Podejście te jednak ma też swoje uzasadnienie, gdyż nadal nie odkryto wysoce skutecznych modeli wysokopoziomowych funkcji mózgu, takich jak na przykład myśl ludzka czy świadomość człowieka, jednak nie można też jednoznacznie stwierdzić czy w ogóle sama świadomość stanowi rzeczywistą funkcję mózgu [13]. Pojemność powszechnie znanych nam nośników informacji oraz czas dostępu do nich, porównując do możliwości mózgu jest ograniczona (widać to zwłaszcza, jeśli porówna się wiedzę zgromadzoną w mózgu oraz

prędkość zarządzania informacją u przeciętnego człowieka z właściwościami współczesnego twardego dysku) [14].


Sztuczna inteligencja gromadzi w sobie trzy podzbiory (rys. 2.1.1.): pierwszy z nich to uczenie maszynowe, kolejne jest głębokie uczenie i na końcu sieci neuronowe.



Rys. 2.1.1. Relacje między sztuczną inteligencją, uczeniem maszynowym, głębokim uczeniem a sztucznymi sieciami neuronowymi [opracowanie własne]

Zacznijmy od uczenia maszynowego, które zasadniczo tworzone jest w celu wyszukiwania wzorców, klasyfikacji danych, przewidywania wyników i na ich podstawie podejmowania zasadnych decyzji. Warto w tym miejscu zauważyć, że wcześniej powszechnie tworzone programy wykorzystujące wyrażenia warunkowe, będące w stanie podejmować decyzje jedynie na podstawie spełnienia określonych warunków, gdzie wszystkie kryteria muszą być uprzednio zdefiniowane przez programistę, powodowały i nadal powodują wiele trudności, które eliminuje obecnie uczenie maszynowe, ponieważ zastosowane algorytmy są w stanie poprawiać się automatycznie poprzez doświadczenie, czyli ekspozycję na dane [15] i nie wymagają predefiniowania żadnych kryteriów warunkowych. Skuteczność tej poddziedziny sztucznej inteligencji została również udowodniona przez Alana Turninga już w 1950 roku w tzw. teście Turninga, podczas którego komputer miał rozróżnić właściwie ludzi od komputerów, aby zdać test [16]. Jednak można poddać wątpliwości ten fakt i stwierdzić, iż rewolucja danych rozpoczęła się jednak od postępów w metodologii zbierania danych i technologii powiązanych z dziedziną [17]. Można by nawet powiedzieć iż dane zawierają odpowiedzi na pytania, o których zadaniu jeszcze nikt nie pomyślał [18]. Pojęcie uczenie


maszynowe zostało użyte po raz pierwszy, przez Arthura Samuela w 1959 roku na konferencji. Powiedział on, iż „Uczenie maszynowe daje komputerom możliwość „uczenia się” bez bycia konkretnie zaprogramowanym do danego zadania.” [19]. Neal Stephenson, autor znanej książki z 1999 roku, pt. „Zamieć”, skupiającej się na negatywnych konsekwencjach funkcjonowania ludzi w otoczeniu zaawansowanej technologii komputerowej i informacyjnej, stwierdził, iż sztuką jest „stworzyć niezbitą fakt z pajęczyny domysłów” [20]. Można powiedzieć, że słowa te doskonale opisują uczenie maszynowe, które opiera się na wyodrębnianiu informacji (przy użyciu algorytmów), z surowych danych i tworzenia reprezentacji tych danych w postaci modelu. Pojęcie modelu możemy określić, jako reprezentację danego systemu, uproszczony lub wyidealizowany opis lub koncepcję określonego procesu [21]. Stworzony model jest wykorzystywany do przetwarzania dalszych zestawów danych, na których nie było wcześniej oparte modelowanie [13]. Modelowaniem nazywamy proces tworzenia odpowiedniej reprezentacji pewnego zjawiska (systemu). Jediną potrzebą jest uchwycenie głównej idei prawdziwego systemu. W przeciwnym razie, projektuje się model, aby przewidzieć zachowanie systemu w obecności pewnego bodźca. Oczywistym jest, że w tym pożądanym model powinien zachowywać się jak najbardziej zbliżony do rzeczywistego systemu [21]. Uczenie maszynowe jako część empirycznego, miękkiego modelowania opartego na danych, zgodnie z taksonomią przedstawioną na rysunku 2.1.2., swoje zastosowanie znajduje w rozwiązywaniu wysokokompleksowych problemów, w których nie mamy wiedzy w zakresie przyczyn wpływających na dane zachowanie obiektu lub procesu [22]. Modelowanie oparte na danych, z użyciem uczenia maszynowego nie wymaga posiadania wszystkich informacji na temat analizowanego procesu, obiektu lub systemu, dane mogą być ograniczone lub fragmentaryczne, gdyż modelowanie empiryczne, miękkie budowane jest z uproszczonych zależności lub reguł, które są wyprowadzane bezpośrednio z danych. Obserwacje procesów przemysłowych są zazwyczaj niepewne. Stopień niepewności zależy od analizowanego procesu. W przypadku danych pochodzących z przedsiębiorstw produkcyjnych jest on często dość wysoki [23].



Rys. 2.1.2. Zakres zastosowania różnych typów modeli procesów [22].

Przykłady uczenia maszynowego sklasyfikowane ze względu na typ uczenia się przedstawiono na poniższym rysunku (rys.2.1.3.). Ogólnie sam temat uczenia maszynowego stał się bardzo żywy w ciągu ostatniej dekady. Podejmowany jest na licznych konferencjach naukowych i gospodarczych, w programach naukowych i praktycznie codziennie w „Wall Street Journal”, gdzie prowadzona jest oddzielna strona dotycząca prowadzonego programu o tytule: „Przyspieszenie rozwoju aplikacji do uczenia maszynowego”. Na przywołanej stronie autor David Schubmehl, Dyrektor badań, z Cognitive/Artificial Intelligence Systems, IDC – firmy poświęconej pogłębianiu rozumienia wpływu technologii na biznes, podsumował iż: „Rynek aplikacji opartych na uczeniu maszynowym i głębokim uczeniu, czyli ogólnie opartych na sztucznej inteligencji szybko się rozrósł i nadal rośnie. Firma IDC szacuje, że wydatki na uczenie maszynowe i rozwiązania uczenia głębokiego przekroczą 57 miliardów dolarów do 2021 roku, a do 2026 roku firma IDC przewiduje, że 75 procent całego oprogramowania dla przedsiębiorstw będzie zawierało aspekty uczenia maszynowego i głębokiego uczenia na potrzeby prognoz, zaleceń lub porad” [24]. Dlatego też sam temat podjęty w niniejszej rozprawie jest ważny i innowacyjny nie tylko z perspektywy naukowej, ale dodatkowo jest potrzebny i wszechobecny z perspektywy biznesowej. Tak jak wspomniano we wstępie rozprawy w obecnym środowisku biznesowym organizacje starają się pracować nad ciągłym ulepszaniem się, aby dostarczać swoim klientom, pracownikom i udziałowcom, coraz lepszą wartość. Ulepszenie te rozumie się poprzez obniżenie kosztów wytworzenia produktu,

usprawnienia czy też uproszczenia procesów produkcyjnych i ostatecznie zwiększenia sprzedaży do klienta ostatecznego. Odpowiedzi na poszukiwane rozwiązania coraz częściej firmy znajdują właśnie w uczeniu maszynowym.



Rys. 2.1.3. Klasyfikacja uczenia maszynowego [19].

Dzięki uczeniu maszynowemu oraz głębokiemu uczeniu wiele firm było w stanie rozwiązać złożone problemy, występujące w rzeczywistych procesach, nie posiadając pełnych informacji na temat analizowanego procesu, obiektu lub systemu, wykorzystując zalety sztucznej inteligencji

Drugi podzbiór sztucznej inteligencji to uczenie głębokie. Temat głębokiego uczenia został podjęty w 2012 roku na konferencji Neural Information Processing Systems (NIPS) i w opublikowanych materiałach pokonferencyjnych autorzy Alex Krizhevsky, Ilya Sutskever i Geoffrey Hinton, w jednym z artykułów, o tytule: ImageNet Classification with Deep Convolutional Neural Network, napisali: „Warto zauważyć, że po usunięciu pojedynczej warstwy konwolucyjnej wydajność sieci obniża się. Na przykład usunięcie dowolnej wewnętrznej warstwy prowadzi do utraty około 2% wydajności sieci. Stąd wniosek, że dla osiągnięcia dobrych wyników bardzo ważna jest głębokość” [25]. W tym przełomowym artykule jednoznacznie podkreślono ważność ilości ukrytych warstw w głębokich sieciach

neuronowych. Autorzy tego artykułu dokładnie omawiają pojęcie warstw konwolucyjnych podkreślając ich znaczenie dla przetwarzania i rozpoznawania obrazów. Samo rozpoznawanie obrazów nadal jest jednym z najbardziej złożonych problemów nauk informatycznych, ponieważ trudno jest przekazać informację maszynie o wszystkich cechach charakteryzujących dany obraz. Zgodnie ze znanym chińskim powiedzeniem „jeden obraz jest wart więcej niż tysiąc słów”. Te niepozorne przysłowie swoją drogą stanowiło skrócony opis metody nauczania zastosowanej przez Abigaila Housena w późnych latach osiemdziesiątych, w której narzędziem do osiągnięcia zamierzonego celu była dyskusja na temat obrazów. Obecnie znany program oparty o tę technikę, to np. Visual Thinking Strategies, w Polsce znany, jako Strategia myślenia Wizualnego. Na szczęście nie musimy opisywać obrazów tysiącami słów, gdyż techniki głębokiego uczenia się a więc głęboka sieć neuronowa sama jest w stanie nauczyć się cech każdego obiektu i dzięki tej wiedzy właściwie je rozpoznawać i klasyfikować [17]. Stwierdzenie te zostało udowodnione w artykule autorstwa H. Lee, R. Grosse, R. Ranganath, A. Ng, pod tytułem: Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations, opublikowanym w materiałach pokonferencyjnych, z konferencji International Conference on Machine Learning w 2009 roku. Autorzy artykułu zaprezentowali sieci neuronowej zdjęcia obiektów z różnych kategorii rzeczy oraz zwierząt. W pierwszej warstwie sieć nauczyła się prostych cech charakterystycznych takich jak kształty krawędzi, linii. W następnej warstwie już wiedziała w jaki sposób wcześniej nauczone krawędzie oraz linie pasują do siebie, dzięki temu była w stanie odtworzyć konkretne obiekty. Artykuł ten potwierdził, że sieć neuronowa w każdej kolejnej warstwie zaczyna rozumieć coraz bardziej skomplikowane cechy [26].

Trzeci ze wspomnianych podzbiorów, (którego dokładna historia powstania i rozwoju zostanie opisana w kolejnym rozdziale), czyli sztuczne sieci neuronowe, zostały odkryte wskutek stworzenia w 1943 roku przez wybitnego matematyka Waltera Pittsa oraz utalentowanego neurofizjologa Warrena McCullocha, pierwszego modelu matematycznego, ludzkiego neuronu biologicznego. W końcu w 1956 roku, spotkanie w Dartmouth, zapoczątkowało oficjalnie nowy dział badań, który nazwano sztuczną inteligencją (nazwa została zaproponowana przez Johna McCarthy’ego, amerykańskiego informatyka i laureata Nagrody Turninga z 1971 r.). Jednym z dziesięciu uczestników tego spotkania był również Allen Newell, amerykański informatyk, który otrzymał wraz z Herbertem Simonem, amerykańskim polihistorem, ekonomistą, informatykiem, Nagrodę Turninga w 1975 roku, za dwudziestoletnie badania nad sztuczną inteligencją i psychologią ludzkiego poznania, które prowadzono głównie na Carnegie Mellon University, w Pittsburghu [27]. Te oraz wiele innych

innowacji w dziedzinie uczenia maszynowego doprowadziły do tworzenia od początku XXI wieku coraz to lepszych, szybszych i bardziej wydajnych maszyn obliczeniowych, nazywanych potocznie superkomputerami, była to swego rodzaju informatyczna „eksplozja kambryjska”. Komputery te są w stanie stale uczyć się i samodzielnie podejmować decyzje, bazując na zdobytym doświadczeniu, dokładnie tak jak ludzie.

2.2. Historia modelowania wykorzystującego Sztuczne Sieci Neuronowe

Tak jak już wspomniano w poprzednim rozdziale historia Sztucznych Sieci Neuronowych sięga 1943 roku, kiedy to Warren S. McCulloch i Walter Pitts stworzyli pierwszy opis matematyczny, uproszczonego schematycznego modelu działania neuronu i przetwarzania przez niego danych, wzorując się na zasadach funkcjonowania ludzkiego mózgu, który jest zdolny do wytwarzania wysokich złożoności, przez wykorzystanie licznych połączeń wzajemnych komórek podstawowych nazywanych neuronami [28]. Stworzony wówczas model, opisując odpowiednią strukturę i naśladując procesy zachodzące w mózgu, który to posiada w swojej strukturze miliardy neuronów połączonych w sieć. W swoich badaniach stworzyli proste neurony, które były zdolne do modelowania opartego na funkcjach logicznych, na przykład: AND, OR itd., w tym opisie natomiast nie było ujętej koncepcji uczenia się sieci. Swoimi badaniami zapoczątkowali szereg kolejnych badań, które skupiały się na problemach modelowania inteligentnych sposobów działania mózgu.

W 1949 roku kanadyjski psycholog Donald Oldigin Hebb rozwinął koncepcję o wzmacnianiu połączeń i współdziałaniu zespołów neuronowych w procesie uczenia się [29]. Opracowany algorytm (nazywany regułą Hebba), czyli reguła uczenia się bez nadzoru, bierze pod uwagę działanie komórek nerwowych, w których połączenie między nimi czyli synapsa, ulega wzmocnieniu, w momencie, kiedy neuron presynaptyczny i postsynaptyczny ulegają równoczesnemu pobudzeniu lub hamowaniu. Dzięki temu algorytm zakłada modyfikację wag poszczególnych neuronów [30]. Ograniczeniami tej metody to zależność przebiegu uczenia od wartości reprezentowanych przez wagi początkowe, nie ma pewności, że zawsze jeden neuron będzie odpowiadał jednej klasie wzorców oraz nie ma pewności, że zawsze wszystkie klasy wzorców będą reprezentowane przez oddzielne zbiory aktywnych neuronów [31]. W 1958 r. John Von Neumann stworzył historyczną pracę teoretyczną, w której wprowadził pomysł uczenia się sieci, które miałyby zastąpić konieczność jej programowania [32]. W tym samym roku Frank Rossenblatt jako pierwszy zbudował działający elektroniczny model ludzkiego mózgu, jako koncepcję systemu złożonego ze sztucznych neuronów, wykazującego zdolność do nabywania wiedzy na podobieństwo ludzi [33]. Proces uczenia się systemu miał przebiegać na

zasadzie rozpoznawania. System ten został nazwany perceptronem, ponieważ zjawisko zdobywania danych i informacji z otoczenia, następnie ich identyfikacja, odpowiednia klasyfikacja i poznanie, w psychologii nosi nazwę percepcji. System nauczony został rozpoznawania znaków alfanumerycznych. Stworzony perceptron wraz ze zwiększającą się ilością pokazów obrazów w procesie uczenia się popełniał coraz mniej błędów. Cały cykl uczenia się trzeba było powtórzyć dwa tysiące razy, co wskazuje na wysoką czasochłonność i pracochłonność badań [34]. Ostatecznie system wykazywał wysoką wrażliwość na transformacje znaków, działał jednak normalnie nawet po uszkodzeniu kilku jednostek. Stworzony system mimo wielu niedoskonałości zainspirował badaczy do dalszych, dynamicznie rozwijających się badań.

W 1960 roku, powstała tzw. struktura pojedynczego elementu liniowego o nazwie Adaline, oparta na modelu Rossenblatta, stworzona przez Bernarda Widrowa ze Stanford University [35]. Adaline był analogowym urządzeniem elektronicznym. Istota modelu neuronu Adaline, skupiała się na sposobie liczenia a dokładniej na korekcie wag, która odbywała się poprzez porównanie oczekiwanej odpowiedzi z potencjałem membranowym neuronu, powodując zmianę we wzorze, który opisuje błąd popełniany przez neuron. Zmiana ta umożliwia zastosowanie gradientowego algorytmu uczenia, który jest oparty o minimalizację funkcji średniokwadratowej, mimo iż neuron wykazuje charakter nieliniowy [36]. Następnie z neuronów Adaline zbudowano sieć jednowarstwową, po dodaniu do niej kolejnych połączonych ze sobą elementów, tworząc sieć o nazwie Madaline (nazwa od słów Many Adaline). W tej sieci każdy neuron uczy się w oparciu o regułę Adaline [36]. Po tym wydarzeniu nastąpił okres frustracji i zniechęcenia, który został spowodowany przez wydarzenia mające miejsce w 1969 roku, kiedy to Marvin Minsky i Seymoura Papert [37], w swojej książce pt. *Perceptrons*, dowiedli, że jednowarstwowe sieci neuronowe typu perceptronu mają bardzo ograniczone zastosowanie i uogólnili je na sieci wielowarstwowe. Zahamowanie badań trwało aż do końca lat osiemdziesiątych, dodatkowym powodem tego spowolnienia były również obcięte fundusze na badania związane z sieciami neuronowymi. Mimo to w latach siedemdziesiątych naukowcy pracowali nad kolejnymi ciekawymi rozwiązaniami, takimi jak: opracowanie i użycie w 1974r. przez Werbosa metody wstecznej propagacji błędu do uczenia sieci neuronowej [38], stworzenie przez F. Kunihiko w 1975 roku sieci do rozpoznawania pisma o nazwie „Cognitron” [39], następnie w 1978 roku rozbudowanej do sieci o nazwie Neocognitron, która była zdolna do odczytu nawet bardzo skomplikowanych znaków takich jak pismo chińskie [40], niezależne opracowanie koncepcji sieci asocjacyjnych „Brain in the Box” w 1977r. przez Andersona i Kohonena [41], stworzenie sieci o nazwie „Cerebellatron” przez

Dawida Mara, oraz stworzenie sieci o nazwie „Avalanche” przez Rossenberga służącej do rozpoznawania mowy. Przełomem w badaniach prowadzonych w temacie sztucznych sieci neuronowych była publikacja poświęcona algorytmowi uczenia wielowarstwowej nieliniowej sieci neuronowej [42], wówczas dowiedziono sensowność używania perceptronów wielowarstwowych w roli klasyfikatorów w warunkach niepewności probabilistycznej [43].

Od początku lat osiemdziesiątych nastąpiło odrodzenie tematu badań, już w 1982 roku Tuwo Kohonen przedstawił opracowanie sieci klasyfikacyjnych niewymagających nauczyciela w procesie uczenia, opierających swoje działanie na odkrywaniu i uzyskiwaniu cech. W połowie lat osiemdziesiątych dwudziestego wieku nastąpił rozwój działalności firm produkujących neuropodobne układy elektroniczne, gdyż rozpoczęto prace nad budową analogowych rozwiązań sprzętowych, między innymi neuroprocesorów. Pomysł Werbosa metody wstecznej propagacji błędu do uczenia sieci neuronowej został rozpowszechniony w 1982 r. i w 1986r. w książce „Learning Internal Representation by Error Propagation” autorstwa Rumelharta, Hinton i Williamsa [44]. Zaproponowana sieć umożliwiała budowę i skuteczne uczenie wielowarstwowych nieliniowych sieci neuronowych wykorzystujących własności sieci z neuronami radialnymi w ukrytej warstwie i stanowiła początek sieci RBF (ang. Radial Basis Function) wykorzystujących lokalną optymalizację w procesie uczenia [34]. Kolejne przełomowe badania prowadzone przez Steve Grossberga i Gail Carpentera, którzy w 1988 wymyślili teorię adaptacyjnych sieci rezonansowych, ART (ang. Adaptive Resonance Theory), bazujących na biologicznych analogiach [45]. W 1987 roku rozpoczęto coroczne międzynarodowe konferencje związane z tematem sztucznych sieci neuronowych organizowane przez Instytut Inżynierów Elektryków i Elektroników, IEEE (od ang. Institute of Electrical and Electronics Engineers). Następnie w 1987 roku powstało międzynarodowe stowarzyszenie - International Neural Network Society (INNS), a w 1988 roku czasopismo INNS Neural Networking journal.

Pod koniec lat dziewięćdziesiątych dwudziestego wieku entuzjazm środowiska naukowego związany z tematem sztucznych sieci neuronowych wygasł, a sieci stały się ustabilizowaną, dobrze znaną technologią. Stało się tak dlatego, że możliwości techniczne związane z technologiami komputerowymi tamtych czasów limitowały ich możliwości rozwoju. Naukowcy aby zaimplementować sieć zdolną do skomplikowanych obliczeń budowali sieci wielowarstwowe, których uczenie wielu warstw i dużej liczby neuronów trwało tygodniami, miesiącami lub latami obliczeń [46]. Przełom nastąpił wraz z rozwojem nowych technologii, w 2006 roku zaczęły pojawiać się głębokie sieci oraz odkrywać metody ich uczenia. Początkowo sieci tego rodzaju wykazywały możliwości generalizacji na bazie niewielkich zbiorów danych

następnie wraz z rozwojem Internetu oraz pojawieniem się elementów obliczeniowych w postaci kart graficznych GPU nurt skierował się na wykorzystywanie wielkich zbiorów danych do obliczeń opartych na wcześniej znanych metodach.

W dzisiejszych czasach w publikacjach można znaleźć przykłady zastosowania sztucznych sieci neuronowych w wielu dziedzinach nauki i techniki w tym procesów odlewniczych, wraz z opisami skomplikowanych problemów, które dzięki ich zastosowaniu można było skutecznie rozwiązać. Jednym z pierwszych głównych i kompleksowych opracowań stworzonych w formie poradnika naukowego była praca Profesora Ryszarda Tadeusiewicza, który opisał główne problemy, które mogą zostać rozwiązane przez implementację sztucznych sieci neuronowych i główne zadania, które mogą zostać powierzone sztucznym sieciom neuronowym. Początek lat dziewięćdziesiątych dwudziestego wieku został uznany za początek badań naukowych nad tematem sztucznych sieci neuronowych w Polsce [47].

2.3. Podstawowe informacje o Sztucznych Sieciach Neuronowych.

Ludzki mózg jest najbardziej złożonym obiektem we Wszechświecie [48]. Waży około 1100 - 1400 gramów, zawiera on trylion komórek, a 100 miliardów spośród nich stanowią neurony połączone w sieci, dzięki którym powstają emocje, świadomość, inteligencja, pamięć i zdolności twórcze. Neuron, inaczej nazywany komórką nerwową, jest zdolny do przetwarzania i przewodzenia informacji zawartej w sygnale elektrycznym oraz do transmisji chemicznej sygnału poprzez pobudzone przez neurotransmitery receptorów. Neuron składa się z ciała komórki tzw. perikarionu oraz aksonu i dendrytów, które umożliwiają przewodzenie informacji [49]. Wzorem do stworzenia mechanizmu sztucznych sieci neuronowych jest neuroplastyczność mózgu, która objawia się w rozwijającym mózgu poprzez dostosowywanie zmian rozwojowych do sygnałów i bodźców płynących ze środowiska zewnętrznego oraz poprzez proces uczenia się. W pełni rozwiniętym mózgu zmiany neuroplastyczne stanowią podstawę procesu uczenia się i zapamiętywania, czyli powstawania nowych obwodów neuronalnych służących śladowi pamięciowemu [48].

Na temat sztucznych sieci neuronowych napisano wiele prac o charakterze przeglądowym oraz popularnonaukowym. W literaturze przedmiotu prezentowane są zróżnicowane podejścia, gdyż przedmiotem badań może być pojedyncza struktura, czyli pojedyncza komórka nerwowa lub jej fragment, na przykład synapsy, aksony, dendryty (rys. 2.3.1.), jak również cała sieć neuronowa, jako samodzielny obiekt badań [47]. Zgodnie z definicją, sztuczna sieć neuronowa jest paradygmatem przetwarzania informacji, inspirowanego przetwarzaniem informacji przez biologiczne systemy nerwowe [50], na przykład w korze mózgowej ssaków tworząc,

uproszczony model funkcjonowania ludzkiego mózgu, a jednocześnie stanowiąc nowoczesną metodę matematycznego modelowania zjawisk i procesów [51].



Rys.2.3.1. Przybliżony wygląd komórki nerwowej [52]

W ciągu ostatnich lat wykorzystanie technik sztucznych sieci neuronowych zyskało duże zainteresowanie i zastosowanie w różnych dziedzinach nauki takich do rozwiązywania skomplikowanych problemów (w rolnictwie, naukach medycznych, edukacji, finansach, zarządzaniu, bezpieczeństwie, handlu, sztuce, architekturze, biznesie, transporcie, bankowości, ubezpieczeniach, zarządzaniu nieruchomościami, marketingu itd.), klasyfikacji, grupowania i rozpoznawania wzorców oraz predykcji [53], stając się konkurencyjnymi dla konwencjonalnych modeli regresyjnych i statystycznych pod względem ich użyteczności [54]. Powody liczego stosowania sztucznych sieci neuronowych wynikają z ich zalet. Ocena zastosowania sztucznych sieci neuronowych może być odniesiona do ich dokładności, wydajności, szybkości przetwarzania, opóźnienia, wartości błędu, skalowalności i kowergencji [55], [56]. W momencie, kiedy istnieje potrzeba opisanie skomplikowanych i złożonych procesów fizycznych, chemicznych z jednoczesną analizą wpływu określonych parametrów na ich przebieg przy użyciu równań odzwierciedlających ich naturę może być trudne i bardzo czasochłonne, dlatego też struktury neuronowe znalazły swoje zastosowanie do modelowania procesów o nieokreślonej naturze fizycznej, nazywanych „czarną skrzynką”. Znaczącym potencjałem sztucznych sieci neuronowych jest również szybkie przetwarzanie wielkich zbiorów danych [57], [58]. Znalazły one liczne zastosowanie również w rozpoznawaniu i analizie obrazu, przetwarzaniu języka i innych, jednak najczęściej są używane do aproksymacji funkcji w paradygmatach numerycznych, ponieważ mają doskonałe właściwości uczenia się, nieliniowości i możliwości uzależnienia wartości wyjściowych od wartości wejściowych [59]. Sztuczne sieci neuronowe ustanawiają więc związek między wieloma wektorami wejściowymi

$(x_1, x_2, \dots, x_n)$, a po jego przetworzeniu zmienną lub zmiennymi wyjściowymi $(y_1, y_2, \dots, y_n)$, wynikającymi z danych zmiennych wejściowych, co można przedstawić w następujący sposób (2.1.) [42]:

$$\begin{aligned} y_1 &= j(x_1, x_2, \dots, x_n) \\ y_2 &= j(x_1, x_2, \dots, x_n) \end{aligned} \quad (2.1)$$


gdzie:

- $y_1, y_2, \dots, y_n$ – wartości zmiennych wyjściowych
- $x_1, x_2, \dots, x_n$ – wartości zmiennych wejściowych
- j – funkcja aktywacji

Jak już wspomniano neuron otrzymuje pewną liczbę sygnałów nazywanych wartościami wejściowymi. Wartości te mogą pochodzić z pierwotnych danych zewnętrznych kierowanych do sieci obliczeń, mogą jednak też pochodzić z wartości wyjściowych innych neuronów tworzących daną sieć, wówczas są to tzw. sygnały pośrednie [60]. Każda wartość wejściowa kierowana do neuronu ma określone znaczenie, nazywane wagą. Odwołując się do inspiracji biologicznej, wagi są odpowiednikami synaps z neuronu biologicznego. W biologii synapsy są miejscem komunikacji między dwoma neuronami (presynaptycznym, czyli nadawczym i postsynaptycznym, czyli odbierającym) lub między neuronem a komórką docelową [61], [62]. W sztucznych sieciach neuronowych synapsy sprowadzane są do operatorów przemnażania wejściowych sygnałów przez współczynniki ustalone w procesie uczenia się sieci. Początkowo wagi są dobierane losowo, następnie następuje ich wielokrotna korekta w procesie uczenia się sieci. Wspomniane korygowanie można przeprowadzić poprzez porównywanie znanych, rzeczywistych, zaobserwowanych, lub doświadczalnie wyznaczonych wartości wyjściowych z tymi obliczonymi przez sieć. Dzieje się tak w jednej z podstawowych metod uczenia się sieci, nazywanej metodą z nauczycielem, czyli metodą uczenia nadzorowanego (ang. supervised learning). W metodzie tej dąży się do osiągnięcia minimalnej wartości funkcji kryterialnej, którą jest suma kwadratów różnic między wartościami otrzymanymi przez sieć w procesie uczenia się z tymi pochodzącymi z rzeczywistego procesu. Celem minimalizacji tej wartości stosuje się gradientową metodę największego spadku. Modyfikacja wielokrotna wag daje nauczoną sieć zdolną do prognozowania wartości wyjściowych na podstawie dowolnych wprowadzonych wartości wejściowych. Znane jest również pojęcie funkcji błędu, służącej do oceny jakości sieci neuronowej podczas jej iteracyjnego uczenia się lub podczas późniejszych

etapów analizy. W algorytmach uczących się iteracyjnie podstawowym narzędziem do modyfikacji wag jest pochodna funkcji błędu [63].

Podsumowując podstawowe elementy neuronu to: wagi ($w_1, w_2, \dots, w_n$), funkcja aktywacji i funkcja wewnętrznego przetwarzania. Ustalenie wartości sygnału wyjściowego z neuronu jest prowadzone najpierw przez przemnożenie sygnałów wejściowych ($x_1, x_2, \dots, x_n$) przez odpowiadające im wagi i poddanie zadanej funkcji (etap nazywany funkcją wewnętrznego przetwarzania), następnie wynik funkcji wewnętrznego przetwarzania e , poddany zostaje działaniu określonej funkcji wejścia-wyjścia, zwanej funkcją aktywacji φ (rys.2.3.2.). Funkcje aktywacji sztucznej sieci neuronowej, to równania matematyczne, które określają moc wyjściową sieci neuronowej, są one kluczowym elementem algorytmów uczenia się. Określają one wyniki modelu, jego dokładność i wydajność obliczeniową, jednocześnie wpływając na zdolność sieci neuronowej do konwergencji, lub jej zapobieżenia.



Rys.2.3.2. Model neuronu [52]

Sygnał wyjściowy pojedynczego neuronu może być obliczany według następującego równania (2.2.) [52]:

$$y = \varphi\left(\sum_{i=1}^n w_i x_i\right) = \varphi(W \cdot X) \quad (2.2.)$$

gdzie:


- X – wektor danych wejściowych
- W – wektor wag
- φ – funkcja aktywacji
- y – sygnał wyjściowy

Naukowcy, którzy poświęcili lata na badania neuronów, odkryli ponad tysiąc różnych typów neuronów biologicznych, dlatego istnieje potrzeba aby umieć zamodelować co najmniej kilka

różnych typów sztucznych sieci neuronowych [64]. Można to zrobić wykorzystując różne typy funkcji aktywacji, określonych na wewnętrznym stanie neuronu, o aktywacji obliczonej na podstawie wejść wszystkich neuronów wejściowych. Najczęściej używane funkcje aktywacji definiujące wyjście neuronu, to:

- funkcja liniowa, pobiera dane wejściowe pomnożone przez wagi i tworzy sygnał wyjściowy proporcjonalny do sygnału wejściowego. Funkcja liniowa posiada przewagę nad funkcją progową, ponieważ umożliwia powstanie wielu wyjść.
- funkcja tangens hiperboliczny (zwana też tangensoidalna), druga najczęściej stosowana funkcja,
- funkcja logistyczna (nazywana też logistycznym sigmoidem), często stosowana, przekazuje wartość w przedziale od 0 do 1, możliwa do interpolacji stochastycznej jako prawdopodobieństwo uaktywnienia neuronu,
- funkcja tożsamości, przekazująca wartość aktywacji,
- funkcja progowa aktywacji, oparta jest na wartości progowej, oznacza to, iż w przypadku, gdy wartość wejściowa jest powyżej lub poniżej pewnego progu, to neuron zostaje aktywowany i wysyła dokładnie ten sam sygnał do następnej warstwy,
- funkcja sigmoid bipolarny (wersja sigmoidu logistycznego o wartościach w przedziale od (-1 do 1)).
- Funkcję ReLU (od ang. Rectifier Linear Unit), (nazywaną też rektyfikatorem), stanowi kombinację funkcji tożsamości z funkcją progową [17].

Jeżeli sieć miałaby nauczyć się złożonych zestawów danych z wysoką dokładnością niezbędne może być zastosowanie kilku ukrytych warstw neuronów (ang. input hidden layer) (rys. 2.3.3), natomiast sieć z jedną warstwą ukrytą powinna nauczyć się rozwiązywać podstawowe problemy, zastosowanie zbyt wielu warstw może spowodować pogorszenie jakości uczenia się sieci, gdyż poświęci się ona zbyt wielu szczegółom.



Rys.2.3.3. Schemat ukrytych warstw neuronów i przykładowa lokalizacja funkcji aktywacji [opracowanie własne]

W literaturze przedmiotu w omawianej dziedzinie nauki i techniki związanej z zagadnieniami metalurgicznymi sieć najczęściej ma strukturę wielowarstwową, zawierającą warstwy wejściowe i wyjściowe a między nimi jedną lub kilka warstw ukrytych. Natomiast najczęściej używane techniki uczenia sieci to aproksymacja funkcji wielu zmiennych. Odnosząc się jednak dokładniej do tematu modelowania zagadnień wytwarzania w procesach odlewniczych sztuczne sieci neuronowe dotychczas stosowano do: analizy wpływu różnych parametrów procesu na poziom porowatości odlewu [65], analizy wytrzymałości na rozciąganie [66], sterowania jakością mas formierskich [67], prognozowania parametrów mas formierskich [68], [69], jak również do projektowania oprzyrządowania odlewniczego, sterowania pracą pieców do topienia metalu i innych. Główne zalety sztucznych sieci neuronowych, wpływające na ich liczne wykorzystanie do modelowania złożonych procesów i zjawisk, to:

- zdolność do odwzorowania złożonych, nieliniowych procesów z dużą ilością zmiennych niezależnych z jednoczesną kontrolą wielowymiarowości procesów i danych, nawet takich procesów, które są niealgorytmizowane, w tym w procesów odlewniczych, czy ogólnie procesów metalurgicznych [69].
- kolektywność (masowa współbieżność) obliczeń, czyli wykonywanie równocześnie przydzielonych zadań przez tysiące sztucznych neuronów w sztucznych sieciach neuronowych,

- samouczenie się sieci, niewymagających programowania, co pozwala na skuteczne działanie bez konieczności formułowania hipotez i znajomości skomplikowanych zależności i mechanizmów danego zjawiska,
- adaptacyjność, czyli nauka na podstawie przedstawionych przykładów,
- zdolność do generalizacji, czyli możliwość pracy sieci na przykładach, których wcześniej nie przetwarzała, co pozwala na prognozy bazujące na zjawiskach, które nigdy wcześniej nie wystąpiły,
- konieczność znajomości podstaw procesu przez twórcę sieci celem selekcji istotnych zmiennych niezależnych mających wpływ na zmienną zależną aby właściwie modelować procesy i dobrać właściwy rodzaj i strukturę sztucznej sieci neuronowej,
- zdolność do przechowywania informacji w sieci neuronowej, a nie w bazie danych, co nie zaburza funkcjonowania sieci,
- zdolność do rozumienia zależności, gdy dane są niekompletne lub zawierają błędy [69].

Wspomniane cechy w znaczny sposób wpłynęły również na wykorzystanie sztucznych sieci neuronowych do realizacji niniejszej pracy.

2.4. Działanie Sztucznych Sieci Neuronowych.

Na przestrzeni wielu lat najpowszechniej stosowaną techniką modelowania matematycznego, do opisywania rzeczywistości w języku matematyki i logiki formalnej, którego algorytmy zapewniały osiągnięcie globalnego minimum funkcji błędu [70], były modele funkcyjne liniowe (w postaci funkcji liniowej) [71]. W zakresie tego typu modeli znane były strategie optymalizacji podczas ich budowy, jednak często zastosowanie aproksymacji liniowej celem opisanie określonego problemu czy zjawiska nie miało podstaw i prowadziło do wniosku o braku możliwości opisu danego problemu czy zjawiska w postaci matematycznej [72], ewentualne zastosowanie modeli liniowych do opisu zjawisk nieliniowych spowoduje duże niedoskonałości w opisie danego procesu lub zjawiska. W związku z tym, celem opisu tych zjawisk używa się modeli nieliniowych, co wiąże się z koniecznością określenia kształtu modelu i doбором parametrów najlepiej określających dany proces, lub zjawisko. Określenie kształtu modelu ma charakter intuicyjny i wpływa na jakość predykcji modelu, ponieważ w przypadku błędnie dobranego modelu, nie ma późniejszej możliwości jego właściwej optymalizacji. W przypadku doboru parametrów można zastosować metody statystyczne, które uprzednio zoptymalizują parametry do wybranego kształtu modelu, na przykład można użyć

do tego regresji nieliniowej. W tym momencie warto odwołać się do sztucznych sieci neuronowych, które umożliwiają szybkie i wygodne modelowanie [43] procesów, z dużym prawdopodobieństwem odniesienia sukcesu w problemach związanych z tworzeniem modeli matematycznych, celem odwzorowania złożonych zależności występujących między zmiennymi wejściowymi i wyjściowymi [73], gdyż mają one zdolność do samodzielnego znajdowania modelu nieliniowego bez potrzeby uprzedniego określania jego kształtu co wpływa na zmniejszenie ryzyka popełnienia błędu na początku modelowania.

Dotychczasowe prace doświadczalne w dziedzinie metalurgii i odlewnictwa w większości wykorzystywały modelowanie oparte na danych, z użyciem sztucznych sieci neuronowych do regresji, czyli aproksymacji nieznanej funkcji wielu zmiennych bazując na danych doświadczalnych, do wykrywania wzorców, grupując sygnały podczas uczenia nienadzorowanego, niewymagającego zbioru uczącego z wejściem i wyjściem, do predykcji, czyli przewidywania wyniku bazując na danych historycznych lub wcześniejszych obserwacjach doświadczalnych [74]. Chciano więc uzyskać jak największą zgodność modelowanego zjawiska z działaniem modelu neuronowego. Sprawdzano dzięki temu również wpływ badanego problemu lub zjawiska na określone parametry, czynniki, których nie było możliwości osiągnięcia w doświadczeniu w prosty sposób, bez zmieniania pozostałych czynników czy parametrów. Oryginalnym podejściem okazało się użycie modeli neuronowych do ekstrakcji wiedzy z danych i uzupełnienie brakującej wiedzy o mało znanym skomplikowanym procesie lub o całkiem nowym zjawisku. Przykładem może być praca [75], w której autorzy wykorzystali miękkie techniki obliczeniowe, w tym sztuczne sieci neuronowe do ekstrakcji wiedzy z danych dotyczących właściwości termomechanicznie przetwarzanej stali wysokowytrzymałej. Badania ukierunkowano na lepsze zrozumienie procesu metalurgicznego przetwarzanej stali i potwierdzono uzyskane informacje z istniejącymi koncepcjami fizycznej metalurgii stali. Udowodniono więc, że sztuczne sieci neuronowe są w stanie potwierdzić niektóre z hipotez wygenerowanych na drodze eksperymentalnej i mogą być wykorzystane do projektowania systemów o lepszych parametrach dostosowanych do potrzeb użytkownika.

Dotychczasowy opis uwydatniał pozytywne cechy modelowania opartego na danych, z użyciem sztucznych sieci neuronowych, jednak należałoby jeszcze rozważyć wady ich działania, a są to między innymi:

- uzależnienie prędkości i jakości przetwarzania od parametrów procesorów sprzętowych, gdyż wymagają one procesorów o odpowiedniej mocy obliczeniowej,

- niewyjaśniona przyczyna źródłowa zachowania się sieci, gdyż podane przez sieć rozwiązanie sondujące, bez uzasadnienia dlaczego zostało wybrane może powodować brak zaufania do jej wyboru,
- brak jednej, sprawdzonej i najlepszej struktury sieci neuronowej, co powoduje konieczność znajomości struktur i ich możliwości oraz doświadczenia, lub po prostu wielu prób i analiz,
- trudność przedstawienia dokładnego problemu sieci neuronowej, gdyż sztuczne sieci neuronowe pracują z danymi numerycznymi, więc należy przetłumaczyć dany problem na wartości liczbowe,
- czas pracy sztucznej sieci neuronowej jest nieznany, gdyż sieć zawsze będzie szukać odpowiedniej wartości błędu na określonej próbce. Osiągnięcie tej wartości będzie dla sieci sygnałem do zakończenia pracy. Możliwe, że te wartości nie są jeszcze wartościami optymalnymi [76],
- brak umiejętności rozwiązania wszystkich skomplikowanych problemów, gdyż sieć nie posiada żadnej reguły prognozującej wartość potrzebnej zmiennej, dlatego też wymagana jest specjalistyczna wiedza procesowa celem właściwego doboru zmiennych wejściowych i wyjściowych umożliwiających wyszukanie istniejących zależności,
- konieczność występowania zależności, relacji lub prawidłowości w danych. Sieć może zidentyfikować nawet ukryte lub mało precyzyjne informacje, jeżeli zbiór uczący będzie odpowiednio duży a zależności będą mały charakter powtarzalny. Ponadto sieć zidentyfikuje występujące zakłócenia w danych i dopasuje się do uogólnionych trendów występujących w zbiorze uczącym,
- trudność uczenia się ze zbioru danych, w których występuje problem silnego nie zrównoważenia danych, z małą reprezentacją wartości, które chcemy prognozować (zauważono w toku badań),
- brak pewności czy znaleziony stopień dopasowania modelu jest optymalny (nawet w przypadku osiągnięcia minimalnego błędu uczenia sieci) w przypadku modelowania nieliniowej charakterystyki przebiegu.


Sztuczne sieci neuronowe rozwijają się bardzo szybko. Należy więc pamiętać, że wady sztucznych sieci neuronowych, napotymane w procesie ich stosowania są stale eliminowane, a jednocześnie następuje wzrost odkrywanych ich zalet. Może być to podstawa do stwierdzenia, że staną się one niebawem nieodłączną częścią naszego życia [76].

2.5. Wybór struktury i rodzaju sieci neuronowych oraz sposobu ich uczenia.

Obecnie istnieje wiele rodzajów sieci neuronowych, zróżnicowanych pod względem struktury i zasad ich działania. Pojedyncze sztuczne neurony posiadają ograniczone możliwości, dlatego też są one łączone w sieci, co gwałtownie podnosi ich rzeczywistą moc obliczeniową, która wynika z jednoczesnej pracy wielu neuronów, tworzących różnorodne architektury (struktury). W związku z tym rozróżnia się sieci jednokierunkowe (ang. feedforward) (jednowarstwowe i wielowarstwowe), sieci rekurencyjne, sieci komórkowe [77], sieci radialne (RBF), sieci GRNN oraz sieci probabilistyczne (PNN). W pierwszym rodzaju struktury do sieci jest dostarczana porcja danych, które rozchodzą się w sieci neuronowej, między neuronami zdolnymi do uczenia się. Sieć wewnątrz opracowuje charakterystyki, dzięki którym definiowane są zmienne wyjściowe [70]. Sieci jednokierunkowe charakteryzują się istnieniem połączeń między neuronami znajdującymi się w sąsiednich warstwach, gdyż mogą składać się z wielu warstw, a informacje przepływają w jednym kierunku. Drugi typ struktury to sieci rekurencyjne, w których następuje przepływ informacji w dwóch kierunkach, sprzężenie zwrotne oraz występują w ich pracy przebiegi dynamiczne [77]. Przykładami sieci rekurencyjnych są sieci Hopfielda (znane z tzw. „Problemu Komiwojażera” [78], czyli rozpoznawania obrazów z dziedziny medycyny), maszyna Boltzman, sieci BAM (Bidirectional Associative Memory), oraz sieci ART (Adaptive Resonance Theory). Trzeci typ struktury, czyli sieci komórkowe, w których każda komórka połączona jest ze wszystkimi neuronami, które znajdują się w jej sąsiedztwie, jednocześnie wszystkie neurony posiadają taką samą funkcję aktywacji. Kolejne struktury to sieci radialne (RBF), mające dwuwarstwową strukturę, w tym warstwę ukrytą realizującą, przez neurony radialne funkcję bazową, odwzorowującą liniowo. Zastosowanie ich zamiast sieci MLP (opisanej dokładniej poniżej) spowoduje, że sieć neuronowa odnajdzie aproksymację, która będzie lepiej dopasowana, do lokalnych właściwości zbioru danych ale będzie miała gorszą zdolność do ekstrapolacji, ponadto sieć ta wykazuje nadmierną wrażliwość na nawet najmniejsze błędy w danych [79], co w przypadku modelowania procesów odlewniczych stanowiłoby duży problem. Kolejna struktura to sieci uogólnione GRNN (ang. Generalized Regression Neural Network) sieć neuronowa realizująca regresję uogólnioną, gdzie liczba neuronów radialnych jest równa liczbie punktów uczących [80]. Ostatnie z omawianych to sieci probabilistyczne PNN (ang. Probabilistic Neural Network), które służą do klasyfikacji danych, na podstawie funkcji decyzyjnej. Sieć ta składa się z minimum trzech warstw: wejściowej, radialnej i wyjściowej. Warstwa radialna zawiera neurony radialne, które reprezentują funkcję radialną z centrum nad

swoim przypadkiem uczącym. Warstwa ta zawiera tyle neuronów ile wzorców znajduje się w ciągu uczącym [81]. Należałoby wspomnieć, że jedną z najbardziej popularnych struktur sztucznych sieci neuronowych są jednokierunkowe sieci liniowe, stanowiące najprostszy model neuronowy, w których funkcja aproksymująca stanowi hiperpłaszczyznę, dodatkowo optymalizacja takiego modelu jest uproszczona i polega na znalezieniu pochylenia i położenia.


Najpopularniejsza architektura sieciowa wiąże się z koncepcją sieci jednokierunkowej a dokładniej perceptronem wielowarstwowym [82], [83]. Sieć jednokierunkowa wielowarstwowa jest najczęściej wykorzystywana do modelowania procesów technologicznych [74]. Wspomniany perceptron wielowarstwowy (ang. Multilayer Perceptron, klasy MLP), to sieć składająca się z neuronów ułożonych w warstwy (rys. 2.5.1.).



Rys. 2.5.1. Schemat perceptronu wielowarstwowego [84]

Posiada warstwę wejściową, w której neurony obliczają ważoną sumę swoich wejść, która następnie staje się argumentem funkcji przejścia celem obliczenia w kolejnej warstwie wyjścia neuronu, warstwy ukrytej i warstwę wyjściową. W warstwie ukrytej najczęściej znajdują się neurony McCullocha-Pittsa. Określenie właściwej liczby warstw ukrytych oraz liczby neuronów ukrytych w poszczególnych warstwach jest problemem ogólnym i swego rodzaju wyzwaniem dla twórcy sieci. Sygnały czy informacje w tej sieci przesyłane są w jednym kierunku od wejścia do wyjścia, bez żadnych sprzężeń zwrotnych. Parametrami sieci są wartości progowe i wagi. Istnieje możliwość modelowania w oparciu o różne funkcje, z dowolnym stopniem złożoności przy użyciu tych sieci, jednak ważne jest aby właściwie dobrać ich strukturę, która wpływa na ostateczną jakość prognozy, czyli jakość modelu. Należałoby więc znaleźć prostą strukturę generującą wyniki na pożądanym poziomie jakości. Jak wspomniano wcześniej prosty model (zawierający małą liczbę neuronów ukrytych i małą liczbę warstw ukrytych) powinien być w stanie rozwiązać podstawowe problemy, jednak może on zbyt ogólnie opisać pewne złożone zależności. Z drugiej strony złożony model (zawierający

dużą liczbę warstw ukrytych i wiele neuronów ukrytych w tych warstwach) powoduje dłuższy proces uczenia się sieci i może wykazywać skłonności do nadmiernego dopasowania się do danych. Sztuczne sieci neuronowe są stosowane aby po nauczaniu się rozwiązywać zadania podobne do tych do których była uczona (jednak nie identyczne z nimi). Przenoszenie zdobytej wiedzy do rozwiązywania nowych przypadków nazywa się generalizacją. Głównym zagrożeniem dla zdolności sieci do generalizacji jest jej przeuczenie, występujące wskutek nadmiernego dopasowania do mniej istotnych szczegółów, niemających znaczenia w rozwiązaniu danego problemu. Taki przewymiarowany model ma skłonności do uczenia się danych ze zbioru uczącego na pamięć. Celem kontroli tego problemu tworzy się zbiory walidacyjne [85] (rys.2.5.2.).




Rys. 2.5.2. Porównanie wykresów sieci zachowującej zdolność do generalizacji i sieci z utraconą zdolnością do generalizacji [85].

W publikacji [86], stwierdzono iż badania wskazują, że nie ma uzasadnienia do zastosowania więcej niż jednej warstwy ukrytej, ponieważ nie wpływa ona na zwiększenie jakości wyniku, a jedynie komplikuje model. Obecnie istnieje wiele teorii dotyczących sposobów doboru struktur sieci, jednak można podsumować, iż do każdego rozpatrywanego problemu, czy przypadku, powinno się podejść indywidualnie i dobrać właściwe parametry w oparciu o badania. Posłużyć do tego może procedura walidacji krzyżowej lub podzielenie zbiorów danych na dwa zbiory trenujący (służy do korygowania wag sieci) i testowy (służy do bieżących obliczeń błędu dla innych danych aby sprawdzić zdolność danej sieci do generalizacji), następnie porównać wyniki prognoz dla różnych struktur dla zbioru testowego a po trenowaniu sieci dla zbioru trenującego. Problem właściwego doboru struktury dotyczy również niniejszej rozprawy doktorskiej i wpłynął w znacznym stopniu na realizację badań, podczas których dobierano indywidualne plany badań dla każdego badanego zbioru danych doświadczalnych pochodzących z rzeczywistego procesu. Należy jednak pamiętać, że dane


procesowe (szczególnie pochodzące z odlewni) mogą posiadać niedobory danych. Trudno jest również wybrać z nich zbiór danych najlepszych jakościowo, aby wytypować dane do zbiorów walidujących i testujących. Dlatego też często pomija się te zbiory w procesie uczenia się sieci jeżeli nie ma konieczności ich tworzenia. Jednak w niniejszej rozprawie sprawdzono również jakość prognoz dla modeli zawierających zbiór walidujący i testujący. Podczas uczenia należy również prowadzić stale obserwacje stopnia dopasowania zbioru danych uczących i walidujących sztucznej sieci neuronowej, aby nie pozwolić na nadmierne jej przeuczenie.

Proces uczenia sieci typu MLP możliwy jest poprzez zastosowanie metody wstecznej propagacji błędów (ang. Backpropagation), polegającej na uczeniu się poprzez propagację różnicy między otrzymanym sygnałem na wyjściu sieci a oczekiwanym [85] (rys. 2.5.3).



Rys. 2.5.3. Przykładowy przebieg korekt błędów sieci w kolejnych iteracjach [69]

Celem całego procesu uczenia się sieci jest poznanie ukrytej wiedzy znajdującej się w danych, czyli pewnych szczegółowych informacji a następnie dzięki temu możliwość rozwiązania problemów czy zadań podobnych do tych, przedstawionych sieci w procesie jej uczenia się, czyli wnioskowanie o ogólnych prawidłowościach. Dlatego też jak wcześniej wspomniano proces uczenia sieci neuronowej to w istocie proces minimalizacji funkcji błędu. Podczas tej minimalizacji jest niestety szansa, że otrzymane zostanie minimum lokalne, zamiast minimum globalnego, więc sieć będzie błędnie aproksymować dane wyjściowe (rys. 2.5.4.) [85], [87], [88].



Rys. 2.5.4. Minimum globalne i minima lokalne [48]


Celem zapobieżenia błędnemu określeniu minimum funkcji błędu wykonywana jest optymalizacja funkcji wielu zmiennych (czyli równej liczbie wag synaps i wyrazów wolnych). Należy znaleźć odpowiednie wartości wag sprawiających, że wartość średniokwadratowego błędu E dla wszystkich odpowiedzi sieci była mniejsza w stosunku do obserwacji doświadczalnych (2.3). Każdorazowe obliczenie błędu i modyfikacja wag nazywana jest epoką [69].

$$E = \frac{1}{p} \cdot \sum_{k=1}^p \left(\frac{1}{m} \cdot \sum_{j=1}^m (d_{kj} - Y_{kj})^2 \right) \quad (2.3)$$


gdzie:

- E – wartość błędu średniokwadratowego
- m – liczba wyjść sieci
- p – liczba prezentacji, czyli rekordów obserwacji doświadczalnych
- d – wartości doświadczalne
- Y – wartości otrzymane z sieci

Optymalizację można wykonać przy pomocy różnych metod, przykładowo może się to odbyć poprzez wykorzystanie algorytmu genetycznego [85], metod gradientowych (najczęściej stosowanych), w których koryguje się wcześniej ustalony zbiór wartości wag (rys. 2.5.5.), dążąc do zmniejszenia błędu sieci i metod poszukujących minimum globalne błędu (rzadko stosowane) np. metodę wyżarzania symulowanego (rys. 2.5.6.) i metody ewolucyjne [87].



Rys. 2.5.5. Ilustracja metod gradientowych [69]



Rys. 2.5.6. Ilustracja metod wyżarzania symulowanego [69]

Kolejnym problemem jest decyzja kiedy zakończyć trenowanie sieci. Można przyjąć, że koniec procesu uczenia sieci następuje, gdy zaczyna wzrastać wartość błędu dla danych weryfikujących. Głównie dlatego aby nie dopuścić do wspomnianego nadmiernego dopasowania się sieci neuronowej do danych uczących, co spowodowałoby brak zdolności do generalizacji, czyli prognoz dla innych danych. Jest to bardzo ważne, ponieważ jak już wspomniano jednym z głównych zadań sztucznych sieci neuronowych jest nauka wzorców i przewidywanie na podstawie danych, których sieć wcześniej nie widziała.

Perceptron wielowarstwowy MLP ze względu na najszerszej stosowaną sieć neuronową, wykorzystywaną przez większość badaczy [89], jednocześnie ocenianą jako najbardziej właściwą do rozwiązywania problemów związanych z odlewnictwem [42], stanowi jedyną strukturę użytą do badań prowadzonych w ramach niniejszej rozprawy.

Sztuczne sieci neuronowe zostały stworzone do realizacji paru rodzajów zadań, z których do modelowania procesów produkcyjnych w tym odlewniczych wykorzystywane są do zadań, takich jak klasyfikacja, regresja, predykcja i wykrywanie wzorców [69]. Klasyfikacja polega na dopasowaniu do odpowiednich klas, przypadków reprezentowanych przez dane. Zadania klasyfikacji najczęściej realizuje się przy uczeniu bez nauczyciela, czyli bez wartości wyjściowych, które są wykorzystywane w metodach uczenia opisywanych powyżej. Klasyfikacja realizowana jest przez wykorzystanie nominalnej zmiennej wyjściowej, dla której wartości odpowiadają danym klasom, do których można przyporządkować wartości wejściowe. Regresja, inaczej nazywana aproksymacją (nieznanej) funkcji wielu zmiennych bazująca na obserwacjach doświadczalnych wykorzystywana jest do określenia wartości ciągłej zmiennej wyjściowej w oparciu o posiadane wartości zmiennych wejściowych [69]. Jako rozwiązanie sieć podaje konkretną wartość, co wiąże się z późniejszym skalowaniem i ekstrapolacją. Skalowanie, może być wykonane poprzez normalizację danych wejściowych i wyjściowych, czyli umieszczenie ich w jednym przedziale np. od 0 do 1. Niestety w momencie kiedy dane

zostaną poddane skalowaniu nie będzie możliwości ekstrapolowania wykresu ciągłej wartości wyjściowej poza zakres danych uczących. Sieć może rozwiązać takie zadanie, jednak pod wpływem nasycenia. Mimo różnych metod radzenia sobie z tym zjawiskiem [88], ogólnie przyjęta zasada mówi, że ekstrapolacja nie powinna wykraczać poza odpowiednią odległość [42]. Kolejne z głównych zadań sieci to predykcja, czyli zdolność do przewidzenia, czy prognozy przyszłych wartości lub zachowań systemu określone w oparciu o wartości historyczne z ciągłą adaptacją wag. Ostatnie czyli wykrywanie wzorców, które jest uczeniem nienadzorowanym, niewymagającym zbioru uczącego składającego się z danych wejściowych i doświadczalnych danych wyjściowych. Wykrywanie wzorców umożliwia zgrupowanie sygnałów charakteryzujących podobne cechy (np. sieci typu Kohonena) [69].

W niniejszej rozprawie doktorskiej głównym zadaniem sztucznych sieci neuronowych będzie predykcja wartości wyjściowych oraz dalsza analiza wyników celem ustalenia wpływu zmiennych wejściowych na wartości zmiennej wyjściowej. Jak wcześniej wspomniano badania zostaną oparte na strukturze MLP, rekomendowanej przez wielu autorów do zadań związanych z wytwarzaniem, a dokładniej odlewnictwem.

2.6. Metodyka gromadzenia i przygotowania danych do zaawansowanego modelowania

Nadrzędny cel wszelkiej nauki to poznawanie, rozumienie i wyjaśnianie czy opisywanie świata. Otaczająca nas rzeczywistość jest jednak zbyt skomplikowana, aby mogła zostać opisana z najwyższą dokładnością, unikając uogólnień czy przybliżeń. Dlatego też celem zbudowania jak najdokładniejszego opisu uwzględnia się aspekty, które mają najwyższy wpływ na określone zjawisko. Pozostałe czynniki mogą wówczas zostać pominięte. Faza wyabstrahowania istotnych czynników i pominięcia tych nieistotnych z punktu widzenia danego zjawiska okazuje się być najważniejszą fazą poznania danego zjawiska. Ważne dlatego jest poznanie pewnych zasad i mechanizmów wpływających na określony obiekt badań, czyli stworzenie swego rodzaju modelu [90], który będzie stanowił reprezentację konceptualną lub umysłową, określonego systemu formalnego lub aksjomatycznego, spełniającą wszystkie jego formuły matematyczne, czy reguły służące do jego opisania. Modele te mogą być nazywane modelami matematycznymi [91]. Odnosząc się do definicji modelu możemy podsumować, że modelowaniem nazywamy proces tworzenia reprezentacji danego zjawiska, czy systemu. Odpowiednia adekwatność modelu związana jest bezpośrednio z jego jakością [90].

Opisywany proces tworzenia reprezentacji danego zjawiska ma swoje odzwierciedlenie w opartym na danych modelowaniu, przyczyn powstawania wad wyrobów, gdyż na początku

tworzenia modelu ważne jest, aby przeanalizować następujące elementy. Po pierwsze należy określić strategię tworzenia zbiorów uczących oraz parametry produkcji i właściwości wyrobu czy materiały użyte do jego produkcji decydujące o powstawaniu wady wyrobu. Istotną trudnością jest pozyskanie tych informacji, gdyż nie zawsze są one zawarte w instrukcjach technologicznych, czy ogólnie w istniejącej dokumentacji stanowiskowej. Na tej podstawie następnie należy wybrać jedynie istotne parametry mające albo mogące mieć duży wpływ na powstawanie wady wyrobu.

Kolejnym ważnym elementem jest podjęcie decyzji, które wartości traktować jako zmienne zależne (wynikowe, czyli sygnały wyjściowe), a które jako zmienne niezależne (sygnały wejściowe). Istotnym zadaniem pojawiającym się w niniejszej rozprawie jest otrzymanie dokładnego odwzorowania relacji bodziec reakcja, czyli relacji wejście wyjście dla modelowanego procesu, bez szczegółowego wyjaśniania jego właściwości. Modele takie jak już wspomniano w poprzednich rozdziałach nazywamy modelami typu czarnej skrzynki (ang. black-box). Podejście tego typu umożliwi odpowiednie zasymulowanie procesu, celem otrzymania przewidzianego stanu wyrobu (informację, czy dany wyrób posiada wadę, czy nie), jednak nie proponuje doboru parametrów technologicznych, celem uzyskania wyrobu o określonych właściwościach. Dlatego też praktykuje się wykorzystanie jako wartości wejściowych właściwości wyrobów oraz jako wartości wyjściowe, wynikowe parametry procesu należne do zastosowania. Tego typu plan modelowania oparty na danych, znajdzie swoje zastosowanie przykładowo w ustalaniu koniecznej ilości dodatków odświeżających do mas formierskich, kiedy znany jest jej aktualny skład oraz właściwości [42]. Warto zauważyć, że nie wszystkie wskazania sieci będą możliwe do wprowadzenia, gdyż czasami nie ma możliwości zmiany danych parametrów albo zmiany ilości użytych surowców, wtedy modelowanie procesu tego rodzaju nie jest uzasadnione. Przykładowo w procesie wytopu wpływ na skład chemiczny kąpieli może być ograniczony, w zależności od materiałów wsadowych. Uzasadnione wtedy jest stworzenie sieci według pierwszego podejścia i dodatkowo celem uzyskania dodatkowych informacji o parametrach procesu należy przeprowadzić symulację wielokrotnego odpytywania sieci. Optymalizacja wartości wejściowych do sztucznych sieci neuronowych w określonych przez użytkownika zakresach, jest możliwa dzięki wybranym programom komputerowym, na przykład za pomocą dodatku Solver, do programu Microsoft Excel, które zostało wykorzystane i opisane w kolejnych rozdziałach niniejszej rozprawy.

Gromadzenie danych przemysłowych, w tym przypadku danych dotyczących procesu odlewania jest znaczną trudnością. Warto zauważyć, że dane przemysłowe mają swoją

specyfikę i można je odróżnić od innych danych pochodzących z różnych obszarów badań i zastosowań naukowych. Dane te posiadają swoje cechy, których jednoczesne współwystępowanie jednoznacznie wyróżnia tego typu dane od innych. Istotna cecha danych przemysłowych, to ich objętość, gdyż zawierają one nie tylko dużą liczbę obserwacji ale też dużo parametrów charakteryzujących pojedynczą obserwację [90]. Przykładowo dla maszyn wyposażonych w systemy typu SCADA zbiory danych przemysłowych zawierają miliony rekordów. Jeżeli dodatkowo rozpatrzymy proces tworzenia zaawansowanego produktu, który może być wytwarzany w wielu operacjach, gdzie każda dostarcza wielu parametrów, powoduje, że bazy danych zawierają setki atrybutów, które w połączeniu z milionami obserwacji tworzą ogromne zbiory danych (ang. Big Data) [90]. W przypadku przemysłu odlewania gromadzenie danych przemysłowych jest znacznie utrudnione, ponieważ standardowy proces produkcyjny odlewu składa się w przybliżeniu ze stu parametrów mogących mieć znaczący wpływ na jego przebieg. Odkrycie zależności między tymi parametrami jest wysoce skomplikowane i prawie niemożliwe, szczególnie w przypadku parametrów pochodzących z różnych etapów produkcji odlewu. Oprócz wyżej opisanej objętości danych, druga zauważona cecha charakteryzująca dane przemysłowe, to ich bezpośrednia zależność od czynnika ludzkiego lub od czynności kontrolnych lub pomiarowych wykonywanych w trakcie procesu produkcyjnego [90]. Zależność procesu od wpływu ludzkiego polega na bezpośrednim wpływie człowieka na wytwarzany produkt lub na półprodukty użyte do wytworzenia ostatecznego produktu. Wspomniana zależność od czynności kontrolnych lub pomiarowych zależy od jakości wskazań aparatury kontrolno-pomiarowej. W obu przypadkach, można zauważyć tworzenie się niezwykle szerokich albo bardzo ograniczonych zakresów wartości określonych parametrów procesu. W praktyce, proces odlewania, proces kontroli jakości i wytwarzania odlewów, (z których każdy posiada własny układ wlewowy, indywidualną masę rdzeniową i masę formierską), przebiega w różnych warunkach i obsługiwany jest przez wielu pracowników, pracujących w różnych komórkach i działach. Istnieje więc szansa, że jest wysoce zależny od wpływu operatorów, oraz od wskazań aparatury kontrolno-pomiarowej, co zostanie rozwinięte w badaniach realizowanych w ramach niniejszej rozprawy doktorskiej. Kolejną potwierdzoną w niniejszej rozprawie cechą danych przemysłowych to zauważalne częste współwystępowanie obserwacji różniących się o jeden, dwa, a nawet więcej rzędów wielkości (np. zawartość określonego pierwiastka w różnych stopach żeliwa) [90]. Następną cechą związaną z poziomem pomiaru dotyczy istnienia w zbiorze danych do badań, wielu typów skali pomiarowych, takich jak skala nominalna (np. nazwy surowców, nazwy brygad), skala porządkowa (np. kolejność próbek pobranych do badań), skala przedziałowa (np. daty pobrania danej próbki) [90]. Ostatnia

cecha danych przemysłowych konieczna do przywołania to niedoskonałość danych polegająca na występowaniu brakujących wartości, błędnych wartości (widocznych na wykresach przebiegu zmiennych oraz ukrytych np. błędów pomiarowych), wartości odstających, nieprecyzyjnych lub niedokładnych, oraz duplikujących się wartości. Cecha ta powoduje konieczność przeprowadzenia procesu czyszczenia danych (ang. Data Cleaning), z wykorzystaniem zaawansowanej wiedzy o procesie. W tym przypadku dobrze znane narzędzia statystyczne mogą okazać się niewystarczające lub nieodpowiednie. Opis przeprowadzonego procesu czyszczenia danych rozszerzono w rozdziale 5.2.1..

Ważnym punktem jest również zwrócenie uwagi na możliwości zbierania danych w czasie rzeczywistym przez przedsiębiorstwa produkcyjne. Obecnie znane jest wiele systemów i rozwiązań umożliwiających gromadzenie wyników i wykonywanie pomiarów wybranych istotnych parametrów technologicznych procesu odlewania. Czasami pomiary wymagają organizacji dodatkowych procesów kontroli i manualnych badań prowadzonych przez załogę odlewni lub automatycznych badań jedynie nadzorowanych. Takie pomiary to między innymi wartość temperatury i czasu zalewania, badania metalograficzne, analiza składu chemicznego wytopu, oraz analiza właściwości mechanicznych. Automatyczny monitoring warunków klimatycznych czyli temperatury i wilgotności powietrza w obszarach formowania i przygotowywania mas formierskich. Fakt zbierania danych świadczy o braku problemu z samymi pomiarami, czy ich przesyłaniem i zapisem. W badanym procesie występuje inny problem, którym jest identyfikacja zapisanej obserwacji i konkretnym fizycznym odlewem. Obecnie punktem odniesienia może być dana seria produkcyjna, co istotnie utrudnia szybką identyfikację przyczyn powstawania wad wyrobów. Zbierane dane mogą być również uśredniane, co też może powodować problemy z wydobywaniem wiedzy z danych.

Budowa modeli na podstawie metod uczenia maszynowego wykorzystujących dane rzeczywiste pochodzące z procesów produkcyjnych stanowi pewnego rodzaju wyzwanie. Powoduje to wiele czynników, między innymi samo ich zebranie może być trudne, następnie należy zwrócić uwagę z jakiego okresu pochodzą dane, czy jest on referencyjny, a więc czy dane reprezentują w odpowiedni sposób cały badany proces produkcyjny. Należy zwrócić uwagę czy zmienność danych nie jest zbyt wysoka, czy nie występują nietypowe przerwy czasowe pomiędzy obserwacjami, czy zbierane dane są powiązane z produkowanym wyrobem na wszystkich etapach przepływu, tak aby warunki procesu były powiązane z jego jakością [92]. Odlewnie dążą więc do budowy coraz dokładniejszych systemów zbierających szczegółowe dane online, gdyż monitoring ten mimo, że jest kosztowny, to przynosi realne korzyści. Związane jest to z coraz powszechniejszym stosowaniem zaawansowanych metod

modelowania bazujących na systemach uczących się. W wyniku im lepsze i dokładniejsze dane będą posiadać przedsiębiorstwa produkcyjne tym lepsze i dokładniejsze wyniki i wnioski mogą z nich otrzymać.

2.7. Przykłady zastosowania SSN w procesach wytwarzania

Rozwój metod sztucznej inteligencji pozwolił na coraz powszechniejsze stosowanie sztucznych sieci neuronowych w sektorze produkcji. Nawiązując do ciągłych zmian procesów produkcyjnych wynikających ze zmian potrzeb klientów ostatecznych, a więc między innymi popytu na dane produkty oraz skróceniu cyklu życia produktu, obszar ten wymaga zastosowania metod i technologii, które są w stanie łatwo dostosowywać się do takich zmian.

W opisywanym kontekście SSN stanowią odpowiednią technologię, gdyż są zdolne do radzenia sobie z zakłóceniami, niepełnymi i zniekształconymi danymi, ponadto są zdolne do uczenia się i tworzenia przybliżonych reguł ekspertowych na bazie przykładowych zestawów danych, co pozwala uniknąć czasochłonnych badań wykonywanych bezpośrednio przez ekspertów. Dodatkowo są one od dawna stosowane do procesów decyzyjnych [93], projektowania, monitorowania i identyfikacji [94], [96], [26], [95], [97], planowania [98] i kontroli [97], [99] procesów wytwórczych. Jest to trudne zadanie, gdyż złożoność procesów produkcyjnych jest często wysoka, procesy są opisywane przez wiele zmiennych parametrów, w których wartościach mogą występować zakłócenia. Dlatego w wielu przypadkach bardzo trudne jest zdiagnozowanie zależności między jakością produktu ostatecznego a wartościami parametrów wejściowych. Autorzy zwrócili szczególną uwagę na elastyczność i złożoność metody SSN, oraz możliwość skutecznej integracji jej z innymi metodami inżynierii produkcji.

Przechodząc do procesów odlewniczych, których modelowanie z zastosowaniem zaawansowanych metod uczących się jest uzasadnione przez złożony charakter tych procesów. Początkowym celem tworzonych modeli była predykcja wartości wyjściowej w oparciu o zmieniające się wartości parametrów wejściowych. Tego typu badania wykonywane były przy użyciu metod opartych na twierdzeniu Bayesa, na metodach statystycznych lub logice rozmytej, jednak najbardziej powszechne były sztuczne sieci neuronowe. Wzrost oczekiwań i wymagań spowodował, że chciano już nie tylko przewidywać wartość zmiennej wyjściowej, ale zaczęto stosować metodę SSN do poznawania przyczyn występowania określonych sytuacji i zjawisk w procesach wytwórczych. Nadal jednak te zastosowanie stanowi nie do końca rozpoznany obszar, będąc jedynie uzupełnieniem do klasycznych celów metody, czyli prognozowania wyników. Z tego powodu naukowcy poświęcili wiele publikacji zagadnieniom związanym z zastosowaniem SSN do odkrywania wiedzy z danych.

Publikacją taką jest artykuł [100] poświęcony zastosowaniu metody SSN do rozwiązywania problemów o wysokiej złożoności bez możliwości stosowania pewnych uproszczeń. Autorzy zaznaczyli, że tworzone modele fizyczne mają możliwość opisu klasy obserwacji oraz umożliwiają prognozowanie łatwe do weryfikacji, jednak w wielu złożonych problemach tego typu modele nie istnieją. Ważnym odniesieniem jest praca [101], w której rozważono wady i zalety metody SSN, z szczególnym nawiązaniem do zastosowania metody do zadań klasyfikacji i regresji nieliniowej. Praca była znacząca, ponieważ autorzy przedstawili opis procesu za pomocą funkcji, zawierającej zdefiniowane współczynniki wynikające z wag sieci. Zaznaczając, że procesy te nie są już czarną skrzynką, co w kolejnych publikacjach zostało wielokrotnie podważone. Następną istotną pracą [102], w której autorzy próbowali wykryć błędy w procesach produkcyjnych w trakcie przejściowych faz procesu, używając wielowarstwowych jednokierunkowych SSN. Głównym celem pracy było stworzenie metody odnoszącej się do wielu procesów przemysłowych. W publikacji porównano różne typy SSN wskazując sieć typu MLP jako lepszą od pozostałych, zaznaczając szczególnie jej wysoką odporność na zakłócenia występujące w danych procesowych. Jedną z publikacji, której celem było określenie źródła wad odlewów był artykuł [103], w którym wskazano, że istotną trudnością, z którą miały radzić sobie SSN jest wpływ wielu losowo zmieniających się parametrów na formowanie wady odlewu.

Kolejne publikacje w tematyce odlewania ciśnieniowego dotyczyły [104] wykorzystania SSN do przewidywania procentowej wartości porowatości w odlewach tworzonych ze stopu aluminium z krzemem (Al – Si). Metoda SSN pozwoliła na skorelowanie składu chemicznego i szybkości chłodzenia z wartością porowatości odlewu. W tym samym roku powstała publikacja [105], której celem było zastosowanie metody SSN do symulacji zależności parametrów procesu od czasu krzepnięcia czy powstawania defektu. Następnie w artykule [106] zaproponowano generyczny model oparty o metodę SSN do estymacji optymalnych wartości parametrów procesu odlewania wysokociśnieniowego, obliczanych w czasie rzeczywistym. W 2009r. [107] pojawiła się publikacja, która zaproponowała system oceny odlewu pod względem określenia ilościowego występowania wad powierzchniowych na podstawie metody SSN, która skorelowała wady powierzchniowe z parametrami procesu. Autorzy, podobnie jak [108] wykorzystali do badań algorytm wstecznej propagacji błędu do stworzenia sieci złożonej z trzech warstw, zawierającej trzy neurony na wejściu i jeden na wyjściu oraz trzy do pięciu neuronów w warstwie ukrytej. W publikacji [108] w oparciu o duże zbiory symulowanych danych opisujących proces odlewania wysokociśnieniowego, opracowano plan szkolenia SSN przez wybór w sposób losowy zbiorów wartości wejściowych. Wykazano wówczas, że defekty

związane z porowatością odlewów mogą być spowodowane przez temperatury początkowe stopu i formy i prędkości pierwszej i drugiej fazy. Jednak wyniki nie były wystarczające aby wyjaśnić wszystkie zjawiska zachodzące w rzeczywistym procesie odlewania wysokociśnieniowego (HPDC), w którym relacje pomiędzy zmiennymi procesu są złożone i często ukryte. Kolejnym przykładem jest [109] zastosowanie modeli predykcyjnych do poprawy jakości odlewów aluminiowych celem minimalizacji odpadów produkcyjnych spowodowanych występowaniem porowatości. Autorzy zastosowali opracowane systemy rozmyte optymalizowane algorytmem genetycznym i symulowanym wyżarzaniem.

Znaczna część artykułów rozważa metodę modelowania procesów z wykorzystaniem sztucznych sieci neuronowych. Metoda ta pozwala na uzyskanie wydajności predykcji na bardzo wysokim poziomie dlatego też zdominowała inne techniki zaawansowanego modelowania opartego na danych. W związku z tym w niniejszej rozprawie doktorskiej badania rozpoczęto od zastosowania właśnie tej metody zaawansowanego modelowania opartego na danych celem wykrycia przyczyn powstawania wad wyrobów. Warto również zwrócić uwagę na możliwości prowadzenia badań z wykorzystaniem technik hybrydowych łączących w sobie różne metody modelowania, które mogą prowadzić ku zwiększeniu dokładności przewidywania określonego parametru.

Analiza literaturowa każdorazowo pozwala zrozumieć temat z wielu stron i pod względem wielu aspektów. W przypadku niniejszej rozprawy doktorskiej analiza ta pozwoliła na poznanie historii powstawania i rozwoju sztucznej inteligencji oraz zrozumienie obecnych trendów stosowanych w różnych sektorach przemysłu jednak ze skupieniem się na sektorze produkcji i wytwarzania a dokładniej na procesie odlewania wysokociśnieniowego. Najważniejsze techniki zaawansowanego modelowania opartego na danych zostały uwzględnione w analizie literaturowej celem wskazania ich kluczowej i ważnej roli w przemyśle produkcyjnym w ostatnich dwóch dekadach.

3. Drzewa decyzyjne

3.1. Wprowadzenie

Historia powstania drzew decyzyjnych sięga 1963 roku, kiedy to Morgan i Sonquist na Wydziale Statystyki Uniwersytetu Wisconsin-Madison zaproponowali nową metodę dopasowania drzew regresji do przewidywania wartości zmiennej ilościowej. Ten pierwszy analityczny algorytm, nazwany został AID, jako skrót od angielskich słów „Automatyczne Wykrywanie Interakcji” (ang. Automatic Interaction Detection) [110]. Następnie w 1966 r. Instytut Informatyki Politechniki Poznańskiej zaprezentował jedną z pierwszych publikacji na temat modelu drzewa decyzyjnego autorstwa Hunta [111]. W psychologii wówczas metodę drzew decyzyjnych wykorzystywano do modelowania koncepcji ludzkiego uczenia się. Badając umysł człowieka, naukowcy odkryli, że algorytm drzew decyzyjnych może być przydatny w technikach programowania [112]. Kolejnym ważnym krokiem było pojawienie się w 1973 r. pierwszego drzewa klasyfikacyjnego w projekcie THAID, autorstwa Messagera i Mandella, stanowiącego rozszerzenie metody AID. Rok później profesorowie nauk statystycznych Breiman i Stone z Berkeley oraz Friedman i Olshen ze Stanford rozpoczęli rozwój algorytmu drzewa klasyfikacji i regresji (CART), w 1977 r. opracowując pierwszą propozycję algorytmu CART.

W 1984 r. nastąpiła swego rodzaju rewolucja świata algorytmów, gdyż oficjalnie opublikowano oprogramowanie oparte na algorytmie CART. Od tamtego momentu drzewa decyzyjne stały się jednym z najczęściej stosowanych metod analizy danych. Dwa lata później w 1986 r. John Ross Quinlan zaprezentował nową koncepcję wprowadzającą możliwość stworzenia drzewa z wieloma odpowiedziami. Do tego czasu zakładano, że wszystkie algorytmy klasyfikacji drzew decyzyjnych mogą mieć tylko dwie odpowiedzi na każde pytanie (zwane były drzewami binarnymi) [113].

Metoda drzew decyzyjnych jako jedna z metod klasyfikacyjnych, ma na celu odkrycie zależności między zmienną celu a zmiennymi objaśniającymi zwanymi predykcyjnymi, tak jak większość metod budowy klasyfikatorów. Wspomniana zależność zawarta jest w strukturze, nazywanej modelem. Modele mają zadanie opisu i reprezentacji ukrytych w zbiorach danych zjawisk oraz predykcji na podstawie wartości atrybutów warunkowych, wartości atrybutu decyzyjnego. Utworzone modele w oparciu o zadania klasyfikacji dzielą przestrzeń poprzez

wyznaczenie granic między klasami na obszary odpowiadające określonym klasom [114]. Proces klasyfikacji obejmuje dwa etapy, czyli uczenia oraz klasyfikacji właściwej [115].

Łatwo wywnioskować, że do zbudowania modelu predykcyjnego potrzebny jest zbiór obiektów, posiadających określone zmienne celu i zmienne predykcyjne. Taki zbiór nazywany jest zbiorem uczącym, gdyż na jego podstawie można przewidzieć wartość zmiennej celu, dla każdej nowej wartości zmiennej predykcyjnej. Tworzenie takiego modelu może odbywać się na przykład przez wygenerowanie zestawu reguł, bądź drzew decyzyjnych, lub właściwego określenia parametrów rozkładu (regresja). Drzewa regresji są odmianą drzew decyzyjnych opracowanych na podstawie zmiennych przyjmujących wartości ciągłe lub uporządkowane dyskretne. Zawierają jedną zmienną wyjściową (numeryczną), nazywaną odpowiedzią i jedną lub więcej zmiennych wejściowych, nazywanych predyktorami. W wyniku działania drzew regresji przewidziane wartości zmiennej wyjściowej będą zawarte w końcowych węzłach drzewa decyzyjnego.

3.2. Przykłady zastosowania DT w procesach wytwarzania

Metoda drzew decyzyjnych znajduje swoje zastosowanie w procesach decyzyjnych dotyczących złożonych problemów, z wieloma możliwymi wariantami działania oraz występujących w warunkach wysokiego ryzyka. Ta zaawansowana metoda analizy danych umożliwia reprezentację hipotez, poprzez utworzenia graficznej reprezentacji badanego procesu lub zjawiska klasyfikującego skutecznie badane obserwacje. Stworzone drzewo zawiera wówczas jak najmniejszy błąd predykcji i ma jak najbardziej zoptymalizowany rozmiar.

Drzewa decyzyjne wykorzystuje się między innymi w ekonomii i bankowości do analizy zdolności kredytowej [116], [117], w przemyśle do predykcji wydajności produkcyjnej [118], w energetyce do planowania konsumpcji energii [119], w medycynie do pogłębionej diagnostyki medycznej [120], [121], do predykcji cen [122] i wielu innych. Drzewa decyzyjne są uważane za łatwiejsze do interpretacji niż inne metody uczenia maszynowego. Struktura drzewiasta ułatwia sprawdzenie wyników zadań, pytań na każdym poziomie utworzonego drzewa. Metoda ta jest uznawana, również przez zdolność do analizy zmiennych zbiorów danych, zawierających kategorię lub ciągłe wartości zmiennych, a nawet zawierające braki w danych [123].

W procesach wytwarzania a dokładniej w przemyśle odlewniczym praca nad redukcją wadliwych produktów była zawsze tematem bardzo ważnym ze względu na pracę nad ciągłym doskonaleniem przedsiębiorstw. Obecnie dodatkowo wzmocniona przez założenia koncepcji

Przemysłu 4.0.. W 2022 roku autorzy artykułu [124] skupili się na wpływie parametrów maszyny na defekty występujące w odlewach pochodzących z procesu odlewania wysokociśnieniowego. Skupiono się na sprawdzeniu różnych technik modelowania opartych na danych, sprawdzając możliwości drzew decyzyjnych, regresji liniowej i lasów losowych, wskazując drzewa decyzyjne jako metodę zapewniającą najlepszą skuteczność. Autorzy zaznaczyli jednak, że temat zastosowania drzew decyzyjnych nadal wymaga pogłębienia i optymalizacji. Między innymi z tego względu znalazł on swoje zastosowanie w niniejszej rozprawie doktorskiej.

Kolejną ważną publikacją był artykuł [125], w którym chciano stworzyć system przewidywania i diagnozowania wad wyrobów celem pracy nad poprawą produktywności w procesie odlewania. Autorzy postanowili poradzić sobie z problemem z brakiem równowagi danych stosując metodę lasów losowych oraz drzew decyzyjnych. Uzyskane dokładności wskazywały na duży potencjał metody drzew decyzyjnych do wspierania procesów decyzyjnych personelu inżynierskiego, celem pracy nad jakością odlewów ciśnieniowych.

Artykuł [126] wskazał konieczność budowy inteligentnych fabryk nakierowanych na dokładne gromadzenie danych, celem ich analizy i interpretacji przy użyciu metod eksploracji danych. Oczekuje się, że wszystkie przedsiębiorstwa produkcyjne chcące poprawiać swoje wyniki będą przekształcać się w inteligentne fabryki systematycznie wdrażając nowe rozwiązania między innymi wykrywanie optymalnych parametrów procesu celem na przykład ustalenia planów zarządzania produktami ubocznymi procesu. Autorzy użyli między innymi metodę drzew decyzyjnych w stworzonym systemie zaawansowanego modelowania opartego na danych, wskazując tę metodę jako właściwą do problemów związanych z zaawansowaną strukturą danych.


Zidentyfikowane przez autorów wady drzew decyzyjnych, to między innymi brak stabilności, czyli przy zmianie zbioru uczącego zmieniają się reguły decyzyjne ustalone w węzłach drzewa decyzyjnego oraz stosunkowo niska skuteczność, czyli występowanie w złożonych zbiorach danych pojedynczych drzew osiągających niską skuteczność klasyfikowania [127]. Mimo to drzewa decyzyjne mają wiele zalet, przede wszystkim pozwalają na osiąganie coraz lepszych wyników zaawansowanych analiz, co wpływa na coraz częstsze wykorzystywanie ich w procesach produkcyjnych. Liczne zastosowania metody do rozwiązywania problemów związanych z procesem odlewania wysokociśnieniowego wpłynęło na zastosowanie drzew decyzyjnych w niniejszej rozprawie celem zbadania przyczyn powstawania wad w wyrobach a dokładniej w odlewach wytwarzanych w procesie HPDC. Przebieg badań oraz wyniki i wnioski zostały przedstawione w rozdziale 5.2.5..

4. Maszyna wektorów wspierających

4.1. Wprowadzenie

Maszyna wektorów wspierających (ang. support vector machine) (SVM) stanowi metodę maszynowego uczenia nadzorowanego, która jest zdolna do identyfikacji ukrytych wzorców w zbiorach danych, które są zaszumione i wysoce złożone. Powstanie tej metody sięga połowy XX wieku, kiedy to publikacja z 1950 r. [128] i prace Warrena McCullocha i Waltera Pittsa [28] zainspirowały Franka Rosenblatt do odkrycia w 1957 r. perceptronu, z którego miały narodzić się oraz doskonalić SSN. Po upływie sześciu lat w 1963 r. Vapnik i Lerner ogłosili „Uogólniony algorytm portretowy” [129], który stanowił inspirację dla Bosera, Guyona i Vapnika, którzy w 1992 r. podczas konferencji COLT (Computational Learning Theory) wprowadzili pojęcie SVM [130]. Następnie Vapnik pracując nad tą dziedziną statystyki, prowadził niezliczoną ilość wybitnych wykładów, a w 1995 r., z udziałem Cortesa odkrył miękki margines klasyfikatora. Zakładał on, że ograniczenie maksymalizacji marginesu linii oddzielającej klasy musi zostać zrelatywizowane, aby niektóre punkty w danych treningowych mogły naruszać linię rozdziałającą. Dodatkowo w tym samym roku rozszerzył jego zastosowanie na analizę regresji [131]. Trzy lata później Taylor, Shawe i inni w znaczący sposób uogólnili metodę SVM z twardym marginesem klasyfikatora. W 2000 roku podali również granice statystyczne dla uogólnienia miękkiego marginesu SVM. Od tego czasu metoda SVM zyskuje na popularności i jest wykorzystywana w wielu zastosowaniach, opisanych w rozdziale 4.2..

Maszyna wektorów wspierających jest jednym z najpopularniejszych i bardziej złożonym klasyfikatorem, którego uczenie polega na znalezieniu hiperpłaszczyzny, czyli swego rodzaju granicy decyzyjnej, która rozdzieli przestrzeń zmiennych wejściowych przynależących do dwóch różnych klas z najlepszą możliwą zdolnością do generalizacji i zachowując optymalność. Dążąc do zachowania przy tym maksymalnej wartości marginesu błędu, czyli maksymalizuje margines separacji jednocześnie minimalizując błąd klasyfikacji [130]. Ważne jest zapewnienie maksymalnej szerokości marginesu występującego pomiędzy próbkami pochodzącymi z różnych klas (rys.4.1.1.). Celem maksymalizacji szerokości marginesu pomiędzy próbkami pochodzącymi z różnych klas, należy zminimalizować parametry hiperpłaszczyzny. Szerszy margines daje możliwość do osiągnięcia lepszych własności generalizacji oraz zmniejsza podatność na ewentualne przeuczenie (ang. overfitting). Węższy margines powoduje małą zmianę granicy i radykalne zmiany klasyfikacji [132].



Rys.4.1.1. Przykład problemu podzielonego na dwuwymiarową przestrzeń z optymalnym marginesem [131]

SVM realizuje zadania klasyfikacyjne, jednak można użyć tej metody również do regresji. Buduje się wówczas optymalną hiperpłaszczyznę w iteracyjnym algorytmie uczącym, minimalizującym funkcję błędu. Modele można rozróżnić ze względu na przynależność do czterech grup ustalonych według użytej funkcji błędu, czyli typ pierwszy klasyfikacyjny, typ drugi klasyfikacyjny, typ pierwszy regresyjny i typ drugi regresyjny [133]. W regresji typu pierwszego i drugiego użytych podczas badań niniejszej rozprawy szukana jest zależność zmiennej zależnej a od zbioru zmiennych niezależnych b , biorąc pod uwagę szum losowy. Funkcja jest obliczana według poniższego równania:

$$a = f(b) + \text{szum losowy} \quad (4.1)$$

Celem tych funkcji błędu jest znalezienie postaci funkcji $f(b)$, podającej jak najbardziej przybliżone wartości zmiennej zależnej y dla nowych przypadków. Proces ten bazuje na minimalizowaniu funkcji błędu co jest realizowane w oparciu o dwa typy regresji, obliczane z dwóch różnych postaci równania (5.2.) [131], [134].

$$\min_{w,b,\xi} \frac{1}{2} w^T w + C \sum_{i=1}^N \xi_i$$

$$y_i(w^T \phi(x_i) + b) \geq 1 - \xi_i \quad (4.2.)$$

$$\xi_i \geq 0$$

gdzie: w i b – współczynniki optymalnej hiperpłaszczyzny,
 ϕ – funkcja jądrowa bazowa,
 C – parametr wysokości kary,
 ξ_i – zmienna rozluźniająca

x - cechy wzorców

y - oznaczenia wzorców

Zastosowano następujące funkcje jądrowe dostępne w oprogramowaniu Statistica:

- o liniową, obliczaną wg wzoru (5.3)

$$\phi = x_i x_j \quad (4.3.)$$

- o wielomianową, obliczaną wg wzoru (5.4)

$$\phi = (\gamma x_i x_j + r)^d, \gamma > 0 \quad (4.4.)$$

- o radialną (RBF), obliczaną wg wzoru (5.5)

$$\phi = \exp(-\gamma |x_i - x_j|^2), \gamma > 0 \quad (4.5.)$$

- o sigmoidalną, obliczaną wg wzoru (5.6)

$$\phi = \tan(x_i x_j + r) \quad (4.6.)$$

gdzie: γ i r – parametry funkcji jądrowych.

SVM są stosowane powszechnie do zaawansowanej analizy poprzez klasyfikację dużych zbiorów danych. Metodę tę można rozpatrywać w trzech wariantach klasyfikatora SVM: zawierającego funkcję jądra, liniowego, dedykowanych dla klas separowanych oraz liniowego z funkcją błędu dedykowanych dla klas nie w pełni liniowo separowanych. Metoda SVM sprawdza się lepiej niż pozostałe metody uczenia maszynowego w braku nadmiernej generalizacji, gdyż celem tej metody jest właśnie zdolność do poprawnego klasyfikowania danych.

4.2. Przykłady zastosowania SVM w procesach wytwarzania

Metoda maszyn wektorów wspierających (SVM) cieszy się dużym zainteresowaniem w różnych dziedzinach nauki. Stosowana jest celem prawidłowej klasyfikacji danych. Jej zalety są związane z możliwością zastosowania do rozwiązywania problemów zarówno o liniowym i nieliniowym charakterze, ponadto jest efektywna obliczeniowo, jej złożoność wzrasta wraz ze wzrostem liczby wymiarów, modelowanie oparte na danych, jest stosunkowo szybkie, ponadto jest ona w stanie poradzić sobie z dużą liczbą atrybutów oraz małą liczbą przykładów uczących [135]. Wszystkie te cechy wpływają na zainteresowanie naukowców aplikacją metody w procesach wytwarzania.

Jedną z ostatnich prac związanych z procesem odlewania wysokociśnieniowego była seria artykułów [136], [137], [138], w których podjęto próbę zbadania właściwości mechanicznych

pręta powstającego w procesie HPDC, podjęto też próbę klasyfikacji dobrych i złych produktów. Skupiono się głównie na sprawdzeniu relacji pomiędzy wytrzymałością na rozciąganie i cechami procesu wytwarzania. Zgromadzono w tym celu duży zbiór danych obejmujący miesiące produkcji. W pracy wykorzystano metody zaawansowanego modelowania oparte na danych, takie jak maszyny wektorów wspierających (SVM), lasy losowe, regresję, sztuczne sieci neuronowe (SSN) i XGBoost, czyli algorytm uczenia maszynowego, który wykorzystuje strukturę wzmacniającą gradient. Oceniono skuteczność zastosowanych metod porównując ich wyniki z danymi historycznymi. Wskazano, że metody nadzorowanego uczenia maszynowego okazały się być skuteczne do klasyfikacji dobrych i złych wyrobów. Prace te jednak skupiały się na modelowaniu opartym na dużych zbiorach danych, pod względem cech procesu i ich wpływu na wyrób ostateczny, jednak nie rozszerzały one rozważań w kierunku wskazania wartości określonych parametrów procesu sprzyjających wytwarzaniu produktu bez wady, co stanowi wyzwanie niniejszej rozprawy doktorskiej.

Należy również wspomnieć o artykule [139], w którym autorzy przedstawili zastosowanie metod nadzorowanego uczenia maszynowego w tym SSN i SVM do sterowania procesami metalurgicznymi, charakteryzujących się występowaniem nieliniowych zależności pomiędzy poszczególnymi parametrami procesu. Głównym celem pracy było przewidzenie ilości dodatków stopowych aby przewidzieć właściwy skład chemiczny żeliwa białego. Badania powstały na podstawie danych rzeczywistych pochodzących z procesu odlewniczego. Opracowano modele i wybrano spośród nich w oparciu o wynik błędu średniokwadratowego modele o najlepszej wydajności. Wyniki pokazały, że zarówno metoda sztucznych sieci neuronowych, jak i maszyn wektorów wspierających jest odpowiednia i niezawodna do kontroli procesu. Metody te zostały jednak sprawdzone dla stosunkowo małych zbiorów danych zawierających 300 obserwacji, artykuł nie rozważa badań w kierunku sprawdzenia skuteczności modeli na dużych zbiorach danych.

W 2022 roku powstała kolejna znacząca publikacja [92], w której autorzy skupili się na stworzeniu modeli celem poprawy jakości produktów w wyniku optymalizacji zmiennych procesu odlewania niskociśnieniowego (LPDC). Modelowanie oparto o metody XGBoost, regresję oraz maszyny wektorów wspierających (SVM). Wyniki modelowania przy użyciu różnych metod porównano ze sobą i wskazano, że SVM zapewniła wystarczającą dokładność klasyfikacji wadliwych części. Zaznaczono jednak, że metoda SVM uzyskała niską skuteczność w przewidywaniu dobrych produktów. Sprawia to, że zastosowanie jej w rzeczywistym przedsiębiorstwie produkcyjnym może spowodować błędną klasyfikację dobrych odlewów, co wygeneruje wysoki koszt dodatkowych czynności kontrolnych. Jednak

zastosowanie metody i uzyskane wyniki były obiecujące i wpłynęły na zastosowanie metody w niniejszej rozprawie doktorskiej.

Liczne zastosowania metody do rozwiązywania problemów związanych z obszarem wytwarzania a w szczególności związanych z procesem odlewania wysokociśnieniowego wpłynęło na zastosowanie metody maszyn wektorów wspierających w niniejszej rozprawie celem zbadania przyczyn powstawania wad w wyrobach a dokładniej w odlewach wytwarzanych w procesie HPDC. Przebieg badań oraz wyniki i wnioski zostały przedstawione w rozdziale 5.2.6..

5. Badania własne

5.1. Sformułowanie problemu

Niniejsza rozprawa skupia się na rozwiązaniu ogólnego problemu badawczego w postaci pytania: w jaki sposób przy użyciu zaawansowanego modelowania opartego na dużych zbiorach danych można diagnozować przyczyny powstawania wad wyrobów?

Ponadto niniejsza rozprawa doktorska zamierza udowodnić ogólną hipotezę badawczą, która zakłada, iż diagnozowanie przyczyn powstawania wad wyrobów wymaga zastosowania określonych w metodologii zbioru metod zaawansowanego modelowania opartego na dużych zbiorach danych. Hipoteza jako przypuszczenie naukowe wymagające sprawdzenia jest uzasadniona, czyli oparta na wcześniejszych obserwacjach, badaniach lub teoriach oraz testowalna, czyli dotycząca istotnych zmiennych, które są manipulowane i mierzalne, gdyż podczas badań własnych sprawdzany będzie wpływ różnych zbiorów i zakresów zmiennych na zmienną zależną.

Dane, które użyto do badań pochodzą z procesu odlewania ciśnieniowego, charakteryzującego się wysokim stopniem skomplikowania, złożonością, nieliniowym charakterem i niewyjaśnioną naturą fizyczną [42]. Obecnie przedsiębiorstwa wytwórcze produkujące odlewy zbierają dane procesowe na podstawowym poziomie technologii informacyjno-komunikacyjnych [125], [140], co oznacza, że obecnie nie ma systematycznej metodyki lub systemu predykcji i diagnozowania wad wyrobów oraz ich przyczyn, ponieważ informacje oparte na technologiach informacyjno-komunikacyjnych nie są właściwie rozpoznane i rozwinięte. Dlatego potrzebna jest metodologia, która wspiera podejście analityczne, aby konkretnie identyfikować i reagować na problemy w procesie odlewania [141]. Diagnostyka wad jakościowych jest jedną z metod kontroli jakości, która pozwala skutecznie rozwiązać problemy jakościowe wyrobów w procesie produkcyjnym i wzbudza coraz większe zainteresowanie w środowisku naukowym [142]. Dlatego też postawiono istotne pytania badawcze w niniejszej rozprawie: czy zaawansowane metody analizy danych będą w stanie skutecznie przewidzieć pojawienie się wady w wyrobie? oraz czy wielowymiarowa optymalizacja parametrów procesu będzie w stanie wskazać wartości parametrów określonych zmiennych, wpływające na powstanie wady w produkcji?

Zauważono potrzebę skutecznego przewidywania dobrych produktów, defektów i stworzenia w przyszłości procesu do inteligentnego podejmowania decyzji przez maszynę

odlewniczą w czasie zbliżonym do rzeczywistego. Potrzeba ta wymaga stworzenia zestawu narzędzi zawierającego metody oparte na danych, zaawansowanego modelowania, które otwierają drzwi do wielowymiarowej analizy danych w procesach wytwórczych. Stale podejmowane są próby przewidywania porowatości odlewu [143], oraz wpływu kształtu odlewu na porowatość [144], mimo to nadal nie są znane rzeczywiste przyczyny lub kombinacja przyczyn wystąpienia wad w wyrobach [92]. Dodatkowo mimo licznych publikacji porównujących skuteczność różnych metod [137], [145] uczenia maszynowego, nadal brakuje opracowanej skutecznej i kompleksowej metodyki diagnozowania wad wyrobów możliwej do zastosowania w rzeczywistej odlewni, co stanowi szansę dla przemysłu oraz środowiska akademickiego aby przyspieszyć lub umożliwić postęp w tym obszarze. Istotną nowością pracy jest między innymi stworzenie metodyki zawierającej metody eksploracji danych w sektorze produkcji i wytwarzania, w myśl koncepcji tzw. „Przemysłu 4.0.”, istotny wpływ na stworzenie sprawnego systemu kontroli procesu celem diagnostyki wadliwych produktów realizując cele koncepcji inteligentnej fabryki.

5.2. Przebieg badań

5.2.1. Wstępne przetwarzanie danych

W niniejszym rozdziale zaprezentowane zostaną wyniki praktycznego zastosowania wstępnego przetwarzania danych, wykonanego w celu poprawy jakości danych i przygotowania ich do dalszych analiz.


Badania oparte będą na danych rzeczywistych pochodzących z procesu odlewania wysokociśnieniowego, bloków cylindrowych przez jedną ze współpracujących odlewni. Krok ten jest niezbędny i wymaga wiedzy o procesie celem prawidłowej klasyfikacji danej próbki jako wartości odstającej, błędu pomiarowego lub ważnej z punktu widzenia procesu wartości.

5.2.1.1. Metodyka i wyniki badań


Wstępne przetwarzanie danych rozpoczęto od procesu czyszczenia danych poprzez normalizację danych, a dokładniej poprzez podział wartości 56 zmiennych (pomijając dwie zmienne a dokładnie zmienną informującą o dacie i godzinie powstania odlewu oraz zmiany roboczej na której powstał) na zakresy od 0,1 do 1 oraz dodanie w trzech kolumnach, informacji, ile w danym zakresie było wartości świadczących o braku wady, ile wartości świadczących o odlewie naprawialnym oraz ile wartości świadczących o wadzie odlewniczej niemożliwej do naprawy - powodującej odpad. W tabelach przedstawiających wyniki (tab.5.1.-

tab.5.56.) dodano również kolumnę prezentującą procentowy udział obserwacji w każdym z zakresów, aby wskazać proponowane zakresy wartości z największym udziałem obserwacji. Dodatkowo stworzono wykresy przebiegu oraz wykresy wartości posortowanych celem wizualnej analizy (rys.5.2.1.1.- rys.5.2.1.56.). Dane zostaną dzięki temu wybrane na podstawie największego ilościowego udziału w danych zakresach wartości oraz na podstawie ilości wytworzonego odlewu naprawialnego i odlewu niemożliwego do naprawy (złomu), czyli odlewu z wadą odlewniczą. Zaproponowane podejście pozwoli zoptymalizować zbiór danych poprzez klasyfikację danej próbki jako wartości odstającej, błędu pomiarowego lub ważnej z punktu widzenia procesu wartości, mającej wpływ na wartość wyjściową, czyli na powstawanie wady w produkcji.


Podczas etapu przygotowania danych skupiono się na weryfikacji podejrzanych wartości, które mogły być wynikiem występowania usterek czujników, różnymi kodami błędów raportowanych przez maszynę, błędnie obliczonymi wartościami, które klasyfikują się jako wartości odstające, mogące reprezentować problemy.




Rys.5.2.1.1. Wykres przebiegu zmiennej niezależnej: *ciśnienie sprężonego powietrza*, z posortowanymi wartościami




Rys.5.2.1.2. Wykres przebiegu zmiennej niezależnej: *ciśnienie wody miejskiej*, z posortowanymi wartościami




Rys.5.2.1.3. Wykres przebiegu zmiennej niezależnej: *ciśnienie wody obiegowej*, z posortowanymi wartościami




Rys.5.2.1.4. Wykres przebiegu zmiennej niezależnej: *czas pierwszej fazy wtrysku*, z posortowanymi wartościami




Rys.5.2.1.5. Wykres przebiegu zmiennej niezależnej: *czas chłodzenia obwodu 1*, z posortowanymi wartościami




Rys.5.2.1.6. Wykres przebiegu zmiennej niezależnej: *czas cyklu*, z posortowanymi wartościami




Rys.5.2.1.7. Wykres przebiegu zmiennej niezależnej: *czas cyklu smarowania*, z posortowanymi wartościami




Rys.5.2.1.8. Wykres przebiegu zmiennej niezależnej: *czas dozowania stopu 1*, z posortowanymi wartościami




Rys.5.2.1.9. Wykres przebiegu zmiennej niezależnej: *czas dozowania stopu 2*, z posortowanymi wartościami




Rys.5.2.1.10. Wykres przebiegu zmiennej niezależnej: *czas krzepnięcia t_2* , z posortowanymi wartościami




Rys.5.2.1.11. Wykres przebiegu zmiennej niezależnej: *czas przedmuchu*, z posortowanymi wartościami




Rys.5.2.1.12. Wykres przebiegu zmiennej niezależnej: *czas smarowania*, z posortowanymi wartościami




Rys.5.2.1.13. Wykres przebiegu zmiennej niezależnej: *dzienny numer wtrysku*, z posortowanymi wartościami




Rys.5.2.1.14. Wykres przebiegu zmiennej niezależnej: *filtr próżni 1*, z posortowanymi wartościami




Rys.5.2.1.15. Wykres przebiegu zmiennej niezależnej: *grubość piętki układu wlewowego*, z posortowanymi wartościami




Rys.5.2.1.16. Wykres przebiegu zmiennej niezależnej: *koncentrat*, z posortowanymi wartościami




Rys.5.2.1.17. Wykres przebiegu zmiennej niezależnej: *ciśnienie maksymalne*, z posortowanymi wartościami




Rys.5.2.1.18. Wykres przebiegu zmiennej niezależnej, *prędkość wtrysku maksymalna*, z posortowanymi wartościami




Rys.5.2.1.19. Wykres przebiegu zmiennej niezależnej: *opóźnienie multiplikacji*, z posortowanymi wartościami




Rys.5.2.1.20. Wykres przebiegu zmiennej niezależnej: *stała temperatura chłodzenia płyty*, z posortowanymi wartościami




Rys.5.2.1.21. Wykres przebiegu zmiennej niezależnej: *poziom stopu w piecu podgrzewczym*, z posortowanymi wartościami




Rys.5.2.1.22. Wykres przebiegu zmiennej niezależnej: *poziom wody w strumieniu chłodzącym*, z posortowanymi wartościami




Rys.5.2.1.23. Wykres przebiegu zmiennej niezależnej: *czas drugiej fazy wtrysku*, z posortowanymi wartościami




Rys.5.2.1.24. Wykres przebiegu zmiennej niezależnej: *profil próżni 1*, z posortowanymi wartościami




Rys.5.2.1.25. Wykres przebiegu zmiennej niezależnej: *profil próżni 2*, z posortowanymi wartościami




Rys.5.2.1.26. Wykres przebiegu zmiennej niezależnej: *przepływ chłodzenia tłoka*, z posortowanymi wartościami




Rys.5.2.1.27. Wykres przebiegu zmiennej niezależnej: *przepływ w obwodzie chłodzenia 1*, z posortowanymi wartościami




Rys.5.2.1.28. Wykres przebiegu zmiennej niezależnej: *przepływ w obwodzie chłodzenia 13*, z posortowanymi wartościami




Rys.5.2.1.29. Wykres przebiegu zmiennej niezależnej: *przepływ w obwodzie chłodzenia 14*, z posortowanymi wartościami




Rys.5.2.1.30. Wykres przebiegu zmiennej niezależnej: *przepływ w obwodzie chłodzenia 15*, z posortowanymi wartościami




Rys.5.2.1.31. Wykres przebiegu zmiennej niezależnej: *przepływ w obwodzie chłodzenia 17*, z posortowanymi wartościami




Rys.5.2.1.32. Wykres przebiegu zmiennej niezależnej: *przepływ w obwodzie chłodzenia 20*, z posortowanymi wartościami




Rys.5.2.1.33. Wykres przebiegu zmiennej niezależnej: *przepływ w obwodzie chłodzenia 6*, z posortowanymi wartościami




Rys.5.2.1.34. Wykres przebiegu zmiennej niezależnej: *prędkość we wlewach doprowadzających*, z posortowanymi wartościami




Rys.5.2.1.35. Wykres przebiegu zmiennej niezależnej: *suw pierwszej fazy wtrysku*, z posortowanymi wartościami




Rys.5.2.1.36. Wykres przebiegu zmiennej niezależnej: *suw docisku po multiplikacji*, z posortowanymi wartościami




Rys.5.2.1.37. Wykres przebiegu zmiennej niezależnej: *temperatura chłodzenia tłoka*, z posortowanymi wartościami




Rys.5.2.1.38. Wykres przebiegu zmiennej niezależnej: *temperatura stopu*, z posortowanymi wartościami




Rys.5.2.1.39. Wykres przebiegu zmiennej niezależnej: *temperatura termoregulatora 2.1.*, z posortowanymi wartościami




Rys.5.2.1.40. Wykres przebiegu zmiennej niezależnej: *temperatura termoregulatora 2.2.*, z posortowanymi wartościami




Rys.5.2.1.41. Wykres przebiegu zmiennej niezależnej: *temperatura termoregulatora 3.2.*, z posortowanymi wartościami




Rys.5.2.1.42. Wykres przebiegu zmiennej niezależnej: *temperatura tulei 1*, z posortowanymi wartościami




Rys.5.2.1.43. Wykres przebiegu zmiennej niezależnej: *temperatura tulei 2*, z posortowanymi wartościami




Rys.5.2.1.44. Wykres przebiegu zmiennej niezależnej: *temperatura tulei 3*, z posortowanymi wartościami




Rys.5.2.1.45. Wykres przebiegu zmiennej niezależnej: *temperatura tulei 4*, z posortowanymi wartościami




Rys.5.2.1.46. Wykres przebiegu zmiennej niezależnej: *temperatura w obwodzie chłodzenia 1*, z posortowanymi wartościami




Rys.5.2.1.47. Wykres przebiegu zmiennej niezależnej: *temperatura w obwodzie chłodzenia 13*, z posortowanymi wartościami




Rys.5.2.1.48. Wykres przebiegu zmiennej niezależnej: *temperatura w obwodzie chłodzenia 14*, z posortowanymi wartościami




Rys.5.2.1.49. Wykres przebiegu zmiennej niezależnej: *temperatura w obwodzie chłodzenia 15*, z posortowanymi wartościami




Rys.5.2.1.50. Wykres przebiegu zmiennej niezależnej: *temperatura w obwodzie chłodzenia 17*, z posortowanymi wartościami




Rys.5.2.1.51. Wykres przebiegu zmiennej niezależnej: *temperatura w obwodzie chłodzenia 7*, z posortowanymi wartościami




Rys.5.2.1.52. Wykres przebiegu zmiennej niezależnej: *temperatura wody miejskiej*, z posortowanymi wartościami




Rys.5.2.1.53. Wykres przebiegu zmiennej niezależnej: *temperatura wody w instalacji*, z posortowanymi wartościami




Rys.5.2.1.54. Wykres przebiegu zmiennej niezależnej: *wartość próżni 1*, z posortowanymi wartościami



Rys.5.2.1.55. Wykres przebiegu zmiennej niezależnej: *wartość próżni 2*, z posortowanymi wartościami



Rys.5.2.1.56. Wykres przebiegu zmiennej niezależnej: *zużycie smaru*, z posortowanymi wartościami



Rys.5.2.1.57. Wykres przebiegu zmiennej zależnej: *przeciek w obwodzie wysokiego ciśnienia*, z posortowanymi wartościami

Tab. 5.1.: Wyniki normalizacji dla zmiennej niezależnej: *ciśnienie sprężonego powietrza*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	2664	20	1	2685	26,60
0.1-0.2	0	0	0	0	0,00
0.2-0.3	0	0	0	0	0,00
0.3-0.4	0	0	0	0	0,00

0.4-0.5	0	0	0	0	0,00
0.5-0.6	0	0	0	0	0,00
0.6-0.7	0	0	0	0	0,00
0.7-0.8	0	0	0	0	0,00
0.8-0.9	0	0	0	0	0,00
0.9-1	0	0	0	0	0,00
1.0	7360	38	11	7409	73,40
Suma:	10024	58	12	10094	100

Tab. 5.2.: Wyniki normalizacji dla zmiennej niezależnej: *ciśnienie wody miejskiej*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	84	0	0	84	0,83
0.1-0.2	1750	15	1	1766	17,50
0.2-0.3	0	0	0	0	0,00
0.3-0.4	6361	36	7	6404	63,44
0.4-0.5	1801	7	4	1812	17,95
0.5-0.6	0	0	0	0	0,00
0.6-0.7	18	0	0	18	0,18
0.7-0.8	0	0	0	0	0,00
0.8-0.9	4	0	0	4	0,04
0.9-1	0	0	0	0	0,00
1.0	6	0	0	6	0,06
Suma:	10024	58	12	10094	100

Tab. 5.3.: Wyniki normalizacji dla zmiennej niezależnej: *ciśnienie wody obiegowej*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	5201	35	5	5241	51,92
0.1-0.2	0	0	0	0	0,00
0.2-0.3	0	0	0	0	0,00
0.3-0.4	0	0	0	0	0,00
0.4-0.5	0	0	0	0	0,00
0.5-0.6	0	0	0	0	0,00
0.6-0.7	0	0	0	0	0,00
0.7-0.8	0	0	0	0	0,00
0.8-0.9	0	0	0	0	0,00
0.9-1	0	0	0	0	0,00
1.0	4823	23	7	4853	48,08
Suma:	10024	58	12	10094	100

Tab. 5.4.: Wyniki normalizacji dla zmiennej niezależnej: *czas pierwszej fazy wtrysku*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	145	0	0	145	1,44
0.1-0.2	440	3	0	443	4,39
0.2-0.3	1575	7	1	1583	15,68
0.3-0.4	2091	18	6	2115	20,95
0.4-0.5	2798	18	1	2817	27,91
0.5-0.6	2282	6	4	2292	22,71
0.6-0.7	616	6	0	622	6,16
0.7-0.8	59	0	0	59	0,58
0.8-0.9	13	0	0	13	0,13
0.9-1	4	0	0	4	0,04
1.0	1	0	0	1	0,01
Suma:	10024	58	12	10094	100

Tab. 5.5.: Wyniki normalizacji dla zmiennej niezależnej: *czas chłodzenia obwodu*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	44	1	0	45	0,45
0.1-0.2	0	0	0	0	0,00
0.2-0.3	0	0	0	0	0,00
0.3-0.4	0	0	0	0	0,00
0.4-0.5	0	0	0	0	0,00
0.5-0.6	9915	57	12	9984	98,91
0.6-0.7	0	0	0	0	0,00
0.7-0.8	0	0	0	0	0,00
0.8-0.9	0	0	0	0	0,00
0.9-1	0	0	0	0	0,00
1.0	65	0	0	65	0,64
Suma:	10024	58	12	10094	100

Tab. 5.6.: Wyniki normalizacji dla zmiennej niezależnej: *czas cyklu*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	6	0	0	6	0,06
0.1-0.2	9400	50	11	9461	93,73
0.2-0.3	338	6	1	345	3,42
0.3-0.4	143	2	0	145	1,44

0.4-0.5	91	0	0	91	0,90
0.5-0.6	29	0	0	29	0,29
0.6-0.7	10	0	0	10	0,10
0.7-0.8	1	0	0	1	0,01
0.8-0.9	4	0	0	4	0,04
0.9-1	1	0	0	1	0,01
1.0	1	0	0	1	0,01
Suma:	10024	58	12	10094	100,00

Tab. 5.7.: Wyniki normalizacji dla zmiennej niezależnej: *czas cyklu smarowania*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	9983	56	12	10051	99,57
0.1-0.2	14	1	0	15	0,15
0.2-0.3	18	1	0	19	0,19
0.3-0.4	5	0	0	5	0,05
0.4-0.5	2	0	0	2	0,02
0.5-0.6	0	0	0	0	0,00
0.6-0.7	0	0	0	0	0,00
0.7-0.8	1	0	0	1	0,01
0.8-0.9	0	0	0	0	0,00
0.9-1	0	0	0	0	0,00
1.0	1	0	0	1	0,01
Suma:	10024	58	12	10094	100

Tab. 5.8.: Wyniki normalizacji dla zmiennej niezależnej: *czas dozowania stopu*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	9859	56	12	9927	98,35
0.1-0.2	36	0	0	36	0,36
0.2-0.3	31	1	0	32	0,32
0.3-0.4	49	1	0	50	0,50
0.4-0.5	35	0	0	35	0,35
0.5-0.6	5	0	0	5	0,05
0.6-0.7	7	0	0	7	0,07
0.7-0.8	0	0	0	0	0,00
0.8-0.9	1	0	0	1	0,01
0.9-1	0	0	0	0	0,00
1.0	1	0	0	1	0,01
Suma:	10024	58	12	10094	100

Tab. 5.9.: Wyniki normalizacji dla zmiennej niezależnej: *czas dozowania stopu 2*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	41	0	0	41	0,41
0.1-0.2	8340	35	10	8385	83,07
0.2-0.3	1541	22	2	1565	15,50
0.3-0.4	21	0	0	21	0,21
0.4-0.5	4	0	0	4	0,04
0.5-0.6	19	1	0	20	0,20
0.6-0.7	46	0	0	46	0,46
0.7-0.8	5	0	0	5	0,05
0.8-0.9	2	0	0	2	0,02
0.9-1	5	0	0	5	0,05
1.0	0	0	0	0	0,00
Suma:	10024	58	12	10094	100

Tab. 5.10.: Wyniki normalizacji dla zmiennej niezależnej: *czas krzepnięcia t2*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	7457	21	11	7489	74,19
0.1-0.2	0	0	0	0	0,00
0.2-0.3	0	0	0	0	0,00
0.3-0.4	0	0	0	0	0,00
0.4-0.5	0	0	0	0	0,00
0.5-0.6	0	0	0	0	0,00
0.6-0.7	0	0	0	0	0,00
0.7-0.8	0	0	0	0	0,00
0.8-0.9	0	0	0	0	0,00
0.9-1	0	0	0	0	0,00
1.0	2567	37	1	2605	25,81
Suma:	10024	58	12	10094	100

Tab. 5.11.: Wyniki normalizacji dla zmiennej niezależnej: *czas przedmuchu*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	1	0	0	1	0,01
0.1-0.2	0	0	0	0	0,00
0.2-0.3	0	0	0	0	0,00
0.3-0.4	21	0	0	21	0,21

0.4-0.5	67	0	0	67	0,66
0.5-0.6	9281	47	10	9338	92,51
0.6-0.7	129	0	0	129	1,28
0.7-0.8	11	0	0	11	0,11
0.8-0.9	262	6	1	269	2,66
0.9-1	251	5	1	257	2,55
1.0	1	0	0	1	0,01
Suma:	10024	58	12	10094	100

Tab. 5.12.: Wyniki normalizacji dla zmiennej niezależnej: *czas smarowania*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	31	0	0	31	0,31
0.1-0.2	0	0	0	0	0,00
0.2-0.3	1	0	0	1	0,01
0.3-0.4	0	0	0	0	0,00
0.4-0.5	0	0	0	0	0,00
0.5-0.6	9747	49	11	9807	97,16
0.6-0.7	0	0	0	0	0,00
0.7-0.8	0	0	0	0	0,00
0.8-0.9	0	0	0	0	0,00
0.9-1	240	9	1	250	2,48
1.0	5	0	0	5	0,05
Suma:	10024	58	12	10094	100

Tab. 5.13.: Wyniki normalizacji dla zmiennej niezależnej: *dzienny numer wtrysku*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	1853	20	2	1875	18,58
0.1-0.2	1814	9	3	1826	18,09
0.2-0.3	1553	8	1	1562	15,47
0.3-0.4	1382	4	1	1387	13,74
0.4-0.5	1219	7	3	1229	12,18
0.5-0.6	949	6	1	956	9,47
0.6-0.7	533	2	0	535	5,30
0.7-0.8	455	1	1	457	4,53
0.8-0.9	203	1	0	204	2,02
0.9-1	63	0	0	63	0,62
1.0	0	0	0	0	0,00
Suma:	10024	58	12	10094	100

Tab. 5.14.: Wyniki normalizacji dla zmiennej niezależnej: *filtr próżni 1*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	112	1	0	113	1,12
0.1-0.2	293	0	0	293	2,90
0.2-0.3	43	0	0	43	0,43
0.3-0.4	32	1	0	33	0,33
0.4-0.5	763	1	0	764	7,57
0.5-0.6	3801	14	8	3823	37,87
0.6-0.7	2745	29	3	2777	27,51
0.7-0.8	1038	8	1	1047	10,37
0.8-0.9	1071	4	0	1075	10,64
0.9-1	126	0	0	126	1,25
1.0	0	0	0	0	0,00
Suma:	10024	58	12	10094	100

Tab. 5.15.: Wyniki normalizacji dla zmiennej niezależnej: *grubość piętki układu wlewowego*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	86	0	1	87	0,86
0.1-0.2	356	0	0	356	3,53
0.2-0.3	997	3	3	1003	9,93
0.3-0.4	2789	9	3	2801	27,75
0.4-0.5	3362	25	5	3392	33,60
0.5-0.6	1757	20	0	1777	17,60
0.6-0.7	529	1	0	530	5,25
0.7-0.8	131	0	0	131	1,29
0.8-0.9	15	0	0	15	0,15
0.9-1	1	0	0	1	0,01
1.0	1	0	0	1	0,01
Suma:	10024	58	12	10094	100

Tab. 5.16.: Wyniki normalizacji dla zmiennej niezależnej: *koncentrat*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	8	0	0	8	0,08
0.1-0.2	16	0	0	16	0,16
0.2-0.3	83	0	0	83	0,82
0.3-0.4	213	1	0	214	2,12

0.4-0.5	312	0	0	312	3,09
0.5-0.6	921	4	1	926	9,17
0.6-0.7	586	6	0	592	5,86
0.7-0.8	514	1	0	515	5,10
0.8-0.9	2791	17	5	2813	27,87
0.9-1	3462	18	6	3486	34,54
1.0	1118	11	0	1129	11,18
Suma:	10024	58	12	10094	100

Tab. 5.17.: Wyniki normalizacji dla zmiennej niezależnej: *ciśnienie maksymalne*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	249	2	0	251	2,49
0.1-0.2	1333	17	0	1350	13,37
0.2-0.3	2314	16	4	2334	23,12
0.3-0.4	2652	12	3	2667	26,42
0.4-0.5	1938	7	2	1947	19,29
0.5-0.6	1029	2	3	1034	10,24
0.6-0.7	364	2	0	366	3,63
0.7-0.8	125	0	0	125	1,24
0.8-0.9	19	0	0	19	0,19
0.9-1	0	0	0	0	0,00
1.0	1	0	0	1	0,01
Suma:	10024	58	12	10094	100

Tab. 5.18.: Wyniki normalizacji dla zmiennej niezależnej, *prędkość wtrysku maksymalna*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	5	0	0	5	0,05
0.1-0.2	11	0	0	11	0,11
0.2-0.3	38	1	0	39	0,39
0.3-0.4	540	7	1	548	5,43
0.4-0.5	1	0	0	1	0,01
0.5-0.6	4597	35	5	4637	45,94
0.6-0.7	38	1	0	39	0,39
0.7-0.8	4615	14	6	4635	45,92
0.8-0.9	5	0	0	5	0,05
0.9-1	106	0	0	106	1,05
1.0	68	0	0	68	0,67
Suma:	10024	58	12	10094	100

Tab. 5.19.: Wyniki normalizacji dla zmiennej niezależnej: *opóźnienie multiplikacji*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	2	0	0	2	0,02
0.1-0.2	2	0	0	2	0,02
0.2-0.3	54	0	0	54	0,53
0.3-0.4	127	0	0	127	1,26
0.4-0.5	412	2	0	414	4,10
0.5-0.6	2494	6	5	2505	24,82
0.6-0.7	2214	11	3	2228	22,07
0.7-0.8	3820	26	4	3850	38,14
0.8-0.9	752	10	0	762	7,55
0.9-1	135	3	0	138	1,37
1.0	12	0	0	12	0,12
Suma:	10024	58	12	10094	100

Tab. 5.20.: Wyniki normalizacji dla zmiennej niezależnej: *stała temperatura chłodzenia płyty*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	21	0	0	21	0,21
0.1-0.2	643	3	1	647	6,41
0.2-0.3	5793	13	9	5815	57,61
0.3-0.4	2539	11	1	2551	25,27
0.4-0.5	0	0	0	0	0,00
0.5-0.6	316	7	0	323	3,20
0.6-0.7	496	18	0	514	5,09
0.7-0.8	194	6	1	201	1,99
0.8-0.9	7	0	0	7	0,07
0.9-1	0	0	0	0	0,00
1.0	15	0	0	15	0,15
Suma:	10024	58	12	10094	100

Tab. 5.21.: Wyniki normalizacji dla zmiennej niezależnej: *poziom stopu w piecu podgrzewczym*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	9397	58	12	9467	93,79
0.1-0.2	0	0	0	0	0,00
0.2-0.3	0	0	0	0	0,00
0.3-0.4	0	0	0	0	0,00

0.4-0.5	0	0	0	0	0,00
0.5-0.6	0	0	0	0	0,00
0.6-0.7	0	0	0	0	0,00
0.7-0.8	0	0	0	0	0,00
0.8-0.9	0	0	0	0	0,00
0.9-1	627	0	0	627	6,21
1.0	0	0	0	0	0,00
Suma:	10024	58	12	10094	100

Tab. 5.22.: Wyniki normalizacji dla zmiennej niezależnej: *poziom wody w strumieniu chłodzącym*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	528	1	2	531	5,26
0.1-0.2	390	1	1	392	3,88
0.2-0.3	861	2	0	863	8,55
0.3-0.4	1215	2	0	1217	12,06
0.4-0.5	1497	10	4	1511	14,97
0.5-0.6	1636	14	2	1652	16,37
0.6-0.7	1487	10	3	1500	14,86
0.7-0.8	1863	8	0	1871	18,54
0.8-0.9	508	7	0	515	5,10
0.9-1	35	3	0	38	0,38
1.0	4	0	0	4	0,04
Suma:	10024	58	12	10094	100

Tab. 5.23.: Wyniki normalizacji dla zmiennej niezależnej: *czas drugiej fazy wtrysku*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	6	0	0	6	0,06
0.1-0.2	292	2	0	294	2,91
0.2-0.3	0	0	0	0	0,00
0.3-0.4	3059	22	2	3083	30,54
0.4-0.5	0	0	0	0	0,00
0.5-0.6	4896	24	8	4928	48,82
0.6-0.7	1603	9	2	1614	15,99
0.7-0.8	0	0	0	0	0,00
0.8-0.9	166	1	0	167	1,65
0.9-1	0	0	0	0	0,00
1.0	2	0	0	2	0,02
Suma:	10024	58	12	10094	100

Tab. 5.24.: Wyniki normalizacji dla zmiennej niezależnej: *profil próżni 1*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	7964	48	10	8022	79,47
0.1-0.2	1478	7	2	1487	14,73
0.2-0.3	558	3	0	561	5,56
0.3-0.4	3	0	0	3	0,03
0.4-0.5	2	0	0	2	0,02
0.5-0.6	2	0	0	2	0,02
0.6-0.7	15	0	0	15	0,15
0.7-0.8	1	0	0	1	0,01
0.8-0.9	0	0	0	0	0,00
0.9-1	1	0	0	1	0,01
1.0	0	0	0	0	0,00
Suma:	10024	58	12	10094	100

Tab. 5.25.: Wyniki normalizacji dla zmiennej niezależnej: *profil próżni 2*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	2428	3	0	2431	24,08
0.1-0.2	1161	1	6	1168	11,57
0.2-0.3	6313	54	6	6373	63,14
0.3-0.4	98	0	0	98	0,97
0.4-0.5	4	0	0	4	0,04
0.5-0.6	0	0	0	0	0,00
0.6-0.7	9	0	0	9	0,09
0.7-0.8	9	0	0	9	0,09
0.8-0.9	0	0	0	0	0,00
0.9-1	1	0	0	1	0,01
1.0	1	0	0	1	0,01
Suma:	10024	58	12	10094	100

Tab. 5.26.: Wyniki normalizacji dla zmiennej niezależnej: *przepływ chłodzenia tłoka*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	1	0	0	1	0,01
0.1-0.2	135	0	0	135	1,34
0.2-0.3	10	0	0	10	0,10
0.3-0.4	189	0	1	190	1,88

0.4-0.5	322	0	0	322	3,19
0.5-0.6	782	2	0	784	7,77
0.6-0.7	5751	11	8	5770	57,16
0.7-0.8	91	2	0	93	0,92
0.8-0.9	523	9	0	532	5,27
0.9-1	1946	31	3	1980	19,62
1.0	274	3	0	277	2,74
Suma:	10024	58	12	10094	100

Tab. 5.27.: Wyniki normalizacji dla zmiennej niezależnej: *przepływ w obwodzie chłodzenia 1*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	22	0	0	22	0,22
0.1-0.2	286	10	0	296	2,93
0.2-0.3	684	17	0	701	6,94
0.3-0.4	0	0	0	0	0,00
0.4-0.5	1347	17	1	1365	13,52
0.5-0.6	4875	7	6	4888	48,42
0.6-0.7	0	0	0	0	0,00
0.7-0.8	2341	6	4	2351	23,29
0.8-0.9	367	1	1	369	3,66
0.9-1	102	0	0	102	1,01
1.0	0	0	0	0	0,00
Suma:	10024	58	12	10094	100

Tab. 5.28.: Wyniki normalizacji dla zmiennej niezależnej: *przepływ w obwodzie chłodzenia 13*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	2	0	0	2	0,02
0.1-0.2	57	0	0	57	0,56
0.2-0.3	114	0	0	114	1,13
0.3-0.4	67	0	0	67	0,66
0.4-0.5	45	0	0	45	0,45
0.5-0.6	98	0	1	99	0,98
0.6-0.7	5581	7	7	5595	55,43
0.7-0.8	189	4	0	193	1,91
0.8-0.9	2148	33	3	2184	21,64
0.9-1	1718	14	1	1733	17,17
1.0	5	0	0	5	0,05
Suma:	10024	58	12	10094	100

Tab. 5.29.: Wyniki normalizacji dla zmiennej niezależnej: *przepływ w obwodzie chłodzenia 14*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	2	0	0	2	0,02
0.1-0.2	22	0	0	22	0,22
0.2-0.3	67	0	0	67	0,66
0.3-0.4	0	0	0	0	0,00
0.4-0.5	788	18	0	806	7,98
0.5-0.6	2443	28	1	2472	24,49
0.6-0.7	0	0	0	0	0,00
0.7-0.8	5590	10	10	5610	55,58
0.8-0.9	1095	2	1	1098	10,87
0.9-1	0	0	0	0	0,00
1.0	17	0	0	17	0,17
Suma:	10024	58	12	10094	100

Tab. 5.30.: Wyniki normalizacji dla zmiennej niezależnej: *przepływ w obwodzie chłodzenia 15*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	37	0	0	37	0,37
0.1-0.2	133	0	0	133	1,32
0.2-0.3	2023	17	0	2040	20,21
0.3-0.4	4849	14	7	4870	48,25
0.4-0.5	2475	7	4	2486	24,63
0.5-0.6	403	19	1	423	4,19
0.6-0.7	84	0	0	84	0,83
0.7-0.8	0	0	0	0	0,00
0.8-0.9	0	0	0	0	0,00
0.9-1	1	0	0	1	0,01
1.0	19	1	0	20	0,20
Suma:	10024	58	12	10094	100

Tab. 5.31.: Wyniki normalizacji dla zmiennej niezależnej: *przepływ w obwodzie chłodzenia 17*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	35	0	0	35	0,35
0.1-0.2	67	3	0	70	0,69
0.2-0.3	15	0	0	15	0,15
0.3-0.4	544	17	0	561	5,56

0.4-0.5	1469	5	0	1474	14,60
0.5-0.6	2033	14	2	2049	20,30
0.6-0.7	182	1	0	183	1,81
0.7-0.8	301	2	0	303	3,00
0.8-0.9	3669	15	5	3689	36,55
0.9-1	1475	1	5	1481	14,67
1.0	234	0	0	234	2,32
Suma:	10024	58	12	10094	100

Tab. 5.32.: Wyniki normalizacji dla zmiennej niezależnej: *przepływ w obwodzie chłodzenia 20*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	36	0	0	36	0,36
0.1-0.2	0	0	0	0	0,00
0.2-0.3	174	1	0	175	1,73
0.3-0.4	0	0	0	0	0,00
0.4-0.5	1492	29	1	1522	15,08
0.5-0.6	0	0	0	0	0,00
0.6-0.7	5265	20	7	5292	52,43
0.7-0.8	0	0	0	0	0,00
0.8-0.9	2949	8	3	2960	29,32
0.9-1	0	0	0	0	0,00
1.0	108	0	1	109	1,08
Suma:	10024	58	12	10094	100

Tab. 5.33.: Wyniki normalizacji dla zmiennej niezależnej: *przepływ w obwodzie chłodzenia 6*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	2	0	0	2	0,02
0.1-0.2	0	0	0	0	0,00
0.2-0.3	4	0	0	4	0,04
0.3-0.4	549	1	0	550	5,45
0.4-0.5	1857	2	2	1861	18,44
0.5-0.6	600	4	1	605	5,99
0.6-0.7	2328	28	0	2356	23,34
0.7-0.8	3227	22	6	3255	32,25
0.8-0.9	345	1	0	346	3,43
0.9-1	1075	0	2	1077	10,66
1.0	37	0	1	38	0,38
Suma:	10024	58	12	10094	100

Tab. 5.34.: Wyniki normalizacji dla zmiennej niezależnej: *prędkość we wlewach doprowadzających*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	4	0	0	4	0,04
0.1-0.2	9	0	0	9	0,09
0.2-0.3	153	1	0	154	1,53
0.3-0.4	547	5	0	552	5,46
0.4-0.5	2010	8	3	2021	20,02
0.5-0.6	3434	21	3	3458	34,26
0.6-0.7	2605	13	4	2622	25,98
0.7-0.8	1100	8	2	1110	10,99
0.8-0.9	156	2	0	158	1,57
0.9-1	5	0	0	5	0,05
1.0	1	0	0	1	0,01
Suma:	10024	58	12	10094	100

Tab. 5.35.: Wyniki normalizacji dla zmiennej niezależnej: *suw pierwszej fazy wtrysku*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	1	0	0	1	0,01
0.1-0.2	11	0	0	11	0,11
0.2-0.3	220	0	0	220	2,18
0.3-0.4	2649	20	2	2671	26,46
0.4-0.5	0	0	0	0	0,00
0.5-0.6	4411	23	6	4440	43,99
0.6-0.7	2399	13	3	2415	23,93
0.7-0.8	299	2	1	302	2,99
0.8-0.9	29	0	0	29	0,29
0.9-1	0	0	0	0	0,00
1.0	5	0	0	5	0,05
Suma:	10024	58	12	10094	100

Tab. 5.36.: Wyniki normalizacji dla zmiennej niezależnej: *suw docisku po multiplikacji*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	3	1	0	4	0,04
0.1-0.2	7	0	0	7	0,07
0.2-0.3	0	0	0	0	0,00
0.3-0.4	179	3	1	183	1,81

0.4-0.5	0	0	0	0	0,00
0.5-0.6	2151	20	1	2172	21,52
0.6-0.7	6139	27	9	6175	61,18
0.7-0.8	0	0	0	0	0,00
0.8-0.9	1538	7	1	1546	15,32
0.9-1	0	0	0	0	0,00
1.0	7	0	0	7	0,07
Suma:	10024	58	12	10094	100

Tab. 5.37.: Wyniki normalizacji dla zmiennej niezależnej: *temperatura chłodzenia tłoka*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	91	0	1	92	0,91
0.1-0.2	178	1	0	179	1,77
0.2-0.3	1503	21	2	1526	15,12
0.3-0.4	3109	13	0	3122	30,93
0.4-0.5	4016	21	7	4044	40,06
0.5-0.6	1003	2	2	1007	9,98
0.6-0.7	6	0	0	6	0,06
0.7-0.8	24	0	0	24	0,24
0.8-0.9	61	0	0	61	0,60
0.9-1	27	0	0	27	0,27
1.0	6	0	0	6	0,06
Suma:	10024	58	12	10094	100

Tab. 5.38.: Wyniki normalizacji dla zmiennej niezależnej: *temperatura stopu*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	2	0	0	2	0,02
0.1-0.2	16	0	1	17	0,17
0.2-0.3	356	0	0	356	3,53
0.3-0.4	1604	7	5	1616	16,01
0.4-0.5	2959	21	3	2983	29,55
0.5-0.6	2382	20	0	2402	23,80
0.6-0.7	1766	5	2	1773	17,56
0.7-0.8	759	4	0	763	7,56
0.8-0.9	164	1	1	166	1,64
0.9-1	15	0	0	15	0,15
1.0	1	0	0	1	0,01
Suma:	10024	58	12	10094	100

Tab. 5.39.: Wyniki normalizacji dla zmiennej *temperatura termoregulatora 2.1.*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	12	1	0	13	0,13
0.1-0.2	15	0	0	15	0,15
0.2-0.3	2757	21	4	2782	27,56
0.3-0.4	1932	14	1	1947	19,29
0.4-0.5	1352	2	1	1355	13,42
0.5-0.6	2490	11	3	2504	24,81
0.6-0.7	1330	7	3	1340	13,28
0.7-0.8	130	1	0	131	1,29
0.8-0.9	6	0	0	6	0,06
0.9-1	0	0	0	0	0,00
1.0	0	1	0	1	0,01
Suma:	10024	58	12	10094	100

Tab. 5.40.: Wyniki normalizacji dla zmiennej *temperatura termoregulatora 2.2.*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	7	0	0	7	0,07
0.1-0.2	34	0	0	34	0,34
0.2-0.3	73	0	0	73	0,72
0.3-0.4	1346	7	1	1354	13,41
0.4-0.5	1807	7	2	1816	17,99
0.5-0.6	1951	10	3	1964	19,46
0.6-0.7	4719	33	6	4758	47,14
0.7-0.8	44	0	0	44	0,44
0.8-0.9	28	0	0	28	0,28
0.9-1	13	0	0	13	0,13
1.0	2	1	0	3	0,03
Suma:	10024	58	12	10094	100

Tab. 5.41.: Wyniki normalizacji dla zmiennej *temperatura termoregulatora 3.2.*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	0	1	0	1	0,01
0.1-0.2	1	0	0	1	0,01
0.2-0.3	1	0	0	1	0,01
0.3-0.4	1	0	0	1	0,01

0.4-0.5	3	0	0	3	0,03
0.5-0.6	4	0	0	4	0,04
0.6-0.7	191	0	0	191	1,89
0.7-0.8	3982	30	4	4016	39,79
0.8-0.9	3120	15	3	3138	31,09
0.9-1	2494	12	3	2509	24,86
1.0	227	0	2	229	2,27
Suma:	10024	58	12	10094	100

Tab. 5.42.: Wyniki normalizacji dla zmiennej niezależnej: *temperatura tulei 1*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	3	0	0	3	0,03
0.1-0.2	0	0	0	0	0,00
0.2-0.3	0	0	0	0	0,00
0.3-0.4	0	0	0	0	0,00
0.4-0.5	0	0	0	0	0,00
0.5-0.6	1	0	0	1	0,01
0.6-0.7	0	0	0	0	0,00
0.7-0.8	37	1	1	39	0,39
0.8-0.9	8930	46	10	8986	89,02
0.9-1	1052	11	1	1064	10,54
1.0	1	0	0	1	0,01
Suma:	10024	58	12	10094	100

Tab. 5.43.: Wyniki normalizacji dla zmiennej niezależnej: *temperatura tulei 2*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	3	0	0	3	0,03
0.1-0.2	0	0	0	0	0,00
0.2-0.3	0	0	0	0	0,00
0.3-0.4	0	0	0	0	0,00
0.4-0.5	0	0	0	0	0,00
0.5-0.6	1	0	0	1	0,01
0.6-0.7	0	0	0	0	0,00
0.7-0.8	1	0	0	1	0,01
0.8-0.9	352	1	0	353	3,50
0.9-1	9665	57	12	9734	96,43
1.0	2	0	0	2	0,02
Suma:	10024	58	12	10094	100

Tab. 5.44.: Wyniki normalizacji dla zmiennej niezależnej: *temperatura tulei 3*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	3	0	0	3	0,03
0.1-0.2	0	0	0	0	0,00
0.2-0.3	0	0	0	0	0,00
0.3-0.4	0	0	0	0	0,00
0.4-0.5	1	0	0	1	0,01
0.5-0.6	0	0	0	0	0,00
0.6-0.7	0	0	0	0	0,00
0.7-0.8	63	1	0	64	0,63
0.8-0.9	9406	49	10	9465	93,77
0.9-1	550	8	2	560	5,55
1.0	1	0	0	1	0,01
Suma:	10024	58	12	10094	100

Tab. 5.45.: Wyniki normalizacji dla zmiennej niezależnej: *temperatura tulei 4*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	3	0	0	3	0,03
0.1-0.2	0	0	0	0	0,00
0.2-0.3	0	0	0	0	0,00
0.3-0.4	0	0	0	0	0,00
0.4-0.5	1	0	0	1	0,01
0.5-0.6	0	0	0	0	0,00
0.6-0.7	0	0	0	0	0,00
0.7-0.8	4	0	0	4	0,04
0.8-0.9	7259	33	8	7300	72,32
0.9-1	2755	25	4	2784	27,58
1.0	2	0	0	2	0,02
Suma:	10024	58	12	10094	100

Tab. 5.46.: Wyniki normalizacji dla zmiennej niezależnej: *temperatura w obwodzie chłodzenia 1*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	1455	3	1	1459	14,45
0.1-0.2	5461	18	8	5487	54,36
0.2-0.3	2352	19	0	2371	23,49
0.3-0.4	464	14	2	480	4,75

0.4-0.5	56	0	0	56	0,55
0.5-0.6	62	1	0	63	0,62
0.6-0.7	130	2	1	133	1,32
0.7-0.8	29	0	0	29	0,29
0.8-0.9	9	1	0	10	0,10
0.9-1	5	0	0	5	0,05
1.0	1	0	0	1	0,01
Suma:	10024	58	12	10094	100

Tab. 5.47.: Wyniki normalizacji dla zmiennej niezależnej: *temperatura w obwodzie chłodzenia 13*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	7	1	0	8	0,08
0.1-0.2	90	4	1	95	0,94
0.2-0.3	879	4	0	883	8,75
0.3-0.4	6552	38	9	6599	65,38
0.4-0.5	0	0	0	0	0,00
0.5-0.6	2024	7	1	2032	20,13
0.6-0.7	252	4	0	256	2,54
0.7-0.8	184	0	1	185	1,83
0.8-0.9	34	0	0	34	0,34
0.9-1	0	0	0	0	0,00
1.0	2	0	0	2	0,02
Suma:	10024	58	12	10094	100

Tab. 5.48.: Wyniki normalizacji dla zmiennej niezależnej: *temperatura w obwodzie chłodzenia 14*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	25	0	0	25	0,25
0.1-0.2	521	7	1	529	5,24
0.2-0.3	4465	10	6	4481	44,39
0.3-0.4	0	0	0	0	0,00
0.4-0.5	4152	28	4	4184	41,45
0.5-0.6	800	11	1	812	8,04
0.6-0.7	0	0	0	0	0,00
0.7-0.8	57	2	0	59	0,58
0.8-0.9	3	0	0	3	0,03
0.9-1	0	0	0	0	0,00
1.0	1	0	0	1	0,01
Suma:	10024	58	12	10094	100

Tab. 5.49.: Wyniki normalizacji dla zmiennej niezależnej: *temperatura w obwodzie chłodzenia 15*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	65	4	0	69	0,68
0.1-0.2	1111	7	0	1118	11,08
0.2-0.3	3680	19	8	3707	36,72
0.3-0.4	4183	22	3	4208	41,69
0.4-0.5	789	3	0	792	7,85
0.5-0.6	123	2	1	126	1,25
0.6-0.7	61	1	0	62	0,61
0.7-0.8	8	0	0	8	0,08
0.8-0.9	3	0	0	3	0,03
0.9-1	0	0	0	0	0,00
1.0	1	0	0	1	0,01
Suma:	10024	58	12	10094	100

Tab. 5.50.: Wyniki normalizacji dla zmiennej niezależnej: *temperatura w obwodzie chłodzenia 17*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	469	6	0	475	4,71
0.1-0.2	2596	12	1	2609	25,85
0.2-0.3	734	8	1	743	7,36
0.3-0.4	476	1	2	479	4,75
0.4-0.5	1134	5	1	1140	11,29
0.5-0.6	2899	7	7	2913	28,86
0.6-0.7	1306	11	0	1317	13,05
0.7-0.8	283	6	0	289	2,86
0.8-0.9	108	2	0	110	1,09
0.9-1	17	0	0	17	0,17
1.0	2	0	0	2	0,02
Suma:	10024	58	12	10094	100

Tab. 5.51.: Wyniki normalizacji dla zmiennej niezależnej: *temperatura w obwodzie chłodzenia 7*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	37	0	0	37	0,37
0.1-0.2	926	6	1	933	9,24
0.2-0.3	5856	21	8	5885	58,30
0.3-0.4	0	0	0	0	0,00

0.4-0.5	2813	27	2	2842	28,16
0.5-0.6	292	2	1	295	2,92
0.6-0.7	0	0	0	0	0,00
0.7-0.8	72	2	0	74	0,73
0.8-0.9	22	0	0	22	0,22
0.9-1	0	0	0	0	0,00
1.0	6	0	0	6	0,06
Suma:	10024	58	12	10094	100

Tab. 5.52.: Wyniki normalizacji dla zmiennej niezależnej: *temperatura wody miejskiej*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	42	0	0	42	0,42
0.1-0.2	618	1	0	619	6,13
0.2-0.3	1872	17	2	1891	18,73
0.3-0.4	4591	30	3	4624	45,81
0.4-0.5	1210	4	4	1218	12,07
0.5-0.6	1538	5	3	1546	15,32
0.6-0.7	138	1	0	139	1,38
0.7-0.8	11	0	0	11	0,11
0.8-0.9	0	0	0	0	0,00
0.9-1	0	0	0	0	0,00
1.0	4	0	0	4	0,04
Suma:	10024	58	12	10094	100

Tab. 5.53.: Wyniki normalizacji dla zmiennej niezależnej: *temperatura wody w instalacji*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	20	0	0	20	0,20
0.1-0.2	0	0	0	0	0,00
0.2-0.3	368	1	1	370	3,67
0.3-0.4	0	0	0	0	0,00
0.4-0.5	0	0	0	0	0,00
0.5-0.6	4569	23	7	4599	45,56
0.6-0.7	0	0	0	0	0,00
0.7-0.8	4866	30	4	4900	48,54
0.8-0.9	0	0	0	0	0,00
0.9-1	0	0	0	0	0,00
1.0	201	4	0	205	2,03
Suma:	10024	58	12	10094	100

Tab. 5.54.: Wyniki normalizacji dla zmiennej niezależnej: *wartość próżni 1*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	1440	1	4	1445	14,32
0.1-0.2	2597	7	4	2608	25,84
0.2-0.3	4129	42	4	4175	41,36
0.3-0.4	1553	8	0	1561	15,46
0.4-0.5	291	0	0	291	2,88
0.5-0.6	10	0	0	10	0,10
0.6-0.7	0	0	0	0	0,00
0.7-0.8	0	0	0	0	0,00
0.8-0.9	0	0	0	0	0,00
0.9-1	4	0	0	4	0,04
1.0	0	0	0	0	0,00
Suma:	10024	58	12	10094	100

Tab. 5.55.: Wyniki normalizacji dla zmiennej niezależnej: *wartość próżni 2*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	1124	3	0	1127	11,17
0.1-0.2	1440	1	5	1446	14,33
0.2-0.3	1905	3	0	1908	18,90
0.3-0.4	5533	51	7	5591	55,39
0.4-0.5	15	0	0	15	0,15
0.5-0.6	3	0	0	3	0,03
0.6-0.7	0	0	0	0	0,00
0.7-0.8	0	0	0	0	0,00
0.8-0.9	1	0	0	1	0,01
0.9-1	2	0	0	2	0,02
1.0	1	0	0	1	0,01
Suma:	10024	58	12	10094	100

Tab. 5.56.: Wyniki normalizacji dla zmiennej niezależnej: *zużycie smaru*, w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)

Przedział	Ilość produktów bez wady [szt.]	Ilość produktów z wadą naprawialną [szt.]	Ilość produktów z wadą nienaprawialną [szt.]	Ilość obserwacji [szt.]	Udział procentowy obserwacji [%]
0.0-0.1	8255	49	11	8315	82,38
0.1-0.2	0	0	0	0	0,00
0.2-0.3	1534	8	1	1543	15,29
0.3-0.4	0	0	0	0	0,00

0.4-0.5	209	1	0	210	2,08
0.5-0.6	0	0	0	0	0,00
0.6-0.7	20	0	0	20	0,20
0.7-0.8	0	0	0	0	0,00
0.8-0.9	4	0	0	4	0,04
0.9-1	0	0	0	0	0,00
1.0	2	0	0	2	0,02
Suma:	10024	58	12	10094	100

Po stworzeniu wykresów i normalizacji zakresów dla każdej zmiennej wejściowej, na podstawie największego ilościowego udziału w danych zakresach wartości i największej liczby odlewów naprawialnych i nienaprawialnych, można wywnioskować zakresy dla każdego parametru danych, mające znaczący wpływ na powstawanie wady produktu. Na podstawie przeprowadzonej zastąpiono zidentyfikowane wartości błędne lub odstające za pomocą teoretycznych wartości minimalnych i maksymalnych danej zmiennej, wyznaczonych bez brania pod uwagę wartości odstających [146] i za pomocą średnich wartości danej zmiennej.

Tab. 5.59.: Wybrane zakresy zmiennych niezależnych:

Nazwa zmiennej niezależnej	Wybrany zakres wartości
<i>Ciśnienie sprężonego powietrza [Bar]</i>	$\geq 0.0 \leq 1.0$
<i>Ciśnienie wody miejskiej [Bar]</i>	$\geq 0.1 < 0.5$
<i>Ciśnienie wody obiegowej [Bar]</i>	$\geq 0.0 \leq 1.0$
<i>Czas pierwszej fazy wtrysku [ms]</i>	$\geq 0.1 < 0.7$
<i>Czas chłodzenia obwodu 1 [s]</i>	$\geq 0.0 \leq 1.0$
<i>Czas cyklu [s]</i>	$\geq 0.1 < 0.4$
<i>Czas cyklu smarowania [s]</i>	$\geq 0.0 < 0.1$
<i>Czas dozowania stopu 1 [s]</i>	$\geq 0.0 < 0.1$
<i>Czas dozowania stopu 2 [s]</i>	$\geq 0.1 < 0.3$
<i>Czas krzepnięcia t2 [s]</i>	$\geq 0.0 \leq 1.0$
<i>Czas przedmuchu [s]</i>	$\geq 0.5 < 0.6, \geq 0.8 < 1.0$
<i>Czas smarowania [s]</i>	$\geq 0.5 < 0.6, \geq 0.9 < 1.0$
<i>Dzienny numer wtrysku [j.]</i>	$\geq 0.0 < 0.9$
<i>Filtr próżni 1 [mBar]</i>	$\geq 0.4 < 0.9$
<i>Grubość piętki układu wlewowego [mm]</i>	$\geq 0.1 < 0.8$
<i>Koncentrat [%]</i>	$\geq 0.3 \leq 1.0$
<i>Ciśnienie maksymalne [Bar]</i>	$\geq 0.0 < 0.8$

<i>Prędkość wtrysku maksymalna [m/s]</i>	$\geq 0.3 < 0.4, \geq 0.5 < 0.6, \geq 0.7 < 0.8,$
<i>Opóźnienie multiplikacji [ms]</i>	$\geq 0.3 < 1.0$
<i>Stała temperatura chłodzenia płyty [°C]</i>	$\geq 0.1 < 0.4, \geq 0.5 < 0.8$
<i>Poziom stopu w piecu podgrzewczym [mm]</i>	$\geq 0.0 < 0.1$
<i>Poziom wody w strumieniu chłodzącym [mm]</i>	$\geq 0.0 < 0.9$
<i>Czas drugiej fazy wtrysku [ms]</i>	$\geq 0.3 < 0.4, \geq 0.5 < 0.7$
<i>Profil próżni 1 [mBar]</i>	$\geq 0.0 < 0.3$
<i>Profil próżni 2 [mBar]</i>	$\geq 0.0 < 0.3$
<i>Przepływ chłodzenia tłoka [l]</i>	$\geq 0.3 < 0.7, \geq 0.8 \leq 1.0$
<i>Przepływ w obwodzie chłodzenia 1 [l]</i>	$\geq 0.1 < 0.3, \geq 0.4 < 0.6, \geq 0.7 < 0.9$
<i>Przepływ w obwodzie chłodzenia 13 [l]</i>	$\geq 0.5 < 1.0$
<i>Przepływ w obwodzie chłodzenia 14 [l]</i>	$\geq 0.4 < 0.6, \geq 0.7 < 0.9$
<i>Przepływ w obwodzie chłodzenia 15 [l]</i>	$\geq 0.2 < 0.6$
<i>Przepływ w obwodzie chłodzenia 17 [l]</i>	$\geq 0.3 \leq 1.0$
<i>Przepływ w obwodzie chłodzenia 20 [l]</i>	$\geq 0.2 < 0.3, \geq 0.4 < 0.5, \geq 0.6 < 0.7, \geq 0.8 < 0.9, \leq 1.0$
<i>Przepływ w obwodzie chłodzenia 6 [l]</i>	$\geq 0.3 \leq 1.0$
<i>Prędkość we wlewach doprowadzających [m/s]</i>	$\geq 0.2 < 0.9$
<i>Suw pierwszej fazy wtrysku [mm]</i>	$\geq 0.2 < 0.4, \geq 0.5 < 0.8$
<i>Suw docisku po multiplikacji [mm]</i>	$\geq 0.3 < 0.4, \geq 0.5 < 0.7, \geq 0.8 < 0.9$
<i>Temperatura chłodzenia tłoka [°C]</i>	$\geq 0.0 < 0.6$
<i>Temperatura stopu [°C]</i>	$\geq 0.1 < 0.9$
<i>Temperatura termoregulatora 2.1 [°C]</i>	$\geq 0.2 < 0.8$
<i>Temperatura termoregulatora 2.2 [°C]</i>	$\geq 0.3 < 0.7$
<i>Temperatura termoregulatora 3.2 [°C]</i>	$\geq 0.6 \leq 1.0$
<i>Temperatura tulei 1 [°C]</i>	$\geq 0.7 < 1.0$
<i>Temperatura tulei 2 [°C]</i>	$\geq 0.8 < 1.0$
<i>Temperatura tulei 3 [°C]</i>	$\geq 0.7 < 1.0$
<i>Temperatura tulei 4 [°C]</i>	$\geq 0.8 < 1.0$
<i>Temperatura w obwodzie chłodzenia 1 [°C]</i>	$\geq 0.0 < 0.8$
<i>Temperatura w obwodzie chłodzenia 13 [°C]</i>	$\geq 0.1 < 0.4, \geq 0.5 < 0.9$
<i>Temperatura w obwodzie chłodzenia 14 [°C]</i>	$\geq 0.1 < 0.3, \geq 0.4 < 0.6$
<i>Temperatura w obwodzie chłodzenia 15 [°C]</i>	$\geq 0.1 < 0.6$

<i>Temperatura w obwodzie chłodzenia 17 [°C]</i>	$\geq 0.0 < 0.8$
<i>Temperatura w obwodzie chłodzenia 7 [°C]</i>	$\geq 0.1 < 0.3, \geq 0.4 < 0.6$
<i>Temperatura wody miejskiej [°C]</i>	$\geq 0.1 < 0.7$
<i>Temperatura wody w instalacji [°C]</i>	$\geq 0.2 < 0.3, \geq 0.5 < 0.6, \geq 0.7 < 0.8,$
<i>Wartość próżni 1 [mBar]</i>	$\geq 0.0 < 0.5$
<i>Wartość próżni 2 [mBar]</i>	$\geq 0.0 < 0.5$
<i>Zużycie smaru [l]</i>	$\geq 0.0 < 0.1, \geq 0.2 < 0.3, \geq 0.4 < 0.5,$


5.2.1.2. Wnioski

Na podstawie przeprowadzonej analizy i optymalizacji wartości danych parametrów zastąpiono zidentyfikowane wartości błędne lub odstające za pomocą teoretycznych wartości minimalnych i maksymalnych danej zmiennej, wyznaczonych bez brania pod uwagę wartości odstających [146] i część zmiennych (tj. *czas cyklu smarowania [s]* i *poziom stopu w piecu podgrzewczym [mm]*) za pomocą średnich wartości danej zmiennej.


Przeprowadzona analiza potwierdziła cechy danych przemysłowych, czyli:

- niedoskonała jakość danych,
- brak równowagi w reprezentacji wartości,
- różnorodność typów rozkładów zmiennych,
- występowanie korelacji pomiędzy różnymi parametrami procesu.


Pierwsza cecha jest związana z zauważonymi wartościami odstającymi oraz brakującymi, zdublowanymi, nieprecyzyjnymi danymi widocznymi na wykresach. Przykładem może być wykres zmiennej *poziom stopu w piecu podgrzewczym [mm]* na którym widoczne są wartości zawierające się w przedziale od 0 do 600 i dodatkowo 6% wartości w przedziale od 6533 do 6548 (rys. 5.2.1.58.). Drugim przykładem może być wykres zmiennej *filtr próżni 1 [mBar]* (rys. 5.2.1.59.), na którym wartości odstające widoczne są doskonale. Cecha nazywana niedoskonałą jakością jest również definiowała ukryte niepoprawności, które wydawały się być uzasadnione i poprawne z punktu widzenia wartości zmiennej jednak okazały się być kodami błędów aparatury kontrolno-pomiarowej. Przykładem jest wykres zmiennej zależnej, której wartości zawierały wartość równą 91, będącą bardzo racjonalną, gdyż z środka zakresu (rys. 5.2.1.60).



Rys.5.2.1.58. Wykres przebiegu zmiennej wejściowej: *poziom stopu w piecu podgrzewczym*, z posortowanymi wartościami zawierający niepoprawne wartości




Rys.5.2.1.59. Wykres przebiegu zmiennej wejściowej: *filtr próżni 1*, z posortowanymi wartościami zawierający niepoprawne wartości




Rys.5.2.1.60. Wykres przebiegu zmiennej zależnej: *przeciek w obwodzie wysokiego ciśnienia*, z posortowanymi wartościami zawierający ukryte niepoprawne wartości

Drugą cechą danych przemysłowych jest różnorodność typów rozkładów zmiennych, takich jak rozkład zbliżony do normalnego (Gausa), rozkład zbliżony do Gamma i inne (rys.5.2.1.61., rys.5.2.1.62.).



Rys.5.2.1.61. Wykres przebiegu zmiennej zależnej: *grubość piętki układu wlewowego*, z posortowanymi wartościami, z rozkładem zbliżonym do rozkładu normalnego



Rys.5.2.1.62. Wykres przebiegu zmiennej zależnej: *przeciek w obwodzie wysokiego ciśnienia*, z posortowanymi wartościami z rozkładem zbliżonym do rozkładu gamma

Druga cecha, czyli brak równowagi w reprezentacji wartości stanowi istotny problem badawczy, gdyż z jednej strony dostępna jest duża ilość danych procesowych, z drugiej natomiast mała ilość danych o stanach krytycznych, czyli mała reprezentacja niektórych krytycznych wartości. Cecha ta jest widoczna na posortowanym wykresie przebiegu zmiennej zależnej (rys.5.2.1.57.). Wykres wskazuje (załamanie na krzywej), że mamy do czynienia z dwoma jakościowo i ilościowo różnymi zakresami wartości zmiennej zależnej, gdzie wartością graniczną jest 7,5. Ważne jest, że mamy aż 10 024 próbek w zakresie do 7,5, co stanowi 99,3% wyników i tylko 70 próbek od 7,5 do 171,86, co stanowi 0,7% wyników. Te rzadkie przypadki mogą zostać zignorowane przez niektóre modele oparte na danych.

Ostatnia cecha może zostać rozszerzona ze względu na rodzaj i pochodzenie wskazywanych korelacji które zostaną dokładnie zbadane w kolejnym rozdziale wyróżniając korelacje:

- naturalne (fizyczne), na przykład między dwiema temperaturami mierzonymi w sąsiednich obszarach odlewu lub między przepływem wody a jej temperaturą w tym samym kanale chłodzącym. Tego rodzaju skorelowane zmienne można łatwo zastąpić jedną zmienną, bardziej widoczną z punktu widzenia jakości produktu.
- celowe, będące wynikiem działań operatorów lub personelu inżynierskiego. Tego rodzaju korelacje powinny zostać uzasadnione lub wyeliminowane.
- przypadkowe, czyli wynikające z jednoczesnego występowania pewnych wartości w niektórych okresach.

5.2.2. Podział danych na zbiory do badań i dyskretyzacja danych


W niniejszym rozdziale zaprezentowane zostaną wyniki podziału zbioru danych na pięć zbiorów danych do badań, wraz z uzasadnieniem zastosowanego podziału oraz metodyka przeprowadzonej dyskretyzacji wartości zmiennych zależnych i niezależnych dla każdego z pięciu zestawów danych do badań. Krok ten jest niezbędny i wymaga wiedzy o procesie celem przygotowania danych do analizy istotności parametrów oraz do zaawansowanego modelowania opartego na zbiorach danych.

5.2.2.1. Metodyka i wyniki badań


W przypadku analizy zbioru danych, w którym liczba rekordów reprezentujących krytyczne wartości wyników procesu jest mała, niektóre korelacje pomiędzy zmiennymi wejściowymi i wyjściowymi mogą być przypadkowe. Zależności te mogą przesłaniać ważne zależności fizyczne w procesie, ze względu na słabość i złożoność tych ostatnich. Wartości niektórych zmiennych wejściowych mogą być celowo wprowadzane przez pracowników jako reakcja na wartości innych zmiennych lub po prostu na podstawie ich indywidualnych doświadczeń, co prowadzi do "lokalnych" korelacji z danymi wyjściowymi pojawiającymi się w danych. Ostatecznie model procesu wejście-wyjście (ang. input-output) może więc łatwo odzwierciedlać nieistniejące zależności.

Tego typu wnioskowanie doprowadziło nas do koncepcji przesłaniania rzeczywistych relacji w procesie przez relacje przypadkowe czy sztucznie wprowadzone do danych, które modele będą wskazywać jako równie ważne. Identyfikacja takich "pasożytniczych" zmiennych jest trudna. Można zastosować w tym przypadku podział głównego zbioru danych na zbiory testowe zawierające różne zakresy wartości zmiennej zależnej. Dlatego w niniejszym rozdziale zaprezentowana zostanie metodyka podziału badanego rzeczywistego zbioru danych na pięć zbiorów danych do badań, z których każdy zawierał inną liczbę obserwacji i z inną proporcją rekordów o mniejszych wartościach zmiennej zależnej.

Pierwszy zbiór danych do badań zawierał wszystkie dane ze zbioru danych rzeczywistych (rys.5.2.1.57.). Drugi zbiór danych do badań natomiast zawierał tylko obserwacje, dla których zmienna zależna przyjmowała wartości $\geq 7,5$ (rys.5.2.2.1). W niniejszym zbiorze można zaobserwować wysoką zmienność wartości zmiennej zależnej (rys.5.2.2.2). Z uwagi na tę wysoką zmienność, modelowanie oparte na tym zbiorze danych do badań, może dać wartościowe wyniki dla niniejszej rozprawy.




Rys.5.2.2.1. Wykres przebiegu zmiennej zależnej, z posortowanymi wartościami, w drugim zbiorze danych do badań




Rys.5.2.2.2. Histogram zmiennej zależnej, w drugim zbiorze danych do badań

Trzeci zbiór danych do badań zawierał tylko obserwacje, dla których zmienna zależna przyjmowała wartości $< 7,5$ (rys.5.2.2.3.). W niniejszym zbiorze również można zaobserwować wysoką zmienność wartości zmiennej zależnej (rys.5.2.2.4.). Rozkład zmiennej zależnej jest zbliżony do normalnego, ale zaznacza się zwiększone występowanie wartości podwyższonych. Modelowanie oparte na tym zbiorze danych do badań może dać interesujące wyniki dotyczące trendów występujących w danych powszechnie.




Rys.5.2.2.3. Wykres przebiegu zmiennej zależnej, z posortowanymi wartościami, w trzecim zbiorze danych do badań




Rys.5.2.2.4. Histogram zmiennej zależnej w trzecim zbiorze danych do badań

Czwarty zbiór danych do badań zawierał w sobie wartości zbioru drugiego, czyli obserwacje, dla których zmienna zależna przyjmowała wartości $< 7,5$ oraz taką samą ilość obserwacji pochodzących z górnego zakresu zbioru trzeciego (rys.5.2.2.5.). Modelowanie oparte na tym zbiorze danych, pozwoli na najbardziej wartościowe wnioski, w temacie wpływu określonych parametrów na zwiększenie wartości zmiennej zależnej w niepożądanym stopniu, a więc na powstanie wady w produkcji.



Rys.5.2.2.5. Wykres przebiegu zmiennej zależnej, z posortowanymi wartościami, w czwartym zbiorze danych do badań

Piąty zbiór danych do badań zawierał w sobie wartości zbioru drugiego, czyli obserwacje, dla których zmienna zależna przyjmowała wartości $< 7,5$ oraz taką samą ilość obserwacji pochodzących ze zbioru trzeciego, wybranych losowo, co 144 rekordy (rys.5.2.2.6.).



Rys.5.2.2.6. Wykres przebiegu zmiennej zależnej, z posortowanymi wartościami, w piątym zbiorze danych do badań

Zbiory pierwszy i trzeci nazywane są dalej zbiorami dużymi, zaś drugi, czwarty i piąty – zbiorami małymi.

Dane wejściowe i wyjściowe zostały następnie zdyskretyzowane (celem przygotowania ich do dalszych analiz), dla każdego z pięciu zestawów danych, w celu wykrycia wpływu parametrów procesu na wartość *przecieku*. Zakresy przedziałów określono poprzez wizualną ocenę, uporządkowanych według wartości przyjmowanych przez dany parametr (wartości typowe, podwyższone i obniżone). Celem przeprowadzenia tej analizy stworzono plik w

programie Microsoft Excel przedstawiony na rys.5.2.2.7..

PODZIAŁ na zadane przedziały											
Nr przedziału	Górne wartości przedziałów	Liczności w przedziałach									
1	5	2685									
2	6	7409									
3											
4											
5											
6											
7											
8											
9											
10											
2											
Liczba przedziałów ręcznych:		2									
Liczba rekordów:		10094									


Wartości ciągłe:		Wartości dyskretne		Nr przedziału									
Ciśnienie sprężonego powietrza [Bar]	Ciśnienie sprężonego powietrza [Bar]			1	2	3	4	5	6	7	8	9	10
5	1	1	0	0	0	0	0	0	0	0	0	0	0
6	2	0	1	0	0	0	0	0	0	0	0	0	0
5	1	1	0	0	0	0	0	0	0	0	0	0	0
6	2	0	1	0	0	0	0	0	0	0	0	0	0
6	2	0	1	0	0	0	0	0	0	0	0	0	0
6	2	0	1	0	0	0	0	0	0	0	0	0	0
6	2	0	1	0	0	0	0	0	0	0	0	0	0
5	1	1	0	0	0	0	0	0	0	0	0	0	0
6	2	0	1	0	0	0	0	0	0	0	0	0	0
6	2	0	1	0	0	0	0	0	0	0	0	0	0
6	2	0	1	0	0	0	0	0	0	0	0	0	0

Rys.5.2.2.7. Tabele umożliwiające dyskretyzację wartości zmiennych zależnych i niezależnych


W celu otrzymania zdyskretyzowanych wartości zmiennej należy:

- w punkcie 1, wprowadzić wartości ciągłe określonej zmiennej,
- w punkcie 2, wprowadzić liczbę obserwacji,
- w punkcie 3 otrzymać najmniejszą i największą wartość ze zbioru liczb typu ciągłego wprowadzonych w punkcie 1, obliczaną w oparciu o funkcję =MAX () i funkcję =MIN (),
- w punkcie 4, zadać górne wartości przedziałów,
- w punkcie 5, otrzymać wynik, czy dana wartość typu ciągłego znajduje się w danym przedziale, obliczony w oparciu o funkcję =JEŻELI (),
- w punkcie 6, otrzymać licznosci wartości zawartych w zadanych przedziałach, w oparciu o funkcję =LICZ.JEŻELI(),
- w punkcie 7, otrzymać wynikowe zdyskretyzowane wartości zmiennej.

Na podstawie otrzymanych danych tworzone są poniższe wykresy (rys.5.2.2.8., rys.5.2.2.9.) umożliwiające weryfikację zadanych przedziałów poprzez wizualną ocenę, uporządkowanych według wartości przyjmowanych przez dany parametr (wartości typowe, podwyższone i obniżone).



Rys.5.2.2.8. Histogram automatyczny dla wartości oryginalnych (typu ciągłego) dla zmiennej niezależnej: *ciśnienie sprężonego powietrza*



Rys.5.2.2.9. Wykres ilości obserwacji w poszczególnych przedziałach dla zmiennej niezależnej: *ciśnienie sprężonego powietrza*

Opisaną procedurę dyskretyzacji danych powtórzono 290 razy, gdyż obliczenia wykonano dla 56 zmiennych niezależnych dla każdego utworzonych pięciu zestawów danych dodatkowo dla zmiennej niezależnej według 2 i 4 przedziałów, również dla każdego z utworzonych pięciu zbiorów danych. Wyniki zapisano w tab.5.60.-tab.5.64..

Tab. 5.60.: Ustalane przedziały i wystąpienia danych wartości w przedziałach dla pierwszego zbioru danych do badań

	Wartość zdyskretyzowana	1	2	3	4	5
<i>Ciśnienie sprężonego powietrza [Bar]</i>	Górne granice przedziałów	5	6			
	Liczby wystąpień	2685	7409			
<i>Ciśnienie wody miejskiej [Bar]</i>	Górne granice przedziałów	3	4	5		
	Liczby wystąpień	1850	6404	1840		
<i>Ciśnienie wody obiegowej [Bar]</i>	Górne granice przedziałów	2	3			
	Liczby wystąpień	5241	4853			
<i>Czas pierwszej fazy wtrysku [ms]</i>	Górne granice przedziałów	2241	2266	2289	2333	
	Liczby wystąpień	2594	2584	2495	2421	
<i>Czas chłodzenia obwodu 1 [s]</i>	Górne granice przedziałów	30	31	32		
	Liczby wystąpień	45	9984	65		
<i>Czas cyklu [s]</i>	Górne granice przedziałów	85	100	172,61		
	Liczby wystąpień	7	9460	627		
<i>Czas cyklu smarowania [s]</i>	Górne granice przedziałów	23	27,5	31,5		
	Liczby wystąpień	9705	336	53		
<i>Czas dozowania stopu [s]</i>	Górne granice przedziałów	11,1	32	33		
	Liczby wystąpień	9420	504	170		
<i>Czas dozowania stopu 2 [s]</i>	Górne granice przedziałów	65	75	106,6		
	Liczby wystąpień	163	9534	397		
<i>Czas krzepnięcia t2 [s]</i>	Górne granice przedziałów	10	11			
	Liczby wystąpień	7527	2567			
<i>Czas przedmuchu [s]</i>	Górne granice przedziałów	6,7	7,5	11,7		
	Liczby wystąpień	163	9315	616		
<i>Czas smarowania [s]</i>	Górne granice przedziałów	6	9,30			
	Liczby wystąpień	9839	255			
<i>Dzienny numer wtrysku [j.]</i>	Górne granice przedziałów	100	210	349	663	
	Liczby wystąpień	2549	2501	2527	2517	
<i>Filtr próżni 1 [mBar]</i>	Górne granice przedziałów	1350	1400	1460	1613	
	Liczby wystąpień	2561	2508	2503	2522	
<i>Grubość piętki układu wlewowego [mm]</i>	Górne granice przedziałów	35,5	41,5	45		
	Liczby wystąpień	1446	7970	678		
<i>Koncentrat [%]</i>	Górne granice przedziałów	2,1	2,6	2,7		
	Liczby wystąpień	633	4846	4615		
<i>Ciśnienie maksymalne [Bar]</i>	Górne granice przedziałów	340	344	346		

	Liczby wystąpień	1601	7982	511		
<i>Prędkość wtrysku maksymalna [m/s]</i>	Górne granice przedziałów	5,9	6			
	Liczby wystąpień	5233	4861			
<i>Opóźnienie multiplikacji [ms]</i>	Górne granice przedziałów	170	175	176		
	Liczby wystąpień	1477	8467	150		
<i>Stała temperatura chłodzenia płyty [°C]</i>	Górne granice przedziałów	28	32			
	Liczby wystąpień	6483	3611			
<i>Poziom stopu w piecu podgrzewczym [mm]</i>	Górne granice przedziałów	1000	6548,6			
	Liczby wystąpień	9467	627			
<i>Poziom wody w strumieniu chłodzącym [mm]</i>	Górne granice przedziałów	246	269	298		
	Liczby wystąpień	3367	3451	3276		
<i>Czas drugiej fazy wtrysku [ms]</i>	Górne granice przedziałów	88	89	90		
	Liczby wystąpień	3383	4928	1783		
<i>Profil próżni 1 [mBar]</i>	Górne granice przedziałów	1170	1300	1384		
	Liczby wystąpień	8328	1724	42		
<i>Profil próżni 2 [mBar]</i>	Górne granice przedziałów	1050	1170	1321		
	Liczby wystąpień	1554	2013	6527		
<i>Przepływ chłodzenia tłoka [l]</i>	Górne granice przedziałów	15	20	26		
	Liczby wystąpień	336	6876	2882		
<i>Przepływ w obwodzie chłodzenia 1 [l]</i>	Górne granice przedziałów	24	26	28		
	Liczby wystąpień	1019	6253	2822		
<i>Przepływ w obwodzie chłodzenia 13 [l]</i>	Górne granice przedziałów	15	17	19	20	
	Liczby wystąpień	384	5595	2377	1738	
<i>Przepływ w obwodzie chłodzenia 14 [l]</i>	Górne granice przedziałów	26	27	28	29	
	Liczby wystąpień	897	2472	5610	1115	
<i>Przepływ w obwodzie chłodzenia 15 [l]</i>	Górne granice przedziałów	25	26	27	28	
	Liczby wystąpień	2210	4870	2486	528	
<i>Przepływ w obwodzie chłodzenia 17 [l]</i>	Górne granice przedziałów	23	26	32	33	36
	Liczby wystąpień	2155	2049	2417	1758	1715
<i>Przepływ w obwodzie chłodzenia 20 [l]</i>	Górne granice przedziałów	22	23	25		
	Liczby wystąpień	1733	5292	3069		
<i>Przepływ w obwodzie chłodzenia 6 [l]</i>	Górne granice przedziałów	28	29	30	33	
	Liczby wystąpień	3022	2356	3255	1461	
<i>Prędkość we wlewach doprowadzających [m/s]</i>	Górne granice przedziałów	38,10	38,80	39,43		
	Liczby wystąpień	386	7098	2610		
<i>Suw pierwszej fazy wtrysku [mm]</i>	Górne granice przedziałów	536	537	538	539	540
	Liczby wystąpień	232	2671	4440	2415	336

Suw docisku po multiplikacji [mm]	Górne granice przedziałów	17	18	19	20	
	Liczby wystąpień	194	2172	6175	1553	
Temperatura chłodzenia tłoka [°C]	Górne granice przedziałów	32	33	35		
	Liczby wystąpień	4919	4044	1131		
Temperatura stopu [°C]	Górne granice przedziałów	674	684	689,2		
	Liczby wystąpień	402	8687	1005		
Temperatura termoregulatora 2.1 [°C]	Górne granice przedziałów	68	72	75		
	Liczby wystąpień	2810	5806	1478		
Temperatura termoregulatora 2.2 [°C]	Górne granice przedziałów	71	73	74		
	Liczby wystąpień	3284	5836	974		
Temperatura termoregulatora 3.2 [°C]	Górne granice przedziałów	148	152	156		
	Liczby wystąpień	2890	4466	2738		
Temperatura tulei 1 [°C]	Górne granice przedziałów	205	223	242		
	Liczby wystąpień	722	8763	609		
Temperatura tulei 2 [°C]	Górne granice przedziałów	215	224	235		
	Liczby wystąpień	1158	7678	1258		
Temperatura tulei 3 [°C]	Górne granice przedziałów	212	230	256		
	Liczby wystąpień	719	8716	659		
Temperatura tulei 4 [°C]	Górne granice przedziałów	220	239	258		
	Liczby wystąpień	716	8656	722		
Temperatura w obwodzie chłodzenia 1 [°C]	Górne granice przedziałów	29	33	39		
	Liczby wystąpień	90	9625	379		
Temperatura w obwodzie chłodzenia 13 [°C]	Górne granice przedziałów	32	37	40		
	Liczby wystąpień	103	9770	221		
Temperatura w obwodzie chłodzenia 14 [°C]	Górne granice przedziałów	31	32	33	34	
	Liczby wystąpień	554	4481	4184	875	
Temperatura w obwodzie chłodzenia 15 [°C]	Górne granice przedziałów	32	33	34	35	36
	Liczby wystąpień	1187	3707	4208	792	200
Temperatura w obwodzie chłodzenia 17 [°C]	Górne granice przedziałów	28	33	35		
	Liczby wystąpień	3827	5695	572		
Temperatura w obwodzie chłodzenia 7 [°C]	Górne granice przedziałów	27	28	29	30	
	Liczby wystąpień	970	5885	2842	397	
Temperatura wody miejskiej [°C]	Górne granice przedziałów	18	25	27		
	Liczby wystąpień	209	9731	154		
Temperatura wody w instalacji [°C]	Górne granice przedziałów	23	24	25		
	Liczby wystąpień	390	4599	5105		
Wartość próżni 1 [mBar]	Górne granice przedziałów	235	435	599		

	Liczby wystąpień	1528	7287	1279		
<i>Wartość próżni 2 [mBar]</i>	Górne granice przedziałów	400	500	659		
	Liczby wystąpień	3532	6263	299		
<i>Zużycie smaru [l]</i>	Górne granice przedziałów	0	1	2		
	Liczby wystąpień	8315	1543	236		
<i>Przeciek w obwodzie wysokiego ciśnienia [cm3] Leakage 2CAT</i>	Górne granice przedziałów	7,4999	171,86			
	Liczby wystąpień	10024	70			
<i>Przeciek w obwodzie wysokiego ciśnienia [cm3] Leakage 4CAT</i>	Górne granice przedziałów	3	7,4999	15	171,86	
	Liczby wystąpień	8965	1059	39	31	

Tab. 5.61.: Ustalane przedziały i wystąpienia danych wartości w przedziałach dla drugiego zbioru danych do badań

	Wartość zdyskretyzowana	1	2	3	4
<i>Ciśnienie sprężonego powietrza [Bar]</i>	Górne granice przedziałów	5	6		
	Liczby wystąpień	21	49		
<i>Ciśnienie wody miejskiej [Bar]</i>	Górne granice przedziałów	3	4	5	
	Liczby wystąpień	16	43	11	
<i>Ciśnienie wody obiegowej [Bar]</i>	Górne granice przedziałów	2	3		
	Liczby wystąpień	40	30		
<i>Czas pierwszej fazy wtrysku [ms]</i>	Górne granice przedziałów	2240	2280	2340	
	Liczby wystąpień	13	41	16	
<i>Czas chłodzenia obwodu 1 [s]</i>	Górne granice przedziałów	31			
	Liczby wystąpień	70			
<i>Czas cyklu [s]</i>	Górne granice przedziałów	100	165,5		
	Liczby wystąpień	61	9		
<i>Czas cyklu smarowania [s]</i>	Górne granice przedziałów	23	31,5		
	Liczby wystąpień	58	12		
<i>Czas dozowania stopu [s]</i>	Górne granice przedziałów	11,1	33		
	Liczby wystąpień	67	3		
<i>Czas dozowania stopu 2 [s]</i>	Górne granice przedziałów	61	80	106,6	
	Liczby wystąpień	3	62	5	
<i>Czas krzepnięcia t2 [s]</i>	Górne granice przedziałów	10	11		
	Liczby wystąpień	32	38		
<i>Czas przedmuchu [s]</i>	Górne granice przedziałów	8	11,7		
	Liczby wystąpień	57	13		

Czas smarowania [s]	Górne granice przedziałów	6	9,30		
	Liczby wystąpień	60	10		
Dzienny numer wtrysku [j.]	Górne granice przedziałów	100	300	652	
	Liczby wystąpień	28	20	22	
Filtr próżni 1 [mBar]	Górne granice przedziałów	1300	1500	1592	
	Liczby wystąpień	3	58	9	
Grubość piętki układu wlewowego [mm]	Górne granice przedziałów	35,5	42		
	Liczby wystąpień	7	63		
Koncentrat [%]	Górne granice przedziałów	2,3	2,7		
	Liczby wystąpień	12	58		
Ciśnienie maksymalne [Bar]	Górne granice przedziałów	340	343	345	
	Liczby wystąpień	19	44	7	
Prędkość wtrysku maksymalna [m/s]	Górne granice przedziałów	5,85	5,9	6	
	Liczby wystąpień	9	40	21	
Opóźnienie multiplikacji [ms]	Górne granice przedziałów	171	174	176	
	Liczby wystąpień	13	44	13	
Stała temperatura chłodzenia płyty [°C]	Górne granice przedziałów	28	32		
	Liczby wystąpień	26	44		
Poziom stopu w piecu podgrzewczym [mm]	Górne granice przedziałów	500	600		
	Liczby wystąpień	11	59		
Poziom wody w strumieniu chłodzącym [mm]	Górne granice przedziałów	260	298		
	Liczby wystąpień	31	39		
Czas drugiej fazy wtrysku [ms]	Górne granice przedziałów	88	89	90,0	
	Liczby wystąpień	26	32	12	
Profil próżni 1 [mBar]	Górne granice przedziałów	1100	1298		
	Liczby wystąpień	25	45		
Profil próżni 2 [mBar]	Górne granice przedziałów	1200	1317		
	Liczby wystąpień	10	60		
Przepływ chłodzenia tłoka [l]	Górne granice przedziałów	24	26		
	Liczby wystąpień	33	37		
Przepływ w obwodzie chłodzenia 1 [l]	Górne granice przedziałów	25	28		
	Liczby wystąpień	45	25		
Przepływ w obwodzie chłodzenia 13 [l]	Górne granice przedziałów	18	19	20	
	Liczby wystąpień	19	36	15	
Przepływ w obwodzie chłodzenia 14 [l]	Górne granice przedziałów	26	27	29	
	Liczby wystąpień	18	29	23	
Przepływ w obwodzie chłodzenia 15 [l]	Górne granice przedziałów	25	26	27	28
	Liczby wystąpień	17	21	11	21

<i>Przepływ w obwodzie chłodzenia 17 [l]</i>	Górne granice przedziałów	20	30	35	
	Liczby wystąpień	18	25	27	
<i>Przepływ w obwodzie chłodzenia 20 [l]</i>	Górne granice przedziałów	22	23	25	
	Liczby wystąpień	31	27	12	
<i>Przepływ w obwodzie chłodzenia 6 [l]</i>	Górne granice przedziałów	29	33		
	Liczby wystąpień	38	32		
<i>Prędkość we wlewach doprowadzających [m/s]</i>	Górne granice przedziałów	38,4	38,8	39,27	
	Liczby wystąpień	13	37	20	
<i>Suw pierwszej fazy wtrysku [mm]</i>	Górne granice przedziałów	537	538	540	
	Liczby wystąpień	22	29	19	
<i>Suw docisku po multiplikacji [mm]</i>	Górne granice przedziałów	17	18	19	20
	Liczby wystąpień	5	21	36	8
<i>Temperatura chłodzenia tłoka [°C]</i>	Górne granice przedziałów	30	33	35	
	Liczby wystąpień	9	57	4	
<i>Temperatura stopu [°C]</i>	Górne granice przedziałów	678	688,5		
	Liczby wystąpień	30	40		
<i>Temperatura termoregulatora 2.1 [°C]</i>	Górne granice przedziałów	67	72	75	
	Liczby wystąpień	17	41	12	
<i>Temperatura termoregulatora 2.2 [°C]</i>	Górne granice przedziałów	72	74		
	Liczby wystąpień	30	40		
<i>Temperatura termoregulatora 3.2 [°C]</i>	Górne granice przedziałów	150	156		
	Liczby wystąpień	44	26		
<i>Temperatura tulei 1 [°C]</i>	Górne granice przedziałów	208	218	229	
	Liczby wystąpień	14	37	19	
<i>Temperatura tulei 2 [°C]</i>	Górne granice przedziałów	218	226	232	
	Liczby wystąpień	15	42	13	
<i>Temperatura tulei 3 [°C]</i>	Górne granice przedziałów	218	228	236	
	Liczby wystąpień	18	36	16	
<i>Temperatura tulei 4 [°C]</i>	Górne granice przedziałów	228	236	245	
	Liczby wystąpień	20	34	16	
<i>Temperatura w obwodzie chłodzenia 1 [°C]</i>	Górne granice przedziałów	30	33	39	
	Liczby wystąpień	4	58	8	
<i>Temperatura w obwodzie chłodzenia 13 [°C]</i>	Górne granice przedziałów	34	35	38	
	Liczby wystąpień	26	31	13	
<i>Temperatura w obwodzie chłodzenia 14 [°C]</i>	Górne granice przedziałów	31	32	33	34
	Liczby wystąpień	8	16	32	14
<i>Temperatura w obwodzie chłodzenia 15 [°C]</i>	Górne granice przedziałów	32	34	36	
	Liczby wystąpień	11	52	7	

Temperatura w obwodzie chłodzenia 17 [°C]	Górne granice przedziałów	28	33	35	
	Liczby wystąpień	28	32	10	
Temperatura w obwodzie chłodzenia 7 [°C]	Górne granice przedziałów	27	28	29	30
	Liczby wystąpień	7	29	29	5
Temperatura wody miejskiej [°C]	Górne granice przedziałów	20	22	26	
	Liczby wystąpień	20	33	17	
Temperatura wody w instalacji [°C]	Górne granice przedziałów	24	25		
	Liczby wystąpień	32	38		
Wartość próżni 1 [mBar]	Górne granice przedziałów	300	400	490	
	Liczby wystąpień	10	49	11	
Wartość próżni 2 [mBar]	Górne granice przedziałów	450	480	526	
	Liczby wystąpień	14	45	11	
Zużycie smaru [l]	Górne granice przedziałów	0	2		
	Liczby wystąpień	60	10		
Przeciek w obwodzie wysokiego ciśnienia [cm3] Leakage 2CAT	Górne granice przedziałów	25	171,86		
	Liczby wystąpień	52	18		
Przeciek w obwodzie wysokiego ciśnienia [cm3] Leakage 4CAT	Górne granice przedziałów	10	25	100	171,86
	Liczby wystąpień	25	27	9	9

Tab. 5.62.: Ustalane przedziały i wystąpienia danych wartości w przedziałach dla trzeciego zbioru danych do badań

	Wartość zdyskretyzowana	1	2	3	4	5
Ciśnienie sprężonego powietrza [Bar]	Górne granice przedziałów	5	6			
	Liczby wystąpień	2664	7360			
Ciśnienie wody miejskiej [Bar]	Górne granice przedziałów	3	4	5		
	Liczby wystąpień	1834	6361	1829		
Ciśnienie wody obiegowej [Bar]	Górne granice przedziałów	2	3			
	Liczby wystąpień	5201	4823			
Czas pierwszej fazy wtrysku [ms]	Górne granice przedziałów	2241	2266	2289	2333	
	Liczby wystąpień	2581	2553	2480	2410	
Czas chłodzenia obwodu 1 [s]	Górne granice przedziałów	30	31	32		
	Liczby wystąpień	44	9915	65		
Czas cyklu [s]	Górne granice przedziałów	85	100	172,61		
	Liczby wystąpień	7	9399	618		
Czas cyklu smarowania [s]	Górne granice przedziałów	23	31,5			
	Liczby wystąpień	9647	377			
Czas dozowania stopu [s]	Górne granice przedziałów	11,1	32	33		

	Liczby wystąpień	9353	503	168		
Czas dozowania stopu 2 [s]	Górne granice przedziałów	65	75	106,6		
	Liczby wystąpień	160	9472	392		
Czas krzepnięcia t2 [s]	Górne granice przedziałów	10	11			
	Liczby wystąpień	7457	2567			
Czas przedmuchu [s]	Górne granice przedziałów	6,7	7,5	11,7		
	Liczby wystąpień	163	9258	603		
Czas smarowania [s]	Górne granice przedziałów	6	9,30			
	Liczby wystąpień	9779	245			
Dzienny numer wtrysku [j.]	Górne granice przedziałów	100	210	349	663	
	Liczby wystąpień	2521	2487	2512	2504	
Filtr próżni 1 [mBar]	Górne granice przedziałów	1350	1400	1460	1613	
	Liczby wystąpień	2553	2491	2472	2508	
Grubość piętki układu wlewowego [mm]	Górne granice przedziałów	35,5	41,5	45		
	Liczby wystąpień	1439	7908	677		
Koncentrat [%]	Górne granice przedziałów	2,1	2,6	2,7		
	Liczby wystąpień	632	4812	4580		
Ciśnienie maksymalne [Bar]	Górne granice przedziałów	340	344	346		
	Liczby wystąpień	1582	7933	509		
Prędkość wtrysku maksymalna [m/s]	Górne granice przedziałów	5,9	6			
	Liczby wystąpień	5184	4840			
Opóźnienie multiplikacji [ms]	Górne granice przedziałów	170	175	176		
	Liczby wystąpień	1473	8404	147		
Stała temperatura chłodzenia płyty [°C]	Górne granice przedziałów	28	32			
	Liczby wystąpień	6457	3567			
Poziom stopu w piecu podgrzewczym [mm]	Górne granice przedziałów	1000	6548,6			
	Liczby wystąpień	9397	627			
Poziom wody w strumieniu chłodzącym [mm]	Górne granice przedziałów	246	269	298		
	Liczby wystąpień	3355	3420	3249		
Czas drugiej fazy wtrysku [ms]	Górne granice przedziałów	88	89	90,0		
	Liczby wystąpień	3357	4896	1771		
Profil próżni 1 [mBar]	Górne granice przedziałów	1170	1300	1384		
	Liczby wystąpień	8265	1717	42		
Profil próżni 2 [mBar]	Górne granice przedziałów	1050	1170	1321		
	Liczby wystąpień	1551	2007	6466		
Przepływ chłodzenia tłoka [l]	Górne granice przedziałów	15	20	26		
	Liczby wystąpień	335	6855	2834		
Przepływ w obwodzie chłodzenia 1 [l]	Górne granice przedziałów	24	26	28		

	Liczby wystąpień	992	6222	2810		
Przepływ w obwodzie chłodzenia 13 [l]	Górne granice przedziałów	15	17	19	20	
	Liczby wystąpień	383	5581	2337	1723	
Przepływ w obwodzie chłodzenia 14 [l]	Górne granice przedziałów	26	27	28	29	
	Liczby wystąpień	879	2443	5590	1112	
Przepływ w obwodzie chłodzenia 15 [l]	Górne granice przedziałów	25	26	27	28	
	Liczby wystąpień	2193	4849	2475	507	
Przepływ w obwodzie chłodzenia 17 [l]	Górne granice przedziałów	23	26	32	33	36
	Liczby wystąpień	2130	2033	2399	1753	1709
Przepływ w obwodzie chłodzenia 20 [l]	Górne granice przedziałów	22	23	25		
	Liczby wystąpień	1702	5265	3057		
Przepływ w obwodzie chłodzenia 6 [l]	Górne granice przedziałów	28	29	30	33	
	Liczby wystąpień	3012	2328	3227	1457	
Prędkość we wlewach doprowadzających [m/s]	Górne granice przedziałów	38,10	38,80	39,43		
	Liczby wystąpień	381,00	7053,00	2590,00		
Suw pierwszej fazy wtrysku [mm]	Górne granice przedziałów	536	537	538	539	540
	Liczby wystąpień	232	2649	4411	2399	333
Suw docisku po multiplikacji [mm]	Górne granice przedziałów	17	18	19	20	
	Liczby wystąpień	189	2151	6139	1545	
Temperatura chłodzenia tłoka [°C]	Górne granice przedziałów	32	33	35		
	Liczby wystąpień	4881	4016	1127		
Temperatura stopu [°C]	Górne granice przedziałów	674	684	689,2		
	Liczby wystąpień	401	8624	999		
Temperatura termoregulatora 2.1 [°C]	Górne granice przedziałów	68	72	75		
	Liczby wystąpień	2784	5774	1466		
Temperatura termoregulatora 2.2 [°C]	Górne granice przedziałów	71	73	74		
	Liczby wystąpień	3267	5787	970		
Temperatura termoregulatora 3.2 [°C]	Górne granice przedziałów	148	152	156		
	Liczby wystąpień	2863	4440	2721		
Temperatura tulei 1 [°C]	Górne granice przedziałów	205	223	242		
	Liczby wystąpień	718	8704	602		
Temperatura tulei 2 [°C]	Górne granice przedziałów	215	224	235		
	Liczby wystąpień	1153	7637	1234		
Temperatura tulei 3 [°C]	Górne granice przedziałów	212	230	256		
	Liczby wystąpień	716	8659	649		
Temperatura tulei 4 [°C]	Górne granice przedziałów	220	239	258		
	Liczby wystąpień	714	8596	714		
Temperatura w obwodzie chłodzenia 1 [°C]	Górne granice przedziałów	29	33	39		

	Liczby wystąpień	90	9563	371		
Temperatura w obwodzie chłodzenia 13 [°C]	Górne granice przedziałów	32	37	40		
	Liczby wystąpień	97	9707	220		
Temperatura w obwodzie chłodzenia 14 [°C]	Górne granice przedziałów	31	32	33	34	
	Liczby wystąpień	546	4465	4152	861	
Temperatura w obwodzie chłodzenia 15 [°C]	Górne granice przedziałów	32	33	34	35	36
	Liczby wystąpień	1176	3680	4183	789	196
Temperatura w obwodzie chłodzenia 17 [°C]	Górne granice przedziałów	28	33	35		
	Liczby wystąpień	3799	5663	562		
Temperatura w obwodzie chłodzenia 7 [°C]	Górne granice przedziałów	27	28	29	30	
	Liczby wystąpień	963	5856	2813	392	
Temperatura wody miejskiej [°C]	Górne granice przedziałów	18	25	27		
	Liczby wystąpień	209	9662	153		
Temperatura wody w instalacji [°C]	Górne granice przedziałów	23	24	25		
	Liczby wystąpień	388	4569	5067		
Wartość próżni 1 [mBar]	Górne granice przedziałów	235	435	599		
	Liczby wystąpień	1523	7228	1273		
Wartość próżni 2 [mBar]	Górne granice przedziałów	400	500	659		
	Liczby wystąpień	3523	6204	297		
Zużycie smaru [l]	Górne granice przedziałów	0	1	2		
	Liczby wystąpień	8255	1534	235		
Przeciek w obwodzie wysokiego ciśnienia [cm3] Leakage 2CAT	Górne granice przedziałów	2	7,49			
	Liczby wystąpień	7985	2039			
Przeciek w obwodzie wysokiego ciśnienia [cm3] Leakage 4CAT	Górne granice przedziałów	1	2	3	7,49	
	Liczby wystąpień	1730	6255	980	1059	

Tab. 5.63.: Ustalane przedziały i wystąpienia danych wartości w przedziałach dla czwartego zbioru danych do badań

	Wartość zdyskretyzowana	1	2	3	4
Ciśnienie sprężonego powietrza [Bar]	Górne granice przedziałów	5	6		
	Liczby wystąpień	46	94		
Ciśnienie wody miejskiej [Bar]	Górne granice przedziałów	3	4	5	
	Liczby wystąpień	28	92	20	
Ciśnienie wody obiegowej [Bar]	Górne granice przedziałów	2	3		
	Liczby wystąpień	74	66		
Czas pierwszej fazy wtrysku [ms]	Górne granice przedziałów	2240	2280	2330	
	Liczby wystąpień	36	63	41	
Czas chłodzenia obwodu 1 [s]	Górne granice przedziałów	31			

	Liczby wystąpień	140			
Czas cyklu [s]	Górne granice przedziałów	100	165,5		
	Liczby wystąpień	126	14		
Czas cyklu smarowania [s]	Górne granice przedziałów	23	31,5		
	Liczby wystąpień	125	15		
Czas dozowania stopu [s]	Górne granice przedziałów	11,1	33		
	Liczby wystąpień	136	4		
Czas dozowania stopu 2 [s]	Górne granice przedziałów	61	80	106,6	
	Liczby wystąpień	5	125	10	
Czas krzepnięcia t2 [s]	Górne granice przedziałów	10	11		
	Liczby wystąpień	94	46		
Czas przedmuchu [s]	Górne granice przedziałów	8,0	11,7		
	Liczby wystąpień	123	17		
Czas smarowania [s]	Górne granice przedziałów	6	9,30		
	Liczby wystąpień	129	11		
Dzienny numer wtrysku [j.]	Górne granice przedziałów	100	300	652	
	Liczby wystąpień	49	48	43	
Filtr próżni 1 [mBar]	Górne granice przedziałów	1300	1500	1613	
	Liczby wystąpień	8	115	17	
Grubość piętki układu wlewowego [mm]	Górne granice przedziałów	35,5	45		
	Liczby wystąpień	15	125		
Koncentrat [%]	Górne granice przedziałów	2,3	2,7		
	Liczby wystąpień	29	111		
Ciśnienie maksymalne [Bar]	Górne granice przedziałów	340	343	345	
	Liczby wystąpień	26	101	13	
Prędkość wtrysku maksymalna [m/s]	Górne granice przedziałów	5,85	5,9	6	
	Liczby wystąpień	13	75	52	
Opóźnienie multiplikacji [ms]	Górne granice przedziałów	171	174	176	
	Liczby wystąpień	37	80	23	
Stała temperatura chłodzenia płyty [°C]	Górne granice przedziałów	28	32		
	Liczby wystąpień	78	62		
Poziom stopu w piecu podgrzewczym [mm]	Górne granice przedziałów	500	6533,6		
	Liczby wystąpień	40	100		
Poziom wody w strumieniu chłodzącym [mm]	Górne granice przedziałów	260	298		
	Liczby wystąpień	61	79		
Czas drugiej fazy wtrysku [ms]	Górne granice przedziałów	88	89	90,0	
	Liczby wystąpień	51	62	27	
Profil próżni 1 [mBar]	Górne granice przedziałów	1100	1298		

	Liczby wystąpień	36	104		
<i>Profil próżni 2 [mBar]</i>	Górne granice przedziałów	1200	1321		
	Liczby wystąpień	39	101		
<i>Przepływ chłodzenia tłoka [l]</i>	Górne granice przedziałów	20,6	26		
	Liczby wystąpień	73	67		
<i>Przepływ w obwodzie chłodzenia 1 [l]</i>	Górne granice przedziałów	25	27	28	
	Liczby wystąpień	56	77	7	
<i>Przepływ w obwodzie chłodzenia 13 [l]</i>	Górne granice przedziałów	18	19	20	
	Liczby wystąpień	65	52	23	
<i>Przepływ w obwodzie chłodzenia 14 [l]</i>	Górne granice przedziałów	26	27	29	
	Liczby wystąpień	23	45	72	
<i>Przepływ w obwodzie chłodzenia 15 [l]</i>	Górne granice przedziałów	25	26	27	28
	Liczby wystąpień	33	53	33	21
<i>Przepływ w obwodzie chłodzenia 17 [l]</i>	Górne granice przedziałów	20	30	36	
	Liczby wystąpień	20	39	81	
<i>Przepływ w obwodzie chłodzenia 20 [l]</i>	Górne granice przedziałów	22	23	25	
	Liczby wystąpień	40	63	37	
<i>Przepływ w obwodzie chłodzenia 6 [l]</i>	Górne granice przedziałów	29	33		
	Liczby wystąpień	72	68		
<i>Prędkość we wlewach doprowadzających [m/s]</i>	Górne granice przedziałów	38,4	38,8	39,27	
	Liczby wystąpień	30	69	41	
<i>Suw pierwszej fazy wtrysku [mm]</i>	Górne granice przedziałów	537	538	540	
	Liczby wystąpień	38	62	40	
<i>Suw docisku po multiplikacji [mm]</i>	Górne granice przedziałów	17	18	19	20
	Liczby wystąpień	8	45	70	17
<i>Temperatura chłodzenia tłoka [°C]</i>	Górne granice przedziałów	30	33	35	
	Liczby wystąpień	18	107	15	
<i>Temperatura stopu [°C]</i>	Górne granice przedziałów	678	688,5		
	Liczby wystąpień	60	80		
<i>Temperatura termoregulatora 2.1 [°C]</i>	Górne granice przedziałów	67	72	75	
	Liczby wystąpień	28	93	19	
<i>Temperatura termoregulatora 2.2 [°C]</i>	Górne granice przedziałów	72	74		
	Liczby wystąpień	73	67		
<i>Temperatura termoregulatora 3.2 [°C]</i>	Górne granice przedziałów	150	156		
	Liczby wystąpień	80	60		
<i>Temperatura tulei 1 [°C]</i>	Górne granice przedziałów	208	218	234	
	Liczby wystąpień	25	83	32	
<i>Temperatura tulei 2 [°C]</i>	Górne granice przedziałów	218	226	232	

	Liczby wystąpień	48	77	15	
<i>Temperatura tulei 3 [°C]</i>	Górne granice przedziałów	218	228	240	
	Liczby wystąpień	37	78	25	
<i>Temperatura tulei 4 [°C]</i>	Górne granice przedziałów	228	236	246	
	Liczby wystąpień	49	66	25	
<i>Temperatura w obwodzie chłodzenia 1 [°C]</i>	Górne granice przedziałów	30	33	39	
	Liczby wystąpień	16	112	12	
<i>Temperatura w obwodzie chłodzenia 13 [°C]</i>	Górne granice przedziałów	34	35	39	
	Liczby wystąpień	48	60	32	
<i>Temperatura w obwodzie chłodzenia 14 [°C]</i>	Górne granice przedziałów	31	32	33	34
	Liczby wystąpień	13	44	62	21
<i>Temperatura w obwodzie chłodzenia 15 [°C]</i>	Górne granice przedziałów	32	34	36	
	Liczby wystąpień	15	108	17	
<i>Temperatura w obwodzie chłodzenia 17 [°C]</i>	Górne granice przedziałów	28	33	35	
	Liczby wystąpień	42	85	13	
<i>Temperatura w obwodzie chłodzenia 7 [°C]</i>	Górne granice przedziałów	27	28	29	30
	Liczby wystąpień	15	72	46	7
<i>Temperatura wody miejskiej [°C]</i>	Górne granice przedziałów	20	22	26	
	Liczby wystąpień	38	59	43	
<i>Temperatura wody w instalacji [°C]</i>	Górne granice przedziałów	24	25		
	Liczby wystąpień	66	74		
<i>Wartość próżni 1 [mBar]</i>	Górne granice przedziałów	300	400	534	
	Liczby wystąpień	39	75	26	
<i>Wartość próżni 2 [mBar]</i>	Górne granice przedziałów	450	480	526	
	Liczby wystąpień	36	90	14	
<i>Zużycie smaru [l]</i>	Górne granice przedziałów	0	2		
	Liczby wystąpień	116	24		
<i>Przeciek w obwodzie wysokiego ciśnienia [cm3] Leakage 2CAT</i>	Górne granice przedziałów	7,49	171,86		
	Liczby wystąpień	70	70		
<i>Przeciek w obwodzie wysokiego ciśnienia [cm3] Leakage 4CAT</i>	Górne granice przedziałów	10	25	100	171,86
	Liczby wystąpień	95	27	9	9

Tab. 5.64.: Ustalane przedziały i wystąpienia danych wartości w przedziałach dla piątego zbioru danych do badań

	Wartość zdyskretyzowana	1	2	3	4
<i>Ciśnienie sprężonego powietrza [Bar]</i>	Górne granice przedziałów	5	6		
	Liczby wystąpień	37	103		
<i>Ciśnienie wody miejskiej [Bar]</i>	Górne granice przedziałów	3	4	5	

	Liczby wystąpień	30	86	24	
<i>Ciśnienie wody obiegowej [Bar]</i>	Górne granice przedziałów	2	3		
	Liczby wystąpień	71	69		
<i>Czas pierwszej fazy wtrysku [ms]</i>	Górne granice przedziałów	2240	2280	2330	
	Liczby wystąpień	31	70	39	
<i>Czas chłodzenia obwodu 1 [s]</i>	Górne granice przedziałów	31			
	Liczby wystąpień	140			
<i>Czas cyklu [s]</i>	Górne granice przedziałów	100	172,61		
	Liczby wystąpień	125	15		
<i>Czas cyklu smarowania [s]</i>	Górne granice przedziałów	23	31,5		
	Liczby wystąpień	122	18		
<i>Czas dozowania stopu 1 [s]</i>	Górne granice przedziałów	11,1	33		
	Liczby wystąpień	136	4		
<i>Czas dozowania stopu 2 [s]</i>	Górne granice przedziałów	61	80	106,6	
	Liczby wystąpień	3	129	8	
<i>Czas krzepnięcia t2 [s]</i>	Górne granice przedziałów	10	11		
	Liczby wystąpień	82	58		
<i>Czas przedmuchu [s]</i>	Górne granice przedziałów	8,0	11,7		
	Liczby wystąpień	121	19		
<i>Czas smarowania [s]</i>	Górne granice przedziałów	6	9,30		
	Liczby wystąpień	126	14		
<i>Dzienny numer wtrysku [j.]</i>	Górne granice przedziałów	100	300	663	
	Liczby wystąpień	44	50	46	
<i>Filtr próżni 1 [mBar]</i>	Górne granice przedziałów	1300	1500	1593	
	Liczby wystąpień	7	113	20	
<i>Grubość piętki układu wlewowego [mm]</i>	Górne granice przedziałów	35,5	45		
	Liczby wystąpień	17	123		
<i>Koncentrat [%]</i>	Górne granice przedziałów	2,3	2,7		
	Liczby wystąpień	27	113		
<i>Ciśnienie maksymalne [Bar]</i>	Górne granice przedziałów	340	343	345	
	Liczby wystąpień	27	97	16	
<i>Prędkość wtrysku maksymalna [m/s]</i>	Górne granice przedziałów	5,85	5,9	6	
	Liczby wystąpień	13	77	50	
<i>Opóźnienie multiplikacji [ms]</i>	Górne granice przedziałów	171	174	176	
	Liczby wystąpień	35	86	19	
<i>Stała temperatura chłodzenia płyty [°C]</i>	Górne granice przedziałów	28	32		
	Liczby wystąpień	67	73		
<i>Poziom stopu w piecu podgrzewczym [mm]</i>	Górne granice przedziałów	500	6543,6		

	Liczby wystąpień	40	100		
Poziom wody w strumieniu chłodzącym [mm]	Górne granice przedziałów	260	298		
	Liczby wystąpień	68	72		
Czas drugiej fazy wtrysku [ms]	Górne granice przedziałów	88	89	90,0	
	Liczby wystąpień	45	65	30	
Profil próżni 1 [mBar]	Górne granice przedziałów	1100	1298		
	Liczby wystąpień	35	105		
Profil próżni 2 [mBar]	Górne granice przedziałów	1200	1321		
	Liczby wystąpień	42	98		
Przepływ chłodzenia tłoka [l]	Górne granice przedziałów	24	26		
	Liczby wystąpień	87	53		
Przepływ w obwodzie chłodzenia 1 [l]	Górne granice przedziałów	25	28		
	Liczby wystąpień	65	75		
Przepływ w obwodzie chłodzenia 13 [l]	Górne granice przedziałów	18	19	20	
	Liczby wystąpień	62	54	24	
Przepływ w obwodzie chłodzenia 14 [l]	Górne granice przedziałów	26	27	29	
	Liczby wystąpień	25	46	69	
Przepływ w obwodzie chłodzenia 15 [l]	Górne granice przedziałów	25	26	27	28
	Liczby wystąpień	30	52	33	25
Przepływ w obwodzie chłodzenia 17 [l]	Górne granice przedziałów	20	30	36	
	Liczby wystąpień	22	48	70	
Przepływ w obwodzie chłodzenia 20 [l]	Górne granice przedziałów	22	23	25	
	Liczby wystąpień	48	61	31	
Przepływ w obwodzie chłodzenia 6 [l]	Górne granice przedziałów	29	33		
	Liczby wystąpień	76	64		
Prędkość we wlewach doprowadzających [m/s]	Górne granice przedziałów	38,4	38,8	39,27	
	Liczby wystąpień	35	73	32	
Suw pierwszej fazy wtrysku [mm]	Górne granice przedziałów	537	538	540	
	Liczby wystąpień	44	60	36	
Suw docisku po multiplikacji [mm]	Górne granice przedziałów	17	18	19	20
	Liczby wystąpień	7	32	88	13
Temperatura chłodzenia tłoka [°C]	Górne granice przedziałów	30	33	35	
	Liczby wystąpień	17	106	17	
Temperatura stopu [°C]	Górne granice przedziałów	678	689		
	Liczby wystąpień	57	83		
Temperatura termoregulatora 2.1 [°C]	Górne granice przedziałów	67	72	75	
	Liczby wystąpień	28	88	24	
Temperatura termoregulatora 2.2 [°C]	Górne granice przedziałów	72	74		

	Liczby wystąpień	66	74		
Temperatura termoregulatora 3.2 [°C]	Górne granice przedziałów	150	156		
	Liczby wystąpień	83	57		
Temperatura tulei 1 [°C]	Górne granice przedziałów	208	218	234	
	Liczby wystąpień	24	84	32	
Temperatura tulei 2 [°C]	Górne granice przedziałów	218	226	232	
	Liczby wystąpień	46	76	18	
Temperatura tulei 3 [°C]	Górne granice przedziałów	218	228	242	
	Liczby wystąpień	41	71	28	
Temperatura tulei 4 [°C]	Górne granice przedziałów	228	236	250	
	Liczby wystąpień	48	69	23	
Temperatura w obwodzie chłodzenia 1 [°C]	Górne granice przedziałów	30	33	39	
	Liczby wystąpień	13	117	10	
Temperatura w obwodzie chłodzenia 13 [°C]	Górne granice przedziałów	34	35	38	
	Liczby wystąpień	50	65	25	
Temperatura w obwodzie chłodzenia 14 [°C]	Górne granice przedziałów	31	32	33	34
	Liczby wystąpień	13	50	60	17
Temperatura w obwodzie chłodzenia 15 [°C]	Górne granice przedziałów	32	34	36	
	Liczby wystąpień	23	103	14	
Temperatura w obwodzie chłodzenia 17 [°C]	Górne granice przedziałów	28	33	35	
	Liczby wystąpień	51	75	14	
Temperatura w obwodzie chłodzenia 7 [°C]	Górne granice przedziałów	27	28	29	30
	Liczby wystąpień	12	69	53	6
Temperatura wody miejskiej [°C]	Górne granice przedziałów	20	22	26	
	Liczby wystąpień	40	63	37	
Temperatura wody w instalacji [°C]	Górne granice przedziałów	24	25		
	Liczby wystąpień	71	69		
Wartość próżni 1 [mBar]	Górne granice przedziałów	300	400	552	
	Liczby wystąpień	36	79	25	
Wartość próżni 2 [mBar]	Górne granice przedziałów	450	480	526	
	Liczby wystąpień	59	68	13	
Zużycie smaru [l]	Górne granice przedziałów	0	2		
	Liczby wystąpień	110	30		
Przeciek w obwodzie wysokiego ciśnienia [cm3] 2CAT	Górne granice przedziałów	7,49	171,86		
	Liczby wystąpień	70	70		
Przeciek w obwodzie wysokiego ciśnienia [cm3] 4CAT	Górne granice przedziałów	10	25	100	171,86
	Liczby wystąpień	95	27	9	9

5.2.2.2. Wnioski

Opisaną procedurę zastosowano w celu przygotowania danych do dalszej identyfikacji ukrytych zależności, które się w nich znajdują. Zastosowana dyskretyzacja umożliwiła zamianę atrybutów liczbowych na określone atrybuty symboliczne typu porządkowego [147]. Przeprowadzona została poprzez podział dziedziny każdego badanego atrybutu liczbowego na zgodną z opracowanym planem badawczym liczbę przedziałów oraz zapisana jako przypisana tym przedziałom liczbę porządkową.

Pośród wielu znanych metod dyskretyzacji takich jak podział równy między przedziałami, przedział o równej częstości, czyli zawierający mniej więcej taką samą liczbę obserwacji i innych, zdecydowano na zastosowanie podziału w odniesieniu do wizualnej oceny, uporządkowanych według wartości przyjmowanych przez dany parametr (wartości typowe, podwyższone i obniżone).

Głównym wnioskiem z przeprowadzonej analizy jest jej waga i wpływ na kolejne etapy badań, gdyż decydują ona o jakości wyników dalszych analiz. Wymagała ona poświęcenia jej dużej ilości czasu, co jest uzasadnione, ponieważ cały proces modelowania opartego na danych, byłby bezcelowy bez właściwego ich przygotowania, stąd przygotowanie może stanowić klucz do sukcesu, czyli do osiągnięcia jak najlepszych wyników przewidywania powstawania wady w produkcji poprzez prawidłową diagnostykę jej przyczyn. Niektóre działania mogą być określone sztuką, jako, że realizowana jest wizja twórcy w oparciu o jego eksperckie doświadczenie niż podążanie za formalnymi procedurami będące niejako rutynowym.

5.2.3. Analiza istotności zmiennych

W niniejszym rozdziale zaprezentowane zostaną wyniki statystycznego określenia istotnych parametrów procesu dla każdego z utworzonych 5 zbiorów danych do badań. Do oceny istotności użyto analizy ANOVA w czterech wariantach.

Pierwszy wariant to klasyczna jednoczynnikowa ANOVA, którą zastosowano w celu określenia wpływu charakterystycznych poziomów parametrów procesu (wartości wejściowych) obserwowanych w danych. Drugi wariant to test Kruskala – Wallisa (jednoczynnikowa ANOVA w wersji rangowej), stosowany, gdy zmienna zależna ma rozkład inny niż normalny. Trzeci wariant to ANOVA klasyczna, odwrócona, wykonana celem sprawdzenia, czy w grupach o wysokiej i niskiej wartości zmiennej zależnej – *przecieku*, występuje silne zróżnicowanie któregoś z parametrów procesu, co może potencjalnie sugerować jego związek z wadą. Problemem w tym przypadku mogą być różne rozkłady

zmiennych niezależnych np. dwupunktowe (np. *czas krzepnięcia t_2 [s]*), dlatego stosowanie analizy wariancji w tym przypadku może być problematyczne.

Krok ten jest niezbędny i wymaga wiedzy o procesie celem przygotowania danych do zaawansowanego modelowania procesu.

5.2.3.1. Metodyka i wyniki badań

Kolejnym krokiem analizy danych jest wybór zmiennych do zaawansowanego modelowania opartego na danych, przeprowadzony poprzez analizę ich istotności, przy zastosowaniu analizy ANOVA w czterech wariantach. Idea wspomnianego podejścia statystycznego skupia się na tym, że w przypadku gdy w grupach obserwacji zawierających zróżnicowane poziomy zmiennej niezależnej, to również wartości zmiennej zależnej są istotnie zróżnicowane, wówczas tę zmienną niezależną powinno się uznać za istotną z punktu widzenia jej wpływu na wartość zmiennej zależnej.

Kolejnym wariantem jest zastosowanie wnioskowania odwrotnego zakładającego, że jeżeli w danej grupie obserwacji zawarte są zróżnicowane poziomy zmiennej zależnej, to można zaobserwować wówczas istotnie różne wartości określonej zmiennej niezależnej, wtedy należy uznać tę zmienną za istotną. Należy pamiętać, iż dla pierwszego jak i dla drugiego założenia możliwa jest identyfikacja jedynie potencjalnie istotnych zmiennych. W niniejszej analizie nie uwzględnia się również jednoczesnego wpływu kilku parametrów procesu czy to synergicznego, czy konkurencyjnego, gdyż rozpatrywana jest tylko jedna zmienna niezależna w danym momencie. Z uwagi na ten fakt, proces redukcji wymiarowości zbiorów danych powinien być przeprowadzony ze szczególną ostrożnością. W konsekwencji w zbiorze uczącym mogą znaleźć się dane, które nie mają istotnego wpływu zamiast tych, które wpływają na wydajność danego procesu. W związku z tym wykryte zmienne niezależne, które zostaną ocenione jako nieistotne z punktu widzenia zmiennej zależnej mogłyby być zmieniane bez wpływu na jakość odlewanych produktów, co mogłoby wpłynąć na obniżenie kosztów kontroli jakości.


Analiza mająca na celu zidentyfikowanie najbardziej istotnych zmiennych została zaimplementowana dzięki oprogramowaniu Statistica opracowanym przez StatSoft Inc., wspomagającym zaawansowaną analizę danych. Jak wspomniano do wyboru istotnych zmiennych zastosowano analizę wariancji ANOVA (ang. analysis of variance) w czterech wariantach. Pierwszy z nich to jednokierunkowa (jednoczynnikowa) (ang. one-way) ANOVA, którą trudno jest jednak zaaplikować do zbiorów danych niemających rozkładów bliskich do rozkładu normalnego. Mimo to istnieje możliwość zastosowania tej metody dla zbiorów o

większej liczbie punktów [148]. Miarą istotności zmiennej jest obliczona statystyka F, obliczana według wzoru (1) poprzez porównanie dwóch wariancji s_1 i s_2 , poprzez ich podział:

$$F = \frac{s_1^2}{s_2^2} \quad (5.1)$$

Drugi wariant zastosowany w niniejszych badaniach, to test Kruskala-Wallisa, czyli jednokierunkowa ANOVA w wersji rangowej, sprawdzająca się w przypadkach kiedy zmienna posiada rozkład inny niż normalny. Trzeci wariant to, klasyczna odwrócona ANOVA pozwalająca dla badanych przypadków określić, czy występuje znaczące zróżnicowanie któregoś parametru procesu w określonych grupach o podwyższonych wartościach *przecieku*, lub niskich wartościach *przecieku*. Czwartym wariantem jest odwrócona ANOVA w wersji rangowej, znana również jako test Kruskala-Wallisa w wersji odwróconej, znajdująca swoje zastosowanie dla dowolnych rozkładów zmiennych.


Procedura wykonywania badań została przeprowadzona zgodnie z opisami z rys.5.2.3.1.-rys.5.2.3.3. dla wariantu pierwszego i trzeciego, oraz zgodnie z opisami z rys.5.2.3.4. dla wariantu drugiego i czwartego.



Rys.5.2.3.1. Okno programu przedstawiające początkowe etapy przeprowadzenia analizy ANOVA klasycznej jednoczynnikowej i odwróconej

W celu przeprowadzenia testu ANOVA klasycznej i odwróconej należy:


- w punkcie 1, wybrać zakładkę „Statistics”,
- w punkcie 2, wybrać test „ANOVA”,
- w punkcie 3, wybrać typ analizy „One-way ANOVA”,
- w punkcie 4, wybrać specyfikację metody „Quick specs dialog”,
- w punkcie 5, zatwierdzić wybrane ustawienia.



Rys.5.2.3.2. Okno programu przedstawiające dalsze etapy przeprowadzenia analizy ANOVA klasycznej jednoczynnikowej i odwróconej

W celu dalszego zatwierdzenia parametrów testu ANOVA klasycznej i odwróconej należy:


- w punkcie 1, wybrać zmienne do badań „Variables”,
- w punkcie 2, wybrać zmienne zależne „Dependent variables”,
- w punkcie 3, wybrać zdyskretyzowane zmienne niezależne „Categorical factor”,
- w punkcie 4, zatwierdzić wybrane ustawienia.



Rys.5.2.3.3. Okno programu przedstawiające wyniki przeprowadzenia analizy ANOVA klasycznej jednoczynnikowej i odwróconej

W celu pobrania wyników testu ANOVA klasycznej i odwróconej należy:

- w punkcie 1, wybrać „Effects sizes”,
- w punkcie 2, zapisać wartości statystyki F i p,
- w punkcie 3, wybrać wszystkie efekty „All effects/graphs”,
- w punkcie 4, zatwierdzić wybrane ustawienia.
- W punkcie 5, zapisać wykres wynikowy



Rys.5.2.3.4. Okno programu przedstawiające wyniki przeprowadzenia testu Kruskalla-Wallisa klasycznego i odwróconego

W celu przeprowadzenia testu Kruskalla-Wallisa klasycznego i odwróconego należy:

- w punkcie 1, wybrać statystyczny test nieparametryczny „Comparing multiple indep. Samples (groups)”,
- w punkcie 2, zatwierdzić wybrane ustawienia,
- w punkcie 3, wybrać typ zmienne do badań „Variables”,
- w punkcie 4, wybrać typ zmienne zależne do badań,
- w punkcie 5, wybrać typ zmienne niezależne do badań,
- w punkcie 6, zatwierdzić wybrane ustawienia,
- w punkcie 7, wybrać specyfikację metody „Multiple comparison of mean ranks for all groups”,
- w punkcie 8, zapisać wartości statystyki H i p

Wyniki zapisano w postaci tabel i wykresów (tab..).

Tab. 5.65.: Zestawienie obliczonych wartości statystyk F i H dla pierwszego zbioru danych do badań

Statystyka	F	F	F	H	H	H
Test	Jedno- czynnikiowa ANOVA	ANOVA odwrócona przeciek 2CAT	ANOVA odwrócona przeciek 4CAT	Test Kruskala- Wallisa	Kruskal- Wallis odwrócony przeciek 2CAT	Kruskal- Wallis odwrócony przeciek 4CAT
Ciśnienie sprężonego powietrza [Bar]	0,255	0,471	0,996	3,298523	0,4173188	2,986752
Ciśnienie wody miejskiej [Bar]	1,068	0,957	3,475	1,79016	0,9569242	10,4145

Ciśnienie wody obiegowej [Bar]	2,532	0,77	3,492	4,840166	0,7696159	10,46878
Czas pierwszej fazy wtrysku [ms]	2,149	0,584	7,673	32,06576	1,413235	25,78073
Czas chłodzenia obwodu 1 [s]	0,119	1,712	1,223	0,4427263	1,710755	3,664811
Czas cyklu [s]	4,723	0,95	6,919	31,93778	12,17835	21,35546
Czas cyklu smarowania [s]	5,263	42,4	18,65	44,9433	6,454037	10,61015
Czas dozowania stopu [s]	1,1606	0,443	9,063	26,09323	0,2641669	6,002321
Czas dozowania stopu 2 [s]	4,884	4,189	2,184	34,54624	14,61024	37,66653
Czas krzepnięcia t2 [s]	19,5	24,09	37,03	1,328193	24,03705	109,9057
Czas przedmuchu [s]	4,632	25,03	10,57	43,84121	4,5	6,70068
Czas smarowania [s]	10,47	40,85	19,17	34,25	12,88076	20,84521
Dzienny numer wtrysku [j.]	0,981	4,049	1,895	5,072492	4,896076	6,769793
Filtr próżni 1 [mBar]	3,196	0,582	30,9	66,93572	2,904119	122,7295
Grubość piętki układu wlewowego [mm]	1,163	2,316	5,455	2,119902	3,953699	23,15601
Koncentrat [%]	0,163	3,036	1,166	22,23257	2,1	2,399743
Ciśnienie maksymalne [Bar]	1,296	7,903	14,95	2,480035	8,627961	52,33013
Prędkość wtrysku maksymalna [m/s]	0,506	12,39	9,987	3,023659	10,34759	24,53073
Opóźnienie multiplikacji [ms]	1,547	11,81	5,591	17,55585	10,37676	16,69106
Stała temperatura chłodzenia płyty [°C]	2,106	68,95	34,82	1,758814	34,5491	77,15074
Poziom stopu w piecu podgrzewczym [mm]	0,947	3,1	2,3	2,0	1,95116	14,44415
Poziom wody w strumieniu chłodzącym [mm]	2,673	5,023	4,64	5,461962	4,795089	11,52655
Czas drugiej fazy wtrysku [ms]	1,77	0,249	10,68	10,33658	0,2792746	31,61594
Profil próżni 1 [mBar]	2,126	6,704	4,543	13,13486	5,381233	5,674093
Profil próżni 2 [mBar]	11,37	8,333	5,608	79,10164	0,4393711	4,852855
Przepływ chłodzenia tłoka [l]	0,141	45,89	19,32	7,29478	41,46279	51,36015
Przepływ w obwodzie chłodzenia 1 [l]	0,243	54,88	27,84	0,4306089	39,64148	60,3091
Przepływ w obwodzie chłodzenia 13 [l]	0,895	28,12	21,71	5,710417	26,45712	58,29693
Przepływ w obwodzie chłodzenia 14 [l]	0,426	37,94	20,96	4,172529	35,96938	57,38471
Przepływ w obwodzie chłodzenia 15 [l]	3,743	15,7	8,844	71,20548	7,317385	19,74998
Przepływ w obwodzie chłodzenia 17 [l]	4,546	20,6	48,09	72,72156	19,78844	157,054
Przepływ w obwodzie chłodzenia 20 [l]	0,007	19,69	14,93	4,211397	21,38843	42,18682
Przepływ w obwodzie chłodzenia 6 [l]	1,291	1,134	4,389	48,99781	0,5933745	11,8638
Prędkość we wlewach doprowadzających [m/s]	0,14	0,89	3,87	2,96	1,24	10,56398
Suw pierwszej fazy wtrysku [mm]	1,234	0,002	1,124	8,353043	0,025599	2,994294
Suw docisku po multiplikacji [mm]	5,502	8,47	18,19	134,504	6,780152	48,94325

<i>Temperatura chłodzenia tłoka [°C]</i>	0,023	6,99	3,838	35,86505	5,586133	7,809001
<i>Temperatura stopu [°C]</i>	0,855	0,133	1,305	33,63239	0,2	5,258253
<i>Temperatura termoregulatora 2.1 [°C]</i>	0,793	1,415	0,745	3,720329	1,93713	2,708377
<i>Temperatura termoregulatora 2.2 [°C]</i>	0,754	0,939	0,477	1,625626	1,169918	1,476165
<i>Temperatura termoregulatora 3.2 [°C]</i>	0,065	2,466	0,836	6,121683	2,414521	2,421386
<i>Temperatura tulei 1 [°C]</i>	0,91	0,231	1,126	0,5409375	0,0750582	3,155166
<i>Temperatura tulei 2 [°C]</i>	2,784	21,88	7,369	11,34226	16,9952	17,1783
<i>Temperatura tulei 3 [°C]</i>	0,996	4,101	2,025	0,2704595	4,191708	7,157121
<i>Temperatura tulei 4 [°C]</i>	0,044	7,125	2,396	0,2727062	9,358098	9,619893
<i>Temperatura w obwodzie chłodzenia 1 [°C]</i>	7,254	29,39	10,2	66,03428	27,87449	38,42332
<i>Temperatura w obwodzie chłodzenia 13 [°C]</i>	18,4	2,043	3,732	4,169058	1,008509	10,4492
<i>Temperatura w obwodzie chłodzenia 14 [°C]</i>	1,709	5,837	3,496	8,690242	6,524176	11,80991
<i>Temperatura w obwodzie chłodzenia 15 [°C]</i>	3,504	0,317	4,249	71,30156	0,8732053	7,823963
<i>Temperatura w obwodzie chłodzenia 17 [°C]</i>	6,494	0,482	5,062	39,28297	0,666354	7,479346
<i>Temperatura w obwodzie chłodzenia 7 [°C]</i>	1,908	5,647	3,329	38,83704	6,123501	15,69997
<i>Temperatura wody miejskiej [°C]</i>	0,502	0,241	7,942	5,995376	0,5539388	28,07293
<i>Temperatura wody w instalacji [°C]</i>	0,986	0,481	0,225	0,5648489	0,4503004	0,8652029
<i>Wartość próżni 1 [mBar]</i>	15,04	1,551	80,26	178,4381	2,685226	214,5486
<i>Wartość próżni 2 [mBar]</i>	1,197	15,81	8,518	56,47239	43,56863	51,85194
<i>Zużycie smaru [l]</i>	0,924	0,616	0,728	3,631308	0,5656555	1,824084

Tab. 5.66.: Zestawienie obliczonych wartości p dla pierwszego zbioru danych do badań

Statystyka	p	p	p	p	p	p
Test	Jedno- czynnikiowa ANOVA	ANOVA odwrócona przeciek 2CAT	ANOVA odwrócona przeciek 4CAT	Test Kruskala- Wallisa	Kruskal- Wallis odwrócony przeciek 2CAT	Kruskal- Wallis odwrócony przeciek 4CAT
<i>Ciśnienie sprężonego powietrza [Bar]</i>	0,613	0,518	0,394	0,0693	0,5183	0,3937
<i>Ciśnienie wody miejskiej [Bar]</i>	0,344	0,328	0,015	0,4086	0,328	0,0154
<i>Ciśnienie wody obiegowej [Bar]</i>	0,112	0,38	0,015	0,0278	0,3803	0,015
<i>Czas pierwszej fazy wtrysku [ms]</i>	0,092	0,445	0,00004	0,000001	0,2345	0,000001

<i>Czas chłodzenia obwodu 1 [s]</i>	0,888	0,191	0,299	0,8014	0,1909	0,3
<i>Czas cyklu [s]</i>	0,009	0,33	0,00012	0,000001	0,0005	0,0001
<i>Czas cyklu smarowania [s]</i>	0,005	0,000001	0,000001	0,000001	0,0111	0,014
<i>Czas dozowania stopu [s]</i>	0,3133339	0,506	0,00001	0,000001	0,6073	0,1115
<i>Czas dozowania stopu 2 [s]</i>	0,008	0,041	0,088	0,000001	0,0001	0,000001
<i>Czas krzepnięcia t2 [s]</i>	0,00001	0,000001	0,000001	0,2491	0,000001	0,000001
<i>Czas przedmuchu [s]</i>	0,01	0,000001	0,00001	0,000001	0,0342	0,0821
<i>Czas smarowania [s]</i>	0,001	0,000001	0,00001	0,000001	0,0003	0,0001
<i>Dzienny numer wtrysku [j.]</i>	0,401	0,044	0,128	0,1666	0,0269	0,0796
<i>Filtr próżni 1 [mBar]</i>	0,022	0,445	0,000001	0,000001	0,0884	0,000001
<i>Grubość piętki układu wlewowego [mm]</i>	0,313	0,128	0,001	0,3465	0,0468	0,000001
<i>Koncentrat [%]</i>	0,849	0,081	0,321	0,000001	0,1457	0,4937
<i>Ciśnienie maksymalne [Bar]</i>	0,274	0,005	0,000001	0,2894	0,0033	0,000001
<i>Prędkość wtrysku maksymalna [m/s]</i>	0,477	0,00043	0,000001	0,0821	0,0013	0,000001
<i>Opóźnienie multiplikacji [ms]</i>	0,213	0,001	0,001	0,0002	0,0013	0,0008
<i>Stała temperatura chłodzenia płyty [°C]</i>	0,147	0,000001	0,000001	0,1848	0,000001	0,000001
<i>Poziom stopu w piecu podgrzewczym [mm]</i>	0,33	0,079	0,078	0,1555	0,1625	0,0024
<i>Poziom wody w strumieniu chłodzącym [mm]</i>	0,069	0,025	0,003	0,0652	0,0285	0,0092
<i>Czas drugiej fazy wtrysku [ms]</i>	0,17	0,618	0,000001	0,0057	0,5972	0,000001
<i>Profil próżni 1 [mBar]</i>	0,119	0,01	0,003	0,0014	0,0204	0,1286
<i>Profil próżni 2 [mBar]</i>	0,00001	0,004	0,001	0,000001	0,5074	0,1829
<i>Przepływ chłodzenia tłoka [l]</i>	0,869	0,000001	0,000001	0,0261	0,000001	0,000001
<i>Przepływ w obwodzie chłodzenia 1 [l]</i>	0,784	0,00001	0,000001	0,8063	0,000001	0,000001
<i>Przepływ w obwodzie chłodzenia 13 [l]</i>	0,443	0,000001	0,000001	0,1266	0,000001	0,000001
<i>Przepływ w obwodzie chłodzenia 14 [l]</i>	0,734	0,000001	0,000001	0,2434	0,000001	0,000001
<i>Przepływ w obwodzie chłodzenia 15 [l]</i>	0,011	0,00007	0,00001	0,000001	0,0068	0,0002
<i>Przepływ w obwodzie chłodzenia 17 [l]</i>	0,001	0,00001	0,000001	0,000001	0,000001	0,000001
<i>Przepływ w obwodzie chłodzenia 20 [l]</i>	0,993	0,00001	0,000001	0,1218	0,000001	0,000001
<i>Przepływ w obwodzie chłodzenia 6 [l]</i>	0,276	0,287	0,004	0,000001	0,4411	0,0079
<i>Prędkość we wlewach doprowadzających [m/s]</i>	0,873	0,346	0,009	0,2275	0,2664	0,0143
<i>Suw pierwszej fazy wtrysku [mm]</i>	0,294	0,963	0,338	0,0795	0,8729	0,3925
<i>Suw docisku po multiplikacji [mm]</i>	0,001	0,004	0,000001	0,000001	0,0092	0,000001
<i>Temperatura chłodzenia tłoka [°C]</i>	0,978	0,008	0,009	0,000001	0,0181	0,0501
<i>Temperatura stopu [°C]</i>	0,425	0,716	0,271	0,000001	0,6399	0,1538

<i>Temperatura termoregulatora 2.1 [°C]</i>	0,453	0,234	0,525	0,1556	0,164	0,4388
<i>Temperatura termoregulatora 2.2 [°C]</i>	0,471	0,333	0,698	0,4436	0,2794	0,6878
<i>Temperatura termoregulatora 3.2 [°C]</i>	0,937	0,116	0,474	0,0468	0,1202	0,4897
<i>Temperatura tulei 1 [°C]</i>	0,402	0,631	0,337	0,763	0,7841	0,3683
<i>Temperatura tulei 2 [°C]</i>	0,062	0,000001	0,000001	0,0034	0,000001	0,0006
<i>Temperatura tulei 3 [°C]</i>	0,369	0,043	0,108	0,8735	0,0406	0,0671
<i>Temperatura tulei 4 [°C]</i>	0,957	0,008	0,066	0,8725	0,0022	0,0221
<i>Temperatura w obwodzie chłodzenia 1 [°C]</i>	0,001	0,000001	0,000001	0,000001	0,000001	0,000001
<i>Temperatura w obwodzie chłodzenia 13 [°C]</i>	0,0000001	0,153	0,011	0,1244	0,3153	0,0151
<i>Temperatura w obwodzie chłodzenia 14 [°C]</i>	0,163	0,016	0,015	0,0337	0,0106	0,0081
<i>Temperatura w obwodzie chłodzenia 15 [°C]</i>	0,007	0,573	0,005	0,000001	0,3501	0,0498
<i>Temperatura w obwodzie chłodzenia 17 [°C]</i>	0,002	0,487	0,002	0,000001	0,4143	0,0581
<i>Temperatura w obwodzie chłodzenia 7 [°C]</i>	0,126	0,017	0,019	0,000001	0,0133	0,0013
<i>Temperatura wody miejskiej [°C]</i>	0,605	0,624	0,000001	0,0499	0,4567	0,000001
<i>Temperatura wody w instalacji [°C]</i>	0,373	0,488	0,879	0,754	0,5022	0,8338
<i>Wartość próżni 1 [mBar]</i>	0,00001	0,213	0,000001	0,000001	0,1013	0,000001
<i>Wartość próżni 2 [mBar]</i>	0,302	0,00007	0,00001	0,000001	0,000001	0,000001
<i>Zużycie smaru [l]</i>	0,397	0,433	0,535	0,1627	0,452	0,6097

Tab. 5.67.: Zestawienie obliczonych wartości statystyk F i H dla drugiego zbioru danych do badań

Statystyka	F	F	F	H	H	H
Test	Jedno- czynnikiowa ANOVA	ANOVA odwrócona przeciek 2CAT	ANOVA odwrócona przeciek 4CAT	Test Kruskala- Wallisa	Kruskal- Wallis odwrócony przeciek 2CAT	Kruskal- Wallis odwrócony przeciek 4CAT
<i>Ciśnienie sprężonego powietrza [Bar]</i>	2,429	2,053	0,806	0,3863928	2,021978	2,437339
<i>Ciśnienie wody miejskiej [Bar]</i>	2,948	8,482	2,918	8,301506	7,559942	7,925285
<i>Ciśnienie wody obiegowej [Bar]</i>	2,906	3,361	1,249	2,045285	3,249733	3,705556
<i>Czas pierwszej fazy wtrysku [ms]</i>	0,969	2,197	0,995	0,6265023	1,842936	2,478879
<i>Czas chłodzenia obwodu 1 [s]</i>		2,971	2,396		2,888889	6,777778

Czas cyklu [s]	0,149	0,024	0,385	3,362181	0,0877138	6,788323
Czas cyklu smarowania [s]	0,490	0,825	0,636	0,0786859	0,0207027	0,2869239
Czas dozowania stopu [s]	0,958	0,703	1,227	2,31784	1,069005	1,704996
Czas dozowania stopu 2 [s]	0,043	0,021	0,1	0,5968615	0,3996987	5,284452
Czas krzepnięcia t2 [s]	12,710	11,38	7,109	0,9808123	9,894695	16,85154
Czas przedmuchu [s]	0,124	0,013	1,242	0,0548032	0,2161364	3,325225
Czas smarowania [s]	0,239	0,20	0,79	0,12	0,0894083	3,644906
Dzienny numer wtrysku [j.]	0,279	0,312	0,198	0,2335092	0,2472141	0,4429671
Filtr próżni 1 [mBar]	0,717	0,718	3,319	2,317934	0,8229552	9,697436
Grubość piętki układu wlewowego [mm]	9,703	18,89	7,296	8,003095	14,13985	16,46923
Koncentrat [%]	1,034	0,1	0,3	0,0	0,0705372	0,547445
Ciśnienie maksymalne [Bar]	4,125	0,606	1,813	7,11283	0,8153199	5,900125
Prędkość wtrysku maksymalna [m/s]	2,809	3,453	1,676	2,726713	3,684616	5,522741
Opóźnienie multiplikacji [ms]	2,881	4,656	2,87	7,327664	4,7488	7,89001
Stała temperatura chłodzenia płyty [°C]	14,893	10	8,177	0,9934879	9,417967	19,47438
Poziom stopu w piecu podgrzewczym [mm]	13,154	20	7,939	7,394622	14,88186	15,95878
Poziom wody w strumieniu chłodzącym [mm]	3,041	4,367	1,476	0,3780431	3,055332	3,568858
Czas drugiej fazy wtrysku [ms]	1,117	1,925	1,18	5,163424	2,3	3,957894
Profil próżni 1 [mBar]	3,467	1,369	1,044	0,3534206	2,64466	3,77615
Profil próżni 2 [mBar]	16,691	4,592	1,814	10,93307	0,497994	2,045617
Przepływ chłodzenia tłoka [l]	5,328	19,67	8,776	4,435589	13,16025	15,59664
Przepływ w obwodzie chłodzenia 1 [l]	26,206	16,97	7,969	6,009915	14,06818	18,43844
Przepływ w obwodzie chłodzenia 13 [l]	4,999	11,65	6,609	7,739514	6,767401	11,29007
Przepływ w obwodzie chłodzenia 14 [l]	16,245	23,3	9,087	9,354872	17,98374	20,75701
Przepływ w obwodzie chłodzenia 15 [l]	4,212	0,086	0,814	8,151805	0,0328846	2,541189
Przepływ w obwodzie chłodzenia 17 [l]	6,945	15,58	8,919	1,740659	13,98318	22,47767
Przepływ w obwodzie chłodzenia 20 [l]	4,768	10,58	5,058	7,4201	8,864979	11,82963
Przepływ w obwodzie chłodzenia 6 [l]	4,492	0,467	0,485	4,404203	0,2610893	1,85177
Prędkość we wlewach doprowadzających [m/s]	0,508	0,0001	0,304	0,6528721	0,01	0,6771648
Suw pierwszej fazy wtrysku [mm]	0,624	0,928	1,633	1,151713	0,5833311	4,605347
Suw docisku po multiplikacji [mm]	1,665	0,453	0,413	4,267613	0,7023595	1,949635
Temperatura chłodzenia tłoka [°C]	1,120	0,043	3,177	2,578336	0,000197	9,019874
Temperatura stopu [°C]	5,404	0,296	0,395	4,412921	1,718022	2,396378

Temperatura termoregulatora 2.1 [°C]	0,588	0,421	1,513	0,7196514	0,3057236	4,439951
Temperatura termoregulatora 2.2 [°C]	1,537	0,16	0,257	0,3178095	1,252078	1,900966
Temperatura termoregulatora 3.2 [°C]	0,583	2,424	1,299	0,2190062	1,951687	2,75312
Temperatura tulei 1 [°C]	1,040	2,3	1,445	1,938197	1,999186	3,394205
Temperatura tulei 2 [°C]	0,749	2,119	1,529	1,781983	1,953457	4,078415
Temperatura tulei 3 [°C]	1,925	1,077	1,447	2,59077	1,390718	3,817435
Temperatura tulei 4 [°C]	0,887	1,922	1,172	1,11966	1,48552	2,958913
Temperatura w obwodzie chłodzenia 1 [°C]	0,437	1,203	1,12	0,5296151	2,842982	9,526812
Temperatura w obwodzie chłodzenia 13 [°C]	0,634	0,168	0,36	2,666657	0,267625	1,719855
Temperatura w obwodzie chłodzenia 14 [°C]	2,527	2,657	1,102	5,230465	3,349669	4,195761
Temperatura w obwodzie chłodzenia 15 [°C]	0,764	0,004	0,13	0,2044889	0,0004549	0,0605263
Temperatura w obwodzie chłodzenia 17 [°C]	4,580	0,0003	0,479	1,119318	0,0852863	1,001342
Temperatura w obwodzie chłodzenia 7 [°C]	1,632	0,616	1,609	1,854109	1,032916	5,669752
Temperatura wody miejskiej [°C]	3,585	2,961	1,052	2,115791	4,584456	5,456402
Temperatura wody w instalacji [°C]	2,772	4,578	3,009	0,0200166	4,386218	9,314399
Wartość próżni 1 [mBar]	7,531	9,751	12,23	9,692538	3,194784	14,54145
Wartość próżni 2 [mBar]	1,963	9,004	3,722	3,193897	3,80062	5,727861
Zużycie smaru [l]	0,696	0,013	1,247	0,4507437	0,0893758	4,29482

Tab. 5.68.: Zestawienie obliczonych wartości p dla drugiego zbioru danych do badań

Statystyka	p	p	p	p	p	p
Test	Jedno-czynnikowa ANOVA	ANOVA odwrócona przeciek 2CAT	ANOVA odwrócona przeciek 4CAT	Test Kruskala-Wallisa	Kruskal-Wallis odwrócony przeciek 2CAT	Kruskal-Wallis odwrócony przeciek 4CAT
Ciśnienie sprężonego powietrza [Bar]	0,124	0,157	0,495	0,5342	0,155	0,4867
Ciśnienie wody miejskiej [Bar]	0,059	0,005	0,041	0,0158	0,006	0,0476
Ciśnienie wody obiegowej [Bar]	0,093	0,071	0,229	0,1527	0,0714	0,2951
Czas pierwszej fazy wtrysku [ms]	0,385	0,143	0,401	0,7311	0,1746	0,4791
Czas chłodzenia obwodu 1 [s]		0,089	0,076		0,0892	0,0793
Czas cyklu [s]	0,701	0,876	0,764	0,0667	0,7671	0,079

Czas cyklu smarowania [s]	0,486	0,367	0,594	0,7791	0,8856	0,9625
Czas dozowania stopu [s]	0,331	0,405	0,307	0,1279	0,3012	0,6358
Czas dozowania stopu 2 [s]	0,958	0,886	0,96	0,742	0,5272	0,1521
Czas krzepnięcia t2 [s]	0,001	0,001	0,00033	0,322	0,0017	0,0008
Czas przedmuchu [s]	0,726	0,911	0,302	0,8149	0,642	0,3441
Czas smarowania [s]	0,627	0,654	0,506	0,7245	0,7649	0,3025
Dzienny numer wtrysku [j.]	0,757	0,578	0,898	0,8898	0,619	0,9312
Filtr próżni 1 [mBar]	0,492	0,4	0,025	0,3138	0,3643	0,0213
Grubość piętki układu wlewowego [mm]	0,003	0,00005	0,00027	0,0047	0,0002	0,0009
Koncentrat [%]	0,313	0,715	0,855	0,907	0,7906	0,9084
Ciśnienie maksymalne [Bar]	0,020	0,439	0,153	0,0285	0,3666	0,1166
Prędkość wtrysku maksymalna [m/s]	0,067	0,067	0,181	0,2558	0,0549	0,1373
Opóźnienie multiplikacji [ms]	0,063	0,034	0,043	0,0256	0,0293	0,0483
Stała temperatura chłodzenia płyty [°C]	0,003	0,002	0,0001	0,3189	0,0021	0,0002
Poziom stopu w piecu podgrzewczym [mm]	0,001	0,000001	0,0001	0,0065	0,0001	0,0012
Poziom wody w strumieniu chłodzącym [mm]	0,086	0,04	0,229	0,5387	0,0805	0,3119
Czas drugiej fazy wtrysku [ms]	0,333	0,17	0,324	0,0756	0,1256	0,266
Profil próżni 1 [mBar]	0,067	0,246	0,379	0,5522	0,1039	0,2867
Profil próżni 2 [mBar]	0,000	0,036	0,153	0,0009	0,4804	0,563
Przepływ chłodzenia tłoka [l]	0,024	0,00003	0,00006	0,0352	0,0003	0,0014
Przepływ w obwodzie chłodzenia 1 [l]	0,000	0,00011	0,0001	0,0142	0,0002	0,0004
Przepływ w obwodzie chłodzenia 13 [l]	0,009	0,001	0,001	0,0209	0,0093	0,0103
Przepływ w obwodzie chłodzenia 14 [l]	0,000	0,00001	0,00004	0,0093	0,000001	0,0001
Przepływ w obwodzie chłodzenia 15 [l]	0,009	0,77	0,491	0,043	0,8561	0,4679
Przepływ w obwodzie chłodzenia 17 [l]	0,002	0,00019	0,00005	0,4188	0,0002	0,0001
Przepływ w obwodzie chłodzenia 20 [l]	0,012	0,002	0,003	0,0245	0,0029	0,008
Przepływ w obwodzie chłodzenia 6 [l]	0,038	0,497	0,694	0,0359	0,6094	0,6037
Prędkość we wlewach doprowadzających [m/s]	0,604	0,997	0,822	0,7215	0,9088	0,8786
Suw pierwszej fazy wtrysku [mm]	0,539	0,339	0,19	0,5622	0,445	0,2031
Suw docisku po multiplikacji [mm]	0,183	0,503	0,744	0,234	0,402	0,5829
Temperatura chłodzenia tłoka [°C]	0,332	0,836	0,03	0,2755	0,9888	0,029
Temperatura stopu [°C]	0,023	0,588	0,757	0,0357	0,1899	0,4943
Temperatura termoregulatora 2.1 [°C]	0,559	0,519	0,219	0,6978	0,5803	0,2177

Temperatura termoregulatora 2.2 [°C]	0,219	0,69	0,856	0,5729	0,2632	0,5932
Temperatura termoregulatora 3.2 [°C]	0,448	0,124	0,282	0,6398	0,1624	0,4313
Temperatura tulei 1 [°C]	0,359	0,134	0,238	0,3794	0,1574	0,3347
Temperatura tulei 2 [°C]	0,478	0,15	0,215	0,4102	0,1622	0,2531
Temperatura tulei 3 [°C]	0,154	0,303	0,237	0,2738	0,2383	0,2819
Temperatura tulei 4 [°C]	0,417	0,17	0,327	0,5713	0,2229	0,398
Temperatura w obwodzie chłodzenia 1 [°C]	0,648	0,277	0,347	0,7674	0,0918	0,023
Temperatura w obwodzie chłodzenia 13 [°C]	0,534	0,684	0,782	0,2636	0,6049	0,6325
Temperatura w obwodzie chłodzenia 14 [°C]	0,065	0,108	0,355	0,1557	0,0672	0,2411
Temperatura w obwodzie chłodzenia 15 [°C]	0,470	0,951	0,942	0,9028	0,983	0,9961
Temperatura w obwodzie chłodzenia 17 [°C]	0,014	0,986	0,698	0,5714	0,7703	0,8009
Temperatura w obwodzie chłodzenia 7 [°C]	0,190	0,435	0,196	0,6032	0,3095	0,1288
Temperatura wody miejskiej [°C]	0,033	0,09	0,376	0,3472	0,0323	0,1413
Temperatura wody w instalacji [°C]	0,101	0,036	0,036	0,8875	0,0362	0,0254
Wartość próżni 1 [mBar]	0,001	0,003	0,00001	0,0079	0,0739	0,0023
Wartość próżni 2 [mBar]	0,148	0,004	0,016	0,2025	0,0512	0,1256
Zużycie smaru [l]	0,407	0,909	0,3	0,502	0,765	0,2313

Tab. 5.69.: Zestawienie obliczonych wartości statystyk F i H dla trzeciego zbioru danych do badań

Statystyka	F	F	F	H	H	H
Test	Jedno-czynnikowa ANOVA	ANOVA odwrócona przeciek 2CAT	ANOVA odwrócona przeciek 4CAT	Test Kruskala-Wallisa	Kruskal-Wallis odwrócony przeciek 2CAT	Kruskal-Wallis odwrócony przeciek 4CAT
Ciśnienie sprężonego powietrza [Bar]	1,792	0,72	1,951	3,035561	0,7203744	5,851408
Ciśnienie wody miejskiej [Bar]	0,310	2,186	0,797	1,706721	2,184639	2,391282
Ciśnienie wody obiegowej [Bar]	10,020	12,43	4,355	5,520844	12,41152	13,05135
Czas pierwszej fazy wtrysku [ms]	8,981	17,49	8,26	33,5372	18,99336	27,27055
Czas chłodzenia obwodu 1 [s]	1,031	0,004	0,531	0,5181515	0,003991	1,590518
Czas cyklu [s]	12,560	42,51	15,39	29,24989	0,0465562	30,45096

Czas cyklu smarowania [s]	10,550	34	15,89	34,1145	2,016532	19,86969
Czas dozowania stopu [s]	11,860	47,63	16,1	25,48414	8,07989	8,23366
Czas dozowania stopu 2 [s]	16,230	12,95	5,583	31,72024	4,936527	36,17869
Czas krzepnięcia t2 [s]	3441,000	31,23	35,92	3,505849	31,13509	106,6525
Czas przedmuchu [s]	7,595	13,87	7,005	37,59767	0,0	1,71812
Czas smarowania [s]	2,164	6,11	10,68	25,81	0,4065546	11,31631
Dzienny numer wtrysku [j.]	1,064	0,3	1,554	4,613983	0,2058174	4,415076
Filtr próżni 1 [mBar]	32,620	72,08	52,22	72,60819	100,9368	195,8961
Grubość piętki układu wlewowego [mm]	0,714	3,553	9,953	2,369938	5,170498	34,2345
Koncentrat [%]	4,500	3,7	1,617	24,48873	6,0	9,799401
Ciśnienie maksymalne [Bar]	3,489	42,2	25	3,040971	48,7659	79,66612
Prędkość wtrysku maksymalna [m/s]	4,450	12,58	5,436	1,728593	7,707207	10,40386
Opóźnienie multiplikacji [ms]	3,138	0,126	2,916	14,98601	0,0037998	7,568358
Stała temperatura chłodzenia płyty [°C]	33,700	20,5	14,89	4,124605	37,21833	52,54113
Poziom stopu w piecu podgrzewczym [mm]	1,304	3,4	6,0	1,2	24,68	25,24205
Poziom wody w strumieniu chłodzącym [mm]	0,942	0,847	3,763	3,898408	0,4041015	9,051005
Czas drugiej fazy wtrysku [ms]	11,280	33,57	16,44	11,16913	33,9	48,23874
Profil próżni 1 [mBar]	1,661	0,141	9,856	15,1382	4,288953	37,45051
Profil próżni 2 [mBar]	74,340	19,88	6,952	89,9513	15,16766	16,12079
Przepływ chłodzenia tłoka [l]	9,790	5,898	21,5	9,684083	3,5552	56,57148
Przepływ w obwodzie chłodzenia 1 [l]	9,504	15,07	8,75	1,432417	13,10193	20,4231
Przepływ w obwodzie chłodzenia 13 [l]	6,015	41,61	44,86	4,098338	34,01835	131,3819
Przepływ w obwodzie chłodzenia 14 [l]	5,198	25,02	1331	5,914369	24,67757	43,65313
Przepływ w obwodzie chłodzenia 15 [l]	12,940	29,15	12	59,37741	35,87096	43,75868
Przepływ w obwodzie chłodzenia 17 [l]	31,580	68	42,83	79,53131	85,84159	140,3223
Przepływ w obwodzie chłodzenia 20 [l]	3,195	17,14	12,72	5,083908	11,09865	34,80311
Przepływ w obwodzie chłodzenia 6 [l]	15,130	1,0009	15,35	56,7365	0,4951261	45,45323
Prędkość we wlewach doprowadzających [m/s]	4,458	10,61	4,55	3,04	10,17	12,34303
Suw pierwszej fazy wtrysku [mm]	2,107	0,518	1,034	7,498708	0,075557	2,128033
Suw docisku po multiplikacji [mm]	34,430	91,39	35,91	126,8225	79,92223	95,23034
Temperatura chłodzenia tłoka [°C]	4,290	26,52	17,86	35,37423	9,825939	52,24249
Temperatura stopu [°C]	9,200	20,61	12	35,68286	22,4	38,67883
Temperatura termoregulatora 2.1 [°C]	0,173	0,6	5,357	3,227588	0,5213332	15,25381

Temperatura termoregulatora 2.2 [°C]	1,868	2,503	1,013	1,796084	2,039413	3,036168
Temperatura termoregulatora 3.2 [°C]	0,331	0,048	0,026	7,393445	0,000276	0,0133996
Temperatura tulei 1 [°C]	0,826	2,767	1,249	0,2867274	2,748014	3,892204
Temperatura tulei 2 [°C]	0,589	1,823	1,736	7,040981	0,1327934	4,254394
Temperatura tulei 3 [°C]	0,477	5,138	1,853	0,5497702	5,826163	5,840768
Temperatura tulei 4 [°C]	0,415	0,696	0,754	0,4521204	1,60078	1,998403
Temperatura w obwodzie chłodzenia 1 [°C]	27,830	14,04	8,021	60,53845	3,285278	16,79737
Temperatura w obwodzie chłodzenia 13 [°C]	0,749	10,94	8,546	3,433127	8,105081	33,33861
Temperatura w obwodzie chłodzenia 14 [°C]	1,827	5,5	2,075	8,232704	6,951086	7,717977
Temperatura w obwodzie chłodzenia 15 [°C]	12,180	2,521	3,785	68,15709	0,1281029	8,523747
Temperatura w obwodzie chłodzenia 17 [°C]	48,800	0,007	10,56	45,97528	2,018874	32,01247
Temperatura w obwodzie chłodzenia 7 [°C]	15,440	3,289	5,127	38,04194	9,027694	21,36187
Temperatura wody miejskiej [°C]	0,336	19,16	9,049	6,869579	21,50064	32,65863
Temperatura wody w instalacji [°C]	0,639	0,114	0,191	0,6052891	0,4954719	1,322686
Wartość próżni 1 [mBar]	138,200	324,8	117,5	186,6402	289,5415	315,9075
Wartość próżni 2 [mBar]	22,150	25,92	10,82	66,5259	11,89618	13,05218
Zużycie smaru [l]	0,652	0,006	0,43	3,394667	0,0007725	0,7395983

Tab. 5.70.: Zestawienie obliczonych wartości p dla trzeciego zbioru danych do badań

Statystyka	p	p	p	p	p	p
Test	Jedno-czynnikowa ANOVA	ANOVA odwrócona przeciek 2CAT	ANOVA odwrócona przeciek 4CAT	Test Kruskala-Wallisa	Kruskal-Wallis odwrócony przeciek 2CAT	Kruskal-Wallis odwrócony przeciek 4CAT
Ciśnienie sprężonego powietrza [Bar]	0,181	0,396	0,119	0,0815	0,396	0,1191
Ciśnienie wody miejskiej [Bar]	0,734	0,139	0,495	0,426	0,1394	0,4953
Ciśnienie wody obiegowej [Bar]	0,002	0,00043	0,005	0,0188	0,0004	0,0045
Czas pierwszej fazy wtrysku [ms]	0,00001	0,00003	0,00002	0,000001	0,000001	0,000001
Czas chłodzenia obwodu 1 [s]	0,357	0,948	0,661	0,7718	0,9496	0,6615
Czas cyklu [s]	0,000001	0,000001	0,000001	0,000001	0,8292	0,000001
Czas cyklu smarowania [s]	0,001	0,000001	0,000001	0,000001	0,1556	0,0002

Czas dozowania stopu [s]	0,00001	0,000001	0,000001	0,000001	0,0045	0,0414
Czas dozowania stopu 2 [s]	0,00001	0,00032	0,001	0,000001	0,0263	0,000001
Czas krzepnięcia t2 [s]	0,00001	0,000001	0,00001	0,0612	0,000001	0,000001
Czas przedmuchu [s]	0,001	0,0002	0,00011	0,000001	0,9866	0,6329
Czas smarowania [s]	0,141	0,013	0,000001	0,000001	0,5237	0,0101
Dzienny numer wtrysku [j.]	0,363	0,584	0,198	0,2023	0,6501	0,22
Filtr próżni 1 [mBar]	0,000001	0,000001	0,000001	0,000001	0,000001	0,000001
Grubość piętki układu wlewowego [mm]	0,49	0,059	0,000001	0,3058	0,023	0,000001
Koncentrat [%]	0,011	0,054	0,183	0,000001	0,0141	0,0204
Ciśnienie maksymalne [Bar]	0,031	0,000001	0,000001	0,2186	0,000001	0,000001
Prędkość wtrysku maksymalna [m/s]	0,035	0,00038	0,001	0,1886	0,0055	0,0154
Opóźnienie multiplikacji [ms]	0,043	0,723	0,033	0,0006	0,9508	0,0558
Stała temperatura chłodzenia płyty [°C]	0,000001	0,00001	0,000001	0,0423	0,000001	0,000001
Poziom stopu w piecu podgrzewczym [mm]	0,253	0,064	0,00046	0,2636	0,000001	0,000001
Poziom wody w strumieniu chłodzącym [mm]	0,39	0,357	0,01	0,1424	0,525	0,0286
Czas drugiej fazy wtrysku [ms]	0,000001	0,000001	0,000001	0,0038	0,000001	0,000001
Profil próżni 1 [mBar]	0,19	0,707	0,000001	0,0005	0,0384	0,000001
Profil próżni 2 [mBar]	0,000001	0,00001	0,00011	0,000001	0,0001	0,0011
Przepływ chłodzenia tłoka [l]	0,000001	0,015	0,000001	0,0079	0,0594	0,000001
Przepływ w obwodzie chłodzenia 1 [l]	0,00001	0,0001	0,00001	0,4886	0,0003	0,0001
Przepływ w obwodzie chłodzenia 13 [l]	0,000001	0,000001	0,000001	0,251	0,000001	0,000001
Przepływ w obwodzie chłodzenia 14 [l]	0,001	0,000001	0,000001	0,1159	0,000001	0,000001
Przepływ w obwodzie chłodzenia 15 [l]	0,000001	0,000001	0,000001	0,000001	0,000001	0,000001
Przepływ w obwodzie chłodzenia 17 [l]	0,000001	0,000001	0,000001	0,000001	0,000001	0,000001
Przepływ w obwodzie chłodzenia 20 [l]	0,041	0,00004	0,000001	0,0787	0,0009	0,000001
Przepływ w obwodzie chłodzenia 6 [l]	0,000001	0,315	0,000001	0,000001	0,4817	0,000001
Prędkość we wlewach doprowadzających [m/s]	0,01	0,00	0,003	0,22	0,00	0,0063
Suw pierwszej fazy wtrysku [mm]	0,077	0,472	0,376	0,1118	0,7834	0,5463
Suw docisku po multiplikacji [mm]	0,00001	0,000001	0,000001	0,000001	0,000001	0,000001
Temperatura chłodzenia tłoka [°C]	0,014	0,000001	0,000001	0,000001	0,0017	0,000001
Temperatura stopu [°C]	0,0001	0,00001	0,000001	0,000001	0,000001	0,000001
Temperatura termoregulatora 2.1 [°C]	0,841	0,438	0,001	0,1991	0,4703	0,0016

Temperatura termoregulatora 2.2 [°C]	0,155	0,114	0,386	0,4074	0,1533	0,3861
Temperatura termoregulatora 3.2 [°C]	0,718	0,826	0,994	0,0248	0,9867	0,9996
Temperatura tulei 1 [°C]	0,438	0,096	0,29	0,8664	0,0974	0,2733
Temperatura tulei 2 [°C]	0,555	0,177	0,157	0,0296	0,7156	0,2353
Temperatura tulei 3 [°C]	0,62	0,023	0,135	0,7597	0,0158	0,1196
Temperatura tulei 4 [°C]	0,66	0,404	0,52	0,7977	0,2058	0,5727
Temperatura w obwodzie chłodzenia 1 [°C]	0,00001	0,00018	0,00002	0,000001	0,0699	0,0008
Temperatura w obwodzie chłodzenia 13 [°C]	0,473	0,001	0,00001	0,1797	0,0044	0,000001
Temperatura w obwodzie chłodzenia 14 [°C]	0,14	0,019	0,101	0,0414	0,0084	0,0522
Temperatura w obwodzie chłodzenia 15 [°C]	0,000001	0,112	0,01	0,000001	0,7204	0,0363
Temperatura w obwodzie chłodzenia 17 [°C]	0,00001	0,932	0,000001	0,000001	0,1554	0,000001
Temperatura w obwodzie chłodzenia 7 [°C]	0,00001	0,07	0,002	0,000001	0,0027	0,0001
Temperatura wody miejskiej [°C]	0,715	0,00001	0,00001	0,0322	0,000001	0,000001
Temperatura wody w instalacji [°C]	0,528	0,736	0,903	0,7389	0,4815	0,7238
Wartość próżni 1 [mBar]	0,000001	0,000001	0,000001	0,000001	0,000001	0,000001
Wartość próżni 2 [mBar]	0,000001	0,000001	0,000001	0,000001	0,0006	0,0045
Zużycie smaru [l]	0,521	0,941	0,732	0,1832	0,9778	0,8639

Tab. 5.71.: Zestawienie obliczonych wartości statystyk F i H dla czwartego zbioru danych do badań

Statystyka	F	F	F	H	H	H
Test	Jedno-czynnikowa ANOVA	ANOVA odwrócona przeciek 2CAT	ANOVA odwrócona przeciek 4CAT	Test Kruskala-Wallisa	Kruskal-Wallis odwrócony przeciek 2CAT	Kruskal-Wallis odwrócony przeciek 4CAT
Ciśnienie sprężonego powietrza [Bar]	2,835	0,513	0,911	0,7834695	0,5143386	2,736873
Ciśnienie wody miejskiej [Bar]	2,703	0,083	2,445	4,131474	0,1008617	7,056941
Ciśnienie wody obiegowej [Bar]	1,231	1,025	1,251	0,2488755	1,02457	3,734122
Czas pierwszej fazy wtrysku [ms]	1,509	0,041	0,89	5,941498	0,2378208	2,57805
Czas chłodzenia obwodu 1 [s]		3,029	2,33		2,985783	6,737961
Czas cyklu [s]	0,73	1,43	0,815	2,431958	8,592792	10,96887

Czas cyklu smarowania [s]	0,049	3,059	1,263	5,079406	1,638048	0,9294497
Czas dozowania stopu [s]	0,45	0,349	0,468	0,1140645	3,519712	0,8183
Czas dozowania stopu 2 [s]	0,088	0,717	0,286	0,1258939	9,275664	11,26972
Czas krzepnięcia t2 [s]	0,976	36,27	14,9	19,8626	28,93154	34,37872
Czas przedmuchu [s]	0,3	6,1	3,2	5,6	3,651647	6,745543
Czas smarowania [s]	0,328	8,881	3,36	7,58	10,52336	13,75958
Dzienny numer wtrysku [j.]	0,597	0,209	0,281	2,828394	0,6570805	0,7504256
Filtr próżni 1 [mBar]	0,681	3,949	1,225	0,0531426	6,613457	5,066672
Grubość piętki układu wlewowego [mm]	6,463	0,032	3,201	0,5848068	0,3825535	9,568175
Koncentrat [%]	1,659	3,637	0,6	0,2	1,33476	0,3838552
Ciśnienie maksymalne [Bar]	2,593	4,205	1,412	2,746324	5,574682	4,424322
Prędkość wtrysku maksymalna [m/s]	0,907	4,475	1,376	2,271017	4,034266	4,500321
Opóźnienie multiplikacji [ms]	0,861	4,319	0,409	2,616167	3,876444	1,523556
Stała temperatura chłodzenia płyty [°C]	1,769	35,47	20,19	10,55792	24,71666	40,73381
Poziom stopu w piecu podgrzewczym [mm]	1,178	0,631	0,3	5,2	1,944674	8,018786
Poziom wody w strumieniu chłodzącym [mm]	2,744	0,63	1,162	0,1446646	0,109834	3,654135
Czas drugiej fazy wtrysku [ms]	1,015	0,214	0,427	1,124651	0,2	1,615829
Profil próżni 1 [mBar]	0,542	2,197	1,544	1,971772	2,327164	5,303965
Profil próżni 2 [mBar]	1,362	6,114	1,005	5,380679	0,4700874	0,3815033
Przepływ chłodzenia tloka [l]	1,047	26,93	7,679	13,18748	22,39177	18,13231
Przepływ w obwodzie chłodzenia 1 [l]	1,416	33,95	13,63	20,7326	26,44215	32,85413
Przepływ w obwodzie chłodzenia 13 [l]	0,157	24,88	4,676	13,7629	19,91644	10,77292
Przepływ w obwodzie chłodzenia 14 [l]	2,666	19,19	9,4	9,297263	18,33402	26,02779
Przepływ w obwodzie chłodzenia 15 [l]	1,282	6,774	3,203	20,57073	4,313219	6,993207
Przepływ w obwodzie chłodzenia 17 [l]	0,745	34,66	13,65	12,33015	30,11878	34,85915
Przepływ w obwodzie chłodzenia 20 [l]	0,762	16,28	3,934	9,532445	15,57798	10,68363
Przepływ w obwodzie chłodzenia 6 [l]	2,603	0,225	0,369	0,0679111	0,0054715	1,036343
Prędkość we wlewach doprowadzających [m/s]	0,571	0,91	0,424	2,489704	1,09	1,205155
Suw pierwszej fazy wtrysku [mm]	0,188	0,096	1,651	3,696941	0,430523	5,146186
Suw docisku po multiplikacji [mm]	1,645	0,49	0,246	1,605582	0,0078638	1,379362

<i>Temperatura chłodzenia tłoka [°C]</i>	0,031	2,914	2,624	1,806434	4,013728	7,005448
<i>Temperatura stopu [°C]</i>	4,413	0,033	0,261	3,105787	0,0604788	1,611166
<i>Temperatura termoregulatora 2.1 [°C]</i>	1,719	0,261	1,699	3,501986	0,4605649	5,588622
<i>Temperatura termoregulatora 2.2 [°C]</i>	0,05	3,023	0,746	1,843853	3,570362	2,645593
<i>Temperatura termoregulatora 3.2 [°C]</i>	0,015	1,155	1,427	1,283173	1,071238	3,539155
<i>Temperatura tulei 1 [°C]</i>	0,775	0,214	1,542	2,59253	0,2149453	3,393007
<i>Temperatura tulei 2 [°C]</i>	0,583	19,98	5,572	9,924865	18,14212	14,71034
<i>Temperatura tulei 3 [°C]</i>	1,758	0,157	1,346	1,153863	0,3824963	3,918823
<i>Temperatura tulei 4 [°C]</i>	0,457	2,867	1,721	1,531314	3,020584	5,279776
<i>Temperatura w obwodzie chłodzenia 1 [°C]</i>	0,102	8,428	3,25	1,229165	15,89497	21,6158
<i>Temperatura w obwodzie chłodzenia 13 [°C]</i>	0,723	1,84	0,238	0,6815788	1,495767	0,4238257
<i>Temperatura w obwodzie chłodzenia 14 [°C]</i>	0,86	1,689	1,494	5,087061	2,300353	5,269863
<i>Temperatura w obwodzie chłodzenia 15 [°C]</i>	0,349	2,426	0,308	5,481624	2,554608	0,8584278
<i>Temperatura w obwodzie chłodzenia 17 [°C]</i>	0,808	0,748	0,864	6,272395	0,2117827	1,449913
<i>Temperatura w obwodzie chłodzenia 7 [°C]</i>	0,378	4,945	3,306	5,838863	5,333607	10,71481
<i>Temperatura wody miejskiej [°C]</i>	1,184	0,618	0,863	1,998355	0,7004746	4,668569
<i>Temperatura wody w instalacji [°C]</i>	1,867	0,337	2,758	0,0954355	0,2245267	9,05284
<i>Wartość próżni 1 [mBar]</i>	0,79	5,491	5,25	11,98752	5,793035	13,90497
<i>Wartość próżni 2 [mBar]</i>	0,658	12,55	2,857	8,174704	30,02427	13,02437
<i>Zużycie smaru [l]</i>	1,178	0,629	1,326	2,2206	0,774092	4,352095

Tab. 5.72.: Zestawienie obliczonych wartości p dla czwartego zbioru danych do badań

Statystyka	p	p	p	p	p	p
Test	Jedno- czynnikowa ANOVA	ANOVA odwrócona przeciek 2CAT	ANOVA odwrócona przeciek 4CAT	Test Kruskala- Wallisa	Kruskal- Wallis odwrócony przeciek 2CAT	Kruskal- Wallis odwrócony przeciek 4CAT
<i>Ciśnienie sprężonego powietrza [Bar]</i>	0,094	0,475	0,438	0,3761	0,4733	0,434
<i>Ciśnienie wody miejskiej [Bar]</i>	0,071	0,774	0,067	0,1267	0,7508	0,0701
<i>Ciśnienie wody obiegowej [Bar]</i>	0,269	0,313	0,294	0,6179	0,3114	0,2916

Czas pierwszej fazy wtrysku [ms]	0,225	0,839	0,448	0,0513	0,6258	0,4614
Czas chłodzenia obwodu 1 [s]		0,084	0,078		0,084	0,0807
Czas cyklu [s]	0,394	0,234	0,488	0,1189	0,0034	0,0119
Czas cyklu smarowania [s]	0,825	0,083	0,29	0,0242	0,2006	0,8183
Czas dozowania stopu [s]	0,503	0,556	0,705	0,7356	0,0606	0,9055
Czas dozowania stopu 2 [s]	0,916	0,399	0,835	0,939	0,0023	0,0104
Czas krzepnięcia t2 [s]	0,325	0,000001	0,000001	0,000001	0,000001	0,000001
Czas przedmuchu [s]	0,57	0,015	0,024	0,0179	0,056	0,0805
Czas smarowania [s]	0,568	0,003	0,021	0,0059	0,0012	0,0033
Dzienny numer wtrysku [j.]	0,552	0,648	0,839	0,2431	0,4176	0,8613
Filtr próżni 1 [mBar]	0,508	0,049	0,303	0,9738	0,0101	0,167
Grubość piętki układu wlewowego [mm]	0,012	0,859	0,025	0,4444	0,5362	0,0226
Koncentrat [%]	0,2	0,059	0,588	0,6639	0,248	0,9436
Ciśnienie maksymalne [Bar]	0,078	0,042	0,242	0,2533	0,0182	0,2191
Prędkość wtrysku maksymalna [m/s]	0,406	0,036	0,253	0,3213	0,0446	0,2123
Opóźnienie multiplikacji [ms]	0,425	0,04	0,747	0,2703	0,049	0,6768
Stała temperatura chłodzenia płyty [°C]	0,186	0,000001	0,000001	0,0012	0,000001	0,000001
Poziom stopu w piecu podgrzewczym [mm]	0,28	0,428	0,849	0,023	0,1632	0,0456
Poziom wody w strumieniu chłodzącym [mm]	0,1	0,429	0,327	0,7037	0,7403	0,3013
Czas drugiej fazy wtrysku [ms]	0,365	0,645	0,734	0,5699	0,669	0,6558
Profil próżni 1 [mBar]	0,463	0,141	0,206	0,1603	0,1271	0,1508
Profil próżni 2 [mBar]	0,245	0,015	0,393	0,0204	0,4929	0,944
Przepływ chłodzenia tłoka [l]	0,308	0,000001	0,00009	0,0003	0,000001	0,0004
Przepływ w obwodzie chłodzenia 1 [l]	0,246	0,000001	0,000001	0,000001	0,000001	0,000001
Przepływ w obwodzie chłodzenia 13 [l]	0,855	0,000001	0,004	0,001	0,000001	0,013
Przepływ w obwodzie chłodzenia 14 [l]	0,073	0,00002	0,00001	0,0096	0,000001	0,000001
Przepływ w obwodzie chłodzenia 15 [l]	0,283	0,01	0,025	0,0001	0,0378	0,0721
Przepływ w obwodzie chłodzenia 17 [l]	0,477	0,000001	0,000001	0,0021	0,000001	0,000001
Przepływ w obwodzie chłodzenia 20 [l]	0,469	0,00009	0,01	0,0085	0,0001	0,0136
Przepływ w obwodzie chłodzenia 6 [l]	0,109	0,636	0,776	0,7944	0,941	0,7925
Prędkość we wlewach	0,566	0,342	0,736	0,288	0,2973	0,7518

<i>doprowadzających [m/s]</i>						
<i>Suw pierwszej fazy wtrysku [mm]</i>	0,829	0,758	0,181	0,1575	0,5117	0,1614
<i>Suw docisku po multiplikacji [mm]</i>	0,182	0,825	0,864	0,6581	0,9293	0,7104
<i>Temperatura chłodzenia tłoka [°C]</i>	0,969	0,09	0,053	0,4053	0,0451	0,0717
<i>Temperatura stopu [°C]</i>	0,037	0,857	0,853	0,078	0,8057	0,6569
<i>Temperatura termoregulatora 2.1 [°C]</i>	0,183	0,61	0,17	0,1736	0,4974	0,1334
<i>Temperatura termoregulatora 2.2 [°C]</i>	0,824	0,084	0,526	0,1745	0,0588	0,4496
<i>Temperatura termoregulatora 3.2 [°C]</i>	0,902	0,284	0,238	0,2573	0,3007	0,3157
<i>Temperatura tulei 1 [°C]</i>	0,463	0,644	0,206	0,2736	0,6429	0,3349
<i>Temperatura tulei 2 [°C]</i>	0,56	0,000001	0,001	0,007	0,000001	0,0021
<i>Temperatura tulei 3 [°C]</i>	0,176	0,693	0,262	0,5616	0,5363	0,2704
<i>Temperatura tulei 4 [°C]</i>	0,634	0,093	0,166	0,465	0,0822	0,1524
<i>Temperatura w obwodzie chłodzenia 1 [°C]</i>	0,903	0,004	0,024	0,5409	0,0001	0,0001
<i>Temperatura w obwodzie chłodzenia 13 [°C]</i>	0,487	0,177	0,87	0,7112	0,2213	0,9353
<i>Temperatura w obwodzie chłodzenia 14 [°C]</i>	0,463	0,196	0,219	0,1655	0,1293	0,1531
<i>Temperatura w obwodzie chłodzenia 15 [°C]</i>	0,706	0,122	0,82	0,0645	0,11	0,8354
<i>Temperatura w obwodzie chłodzenia 17 [°C]</i>	0,448	0,3889	0,461	0,0434	0,6454	0,6939
<i>Temperatura w obwodzie chłodzenia 7 [°C]</i>	0,769	0,028	0,022	0,1197	0,0209	0,0134
<i>Temperatura wody miejskiej [°C]</i>	0,309	0,433	0,462	0,3682	0,7004746	0,1977
<i>Temperatura wody w instalacji [°C]</i>	0,174	0,563	0,045	0,7574	0,6356	0,0286
<i>Wartość próżni 1 [mBar]</i>	0,456	0,021	0,002	0,0025	0,0161	0,003
<i>Wartość próżni 2 [mBar]</i>	0,519	0,001	0,039	0,0168	0,000001	0,0046
<i>Zużycie smaru [l]</i>	0,28	0,429	0,269	0,1362	0,379	0,2259

Tab. 5.73.: Zestawienie obliczonych wartości statystyk F i H dla piątego zbioru danych do badań

Statystyka	F	F	F	H	H	H
Test	Jedno- czynnikowa ANOVA	ANOVA odwrócona przeciek 2CAT	ANOVA odwrócona przeciek 4CAT	Test Kruskala- Wallisa	Kruskal- Wallis odwrócony przeciek 2CAT	Kruskal- Wallis odwrócony przeciek 4CAT
Ciśnienie sprężonego powietrza [Bar]	0,944	0,911	0,924	0,0503866	0,9118342	2,777024
Ciśnienie wody miejskiej [Bar]	1,626	0,294	2,023	0,0890776	0,2943874	5,956018
Ciśnienie wody obiegowej [Bar]	0,543	2,32	1,395	0,5504266	2,298224	4,148285
Czas pierwszej fazy wtrysku [ms]	1,0009	0,004	0,873	4,079714	0,0478864	2,384806
Czas chłodzenia obwodu 1 [s]		0	2,246		6,57E-16	6,561827
Czas cyklu [s]	0,655	0,169	0,398	2,963108	5,928097	9,758347
Czas cyklu smarowania [s]	0,001	4,826	1,769	2,783583	0,7801886	0,6004655
Czas dozowania stopu [s]	0,32	2,075	0,307	0,0901136	3,581989	0,5703893
Czas dozowania stopu 2 [s]	0,775	0,821	0,348	3,672993	6,490876	9,835997
Czas krzepnięcia t2 [s]	2,235	10,09	8,844	5,452594	9,469302	22,69118
Czas przedmuchu [s]	0,2	3,5	2,6	3,3	1,369927	4,757867
Czas smarowania [s]	0,086	3,10	1,87	2,73	5,410804	9,245659
Dzienny numer wtrysku [j.]	0,839	2,055	0,605	2,573865	2,641864	1,709794
Filtr próżni 1 [mBar]	0,901	0,788	1,394	0,8693439	2,849304	4,986875
Grubość piętki układu wlewowego [mm]	3,97	1,488	2,533	0,0354207	2,504638	7,950731
Koncentrat [%]	1,404	2,6	0,5	0,7	1,516144	0,4460746
Ciśnienie maksymalne [Bar]	4,816	6,994	1,386	6,009481	7,520637	4,442243
Prędkość wtrysku maksymalna [m/s]	0,922	3,704	1,329	0,8477555	3,635032	4,319043
Opóźnienie multiplikacji [ms]	0,453	5,611	0,38	1,26139	5,158934	1,58911
Stała temperatura chłodzenia płyty [°C]	3,399	14,78	13,5	2,350087	11,37724	31,95404
Poziom stopu w piecu podgrzewczym [mm]	0,617	6,6	1,1	2,8	1,585974	7,104122
Poziom wody w strumieniu chłodzącym [mm]	1,143	7,864	1,8	0,1044068	5,636161	4,898486
Czas drugiej fazy wtrysku [ms]	0,57	2,308	0,161	1,274115	2,3	0,6223239
Profil próżni 1 [mBar]	0,143	4,818	1,748	5,847654	2,977529	5,166851
Profil próżni 2 [mBar]	0,284	12,77	1,558	5,655811	2,800459	0,4166995

Przepływ chłodzenia tłoka [l]	0,097	23,36	8,704	3,990963	20,55694	19,21435
Przepływ w obwodzie chłodzenia 1 [l]	2,919	20,78	10,68	7,467028	18,4824	26,65535
Przepływ w obwodzie chłodzenia 13 [l]	0,092	17,21	4,474	9,212144	14,66517	9,770117
Przepływ w obwodzie chłodzenia 14 [l]	2,215	18,06	7,756	5,633901	16,52528	22,22218
Przepływ w obwodzie chłodzenia 15 [l]	0,93	2,535	1,948	12,37044	1,609391	4,488112
Przepływ w obwodzie chłodzenia 17 [l]	1,261	12,08	9,734	6,621948	12,32556	27,86023
Przepływ w obwodzie chłodzenia 20 [l]	1,094	3,874	2,963	1,457155	4,968896	8,435272
Przepływ w obwodzie chłodzenia 6 [l]	3,427	0,623	0,483	0,2866773	0,3784252	1,667609
Prędkość we wlewach doprowadzających [m/s]	1,815	2,993	0,688	4,157246	4,11	2,181754
Suw pierwszej fazy wtrysku [mm]	0,534	0,136	1,082	0,4914757	0,0956472	3,358416
Suw docisku po multiplikacji [mm]	0,303	2,602	0,241	3,246834	2,773835	1,328445
Temperatura chłodzenia tłoka [°C]	0,037	4,36	3,053	2,281547	4,101859	7,333137
Temperatura stopu [°C]	5,362	0,002	0,296	3,272292	0,0022977	1,56048
Temperatura termoregulatora 2.1 [°C]	1,097	0,29	1,645	2,981599	0,5149762	5,304476
Temperatura termoregulatora 2.2 [°C]	0,353	0,595	0,351	0,3588352	0,5922079	1,571942
Temperatura termoregulatora 3.2 [°C]	0,37	0,681	1,396	0,0121608	0,737045	3,373475
Temperatura tulei 1 [°C]	0,913	0,007	1,738	2,997863	0,0369491	3,332422
Temperatura tulei 2 [°C]	0,735	15,05	4,578	7,178407	13,50697	11,83992
Temperatura tulei 3 [°C]	0,875	0,297	1,241	0,8708797	0,6531865	3,779984
Temperatura tulei 4 [°C]	0,763	2,47	1,803	4,652167	3,385899	5,718656
Temperatura w obwodzie chłodzenia 1 [°C]	0,435	9,532	3,749	4,552694	12,77461	21,3636
Temperatura w obwodzie chłodzenia 13 [°C]	0,287	0,224	0,293	0,0930829	0,1108883	0,8945695
Temperatura w obwodzie chłodzenia 14 [°C]	0,442	5,771	2,177	10,23894	6,62236	7,039525
Temperatura w obwodzie chłodzenia 15 [°C]	0,679	0,127	0,191	0,1979463	0,0009502	0,0642518

Temperatura w obwodzie chłodzenia 17 [°C]	1,29	0,014	0,495	2,660881	0,00007167	0,8022779
Temperatura w obwodzie chłodzenia 7 [°C]	0,685	1,752	2,554	3,938162	1,806585	8,342331
Temperatura wody miejskiej [°C]	2,015	0,003	0,907	0,0575995	0,0248817	4,757703
Temperatura wody w instalacji [°C]	0,793	1,733	3,237	0,6639769	1,622968	10,47092
Wartość próżni 1 [mBar]	0,792	2,622	5,367	5,072948	2,176712	13,08863
Wartość próżni 2 [mBar]	0,842	16,33	3,095	16,34794	35,55467	15,17886
Zużycie smaru [l]	2,592	3,124	1,894	4,441699	3,967396	5,712921

Tab. 5.74.: Zestawienie obliczonych wartości p dla piątego zbioru danych do badań

Statystyka	p	p	p	p	p	p
Test	Jedno- czynnikiowa ANOVA	ANOVA odwrócona przeciek 2CAT	ANOVA odwrócona przeciek 4CAT	Test Kruskala- Wallisa	Kruskal- Wallis odwrócony przeciek 2CAT	Kruskal- Wallis odwrócony przeciek 4CAT
Ciśnienie sprężonego powietrza [Bar]	0,333	0,341	0,431	0,8224	0,3396	0,4273
Ciśnienie wody miejskiej [Bar]	0,2	0,588	0,114	0,9564	0,5874	0,1138
Ciśnienie wody obiegowej [Bar]	0,462	0,13	0,247	0,4581	0,1295	0,2459
Czas pierwszej fazy wtrysku [ms]	0,367	0,948	0,457	0,13	0,8268	0,4965
Czas chłodzenia obwodu 1 [s]		1	0,086		1	0,0873
Czas cyklu [s]	0,42	0,682	0,755	0,0852	0,0149	0,0207
Czas cyklu smarowania [s]	0,982	0,03	0,156	0,0952	0,3771	0,8963
Czas dozowania stopu [s]	0,573	0,154	0,82	0,764	0,0584	0,9032
Czas dozowania stopu 2 [s]	0,462	0,366	0,791	0,1594	0,0108	0,02
Czas krzepnięcia t2 [s]	0,137	0,002	0,00002	0,0195	0,0021	0,000001
Czas przedmuchu [s]	0,633	0,065	0,055	0,0712	0,2418	0,1904
Czas smarowania [s]	0,77	0,08	0,138	0,0983	0,02	0,0262
Dzienny numer wtrysku [j.]	0,435	0,154	0,613	0,2761	0,1041	0,6348
Filtr próżni 1 [mBar]	0,408	0,376	0,247	0,6475	0,0914	0,1728
Grubość piętki układu wlewowego [mm]	0,048	0,225	0,06	0,8507	0,1135	0,047
Koncentrat [%]	0,238	0,106	0,672	0,407	0,2182	0,9306
Ciśnienie maksymalne [Bar]	0,011	0,009	0,25	0,0496	0,0061	0,2175
Prędkość wtrysku maksymalna [m/s]	0,4	0,056	0,268	0,6545	0,0566	0,229
Opóźnienie multiplikacji [ms]	0,637	0,019	0,768	0,5322	0,0231	0,6619
Stała temperatura chłodzenia płyty [°C]	0,067	0,00018	0,000001	0,1253	0,0007	0,000001

Poziom stopu w piecu podgrzewczym [mm]	0,433	0,011	0,336	0,0931	0,2079	0,0687
Poziom wody w strumieniu chłodzącym [mm]	0,287	0,006	0,15	0,7466	0,0176	0,1794
Czas drugiej fazy wtrysku [ms]	0,567	0,131	0,923	0,5288	0,1315	0,8913
Profil próżni 1 [mBar]	0,706	0,03	0,16	0,0156	0,0844	0,16
Profil próżni 2 [mBar]	0,595	0,00049	0,203	0,0174	0,0942	0,9368
Przepływ chłodzenia tłoka [l]	0,756	0,000001	0,00003	0,0457	0,000001	0,0002
Przepływ w obwodzie chłodzenia 1 [l]	0,09	0,00001	0,000001	0,0063	0,000001	0,000001
Przepływ w obwodzie chłodzenia 13 [l]	0,913	0,00006	0,005	0,01	0,0001	0,0206
Przepływ w obwodzie chłodzenia 14 [l]	0,113	0,00004	0,00008	0,0598	0,000001	0,0001
Przepływ w obwodzie chłodzenia 15 [l]	0,428	0,114	0,125	0,0062	0,2046	0,2134
Przepływ w obwodzie chłodzenia 17 [l]	0,287	0,001	0,00001	0,0365	0,0004	0,000001
Przepływ w obwodzie chłodzenia 20 [l]	0,338	0,051	0,034	0,4826	0,0258	0,0378
Przepływ w obwodzie chłodzenia 6 [l]	0,066	0,431	0,695	0,5924	0,5384	0,6442
Prędkość we wlewach doprowadzających [m/s]	0,167	0,086	0,561	0,1251	0,0427	0,5356
Suw pierwszej fazy wtrysku [mm]	0,587	0,713	0,359	0,7821	0,7571	0,3396
Suw docisku po multiplikacji [mm]	0,823	0,109	0,868	0,3551	0,0958	0,7224
Temperatura chłodzenia tłoka [°C]	0,963	0,039	0,031	0,3196	0,0428	0,062
Temperatura stopu [°C]	0,022	0,968	0,828	0,0705	0,9618	0,6684
Temperatura termoregulatora 2.1 [°C]	0,337	0,591	0,182	0,2252	0,473	0,1508
Temperatura termoregulatora 2.2 [°C]	0,554	0,442	0,789	0,5492	0,4416	0,6658
Temperatura termoregulatora 3.2 [°C]	0,792	0,411	0,247	0,9122	0,3906	0,3375
Temperatura tulei 1 [°C]	0,404	0,936	0,162	0,2234	0,8476	0,3432
Temperatura tulei 2 [°C]	0,482	0,00016	0,004	0,0276	0,0002	0,008
Temperatura tulei 3 [°C]	0,419	0,587	0,297	0,647	0,419	0,2862
Temperatura tulei 4 [°C]	0,468	0,118	0,149	0,0977	0,0658	0,1261
Temperatura w obwodzie chłodzenia 1 [°C]	0,648	0,002	0,013	0,1027	0,0004	0,0001
Temperatura w obwodzie chłodzenia 13 [°C]	0,751	0,637	0,831	0,9545	0,7391	0,8267

Temperatura w obwodzie chłodzenia 14 [°C]	0,723	0,018	0,094	0,0166	0,0101	0,0707
Temperatura w obwodzie chłodzenia 15 [°C]	0,509	0,722	0,902	0,9058	0,9754	0,9958
Temperatura w obwodzie chłodzenia 17 [°C]	0,279	906	0,687	0,2644	0,9932	0,8489
Temperatura w obwodzie chłodzenia 7 [°C]	0,563	0,118	0,058	0,2682	0,1789	0,0394
Temperatura wody miejskiej [°C]	0,137	0,96	0,44	0,9716	0,8747	0,1904
Temperatura wody w instalacji [°C]	0,375	0,19	0,024	0,4152	0,2027	0,015
Wartość próżni 1 [mBar]	0,455	0,108	0,002	0,0791	0,1401	0,0044
Wartość próżni 2 [mBar]	0,433	0,00009	0,029	0,0003	0,000001	0,0017
Zużycie smaru [l]	0,11	0,079	0,134	0,0351	0,0464	0,1264


Wykonano więc 1680 obliczeń, gdyż utworzono 6 modeli dla pięciu zbiorów danych, zawierających 56 zmiennych. W wyniku uzyskano dwa parametry statystyczne: dla analizy ANOVA klasycznej i odwróconej była to statystyka F i p, a w przypadku testu Kruskala-Wallisa statystyka H i p. Następnie określono maksymalne i średnie wartości obliczonych statystyk F i H dla każdego wariantu analizy (tab.5.75.)

Tab. 5.75.: Zestawienie maksymalnych i średnich wartości statystyk F i H

Statystyka	Test	Zbiór	Max F lub H	Średnie F lub H
F	Jednoczynnikowa ANOVA	1	19,500	3,034
F	ANOVA odwrócona przeciek 2CAT	1	68,950	11,034
F	ANOVA odwrócona przeciek 4CAT	1	80,260	10,537
H	Test Kruskala-Wallisa	1	178,438	25,321
H	Kruskal-Wallis odwrócony przeciek 2CAT	1	43,569	9,005
H	Kruskal-Wallis odwrócony przeciek 4CAT	1	214,549	29,047
F	Jednoczynnikowa ANOVA	2	26,206	3,906
F	ANOVA odwrócona przeciek 2CAT	2	23,300	4,369
F	ANOVA odwrócona przeciek 4CAT	2	12,230	2,630
H	Test Kruskala-Wallisa	2	10,933	3,089
H	Kruskal-Wallis odwrócony przeciek 2CAT	2	17,984	3,550
H	Kruskal-Wallis odwrócony przeciek 4CAT	2	22,478	6,513
F	Jednoczynnikowa ANOVA	3	3441,000	73,547
F	ANOVA odwrócona przeciek 2CAT	3	324,800	21,544
F	ANOVA odwrócona przeciek 4CAT	3	1331,000	36,205
H	Test Kruskala-Wallisa	3	186,640	25,368
H	Kruskal-Wallis odwrócony przeciek 2CAT	3	289,542	18,968

H	Kruskal-Wallis odwrócony przeciek 4CAT	3	315,908	36,248
F	Jednoczynnikowa ANOVA	4	6,463	1,189
F	ANOVA odwrócona przeciek 2CAT	4	36,270	6,469
F	ANOVA odwrócona przeciek 4CAT	4	20,190	2,922
H	Test Kruskala-Wallisa	4	20,733	4,921
H	Kruskal-Wallis odwrócony przeciek 2CAT	4	30,119	6,394
H	Kruskal-Wallis odwrócony przeciek 4CAT	4	40,734	8,389
F	Jednoczynnikowa ANOVA	5	5,362	1,162
F	ANOVA odwrócona przeciek 2CAT	5	23,360	4,817
F	ANOVA odwrócona przeciek 4CAT	5	13,500	2,508
H	Test Kruskala-Wallisa	5	16,348	3,343
H	Kruskal-Wallis odwrócony przeciek 2CAT	5	35,555	4,888
H	Kruskal-Wallis odwrócony przeciek 4CAT	5	31,954	7,386

Następnie na podstawie obliczonych wyników dla każdego zbioru danych do badań utworzono trzy kryteria zmiennych wybierając te, dla których wartość p była mniejsza niż 0,05 (rys.5.2.3.5).



Rys.5.2.3.5. Kryterium wyboru statystycznie ważnych zmiennych, na podstawie testu Kruskala-Wallisa dla pierwszego zbioru danych

Podsumowując, zastosowano w pracy trzy kryteria istotności zmiennych wejściowych, nazwane dalej: kryterium K-W, gdyż w jego zakres wchodziły zmienne wyznaczone na podstawie testu Kruskala-Wallisa, kryterium odwróconego K-W, na podstawie testu Kruskala-Wallisa odwróconego dla *przecieku* podzielonego na 2 i 4 kategorie oraz kryterium ANOVA, obejmującego wyniki analizy ANOVA klasycznej jednoczynnikowej i odwróconej dla *przecieku* podzielonego na 2 i 4 kategorie.

Kolejnym krokiem przygotowania danych była identyfikacja danych silnie oraz bardzo silnie skorelowanych. Analiza ta jest bardzo ważnym punktem badań wielowymiarowych, ponieważ jest w stanie na podstawie wizualnej reprezentacji, umożliwić identyfikację wzajemnych korelacji między różnymi składnikami wektora losowego. Wykonano więc analizę współczynników korelacji liniowej Pearsona i nieparametrycznej Spearmana. Przykład otrzymanych wyników obliczeń zestawiono w tab.5.76..


Tab. 5.76.: Zestawienie wyników analizy korelacji dla zbioru piątego według kryterium K-W

Numer zmiennej	Zmienna	Korelacje (Dane do modelowania) Oznaczone wsp. korelacji są istotne z $p < ,05000$ N=140												
		1	2	3	4	5	6	7	8	9	10	11	12	13
1	Czas krzepnięcia t2 [s]	1,0	-0,1	0,1	-0,2	0,3	-0,6	0,1	0,5	-0,9	0,4	0,0	0,0	-0,1
2	Ciśnienie maksymalne [Bar]	-0,1	1,0	-0,1	-0,2	-0,4	0,3	-0,5	0,2	0,0	0,0	-0,1	-0,2	0,1
3	Profil próżni 1 [mBar]	0,1	-0,1	1,0	-0,5	-0,2	0,3	-0,2	-0,2	0,0	-0,1	-0,3	-0,6	0,0
4	Profil próżni 2 [mBar]	-0,2	-0,2	-0,5	1,0	0,4	-0,3	0,6	-0,1	0,0	0,0	0,3	0,8	0,0
5	Przepływ chłodzenia tłoka [l]	0,3	-0,4	-0,2	0,4	1,0	-0,5	0,7	0,1	-0,3	0,3	0,3	0,5	-0,2
6	Przepływ w obwodzie chłodzenia 1 [l]	-0,6	0,3	0,3	-0,3	-0,5	1,0	-0,4	-0,2	0,6	-0,3	-0,3	-0,4	0,1
7	Przepływ w obwodzie chłodzenia 13 [l]	0,1	-0,5	-0,2	0,6	0,7	-0,4	1,0	-0,1	-0,1	0,1	0,3	0,6	0,0
8	Przepływ w obwodzie chłodzenia 15 [l]	0,5	0,2	-0,2	-0,1	0,1	-0,2	-0,1	1,0	-0,4	0,4	-0,2	0,0	0,0
9	Przepływ w obwodzie chłodzenia 17 [l]	-0,9	0,0	0,0	0,0	-0,3	0,6	-0,1	-0,4	1,0	-0,3	-0,1	-0,1	0,0
10	Temperatura tulei 2 [°C]	0,4	0,0	-0,1	0,0	0,3	-0,3	0,1	0,4	-0,3	1,0	0,0	0,1	-0,1
11	Temperatura w obwodzie chłodzenia 14 [°C]	0,0	-0,1	-0,3	0,3	0,3	-0,3	0,3	-0,2	-0,1	0,0	1,0	0,3	0,1
12	Wartość próżni 2 [mBar]	0,0	-0,2	-0,6	0,8	0,5	-0,4	0,6	0,0	-0,1	0,1	0,3	1,0	0,1
13	Zużycie smaru [l]	-0,1	0,1	0,0	0,0	-0,2	0,1	0,0	0,0	0,0	-0,1	0,1	0,1	1,0


Tab. 5.77.: Interpretacja wysokości współczynnika korelacji

Wartość korelacji (wartość bezwzględna)	Interpretacja
0,0-0,3	Brak korelacji
0,3-0,5	Umiarkowanie skorelowane
0,5-0,7	Wysoko skorelowane
0,7-1,0	Bardzo wysoko skorelowane

Następnie wybrano wysoko i bardzo wysoko skorelowane zmienne ze wszystkich zbiorów danych ustalonych według trzech kryteriów i zredukowano ponownie zmienne zastępując dwie jedną ważniejszą z punktu widzenia wartości wyjściowej. W tym celu wykonano wykresy zależności zmiennych oraz obliczono kwadrat współczynnika korelacji Pearsona (rys.5.2.3.6.-rys.5.2.3.7.)




Rys.5.2.3.6. Wykres zależności zmiennych: *profil próżni 2* i *wartość próżni 2*, w piątym zbiorze, według kryterium K-W



Rys.5.2.3.7. Wykres zależności zmiennych: *czas krzepnięcia* i *przepływ w obwodzie chłodzenia 17*, w zbiorze piątym według kryterium K-W

W wyniku przeprowadzonej analizy wariancji i korelacji oraz podziału zbiorów według kryteriów zredukowano ilość parametrów opisujących proces do istotnych z punktu widzenia zmiennej zależnej (rys.5.2.3.8.).



Rys.5.2.3.8. Liczba zmiennych wejściowych w etapie redukcji wymiarowości danych

5.2.3.1. Wnioski

W wyniku przeprowadzonej redukcji wymiarowości danych, celem przygotowania ich do dalszego zaawansowanego modelowania, można z pewnością potwierdzić skuteczność i niezawodność zastosowanych metod. Należy zauważyć, iż przykładowo dla piątego zbioru danych liczba istotnych zmiennych została zredukowana, zoptymalizowana aż o 81% w odniesieniu do początkowej liczby zmiennych niezależnych.

Uzupełniając charakterystykę wspomnianej cechy danych przemysłowych jaką są korelacje pomiędzy parametrami procesu, których występowanie i rodzaje zostały zidentyfikowane przez współpracującą odlewnię i przedstawione między innymi na World Foundry Congress w Krakowie i potwierdzone w niniejszej pracy poprzez analizę współczynników korelacji dla wszystkich zmiennych wejściowych. Głównym wnioskiem pochodzącym z przeprowadzonej analizy korelacji była ilość bardzo wysoko i wysoko skorelowanych zmiennych niezależnych, których ilość wyniosła aż 25, co stanowi aż 44% ilości wszystkich parametrów procesu. Analiza korelacji doprowadziła nas do potwierdzenia występowania głównych rodzajów źródeł powstawania korelacji [149], czyli korelacje naturalne występujące pomiędzy wynikającymi z siebie parametrów procesu, na przykład pomiędzy temperaturą wody a jej przepływem. Tego typu korelację można zastąpić jedną zmienną, określoną jako ważniejszą z punktu widzenia

jakości produktu. Drugi typ korelacji, to korelacje celowe, będące zależne od czynnika ludzkiego. Tego typu korelacje należy wykluczyć z badanego zbioru danych. Dzieje się tak, dlatego, że wartości określonych zmiennych niezależnych mogą być celowo manipulowane przez personel obsługujący proces jako ich reakcja na odczyty wartości innych zmiennych lub na podstawie indywidualnego doświadczenia. Tego typu zmiany mogą prowadzić do lokalnych korelacji ze zmienną zależną. W wyniku model wejście-wyście danego procesu może z łatwością pokazać nieistniejące korelacje. Przeprowadzona analiza przyczyniła się do powstania wniosku, iż rzeczywiste relacje w badanych procesach mogą być przesłaniane przez sztucznie wprowadzone relacje lub przypadkowo wprowadzone zmiany, co wpłynie na efekt modelu pokazujący te relacje jako równie ważne. Praca nad identyfikacją takich zmiennych jest trudna, dlatego podzielono zbiory na pięć podzbiorów o różnych zakresach zmiennej wyjściowej. Ostatnie, to korelacje losowe mogące być spowodowane przez występowanie pewnych wartości w podobnym czasie, należy również ich unikać i koniecznie wykonać ich pogłębioną analizę.

Wnioski z analizy również potwierdziły skuteczność i niezawodność metod. Szczególną uwagę należy poświęcić analizie ANOVA, która wciąż stanowi nowoczesne i wciąż jeszcze mało rozpowszechnione narzędzie do stosowania w przemyśle. Pozwala ona m. in. na ocenę znaczenia zmiennych procesu (wejścia X) z punktu widzenia jego efektów (wyście Y), może być bardzo użytecznym narzędziem do wykrywania przyczyn powstawania wad w wyrobach [5]. Dobra znajomość analizy wariancji pozwala zrozumieć zmienność, która jest nieodłączną cechą niemal wszystkich procesów zachodzących w otaczającym nas świecie. Ponadto metoda ta jest podstawą wielu innych analiz statystycznych, do których przejdziemy w kolejnych rozdziałach niniejszej rozprawy.

5.2.4. Zaawansowane modelowanie oparte na danych metodą SSN

5.2.4.1. Metodyka i wyniki badań

Założeniem niniejszej rozprawy było opracowanie modelu będącego w stanie w jak najlepszy sposób przewidzieć powstawanie wady w produkcji, a więc przewidzieć wartość zmiennej wyjściowej, czyli *przecieku w obwodzie wysokiego ciśnienia*. Określono, że w tym przypadku zastosowanie metody Sztucznych Sieci Neuronowych (SSN), zdolnych do uwidoczniania ukrytych i złożonych zależności występujących w wyjątkowo skomplikowanych danych produkcyjnych jest uzasadnione. Założono, że istnieje taka sztuczna sieć neuronowa, która na podstawie przedstawionych wartości zmiennych wejściowych

opisujących proces potrafi skutecznie odwzorować dynamikę zmiany wartości zmiennej wyjściowej zachodzącej podczas tego procesu. Mając tak sprecyzowaną istotę problemu przystąpiono do projektowania architektury sztucznych sieci neuronowych. Analizując proces wytwarzania odlewów utworzono na podstawie wcześniej prezentowanych badań listę istotnych parametrów procesu, które zdefiniowano i użyto do niniejszego badania. Podsumowując wykonano identyfikację istoty problemu i określono listy zmiennych opisujących badany proces.

Następnie przygotowano wzorce uczące, testujące i walidacyjne na podstawie posiadanych zbiorów danych do badań, bazujących na rzeczywistych danych produkcyjnych. Analizę przeprowadzono w oparciu o specjalnie utworzoną i zaproponowaną metodykę. Opracowano dedykowane plany badań dla każdego z piętnastu zbiorów danych (pięć zbiorów ustalonych według trzech kryteriów) (tab.5.78-tab.5.89). Dla każdego z planowanych ustawień parametrów sieci, powtórzono obliczenia pięć razy zakładając 200 SSN i 200 zachowywanych, w wyniku stworzono 590 modeli neuronowych.

Kolejnym krokiem był wybór typu sieci. Podczas tego etapu rozpatrywano sieć CP, sieć Kohenena, sieć RBF, sieć GRNN i sieć MLP. Zdecydowano iż do niniejszej analizy zastosowany będzie perceptron wielowarstwowy (MLP), tworząc sieć jednokierunkową, posiadającą warstwę wejściową, wyjściową i co najmniej jedną warstwę ukrytą [47]. Uczenie perceptronu wielowarstwowego odbywało się poprzez przedstawienie zbiorów danych podzielonych w różnych proporcjach na zbiór uczący, testujący i walidacyjny. Zbiory zawierały zestawy wejść dla kolejnych obserwacji uczących i odpowiadające tym wejściom przykłady wyjść jakimi powinna odpowiedzieć modelowana sztuczna sieć neuronowa. Podczas badań bardzo ważnym punktem było wyspecyfikowanie zbioru testującego równego 0, 10, 15 lub 20%. Jednak często dla danych rzeczywistych pochodzących z odlewni pomija się w procesie uczenia sieci tworzenie zbiorów testowych i walidacyjnych (całkowicie niezależnych), gdyż dane rzeczywiste mogą posiadać braki i być niezerównoważone co wpływa na trudność wyboru takich zbiorów. Jednakże w prezentowanej pracy sprawdzono również jakość sieci dla modeli posiadających zbiory testujące i walidacyjne.

Kolejnym krokiem było określenie architektury sieci czyli liczby warstw, liczby neuronów w warstwach. Podczas tego kroku należało mieć na uwadze fakt, iż określenie odpowiedniej liczby neuronów ukrytych i warstw ukrytych jest swoistym wyzwaniem dla projektanta SSN. W niniejszej rozprawie liczby neuronów były niewielkie, aby nie dopuszczać do przeuczenia się modelu i wynosiły od 7 do 23 dla dużych zbiorów danych (czyli pierwszego i trzeciego) oraz od 2 do 5 dla małych zbiorów danych (czyli drugiego, czwartego i piątego). Stwierdzono,

że nie ma powodu tworzyć więcej niż jednej warstwy ukrytej, gdyż nie wpłynie to na zwiększenie jakości wyniku a jedynie skomplikuje model neuronowy. Ostatnim krokiem było uczenie sieci, podczas którego użyto funkcję aktywacji w warstwie ukrytej tangensoidalną i w warstwie wyjściowej funkcje tangensoidalną i liniową. Ocenę przyjętego rozwiązania, czyli działania SSN sprawdzano obliczając wartość RMSE - średniej kwadratowej błędów.

Tab. 5.78.: Plan badań pierwszego zbioru ustalonego według kryterium K-W

% wartości w zbiorze uczącym	% wartości w zbiorze testującym	% wartości w zbiorze walidacyjnym	Liczby neuronów ukrytych:	Funkcja aktywacji w warstwie ukrytej	Funkcja aktywacji na wyjściu
100	0	0	Losowo (wg sugestii Statistica)	tangensoidalna	liniowa
80	20	0	Losowo (wg sugestii Statistica)	tangensoidalna	liniowa
70	15	15	Losowo (wg sugestii Statistica)	tangensoidalna	liniowa
70	15	15	Losowo (wg sugestii Statistica)	tangensoidalna	liniowa
100	0	0	Losowo (wg sugestii Statistica)	tangensoidalna	tangensoidalna
80	20	0	Losowo (wg sugestii Statistica)	tangensoidalna	tangensoidalna
70	15	15	Losowo (wg sugestii Statistica)	tangensoidalna	tangensoidalna
70	15	15	Losowo (wg sugestii Statistica)	tangensoidalna	tangensoidalna

Tab. 5.79.: Plan badań drugiego zbioru ustalonego według kryterium K-W

% wartości w zbiorze uczącym	% wartości w zbiorze testującym	% wartości w zbiorze walidacyjnym	Liczby neuronów ukrytych:	Funkcja aktywacji w warstwie ukrytej	Funkcja aktywacji na wyjściu
100	0	0	2	tangensoidalna	liniowa
100	0	0	3	tangensoidalna	liniowa
90	10	0	2	tangensoidalna	liniowa
90	10	0	3	tangensoidalna	liniowa
80	20	0	2	tangensoidalna	liniowa
80	20	0	3	tangensoidalna	liniowa
100	0	0	2	tangensoidalna	tangensoidalna
100	0	0	3	tangensoidalna	tangensoidalna
90	10	0	2	tangensoidalna	tangensoidalna
90	10	0	3	tangensoidalna	tangensoidalna
80	20	0	2	tangensoidalna	tangensoidalna
80	20	0	3	tangensoidalna	tangensoidalna

Tab. 5.80.: Plan badań trzeciego zbioru ustalonego według kryterium K-W

% wartości w zbiorze uczącym	% wartości w zbiorze testującym	% wartości w zbiorze walidacyjnym	Liczby neuronów ukrytych:	Funkcja aktywacji w warstwie ukrytej	Funkcja aktywacji na wyjściu
100	0	0	Losowo (wg sugestii Statistica)	tangensoidalna	liniowa
70	15	15	Losowo (wg sugestii Statistica)	tangensoidalna	liniowa
100	0	0	Losowo (wg sugestii Statistica)	tangensoidalna	tangensoidalna
70	15	15	Losowo (wg sugestii Statistica)	tangensoidalna	tangensoidalna

Tab. 5.81.: Plan badań czwartego zbioru ustalonego według kryterium K-W

% wartości w zbiorze uczącym	% wartości w zbiorze testującym	% wartości w zbiorze walidacyjnym	Liczby neuronów ukrytych:	Funkcja aktywacji w warstwie ukrytej	Funkcja aktywacji na wyjściu
100	0	0	2	tangensoidalna	liniowa
100	0	0	3	tangensoidalna	liniowa
100	0	0	4	tangensoidalna	liniowa
100	0	0	5	tangensoidalna	liniowa
90	10	0	2	tangensoidalna	liniowa
90	10	0	3	tangensoidalna	liniowa
90	10	0	4	tangensoidalna	liniowa
90	10	0	5	tangensoidalna	liniowa
80	20	0	2	tangensoidalna	liniowa
80	20	0	3	tangensoidalna	liniowa
80	20	0	4	tangensoidalna	liniowa
80	20	0	5	tangensoidalna	liniowa
100	0	0	2	tangensoidalna	tangensoidalna
100	0	0	3	tangensoidalna	tangensoidalna
100	0	0	4	tangensoidalna	tangensoidalna
100	0	0	5	tangensoidalna	tangensoidalna
90	10	0	2	tangensoidalna	tangensoidalna
90	10	0	3	tangensoidalna	tangensoidalna
90	10	0	4	tangensoidalna	tangensoidalna
90	10	0	5	tangensoidalna	tangensoidalna
80	20	0	2	tangensoidalna	tangensoidalna
80	20	0	3	tangensoidalna	tangensoidalna
80	20	0	4	tangensoidalna	tangensoidalna
80	20	0	5	tangensoidalna	tangensoidalna

Tab. 5.82.: Plan badań piątego zbioru ustalonego według kryterium K-W

% wartości w zbiorze uczącym	% wartości w zbiorze testującym	% wartości w zbiorze walidacyjnym	Liczby neuronów ukrytych:	Funkcja aktywacji w warstwie ukrytej	Funkcja aktywacji na wyjściu
100	0	0	2	tangensoidalna	liniowa
100	0	0	3	tangensoidalna	liniowa
100	0	0	4	tangensoidalna	liniowa
100	0	0	5	tangensoidalna	liniowa
90	10	0	2	tangensoidalna	liniowa
90	10	0	3	tangensoidalna	liniowa
90	10	0	4	tangensoidalna	liniowa
90	10	0	5	tangensoidalna	liniowa
80	20	0	2	tangensoidalna	liniowa
80	20	0	3	tangensoidalna	liniowa
80	20	0	4	tangensoidalna	liniowa
80	20	0	5	tangensoidalna	liniowa
100	0	0	2	tangensoidalna	tangensoidalna
100	0	0	3	tangensoidalna	tangensoidalna
100	0	0	4	tangensoidalna	tangensoidalna
100	0	0	5	tangensoidalna	tangensoidalna
90	10	0	2	tangensoidalna	tangensoidalna
90	10	0	3	tangensoidalna	tangensoidalna
90	10	0	4	tangensoidalna	tangensoidalna
90	10	0	5	tangensoidalna	tangensoidalna
80	20	0	2	tangensoidalna	tangensoidalna

80	20	0	3	tangensoidalna	tangensoidalna
80	20	0	4	tangensoidalna	tangensoidalna
80	20	0	5	tangensoidalna	tangensoidalna

Tab. 5.83.: Plan badań pierwszego zbioru ustalonego według kryterium odwróconego K-W i ANOVA

% wartości w zbiorze uczącym	% wartości w zbiorze testującym	% wartości w zbiorze walidacyjnym	Liczby neuronów ukrytych:	Funkcja aktywacji w warstwie ukrytej	Funkcja aktywacji na wyjściu
100	0	0	21	tangensoidalna	liniowa
100	0	0	22	tangensoidalna	liniowa
70	15	15	7	tangensoidalna	liniowa
70	15	15	7	tangensoidalna	liniowa
100	0	0	19	tangensoidalna	tangensoidalna
100	0	0	22	tangensoidalna	tangensoidalna

Tab. 5.84.: Plan badań drugiego zbioru ustalonego według kryterium odwróconego K-W i ANOVA

% wartości w zbiorze uczącym	% wartości w zbiorze testującym	% wartości w zbiorze walidacyjnym	Liczby neuronów ukrytych:	Funkcja aktywacji w warstwie ukrytej	Funkcja aktywacji na wyjściu
100	0	0	2	tangensoidalna	liniowa
100	0	0	3	tangensoidalna	liniowa
100	0	0	2	tangensoidalna	tangensoidalna
100	0	0	3	tangensoidalna	tangensoidalna

Tab. 5.85.: Plan badań trzeciego zbioru ustalonego według kryterium odwróconego K-W i ANOVA

% wartości w zbiorze uczącym	% wartości w zbiorze testującym	% wartości w zbiorze walidacyjnym	Liczby neuronów ukrytych:	Funkcja aktywacji w warstwie ukrytej	Funkcja aktywacji na wyjściu
100	0	0	23	tangensoidalna	liniowa
100	0	0	21	tangensoidalna	tangensoidalna
70	15	15	7	tangensoidalna	tangensoidalna
70	15	15	14	tangensoidalna	tangensoidalna

Tab. 5.86.: Plan badań czwartego zbioru ustalonego według kryterium odwróconego K-W

% wartości w zbiorze uczącym	% wartości w zbiorze testującym	% wartości w zbiorze walidacyjnym	Liczby neuronów ukrytych:	Funkcja aktywacji w warstwie ukrytej	Funkcja aktywacji na wyjściu
100	0	0	2	tangensoidalna	liniowa
100	0	0	3	tangensoidalna	liniowa
100	0	0	4	tangensoidalna	liniowa
100	0	0	2	tangensoidalna	tangensoidalna
100	0	0	4	tangensoidalna	tangensoidalna

100	0	0	5	tangensoidalna	tangensoidalna
90	10	0	3	tangensoidalna	tangensoidalna
90	10	0	4	tangensoidalna	tangensoidalna

Tab. 5.87.: Plan badań piątego zbioru ustalonego według kryterium odwróconego K-W

% wartości w zbiorze uczącym	% wartości w zbiorze testującym	% wartości w zbiorze walidacyjnym	Liczby neuronów ukrytych:	Funkcja aktywacji w warstwie ukrytej	Funkcja aktywacji na wyjściu
100	0	0	2	tangensoidalna	liniowa
90	10	0	2	tangensoidalna	liniowa
90	10	0	5	tangensoidalna	liniowa
100	0	0	2	tangensoidalna	tangensoidalna
100	0	0	3	tangensoidalna	tangensoidalna
90	10	0	3	tangensoidalna	tangensoidalna


Tab. 5.88.: Plan badań czwartego zbioru ustalonego według kryterium ANOVA

% wartości w zbiorze uczącym	% wartości w zbiorze testującym	% wartości w zbiorze walidacyjnym	Liczby neuronów ukrytych:	Funkcja aktywacji w warstwie ukrytej	Funkcja aktywacji na wyjściu
100	0	0	2	tangensoidalna	liniowa
100	0	0	3	tangensoidalna	liniowa
100	0	0	4	tangensoidalna	liniowa
100	0	0	2	tangensoidalna	tangensoidalna
100	0	0	4	tangensoidalna	tangensoidalna
100	0	0	5	tangensoidalna	tangensoidalna
90	10	0	3	tangensoidalna	tangensoidalna
90	10	0	4	tangensoidalna	tangensoidalna

Tab. 5.89.: Plan badań piątego zbioru ustalonego według kryterium ANOVA

% wartości w zbiorze uczącym	% wartości w zbiorze testującym	% wartości w zbiorze walidacyjnym	Liczby neuronów ukrytych:	Funkcja aktywacji w warstwie ukrytej	Funkcja aktywacji na wyjściu
100	0	0	2	tangensoidalna	liniowa
90	10	0	2	tangensoidalna	liniowa
90	10	0	5	tangensoidalna	liniowa
100	0	0	2	tangensoidalna	tangensoidalna
100	0	0	3	tangensoidalna	tangensoidalna
90	10	0	3	tangensoidalna	tangensoidalna

Zaawansowane modelowanie oparte na dużych zbiorów danych było możliwe dzięki oprogramowaniu Statistica opracowanym przez StatSoft Inc.. Dzięki automatycznie tworzonymi SSN istnieje możliwość przeprowadzania badań zadając różne typy sieci oraz różne ich architektury. Od wyboru zależy jakość otrzymanych modeli i szybkość ich tworzenia. Uczenie przeprowadzono przy użyciu algorytmu uczącego BFGS, który jest w stanie osiągnąć zbieżność zazwyczaj szybciej niż inne algorytmy takie jak metoda najszybszego spadku [60]. Zastosowaną funkcją błędu była wartość entropii krzyżowej.




Rys.5.2.4.1. Wybór badań metodą sztucznych sieci neuronowych

W celu przeprowadzenia zaawansowanego modelowania opartego na danych, przy pomocy metody Sztucznych Sieci Neuronowych (SSN) należy (rys 5.2.4.1.):


- w punkcie 1, wybrać zakładkę „Data Mining”,
- w punkcie 2, wybrać uczenie „Neural Networks”,
- w punkcie 3, wybrać typ analizy „Regression”,
- w punkcie 4, zatwierdzić wybrane ustawienia.

Następnie należy (rys 5.2.4.2.):

- w punkcie 5, wybrać zakładkę „Quick”,
- w punkcie 6, wybrać zmienne poprzez „Variables”,
- w punkcie 7, zatwierdzić wybór,
- w punkcie 8, wybrać zmienne zależne „Continuous targets”,
- w punkcie 9, wybrać zmienne niezależne „Continuous inputs”
- w punkcie 10, wybrać zatwierdzić wybrane zmienne,
- w punkcie 11, wybrać zakładkę „Sampling CNN and ANN”,
- w punkcie 12, wybrać procent wartości w zbiorze uczącym, testowym i walidacyjnym,
- w punkcie 13, zatwierdzić wybrane ustawienia.



Rys.5.2.4.2. Wybór parametrów do metody sztucznych sieci neuronowych




Rys.5.2.4.3. Określenie parametrów programowanej sieci neuronowej


W celu określenia parametrów programowanej sieci neuronowej należy (rys 5.2.4.3.):

- w punkcie 1, wybrać zakładkę „Quick”,
- w punkcie 2, wybrać typ sieci MLP i określić minimalną i maksymalną ilość neuronów w warstwie ukrytej,
- w punkcie 3, określić ilość sieci do przetrenowania,
- w punkcie 4, wybrać zakładkę wyboru funkcji aktywacji „MLP activation function”.

- W punkcie 5, wybrać funkcję aktywacji w warstwie ukrytej,
- W punkcie 6, wybrać funkcję aktywacji na wyjściu,
- W punkcie 7, zatwierdzić wybrane parametry.



Rys.5.2.4.4. Proces budowania sztucznych sieci neuronowych



Rys.5.2.4.5. Otrzymane wyniki modelowania opartego na danych, metodą sztucznych sieci neuronowych

W celu zapisu wyników zaawansowanego modelowania opartego na danych, przy pomocy metody Sztucznych Sieci Neuronowych (SSN) należy (rys 5.2.4.5.):

- w punkcie 1, otworzyć szczegóły stworzonych modeli SSN,
- w punkcie 2, wybrać sieć neuronową wytypowaną przy użyciu arkusza stworzonego w programie Microsoft Office Excel (rys. 5.2.4.6.),
- w punkcie 3, zatwierdzić wybór.


Dla każdej serii badań wybrana została jedna najlepsza sieć, zidentyfikowana na podstawie wyników analizy arkusza, stworzonego w programie Microsoft Excel. Ponadto dla sieci zawierających zbiór walidacyjny wybrano dodatkową drugą najlepszą sieć na podstawie

najwyższej wartości jakości walidacji. Do arkusza wprowadzane były wyniki podsumowujące przeprowadzone modelowanie (punkt 1, rys. 5.2.4.6.), następnie arkusz obliczał wartość maksymalną z wartości kolumny przedstawiające wyniki jakości uczenia (punkt 2, rys. 5.2.4.6.), oraz jakości testowania (punkt 3, rys. 5.2.4.6.), na końcu obliczając maksymalną wartość wydajności obliczonej z iloczynu wartości jakości uczenia i jakości testowania (punkt 4, rys. 5.2.4.6.). Każdą utworzoną SSN z najwyższą wydajnością wybierano do dalszych analiz.

Podsumowanie aktywnych sieci (ANN1)													
Id sieci	Nazwa sieci	Jakość (uczenie)	Jakość (testowanie)	Jakość (walidac)	Błąd (uczenie)	Błąd (testowanie)	Błąd (walidac)	Algorytm uczenia	Funkcja błęd	Aktywacja (ukryte)	Aktywacja (wyjściow)	Max performance (ucz x test)	Max validation perf
28	MLP 30-11-1	0.107344	0.121706	0.065271	11.19453	4.216217	5.898966	BFGS 47	SOS	Tanh	Tanh	0.0131	0.0653
14	MLP 30-17-1	0.105459	0.118333	0.064822	11.20095	4.218244	5.891029	BFGS 45	SOS	Tanh	Tanh	0.0125	0.0648
180	MLP 30-18-1	0.108900	0.123377	0.064398	11.19066	4.216133	5.905884	BFGS 50	SOS	Tanh	Tanh	0.0134	0.0644
53	MLP 30-11-1	0.108414	0.111024	0.063662	11.19207	4.231194	5.900191	BFGS 37	SOS	Tanh	Tanh	0.0120	0.0637
83	MLP 30-22-1	0.105049	0.119645	0.063298	11.19988	4.219455	5.902301	BFGS 40	SOS	Tanh	Tanh	0.0126	0.0633
48	MLP 30-10-1	0.104871	0.118976	0.062516	11.20030	4.222143	5.905590	BFGS 40	SOS	Tanh	Tanh	0.0125	0.0628
93	MLP 30-15-1	0.105937	0.113954	0.062289	11.19828	4.224451	5.897319	BFGS 39	SOS	Tanh	Tanh	0.0121	0.0623
74	MLP 30-21-1	0.091324	0.106630	0.062221	11.23094	4.224430	5.881952	BFGS 5	SOS	Tanh	Tanh	0.0097	0.0622
199	MLP 30-11-1	0.117321	0.123532	0.060287	11.16944	4.220025	5.921827	BFGS 54	SOS	Tanh	Tanh	0.0145	0.0603
29	MLP 30-8-1	0.107605	0.120255	0.059700	11.19516	4.215362	5.901758	BFGS 33	SOS	Tanh	Tanh	0.0129	0.0597
21	MLP 30-8-1	0.090197	0.112833	0.059563	11.23261	4.219698	5.889528	BFGS 5	SOS	Tanh	Tanh	0.0102	0.0596
87	MLP 30-9-1	0.103364	0.111770	0.059528	11.20376	4.232648	5.912508	BFGS 11	SOS	Tanh	Tanh	0.0116	0.0595
196	MLP 30-19-1	0.103758	0.113316	0.059434	11.20282	4.228530	5.908289	BFGS 14	SOS	Tanh	Tanh	0.0118	0.0594
105	MLP 30-11-1	0.104818	0.109211	0.059397	11.20066	4.231053	5.903352	BFGS 42	SOS	Tanh	Tanh	0.0114	0.0594

Rys.5.2.4.6. Identyfikacja najbardziej wydajnej SSN

W tym celu zapisywane były szczegóły przewidywanych wartości zmiennej wyjściowej pobierane z zakładki „Przewidywania” (rys. 5.2.4.7.). Pobrane wyniki zapisywane były w dedykowanych plikach programowi Microsoft Excel (rys. 5.2.4.8.).



Rys.5.2.4.7. Zapisywanie wyników sztucznych sieci neuronowych

1										
Nazwa sieci	Jakość (uczenie)	Jakość (testowanie)	Jakość (walidacja)	Błąd (uczenie)	Błąd (testowanie)	Błąd (walidacja)	Algorytm uczenia	Funkcja błędu	Aktywacja (ukryte)	Aktywacja (wyjściowe)
MLP 30-7-1	0,366269	0,090499		8,72145	6,908872		BFGS 70	SOS	Tanh	Logistic

2										
ID	Wartość zmierzona	Wartość przewidziana	For RMSE							
Test	0,0200	2,3041	5,2							
Train	0,0200	1,3642	1,8							
Train	0,0500	1,8963	3,4							
Train	0,0600	2,5697	6,3							
Train	0,0700	1,5841	2,3							
Train	0,0800	1,4859	2,0							
Train	0,0800	1,8047	3,0							

3										
Error										
RMSE										4,09


Rys.5.2.4.8. Zapisywanie wyników w arkuszu Excel

W pliku zapisywano parametry SSN, takie jak jej jakość oraz błąd uczenia, testowania i walidacji, algorytm uczenia, funkcję błędu oraz wybraną funkcję aktywacji w warstwie ukrytej i wyjściowej (punkt 1, rys. 5.2.4.8.). Dodatkowo zestawiono wartości zmierzone z wartościami modelowanymi (punkt 2, rys. 5.2.4.8.) celem obliczenia średniej kwadratowej błędów - RMSE (ang. root-mean-square error) (punkt 3, rys. 5.2.4.8.). Jest to jedna z najczęściej stosowanych miar błędu stosowanych w ocenie danej SSN.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - h_i)^2}{n}} \quad (5.2.)$$


gdzie: y_i – zmierzona wartość *przecieku* (zmiennej wyjściowej)
 h_i - przewidziana wartość *przecieku* (zmiennej wyjściowej)
 n – ilość obserwacji

Celem dodatkowej wizualnej oceny wspomagającej klasyfikację najlepszych modeli wykonano również wykresy zależności zmiennej wyjściowej zmierzonej i przewidzianej.




Rys.5.2.4.9. Wykres zależności zmiennej wyjściowej zmierzonej i przewidzianej na przykładzie wyników zbioru 1, wg. kryterium K-W, zawierającego 100% wartości w zbiorze uczącym, 22 neurony ukryte, funkcję aktywacji w warstwie ukrytej i funkcję aktywacji na wyjściu tangensoidalna

Spośród wszystkich uzyskanych wyników zebrano najlepsze modele (tab. 5.90. – tab.5.92), jednocześnie przeanalizowano wpływ zmian parametrów modelu na wyniki modelowania zgodnie z jednym z założonych celów rozprawy. Zauważono, że w dużych zbiorach danych tj. pierwszym i trzecim uzyskano niższe wartości RMSE niż w małych zbiorach danych tj. w drugim, czwartym i piątym. Im więcej zmiennych wejściowych opisujących proces biorących w modelowaniu tym również uzyskano niższe wartości RMSE. Najniższą wartość równą 0,85 uzyskano dla dużego zbioru danych (trzeciego) ustalonego według kryterium odwróconego K-W - niezawierającego zbioru testującego, posiadającego 23 neurony w warstwie ukrytej i funkcję aktywacji liniową (lin) na wyjściu. Dla małych zbiorów danych najniższą wartość RMSE równe 0,9 otrzymano dla zbioru czwartego według kryterium ANOVA – niezawierającego zbioru testującego, posiadającego 5 neuronów i funkcję aktywacji tangensoidalną (tanh) na wyjściu (rys.5.2.4.10.). Natomiast jeszcze dokładniejszy wynik uzyskano dla czwartego zbioru danych, według kryterium ANOVA – niezawierającego zbioru testującego, posiadającego 4 neurony i funkcję tangensoidalną na wyjściu (rys. 5.2.4.11).



Rys.5.2.4.10. Wykres zależności zmiennej wyjściowej zmierzonej i przewidzianej na przykładzie wyników zbioru 4, wg. kryterium ANOVA, zawierającego 100% wartości w zbiorze uczącym, 5 neuronów ukrytych, funkcję aktywacji w warstwie ukrytej i funkcję aktywacji na wyjściu tangensoidalna



Rys.5.2.4.11. Wykres zależności zmiennej wyjściowej zmierzonej i przewidzianej na przykładzie wyników zbioru 4, wg. kryterium ANOVA, zawierającego 100% wartości w zbiorze uczącym, 4 neuronów ukrytych, funkcję aktywacji w warstwie ukrytej i funkcję aktywacji na wyjściu tangensoidalna

Tab. 5.90.: Wybrane wyniki modelowania z najniższą wartością RMSE dla pięciu zbiorów ustalonych według kryterium K-W, z oznaczeniem RMSE, od najniższych wartości (od zielonego koloru) do najwyższych wartości (do czerwonego koloru)

Numer zbioru	Zbiory według kryterium K-W															
1	% wartości w zbiorze testowym	0	0	0	0	0	15									
1	Liczba neuronów w warstwie ukrytej	20	19	22	22	21	7									
1	Funkcja aktywacji na wyjściu	tanh	tanh	lin	tanh	lin	lin									
1	RMSE	1,53	1,59	1,77	1,81	2,5	5,31									
2	% wartości w zbiorze testowym	0	0	0	0	0	0									
2	Liczba neuronów w warstwie ukrytej	3	3	2	3	2	2									
2	Funkcja aktywacji na wyjściu	tanh	tanh	tanh	lin	tanh	lin									
2	RMSE	15,5	15,6	20,8	20,9	21,2	23,5									
3	% wartości w zbiorze testowym	0	0	15	15											
3	Liczba neuronów w warstwie ukrytej	23	21	14	7											
3	Funkcja aktywacji na wyjściu	lin	tanh	tanh	tanh											
3	RMSE	0,93	0,96	1,28	1,28											
4	% wartości w zbiorze testowym	0	0	0	0	0	0	0	10	0	0	10				
4	Liczba neuronów w warstwie ukrytej	5	5	4	4	2	2	4	3	2	3	4				
4	Funkcja aktywacji na wyjściu	tanh	tanh	tanh	tanh	tanh	tanh	lin	tanh	lin	lin	tanh				
4	RMSE	4,4	4,9	5,2	7,0	12,5	13,5	14,0	15,9	16,6	16,9	17,7				
5	% wartości w zbiorze testowym	0	0	0	0	0	10	10	10	10						
5	Liczba neuronów w warstwie ukrytej	3	2	2	2	2	5	2	2	3						
5	Funkcja aktywacji na wyjściu	tanh	tanh	tanh	lin	lin	lin	lin	lin	tanh						
5	RMSE	11,8	15,1	15,5	16,7	17,5	18,1	19,2	19,8	24,0						

Tab. 5.91.: Wybrane wyniki modelowania z najniższą wartością RMSE dla pięciu zbiorów ustalonych według kryterium odwróconego K-W, z oznaczeniem RMSE, od najniższych wartości (od zielonego koloru) do najwyższych wartości (do czerwonego koloru)

Numer zbioru	Zbiory według kryterium odwróconego K-W					
1	% wartości w zbiorze testowym	0	0	2	0	15
1	Liczba neuronów w warstwie ukrytej	19	22	20	22	7
1	Funkcja aktywacji na wyjściu	tanh	lin	tanh	tanh	lin
1	RMSE	1,36	1,53	1,61	1,76	4,28
2	% wartości w zbiorze testowym	0	0	0		
2	Liczba neuronów w warstwie ukrytej	3	3	2		
2	Funkcja aktywacji na wyjściu	tanh	lin	tanh		
2	RMSE	21,5	21,6	21,7		
3	% wartości w zbiorze testowym	0	0			
3	Liczba neuronów w warstwie ukrytej	23	21			
3	Funkcja aktywacji na wyjściu	lin	tanh			

3	RMSE	0,86	0,9				
4	% wartości w zbiorze testowym	0	0	0	0	0	0
4	Liczba neuronów w warstwie ukrytej	4	5	4	3	2	2
4	Funkcja aktywacji na wyjściu	tanh	tanh	lin	lin	tanh	lin
4	RMSE	2,5	0,9	4,3	4,5	5,1	14
5	% wartości w zbiorze testowym	0	0	0	10		
5	Liczba neuronów w warstwie ukrytej	3	2	2	2		
5	Funkcja aktywacji na wyjściu	tanh	tanh	lin	lin		
5	RMSE	3,5	7,2	11,7	19		


Tab. 5.92.: Wybrane wyniki modelowania z najniższą wartością RMSE dla pięciu zbiorów ustalonych według kryterium ANOVA, z oznaczeniem RMSE, od najniższych wartości (od zielonego koloru) do najwyższych wartości (do czerwonego koloru)

Numer zbioru	Zbiory według kryterium ANOVA						
1	% wartości w zbiorze testowym	0	0	0	15		
1	Liczba neuronów w warstwie ukrytej	19	22	22	7		
1	Funkcja aktywacji na wyjściu	tanh	lin	tanh	lin		
1	RMSE	1,36	1,53	1,76	4,28		
2	% wartości w zbiorze testowym	0	0	0			
2	Liczba neuronów w warstwie ukrytej	3	3	2			
2	Funkcja aktywacji na wyjściu	tanh	lin	tanh			
2	RMSE	21,5	21,6	21,7			
3	% wartości w zbiorze testowym	0	0				
3	Liczba neuronów w warstwie ukrytej	23	21				
3	Funkcja aktywacji na wyjściu	lin	tanh				
3	RMSE	0,86	0,9				
4	% wartości w zbiorze testowym	0	0	0	0	0	0
4	Liczba neuronów w warstwie ukrytej	5	4	4	3	2	2
4	Funkcja aktywacji na wyjściu	tanh	tanh	lin	lin	tanh	lin
4	RMSE	0,9	2,1	2,4	3,7	3,9	6,5
5	% wartości w zbiorze testowym	0	0	0	10		
5	Liczba neuronów w warstwie ukrytej	3	2	2	5		
5	Funkcja aktywacji na wyjściu	tanh	tanh	lin	lin		
5	RMSE	3,8	6	6	17,8		


Jednym z efektów badań jest wynik modelowania sieci zawierającej pięć neuronów oraz całym zbiorem wykorzystanym do uczenia, zestawiony z wynikiem modelowania dla sieci zawierającej również pięć neuronów, ale z zadaniem zatrzymaniem uczenia wskutek wzrostu błędu dla zbioru testującego, gdzie można zauważyć wzrost błędu uczenia się sieci. Wynik średniej kwadratowej błędów – RMSE dla zbioru w całości wykorzystanego do uczenia wynosi

7,8 (rys.5.2.4.12.), natomiast dla zbioru z wydzielonym zbiorem testującym na poziomie 20% rekordów wynosi 24,9 (rys.5.2.4.13.).


Na podstawie zestawionych wyników, przykładowo otrzymanych podczas modelowania w oparciu o dane z pierwszego zbioru według kryterium K-W o największej liczbie obserwacji, gdzie najniższą uzyskaną wartością RMSE było 1,53 dla modelu bez zatrzymania uczenia się, zawierającego 20 neuronów oraz funkcje aktywacji tangensoidalne, można stwierdzić, że w przypadku kiedy mamy 0% wartości w zbiorze testującym, wówczas otrzymujemy najlepsze wyniki z najmniejszą wartością średniej kwadratowej błędów – RMSE (rys.5.2.4.14.). Prawdopodobnie są to modele wykazujące nadmierne dopasowanie się. Dla porównania najniższą wartość RMSE równą 1,77, dla tego samego zbioru jednak z funkcjami aktywacji w warstwie ukrytej tangensoidalną (tanh) i funkcją aktywacji na wyjściu liniową (lin) uzyskano dla modelu zawierającego 22 neurony w warstwie ukrytej, również z 0% wartości w zbiorze testującym (rys. 5.2.4.15.). Można na tej podstawie stwierdzić, że wyniki otrzymane z funkcjami tanh-lin i tanh-tanh są porównywalnie dobre.




Rys.5.2.4.12. Wykres zależności zmiennej wyjściowej zmierzonej i przewidzianej na przykładzie wyników zbioru 5, wg. kryterium K-W, model bez zatrzymania uczenia



Rys.5.2.4.13. Wykres zależności zmiennej wyjściowej zmierzonej i przewidzianej na przykładzie wyników zbioru 5, wg. kryterium K-W, model z zatrzymaniem uczenia wskutek wzrostu błędu dla zbioru testującego




Rys.5.2.4.14. Wyniki modelowania w oparciu o dane ze zbioru 1, według kryterium K-W, funkcja aktywacji tanh-tanh



Rys.5.2.4.15. Wyniki modelowania opartego na danych ze zbioru 1, według kryterium K-W, funkcja aktywacji tanh-lin

5.2.4.2. Wnioski

Ogólne wnioski przywołują stwierdzenie, iż poszukiwania optymalnej architektury powoduje w przypadku niniejszych badań największą trudność, ponieważ obecnie nie istnieje żaden wzór lub reguła, mówiąca jaki typ architektury powinien być zastosowany celem rozwiązania określonego problemu, dlatego kluczem do sukcesu jest stworzenie odpowiedniego procesu uczenia sieci dostosowanej do określonego problemu. Literatura podaje jedynie proponowane rozwiązania opierające się o aktualne trendy, co wzięto pod uwagę w tworzeniu planu badań opisanych w niniejszym rozdziale. Przetestowano kilkadziesiąt różnych architektur w różnych zbiorach danych posiadających zróżnicowane zakresy zmiennej zależnej. Przeprowadzone badania prowadzą do następujących wniosków: w bardzo niewielu przypadkach sieć jest w stanie się uczyć, jeśli wydzielimy zbiór testowy, lub testowy i walidacyjny, jednak czasami sieć jest w stanie to zrobić, co widać na rys. 5.2.4.16.



Rys.5.2.4.16. Wyniki modelowania opartego na danych ze zbioru 1, według kryterium K-W, funkcja aktywacji tanh-lin, 7 neuronów w warstwie ukrytej, z 20% wartości w zbiorze testującym

Nasuwa się pytanie, które modele są najlepsze do dalszej analizy, polegającej na wielowymiarowej optymalizacji parametrów procesu - czy użyć tych, które mają lepszą zdolność generalizacji, ponieważ sieć została zatrzymana na wzrost błędu dla nowych danych, czy też użyć tych modeli, które dały lepsze wyniki, ale ich zdolność generalizacji była słaba, ponieważ nie zastosowano zatrzymania uczenia.

Kluczowe jednak jest wydobywanie informacji z modelu opartego na danych np. neuronowego. Wskazano, możliwość zastosowania sztucznych sieci neuronowych do projektowania procesów wytwarzania w aspekcie praktycznym. Tym samym wykazano, że stosowanie metod sztucznej inteligencji, czyli między innymi sztucznych sieci neuronowych jest sposobem rozważania zjawisk powstawania wad w wyrobach, co może w przyszłości zastąpić tworzenie skomplikowanych modeli matematycznych lub dochodzenie do właściwych parametrów procesu metodami doświadczalnymi oraz uniknąć kosztownych badań jakości wyrobu.

Stwierdzono jednak, że przez brak jednoznacznej powtarzalności wyników potrzebne byłoby opracowanie innych metod analizy modeli miękkich, odfiltrujących te przysłaniające zależności. Dlatego w kolejnych rozdziałach przeprowadzono sprawdzenie alternatywnych rodzajów modeli opartych na danych: drzew decyzyjnych (z uwagi na ich diametralnie inny

charakter oraz rozpowszechnienie w zastosowaniach przemysłowych i innych), oraz maszyn wektorów wspierających (SVM) z uwagi na aktualne trendy.

Ostatecznie dokonano wyboru metody wykazującej najwyższą skuteczność i zastosowano jej wyniki modelowania do opracowania wielowymiarowej optymalizacji parametrów procesu dla minimalnej i maksymalnej wartości wady w produkcji, dla której opracowano strategię odpytywania modeli z wykorzystaniem metod gradientowych (z multistatem) i ewolucyjnych.

5.2.5. Zaawansowane modelowanie oparte na danych metodą DT

5.2.5.1. Metodyka i wyniki badań

Zdecydowano się na zastosowanie metody drzew regresyjnych, z uwagi na ich powszechność w zastosowaniach przemysłowych, możliwość aplikacji nawet w przypadku braku znajomości natury związku między zmienną zależną a jej predyktorami (czy jest on liniowy, czy nieliniowy) oraz diametralnie inny charakter względem sprawdzonej metody sztucznych sieci neuronowych, celem właściwego diagnozowania przyczyn powstawania wad wyrobów. Model regresyjny ogólnie stosowany jest w przypadku zagadnień, których celem jest określenie wartości zmiennej zależnej typu ciągłego, w oparciu o znane wartości zmiennych niezależnych typu ciągłego. W tego rodzaju analizach metoda ta potrafi odkryć ukryte zależności (pomiędzy parametrami procesu), które mogły zostać pominięte poprzez inne metody zaawansowanej analizy danych, dlatego zdecydowano się na zastosowanie jej w niniejszej rozprawie.


Do badań wykorzystano algorytm klasyfikacyjnych i regresyjnych drzew decyzyjnych (CART – ang. classification and regression trees) z pakietu Statistica, ponieważ umożliwia on manualne zadanie parametrów (przedstawionych w tab.5.93.) drzew decyzyjnych użytych do badań. Celem jest znalezienie odpowiedniego i logicznego zbioru warunków podziału, aby właściwie zaklasyfikować wszystkie analizowane obserwacje. Właściwy dobór założeń i parametrów tworzonego drzewa decyzyjnego, a więc określenie odpowiedniego rozmiaru drzewa, poprzez dobór wartości minimalnej liczności oraz odpowiedniego kryterium stopu jest kluczowy dla jakości uzyskanych wyników predykcji. W teorii możliwe byłoby kontynuowanie podziałów celem uzyskania doskonałego dopasowania modelu do danych, jednak skutkowałoby to stworzeniem bardzo złożonej struktury drzewa z najprawdopodobniej wręcz nadmiernym dopasowaniem, co wpłynęło by na brak zdolności modelu do prawidłowej predykcji dla nowych obserwacji. Dodatkowo decyzja o wyborze kryterium stopu podziału jest kluczowa dla danych rzeczywistych zawierających szumy występujące losowo. W tym celu

zastosowano kryterium stopu oparte na minimalnej liczności, a więc podziały były prowadzone do momentu osiągnięcia we wszystkich jednorodnych węzłach nie większej niż określonej minimalnej liczności przypadków. Sprawdzono różne zadane wartości minimalnych licznosci, celem uzyskania wniosków o wpływie tego parametru na otrzymaną jakość modelu [150]. Dodatkowo sprawdzono dwa typy ustawień wielokrotnej walidacji krzyżowej, umożliwiającą wybór najlepszego modelu regresyjnego dającego najlepszą prognozę dla badanych zbiorów danych na podstawie różnych zbiorów testowych i uczących.

Tab. 5.93.: Założenia przyjęte w CART

Parametr	Model ogólny drzewa regresyjnego
Wielokrotna walidacja krzyżowa	dwa typy ustawień (z walidacją, lub bez)
Minimalna licznosc	5, 10, 20, 50
Maksymalna liczba węzłów	1000

Analizie poddano dane z piętnastu zbiorów danych (pięciu zbiorów głównych ustalonych dodatkowo według trzech kryteriów, opisanych w poprzednich rozdziałach). Zbiory te zawierały zmienne niezależne oraz zmienną zależną typu ciągłego, a więc dane przygotowane do analizy metodą drzew regresyjnych. Ostatecznie wykonano 120 obliczeń, których wyniki zgromadzono w przygotowanych arkuszach oprogramowania Microsoft Excel.




Rys.5.2.5.1. Proces przeprowadzania badań metodą drzew regresyjnych

W celu przeprowadzenia modelowania opartego na danych, metodą drzew regresyjnych należy (rys.5.2.5.1):

- w punkcie 1, wybrać w zakładce „Data Mining” metodę „C&RT”,
- w punkcie 2, wybrać specyfikację metody „Quick specs dialog”,
- w punkcie 3, wybrać zmienne wejściowe i wyjściowe,
- w punkcie 4, ustalić minimalną licznosc i maksymalną liczbę węzłów,
- w punkcie 5, ustalić czy analiza ma zawierać wielokrotną walidację krzyżową.

Następnie, aby zapisać wyniki modelowania należy (rys.5.2.5.1) wybrać przycisk z przewidzianymi wartościami (punkt 1) i skopiować wyniki modelowania do utworzonych arkuszy excel (punkt 2).



Rys.5.2.5.2. Zapisywanie wyników modelowania metodą drzew regresyjnych

Ważnym punktem podczas zapisywania wyników było obliczenie dla każdego modelu wyniku obliczeń wartości RMSE, która służyła ocenie modelu. Wyniki modelowania zestawiono w tab.5.94 – tab.5.96..

Tab. 5.94.: Wyniki modelowania metodą drzew regresyjnych zbiorów według kryterium K-W, z oznaczeniem RMSE, od najniższych wartości (od zielonego koloru) do najwyższych wartości (do czerwonego koloru)

Numer zbioru	Zbiory według kryterium K-W				
1	Minimalna licznosc	5	10	20	50
1	RMSE z wielokrotną walidacją krzyżową	4,3	4,3	4,3	4,3
1	RMSE bez wielokrotnej walidacji krzyżowej	3,8	3,8	3,9	4,1

2	Minimalna liczność	5	10	20	50
2	RMSE z wielokrotną walidacją krzyżową	40	40	40	40
2	RMSE bez wielokrotnej walidacji krzyżowej	7,1	10,1	26,1	31,6
3	Minimalna liczność	5	10	20	50
3	RMSE z wielokrotną walidacją krzyżową	1,1	1,1	1,1	1,1
3	RMSE bez wielokrotnej walidacji krzyżowej	0,99	0,97	0,95	0,95
4	Minimalna liczność	5	10	20	50
4	RMSE z wielokrotną walidacją krzyżową	31	31	31	31
4	RMSE bez wielokrotnej walidacji krzyżowej	12	24,2	26,7	27,3
5	Minimalna liczność	5	10	20	50
5	RMSE z wielokrotną walidacją krzyżową	32,2	32,2	32,2	32,2
5	RMSE bez wielokrotnej walidacji krzyżowej	18,9	22,7	26,7	28,5

Tab. 5.95.: Wyniki modelowania metodą drzew regresyjnych zbiorów według kryterium odwróconego K-W, z oznaczeniem RMSE, od najniższych wartości (od zielonego koloru) do najwyższych wartości (do czerwonego koloru)


Numer zbioru	Zbiory według kryterium odwróconego K-W				
1	Minimalna liczność	5	10	20	50
1	RMSE z wielokrotną walidacją krzyżową	4,3	4,3	4,3	4,3
1	RMSE bez wielokrotnej walidacji krzyżowej	3,4	3,4	3,5	3,7
2	Minimalna liczność	5	10	20	50
2	RMSE z wielokrotną walidacją krzyżową	40	40	40	40
2	RMSE bez wielokrotnej walidacji krzyżowej	14,7	16,3	26,1	31,6
3	Minimalna liczność	5	10	20	50
3	RMSE z wielokrotną walidacją krzyżową	1,1	1,1	1,1	1,1
3	RMSE bez wielokrotnej walidacji krzyżowej	0,99	0,96	0,94	0,93
4	Minimalna liczność	5	10	20	50
4	RMSE z wielokrotną walidacją krzyżową	31	31	31	31
4	RMSE bez wielokrotnej walidacji krzyżowej	12,2	21,1	25,5	27,9
5	Minimalna liczność	5	10	20	50
5	RMSE z wielokrotną walidacją krzyżową	32,2	32,2	32,2	32,2
5	RMSE bez wielokrotnej walidacji krzyżowej	16	19,3	24,9	25,7

Tab. 5.96.: Wyniki modelowania metodą drzew regresyjnych zbiorów według kryterium ANOVA, z oznaczeniem RMSE, od najniższych wartości (od zielonego koloru) do najwyższych wartości (do czerwonego koloru)

Numer zbioru	Zbiory według kryterium ANOVA				
1	Minimalna liczność	5	10	20	50
1	RMSE z wielokrotną walidacją krzyżową	4,3	4,3	4,3	4,3
1	RMSE bez wielokrotnej walidacji krzyżowej	3,4	3,4	3,5	3,7
2	Minimalna liczność	5	10	20	50
2	RMSE z wielokrotną walidacją krzyżową	40	40	40	40
2	RMSE bez wielokrotnej walidacji krzyżowej	14,7	16,3	26,1	31,6
3	Minimalna liczność	5	10	20	50
3	RMSE z wielokrotną walidacją krzyżową	1,1	1,1	1,1	1,1
3	RMSE bez wielokrotnej walidacji krzyżowej	0,99	0,96	0,94	0,93
4	Minimalna liczność	5	10	20	50
4	RMSE z wielokrotną walidacją krzyżową	31	31	31	31

4	RMSE bez wielokrotnej walidacji krzyżowej	10,2	14	22,8	25,5
5	Minimalna liczność	5	10	20	50
5	RMSE z wielokrotną walidacją krzyżową	32,2	32,2	32,2	32,2
5	RMSE bez wielokrotnej walidacji krzyżowej	16,4	19	23,2	24,9

Najlepsze wyniki o najmniejszej wartości RMSE równej 7,1 dla małych zbiorów danych (czyli drugiego, czwartego i piątego) uzyskano w zbiorze drugim ustalonym według kryterium K-W z minimalną licznnością równą 5, bez zastosowania walidacji krzyżowej (rys.5.2.5.3.). Natomiast pośród dużych zbiorów danych (pierwszego i trzeciego) najniższą wartość RMSE równe 0,93 otrzymano w trzecim zbiorze danych ustalonym według kryterium odwróconego K-W i ANOVA z minimalną licznnością równą 50 (rys.5.2.5.4.).



Rys.5.2.5.3. Wyniki modelowania opartego na danych ze zbioru drugiego wg. kryterium K-W, z minimalną licznnością równą 5




Rys.5.2.5.4. Wyniki modelowania opartego na danych ze zbioru trzeciego według kryterium odwróconego K-W i ANOVA

5.2.5.2. Wnioski

Przeprowadzone badania umożliwiły sprawdzenie skuteczności metody drzew regresyjnych jako nieparametrycznej metody dyskryminacji do rozwiązania problemu związanego z właściwą predykcją wartości wyjściowej na podstawie określonych wartości zmiennych wejściowych.

Zauważono, że zwiększenie wartości minimalnej licznosci generalnie degraduje jakość badanego modelu drzew regresyjnych w szczególności w małych zbiorach danych (rys.5.2.5.5.). Na podstawie dwóch ustawień modeli, czyli zawierających wielokrotną walidację krzyżową, lub jej niezawierających można podsumować, że jej zastosowanie spowodowało uzyskanie jako wynikowych wartości zmiennej zależnej równych średniej z jej wszystkich wartości obserwacji. Stwierdzono, że drzewa regresyjne z zastosowaną wielokrotną walidacją krzyżową, nie są w stanie prawidłowo przewidzieć wartości zmiennej zależnej, a więc nie są w stanie przeprowadzić skutecznego procesu uczenia się (tab.5.94. – tab.5.96.).



Rys.5.2.5.5. Wynikowe wartości średnie RMSE w odniesieniu do wartości minimalnej licznosci dla małych i dużych zbiorów danych, bez walidacji krzyżowej

Wyniki modelowania opartego na danych z małych zbiorów danych w oparciu o obliczone wartości RMSE, w porównaniu z metodą sztucznych sieci neuronowych były znacznie gorsze. W przypadku dużych zbiorów danych wartości RMSE były zbliżone w obu metodach, jednak metoda drzew decyzyjnych nie dała lepszych wyników niż modelowanie SSN. Niewątpliwą zaletą metody jest czytelna i graficzna reprezentacja wyników.

5.2.6. Zaawansowane modelowanie oparte na danych metodą SVM


5.2.6.1. Metodyka i wyniki badań

W kolejnym etapie badań, opisywanym w niniejszym rozdziale zdecydowano o konieczności zastosowania metody maszyn wektorów wspierających (SVM), z uwagi na aktualne trendy analizy modeli miękkich w zagadnieniach przemysłowych. Zaawansowane modelowanie oparte na danych, metodą SVM stało się w pewnym momencie dość konkurencyjne względem metody sztucznych sieci neuronowych [151] z uwagi na jej skuteczne radzenie sobie z rozwiązywanymi problemami oraz poprawę jakości modeli. Celem badań jest więc stworzenie modelu opartego na metodzie SVM, skutecznie określającego zmianę wartości zmiennej wyjściowej na podstawie zmieniających się wartości parametrów wejściowych opisujących proces wytwarzania, aby właściwie wskazać przyczyny powstawania wad w wyrobach.


W celu realizacji badań opracowane dedykowane plany badawcze oparte o modele regresji. Zbiory danych przygotowane do badań zawierały inne zakresy zmiennej wyjściowej. Celem budowy optymalnej hiperpłaszczyzny, która będzie w stanie odseparować badane obiekty o różnej przynależności klasowej, budowanej w iteracyjnym algorytmie uczącym, zastosowano dwie minimalizujące funkcje błędu regresyjną typu pierwszego i regresyjną typu drugiego. Podczas badań zastosowano osiem różnych metod próbkowania danych, czyli w oparciu o cztery funkcje jądrowe i dwie różne funkcje błędu, w każdym z piętnastu opracowanych wcześniej zbiorów danych (pięć zbiorów ustalonych według trzech kryteriów). W celu nauczania SVM stworzono ostatecznie 120 modeli opartych o model regresyjny z różną ilością próbek.

W celu przeprowadzenia modelowania metodą drzew regresyjnych należy (rys.5.2.6.1. – rys.5.2.6.2.):

- w punkcie 1, wybrać w zakładce „Data Mining” - „Uczenie Maszynowe”,
- w punkcie 2, wybrać metodę „Maszyny wektorów wspierających”,
- w punkcie 3 i 4, wybrać zmienne wejściowe i wyjściowe,
- w punkcie 5, ustalić typ regresji SVM,
- w punkcie 6, wybrać funkcję jądrową,
- w punkcie 7, ustalić czy analiza ma zawierać wielokrotną walidację krzyżową.




Rys.5.2.6.1. Proces przeprowadzania badań metodą SVM



Rys.5.2.6.2. Proces ustawiania parametrów do badań metodą SVM

Następnie, aby zapisać wyniki modeowania należy (rys.5.2.6.3.) wybrać wszystkie próbki (punkt 1), następnie przycisk z przewidzianymi wartościami (punkt 2) i skopiować wyniki modelowania do utworzonych arkuszy excel (punkt 3).



Rys.5.2.6.3. Zapisywanie wyników modelowania metodą SVM

Metodą użytą do oceny jakości stworzonych modeli była obliczona wartość RMSE dla każdego z otrzymanych wyników badań (tab.5.97.-5.-99.). Wartość obliczonego RMSE pomogła podjąć decyzję, czy dany model może zostać użyty do dalszych etapów badań mających na celu diagnostykę przyczyn powstawania wad w wyrobach. Tego typu podejście zastosowane już w badaniach opartych o dwie opisywane wcześniej metody pozwala na obiektywne i praktycznie automatyczne testowanie modeli oraz ich ocenę.

Tab. 5.97.: Wyniki modelowania metodą SVM, zbiorów według kryterium K-W, z oznaczeniem RMSE, od najniższych wartości (od zielonego koloru) do najwyższych wartości (do czerwonego koloru)

Numer zbioru	Zbiory według kryterium K-W				
1	Funkcje jądrowe	Liniowa	Wielomian	RBF	Sigmoidalna
1	RMSE dla SVM typu 1	8	8,1	7,9	6,4
1	RMSE dla SVM typu 2	5,2	4,5	4,5	23,7
2	Funkcje jądrowe	Liniowa	Wielomian	RBF	Sigmoidalna
2	RMSE dla SVM typu 1	36,9	40,7	31,4	38,2
2	RMSE dla SVM typu 2	44,8	55,4	31,7	34,9
3	Funkcje jądrowe	Liniowa	Wielomian	RBF	Sigmoidalna
3	RMSE dla SVM typu 1	1,6	1,1	1,4	1,6
3	RMSE dla SVM typu 2	1,6	1,2	1,3	1,4
4	Funkcje jądrowe	Liniowa	Wielomian	RBF	Sigmoidalna
4	RMSE dla SVM typu 1	40,7	30,7	30,8	30,9
4	RMSE dla SVM typu 2	31,6	31,5	31,5	31,4
5	Funkcje jądrowe	Liniowa	Wielomian	RBF	Sigmoidalna
5	RMSE dla SVM typu 1	41,2	32,1	41,7	32,1
5	RMSE dla SVM typu 2	32,8	32,7	32,6	32,8

Tab. 5.98.: Wyniki modelowania metodą SVM, zbiorów według kryterium odwróconego K-W, z oznaczeniem RMSE, od najniższych wartości (od zielonego koloru) do najwyższych wartości (do czerwonego koloru)


Numer zbioru	Zbiory według kryterium odwróconego K-W				
1	Funkcje jądrowe	Liniowa	Wielomian	RBF	Sigmoidalna
1	RMSE dla SVM typu 1	6,9	7,9	7,1	6,9
1	RMSE dla SVM typu 2	5,7	4,4	4,5	12,8
2	Funkcje jądrowe	Liniowa	Wielomian	RBF	Sigmoidalna
2	RMSE dla SVM typu 1	32,9	31,7	38,3	32,2
2	RMSE dla SVM typu 2	34,8	33	29,2	31,9
3	Funkcje jądrowe	Liniowa	Wielomian	RBF	Sigmoidalna
3	RMSE dla SVM typu 1	1,8	1,1	1,4	1,4
3	RMSE dla SVM typu 2	1,6	1,2	1,3	1,3
4	Funkcje jądrowe	Liniowa	Wielomian	RBF	Sigmoidalna
4	RMSE dla SVM typu 1	34,1	30,6	30,4	30,2
4	RMSE dla SVM typu 2	37,1	31,5	31,3	31,3
5	Funkcje jądrowe	Liniowa	Wielomian	RBF	Sigmoidalna
5	RMSE dla SVM typu 1	33,9	41,8	41,5	41,7
5	RMSE dla SVM typu 2	31,9	32,6	32,5	32,5

Tab. 5.99.: Wyniki modelowania metodą SVM, zbiorów według kryterium ANOVA, z oznaczeniem RMSE, od najniższych wartości (od zielonego koloru) do najwyższych wartości (do czerwonego koloru)


Numer zbioru	Zbiory według kryterium ANOVA				
1	Funkcje jądrowe	Liniowa	Wielomian	RBF	Sigmoidalna
1	RMSE dla SVM typu 1	6,9	7,9	7,1	6,9
1	RMSE dla SVM typu 2	5,7	4,4	4,5	12,8
2	Funkcje jądrowe	Liniowa	Wielomian	RBF	Sigmoidalna
2	RMSE dla SVM typu 1	32,9	31,7	38,3	32,2
2	RMSE dla SVM typu 2	34,8	33	29,2	31,9
3	Funkcje jądrowe	Liniowa	Wielomian	RBF	Sigmoidalna
3	RMSE dla SVM typu 1	1,8	1,1	1,4	1,4
3	RMSE dla SVM typu 2	1,6	1,2	1,3	1,3
4	Funkcje jądrowe	Liniowa	Wielomian	RBF	Sigmoidalna
4	RMSE dla SVM typu 1	34,3	30,5	30,2	30,5
4	RMSE dla SVM typu 2	37,1	31,5	31,3	31,3
5	Funkcje jądrowe	Liniowa	Wielomian	RBF	Sigmoidalna
5	RMSE dla SVM typu 1	32,3	41,8	41,6	41,7
5	RMSE dla SVM typu 2	35,8	32,6	32,5	32,5

Najniższą wartość RMSE równą 29,2 spośród stosunkowo małych zbiorów danych uzyskano w drugim zbiorze ustalonym według odwróconego K-W i kryterium ANOVA, z SVM typu 2 i funkcją jądrową RBF (rys.5.2.6.4.). Spośród dużych zbiorów najlepszy wynik RMSE równe

1,1 otrzymano w 3 zbiorze ustalonym według kryterium K-W i odwóconego K-W z SVM typu 1 i funkcją jądrową wielomianową (rys. 5.2.6.5.).




Rys.5.2.6.4. Wyniki modelowania opartego na danych ze zbioru 2, wg kryterium odwóconego K-W i ANOVA, z funkcją jądrową RBF i SVM typu drugiego



Rys.5.2.6.5. Wyniki modelowania opartego na danych ze zbioru 3, wg kryterium K-W


5.2.6.2. Wnioski

Podczas przeprowadzonych analiz zbadano wpływ czterech funkcji jądrowych i dwóch typów regresji SVM na jakość utworzonego modelu (rys. 5.2.6.6.). W dużych zbiorach danych lepszą czyli niższą wartość RMSE otrzymano dla większości przypadków dla SVM typu drugiego.



Rys.5.2.6.6. Wyniki RMSE w podziale na rodzaj funkcji jądrowej i typ funkcji błędu

W małych zbiorach danych można było również zauważyć lepsze wyniki dla SVM typu drugiego. Jeżeli weźmiemy pod uwagę wyniki w podziale na rodzaj zastosowanej funkcji jądrowej, wówczas należy zauważyć, iż najlepsze wyniki otrzymano dla funkcji jądrowej RBF w dużych i małych zbiorach danych.



Rys.5.2.6.7. Średnie RMSE według numeru zbioru danych i kryterium

Generalnie najwyższe wartości RMSE otrzymano w drugim zbiorze danych ustalonym według kryterium K-W (rys.5.2.6.7.). Zbiór ten zawierał najmniejszą liczbę obserwacji. Najlepsze wyniki otrzymano natomiast w dużym zbiorze danych numer trzy w każdym z trzech kryteriów, zbiór ten zawierał tylko wartości *przecieku w obwodzie wysokiego ciśnienia* $< 7,5 \text{ cm}^3$ (było ich ponad 10000). W zbiorze tym można było zaobserwować znaczącą zmienność wartości zmiennej wyjściowej, której rozkład był zbliżony do normalnego, ale zaznaczało się zwiększone występowanie wartości podwyższonych. Modelowanie oparte na danych w tym zbiorze, może uwidaczniać trendy występujące w danych powszechnie. Zbiór ten nie obejmował podwyższonych wartości zmiennej zależnej a więc informacji o produktach z wadą.

5.2.7. Badanie modelu w celu wielowymiarowej optymalizacji parametrów procesu

5.2.7.1. Cel, metodyka i wyniki badań

Ostatni krok badań zrealizowano poprzez opracowanie planu badań zmierzających do wydobywania z modeli, wybranych jako najlepsze spośród zastosowanych metod zaawansowanego modelowania opartego na danych, a więc sztucznych sieci neuronowych, informacji o przyczynach powstawania wad wyrobów. Głównym celem było określenie, jaka wartość określonych parametrów wpływa na formowanie się wady w badanym odlewie lub jej brak. Informacje z modelu neuronowego można wydobywać w różny sposób, najlepiej przez odpowiednio zaplanowane odpytywanie sieci [151]. Ten sposób, nazywany „pedagogicznym”, polega na traktowaniu modelu, jako czarnej skrzynki, wykorzystując odpowiednio zaprojektowaną procedurę odpytywania sieci, celem uzyskania szukanych informacji [151]. Istnieje również drugi sposób, nazywany „dekompozycyjnym”, polega na analizie wag stworzonych sztucznych sieci neuronowych, lub ogólniej poszczególnych parametrów modelu [151]. Jednak podejście oparte na analizie wag sieci okazało się być niewystarczające [152], [153]. Dzieje się tak, ponieważ każdy proces uczenia się sieci generuje różne wagi, które są źródłem znacznych różnic w wartościach współczynników istotności [151]. Z tego powodu opracowana w ramach niniejszej rozprawy strategia zakładała pierwsze podejście - „pedagogiczne” i zawierała wielowariantową optymalizację wszystkich parametrów procesu dla maksymalnych i minimalnych wartości wad (wycieku). Idea takiego podejścia polegała na założeniu, że w warunkach możliwych zmian wszystkich parametrów procesu, zachodzących losowo, powtarzalne wartości sprzyjające wadzie i jej zapobiegające przyjmować będą te z nich, które rzeczywiście odgrywają istotną rolę. Wyniki takiej optymalizacji powinny także pozwolić na określenie kierunku wywoływanych zmian.


Badania prowadzące do optymalizacji były rozpoczęte od ponownego zbudowania sztucznych sieci neuronowych w programie Statistica, zgodnie z modelami wybranymi podczas zaawansowanej analizy z ponownym obliczeniem wartości RMSE. Ważnym punktem był fakt, iż wybrano nie tylko bezwzględnie najlepsze modele, które charakteryzowały się brakiem zdolności do generalizacji (zazwyczaj uzyskane bez zbioru testującego) ale również modele, które miały wyższy błąd średniokwadratowy predykcji, jednak posiadały lepszą zdolność do generalizacji (zazwyczaj zawierały zbiór testujący). Opis wybranych modeli zestawiono w tabeli (5.100).

Tab. 5.100.: Charakterystyka wybranych modeli do wielowymiarowej optymalizacji parametrów procesu

Kryterium	Zbiór	% wartości w zbiorze uczącym	% wartości w zbiorze testującym	% wartości w zbiorze walidacyjnym	Liczby neuronów ukrytych:	Funkcja aktywacji w warstwie ukrytej	Funkcja aktywacji na wyjściu	RMSE	Liczba zmiennych
K-W	1	100	0	0	19	tangensoidalna	tangensoidalna	1,50	30
K-W	1	100	0	0	22	tangensoidalna	liniowa	1,85	30
K-W	1	100	0	0	22	tangensoidalna	tangensoidalna	1,52	30
K-W	1	100	0	0	21	tangensoidalna	liniowa	1,56	30
K-W	1	70	15	15	7	tangensoidalna	liniowa	5,69	30
odwróconego K-W i ANOVA	1	100	0	0	19	tangensoidalna	tangensoidalna	1,78	47
odwróconego K-W i ANOVA	1	100	0	0	22	tangensoidalna	liniowa	1,60	47
odwróconego K-W i ANOVA	1	100	0	0	22	tangensoidalna	tangensoidalna	1,46	47
odwróconego K-W i ANOVA	1	100	0	0	20	tangensoidalna	tangensoidalna	1,61	47
odwróconego K-W i ANOVA	1	70	15	15	7	tangensoidalna	liniowa	4,03	47
K-W	2	100	0	0	2	tangensoidalna	tangensoidalna	21,50	13
K-W	2	100	0	0	3	tangensoidalna	tangensoidalna	21,50	13
K-W	2	100	0	0	2	tangensoidalna	liniowa	22,70	13
K-W	2	100	0	0	3	tangensoidalna	liniowa	22,70	13
odwróconego K-W i ANOVA	2	100	0	0	2	tangensoidalna	tangensoidalna	21,80	19
odwróconego K-W i ANOVA	2	100	0	0	3	tangensoidalna	tangensoidalna	21,50	19
odwróconego K-W i ANOVA	2	100	0	0	3	tangensoidalna	liniowa	21,60	19
K-W	3	100	0	0	23	tangensoidalna	liniowa	0,92	31
K-W	3	100	0	0	21	tangensoidalna	tangensoidalna	0,96	31
K-W	3	70	15	15	14	tangensoidalna	tangensoidalna	1,28	31
K-W	3	70	15	15	7	tangensoidalna	tangensoidalna	1,28	31
odwróconego K-W i ANOVA	3	100	0	0	23	tangensoidalna	liniowa	0,85	45
odwróconego K-W i ANOVA	3	100	0	0	21	tangensoidalna	tangensoidalna	0,90	45
K-W	4	100	0	0	2	tangensoidalna	tangensoidalna	11,20	16
K-W	4	100	0	0	4	tangensoidalna	tangensoidalna	5,40	16
K-W	4	100	0	0	5	tangensoidalna	tangensoidalna	4,40	16
K-W	4	90	10	0	3	tangensoidalna	tangensoidalna	12,70	16
K-W	4	90	10	0	4	tangensoidalna	tangensoidalna	15,10	16
K-W	4	100	0	0	2	tangensoidalna	liniowa	16,90	16
K-W	4	100	0	0	3	tangensoidalna	liniowa	15,40	16
K-W	4	100	0	0	4	tangensoidalna	liniowa	14,70	16

odwróconego K-W	4	100	0	0	2	tangensoidalna	tangensoidalna	6,30	25
odwróconego K-W	4	100	0	0	4	tangensoidalna	tangensoidalna	2,10	25
odwróconego K-W	4	100	0	0	5	tangensoidalna	tangensoidalna	0,70	25
odwróconego K-W	4	100	0	0	2	tangensoidalna	liniowa	5,30	25
odwróconego K-W	4	100	0	0	3	tangensoidalna	liniowa	6,20	25
odwróconego K-W	4	100	0	0	4	tangensoidalna	liniowa	4,10	25
ANOVA	4	100	0	0	2	tangensoidalna	tangensoidalna	6,40	26
ANOVA	4	100	0	0	4	tangensoidalna	tangensoidalna	2,10	26
ANOVA	4	100	0	0	5	tangensoidalna	tangensoidalna	1,30	26
ANOVA	4	90	10	0	3	tangensoidalna	tangensoidalna	23,20	26
ANOVA	4	90	10	0	4	tangensoidalna	tangensoidalna	12,10	26
ANOVA	4	100	0	0	2	tangensoidalna	liniowa	7,00	26
ANOVA	4	100	0	0	3	tangensoidalna	liniowa	4,20	26
ANOVA	4	100	0	0	4	tangensoidalna	liniowa	2,30	26
K-W	5	100	0	0	2	tangensoidalna	tangensoidalna	15,30	11
K-W	5	100	0	0	3	tangensoidalna	tangensoidalna	12,70	11
K-W	5	90	10	0	3	tangensoidalna	tangensoidalna	22,00	11
K-W	5	100	0	0	2	tangensoidalna	liniowa	19,20	11
K-W	5	90	10	0	2	tangensoidalna	liniowa	20,40	11
K-W	5	90	10	0	5	tangensoidalna	liniowa	17,80	11
odwróconego K-W	5	100	0	0	2	tangensoidalna	tangensoidalna	6,30	26
odwróconego K-W	5	100	0	0	3	tangensoidalna	tangensoidalna	4,70	26
odwróconego K-W	5	100	0	0	2	tangensoidalna	liniowa	12,10	26
odwróconego K-W	5	90	10	0	2	tangensoidalna	liniowa	23,10	26
ANOVA	5	100	0	0	2	tangensoidalna	tangensoidalna	5,90	27
ANOVA	5	100	0	0	3	tangensoidalna	tangensoidalna	3,60	27
ANOVA	5	100	0	0	2	tangensoidalna	liniowa	5,80	27
ANOVA	5	90	10	0	5	tangensoidalna	liniowa	31,20	27

Dokonano takiego wyboru, aby jednoznacznie określić co wpływa na powstawanie wady w produkcie. Podczas badań jednocześnie zapisywano obliczone wagi i programowano odpowiedź modelu (rys.5.2.7.1.). Dzięki temu możliwa była optymalizacja parametrów procesu dla minimalnej wartości wycieku, a więc odlewu bez wady, oraz maksymalnej wartości wycieku, a więc odlewu z wadą.



Rys.5.2.7.1. Zapisywanie obliczonych wartości wag parametrów sztucznej sieci neuronowej

W celu zapisania wag obliczonych podczas zaawansowanego modelowania sztucznych sieci neuronowych należy (rys.5.2.7.1.):

- w punkcie 1, po ukończeniu obliczeń wybrać w zakładce szczegóły przycisk „Wagi”
- w punkcie 2, skopiować wynikowe wartości wag do stworzonego pliku.

Celem zapisu wag zaprojektowano specjalny zaprogramowany arkusz programu Microsoft Excel z wbudowanym dodatkiem Solver, umożliwiającym nie tylko dowolne odpytywanie zapisanej sieci ale także np. optymalizację parametrów procesu dla uzyskania określonego wyniku (rys. 5.2.7.2.). Dzięki czemu możliwa będzie analiza i zbadanie, jakie parametry dają niebezpieczne, czyli podwyższone wartości *przecieku w obwodzie wysokiego ciśnienia*, a jakie bezpieczne czyli małe wartości *przecieku w obwodzie wysokiego ciśnienia*.

The screenshot shows an Excel spreadsheet for neural network optimization. Numbered callouts point to specific elements:

- 1**: Points to the 'Number of hidden neurons' input field, which contains the value 22.
- 2**: Points to the 'Max' and 'Min' input fields for the Solver, with values 0,02 and 171,86 respectively.
- 3**: Points to the 'Number of inputs' input field, which contains the value 30.
- 4**: Points to the 'OUTPUT' cell, which contains the value 62,44021579.
- 5**: Points to the 'Prepare' button.
- 6**: Points to the 'Normalized value' column header in the output table.
- 7**: Points to the 'RESULT of optimization' cell, which contains the value 62,44021579.
- 8**: Points to the 'Weights from Statistica' table.

DATA VALID FOR CURRENT DATA SET (all networks)

Before starting a new neural network delete values in columns B and C
Before each run of Solver remember to: delete the values in column G (G12:G31)

Max	Min	Value	No.
3	2	2,245803	1
2333	2186	2281,754	2
172,6	78,2	136,9233	3
31,5	22,4	27,19737	4
33	10,9	25,43179	5
106,6	53,8	100,4846	6
11,7	6,3	7,855077	7
9,3	5,1	9,031612	8
1613	1259	1433,34	9
2,7	1,9	2,474184	10
176	168	173,8228	11
90	88	88,97899	12
1384	1037	1037	13
870539	75900	293125,5	14
26	14	19,86058	15
28	25	26,13516	16
36	20	23,75787	17
33	26	30,56338	18
20	17	18,40957	19

Name	RESULT of optimization
OUTPUT	62,44021579


Normalized value
Facilitypressure
1stphasetime
Cycletime
Lubricationcycletime
Dosingtime1
Dosingtime2
Blowingtime
Lubricationtime
Vacuumfilter1
Lubricantconcentration
Multiplicationdelay
2ndphasetime
Vacuumprofile1
V2xVp2
Plungercoolingflow
Coolingcircuit15flow
Coolingcircuit17flow
Coolingcircuit6flow
Multiplicationstroke

Weights from Statistica
Facilitypressure --> hidden neuron 1
1stphasetime --> hidden neuron 1
Cycletime --> hidden neuron 1
Lubricationcycletime --> hidden neuron 1
Dosingtime1 --> hidden neuron 1
Dosingtime2 --> hidden neuron 1
Blowingtime --> hidden neuron 1
Lubricationtime --> hidden neuron 1
Vacuumfilter1 --> hidden neuron 1
Lubricantconcentration --> hidden neuron 1
Multiplicationdelay --> hidden neuron 1
2ndphasetime --> hidden neuron 1
Vacuumprofile1 --> hidden neuron 1
V2xVp2 --> hidden neuron 1
Plungercoolingflow --> hidden neuron 1
Coolingcircuit15flow --> hidden neuron 1
Coolingcircuit17flow --> hidden neuron 1
Coolingcircuit6flow --> hidden neuron 1
Multiplicationstroke --> hidden neuron 1
Plungercoolingtemperature --> hidden neuron 1

Rys.5.2.7.2. Struktura zaprogramowanego arkusza do optymalizacji parametrów procesu

W celu przeprowadzenia wielowymiarowej optymalizacji parametrów procesu należy (rys.5.2.7.2.):

- w punkcie 1, wpisać ilość neuronów ukrytych,
- w punkcie 2, wpisać minimalną i maksymalną wartość zmiennej wyjściowej,
- punkcie 3, wpisać minimalne i maksymalne wartości każdej zmiennej z punktu 4,
- w punkcie 5, wybrać przycisk uruchamiający makro przygotowujące dane, a dokładniej kopiuje wartości wag z punktu 8, do innych obszarów arkusza w innym układzie niż dostępne w programie Statistica,
- w punkcie 6 i w punkcie 7 otrzymywany jest wynik obliczeń po uruchomieniu analizy przy użyciu wbudowanego w oprogramowaniu Microsoft Excel dodatku Solver (rys. 5.2.7.3.).



Rys.5.2.7.3. Prowadzenie badań przy użyciu dodatku Solver

Dzięki wbudowanemu dodatkowi Solver, do oprogramowania Microsoft Excel istnieje możliwość prowadzenia automatycznych obliczeń optymalizacji parametrów procesu. Dodatek ten został stworzony w celu wykonywania analiz typu „co jeżeli”. Funkcjonowanie tego dodatku daje możliwość obliczenia optymalnej, czyli minimalnej lub maksymalnej wartości formuły w jednej z komórek wybieranej jako komórka celu, biorąc jednocześnie pod uwagę ograniczenia i limity zadane w innych komórkach. Dodatek Solver analizuje grupę komórek, określanych jako zmienne decyzyjne, używanych do obliczeń wynikowych komórek celu i ograniczeń. Dodatek ten dostosowuje wartości komórek zmiennych decyzyjnych celem dopasowania się do zadanych ograniczeń i uzyskania określonego wyniku dla celu komórki. W oknie dialogowym można wybrać metodę rozwiązywania problemu bazującą na jednym z trzech algorytmów, a dokładniej na metodzie nieliniowej GRG, LP simplex i ewolucyjnej.

Pierwsza z nich znajduje swoje zastosowanie w przypadku gładkich nieliniowych problemów, druga metoda jest dedykowana dla problemów liniowych, trzecia natomiast dla problemów, które nie są gładkie. Wybrana metoda nieliniowa GRG analizuje problem poprzez analizę gradientu lub nachylenia funkcji celu, gdy zmienne decyzyjne zmieniają się, określa osiągnięcie optymalnego rozwiązania, gdy uzyska zero w wartości pochodnych cząstkowych. W matematyce programowanie nieliniowe (NLP) jest procesem podczas którego rozwiązywany jest problem optymalizacyjny, zawierający nieliniową funkcję celu lub nieliniowe ograniczenia. Jest to ogólnie mówiąc dziedzina matematycznej optymalizacji

dedykowana do rozwiązywania problemów nieliniowych. Druga z wybranych metod, to metoda ewolucyjna. Dla tych dwóch metod przeprowadzono następnie badania i zapisano wyniki w tabelach dedykowanych dwóm algorytmom w oddzielnych tabelach dla minimalnej wartości zmiennej wyjściowej, maksymalnej wartości zmiennej wyjściowej.

Poniżej przedstawiono przykład utworzonych tabel na podstawie optymalizacji wyników modelowania opartego na danych ze zbioru pierwszego, ustalonego według kryterium K-W, dla którego ustalono 30 zmiennych wejściowych. Sieć zawierała 100% wartości w zbiorze uczącym, 19 neuronów w warstwie ukrytej i funkcję aktywacji w warstwie ukrytej i na wyjściu tangensoidalną, dla której RMSE wyniosło 1,5.

Tab. 5.101.: Wyniki wielowymiarowej optymalizacji metodą nieliniową GRG, z wielostartem dla minimalnej wartości zmiennej wyjściowej

No.	MIN, metoda nieliniowa GRG z wielostartem	Max	MIN	Numer wykonanej optymalizacji				
				1	2	3	4	5
1	Ciśnienie wody obiegowej [Bar]	3,0	2,0	2,2	2,6	2,5	2,4	2,9
2	Czas pierwszej fazy wtrysku [ms]	2333,0	2186,0	2333,0	2333,0	2190,1	2193,7	2216,4
3	Czas cyklu [s]	172,6	78,2	170,8	112,5	169,3	172,4	116,9
4	Czas cyklu smarowania [s]	31,5	22,4	23,9	24,7	30,4	31,5	26,2
5	Czas dozowania stopu [s]	33,0	10,9	14,8	31,3	29,7	17,8	31,7
6	Czas dozowania stopu 2 [s]	106,6	53,8	64,1	64,4	65,3	65,0	71,8
7	Czas przedmuchu [s]	11,7	6,3	9,9	7,7	6,3	8,0	9,1
8	Czas smarowania [s]	9,3	5,1	5,9	7,0	8,5	8,0	8,1
9	Filtr próżni 1 [mBar]	1613,0	1259,0	1583,2	1570,0	1259,0	1259,0	1367,9
10	Koncentrat [%]	2,7	1,9	2,6	2,0	2,0	2,6	2,1
11	Opóźnienie multiplikacji [ms]	176,0	168,0	169,4	168,0	168,0	168,0	169,3
12	Czas drugiej fazy wtrysku [ms]	90,0	88,0	89,9	88,6	88,0	88,0	88,0
13	Profil próżni 1 [mBar]	1384,0	1037,0	1259,5	1119,5	1116,6	1260,8	1303,9
14	V2xVp2	870539,0	75900,0	753407,5	822676,1	580134,6	626539,5	495750,5
15	Przepływ chłodzenia tłoka [l]	26,0	14,0	21,0	21,2	14,0	14,3	23,5
16	Przepływ w obwodzie chłodzenia 15 [l]	28,0	25,0	27,2	27,6	25,1	26,4	27,4
17	Przepływ w obwodzie chłodzenia 17 [l]	36,0	20,0	23,7	33,1	28,5	20,4	25,5
18	Przepływ w obwodzie chłodzenia 6 [l]	33,0	26,0	31,6	28,8	26,0	31,0	31,3
19	Suw pierwszej fazy wtrysku [mm]	20,0	17,0	17,5	18,1	17,0	17,7	19,2
20	Temperatura chłodzenia tłoka [°C]	35,0	27,0	32,1	33,2	27,0	32,1	32,0
21	Temperatura stopu [°C]	689,2	669,9	677,1	670,9	686,1	675,3	685,3
22	Temperatura termoregulatora 3.2 [°C]	156,0	144,0	154,3	145,4	149,7	145,9	154,8
23	Temperatura tulei 2 [°C]	235,0	205,0	224,5	222,8	219,9	211,7	230,6
24	Temperatura w obwodzie chłodzenia 1 [°C]	39,0	29,0	29,8	31,7	32,4	32,4	35,1

25	Temperatura w obwodzie chłodzenia 14 [°C]	34,0	31,0	34,0	33,1	31,3	31,3	33,1
26	Temperatura w obwodzie chłodzenia 15 [°C]	36,0	32,0	34,5	32,4	35,8	33,2	33,1
27	Temperatura w obwodzie chłodzenia 17 [°C]	35,0	25,0	27,9	34,8	27,5	32,6	25,5
28	Temperatura w obwodzie chłodzenia 7 [°C]	30,0	27,0	27,1	28,0	29,9	28,0	29,0
29	Temperatura wody miejskiej [°C]	27,0	18,0	24,5	25,0	18,1	19,9	21,9
30	Wartość próżni 1 [mBar]	599,0	138,0	140,2	413,7	451,2	262,4	599,0

Tab. 5.102.: Wyniki wielowymiarowej optymalizacji metodą nieliniową GRG, z wielostartem dla maksymalnej wartości zmiennej wyjściowej

No.	MAX, metoda nieliniowa GRG z wielostartem	Numer wykonanej optymalizacji				
		1	2	3	4	5
1	Ciśnienie wody obiegowej [Bar]	2,9	2,8	2,8	2,9	3,0
2	Czas pierwszej fazy wtrysku [ms]	2186,0	2333,0	2333,0	2292,6	2186,0
3	Czas cyklu [s]	140,2	132,2	144,9	137,4	89,9
4	Czas cyklu smarowania [s]	23,2	24,7	28,2	30,5	31,0
5	Czas dozowania stopu [s]	13,7	24,6	12,9	23,4	13,9
6	Czas dozowania stopu 2 [s]	76,0	74,1	60,6	66,6	63,4
7	Czas przedmuchu [s]	9,2	9,9	8,9	10,4	6,8
8	Czas smarowania [s]	8,4	8,8	7,1	9,0	7,4
9	Filtr próżni 1 [mBar]	1425,5	1568,8	1279,8	1445,9	1562,7
10	Koncentrat [%]	1,9	2,2	2,2	2,3	2,5
11	Opóźnienie multiplikacji [ms]	174,9	173,6	171,8	171,0	172,2
12	Czas drugiej fazy wtrysku [ms]	88,6	90,0	89,3	89,7	88,0
13	Profil próżni 1 [mBar]	1319,7	1359,8	1158,3	1229,0	1246,5
14	V2xVp2	543127,9	640109,6	113305,5	119170,3	692154,5
15	Przepływ chłodzenia tłoka [l]	23,5	24,6	23,6	20,9	15,2
16	Przepływ w obwodzie chłodzenia 15 [l]	25,8	26,1	26,1	26,6	27,3
17	Przepływ w obwodzie chłodzenia 17 [l]	28,9	35,7	28,8	32,6	28,2
18	Przepływ w obwodzie chłodzenia 6 [l]	32,1	32,8	26,4	28,8	32,8
19	Suw pierwszej fazy wtrysku [mm]	17,1	19,1	18,9	17,9	17,8
20	Temperatura chłodzenia tłoka [°C]	30,2	33,8	34,6	27,7	33,9
21	Temperatura stopu [°C]	685,4	671,6	672,8	674,6	683,1
22	Temperatura termoregulatora 3.2 [°C]	149,6	146,2	148,9	155,5	145,8
23	Temperatura tulei 2 [°C]	228,2	205,5	230,4	226,2	229,6
24	Temperatura w obwodzie chłodzenia 1 [°C]	34,3	29,8	36,9	30,0	30,8
25	Temperatura w obwodzie chłodzenia 14 [°C]	33,9	33,0	32,1	32,1	31,8
26	Temperatura w obwodzie chłodzenia 15 [°C]	35,2	34,6	35,9	33,2	32,9
27	Temperatura w obwodzie chłodzenia 17 [°C]	30,3	26,6	28,5	27,1	32,7
28	Temperatura w obwodzie chłodzenia 7 [°C]	29,4	27,9	29,6	27,2	28,7
29	Temperatura wody miejskiej [°C]	26,8	22,9	23,7	18,9	22,3
30	Wartość próżni 1 [mBar]	489,2	420,9	546,9	528,4	186,7

Tab. 5.103.: Wyniki wielowymiarowej optymalizacji metodą ewolucyjną, dla minimalnej wartości zmiennej wyjściowej

		Numer wykonanej optymalizacji				
No.	MIN, metoda ewolucyjna	1	2	3	4	5
1	Ciśnienie wody obiegowej [Bar]	2,1	2,9	2,5	2,1	2,3
2	Czas pierwszej fazy wtrysku [ms]	2238,4	2321,6	2250,5	2229,2	2270,3
3	Czas cyklu [s]	103,4	154,6	119,8	146,0	160,9
4	Czas cyklu smarowania [s]	24,0	22,5	25,0	29,9	23,6
5	Czas dozowania stopu [s]	19,8	20,0	20,5	22,7	16,1
6	Czas dozowania stopu 2 [s]	59,9	70,6	87,8	63,3	92,6
7	Czas przedmuchu [s]	7,2	8,4	10,2	7,9	9,9
8	Czas smarowania [s]	8,6	5,9	5,3	7,8	7,0
9	Filtr próżni 1 [mBar]	1268,1	1332,6	1587,3	1421,2	1459,4
10	Koncentrat [%]	2,4	2,5	1,9	2,3	2,7
11	Opóźnienie multiplikacji [ms]	170,4	168,3	168,6	169,6	170,9
12	Czas drugiej fazy wtrysku [ms]	89,5	89,7	89,7	89,3	88,7
13	Profil próżni 1 [mBar]	1310,3	1355,1	1093,0	1222,9	1317,5
14	V2xVp2	187138,8	698137,1	528601,0	649724,3	620248,5
15	Przepływ chłodzenia tłoka [l]	16,3	21,4	21,8	14,9	24,9
16	Przepływ w obwodzie chłodzenia 15 [l]	26,4	27,0	26,5	27,2	27,3
17	Przepływ w obwodzie chłodzenia 17 [l]	20,6	35,9	20,8	35,9	20,9
18	Przepływ w obwodzie chłodzenia 6 [l]	31,3	29,0	29,0	31,9	29,9
19	Suw pierwszej fazy wtrysku [mm]	17,1	18,5	17,9	17,5	20,0
20	Temperatura chłodzenia tłoka [°C]	27,9	33,0	33,3	32,3	35,0
21	Temperatura stopu [°C]	682,5	687,5	675,6	677,7	685,7
22	Temperatura termoregulatora 3.2 [°C]	153,8	148,0	152,5	146,6	149,2
23	Temperatura tulei 2 [°C]	221,9	209,7	231,1	232,9	226,6
24	Temperatura w obwodzie chłodzenia 1 [°C]	33,3	32,4	29,1	32,9	33,1
25	Temperatura w obwodzie chłodzenia 14 [°C]	33,3	31,0	33,7	32,1	33,9
26	Temperatura w obwodzie chłodzenia 15 [°C]	33,2	34,6	35,8	33,4	34,1
27	Temperatura w obwodzie chłodzenia 17 [°C]	31,0	28,4	28,0	32,9	31,7
28	Temperatura w obwodzie chłodzenia 7 [°C]	29,1	28,9	28,4	27,8	29,7
29	Temperatura wody miejskiej [°C]	19,1	23,8	26,2	23,9	26,2
30	Wartość próżni 1 [mBar]	177,2	383,7	225,6	431,3	514,6

Tab. 5.104.: Wyniki wielowymiarowej optymalizacji metodą ewolucyjną, dla maksymalnej wartości zmiennej wyjściowej

		Numer wykonanej optymalizacji				
No.	MAX, metoda ewolucyjna	1	2	3	4	5
1	Ciśnienie wody obiegowej [Bar]	2,5	2,5	2,7	2,7	2,9
2	Czas pierwszej fazy wtrysku [ms]	2251,1	2230,0	2224,7	2331,3	2239,4
3	Czas cyklu [s]	128,8	116,6	139,4	111,7	123,7
4	Czas cyklu smarowania [s]	26,2	30,1	23,5	26,4	28,8

5	Czas dozowania stopu [s]	17,4	30,0	31,0	22,2	15,7
6	Czas dozowania stopu 2 [s]	88,0	96,8	103,7	77,9	90,6
7	Czas przedmuchu [s]	10,9	7,1	10,7	8,0	8,7
8	Czas smarowania [s]	5,6	8,4	6,0	5,4	6,1
9	Filtr próżni 1 [mBar]	1385,9	1304,0	1386,2	1329,6	1446,0
10	Koncentrat [%]	2,3	1,9	2,4	2,2	2,4
11	Opóźnienie multiplikacji [ms]	172,9	174,7	170,6	172,3	173,2
12	Czas drugiej fazy wtrysku [ms]	88,8	88,6	88,7	88,8	88,9
13	Profil próżni 1 [mBar]	1107,6	1171,9	1261,9	1211,1	1295,3
14	V2xVp2	619061,9	530198,8	275586,1	696663,2	549261,3
15	Przepływ chłodzenia tłoka [l]	16,0	18,0	14,5	17,8	17,1
16	Przepływ w obwodzie chłodzenia 15 [l]	27,7	26,7	25,5	27,9	25,8
17	Przepływ w obwodzie chłodzenia 17 [l]	27,7	23,8	20,2	34,7	27,4
18	Przepływ w obwodzie chłodzenia 6 [l]	28,3	31,6	27,5	29,3	27,3
19	Suw pierwszej fazy wtrysku [mm]	18,9	19,2	18,2	17,4	18,5
20	Temperatura chłodzenia tłoka [°C]	28,5	34,3	32,4	35,0	29,9
21	Temperatura stopu [°C]	677,5	683,8	678,6	669,9	676,5
22	Temperatura termoregulatora 3.2 [°C]	150,1	149,5	148,0	146,9	154,4
23	Temperatura tulei 2 [°C]	233,3	214,7	210,1	212,9	211,8
24	Temperatura w obwodzie chłodzenia 1 [°C]	31,3	30,7	31,5	34,3	35,4
25	Temperatura w obwodzie chłodzenia 14 [°C]	34,0	32,5	32,7	31,3	31,7
26	Temperatura w obwodzie chłodzenia 15 [°C]	33,1	34,4	34,6	32,4	34,3
27	Temperatura w obwodzie chłodzenia 17 [°C]	31,2	25,9	27,2	28,0	28,3
28	Temperatura w obwodzie chłodzenia 7 [°C]	28,3	28,4	29,1	27,9	29,0
29	Temperatura wody miejskiej [°C]	26,6	24,0	24,6	23,1	21,5
30	Wartość próżni 1 [mBar]	302,0	493,4	333,7	273,1	170,0

Celem dalszej analizy dla wszystkich modeli policzono średnie z pięciu przeprowadzonych optymalizacji. Dodatkowo wyniki oznaczono kolorami, aby sprawdzić wpływ określonych wartości danych parametrów na niskie i podwyższone wartości zmiennej zależnej – *przecieku*.

Tab. 5.105.: Wyniki wielowymiarowej optymalizacji zbioru 1, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, 19 neuronami w warstwie ukrytej i funkcją aktywacji tangensooidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Ciśnienie wody obiegowej [Bar]	2,5	2,9	2,4	2,7	2	3
Czas pierwszej fazy wtrysku [ms]	2253,2	2266,1	2262,0	2255,3	2186	2333
Czas cyklu [s]	148,4	128,9	136,9	124,0	78,2	172,6
Czas cyklu smarowania [s]	27,3	27,5	25,0	27,0	22,4	31,5
Czas dozowania stopu [s]	25,1	17,7	19,8	23,3	10,9	33
Czas dozowania stopu 2 [s]	66,1	68,1	74,8	91,4	53,8	106,6

Czas przedmuchu [s]	8,2	9,1	8,7	9,1	6,3	11,7
Czas smarowania [s]	7,5	8,2	6,9	6,3	5,1	9,3
Filtr próżni 1 [mBar]	1407,8	1456,5	1413,7	1370,3	1259	1613
Koncentrat [%]	2,3	2,2	2,4	2,2	1,9	2,7
Opóźnienie multiplikacji [ms]	168,5	172,7	169,6	172,7	168	176
Czas drugiej fazy wtrysku [ms]	88,5	89,1	89,4	88,7	87,92	89,92
Profil próżni 1 [mBar]	1212,1	1262,7	1259,7	1209,5	1037	1384
V2xVp2	655701,7	421573,6	536770,0	534154,3	75900	870539
Przepływ chłodzenia tłoka [l]	18,8	21,6	19,9	16,7	14	26
Przepływ w obwodzie chłodzenia 15 [l]	26,7	26,4	26,9	26,7	25	28
Przepływ w obwodzie chłodzenia 17 [l]	26,3	30,9	26,8	26,8	20	36
Przepływ w obwodzie chłodzenia 6 [l]	29,7	30,6	30,2	28,8	26	33
Suw pierwszej fazy wtrysku [mm]	17,9	18,2	18,2	18,4	17	20
Temperatura chłodzenia tłoka [°C]	31,3	32,0	32,3	32,0	27	35
Temperatura stopu [°C]	678,9	677,5	681,8	677,3	669,9	689,2
Temperatura termoregulatora 3.2 [°C]	150,0	149,2	150,0	149,8	144	156
Temperatura tulei 2 [°C]	221,9	224,0	224,4	216,6	205	235
Temperatura w obwodzie chłodzenia 1 [°C]	32,3	32,4	32,2	32,6	29	39
Temperatura w obwodzie chłodzenia 14 [°C]	32,6	32,6	32,8	32,4	31	34
Temperatura w obwodzie chłodzenia 15 [°C]	33,8	34,4	34,2	33,7	32	36
Temperatura w obwodzie chłodzenia 17 [°C]	29,7	29,0	30,4	28,1	25	35
Temperatura w obwodzie chłodzenia 7 [°C]	28,4	28,5	28,8	28,5	27	30
Temperatura wody miejskiej [°C]	21,9	22,9	23,8	24,0	18	27
Wartość próżni 1 [mBar]	373,3	434,4	346,5	314,4	138	599

Tab. 5.106.: Wyniki wielowymiarowej optymalizacji zbioru 1, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, 22 neuronami w warstwie ukrytej i funkcją aktywacji tangensooidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Cisnienie wody obiegowej [Bar]	2,6	2,4	2,5	2,4	2	3
Czas pierwszej fazy wtrysku [ms]	2228,3	2228,9	2262,8	2226,9	2186	2333
Czas cyklu [s]	129,4	123,9	107,8	140,3	78,2	172,6
Czas cyklu smarowania [s]	25,7	26,4	25,3	27,9	22,4	31,5
Czas dozowania stopu [s]	21,8	21,5	19,1	20,5	10,9	33
Czas dozowania stopu 2 [s]	74,1	82,3	72,7	78,0	53,8	106,6
Czas przedmuchu [s]	8,6	9,7	10,0	8,3	6,3	11,7
Czas smarowania [s]	8,0	8,0	8,5	6,7	5,1	9,3
Filtr próżni 1 [mBar]	1336,2	1458,6	1421,1	1342,1	1259	1613
Koncentrat [%]	2,4	2,3	2,2	2,4	1,9	2,7
Opóźnienie multiplikacji [ms]	169,7	174,5	172,0	173,7	168	176
Czas drugiej fazy wtrysku [ms]	88,7	89,4	88,3	89,1	87,92	89,92
Profil próżni 1 [mBar]	1244,0	1198,6	1204,8	1279,0	1037	1384
V2xVp2	694416,6	612577,5	561287,8	530365,0	75900	870539
Przepływ chłodzenia tłoka [l]	19,3	20,6	19,8	18,7	14	26
Przepływ w obwodzie chłodzenia 15 [l]	26,5	26,2	26,3	26,5	25	28

Przepływ w obwodzie chłodzenia 17 [l]	27,8	29,2	27,8	29,8	20	36
Przepływ w obwodzie chłodzenia 6 [l]	31,1	29,7	29,8	31,1	26	33
Suw pierwszej fazy wtrysku [mm]	18,6	18,3	18,0	18,4	17	20
Temperatura chłodzenia tłoka [°C]	31,4	30,9	31,4	31,0	27	35
Temperatura stopu [°C]	680,4	681,3	676,4	676,6	669,9	689,2
Temperatura termoregulatora 3.2 [°C]	151,8	150,7	154,3	149,2	144	156
Temperatura tulei 2 [°C]	221,7	220,0	218,6	222,7	205	235
Temperatura w obwodzie chłodzenia 1 [°C]	35,1	36,5	37,1	34,2	29	39
Temperatura w obwodzie chłodzenia 14 [°C]	32,5	32,6	32,1	32,1	31	34
Temperatura w obwodzie chłodzenia 15 [°C]	34,1	34,1	34,1	33,5	32	36
Temperatura w obwodzie chłodzenia 17 [°C]	32,2	30,9	28,9	32,1	25	35
Temperatura w obwodzie chłodzenia 7 [°C]	29,0	28,0	28,8	28,4	27	30
Temperatura wody miejskiej [°C]	19,2	24,2	18,5	25,0	18	27
Wartość próżni 1 [mBar]	341,2	360,4	304,9	538,4	138	599

W przypadku wielowymiarowej optymalizacji zbioru 1, ustalonego wg. kr. K-W Solver nie mógł znaleźć dopuszczalnego rozwiązania:

- dla sieci z 70% wartości w zbiorze uczącym, 15% w zbiorze walidacyjnym i 15% w zbiorze testującym, z 7 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu,
- dla sieci z 100% wartości w zbiorze uczącym, 22 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu
- dla sieci z 100% wartości w zbiorze uczącym, 21 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu.

Tab. 5.107.: Wyniki wielowymiarowej optymalizacji zbioru 1, ustalonego wg. kr. odwróconego K-W i ANOVA, dla sieci z 100% wartości w zbiorze uczącym, 19 neuronami w warstwie ukrytej i funkcją aktywacji tangensooidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Ciśnienie wody miejskiej [Bar]	4,1	3,9	4,4	3,3	3	5
Ciśnienie wody obiegowej [Bar]	2,4	2,7	2,3	2,3	2	3
Czas pierwszej fazy wtrysku [ms]	2255,0	2289,6	2296,7	2275,8	2186	2333
Czas cyklu [s]	110,0	118,3	115,8	114,4	78,2	172,6
Czas cyklu smarowania [s]	27,0	26,4	27,2	26,7	22,4	31,5
Czas dozowania stopu [s]	22,8	26,2	20,7	18,2	10,9	33
Czas dozowania stopu 2 [s]	79,4	67,7	65,5	94,2	53,8	106,6
Czas krzepnięcia t2 [s]	10,1	10,8	10,3	10,3	10	11
Czas przedmuchu [s]	8,9	9,7	9,5	9,2	6,3	11,7
Czas smarowania [s]	6,6	5,8	8,3	7,8	5,1	9,3
Dzienny numer wtrysku [j.]	342,3	487,3	267,8	310,1	1	663

<i>Filtr próżni 1 [mBar]</i>	1493,1	1425,6	1421,8	1388,3	1259	1613
<i>Grubość piętki układu wlewowego [mm]</i>	37,1	38,3	38,2	40,2	32	45
<i>Koncentrat [%]</i>	2,3	2,3	2,3	2,6	1,9	2,7
<i>Ciśnienie maksymalne [Bar]</i>	344,0	339,4	341,7	341,6	339	346
<i>Prędkość wtrysku maksymalna [m/s]</i>	5,8	5,8	5,9	5,9	5,8	6
<i>Opóźnienie multiplikacji [ms]</i>	175,1	169,5	172,6	173,3	168	176
<i>Stała temperatura chłodzenia płyty [°C]</i>	28,1	30,2	31,1	30,6	27	32
<i>Poziom stopu w piecu podgrzewczym [mm]</i>	202,0	260,7	288,9	330,1	0	600
<i>Poziom wody w strumieniu chłodzącym [mm]</i>	246,1	260,8	265,0	276,3	200	298
<i>Czas drugiej fazy wtrysku [ms]</i>	89,0	88,9	89,1	88,7	87,9	89,9
<i>Profil próżni 1 [mBar]</i>	1345,6	1149,1	1160,5	1224,5	1037	1384
<i>V2xVp2</i>	335167,5	658526,8	442790,1	416407,0	75900	870539
<i>Przepływ chłodzenia tłoka [l]</i>	20,2	19,8	22,5	19,4	14	26
<i>Przepływ w obwodzie chłodzenia 1 [l]</i>	26,1	24,4	25,4	25,2	23	28
<i>Przepływ w obwodzie chłodzenia 13 [l]</i>	18,0	17,6	16,9	18,0	15	20
<i>Przepływ w obwodzie chłodzenia 14 [l]</i>	27,8	27,3	27,8	27,4	26	29
<i>Przepływ w obwodzie chłodzenia 15 [l]</i>	26,9	26,3	26,7	26,1	25	28
<i>Przepływ w obwodzie chłodzenia 17 [l]</i>	32,6	24,6	30,4	25,6	20	36
<i>Przepływ w obwodzie chłodzenia 20 [l]</i>	23,5	23,4	23,6	23,1	21	25
<i>Przepływ w obwodzie chłodzenia 6 [l]</i>	30,5	27,8	30,4	30,0	26	33
<i>Prędkość we wlewach doprowadzających [m/s]</i>	38,4	38,6	38,4	38,8	37,69	39,43
<i>Suw pierwszej fazy wtrysku [mm]</i>	18,3	18,2	18,9	19,0	17	20
<i>Temperatura chłodzenia tłoka [°C]</i>	31,5	30,8	31,4	32,0	27	35
<i>Temperatura stopu [°C]</i>	678,8	677,6	677,8	677,0	669,9	689,2
<i>Temperatura termoregulatora 3.2 [°C]</i>	147,9	148,8	150,2	150,7	144	156
<i>Temperatura tulei 2 [°C]</i>	225,4	218,3	213,5	219,9	205	235
<i>Temperatura tulei 3 [°C]</i>	217,5	229,4	220,8	204,7	182	256
<i>Temperatura tulei 4 [°C]</i>	234,3	232,6	225,9	233,8	208	258
<i>Temperatura w obwodzie chłodzenia 1 [°C]</i>	33,1	35,3	34,9	35,4	29	39
<i>Temperatura w obwodzie chłodzenia 13 [°C]</i>	36,3	34,6	35,4	34,5	32	40
<i>Temperatura w obwodzie chłodzenia 14 [°C]</i>	32,0	32,8	32,9	32,5	31	34
<i>Temperatura w obwodzie chłodzenia 15 [°C]</i>	33,7	34,4	33,3	34,4	32	36
<i>Temperatura w obwodzie chłodzenia 17 [°C]</i>	27,3	31,9	31,7	32,2	25	35
<i>Temperatura w obwodzie chłodzenia 7 [°C]</i>	27,9	28,1	28,4	28,7	27	30
<i>Temperatura wody miejskiej [°C]</i>	21,2	20,7	22,4	20,5	18	27
<i>Wartość próżni 1 [mBar]</i>	474,8	369,6	350,2	388,9	138	599

Tab. 5.108.: Wyniki wielowymiarowej optymalizacji zbioru 1, ustalonego wg. kr. odwróconego K-W i ANOVA, dla sieci z 100% wartości w zbiorze uczącym, 22 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
<i>Ciśnienie wody miejskiej [Bar]</i>	4,3	3,8	3,8	3,7	3	5
<i>Ciśnienie wody obiegowej [Bar]</i>	2,4	2,2	2,7	2,6	2	3
<i>Czas pierwszej fazy wtrysku [ms]</i>	2289,7	2239,0	2251,9	2251,5	2186	2333
<i>Czas cyklu [s]</i>	144,3	124,8	138,2	112,1	78,2	172,6
<i>Czas cyklu smarowania [s]</i>	29,2	25,9	28,5	26,7	22,4	31,5
<i>Czas dozowania stopu [s]</i>	18,1	24,5	19,0	21,1	10,9	33
<i>Czas dozowania stopu 2 [s]</i>	63,8	89,0	62,2	84,9	53,8	106,6
<i>Czas krzepnięcia t2 [s]</i>	10,4	10,4	10,2	10,3	10	11

Czas przedmuchu [s]	10,4	9,0	10,1	10,2	6,3	11,7
Czas smarowania [s]	6,0	7,7	7,7	8,1	5,1	9,3
Dzienny numer wtrysku [j.]	434,6	415,7	469,7	267,4	1	663
Filtr próżni I [mBar]	1371,4	1361,1	1403,9	1452,8	1259	1613
Grubość piętki układu wlewowego [mm]	38,8	36,8	38,8	38,5	32	45
Koncentrat [%]	2,5	2,2	2,1	2,3	1,9	2,7
Ciśnienie maksymalne [Bar]	341,5	342,6	341,0	340,6	339	346
Prędkość wtrysku maksymalna [m/s]	5,8	5,9	5,9	5,8	5,8	6
Opóźnienie multiplikacji [ms]	171,6	170,4	171,5	171,8	168	176
Stała temperatura chłodzenia płyty [°C]	30,1	28,2	28,8	29,5	27	32
Poziom stopu w piecu podgrzewczym [mm]	367,0	365,2	268,1	359,2	0	600
Poziom wody w strumieniu chłodzącym [mm]	264,8	238,1	242,2	223,0	200	298
Czas drugiej fazy wtrysku [ms]	88,8	88,9	89,4	89,3	87,9	89,9
Profil próżni I [mBar]	1233,2	1203,1	1175,4	1203,1	1037	1384
V2xVp2	361523,6	413018,7	407079,5	517808,4	75900	870539
Przepływ chłodzenia tłoka [l]	19,3	21,2	21,7	18,3	14	26
Przepływ w obwodzie chłodzenia 1 [l]	25,4	25,5	25,8	24,6	23	28
Przepływ w obwodzie chłodzenia 13 [l]	17,3	16,4	17,9	17,8	15	20
Przepływ w obwodzie chłodzenia 14 [l]	27,6	27,3	27,3	27,5	26	29
Przepływ w obwodzie chłodzenia 15 [l]	26,1	25,9	26,3	26,4	25	28
Przepływ w obwodzie chłodzenia 17 [l]	28,7	27,0	32,0	27,6	20	36
Przepływ w obwodzie chłodzenia 20 [l]	22,5	23,8	22,5	23,0	21	25
Przepływ w obwodzie chłodzenia 6 [l]	30,6	30,4	29,1	28,8	26	33
Prędkość we wlewach doprowadzających [m/s]	38,2	39,0	38,6	38,3	37,69	39,43
Suw pierwszej fazy wtrysku [mm]	17,4	18,9	18,5	18,5	17	20
Temperatura chłodzenia tłoka [°C]	31,1	30,3	32,0	31,3	27	35
Temperatura stopu [°C]	678,6	677,1	679,8	679,7	669,9	689,2
Temperatura termoregulatora 3.2 [°C]	151,2	151,9	149,3	150,6	144	156
Temperatura tulei 2 [°C]	217,7	216,5	226,0	222,7	205	235
Temperatura tulei 3 [°C]	218,4	202,7	228,8	216,6	182	256
Temperatura tulei 4 [°C]	241,2	226,6	222,3	242,7	208	258
Temperatura w obwodzie chłodzenia 1 [°C]	33,6	32,4	32,2	33,5	29	39
Temperatura w obwodzie chłodzenia 13 [°C]	35,1	35,1	36,0	36,7	32	40
Temperatura w obwodzie chłodzenia 14 [°C]	32,0	32,6	33,0	32,7	31	34
Temperatura w obwodzie chłodzenia 15 [°C]	33,8	34,4	34,2	33,6	32	36
Temperatura w obwodzie chłodzenia 17 [°C]	30,4	30,2	32,1	30,3	25	35
Temperatura w obwodzie chłodzenia 7 [°C]	29,3	28,4	28,0	28,2	27	30
Temperatura wody miejskiej [°C]	22,2	23,7	24,4	22,6	18	27
Wartość próżni I [mBar]	432,1	385,7	415,0	377,4	138	599

Tab. 5.109.: Wyniki wielowymiarowej optymalizacji zbioru 1, ustalonego wg. kr. odwróconego K-W i ANOVA, dla sieci z 100% wartości w zbiorze uczącym, 20 neuronami w warstwie ukrytej i funkcją aktywacji tangensooidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Ciśnienie wody miejskiej [Bar]	4,2	3,9	3,0	4,3	3	5
Ciśnienie wody obiegowej [Bar]	2,4	2,5	2,0	2,3	2	3
Czas pierwszej fazy wtrysku [ms]	2246,6	2260,1	2186,0	2274,2	2186	2333
Czas cyklu [s]	133,2	113,9	78,2	106,4	78,2	172,6
Czas cyklu smarowania [s]	26,3	28,3	22,4	28,1	22,4	31,5
Czas dozowania stopu [s]	23,0	25,8	10,9	27,5	10,9	33
Czas dozowania stopu 2 [s]	76,6	82,2	53,8	72,3	53,8	106,6
Czas krzepnięcia t2 [s]	10,2	10,1	10,0	10,1	10	11

Czas przedmuchu [s]	8,2	8,6	6,3	9,7	6,3	11,7
Czas smarowania [s]	8,1	7,7	5,1	6,2	5,1	9,3
Dzienny numer wtrysku [i.]	368,7	270,0	1,0	402,9	1	663
Filtr próżni 1 [mBar]	1499,4	1415,3	1259,0	1506,8	1259	1613
Grubość piętki układu wlewowego [mm]	38,4	37,1	32,0	38,4	32	45
Koncentrat [%]	2,5	2,3	1,9	2,2	1,9	2,7
Ciśnienie maksymalne [Bar]	339,6	343,8	339,0	341,4	339	346
Prędkość wtrysku maksymalna [m/s]	5,9	5,9	5,8	5,9	5,8	6
Opóźnienie multiplikacji [ms]	169,7	171,0	168,0	172,8	168	176
Stala temperatura chłodzenia płyty [°C]	30,3	30,2	27,0	29,6	27	32
Poziom stopu w piecu podgrzewczym [mm]	274,2	217,1	0,0	229,2	0	600
Poziom wody w strumieniu chłodzącym [mm]	261,0	260,1	200,0	257,2	200	298
Czas drugiej fazy wtrysku [ms]	89,1	89,1	88,0	88,9	87,9	89,9
Profil próżni 1 [mBar]	1104,0	1191,8	1037,0	1185,1	1037	1384
V2xVp2	511556,0	474273,9	75900,0	403391,8	75900	870539
Przepływ chłodzenia tłoka [l]	19,3	21,3	14,0	18,9	14	26
Przepływ w obwodzie chłodzenia 1 [l]	25,9	24,9	23,0	25,6	23	28
Przepływ w obwodzie chłodzenia 13 [l]	16,5	17,8	15,0	17,6	15	20
Przepływ w obwodzie chłodzenia 14 [l]	28,0	27,8	26,0	27,6	26	29
Przepływ w obwodzie chłodzenia 15 [l]	26,3	26,8	25,0	26,9	25	28
Przepływ w obwodzie chłodzenia 17 [l]	28,7	27,8	20,0	27,1	20	36
Przepływ w obwodzie chłodzenia 20 [l]	23,4	22,3	21,0	23,3	21	25
Przepływ w obwodzie chłodzenia 6 [l]	28,7	31,0	26,0	29,1	26	33
Prędkość we wlewach doprowadzających [m/s]	38,5	38,7	37,7	38,7	37,69	39,43
Suw pierwszej fazy wtrysku [mm]	19,0	19,1	17,0	18,7	17	20
Temperatura chłodzenia tłoka [°C]	31,5	32,1	27,0	31,5	27	35
Temperatura stopu [°C]	680,8	681,1	669,9	679,4	669,9	689,2
Temperatura termoregulatora 3.2 [°C]	150,2	151,2	144,0	151,0	144	156
Temperatura tulei 2 [°C]	224,3	222,1	205,0	217,9	205	235
Temperatura tulei 3 [°C]	214,9	236,1	182,0	230,3	182	256
Temperatura tulei 4 [°C]	233,6	225,8	208,0	225,9	208	258
Temperatura w obwodzie chłodzenia 1 [°C]	32,9	32,8	29,0	34,0	29	39
Temperatura w obwodzie chłodzenia 13 [°C]	34,4	36,1	32,0	34,8	32	40
Temperatura w obwodzie chłodzenia 14 [°C]	32,6	32,6	31,0	32,3	31	34
Temperatura w obwodzie chłodzenia 15 [°C]	33,7	34,2	32,0	33,4	32	36
Temperatura w obwodzie chłodzenia 17 [°C]	29,3	31,1	25,0	31,2	25	35
Temperatura w obwodzie chłodzenia 7 [°C]	28,8	28,8	27,0	28,5	27	30
Temperatura wody miejskiej [°C]	21,0	23,7	18,0	24,0	18	27
Wartość próżni 1 [mBar]	311,3	316,4	138,0	411,1	138	599

W przypadku wielowymiarowej optymalizacji zbioru 1, ustalonego wg. kr. odwróconego K-W i ANOVA, Solver nie mógł znaleźć dopuszczalnego rozwiązania:

- dla sieci z 100% wartości w zbiorze uczącym, 22 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu,
- dla sieci z 70% wartości w zbiorze uczącym, 15% w zbiorze walidacyjnym i 15% w testującym, 7 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu.

Tab. 5.110.: Wyniki wielowymiarowej optymalizacji zbioru 2, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji tangensooidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Ciśnienie wody miejskiej [Bar]	3,6	4,3	3,9	4,2	3	5
Grubość piętki układu wlewowego [mm]	38,2	35,6	35,1	37,8	32	42
Ciśnienie maksymalne [Bar]	344,7	339,9	343,4	342,2	339	345
Opóźnienie multiplikacji [ms]	172,7	172,3	172,1	170,9	169	176
Profil próżni 2 [mBar]	1167,7	1131,5	1147,3	1117,9	977	1317
Przepływ chłodzenia tłoka [l]	23,9	18,0	22,3	20,3	14	26
Przepływ w obwodzie chłodzenia 13 [l]	18,0	17,2	17,0	17,1	15	20
C1FxCl4F	684,9	656,9	714,5	678,2	598	784
Przepływ w obwodzie chłodzenia 15 [l]	27,7	26,6	27,2	27,4	25	28
Przepływ w obwodzie chłodzenia 20 [l]	22,1	22,9	22,4	24,0	21	25
Przepływ w obwodzie chłodzenia 6 [l]	29,3	30,0	28,9	29,1	26	33
Temperatura stopu [°C]	678,4	687,8	676,2	680,0	670,9	688,5
Wartość próżni 1 [mBar]	253,6	340,2	329,2	325,8	172	490

Tab. 5.111.: Wyniki wielowymiarowej optymalizacji zbioru 2, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 3 neuronami w warstwie ukrytej i funkcją aktywacji tangensooidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Ciśnienie wody miejskiej [Bar]	4,0	4,2	3,0	4,0	3	5
Grubość piętki układu wlewowego [mm]	35,0	37,6	32,0	36,1	32	42
Ciśnienie maksymalne [Bar]	342,4	343,0	339,0	341,4	339	345
Opóźnienie multiplikacji [ms]	172,6	171,4	169,0	173,4	169	176
Profil próżni 2 [mBar]	1134,9	1112,2	977,0	1179,2	977	1317
Przepływ chłodzenia tłoka [l]	19,2	18,4	14,0	20,4	14	26
Przepływ w obwodzie chłodzenia 13 [l]	17,6	18,1	15,0	17,0	15	20
C1FxCl4F	678,5	694,1	598,0	691,4	598	784
Przepływ w obwodzie chłodzenia 15 [l]	26,6	26,8	25,0	25,8	25	28
Przepływ w obwodzie chłodzenia 20 [l]	23,4	23,4	21,0	22,4	21	25
Przepływ w obwodzie chłodzenia 6 [l]	28,8	29,4	26,0	28,4	26	33
Temperatura stopu [°C]	677,5	678,1	670,9	683,1	670,9	688,5
Wartość próżni 1 [mBar]	274,9	328,4	172,0	358,6	172	490

Tab. 5.112.: Wyniki wielowymiarowej optymalizacji zbioru 2, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Ciśnienie wody miejskiej [Bar]	3,4	4,3	3,9	3,9	3	5
Grubość piętki układu wlewowego [mm]	34,9	35,1	35,6	38,4	32	42
Ciśnienie maksymalne [Bar]	342,5	341,2	341,7	343,3	339	345
Opóźnienie multiplikacji [ms]	170,3	173,7	172,1	172,3	169	176
Profil próżni 2 [mBar]	1110,6	1099,2	1124,4	1152,4	977	1317
Przepływ chłodzenia tłoka [l]	21,9	21,8	21,5	19,4	14	26

Przepływ w obwodzie chłodzenia 13 [l]	16,9	17,1	17,0	17,6	15	20
C1FxC14F	684,6	711,9	662,0	684,8	598	784
Przepływ w obwodzie chłodzenia 15 [l]	26,5	26,4	26,5	26,3	25	28
Przepływ w obwodzie chłodzenia 20 [l]	22,5	22,6	23,7	23,2	21	25
Przepływ w obwodzie chłodzenia 6 [l]	29,5	29,2	29,5	29,6	26	33
Temperatura stopu [°C]	673,9	681,3	676,2	681,4	670,9	688,5
Wartość próżni 1 [mBar]	273,0	251,6	359,9	372,8	172	490

Tab. 5.113.: Wyniki wielowymiarowej optymalizacji zbioru 2, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 3 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Ciśnienie wody miejskiej [Bar]	3,6	3,7	3,7	3,9	3	5
Grubość piętki układu wlewowego [mm]	36,7	37,1	36,5	37,1	32	42
Ciśnienie maksymalne [Bar]	341,3	341,7	342,1	341,1	339	345
Opóźnienie multiplikacji [ms]	170,9	171,5	170,6	172,7	169	176
Profil próżni 2 [mBar]	1191,1	1161,7	1168,6	1087,2	977	1317
Przepływ chłodzenia tłoka [l]	20,2	18,0	21,8	20,8	14	26
Przepływ w obwodzie chłodzenia 13 [l]	18,0	19,4	16,7	17,9	15	20
C1FxC14F	739,9	729,7	687,7	691,1	598	784
Przepływ w obwodzie chłodzenia 15 [l]	26,6	26,2	26,2	26,4	25	28
Przepływ w obwodzie chłodzenia 20 [l]	22,5	22,7	23,3	23,9	21	25
Przepływ w obwodzie chłodzenia 6 [l]	29,1	30,3	30,4	30,1	26	33
Temperatura stopu [°C]	682,8	683,1	675,7	680,9	670,9	688,5
Wartość próżni 1 [mBar]	326,7	282,6	297,2	361,6	172	490

Tab. 5.114.: Wyniki wielowymiarowej optymalizacji zbioru 2, ustalonego wg. kr. odwróconego K-W i ANOVA, dla sieci z 100% wartości w zbiorze uczącym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji tangensooidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Ciśnienie wody miejskiej [Bar]	3,8	4,3	4,2	3,6	3	5
Czas krzepnięcia t2 [s]	10,3	10,6	10,4	10,4	10	11
Filtr próżni 1 [mBar]	1486,2	1389,1	1473,4	1414,9	1259	1592
Grubość piętki układu wlewowego [mm]	35,3	36,8	37,7	36,5	32	42
Ciśnienie maksymalne [Bar]	341,5	342,9	342,0	340,8	339	345
Opóźnienie multiplikacji [ms]	171,7	172,5	173,0	172,6	169	176
Profil próżni 2 [mBar]	1180,5	1123,0	1159,9	1158,2	977	1317
Przepływ chłodzenia tłoka [l]	21,1	18,9	19,0	20,9	14	26
C1FxC14F	719,8	662,1	712,5	683,0	598	784
Przepływ w obwodzie chłodzenia 13 [l]	17,6	16,9	18,1	16,1	15	20
Przepływ w obwodzie chłodzenia 15 [l]	25,9	26,0	26,4	26,1	25	28
Przepływ w obwodzie chłodzenia 20 [l]	23,2	22,9	23,0	21,9	21,0	25
Przepływ w obwodzie chłodzenia 6 [l]	26,9	29,8	29,5	29,2	26	33
Temperatura chłodzenia tłoka [°C]	31,7	31,4	33,1	30,2	28	35
Temperatura stopu [°C]	676,8	677,1	680,5	684,1	670,9	688,5
Temperatura w obwodzie chłodzenia 1 [°C]	34,9	34,7	35,1	32,7	30	39
Temperatura wody miejskiej [°C]	21,2	22,4	22,3	22,3	19	26
Temperatura wody w instalacji [°C]	23,5	24,3	24,0	23,9	23,0	25
Wartość próżni 1 [mBar]	312,1	330,8	325,5	326,6	172	490

Tab. 5.115.: Wyniki wielowymiarowej optymalizacji zbioru 2, ustalonego wg. kr. odwróconego K-W i ANOVA, dla sieci z 100% wartości w zbiorze uczącym, z 3 neuronami w warstwie ukrytej i funkcją aktywacji tangensooidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Ciśnienie wody miejskiej [Bar]	4,3	3,7	4,0	4,0	3	5
Czas krzepnięcia t2 [s]	10,5	10,2	10,4	10,6	10	11
Filtr próżni 1 [mBar]	1394,2	1358,1	1420,3	1449,8	1259	1592
Grubość piętki układu wlewowego [mm]	35,9	37,3	36,9	39,8	32	42
Ciśnienie maksymalne [Bar]	343,9	341,3	341,9	342,3	339	345
Opóźnienie multiplikacji [ms]	170,9	175,4	173,4	172,8	169	176
Profil próżni 2 [mBar]	1180,7	1177,1	1173,5	1170,2	977	1317
Przepływ chłodzenia tłoka [l]	22,1	20,7	19,8	18,8	14	26
C1Fx C14F	666,9	679,4	717,9	748,2	598	784
Przepływ w obwodzie chłodzenia 13 [l]	16,7	17,5	17,6	17,3	15	20
Przepływ w obwodzie chłodzenia 15 [l]	26,2	26,2	26,6	26,9	25	28
Przepływ w obwodzie chłodzenia 20 [l]	23,5	22,8	22,9	22,9	21,0	25
Przepływ w obwodzie chłodzenia 6 [l]	29,9	28,6	29,0	31,8	26	33
Temperatura chłodzenia tłoka [°C]	30,9	33,6	31,3	33,3	28	35
Temperatura stopu [°C]	678,8	676,0	679,7	681,0	670,9	688,5
Temperatura w obwodzie chłodzenia 1 [°C]	36,1	34,7	35,5	31,6	30	39
Temperatura wody miejskiej [°C]	24,2	22,3	23,5	20,8	19	26
Temperatura wody w instalacji [°C]	24,1	23,9	24,0	24,1	23,0	25
Wartość próżni 1 [mBar]	295,2	370,5	374,8	313,7	172	490

W przypadku wielowymiarowej optymalizacji zbioru 2, ustalonego wg. kr. odwróconego K-W i ANOVA, Solver nie mógł znaleźć dopuszczalnego rozwiązania:

- dla sieci z 100% wartości w zbiorze uczącym, z 3 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu.

Tab. 5.116.: Wyniki wielowymiarowej optymalizacji zbioru 3, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 23 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Ciśnienie wody obiegowej [Bar]	2,3	2,5	2,2	2,4	2	3
Czas pierwszej fazy wtrysku [ms]	2278,4	2261,0	2260,0	2297,6	2186	2333
Czas cyklu [s]	117,4	106,2	112,8	118,6	78,2	172,6
Czas cyklu smarowania [s]	27,8	27,6	27,0	27,9	22,4	31,5
Czas dozowania stopu [s]	24,7	21,5	16,3	19,3	10,9	33
Czas dozowania stopu 2 [s]	75,4	87,1	77,0	74,5	53,8	106,6
Czas przedmuchu [s]	10,4	8,9	8,3	9,5	6,3	11,7
Czas smarowania [s]	6,9	7,3	7,3	7,8	5,1	9,3
Filtr próżni 1 [mBar]	1426,3	1339,8	1449,0	1336,1	1259	1613
Koncentrat [%]	2,2	2,2	2,3	2,6	1,9	2,7
Opóźnienie multiplikacji [ms]	172,4	173,5	174,1	169,3	168	176
Stała temperatura chłodzenia płyty [°C]	29,3	28,7	28,4	29,2	27,0	32
Czas drugiej fazy wtrysku [ms]	89,3	88,6	88,6	88,6	87,9	89,9
Profil próżni 1 [mBar]	1226,3	1256,5	1204,7	1185,3	1037	1384
V2xVp2	461501,7	378953,8	418216,3	620333,5	75900	870539
Przepływ chłodzenia tłoka [l]	19,1	18,5	18,6	22,8	14	26
Przepływ w obwodzie chłodzenia 15 [l]	26,5	26,6	25,6	25,9	25	28
Przepływ w obwodzie chłodzenia 17 [l]	32,8	30,2	26,1	26,6	20,0	36
Przepływ w obwodzie chłodzenia 6 [l]	30,0	29,6	29,8	29,9	26	33
Suw docisku po multiplikacji [mm]	18,3	18,3	19,0	18,5	17	20
Temperatura chłodzenia tłoka [°C]	31,8	31,6	31,4	31,3	27	35
Temperatura stopu [°C]	678,1	676,9	676,6	680,9	669,9	689,2
Temperatura termoregulatora 3.2 [°C]	151,1	148,9	150,0	152,2	144	156
Temperatura tulei 2 [°C]	213,7	216,6	226,7	217,0	205,0	235
Temperatura w obwodzie chłodzenia 1 [°C]	33,8	31,7	32,2	33,6	29	39
Temperatura w obwodzie chłodzenia 14 [°C]	32,5	31,8	32,8	32,9	31	34
Temperatura w obwodzie chłodzenia 15 [°C]	34,7	33,2	34,1	33,7	32	36
Temperatura w obwodzie chłodzenia 17 [°C]	29,5	28,7	30,2	29,7	25	35
Temperatura w obwodzie chłodzenia 7 [°C]	27,9	29,1	27,9	28,6	27	30
Temperatura wody miejskiej [°C]	21,6	22,5	22,7	21,9	18,0	27
Wartość próżni 1 [mBar]	333,3	282,8	354,7	310,4	138	599

Tab. 5.117.: Wyniki wielowymiarowej optymalizacji zbioru 3, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 21 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Ciśnienie wody obiegowej [Bar]	2,3	2,6	2,6	2,3	2	3
Czas pierwszej fazy wtrysku [ms]	2266,2	2246,2	2239,0	2242,6	2186	2333
Czas cyklu [s]	140,9	147,8	131,0	92,4	78,2	172,6
Czas cyklu smarowania [s]	27,4	27,7	28,0	26,1	22,4	31,5
Czas dozowania stopu [s]	20,8	27,5	14,5	17,7	10,9	33
Czas dozowania stopu 2 [s]	81,3	66,9	74,7	83,0	53,8	106,6
Czas przedmuchu [s]	8,7	8,1	9,8	8,7	6,3	11,7
Czas smarowania [s]	6,8	6,7	6,5	7,0	5,1	9,3
Filtr próżni 1 [mBar]	1417,6	1400,8	1392,9	1463,8	1259	1613
Koncentrat [%]	2,2	2,2	2,2	2,4	1,9	2,7
Opóźnienie multiplikacji [ms]	170,3	169,7	171,3	172,0	168	176

Stała temperatura chłodzenia płyty [°C]	28,5	29,2	28,7	29,6	27,0	32
Czas drugiej fazy wtrysku [ms]	88,2	89,5	89,0	89,1	87,9	89,9
Profil próżni 1 [mBar]	1190,9	1197,5	1182,3	1154,4	1037	1384
V2xVp2	376320,5	472592,8	431653,3	644357,1	75900	870539
Przepływ chłodzenia tłoka [l]	22,6	19,7	22,7	20,6	14	26
Przepływ w obwodzie chłodzenia 15 [l]	26,1	26,9	26,3	26,4	25	28
Przepływ w obwodzie chłodzenia 17 [l]	26,4	26,3	22,6	27,0	20,0	36
Przepływ w obwodzie chłodzenia 6 [l]	29,2	30,9	29,8	29,2	26	33
Suw docisku po multiplikacji [mm]	19,1	17,9	19,1	18,4	17	20
Temperatura chłodzenia tłoka [°C]	30,5	30,8	30,4	30,0	27	35
Temperatura stopu [°C]	681,3	682,6	679,4	676,4	669,9	689,2
Temperatura termoregulatora 3.2 [°C]	148,2	151,1	151,3	148,6	144	156
Temperatura tulei 2 [°C]	215,1	225,8	217,3	221,7	205,0	235
Temperatura w obwodzie chłodzenia 1 [°C]	33,9	34,8	34,9	35,0	29	39
Temperatura w obwodzie chłodzenia 14 [°C]	32,4	33,1	32,1	32,4	31	34
Temperatura w obwodzie chłodzenia 15 [°C]	34,1	34,6	33,4	34,6	32	36
Temperatura w obwodzie chłodzenia 17 [°C]	28,6	29,6	28,0	31,8	25	35
Temperatura w obwodzie chłodzenia 7 [°C]	28,5	28,8	28,7	29,2	27	30
Temperatura wody miejskiej [°C]	22,7	23,8	21,5	23,4	18,0	27
Wartość próżni 1 [mBar]	392,4	324,2	406,3	393,0	138	599

W przypadku wielowymiarowej optymalizacji zbioru 3, ustalonego wg. kr. K-W Solver nie mógł znaleźć dopuszczalnego rozwiązania:

- dla sieci z 70% wartości w zbiorze uczącym, 15% w zbiorze walidacyjnym i 15% w zbiorze testującym, z 7 i 14 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu.

Tab. 5.118.: Wyniki wielowymiarowej optymalizacji zbioru 3, ustalonego wg. kr. odwróconego K-W i ANOVA, dla sieci z 100% wartości w zbiorze uczącym, z 21 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Cisnienie wody obiegowej [Bar]	2,2	2,5	2,4	2,4	2	3
Czas pierwszej fazy wtrysku [ms]	2240,1	2281,4	2256,5	2286,6	2186	2333
Czas cyklu [s]	96,8	121,5	109,7	106,6	78,2	172,6
Czas cyklu smarowania [s]	28,2	26,7	28,5	26,3	22,4	31,5
Czas dozowania stopu [s]	29,5	27,3	15,2	21,6	10,9	33
Czas dozowania stopu 2 [s]	61,8	83,9	82,5	84,1	53,8	106,6
Czas krzepnięcia t2 [s]	10,4	10,6	10,2	10,3	10	11
Czas przedmuchu [s]	10,8	7,4	11,0	7,4	6,3	11,7
Czas smarowania [s]	6,9	6,8	6,9	7,1	5,1	9,3
Filtr próżni 1 [mBar]	1439,0	1467,9	1419,0	1485,7	1259	1613
Grubość piętki układu wlewowego [mm]	39,7	36,1	38,0	38,8	32	45
Koncentrat [%]	2,3	2,3	2,3	2,2	1,9	2,7
Cisnienie maksymalne [Bar]	341,7	343,1	342,4	342,5	339	346
Prędkość wtrysku maksymalna [m/s]	5,9	5,9	5,9	5,9	5,8	6
Opóźnienie multiplikacji [ms]	172,3	171,9	171,6	171,5	168	176
Stała temperatura chłodzenia płyty [°C]	28,2	29,6	29,3	29,4	27	32
Poziom stopu w piecu podgrzewczym [mm]	206,0	261,9	337,1	339,8	0	600
Poziom wody w strumieniu chłodzącym [mm]	257,7	270,6	230,8	252,7	200,0	298
Czas drugiej fazy wtrysku [ms]	89,4	88,9	88,6	89,4	87,9	89,9

Profil próżni 1 [mBar]	1184,3	1215,5	1098,7	1288,8	1037	1384
V2xVp2	483497,4	577698,6	310240,5	475940,1	75900	870539
Przepływ chłodzenia tłoka [l]	20,0	20,7	17,8	18,2	14	26
Przepływ w obwodzie chłodzenia 1 [l]	26,5	25,4	25,5	25,6	23	28
Przepływ w obwodzie chłodzenia 13 [l]	17,9	18,4	16,4	17,0	15,0	20
Przepływ w obwodzie chłodzenia 14 [l]	27,1	27,5	27,6	27,8	26	29
Przepływ w obwodzie chłodzenia 15 [l]	25,7	26,1	26,0	26,7	25	28
Przepływ w obwodzie chłodzenia 17 [l]	26,7	26,6	27,3	26,9	20	36
Przepływ w obwodzie chłodzenia 17 [l]	22,7	23,2	22,8	23,6	21	25
Przepływ w obwodzie chłodzenia 6 [l]	29,2	29,0	28,4	28,6	26	33
Prędkość we wlewach doprowadzających [m/s]	38,8	38,5	38,4	38,5	37,7	39,4
Suw docisku po multiplikacji [mm]	18,1	17,8	18,6	17,8	17	20
Temperatura chłodzenia tłoka [°C]	32,4	30,6	30,1	29,3	27,0	35
Temperatura stopu [°C]	679,2	680,1	677,8	679,6	669,9	689,2
Temperatura termoregulatora 2.1 [°C]	70,8	70,7	70,5	71,1	67	75
Temperatura termoregulatora 3.2 [°C]	149,1	150,7	148,9	153,6	144	156
Temperatura tulei 2 [°C]	219,8	221,4	217,6	213,6	205	235
Temperatura tulei 3 [°C]	222,5	226,4	209,7	222,7	182	256
Temperatura w obwodzie chłodzenia 1 [°C]	34,4	33,2	33,9	34,7	29,0	39
Temperatura w obwodzie chłodzenia 13 [°C]	37,2	35,9	34,3	36,4	32	40
Temperatura w obwodzie chłodzenia 14 [°C]	32,5	32,5	31,8	32,5	31	34
Temperatura w obwodzie chłodzenia 15 [°C]	35,0	34,0	34,0	34,0	32	36
Temperatura w obwodzie chłodzenia 17 [°C]	28,7	29,9	27,6	30,6	25	35
Temperatura w obwodzie chłodzenia 7 [°C]	28,5	28,9	28,5	28,2	27	30
Temperatura wody miejskiej [°C]	23,4	23,4	21,8	22,8	18,0	27
Wartość próżni 1 [mBar]	467,3	327,5	348,2	304,1	138	599

W przypadku wielowymiarowej optymalizacji zbioru 3, ustalonego wg. kr. K-W odwróconego i ANOVA, Solver nie mógł znaleźć dopuszczalnego rozwiązania:

- dla sieci z 100% wartości w zbiorze uczącym, z 23 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu.

Tab. 5.119.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji tangensooidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Czas cyklu smarowania [s]	27,4	26,2	27,9	25,2	22,5	31,5
Czas krzepnięcia t2 [s]	10,6	10,2	10,7	10,3	10	11
Czas przedmuchu [s]	7,2	9,1	8,7	10,2	6,3	11,7
Czas smarowania [s]	6,7	7,9	6,6	7,5	5,1	9,3
Stała temperatura chłodzenia płyty [°C]	28,5	28,7	29,0	30,4	27	32
Poziom stopu w piecu podgrzewczym [mm]	372,4	373,2	410,5	354,4	145	600
V2xVp2	223066,3	350082,0	253880,4	355108,9	106182	650502
Przepływ chłodzenia tłoka [l]	19,0	20,5	21,2	20,1	14	26

Przepływ w obwodzie chłodzenia 1 [l]	26,6	24,5	25,6	24,4	23	28
Przepływ w obwodzie chłodzenia 13 [l]	17,9	17,5	17,4	18,5	15	20
Przepływ w obwodzie chłodzenia 14 [l]	27,1	27,2	27,5	27,0	26	29
Przepływ w obwodzie chłodzenia 15 [l]	26,7	26,9	26,7	27,2	25,0	28
Przepływ w obwodzie chłodzenia 20 [l]	22,4	23,9	23,0	23,7	21	25
Temperatura tulei 2 [°C]	221,6	216,2	219,9	221,4	209	232
Temperatura w obwodzie chłodzenia 17 [°C]	30,1	31,5	29,7	28,5	26	35
Wartość próżni 1 [mBar]	351,9	382,8	347,5	380,1	152	534

Tab. 5.120.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 4 neuronami w warstwie ukrytej i funkcją aktywacji tangensooidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Czas cyklu smarowania [s]	28,5	24,0	27,9	28,3	22,5	31,5
Czas krzepnięcia t2 [s]	10,4	10,4	10,6	10,2	10	11
Czas przedmuchu [s]	9,8	10,0	9,9	10,4	6,3	11,7
Czas smarowania [s]	7,8	7,2	8,0	8,1	5,1	9,3
Stała temperatura chłodzenia płyty [°C]	29,5	29,9	29,6	29,6	27	32
Poziom stopu w piecu podgrzewczym [mm]	400,6	494,6	369,5	396,6	145	600
V2xVp2	445869,4	374795,3	305496,2	499166,8	106182	650502
Przepływ chłodzenia tłoka [l]	19,4	20,0	18,4	17,3	14	26
Przepływ w obwodzie chłodzenia 1 [l]	25,5	23,7	25,7	25,1	23	28
Przepływ w obwodzie chłodzenia 13 [l]	17,2	18,5	17,0	16,9	15	20
Przepływ w obwodzie chłodzenia 14 [l]	28,5	26,3	28,3	27,0	26	29
Przepływ w obwodzie chłodzenia 15 [l]	26,6	25,6	25,5	26,9	25,0	28
Przepływ w obwodzie chłodzenia 20 [l]	22,2	23,4	22,1	23,2	21	25
Temperatura tulei 2 [°C]	220,6	217,0	219,3	217,6	209	232
Temperatura w obwodzie chłodzenia 17 [°C]	28,8	30,9	30,3	31,3	26	35
Wartość próżni 1 [mBar]	405,8	354,2	365,3	404,3	152	534

Tab. 5.121.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 5 neuronami w warstwie ukrytej i funkcją aktywacji tangensooidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Czas cyklu smarowania [s]	27,4	28,6	28,9	27,3	22,5	31,5
Czas krzepnięcia t2 [s]	10,2	10,7	10,0	10,7	10	11
Czas przedmuchu [s]	8,5	8,1	9,2	9,5	6,3	11,7
Czas smarowania [s]	7,3	7,6	7,2	7,2	5,1	9,3
Stała temperatura chłodzenia płyty [°C]	29,8	30,3	29,6	29,3	27	32
Poziom stopu w piecu podgrzewczym [mm]	319,2	190,3	429,2	321,1	145	600
V2xVp2	559367,5	374456,4	490026,4	406752,7	106182	650502
Przepływ chłodzenia tłoka [l]	22,4	18,4	21,7	17,7	14	26
Przepływ w obwodzie chłodzenia 1 [l]	25,9	25,5	24,1	27,0	23	28
Przepływ w obwodzie chłodzenia 13 [l]	18,0	18,6	18,0	17,1	15	20
Przepływ w obwodzie chłodzenia 14 [l]	27,3	27,8	27,2	28,4	26	29

Przepływ w obwodzie chłodzenia 15 [l]	26,1	26,6	25,8	26,6	25,0	28
Przepływ w obwodzie chłodzenia 20 [l]	23,1	23,5	22,4	23,3	21	25
Temperatura tulei 2 [°C]	225,0	221,4	222,3	223,8	209	232
Temperatura w obwodzie chłodzenia 17 [°C]	32,0	30,5	29,9	30,0	26	35
Wartość próżni 1 [mBar]	311,9	360,0	290,9	421,2	152	534

Tab. 5.122.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. K-W, dla sieci z 90% wartości w zbiorze uczącym i 10% w testującym, z 3 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Czas cyklu smarowania [s]	27,6	26,9	26,5	26,5	22,5	31,5
Czas krzepnięcia t2 [s]	10,3	10,9	10,1	10,2	10	11
Czas przedmuchu [s]	10,2	8,7	8,1	9,5	6,3	11,7
Czas smarowania [s]	7,7	7,8	5,9	8,1	5,1	9,3
Stała temperatura chłodzenia płyty [°C]	28,6	28,9	28,8	30,4	27	32
Poziom stopu w piecu podgrzewczym [mm]	467,1	272,4	480,2	451,2	145	600
V2xVp2	308761,5	395909,3	249079,9	411935,2	106182	650502
Przepływ chłodzenia tłoka [l]	16,3	17,4	16,2	21,0	14	26
Przepływ w obwodzie chłodzenia 1 [l]	26,9	27,3	26,9	25,8	23	28
Przepływ w obwodzie chłodzenia 13 [l]	17,6	16,5	17,8	18,5	15	20
Przepływ w obwodzie chłodzenia 14 [l]	28,9	28,0	28,4	27,9	26	29
Przepływ w obwodzie chłodzenia 15 [l]	27,4	26,5	26,6	27,3	25,0	28
Przepływ w obwodzie chłodzenia 20 [l]	21,7	22,1	21,5	21,6	21	25
Temperatura tulei 2 [°C]	223,5	220,3	220,2	216,5	209	232
Temperatura w obwodzie chłodzenia 17 [°C]	29,4	30,6	31,7	30,4	26	35
Wartość próżni 1 [mBar]	270,9	441,1	310,0	321,4	152	534

Tab. 5.123.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. K-W, dla sieci z 90% wartości w zbiorze uczącym i 10% w testującym, z 4 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Czas cyklu smarowania [s]	25,8	27,0	29,1	22,5	22,5	31,5
Czas krzepnięcia t2 [s]	10,6	10,2	10,3	10,0	10	11
Czas przedmuchu [s]	8,7	9,3	9,2	6,3	6,3	11,7
Czas smarowania [s]	7,9	6,8	5,8	5,1	5,1	9,3
Stała temperatura chłodzenia płyty [°C]	28,3	30,5	28,8	27,0	27	32
Poziom stopu w piecu podgrzewczym [mm]	472,4	443,9	294,9	145,0	145	600
V2xVp2	516944,2	268098,9	392647,5	106182,0	106182	650502
Przepływ chłodzenia tłoka [l]	18,7	22,0	16,1	14,0	14	26
Przepływ w obwodzie chłodzenia 1 [l]	25,5	23,7	26,1	23,0	23	28
Przepływ w obwodzie chłodzenia 13 [l]	18,0	17,4	16,7	15,0	15	20
Przepływ w obwodzie chłodzenia 14 [l]	28,2	27,4	27,4	26,0	26	29
Przepływ w obwodzie chłodzenia 15 [l]	26,4	27,0	27,4	25,0	25,0	28
Przepływ w obwodzie chłodzenia 20 [l]	23,1	24,2	22,6	21,0	21	25
Temperatura tulei 2 [°C]	221,5	220,5	222,9	209,0	209	232
Temperatura w obwodzie chłodzenia 17 [°C]	30,5	29,9	30,9	26,0	26	35
Wartość próżni 1 [mBar]	370,2	392,4	335,9	152,0	152	534

Tab. 5.124.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Czas cyklu smarowania [s]	27,2	27,6	28,2	27,3	22,5	31,5
Czas krzepnięcia t2 [s]	10,4	10,4	10,7	10,4	10	11
Czas przedmuchu [s]	8,7	9,3	9,7	8,7	6,3	11,7
Czas smarowania [s]	7,5	7,1	7,4	7,9	5,1	9,3
Stała temperatura chłodzenia płyty [°C]	30,6	27,9	30,6	28,4	27	32
Poziom stopu w piecu podgrzewczym [mm]	303,9	387,6	406,3	455,7	145	600
V2xVp2	330312,8	337179,5	462937,9	496844,4	106182	650502
Przepływ chłodzenia tłoka [l]	21,0	17,9	21,4	19,4	14	26
Przepływ w obwodzie chłodzenia 1 [l]	26,0	26,0	24,6	24,4	23	28
Przepływ w obwodzie chłodzenia 13 [l]	17,4	17,8	16,7	18,1	15	20
Przepływ w obwodzie chłodzenia 14 [l]	28,5	28,4	27,0	27,8	26	29
Przepływ w obwodzie chłodzenia 15 [l]	27,1	26,8	26,5	26,6	25,0	28
Przepływ w obwodzie chłodzenia 20 [l]	22,6	21,6	21,9	22,7	21	25
Temperatura tulei 2 [°C]	221,8	218,0	223,5	221,9	209	232
Temperatura w obwodzie chłodzenia 17 [°C]	29,1	29,1	32,6	32,3	26	35
Wartość próżni 1 [mBar]	320,2	332,2	279,6	290,1	152	534

Tab. 5.125.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 3 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Czas cyklu smarowania [s]	25,9	27,2	27,1	28,1	22,5	31,5
Czas krzepnięcia t2 [s]	10,5	10,2	10,4	10,5	10	11
Czas przedmuchu [s]	8,6	8,4	9,0	9,3	6,3	11,7
Czas smarowania [s]	6,9	7,4	7,8	7,6	5,1	9,3
Stała temperatura chłodzenia płyty [°C]	29,0	29,0	29,0	29,9	27	32
Poziom stopu w piecu podgrzewczym [mm]	380,2	354,2	310,6	393,6	145	600
V2xVp2	356126,2	326865,0	333704,2	408109,7	106182	650502
Przepływ chłodzenia tłoka [l]	17,0	18,5	22,3	19,8	14	26
Przepływ w obwodzie chłodzenia 1 [l]	25,3	25,8	24,8	25,8	23	28
Przepływ w obwodzie chłodzenia 13 [l]	16,6	16,3	16,5	18,0	15	20
Przepływ w obwodzie chłodzenia 14 [l]	27,8	27,4	27,2	28,1	26	29
Przepływ w obwodzie chłodzenia 15 [l]	27,1	26,7	26,3	26,8	25,0	28
Przepływ w obwodzie chłodzenia 20 [l]	23,5	22,3	22,8	22,8	21	25
Temperatura tulei 2 [°C]	225,7	224,2	223,4	221,5	209	232
Temperatura w obwodzie chłodzenia 17 [°C]	31,1	31,4	31,6	32,3	26	35
Wartość próżni 1 [mBar]	394,7	293,6	225,7	369,6	152	534

Tab. 5.126.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 4 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Czas cyklu smarowania [s]	27,7	27,0	27,4	28,0	22,5	31,5
Czas krzepnięcia t2 [s]	10,5	10,2	10,2	10,5	10	11
Czas przedmuchu [s]	9,2	8,4	9,4	10,1	6,3	11,7
Czas smarowania [s]	7,6	6,6	7,8	7,0	5,1	9,3
Stała temperatura chłodzenia płyty [°C]	29,1	29,0	30,0	28,9	27	32
Poziom stopu w piecu podgrzewczym [mm]	307,1	361,8	377,8	287,5	145	600
V2xVp2	308025,0	436490,9	503890,2	333389,5	106182	650502
Przepływ chłodzenia tłoka [l]	19,6	16,7	19,1	19,2	14	26
Przepływ w obwodzie chłodzenia 1 [l]	26,4	26,4	25,5	25,6	23	28
Przepływ w obwodzie chłodzenia 13 [l]	16,7	17,0	17,8	17,7	15	20
Przepływ w obwodzie chłodzenia 14 [l]	28,2	28,4	27,7	27,9	26	29
Przepływ w obwodzie chłodzenia 15 [l]	27,0	26,8	26,6	26,6	25,0	28
Przepływ w obwodzie chłodzenia 20 [l]	22,7	22,7	23,4	22,7	21	25
Temperatura tulei 2 [°C]	217,6	223,2	218,3	224,3	209	232
Temperatura w obwodzie chłodzenia 17 [°C]	29,6	30,5	30,9	29,8	26	35
Wartość próżni 1 [mBar]	275,3	340,6	321,8	320,3	152	534

Tab. 5.127.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. odwróconego K-W, dla sieci z 100% wartości w zbiorze uczącym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji tangensooidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Czas cyklu smarowania [s]	27,6	25,8	27,1	27,7	22,5	31,5
CtxDt2	6360,0	14185,3	9310,4	12936,3	4820,3	17642,3
Czas krzepnięcia t2 [s]	10,5	10,4	10,5	10,4	10	11
Czas przedmuchu [s]	8,3	8,7	8,2	9,1	6,3	11,7
Czas smarowania [s]	7,3	7,1	6,8	7,9	5,1	9,3
Filtr próżni 1 [mBar]	1398,8	1430,8	1394,5	1455,6	1259	1613
Grubość piętki układu wlewowego [mm]	41,2	38,1	40,7	41,3	32	45
Cisnienie maksymalne [Bar]	341,7	340,8	343,2	342,8	339	345
Prędkość wtrysku maksymalna [m/s]	5,9	5,9	5,9	5,9	5,8	6
Opóźnienie multiplikacji [ms]	172,9	172,4	172,6	171,6	168	176
Stała temperatura chłodzenia płyty [°C]	30,8	30,4	30,4	28,9	27	32
V2xVp2	213849,8	453349,8	303422,7	422436,2	106182,0	650502
Przepływ chłodzenia tłoka [l]	19,2	19,9	20,2	18,4	14	26
Przepływ w obwodzie chłodzenia 1 [l]	25,2	26,4	24,6	25,5	23	28
Przepływ w obwodzie chłodzenia 13 [l]	17,4	18,9	16,9	17,1	15	20
Przepływ w obwodzie chłodzenia 14 [l]	27,1	27,9	27,3	27,3	26	29
Przepływ w obwodzie chłodzenia 15 [l]	26,4	27,0	26,9	26,4	25	28
Przepływ w obwodzie chłodzenia 20 [l]	23,9	22,6	22,9	23,2	21	25
Temperatura chłodzenia tłoka [°C]	30,6	32,1	29,4	32,4	28	35
Temperatura tulei 2 [°C]	224,7	221,0	215,7	223,5	209	232
Temperatura w obwodzie chłodzenia 1 [°C]	31,9	33,6	34,1	34,0	29	39
Temperatura w obwodzie chłodzenia 17 [°C]	30,1	30,7	31,2	30,3	26,0	35
Temperatura w obwodzie chłodzenia 7 [°C]	28,8	27,3	28,5	28,3	27	30
Temperatura wody miejskiej [°C]	23,9	24,1	24,2	23,9	23	25
Wartość próżni 1 [mBar]	364,1	351,3	312,4	292,8	152	534

Tab. 5.128.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. odwróconego K-W, dla sieci z 100% wartości w zbiorze uczącym, z 4 neuronami w warstwie ukrytej i funkcją aktywacji tangensooidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Czas cyklu smarowania [s]	26,8	26,0	28,0	29,5	22,5	31,5
CtxDt2	12412,9	9981,4	8116,0	7660,1	4820,3	17642,3
Czas krzepnięcia t2 [s]	10,4	10,4	10,6	10,4	10	11
Czas przedmuchu [s]	8,3	9,9	7,3	8,6	6,3	11,7
Czas smarowania [s]	7,4	7,9	6,4	7,2	5,1	9,3
Filtr próżni 1 [mBar]	1425,1	1461,9	1449,3	1416,2	1259	1613
Grubość piętki układu wlewowego [mm]	38,0	37,3	38,1	41,0	32	45
Ciśnienie maksymalne [Bar]	342,5	343,4	341,9	341,8	339	345
Prędkość wtrysku maksymalna [m/s]	5,9	5,8	5,8	5,9	5,8	6
Opóźnienie multiplikacji [ms]	174,0	175,8	173,7	171,4	168	176
Stala temperatura chłodzenia płyty [°C]	29,6	30,2	29,8	30,0	27	32
V2xVp2	298984,8	331876,9	256446,5	421930,4	106182,0	650502
Przepływ chłodzenia tłoka [l]	21,3	21,1	20,3	19,2	14	26
Przepływ w obwodzie chłodzenia 1 [l]	25,4	25,6	25,7	25,1	23	28
Przepływ w obwodzie chłodzenia 13 [l]	16,9	18,8	17,4	17,7	15	20
Przepływ w obwodzie chłodzenia 14 [l]	27,5	27,1	27,0	27,8	26	29
Przepływ w obwodzie chłodzenia 15 [l]	26,7	27,3	26,6	26,6	25	28
Przepływ w obwodzie chłodzenia 20 [l]	22,4	22,7	22,2	22,5	21	25
Temperatura chłodzenia tłoka [°C]	31,5	29,8	30,1	30,4	28	35
Temperatura tulei 2 [°C]	220,2	213,7	217,4	218,2	209	232
Temperatura w obwodzie chłodzenia 1 [°C]	33,9	34,9	33,1	33,9	29	39
Temperatura w obwodzie chłodzenia 17 [°C]	29,6	30,5	28,8	30,0	26,0	35
Temperatura w obwodzie chłodzenia 7 [°C]	28,3	28,7	28,2	28,6	27	30
Temperatura wody miejskiej [°C]	24,5	24,2	23,8	24,0	23	25
Wartość próżni 1 [mBar]	378,2	326,4	289,6	338,9	152	534

W przypadku wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. K-W odwróconego, Solver nie mógł znaleźć dopuszczalnego rozwiązania:

- dla sieci z 100% wartości w zbiorze uczącym, z 5 neuronami w warstwie ukrytej i funkcją aktywacji tangensooidalną na wyjściu,
- dla sieci z 100% wartości w zbiorze uczącym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu,
- dla sieci z 100% wartości w zbiorze uczącym, z 3 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu,
- dla sieci z 100% wartości w zbiorze uczącym, z 4 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu.

Tab. 5.129.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. ANOVA, dla sieci z 100% wartości w zbiorze uczącym, z 4 neuronami w warstwie ukrytej i funkcją aktywacji tangensooidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Czas cyklu smarowania [s]	27,5	28,8	25,3	28,5	22,5	31,5
CtxDt2	9887,0	14247,5	7509,3	11446,9	4820,3	17642,3
Czas krzepnięcia t2 [s]	10,4	10,4	10,5	10,6	10	11
Czas przedmuchu [s]	8,0	9,7	9,1	8,7	6,3	11,7
Czas smarowania [s]	7,1	6,2	5,7	6,3	5,1	9,3
Filtr próżni 1 [mBar]	1387,8	1422,8	1360,6	1510,2	1259	1613
V2xVp2	193590,0	260699,3	308162,4	437917,1	106182	650502
Grubość piętki układu wlewowego [mm]	39,4	37,3	40,2	35,3	32	45
Ciśnienie maksymalne [Bar]	343,3	340,0	341,9	341,2	339	345
Prędkość wtrysku maksymalna [m/s]	5,9	5,8	5,9	5,9	5,8	6
Opóźnienie multiplikacji [ms]	172,9	169,2	171,7	173,8	168	176
Stała temperatura chłodzenia płyty [°C]	29,8	29,7	29,8	28,9	27,0	32
Przepływ chłodzenia tłoka [l]	22,8	20,0	21,1	20,4	14	26
Przepływ w obwodzie chłodzenia 1 [l]	25,0	25,9	26,2	25,4	23	28
Przepływ w obwodzie chłodzenia 13 [l]	17,2	17,9	16,3	18,0	15	20
Przepływ w obwodzie chłodzenia 14 [l]	27,6	27,4	27,0	27,8	26	29
Przepływ w obwodzie chłodzenia 15 [l]	26,8	26,4	26,7	26,3	25	28
Przepływ w obwodzie chłodzenia 20 [l]	22,5	22,4	22,8	22,6	21	25
Temperatura chłodzenia tłoka [°C]	30,8	32,6	31,1	29,9	28	35
Temperatura stopu [°C]	675,7	682,7	677,8	677,7	670,9	688,5
Temperatura tulei 2 [°C]	217,1	221,1	222,4	220,2	209	232
Temperatura w obwodzie chłodzenia 1 [°C]	35,8	34,1	35,6	31,8	29,0	39
Temperatura w obwodzie chłodzenia 17 [°C]	29,8	31,5	29,8	29,1	26	35
Temperatura w obwodzie chłodzenia 7 [°C]	28,8	28,3	28,2	28,8	27	30
Temperatura wody miejskiej [°C]	24,1	24,1	24,1	24,2	23	25
Wartość próżni 1 [mBar]	263,9	390,8	295,6	387,3	152	534

Tab. 5.130.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. ANOVA, dla sieci z 100% wartości w zbiorze uczącym, z 5 neuronami w warstwie ukrytej i funkcją aktywacji tangensooidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Czas cyklu smarowania [s]	27,3	24,9	25,6	26,6	22,5	31,5
CtxDt2	12159,9	12118,2	9572,3	13749,4	4820,3	17642,3
Czas krzepnięcia t2 [s]	10,6	10,6	10,6	10,5	10	11
Czas przedmuchu [s]	9,8	7,2	8,7	9,5	6,3	11,7
Czas smarowania [s]	6,8	9,0	7,2	7,4	5,1	9,3
Filtr próżni 1 [mBar]	1463,7	1304,2	1482,4	1458,7	1259	1613
V2xVp2	467304,2	458864,5	475087,8	500348,1	106182	650502
Grubość piętki układu wlewowego [mm]	37,8	36,2	40,7	35,2	32	45
Ciśnienie maksymalne [Bar]	344,0	343,9	341,4	341,1	339	345
Prędkość wtrysku maksymalna [m/s]	5,9	6,0	5,9	5,9	5,8	6
Opóźnienie multiplikacji [ms]	171,9	174,4	172,0	171,1	168	176
Stała temperatura chłodzenia płyty [°C]	30,3	31,4	29,3	27,5	27,0	32
Przepływ chłodzenia tłoka [l]	17,6	21,7	17,8	21,8	14	26

Przepływ w obwodzie chłodzenia 1 [l]	25,4	24,0	25,4	25,0	23	28
Przepływ w obwodzie chłodzenia 13 [l]	18,5	17,7	17,8	17,7	15	20
Przepływ w obwodzie chłodzenia 14 [l]	27,2	28,2	27,6	28,1	26	29
Przepływ w obwodzie chłodzenia 15 [l]	25,6	25,5	25,6	26,6	25	28
Przepływ w obwodzie chłodzenia 20 [l]	23,4	23,9	23,3	23,3	21	25
Temperatura chłodzenia tłoka [°C]	31,1	29,8	30,9	30,4	28	35
Temperatura stopu [°C]	677,8	674,0	680,6	682,8	670,9	688,5
Temperatura tulei 2 [°C]	215,4	214,7	224,1	220,3	209	232
Temperatura w obwodzie chłodzenia 1 [°C]	34,0	34,5	33,1	33,6	29,0	39
Temperatura w obwodzie chłodzenia 17 [°C]	29,7	27,9	30,7	30,0	26	35
Temperatura w obwodzie chłodzenia 7 [°C]	28,7	27,5	28,6	28,3	27	30
Temperatura wody miejskiej [°C]	24,3	24,2	24,1	24,1	23	25
Wartość próżni 1 [mBar]	404,7	344,3	403,8	330,7	152	534

Tab. 5.131.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. ANOVA, dla sieci z 90% wartości w zbiorze uczącym i 10% w testującym, z 4 neuronami w warstwie ukrytej i funkcją aktywacji tangensooidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Czas cyklu smarowania [s]	27,2	28,2	26,3	25,9	22,5	31,5
CtxDt2	7372,4	10869,3	7540,2	11101,2	4820,3	17642,3
Czas krzepnięcia t2 [s]	10,3	10,5	10,6	10,6	10	11
Czas przedmuchu [s]	9,2	8,7	8,1	9,8	6,3	11,7
Czas smarowania [s]	7,3	8,2	6,5	6,8	5,1	9,3
Filtr próżni 1 [mBar]	1464,6	1335,1	1483,9	1464,0	1259	1613
V2xVp2	245988,3	254517,0	404911,3	416997,2	106182	650502
Grubość piętki układu wlewowego [mm]	41,6	36,0	40,5	39,6	32	45
Ciśnienie maksymalne [Bar]	342,1	341,6	342,4	340,9	339	345
Prędkość wtrysku maksymalna [m/s]	5,9	5,9	5,9	5,9	5,8	6
Opóźnienie multiplikacji [ms]	174,0	172,2	173,2	173,2	168	176
Stała temperatura chłodzenia płyty [°C]	29,4	30,5	29,7	29,2	27,0	32
Przepływ chłodzenia tłoka [l]	22,7	19,0	19,9	20,5	14	26
Przepływ w obwodzie chłodzenia 1 [l]	25,6	25,2	25,1	26,0	23	28
Przepływ w obwodzie chłodzenia 13 [l]	17,4	17,6	16,9	18,1	15	20
Przepływ w obwodzie chłodzenia 14 [l]	27,7	27,7	26,9	27,3	26	29
Przepływ w obwodzie chłodzenia 15 [l]	26,5	26,3	26,7	26,4	25	28
Przepływ w obwodzie chłodzenia 20 [l]	23,6	23,2	23,2	23,1	21	25
Temperatura chłodzenia tłoka [°C]	28,9	31,4	30,4	33,1	28	35
Temperatura stopu [°C]	678,2	684,7	678,1	676,7	670,9	688,5
Temperatura tulei 2 [°C]	224,8	218,1	218,9	214,2	209	232
Temperatura w obwodzie chłodzenia 1 [°C]	32,5	32,8	33,9	34,0	29,0	39
Temperatura w obwodzie chłodzenia 17 [°C]	30,6	29,4	30,5	30,5	26	35
Temperatura w obwodzie chłodzenia 7 [°C]	28,7	28,5	28,1	28,2	27	30
Temperatura wody miejskiej [°C]	24,1	24,0	24,4	23,7	23	25
Wartość próżni 1 [mBar]	289,6	416,7	355,1	344,2	152	534

Tab. 5.132.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. ANOVA, dla sieci z 100% wartości w zbiorze uczącym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Czas cyklu smarowania [s]	27,1	26,4	28,4	27,1	22,5	31,5
CtxDt2	12001,0	13143,7	13109,1	12052,8	4820,3	17642,3
Czas krzepnięcia t2 [s]	10,5	10,6	10,5	10,5	10	11
Czas przedmuchu [s]	7,8	8,7	8,1	8,1	6,3	11,7
Czas smarowania [s]	7,5	6,7	7,1	6,9	5,1	9,3
Filtr próżni 1 [mBar]	1438,3	1396,2	1457,5	1423,5	1259	1613
V2xVp2	342087,3	366957,0	371670,9	377741,2	106182	650502
Grubość piętki układu wlewowego [mm]	37,9	41,7	36,4	39,0	32	45
Ciśnienie maksymalne [Bar]	340,3	343,6	342,1	342,1	339	345
Prędkość wtrysku maksymalna [m/s]	5,9	5,9	5,8	5,8	5,8	6
Opóźnienie multiplikacji [ms]	170,6	174,2	172,5	171,5	168	176
Stała temperatura chłodzenia płyty [°C]	30,7	29,0	28,8	29,7	27,0	32
Przepływ chłodzenia tłoka [l]	20,7	19,9	21,6	20,2	14	26
Przepływ w obwodzie chłodzenia 1 [l]	24,2	25,7	26,0	24,6	23	28
Przepływ w obwodzie chłodzenia 13 [l]	17,3	17,6	17,7	17,3	15	20
Przepływ w obwodzie chłodzenia 14 [l]	27,5	27,6	27,8	27,7	26	29
Przepływ w obwodzie chłodzenia 15 [l]	26,7	26,0	26,2	26,7	25	28
Przepływ w obwodzie chłodzenia 20 [l]	24,1	23,1	23,1	23,3	21	25
Temperatura chłodzenia tłoka [°C]	29,8	30,4	31,1	31,2	28	35
Temperatura stopu [°C]	683,4	675,5	679,8	678,8	670,9	688,5
Temperatura tulei 2 [°C]	221,8	222,1	225,4	219,6	209	232
Temperatura w obwodzie chłodzenia 1 [°C]	33,3	34,5	36,3	33,6	29,0	39
Temperatura w obwodzie chłodzenia 17 [°C]	28,6	32,2	31,3	32,2	26	35
Temperatura w obwodzie chłodzenia 7 [°C]	28,2	28,4	28,7	28,3	27	30
Temperatura wody miejskiej [°C]	23,4	23,9	23,7	23,8	23	25
Wartość próżni 1 [mBar]	410,9	324,0	338,5	294,5	152	534

W przypadku wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. ANOVA, Solver nie mógł znaleźć dopuszczalnego rozwiązania:

- dla sieci z 100% wartości w zbiorze uczącym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji tangensooidalną na wyjściu,
- dla sieci z 90% wartości w zbiorze uczącym, 10% w testującym z 3 neuronami w warstwie ukrytej i funkcją aktywacji tangensooidalną na wyjściu,
- dla sieci z 100% wartości w zbiorze uczącym, z 3 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu,
- dla sieci z 100% wartości w zbiorze uczącym, z 4 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu.

Tab. 5.132.: Wyniki wielowymiarowej optymalizacji zbioru 5, ustalonego wg. kr. K-W, dla sieci z 90% wartości w zbiorze uczącym, 10 % w testującym, z 3 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Czas krzepnięcia t2 [s]	10,2	10,4	10,0	10,5	10	11
Ciśnienie maksymalne [Bar]	342,4	341,4	342,0	342,2	339	345
Profil próżni 1 [mBar]	1135,1	1175,1	1214,3	1145,5	1055	1298
V2xVp2	242309,4	388547,7	401939,1	252461,4	82740	650502
Przepływ chłodzenia tłoka [l]	19,9	16,8	20,8	15,8	14	26
Przepływ w obwodzie chłodzenia 1 [l]	24,3	26,8	25,9	27,8	23	28
Przepływ w obwodzie chłodzenia 13 [l]	16,6	17,7	18,5	16,1	15	20
Przepływ w obwodzie chłodzenia 15 [l]	26,7	26,8	26,6	27,3	25	28
Temperatura tulei 2 [°C]	225,3	232,0	218,9	224,1	211	232
Temperatura w obwodzie chłodzenia 14 [°C]	32,2	33,1	32,1	32,0	31	34
Zużycie smaru [l]	0,6	0,6	0,3	0,1	0	2

W przypadku wielowymiarowej optymalizacji zbioru 5, ustalonego wg. kr. K-W, Solver nie mógł znaleźć dopuszczalnego rozwiązania:

- dla sieci z 100% wartości w zbiorze uczącym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu,
- dla sieci z 100% wartości w zbiorze uczącym, z 3 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu,
- dla sieci z 100% wartości w zbiorze uczącym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu,
- dla sieci z 90% wartości w zbiorze uczącym, 10% w testującym z 2 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu,
- dla sieci z 90% wartości w zbiorze uczącym, 10% w testującym z 5 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu.

Tab. 5.133.: Wyniki wielowymiarowej optymalizacji zbioru 5, ustalonego wg. kr. odwróconego K-W, dla sieci z 90% wartości w zbiorze uczącym, 10 % w testującym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Czas cyklu [s]	123,3	136,2	149,5	116,8	89,1	172,6
Czas dozowania stopu 2 [s]	75,5	83,3	77,9	77,4	54,1	106,6
Czas krzepnięcia t2 [s]	10,8	10,3	10,6	10,9	10	11
Czas smarowania [s]	7,7	6,1	7,9	6,9	5,1	9,3

Grubość piętki układu wlewowego [mm]	40,8	38,8	38,9	37,2	32	45
Ciśnienie maksymalne [Bar]	341,9	340,7	342,2	341,0	339	345
Opóźnienie multiplikacji [ms]	170,8	170,0	172,5	171,5	168	176
Stała temperatura chłodzenia płyty [°C]	28,7	29,7	29,5	29,2	27	32
Poziom wody w strumieniu chłodzącym [mm]	247,7	238,2	238,4	249,5	200	298
Profil próżni 1 [mBar]	1202,7	1203,9	1139,2	1175,1	1055	1298
V2xVp2	271565,1	385240,6	324558,9	454804,9	82740	650502
Przepływ chłodzenia tłoka [l]	18,5	19,1	17,3	21,5	14,0	26
Przepływ w obwodzie chłodzenia 1 [l]	25,9	25,7	26,1	24,5	23	28
Przepływ w obwodzie chłodzenia 13 [l]	17,7	18,4	17,7	17,4	15	20
Przepływ w obwodzie chłodzenia 14 [l]	26,8	28,1	27,5	27,6	26	29
Przepływ w obwodzie chłodzenia 15 [l]	26,6	26,1	26,6	26,3	25	28
Przepływ w obwodzie chłodzenia 20 [l]	22,8	23,1	23,0	22,7	21	25
Prędkość we wlewach doprowadzających [m/s]	38,4	38,2	38,6	38,7	37,7	39,3
Temperatura chłodzenia tłoka [°C]	32,6	32,4	30,9	30,8	28	35
Temperatura tulei 2 [°C]	221,1	216,2	222,3	219,8	211	232
Temperatura w obwodzie chłodzenia 1 [°C]	33,3	34,6	34,3	35,2	30	39
Temperatura w obwodzie chłodzenia 14 [°C]	32,4	33,0	32,7	32,8	31,0	34
Temperatura w obwodzie chłodzenia 7 [°C]	28,1	27,4	28,2	28,2	27	30
Temperatura wody miejskiej [°C]	24,1	24,0	24,0	23,8	23	25
Wartość próżni 1 [mBar]	274,1	368,7	351,8	373,8	159	552
Zużycie smaru [l]	0,4	0,9	0,9	0,4	0	2

Tab. 5.134.: Wyniki wielowymiarowej optymalizacji zbioru 5, ustalonego wg. kr. odwróconego K-W, dla sieci z 100% wartości w zbiorze uczącym z 2 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Czas cyklu [s]	125,1	132,2	141,7	127,5	89,1	172,6
Czas dozowania stopu 2 [s]	76,6	78,6	70,8	72,9	54,1	106,6
Czas krzepnięcia t2 [s]	10,5	10,6	10,7	10,7	10	11
Czas smarowania [s]	6,8	5,9	6,9	7,8	5,1	9,3
Grubość piętki układu wlewowego [mm]	40,2	36,5	38,4	38,9	32	45
Ciśnienie maksymalne [Bar]	342,2	342,2	342,0	341,9	339	345
Opóźnienie multiplikacji [ms]	172,6	172,0	172,9	172,6	168	176
Stała temperatura chłodzenia płyty [°C]	28,7	29,0	29,7	30,6	27	32
Poziom wody w strumieniu chłodzącym [mm]	257,5	242,1	246,5	235,2	200	298
Profil próżni 1 [mBar]	1208,4	1175,4	1173,0	1200,5	1055	1298
V2xVp2	483258,2	296550,1	419242,1	326483,6	82740	650502
Przepływ chłodzenia tłoka [l]	18,7	21,3	17,9	20,4	14,0	26
Przepływ w obwodzie chłodzenia 1 [l]	25,1	25,1	25,3	25,9	23	28
Przepływ w obwodzie chłodzenia 13 [l]	17,0	17,4	17,1	16,5	15	20
Przepływ w obwodzie chłodzenia 14 [l]	27,4	27,5	27,4	27,5	26	29
Przepływ w obwodzie chłodzenia 15 [l]	27,2	26,0	26,5	26,5	25	28
Przepływ w obwodzie chłodzenia 20 [l]	23,3	24,1	23,2	23,0	21	25
Prędkość we wlewach doprowadzających [m/s]	38,3	38,2	38,3	38,4	37,7	39,3
Temperatura chłodzenia tłoka [°C]	31,1	29,4	31,1	30,6	28	35
Temperatura tulei 2 [°C]	217,5	222,0	220,6	220,0	211	232
Temperatura w obwodzie chłodzenia 1 [°C]	32,3	34,3	35,3	34,0	30	39
Temperatura w obwodzie chłodzenia 14 [°C]	32,5	33,4	32,5	32,8	31,0	34

Temperatura w obwodzie chłodzenia 7 [°C]	28,8	29,0	28,5	27,8	27	30
Temperatura wody miejskiej [°C]	23,7	23,8	24,1	23,9	23	25
Wartość próżni 1 [mBar]	292,8	413,7	291,9	352,8	159	552
Zużycie smaru [l]	0,8	0,4	0,9	1,0	0	2

W przypadku wielowymiarowej optymalizacji zbioru 5, ustalonego wg. kr. odwróconego K-W, Solver nie mógł znaleźć dopuszczalnego rozwiązania:

- dla sieci z 100% wartości w zbiorze uczącym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu,
- dla sieci z 100% wartości w zbiorze uczącym, z 3 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu.

Tab. 5.135.: Wyniki wielowymiarowej optymalizacji zbioru 5, ustalonego wg. kr. ANOVA, dla sieci z 100% wartości w zbiorze uczącym z 2 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu

Nazwa zmiennej niezależnej	MIN, metoda nieliniowa GRG z wielostartem	MAX, metoda nieliniowa GRG z wielostartem	MIN, metoda ewolucyjna	MAX, metoda ewolucyjna	MIN wartość zmiennej niezależnej	MAX wartość zmiennej niezależnej
Czas cyklu smarowania [s]	129,2	127,1	121,1	118,2	89,1	172,6
Czas dozowania stopu 2 [s]	73,9	90,6	78,6	78,2	54,1	106,6
Czas krzepnięcia t2 [s]	10,5	10,6	10,4	10,5	10	11
Czas smarowania [s]	6,9	7,3	6,8	7,0	5,1	9,3
Grubość piętki układu wlewowego [mm]	38,0	36,6	38,5	37,6	32	45
Ciśnienie maksymalne [Bar]	342,6	343,5	343,0	342,6	339	345
Opóźnienie multiplikacji [ms]	171,9	171,4	171,3	170,6	168	176
Stała temperatura chłodzenia płyty [°C]	29,8	30,0	29,5	29,6	27	32
Poziom wody w strumieniu chłodzącym [mm]	244,8	232,1	248,9	250,3	200	298
Profil próżni 1 [mBar]	1172,7	1233,0	1146,7	1163,8	1055	1298
V2xVp2	429876,6	414196,7	359649,2	339142,5	82740	650502
Przepływ chłodzenia tłoka [l]	21,7	19,5	21,7	20,7	14,0	26
Przepływ w obwodzie chłodzenia 13 [l]	18,4	16,8	17,3	17,9	15	20
C1Fx C14F	684,5	660,3	689,2	674,0	598	784
Przepływ w obwodzie chłodzenia 15 [l]	26,4	26,3	26,5	26,5	25	28
Przepływ w obwodzie chłodzenia 20 [l]	23,0	23,2	22,9	22,4	21	25
Przepływ w obwodzie chłodzenia 6 [l]	29,5	30,9	29,5	29,4	26	33
Prędkość we wlewach doprowadzających [m/s]	38,3	38,1	38,7	38,2	37,7	39,3
Temperatura chłodzenia tłoka [°C]	31,4	30,3	31,3	31,6	28	35
Temperatura stopu [°C]	681,8	679,6	676,9	679,8	670,9	689
Temperatura tulei 2 [°C]	221,2	220,6	224,1	222,4	211	232
Temperatura w obwodzie chłodzenia 1 [°C]	35,2	35,8	34,0	35,0	30,0	39
Temperatura w obwodzie chłodzenia 14 [°C]	31,8	32,1	32,6	32,9	31	34
Temperatura w obwodzie chłodzenia 7 [°C]	27,9	28,8	29,0	28,6	27	30
Temperatura wody miejskiej [°C]	23,9	24,3	24,2	24,1	23	25
Wartość próżni 1 [mBar]	423,9	453,7	334,1	363,2	159	552
Zużycie smaru [l]	1,1	0,9	1,1	0,9	0	2

W przypadku wielowymiarowej optymalizacji zbioru 5, ustalonego wg. kr. ANOVA, Solver nie mógł znaleźć dopuszczalnego rozwiązania:


- dla sieci z 100% wartości w zbiorze uczącym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu,
- dla sieci z 100% wartości w zbiorze uczącym, z 3 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu,
- dla sieci z 90% wartości w zbiorze uczącym, z 5 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu.

W niektórych przypadkach Solver nie znalazł wykonalnego rozwiązania. Oznacza to, że nie istnieje żaden zestaw wartości spełniający wszystkie ograniczenia a zadany problem jest niewykonalny. Czyli nie ma limitu wartości funkcji celu, ponieważ wartości komórki celu nie są zbieżne.

5.2.7.2. Omówienie wyników i wnioski


Wyniki analizy przeprowadzonej dla pięciu zbiorów danych według trzech kryteriów wskazują, że w większości przypadków wielowymiarowa optymalizacja parametrów procesu nie ma możliwości zobrazowania co dokładnie wpływa na formowanie się wady w produkcie, w tym przypadku w odlewie. Dokładniej nie jest w stanie określić jakie wartości parametrów procesu wpływają na wytwarzanie wadliwych odlewów.

Mimo to udało się uzyskać w paru przypadkach taką odpowiedź. (rys. od 5.7.7.4 do 5.7.7.8). Na wykresie (rys.5.7.7.4.) należy zwrócić uwagę, że wyższe wartości zmiennej niezależnej - *opóźnienie multiplikacji [ms]* sprzyjają powstawaniu wyższych wartości *przecieku*. Parametr ten jest kluczowym etapem w procesie, którego celem jest zmniejszenie porowatości skurczowej produkowanych odlewów, poprzez wymuszone podawanie ciekłego stopu do krzepnącego odlewu. Parametr ten definiuje moment rozpoczęcia tej fazy procesu i jego znaczenie uzyskane w wyniku modelowania nie jest zaskakujące. Możliwe, że w przypadku wymuszenia podawania metalu, które rozpocznie się za późno może okazać się, że będzie ono nieefektywne z powodu dużej frakcji zakrzepniętego metalu w odlewie. W publikacji [149] ten sam parametr został zidentyfikowany jako statystycznie istotny i wpływający na właściwości materiałowe. Wynik ten sugeruje że parametr ten ma z pewnością duży wpływ na występowanie nieszczelności w odlewach i powinien być bardzo poważnie traktowany przez pracowników odlewni, uznany wręcz za krytyczny z punktu widzenia zarządzania i kontroli jakości.




Rys.5.2.7.4. Wyniki optymalizacji skłonności do powstania wady na podstawie modelu neuronowego dla parametru opóźnienie multiplikacji (szczegóły w Tablicy 5.105)

Drugim wykrytym parametrem była widoczna na wykresie (rys.5.7.7.5.) *temperatura wody miejskiej*. Wyższe wartości zmiennej niezależnej również sprzyjają powstawaniu wyższych wartości *przecieku*, co może mieć związek z niedoskonałością systemu stabilizacji temperatury formy, której rola w powstawaniu porowatości jest dość oczywista.




Rys.5.2.7.5. Wyniki skłonności do powstania wady na podstawie modelu neuronowego dla parametru temperatura wody miejskiej (szczegóły w Tablicy 5.106)

Trzecim wykrytym parametrem był widoczny na wykresie (rys.5.7.7.6.) *czas dozowania stopu 2*. Wyższe wartości zmiennej niezależnej również sprzyjają powstawaniu wyższych wartości *przecieku*, jednak mechanizm tego oddziaływania nie jest jasny. Być może, znaczącą rolę odgrywają tu korelacje z innymi parametrami procesu, co omówiono w p. 5.2.2.1.




Rys.5.2.7.6. Wyniki skłonności do powstania wady na podstawie modelu neuronowego dla parametru czas dozowania stopu 2 (szczegóły w Tablicy 5.108)

Czwartym wykrytym parametrem było widoczne na wykresie (rys.5.7.7.7.) *czas przedmuchu*. W tym przypadku niższe wartości zmiennej niezależnej sprzyjają powstawaniu wyższych wartości *przecieku*. Wykazana zależność pochodzi z optymalizacji modelu zbioru 3, w którym występowała znacząca zmienność wartości *przecieku*, a rozkład zmiennej zależnej był zbliżony do rozkładu normalnego, z zwiększonym występowaniem wartości podwyższonych. Interpretacja wpływu tego parametru nie jest prosta, również dla personelu technicznego odlewni i wymagałaby głębszych analiz i dodatkowych prób.




Rys.5.2.7.7. Wyniki skłonności do powstania wady na podstawie modelu neuronowego dla parametru czas przedmuchu (szczegóły w Tablicy 5.118)

Piątym wykrytym parametrem był widoczny na wykresie (rys.5.7.7.8.) *przepływ w obwodzie chłodzenia 14*. W tym przypadku również niższe wartości zmiennej niezależnej sprzyjają powstawaniu wyższych wartości *przecieku*. Wykazana zależność pochodzi z optymalizacji modelu zbioru 4, który utworzony został celem wykrycia parametrów wpływających na zwiększenie wartości *przecieku* w niepożądanym stopniu. Wydaje się dość oczywiste, że obniżenie intensywności przepływu wody w określonych kanałach, skutkujące zmniejszeniem lokalnej intensywności studzenia odlewu może mieć wpływ na zwiększenie czasu krzepnięcia i koncentrację porowatości odlewu w tym miejscu prowadzącej do nieszczelności.



Rys.5.2.7.8. Wyniki skłonności do powstania wady na podstawie modelu neuronowego dla przepływu w obwodzie chłodzenia 14 (szczegóły w Tabelcy 5.120)

Na rys. 5.2.7.9 pokazano przykład wyników optymalizacji, które nie wskazały jednoznacznego wpływu danej zmiennej procesu na występowanie wady - *przecieku*.



Rys.5.2.7.9. Wyniki optymalizacji skłonności do powstania wady na podstawie modelu neuronowego dla parametru czas cyklu (szczegóły w Tabelcy 5.134.)

Przyczyny dla których procedury optymalizacyjne nie wskazały jednoznacznie na kierunek wpływu większości zmiennych wejściowych mogą być różne. Pierwsza związana jest z losowym charakterem działania procedur optymalizacyjnych, co prowadzi do znajdowania

ekstremów lokalnych. Ma to szczególne znaczenie przy optymalizacji wielowymiarowej, jak w niniejszej pracy. Drugą przyczyną może być fakt słabych zależności między niektórymi zmiennymi wejściowymi a zmienną wyjściową odzwierciedlanych przez modele neuronowe pomimo, że analizy istotności oparte na metodach statystycznych (p. 5.2.3) wskazywały na znaczące role tych zmiennych. To z kolei mogło być wynikiem złożoności tych wielowymiarowych zależności i naturalnego zaszumienia danych przemysłowych.

Niemniej, w przypadku kilku zmiennych wskazania uzyskane z optymalizacji są dość wyraźne, choć nie zawsze możliwe do zinterpretowania bez dodatkowych pomiarów i prób warsztatowych, ewentualnie komputerowych symulacji procesów krzepnięcia odlewu. Warto zauważyć, że nawet bez takich pogłębionych analiz mogą one posłużyć personelowi odlewni do wprowadzenia bardziej rygorystycznych procedur kontrolnych tych właśnie parametrów.

6. Podsumowanie i wnioski ogólne

Problematyka ogólna doktoratu zawierająca się w pytaniu „w jaki sposób przy użyciu zaawansowanego modelowania opartego na dużych zbiorach danych można diagnozować przyczyny powstawania wad wyrobów?”, stanowi swego rodzaju przyczynę podjętych i realizowanych w niniejszej rozprawie doktorskiej badań. Niniejsza praca zamierzała udowodnić ogólną hipotezę badawczą, która zakładała, iż diagnozowanie przyczyn powstawania wad wyrobów wymaga zastosowania zbioru metod zaawansowanego modelowania opartego na dużych zbiorach danych.

W rozdziałach 2, 3 i 4 poświęconych studium literaturowemu, zwrócono szczególną uwagę, na fakt, iż dotychczas używane metody zaawansowanej analizy danych oraz ekstrakcji wiedzy były niewystarczające, aby stworzyć uniwersalną metodologię przewidywania wartości badanej zmiennej zależnej oraz dzięki temu skutecznego diagnozowania przyczyn powstawania wad wyrobów. Dotychczas badane metody nie były w stanie automatycznie wykrywać zależności występujących w danych, opisujących określone procesy czy zjawiska. Zgodnie z opinią wielu badaczy kolejnym przełomowym krokiem w zakresie dziedziny było opracowanie dedykowanych badań w oparciu o specjalnie wybrane narzędzia, celem optymalizacji uzyskanych wcześniej modeli, a więc rozszerzenie interpretacji ich wyników poza podstawową interpretację skuteczności przewidywania wartości zadanej zmiennej wyjściowej. Przekonanie stanowiło swego rodzaju podstawę do opracowania etapów i metod badań zmierzających do wydobywania wiedzy z badanych zbiorów danych, w oparciu o metody sztucznych sieci neuronowych, których wynikiem była wielowymiarowa optymalizacja parametrów procesu.

W niniejszej rozprawie doktorskiej opisano dokładnie 6 etapów badań własnych, mających na celu doprowadzić do odkrycia przyczyn powstawania wad w produktach:

- wstępne przetwarzanie danych,
- analizę istotności zmiennych,
- zaawansowane modelowanie oparte na danych metodą sztucznych sieci neuronowych,
- zaawansowane modelowanie danych metodą drzew regresyjnych,
- zaawansowane modelowanie oparte na danych metodą maszyn wektorów wspierających,
- badanie modelu w celu wielowymiarowej optymalizacji parametrów procesu.

Podczas badań zrealizowano koncepcje rozwiązania problemu badawczego, poprzez postępowanie uwzględniające następujące działania: określenie obszaru badawczego, sformułowanie pytań badawczych, ocenę wartości naukowej pytania na podstawie studiów literaturowych, wykonanie studium przypadku, sformułowanie problemu badawczego i hipotezy badawczej, zweryfikowanie hipotezy badawczej przez własne badania zasadnicze. Postawione w rozdziale piątym niniejszej rozprawy pytania badawcze znalazły odpowiedź w przeprowadzonych badaniach własnych oraz ich wynikach. Pierwsze pytanie rozważało, czy zaawansowane metody analizy danych będą w stanie skutecznie przewidzieć pojawienie się wady w wyrobie? Każda z użytych metod pozwoliła na dość skuteczne przewidzenie wartości zmiennej wyjściowej, jednak metoda sztucznych sieci neuronowych uzyskała najlepsze wyniki, a więc najlepsze dopasowanie i najmniejsze wartości błędu przewidywania (RMSE, tab. 6.1.) spośród dużych i małych zbiorów danych. Dane do tab. 6.1. zostały wybrane spośród wyników zaprezentowanych w rozdziale 5 w tab. 5.91. i 5.92. (dla badań przeprowadzonych metodą sztucznych sieci neuronowych), tab. 5.94., tab. 5.95. i 5.96. (dla badań przeprowadzonych metodą drzew regresyjnych) i w tab. 5.98. i 5.99. (dla badań przeprowadzonych metodą wektorów wspierających). W tabeli 6.1. przywołano również parametry modeli, w których uzyskano najniższe wartości RMSE. Uzasadnienie wyboru wskazanych parametrów modeli zawarto w rozdziałach 5.2.4.1., 5.2.5.1., 5.2.6.1..

Tab. 6.1.: Porównanie najlepszych wyników zaawansowanego modelowania

Metoda zaawansowanego modelowania opartego na danych	Rozmiar zbioru danych	Wynik RMSE	Parametry modelu
Sztuczne sieci neuronowe (SSN)	Mały	0,90	Zbiór 4 (ustalony według kryterium odwróconego K-W i ANOVA), bez zbioru testującego, 5 neuronów w warstwie ukrytej, tangensoidalna funkcja aktywacji na wyjściu

	Duży	0,86	Zbiór 3 (ustalony według kryterium odwróconego K-W i ANOVA), bez zbioru testującego, 23 neurony w warstwie ukrytej, liniowa funkcja aktywacji na wyjściu
Drzewa regresyjne (RT)	Mały	7,10	Zbiór 2 (ustalony według kryterium K-W), bez walidacji krzyżowej, minimalna liczność węzła równa 5
	Duży	0,93	Zbiór 3 (ustalony według kryterium odwróconego K-W i ANOVA), bez walidacji krzyżowej, minimalna liczność węzła równa 50
Maszyny wektorów wspierających (SVM)	Mały	29,20	Zbiór 2 (ustalony według kryterium odwróconego K-W i ANOVA), SVM typu 2, z funkcją jądrową RBF
	Duży	1,10	Zbiór 3 (ustalony według kryterium odwróconego K-W i ANOVA), SVM typu 1, z funkcją jądrową wielomian

Najlepsze wyniki każdorazowo otrzymywano dla dużych zbiorów danych zawierających więcej obserwacji opisujących proces, jednocześnie bardziej zróżnicowanych. W małych zbiorach danych, które zawierały mniej obserwacji, spośród których było mniej danych zaszumionych i niezrównoważonych najlepsze wyniki z najmniejszymi wartościami błędów przewidywania uzyskano również metodą sztucznych sieci neuronowych. Metoda drzew decyzyjnych okazała się być mniej precyzyjna, szczególnie dla małych zbiorów danych. Wyniki modelowania uzyskane za pomocą maszyn wektorów wspierających zasadniczo odzwierciedlają oczekiwane tendencje, jednak wartości wynikowe są mniej dokładne niż te uzyskane metodą sztucznych sieci neuronowych i drzew decyzyjnych.

Końcowa część planu badań dotyczyła zaawansowanej analizy wyników i badania modelu w celu wielowymiarowej optymalizacji parametrów procesu przeprowadzonej, aby określić jakie wartości parametrów danej zmiennej wpływają na formowanie się wady w wyrobie. Wyniki tej analizy pozwalają uzyskać odpowiedź na drugie zadane pytanie badawcze, czy wielowymiarowa optymalizacja parametrów procesu będzie w stanie wskazać wartości parametrów określonych zmiennych, wpływające na powstanie wady w produkcji? Wyniki

analizy pokazały, że konkretne wartości parametrów sprzyjają powstawaniu wyższych wartości *przecieku* a więc formowania się wady w produkcie, w odlewie. Wskazano, że podwyższone wartości parametrów: *opóźnienie multiplikacji*, *temperatura wody miejskiej* i *czas dozowania stopu 2* oraz obniżone wartości paramentów: *czas przedmuchu* i *przepływ w obwodzie chłodzenia 14*, wpływają na osiąganie wyższych wartości *przecieku* w obwodzie *wysokiego ciśnienia* a tym samym na powstawanie wady w odlewie. Mimo, że udało się w niektórych przypadkach uzyskać obiecujące wyniki, dzięki którym istnieje możliwość wyboru istotnych zmiennych i ich określonych wartości jako istotnych dla badanego procesu, wskazując na konieczność traktowania ich jako krytycznych przez pracowników odlewni, to nie w każdym przypadku uzyskanie takiej informacji z utworzonych modeli było możliwe.

Niniejsza praca dowiodła, iż tworzenie się wad w odlewach mimo, że często wydaje się przypadkowe, bez możliwości identyfikacji jego przyczyn, tak naprawdę jest spowodowane określonymi przedziałami wartości parametrów opisujących dany proces. Narzędzia zastosowane do badań dobrane zostały w oparciu o ich możliwości pracy z danymi o niedoskonałej jakości i wysokim skomplikowaniu, a więc zawierającymi różnego typu rozkłady zmiennych, z różnego typu korelacjami pomiędzy parametrami procesu i, co najtrudniejsze, zawierającymi bardzo małą reprezentację podwyższonych wartości *przecieku* w obwodzie *wysokiego ciśnienia*, opisujących produkty z wadą. Podczas badań zidentyfikowano ogólne trudności związane z zaawansowanym modelowaniem opartym na dużych zbiorach danych, a więc w modelach sztucznych sieci neuronowych ich nieodłączną losowość (różne wartości wag w sieciach o identycznej strukturze, ograniczoną wydajność modeli drzew regresyjnych oraz trudność zastosowania modeli maszyn wektorów wspierających.

Mimo, zidentyfikowanych problemów, uzyskane wyniki modelowania i wielowymiarowej optymalizacji wydają się być obiecujące i mogą stanowić motywację do dalszych badań. Wyniki potwierdzają, że przewidywanie poziomu wady w odlewie może być dokonywane z zadowalającą jakością i dokładnością, dlatego może stanowić bardzo ważny punkt dla dalszego rozwoju odlewni. Nadal jednak widoczna jest potrzeba pracy nad nowymi metodami wstępnego przygotowania danych, aby zapewnić eliminację błędów i właściwą reprezentację wartości parametrów jakości w zbiorach danych. Dużą szansą może być opracowanie modeli mogących przewidzieć jakość produktów z określonym wyprzedzeniem czasowym, co może pozwolić na lepsze poznanie procesu produkcyjnego i ewentualną zmianę procedur kontroli jakości w przedsiębiorstwie.

7. Spis ilustracji

Rys. 2.1.1. Relacje między sztuczną inteligencją, uczeniem maszynowym, 18	18
głębokim uczeniem a sztucznymi sieciami neuronowymi [opracowanie własne]..... 18	18
Rys. 2.1.2. Zakres zastosowania różnych typów modeli procesów [22]. 20	20
Rys. 2.1.3. Klasyfikacja uczenia maszynowego [19]..... 21	21
Rys.2.3.1. Przybliżony wygląd komórki nerwowej [52]..... 27	27
Rys.2.3.2. Model neuronu [52] 29	29
Rys.2.3.3. Schemat ukrytych warstw neuronów i przykładowa lokalizacja funkcji aktywacji [opracowanie własne] 31	31
Rys. 2.5.1. Schemat perceptronu wielowarstwowego [84] 36	36
Rys. 2.5.2. Porównanie wykresów sieci zachowującej zdolność do generalizacji i sieci z utraconą zdolnością do generalizacji [85]. 37	37
Rys. 2.5.3. Przykładowy przebieg korekt błędu sieci w kolejnych iteracjach [69]..... 38	38
Rys. 2.5.4. Minimum globalne i minima lokalne [48] 38	38
Rys. 2.5.5. Ilustracja metod gradientowych [69] 39	39
Rys. 2.5.6. Ilustracja metod wyżarzania symulowanego [69]..... 40	40
Rys.4.1.1. Przykład problemu podzielonego na dwuwymiarową przestrzeń z optymalnym marginesem [131] 52	52
Rys.5.2.1.1. Wykres przebiegu zmiennej niezależnej: <i>ciśnienie sprężonego powietrza</i> , z posortowanymi wartościami..... 58	58
Rys.5.2.1.2. Wykres przebiegu zmiennej niezależnej: <i>ciśnienie wody miejskiej</i> , z posortowanymi wartościami 59	59
Rys.5.2.1.3. Wykres przebiegu zmiennej niezależnej: <i>ciśnienie wody obiegowej</i> , z posortowanymi wartościami 59	59
Rys.5.2.1.4. Wykres przebiegu zmiennej niezależnej: <i>czas pierwszej fazy wtrysku</i> , z posortowanymi wartościami 60	60
Rys.5.2.1.5. Wykres przebiegu zmiennej niezależnej: <i>czas chłodzenia obwodu I</i> , z posortowanymi wartościami 60	60
Rys.5.2.1.6. Wykres przebiegu zmiennej niezależnej: <i>czas cyklu</i> , z posortowanymi wartościami 61	61
Rys.5.2.1.7. Wykres przebiegu zmiennej niezależnej: <i>czas cyklu smarowania</i> , z posortowanymi wartościami 61	61

Rys.5.2.1.8. Wykres przebiegu zmiennej niezależnej: <i>czas dozowania stopu 1</i> , z posortowanymi wartościami	62
Rys.5.2.1.9. Wykres przebiegu zmiennej niezależnej: <i>czas dozowania stopu 2</i> , z posortowanymi wartościami	62
Rys.5.2.1.10. Wykres przebiegu zmiennej niezależnej: <i>czas krzepnięcia t₂</i> , z posortowanymi wartościami	63
Rys.5.2.1.11. Wykres przebiegu zmiennej niezależnej: <i>czas przedmuchu</i> , z posortowanymi wartościami	63
Rys.5.2.1.12. Wykres przebiegu zmiennej niezależnej: <i>czas smarowania</i> , z posortowanymi wartościami	64
Rys.5.2.1.13. Wykres przebiegu zmiennej niezależnej: <i>dzienny numer wtrysku</i> , z posortowanymi wartościami	64
Rys.5.2.1.14. Wykres przebiegu zmiennej niezależnej: <i>filtr próżni 1</i> , z posortowanymi wartościami	65
Rys.5.2.1.15. Wykres przebiegu zmiennej niezależnej: <i>grubość piętki układu wlewowego</i> , z posortowanymi wartościami	65
Rys.5.2.1.16. Wykres przebiegu zmiennej niezależnej: <i>koncentrat</i> , z posortowanymi wartościami	66
Rys.5.2.1.17. Wykres przebiegu zmiennej niezależnej: <i>ciśnienie maksymalne</i> , z posortowanymi wartościami	66
Rys.5.2.1.18. Wykres przebiegu zmiennej niezależnej: <i>prędkość wtrysku maksymalna</i> , z posortowanymi wartościami.....	67
Rys.5.2.1.19. Wykres przebiegu zmiennej niezależnej: <i>opóźnienie multiplikacji</i> , z posortowanymi wartościami	67
Rys.5.2.1.20. Wykres przebiegu zmiennej niezależnej: <i>stała temperatura chłodzenia płyty</i> , z posortowanymi wartościami	68
Rys.5.2.1.21. Wykres przebiegu zmiennej niezależnej: <i>poziom stopu w piecu podgrzewczym</i> , z posortowanymi wartościami	68
Rys.5.2.1.22. Wykres przebiegu zmiennej niezależnej: <i>poziom wody w strumieniu chłodzącym</i> , z posortowanymi wartościami.....	69
Rys.5.2.1.23. Wykres przebiegu zmiennej niezależnej: <i>czas drugiej fazy wtrysku</i> , z posortowanymi wartościami	69
Rys.5.2.1.24. Wykres przebiegu zmiennej niezależnej: <i>profil próżni 1</i> , z posortowanymi wartościami	70

Rys.5.2.1.25. Wykres przebiegu zmiennej niezależnej: <i>profil próżni 2</i> , z posortowanymi wartościami	70
Rys.5.2.1.26. Wykres przebiegu zmiennej niezależnej: <i>przepływ chłodzenia tłoka</i> , z posortowanymi wartościami	71
Rys.5.2.1.27. Wykres przebiegu zmiennej niezależnej: <i>przepływ w obwodzie chłodzenia 1</i> , z posortowanymi wartościami	71
Rys.5.2.1.28. Wykres przebiegu zmiennej niezależnej: <i>przepływ w obwodzie chłodzenia 13</i> , z posortowanymi wartościami	72
Rys.5.2.1.29. Wykres przebiegu zmiennej niezależnej: <i>przepływ w obwodzie chłodzenia 14</i> , z posortowanymi wartościami	72
Rys.5.2.1.30. Wykres przebiegu zmiennej niezależnej: <i>przepływ w obwodzie chłodzenia 15</i> , z posortowanymi wartościami	73
Rys.5.2.1.31. Wykres przebiegu zmiennej niezależnej: <i>przepływ w obwodzie chłodzenia 17</i> , z posortowanymi wartościami	73
Rys.5.2.1.32. Wykres przebiegu zmiennej niezależnej: <i>przepływ w obwodzie chłodzenia 20</i> , z posortowanymi wartościami	74
Rys.5.2.1.33. Wykres przebiegu zmiennej niezależnej: <i>przepływ w obwodzie chłodzenia 6</i> , z posortowanymi wartościami	74
Rys.5.2.1.34. Wykres przebiegu zmiennej niezależnej: <i>prędkość we wlewach doprowadzających</i> , z posortowanymi wartościami	75
Rys.5.2.1.35. Wykres przebiegu zmiennej niezależnej: <i>suw pierwszej fazy wtrysku</i> , z posortowanymi wartościami	75
Rys.5.2.1.36. Wykres przebiegu zmiennej niezależnej: <i>suw docisku po multiplikacji</i> , z posortowanymi wartościami	76
Rys.5.2.1.37. Wykres przebiegu zmiennej niezależnej: <i>temperatura chłodzenia tłoka</i> , z posortowanymi wartościami	76
Rys.5.2.1.38. Wykres przebiegu zmiennej niezależnej: <i>temperatura stopu</i> , z posortowanymi wartościami	77
Rys.5.2.1.39. Wykres przebiegu zmiennej niezależnej: <i>temperatura termoregulatora 2.1.</i> , z posortowanymi wartościami.....	77
Rys.5.2.1.40. Wykres przebiegu zmiennej niezależnej: <i>temperatura termoregulatora 2.2.</i> , z posortowanymi wartościami.....	78
Rys.5.2.1.41. Wykres przebiegu zmiennej niezależnej: <i>temperatura termoregulatora 3.2.</i> , z posortowanymi wartościami.....	78

Rys.5.2.1.42. Wykres przebiegu zmiennej niezależnej: <i>temperatura tulei 1</i> , z posortowanymi wartościami	79
Rys.5.2.1.43. Wykres przebiegu zmiennej niezależnej: <i>temperatura tulei 2</i> , z posortowanymi wartościami	79
Rys.5.2.1.44. Wykres przebiegu zmiennej niezależnej: <i>temperatura tulei 3</i> , z posortowanymi wartościami	80
Rys.5.2.1.45. Wykres przebiegu zmiennej niezależnej: <i>temperatura tulei 4</i> , z posortowanymi wartościami	80
Rys.5.2.1.46. Wykres przebiegu zmiennej niezależnej: <i>temperatura w obwodzie chłodzenia 1</i> , z posortowanymi wartościami	81
Rys.5.2.1.47. Wykres przebiegu zmiennej niezależnej: <i>temperatura w obwodzie chłodzenia 13</i> , z posortowanymi wartościami	81
Rys.5.2.1.48. Wykres przebiegu zmiennej niezależnej: <i>temperatura w obwodzie chłodzenia 14</i> , z posortowanymi wartościami	82
Rys.5.2.1.49. Wykres przebiegu zmiennej niezależnej: <i>temperatura w obwodzie chłodzenia 15</i> , z posortowanymi wartościami	82
Rys.5.2.1.50. Wykres przebiegu zmiennej niezależnej: <i>temperatura w obwodzie chłodzenia 17</i> , z posortowanymi wartościami	83
Rys.5.2.1.51. Wykres przebiegu zmiennej niezależnej: <i>temperatura w obwodzie chłodzenia 7</i> , z posortowanymi wartościami	83
Rys.5.2.1.52. Wykres przebiegu zmiennej niezależnej: <i>temperatura wody miejskiej</i> , z posortowanymi wartościami	84
Rys.5.2.1.53. Wykres przebiegu zmiennej niezależnej: <i>temperatura wody w instalacji</i> , z posortowanymi wartościami.....	84
Rys.5.2.1.54. Wykres przebiegu zmiennej niezależnej: <i>wartość próżni 1</i> , z posortowanymi wartościami	85
Rys.5.2.1.55. Wykres przebiegu zmiennej niezależnej: <i>wartość próżni 2</i> , z posortowanymi wartościami	85
Rys.5.2.1.56. Wykres przebiegu zmiennej niezależnej: <i>zużycie smaru</i> , z posortowanymi wartościami	86
Rys.5.2.1.57. Wykres przebiegu zmiennej zależnej: <i>przeciek w obwodzie wysokiego ciśnienia</i> , z posortowanymi wartościami	86
Rys.5.2.1.58. Wykres przebiegu zmiennej wejściowej: <i>poziom stopu w piecu podgrzewczym</i> , z posortowanymi wartościami zawierający niepoprawne wartości..	112

Rys.5.2.1.59. Wykres przebiegu zmiennej wejściowej: <i>filtr próżni 1</i> , z posortowanymi wartościami zawierający niepoprawne wartości	112
Rys.5.2.1.60. Wykres przebiegu zmiennej zależnej: <i>przeciek w obwodzie wysokiego ciśnienia</i> , z posortowanymi wartościami zawierający ukryte niepoprawne wartości	113
Rys.5.2.1.61. Wykres przebiegu zmiennej zależnej: <i>grubość piętki układu wlewowego</i> , z posortowanymi wartościami, z rozkładem zbliżonym do rozkładu normalnego	113
Rys.5.2.1.62. Wykres przebiegu zmiennej zależnej: <i>przeciek w obwodzie wysokiego ciśnienia</i> , z posortowanymi wartościami z rozkładem zbliżonym do rozkładu gamma	114
Rys.5.2.2.1. Wykres przebiegu zmiennej zależnej, z posortowanymi wartościami, w drugim zbiorze danych do badań	116
Rys.5.2.2.2. Histogram zmiennej zależnej, w drugim zbiorze danych do badań.....	116
Rys.5.2.2.3. Wykres przebiegu zmiennej zależnej, z posortowanymi wartościami, w trzecim zbiorze danych do badań	117
Rys.5.2.2.4. Histogram zmiennej zależnej w trzecim zbiorze danych do badań	117
Rys.5.2.2.5. Wykres przebiegu zmiennej zależnej, z posortowanymi wartościami, w czwartym zbiorze danych do badań	118
Rys.5.2.2.6. Wykres przebiegu zmiennej zależnej, z posortowanymi wartościami, w piątym zbiorze danych do badań	118
Rys.5.2.2.7. Tabele umożliwiające dyskretyzację wartości zmiennych zależnych i niezależnych	119
Rys.5.2.2.8. Histogram automatyczny dla wartości oryginalnych (typu ciągłego) dla zmiennej niezależnej: <i>ciśnienie sprężonego powietrza</i>	120
Rys.5.2.2.9. Wykres ilości obserwacji w poszczególnych przedziałach dla zmiennej niezależnej: <i>ciśnienie sprężonego powietrza</i>	120
Rys.5.2.3.1. Okno programu przedstawiające początkowe etapy przeprowadzenia analizy ANOVA klasycznej jednoczynnikowej i odwróconej	139
Rys.5.2.3.2. Okno programu przedstawiające dalsze etapy przeprowadzenia analizy ANOVA klasycznej jednoczynnikowej i odwróconej	140
Rys.5.2.3.3. Okno programu przedstawiające wyniki przeprowadzenia analizy ANOVA klasycznej jednoczynnikowej i odwróconej	141
Rys.5.2.3.4. Okno programu przedstawiające wyniki przeprowadzenia testu Kruskalla-Wallisa klasycznego i odwróconego	142

Rys.5.2.3.5. Kryterium wyboru statystycznie ważnych zmiennych, na podstawie testu Kruskala-Wallisa dla pierwszego zbioru danych	164
Rys.5.2.3.6. Wykres zależności zmiennych: <i>profil próżni 2</i> i <i>wartość próżni 2</i> , w piątym zbiorze, według kryterium K-W.....	166
Rys.5.2.3.7. Wykres zależności zmiennych: <i>czas krzepnięcia</i> i <i>przepływ w obwodzie chłodzenia 17</i> , w zbiorze piątym według kryterium K-W	166
Rys.5.2.3.8. Liczba zmiennych wejściowych w etapie redukcji wymiarowości danych	167
Rys.5.2.4.1. Wybór badań metodą sztucznych sieci neuronowych	174
Rys.5.2.4.2. Wybór parametrów do metody sztucznych sieci neuronowych.....	175
Rys.5.2.4.3. Określenie parametrów programowanej sieci neuronowej	175
Rys.5.2.4.4. Proces budowania sztucznych sieci neuronowych.....	176
Rys.5.2.4.5. Otrzymane wyniki modelowania opartego na danych, metodą sztucznych sieci neuronowych.....	176
Rys.5.2.4.6. Identyfikacja najbardziej wydajnej SSN.....	177
Rys.5.2.4.7. Zapisywanie wyników sztucznych sieci neuronowych	177

1

Nazwa sieci	Jakość (uczenie)	Jakość (testowanie)	Jakość (walidacja)	Błąd (uczenie)	Błąd (testowanie)	Błąd (walidacja)	Algorytm uczenia	Funkcja błędu	Aktywacja (ukryte)	Aktywacja (wyjściowe)
MLP 30-7-1	0,366269	0,090499		8,72145	6,908872		BFGS 70	SOS	Tanh	Logistic

2

ID	Wartość zmierzona	Wartość przewidziana	For RMSE
Test	0,0200	2,3041	5,2
Train	0,0200	1,3642	1,8
Train	0,0500	1,8963	3,4
Train	0,0600	2,5697	6,3
Train	0,0700	1,5841	2,3
Train	0,0800	1,4859	2,0
Train	0,0800	1,8047	3,0

3

Error
RMSE
4,09

.....	178
Rys.5.2.4.8. Zapisywanie wyników w arkuszu Excel	178
Rys.5.2.4.9. Wykres zależności zmiennej wyjściowej zmierzonej i przewidzianej na przykładzie wyników zbioru 1, wg. kryterium K-W, zawierającego 100% wartości w zbiorze uczącym, 22 neurony ukryte, funkcję aktywacji w warstwie ukrytej i funkcję aktywacji na wyjściu tangensoidalna	179
Rys.5.2.4.10. Wykres zależności zmiennej wyjściowej zmierzonej i przewidzianej na przykładzie wyników zbioru 4, wg. kryterium ANOVA, zawierającego 100% wartości w zbiorze uczącym, 5 neuronów ukrytych, funkcję aktywacji w warstwie ukrytej i funkcję aktywacji na wyjściu tangensoidalna	180

Rys.5.2.4.11. Wykres zależności zmiennej wyjściowej zmierzonej i przewidzianej na przykładzie wyników zbioru 4, wg. kryterium ANOVA, zawierającego 100% wartości w zbiorze uczącym, 4 neuronów ukrytych, funkcję aktywacji w warstwie ukrytej i funkcję aktywacji na wyjściu tangensoidalna	180
Rys.5.2.4.12. Wykres zależności zmiennej wyjściowej zmierzonej i przewidzianej na przykładzie wyników zbioru 5, wg. kryterium K-W, model bez zatrzymania uczenia	183
Rys.5.2.4.13. Wykres zależności zmiennej wyjściowej zmierzonej i przewidzianej na przykładzie wyników zbioru 5, wg. kryterium K-W, model z zatrzymaniem uczenia wskutek wzrostu błędu dla zbioru testującego	184
Rys.5.2.4.14. Wyniki modelowania w oparciu o dane ze zbioru 1, według kryterium K-W, funkcja aktywacji tanh-tanh	184
Rys.5.2.4.15. Wyniki modelowania opartego na danych ze zbioru 1, według kryterium K-W, funkcja aktywacji tanh-lin	185
Rys.5.2.4.16. Wyniki modelowania opartego na danych ze zbioru 1, według kryterium K-W, funkcja aktywacji tanh-lin, 7 neuronów w warstwie ukrytej, z 20% wartości w zbiorze testującym	186
Rys.5.2.5.1. Proces przeprowadzania badań metodą drzew regresyjnych	188
Rys.5.2.5.2. Zapisywanie wyników modelowania metodą drzew regresyjnych	189
Rys.5.2.5.3. Wyniki modelowania opartego na danych ze zbioru drugiego wg. kryterium K-W, z minimalną licznością równą 5	191
Rys.5.2.5.4. Wyniki modelowania opartego na danych ze zbioru trzeciego według kryterium odwróconego K-W i ANOVA	191
Rys.5.2.5.5. Wynikowe wartości średnie RMSE w odniesieniu do wartości minimalnej liczności dla małych i dużych zbiorów danych, bez walidacji krzyżowej	192
Rys.5.2.6.1. Proces przeprowadzania badań metodą SVM	194
Rys.5.2.6.2. Proces ustawiania parametrów do badań metodą SVM	194
Rys.5.2.6.3. Zapisywanie wyników modelowania metodą SVM	195
Rys.5.2.6.4. Wyniki modelowania opartego na danych ze zbioru 2, wg kryterium odwróconego K-W i ANOVA, z funkcją jądrową RBF i SVM typu drugiego	197
Rys.5.2.6.5. Wyniki modelowania opartego na danych ze zbioru 3, wg kryterium K-W	197
Rys.5.2.6.6. Wyniki RMSE w podziale na rodzaj funkcji jądrowej i typ funkcji błędu	198

Rys.5.2.6.7. Średnie RMSE według numeru zbioru danych i kryterium	198
Rys.5.2.7.1. Zapisywanie obliczonych wartości wag parametrów sztucznej sieci neuronowej	202
Rys.5.2.7.2. Struktura zaprogramowanego arkusza do optymalizacji parametrów procesu	203
Rys.5.2.7.3. Prowadzenie badań przy użyciu dodatku Solver	204
Rys.5.2.7.4. Wyniki optymalizacji skłonności do powstania wady na podstawie modelu neuronowego dla parametru opóźnienie multiplikacji (szczegóły w Tablicy 5.105).....	232
Rys.5.2.7.5. Wyniki skłonności do powstania wady na podstawie modelu neuronowego dla parametru temperatura wody miejskiej (szczegóły w Tablicy 5.106)	233
Rys.5.2.7.6. Wyniki skłonności do powstania wady na podstawie modelu neuronowego dla parametru czas dozowania stopu 2 (szczegóły w Tablicy 5.108)..	233
Rys.5.2.7.7. Wyniki skłonności do powstania wady na podstawie modelu neuronowego dla parametru czas przedmuchu (szczegóły w Tablicy 5.118).....	234
Rys.5.2.7.8. Wyniki skłonności do powstania wady na podstawie modelu neuronowego dla przepływ w obwodzie chłodzenia 14 (szczegóły w Tablicy 5.120)	235
Rys.5.2.7.9. Wyniki optymalizacji skłonności do powstania wady na podstawie modelu neuronowego dla parametru czas cyklu (szczegóły w Tablicy 5.134.).....	235

8. Spis tabel

Tab. 5.1.: Wyniki normalizacji dla zmiennej niezależnej: <i>ciśnienie sprężonego powietrza</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	86
Tab. 5.2.: Wyniki normalizacji dla zmiennej niezależnej: <i>ciśnienie wody miejskiej</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) ...	87
Tab. 5.3.: Wyniki normalizacji dla zmiennej niezależnej: <i>ciśnienie wody obiegowej</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) ...	87
Tab. 5.4.: Wyniki normalizacji dla zmiennej niezależnej: <i>czas pierwszej fazy wtrysku</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)	88
Tab. 5.5.: Wyniki normalizacji dla zmiennej niezależnej: <i>czas chłodzenia obwodu</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) ...	88
Tab. 5.6.: Wyniki normalizacji dla zmiennej niezależnej: <i>czas cyklu</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	88
Tab. 5.7.: Wyniki normalizacji dla zmiennej niezależnej: <i>czas cyklu smarowania</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) ...	89
Tab. 5.8.: Wyniki normalizacji dla zmiennej niezależnej: <i>czas dozowania stopu</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) ...	89
Tab. 5.9.: Wyniki normalizacji dla zmiennej niezależnej: <i>czas dozowania stopu 2</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) ...	90
Tab. 5.10.: Wyniki normalizacji dla zmiennej niezależnej: <i>czas krzepnięcia t₂</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) ...	90

Tab. 5.11.: Wyniki normalizacji dla zmiennej niezależnej: <i>czas przedmuchu</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) ...	90
Tab. 5.12.: Wyniki normalizacji dla zmiennej niezależnej: <i>czas smarowania</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) ...	91
Tab. 5.13.: Wyniki normalizacji dla zmiennej niezależnej: <i>dzienny numer wtrysku</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) ...	91
Tab. 5.14.: Wyniki normalizacji dla zmiennej niezależnej: <i>filtr próżni I</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	92
Tab. 5.15.: Wyniki normalizacji dla zmiennej niezależnej: <i>grubość piętki układu wlewowego</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	92
Tab. 5.16.: Wyniki normalizacji dla zmiennej niezależnej: <i>koncentrat</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	92
Tab. 5.17.: Wyniki normalizacji dla zmiennej niezależnej: <i>ciśnienie maksymalne</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) ...	93
Tab. 5.18.: Wyniki normalizacji dla zmiennej niezależnej, <i>prędkość wtrysku maksymalna</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	93
Tab. 5.19.: Wyniki normalizacji dla zmiennej niezależnej: <i>opóźnienie multiplikacji</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) ...	94
Tab. 5.20.: Wyniki normalizacji dla zmiennej niezależnej: <i>stała temperatura chłodzenia płyty</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	94

Tab. 5.21.: Wyniki normalizacji dla zmiennej niezależnej: <i>poziom stopu w piecu podgrzewczym</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	94
Tab. 5.22.: Wyniki normalizacji dla zmiennej niezależnej: <i>poziom wody w strumieniu chłodzącym</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	95
Tab. 5.23.: Wyniki normalizacji dla zmiennej niezależnej: <i>czas drugiej fazy wtrysku</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) ...	95
Tab. 5.24.: Wyniki normalizacji dla zmiennej niezależnej: <i>profil próżni 1</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) ...	96
Tab. 5.25.: Wyniki normalizacji dla zmiennej niezależnej: <i>profil próżni 2</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) ...	96
Tab. 5.26.: Wyniki normalizacji dla zmiennej niezależnej: <i>przepływ chłodzenia tłoka</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)	96
Tab. 5.27.: Wyniki normalizacji dla zmiennej niezależnej: <i>przepływ w obwodzie chłodzenia 1</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	97
Tab. 5.28.: Wyniki normalizacji dla zmiennej niezależnej: <i>przepływ w obwodzie chłodzenia 13</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	97
Tab. 5.29.: Wyniki normalizacji dla zmiennej niezależnej: <i>przepływ w obwodzie chłodzenia 14</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	98
Tab. 5.30.: Wyniki normalizacji dla zmiennej niezależnej: <i>przepływ w obwodzie chłodzenia 15</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego	

udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	98
Tab. 5.31.: Wyniki normalizacji dla zmiennej niezależnej: <i>przepływ w obwodzie chłodzenia 17</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	98
Tab. 5.32.: Wyniki normalizacji dla zmiennej niezależnej: <i>przepływ w obwodzie chłodzenia 20</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	99
Tab. 5.33.: Wyniki normalizacji dla zmiennej niezależnej: <i>przepływ w obwodzie chłodzenia 6</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	99
Tab. 5.34.: Wyniki normalizacji dla zmiennej niezależnej: <i>prędkość we wlewach doprowadzających</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	100
Tab. 5.35.: Wyniki normalizacji dla zmiennej niezależnej: <i>suw pierwszej fazy wtrysku</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego)	100
Tab. 5.36.: Wyniki normalizacji dla zmiennej niezależnej: <i>suw docisku po multiplikacji</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	100
Tab. 5.37.: Wyniki normalizacji dla zmiennej niezależnej: <i>temperatura chłodzenia tłoka</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	101
Tab. 5.38.: Wyniki normalizacji dla zmiennej niezależnej: <i>temperatura stopu</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) .	101

Tab. 5.39.: Wyniki normalizacji dla zmiennej <i>temperatura termoregulatora 2.1.</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) .	102
Tab. 5.40.: Wyniki normalizacji dla zmiennej <i>temperatura termoregulatora 2.2.</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) .	102
Tab. 5.41.: Wyniki normalizacji dla zmiennej <i>temperatura termoregulatora 3.2.</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) .	102
Tab. 5.42.: Wyniki normalizacji dla zmiennej niezależnej: <i>temperatura tulei 1</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) .	103
Tab. 5.43.: Wyniki normalizacji dla zmiennej niezależnej: <i>temperatura tulei 2</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) .	103
Tab. 5.44.: Wyniki normalizacji dla zmiennej niezależnej: <i>temperatura tulei 3</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) .	104
Tab. 5.45.: Wyniki normalizacji dla zmiennej niezależnej: <i>temperatura tulei 4</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) .	104
Tab. 5.46.: Wyniki normalizacji dla zmiennej niezależnej: <i>temperatura w obwodzie chłodzenia 1</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	104
Tab. 5.47.: Wyniki normalizacji dla zmiennej niezależnej: <i>temperatura w obwodzie chłodzenia 13</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	105
Tab. 5.48.: Wyniki normalizacji dla zmiennej niezależnej: <i>temperatura w obwodzie chłodzenia 14</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	105

Tab. 5.49.: Wyniki normalizacji dla zmiennej niezależnej: <i>temperatura w obwodzie chłodzenia 15</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	106
Tab. 5.50.: Wyniki normalizacji dla zmiennej niezależnej: <i>temperatura w obwodzie chłodzenia 17</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	106
Tab. 5.51.: Wyniki normalizacji dla zmiennej niezależnej: <i>temperatura w obwodzie chłodzenia 7</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	106
Tab. 5.52.: Wyniki normalizacji dla zmiennej niezależnej: <i>temperatura wody miejskiej</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	107
Tab. 5.53.: Wyniki normalizacji dla zmiennej niezależnej: <i>temperatura wody w instalacji</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego).....	107
Tab. 5.54.: Wyniki normalizacji dla zmiennej niezależnej: <i>wartość próżni 1</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) .	108
Tab. 5.55.: Wyniki normalizacji dla zmiennej niezależnej: <i>wartość próżni 2</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) .	108
Tab. 5.56.: Wyniki normalizacji dla zmiennej niezależnej: <i>zużycie smaru</i> , w odniesieniu do zmiennej zależnej, z oznaczeniem procentowego udziału obserwacji w każdym z zakresów od największego (zielonego) do najmniejszego (czerwonego) .	108
Tab. 5.59.: Wybrane zakresy zmiennych niezależnych:	109
Tab. 5.60.: Ustalane przedziały i wystąpienia danych wartości w przedziałach dla pierwszego zbioru danych do badań	121
Tab. 5.61.: Ustalane przedziały i wystąpienia danych wartości w przedziałach dla drugiego zbioru danych do badań	124

Tab. 5.62.: Ustalane przedziały i wystąpienia danych wartości w przedziałach dla trzeciego zbioru danych do badań	127
Tab. 5.63.: Ustalane przedziały i wystąpienia danych wartości w przedziałach dla czwartego zbioru danych do badań	130
Tab. 5.64.: Ustalane przedziały i wystąpienia danych wartości w przedziałach dla piątego zbioru danych do badań.....	133
Tab. 5.65.: Zestawienie obliczonych wartości statystyk F i H dla pierwszego zbioru danych do badań.....	142
Tab. 5.66.: Zestawienie obliczonych wartości p dla pierwszego zbioru danych do badań	144
Tab. 5.67.: Zestawienie obliczonych wartości statystyk F i H dla drugiego zbioru danych do badań.....	146
Tab. 5.68.: Zestawienie obliczonych wartości p dla drugiego zbioru danych do badań	148
Tab. 5.69.: Zestawienie obliczonych wartości statystyk F i H dla trzeciego zbioru danych do badań.....	150
Tab. 5.70.: Zestawienie obliczonych wartości p dla trzeciego zbioru danych do badań	152
Tab. 5.71.: Zestawienie obliczonych wartości statystyk F i H dla czwartego zbioru danych do badań.....	154
Tab. 5.72.: Zestawienie obliczonych wartości p dla czwartego zbioru danych do badań	156
Tab. 5.73.: Zestawienie obliczonych wartości statystyk F i H dla piątego zbioru danych do badań.....	159
Tab. 5.74.: Zestawienie obliczonych wartości p dla piątego zbioru danych do badań	161
Tab. 5.75.: Zestawienie maksymalnych i średnich wartości statystyk F i H	163
Tab. 5.76.: Zestawienie wyników analizy korelacji dla zbioru piątego według kryterium K-W	165
Tab. 5.77.: Interpretacja wysokości współczynnika korelacji	165
Tab. 5.78.: Plan badań pierwszego zbioru ustalonego według kryterium K-W.....	170
Tab. 5.79.: Plan badań drugiego zbioru ustalonego według kryterium K-W.....	170
Tab. 5.80.: Plan badań trzeciego zbioru ustalonego według kryterium K-W	170
Tab. 5.81.: Plan badań czwartego zbioru ustalonego według kryterium K-W	171

Tab. 5.82.: Plan badań piątego zbioru ustalonego według kryterium K-W	171
Tab. 5.83.: Plan badań pierwszego zbioru ustalonego według kryterium odwróconego K-W i ANOVA	172
Tab. 5.84.: Plan badań drugiego zbioru ustalonego według kryterium odwróconego K-W i ANOVA.....	172
Tab. 5.85.: Plan badań trzeciego zbioru ustalonego według kryterium odwróconego K-W i ANOVA.....	172
Tab. 5.86.: Plan badań czwartego zbioru ustalonego według kryterium odwróconego K-W	172
Tab. 5.87.: Plan badań piątego zbioru ustalonego według kryterium odwróconego K-W	173
Tab. 5.88.: Plan badań czwartego zbioru ustalonego według kryterium ANOVA	173
Tab. 5.89.: Plan badań piątego zbioru ustalonego według kryterium ANOVA.....	173
Tab. 5.90.: Wybrane wyniki modelowania z najniższą wartością RMSE dla pięciu zbiorów ustalonych według kryterium K-W, z oznaczeniem RMSE, od najniższych wartości (od zielonego koloru) do najwyższych wartości (do czerwonego koloru) ..	181
Tab. 5.91.: Wybrane wyniki modelowania z najniższą wartością RMSE dla pięciu zbiorów ustalonych według kryterium odwróconego K-W, z oznaczeniem RMSE, od najniższych wartości (od zielonego koloru) do najwyższych wartości (do czerwonego koloru)	181
Tab. 5.92.: Wybrane wyniki modelowania z najniższą wartością RMSE dla pięciu zbiorów ustalonych według kryterium ANOVA, z oznaczeniem RMSE, od najniższych wartości (od zielonego koloru) do najwyższych wartości (do czerwonego koloru)	182
Tab. 5.93.: Założenia przyjęte w CART	188
Tab. 5.94.: Wyniki modelowania metodą drzew regresyjnych zbiorów według kryterium K-W, z oznaczeniem RMSE, od najniższych wartości (od zielonego koloru) do najwyższych wartości (do czerwonego koloru)	189
Tab. 5.95.: Wyniki modelowania metodą drzew regresyjnych zbiorów według kryterium odwróconego K-W, z oznaczeniem RMSE, od najniższych wartości (od zielonego koloru) do najwyższych wartości (do czerwonego koloru)	190
Tab. 5.96.: Wyniki modelowania metodą drzew regresyjnych zbiorów według kryterium ANOVA, z oznaczeniem RMSE, od najniższych wartości (od zielonego koloru) do najwyższych wartości (do czerwonego koloru).....	190

Tab. 5.97.: Wyniki modelowania metodą SVM, zbiorów według kryterium K-W, z oznaczeniem RMSE, od najniższych wartości (od zielonego koloru) do najwyższych wartości (do czerwonego koloru).....	195
Tab. 5.98.: Wyniki modelowania metodą SVM, zbiorów według kryterium odwróconego K-W, z oznaczeniem RMSE, od najniższych wartości (od zielonego koloru) do najwyższych wartości (do czerwonego koloru).....	196
Tab. 5.99.: Wyniki modelowania metodą SVM, zbiorów według kryterium ANOVA, z oznaczeniem RMSE, od najniższych wartości (od zielonego koloru) do najwyższych wartości (do czerwonego koloru).....	196
Tab. 5.100.: Charakterystyka wybranych modeli do wielowymiarowej optymalizacji parametrów procesu	200
Tab. 5.101.: Wyniki wielowymiarowej optymalizacji metodą nieliniową GRG, z wielostartem dla minimalnej wartości zmiennej wyjściowej.....	205
Tab. 5.102.: Wyniki wielowymiarowej optymalizacji metodą nieliniową GRG, z wielostartem dla maksymalnej wartości zmiennej wyjściowej.....	206
Tab. 5.103.: Wyniki wielowymiarowej optymalizacji metodą ewolucyjną, dla minimalnej wartości zmiennej wyjściowej	207
Tab. 5.104.: Wyniki wielowymiarowej optymalizacji metodą ewolucyjną, dla maksymalnej wartości zmiennej wyjściowej	207
Tab. 5.105.: Wyniki wielowymiarowej optymalizacji zbioru 1, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, 19 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu	208
Tab. 5.106.: Wyniki wielowymiarowej optymalizacji zbioru 1, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, 22 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu	209
Tab. 5.107.: Wyniki wielowymiarowej optymalizacji zbioru 1, ustalonego wg. kr. odwróconego K-W i ANOVA, dla sieci z 100% wartości w zbiorze uczącym, 19 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu	210
Tab. 5.108.: Wyniki wielowymiarowej optymalizacji zbioru 1, ustalonego wg. kr. odwróconego K-W i ANOVA, dla sieci z 100% wartości w zbiorze uczącym, 22 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu	211
Tab. 5.109.: Wyniki wielowymiarowej optymalizacji zbioru 1, ustalonego wg. kr. odwróconego K-W i ANOVA, dla sieci z 100% wartości w zbiorze uczącym, 20 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu	212

Tab. 5.110.: Wyniki wielowymiarowej optymalizacji zbioru 2, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu	214
Tab. 5.111.: Wyniki wielowymiarowej optymalizacji zbioru 2, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 3 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu	214
Tab. 5.112.: Wyniki wielowymiarowej optymalizacji zbioru 2, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu	214
Tab. 5.113.: Wyniki wielowymiarowej optymalizacji zbioru 2, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 3 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu	215
Tab. 5.114.: Wyniki wielowymiarowej optymalizacji zbioru 2, ustalonego wg. kr. odwróconego K-W i ANOVA, dla sieci z 100% wartości w zbiorze uczącym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu	215
Tab. 5.115.: Wyniki wielowymiarowej optymalizacji zbioru 2, ustalonego wg. kr. odwróconego K-W i ANOVA, dla sieci z 100% wartości w zbiorze uczącym, z 3 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu	216
Tab. 5.116.: Wyniki wielowymiarowej optymalizacji zbioru 3, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 23 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu	217
Tab. 5.117.: Wyniki wielowymiarowej optymalizacji zbioru 3, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 21 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu	217
Tab. 5.118.: Wyniki wielowymiarowej optymalizacji zbioru 3, ustalonego wg. kr. odwróconego K-W i ANOVA, dla sieci z 100% wartości w zbiorze uczącym, z 21 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu	218
Tab. 5.119.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu	219
Tab. 5.120.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 4 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu	220

Tab. 5.121.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 5 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu	220
Tab. 5.122.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. K-W, dla sieci z 90% wartości w zbiorze uczącym i 10% w testującym, z 3 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu	221
Tab. 5.123.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. K-W, dla sieci z 90% wartości w zbiorze uczącym i 10% w testującym, z 4 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu	221
Tab. 5.124.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu	222
Tab. 5.125.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 3 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu	222
Tab. 5.126.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. K-W, dla sieci z 100% wartości w zbiorze uczącym, z 4 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu	223
Tab. 5.127.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. odwróconego K-W, dla sieci z 100% wartości w zbiorze uczącym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu	223
Tab. 5.128.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. odwróconego K-W, dla sieci z 100% wartości w zbiorze uczącym, z 4 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu	224
Tab. 5.129.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. ANOVA, dla sieci z 100% wartości w zbiorze uczącym, z 4 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu.....	225
Tab. 5.130.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. ANOVA, dla sieci z 100% wartości w zbiorze uczącym, z 5 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu.....	225
Tab. 5.131.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. ANOVA, dla sieci z 90% wartości w zbiorze uczącym i 10% w testującym, z 4 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu	226

Tab. 5.132.: Wyniki wielowymiarowej optymalizacji zbioru 4, ustalonego wg. kr. ANOVA, dla sieci z 100% wartości w zbiorze uczącym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu.....	227
Tab. 5.132.: Wyniki wielowymiarowej optymalizacji zbioru 5, ustalonego wg. kr. K-W, dla sieci z 90% wartości w zbiorze uczącym, 10 % w testującym, z 3 neuronami w warstwie ukrytej i funkcją aktywacji tangensoidalną na wyjściu	228
Tab. 5.133.: Wyniki wielowymiarowej optymalizacji zbioru 5, ustalonego wg. kr. odwróconego K-W, dla sieci z 90% wartości w zbiorze uczącym, 10 % w testującym, z 2 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu	228
Tab. 5.134.: Wyniki wielowymiarowej optymalizacji zbioru 5, ustalonego wg. kr. odwróconego K-W, dla sieci z 100% wartości w zbiorze uczącym z 2 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu	229
Tab. 5.135.: Wyniki wielowymiarowej optymalizacji zbioru 5, ustalonego wg. kr. ANOVA, dla sieci z 100% wartości w zbiorze uczącym z 2 neuronami w warstwie ukrytej i funkcją aktywacji liniową na wyjściu.....	230
Tab. 6.1.: Porównanie najlepszych wyników zaawansowanego modelowania	238

9. Literatura

- [1] BIENKOWSKI, M. Przemysł 4.0 – od koncepcji do realizacji, Automatyka 5-6/2020
Systemy wizyjne, kamery termowizyjne. Przemysł 4.0, ISSN 2392-1056, 12.2020
- [2] AGRAWAL, R.; Imielinski, T.; Swami, A.; “Mining Association Rules Between Sets
of Items in Large Databases”, Proc. ACM SIGMOD Conference, pp. 207-216,
Washington DC, USA, May 1993
- [3] FAYYAD, U.; Piatetsky-Shapiro, G.; Smyth, P.; The KDD Process for Extracting Useful
Knowledge from Volumes of Data, Comm. of the ACM, Vol. 39, No. 11, November
1996
- [4] ZAKRZEWICZ, M.; "Data Mining i odkrywanie wiedzy w bazach danych", Materiały
konf. Polish Oracle Users Group PLOUG'97, str. 57-67, Zakopane, 1997
- [5] PERZYK M., Data mining in foundry production. Research in Polish Metallurgy At the
Beginning of XXL Century. Ed. K. Świątkowski, Committee of Metallurgy of the
Polish Academy of Sciences, Kraków, p. 255-276, 2006.
- [6] SHANBAZ, M. et al., Product design and manufacturing process improvement using
association rules. Proc. IMechE Part B: J. Engineering Manufacture, 220(2), 243-254,
2006.
- [7] PATURI, Uma Maheshwera Reddy & Cheruku, Suryapavan. (2020). Application and
performance of machine learning techniques in manufacturing sector from the past two
decades: A review. Materials Today: Proceedings. 38. 10.1016/j.matpr.2020.07.209.
- [8] KUSIAK A., Data mining: manufacturing and service applications. International Journal
of Production Research, 44(18-19), 4175–4191, 2006.
- [9] HARDING J.A., Shahbaz M., Srinivas and Kusiak, A. Data mining in manufacturing: A
review. J Manuf Sci Eng Trans ASME, 128(4), 969-976, 2006.
- [10] WANG, K. Applying data mining to manufacturing: The nature and implications. J
Intell Manuf, 18(4), 487–495, 2007
- [11] HINTON, Geoffrey; The, Yee-Whye. A fast learning algorithm for deep belief nets.
Neural Computation, 2006; 18(7):1527-54. doi: 10.1162/neco.2006.18.7.1527. PMID:
16764513.
- [12] EPPSTEIN Robert, The empty brain. Your brain does not process information, retrieve
knowledge or store memories. In short: your brain is not a computer. Aeon Newsletter.
Udostępniono 18.05.2016. Pobrano: <https://aeon.co/essays/your-brain-does-not-process-information-and-it-is-not-a-computer>.

- [13] PATTERSON, Josh; Gibson, Adam. Deep Learning. Praktyczne wprowadzenie. Tł. A. Wiatrak, Gliwice: Wydawnictwo Helion S.A., 2018, ISBN: 978-83-283-4227-9.
- [14] KOSIŃSKI, R.A., Sztuczne sieci neuronowe. Dynamika nieliniowa i chaos. Wydawnictwo Naukowe PWN, 2017, ISBN: 978-83-0119-732-2
- [15] CICHOSZ, Paweł. Systemy uczące się. Warszawa: WNT, 2000, ISBN 83-204-2544-1, OCLC 749595834.
- [16] TURNING, A.M. Computing Machinery and Intelligence. In: Epstein R., Roberts G., Beber G. (eds) Parsing the Turing Test. Springer, Dordrecht. 2009, ISBN: 978-1-4020-9624-2, DOI: https://doi.org/10.1007/978-1-4020-6710-5_3
- [17] ZOCCA, Valentino; Spacagna, Gianmario i inni. Deep Learning. Uczenie głębokie z językiem Pyhon. Sztuczna inteligencja i sieci neuronowe. Tł. R. Meryk. Gliwice: Wydawnictwo Helion S.A., 2018, ISBN:978-83-283-4173-9
- [18] GRUS, Joel. Data Science od podstaw. Analiza danych w Pythonie. Tł. K. Matuk. Gliwice: Wydawnictwo Helion S.A., 2018, ISBN: 978-83-283-4602-4.
- [19] MAMCZUR, Mirosław, Czym jest uczenie maszynowe? I jakie są rodzaje? Opublikowano 30.11.2019r. <https://mirosławmamczur.pl/czym-jest-uczenie-maszynowe-i-jakie-sa-rodzaje/>
- [20] STEPHENSON, Neal. Zamieć. Tł. W. Szypuła, 1999. ISBN: 9788366409118.
- [21] GRZEGORZEWSKI P., Kochański, A., Kacprzyk J. Data and Modeling in Industrial Manufacturing. Studies in Systems, Decision and Control 183, Springer Nature Switzerland DOI: 10.1007/978-3-030-03201-2_1., 2019.
- [22] PERZYK, M., Kochanski, A., Biernacki, R., Kozłowski, J., Soroczynski, A.: Modelowanie procesów produkcyjnych w odlewni, Postepy teorii i praktyki odlewniczej, 325–344 (2009)
- [23] KOCHAŃSKI, A., Perzyk, M., Kłebczyk, M.: Knowledge in imperfect data. In: Ramiraz, C. (Ed.), Advances in Knowledge Representation, pp. 181–210. InTech (2012)
- [24] SCHUBMEHL, David. Accelerating the Development of Machine Learning Applications. Udostępniono 05.09.2021. Pobrano: <https://partners.wsj.com/aws/accelerating-development-machine-learning-applications/>
- [25] KIZHEVSKY, Alex; Sutskever, Ilya; Hinton, Geoffrey. ImageNet Classification with Deep Convolutional Neural Networks. University of Toronto. Materiały konferencyjne: Advances in Neural Information Processing Systems 25: 26th Annual Conference on Neural Information Processing Systems 2012., Editor: Bartlett, P. ISBN: 9781627480031.

- [26] LEE H, Malave CO, Ramachandran S. A selforganizing neural network approach for the design of cellular manufacturing systems. *Journal of Intelligent Manufactuting*. 1992;3:325-332,2006
- [27] RUSSELL, Stuart; Norvig, Peter. *Artificial Intellience: a modern approach.*, Wydawnictwo: Prentice Hall, Fourth edition, 2020. ISBN: 0-13-461099-7 (<http://aima.cs.berkeley.edu/>)
- [28] MCCULLOCH, W., Pitts W. A.: A Logical Calculus of the Ideas Immanent in Nervous Activity. *Bull. Math. Biophys.* 5, 115-133, 1943. <https://doi.org/10.1007/BF02478259>
- [29] KLEIN, R.M., The Hebb legacy, „*Canadian Journal of Experimental Psychology/Revue canadienne de psychologie expérimentale*”, 53 (1), 1999, DOI: 10.1037/h0087295.
- [30] HEBB, D.O., *The organization of behavior*, New York: Wiley, 1949.
- [31] BRAIN-WIKI contributors. *Uczenie maszynowe i sztuczne sieci neuronowe/Wykład 10* [Internet]. Brain-wiki, ; 2017 lut 16, 16:34 UTC [cited 2021 cze 30]. Available from: http://brain.fuw.edu.pl/edu/index.php?title=Uczenie_maszynowe_i_sztuczne_sieci_neuronowe/Wyk%C5%82ad_10&oldid=6444.
- [32] FREEMAN W.J. (1986) John von Neumann: The Computer and the Brain. In: Palm G., Aertsen A. (eds) *Brain Theory*. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-70911-1_18
- [33] ROSENBLATT F, *The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain*, Cornell Aeronautical Laboratory, *Psychological Review*, v65, No. 6, pp. 386-408, 1958.
- [34] TADEUSIEWICZ, R., *Pierwszy elektroniczny model mózgu*, 2015, www.natemat.pl
- [35] WIDROW B., *An Adaptive Adaline Neuron Using Chemical Memistors*, Stanford Electronics Laboratories Technical Report 1553-2, October 1960.
- [36] BARTMAN, J. *Nowoczesne techniki informatyczne – Ćwiczenie 3: Neurony Liniowe: Adaline*, Katedra inżynierii komputerowej, Uniwersytet Rzeszowski, 2016.
- [37] MINSKY M., Papert S., *Perceptrons – An Introduction to Computational Geometry*. The MIT Press, Cambridge, MA., 1969.
- [38] WERBOS P.J., *Backpropagation Through Time: What It Does and How to Do. It.*, *Proceedings of the IEEE*, vol. 78, no. 10, October 1990
- [39] FUKUSHIMA, K. *Cognitron: A self-organizing multilayered neural network*. *Biol. Cybernetics* 20, 121–136 (1975). <https://doi.org/10.1007/BF00342633>

- [40] FUKUSHIMA, K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biol. Cybernetics* 36, 193–202 (1980). <https://doi.org/10.1007/BF00344251>
- [41] BRAIN-WIKI contributors. *Uczenie maszynowe i sztuczne sieci neuronowe/Wykład 2* [Internet]. Brain-wiki, ; 2017 lut 16, 16:32 UTC [cited 2021 lip 5]. Available from: http://brain.fuw.edu.pl/edu/index.php?title=Uczenie_maszynowe_i_sztuczne_sieci_neuronowe/Wyk%C5%82ad_2&oldid=6439.
- [42] KOZŁOWSKI, J., *Wspomaganie sterowania procesami odlewniczymi z wykorzystaniem zaawansowanych metod analizy sztucznych sieci neuronowych. Rozprawa Doktorska*, Warszawa, Wydział Inżynierii Produkcji, Politechnika Warszawska, 2009
- [43] DUCH, W., Korbicz J., Rutkowski, L., Tadeusiewicz R., “Sieci Neuronowe”, Rozdz. 1. *Biocybernetyka i Inżynieria Medyczna*, tom VI, AOFE, Warszawa 2000
- [44] RUMELHART, D.E., McClelland, J.L., "Learning Internal Representations by Error Propagation," in *Parallel Distributed Processing: Explorations in the Microstructure of Cognition: Foundations*, MIT Press, 1987, pp.318-362.
- [45] GROSSBERG, S. Adaptive Resonance Theory: How a brain learns to consciously attend, learn, and recognize a changing world. *Neural. Neural networks : the official journal of the International Neural Network Society*. 37. 10.1016/j.neunet.2012.09.017., 2012.
- [46] PALUSZYŃSKI, W., *Historia — pierwsze modele sztucznych sieci neuronowych. Wykład Specjalność ARR Katedra Cybernetyki i Robotyki Wydział Elektroniki, Politechnika Wrocławska*, 2021 https://kcir.pwr.edu.pl/~witold/ai/ml_nndeep_s.pdf
- [47] TADEUSIEWICZ, R., *Sieci neuronowe*, Wyd. 2, Akademicka Oficyna Wydaw. RM, 1993.
- [48] EREMENKO, K., De Ponteves, H., SuperDataScience Team - Deep Learning A-Z™: Hands-On Artificial Neural Networks, Udemy kurs on-line, 2019r.
- [49] PRASZCZYK, R., Gajos E., *Mózg - największa tajemnica ludzkiego ciała*, *Prace Naukowe. Pedagogika* 11, 139-146, 2002
- [50] DONGARE, A.D., Kharde R. R., Amit Kachare D. “Introduction to Artificial Neural Network”, *International Journal of Engineering and Innovative Technology (IJEIT)* Volume 2, Issue 1, July 2012, pp- 189-194.
- [51] PERZYK, M., Waszkiewicz S., Kaczorowski M., Jopkiewicz A., *Odlewnictwo*, Warszawa WNT 2004.

- [52] STĘGOWSKI, Z., Sztuczne Sieci Neuronowe, Wydział Fizyki i Techniki Jądrowej AGH, Kernel. 2004 nr 1, s. 16-19.
http://www.fis.agh.edu.pl/~Stegowski/rozne/neurony/art_kern_1.pdf
- [53] ABIODUN, OI, Jantan A, Omolara AE, Dada KV, Mohamed NA, Arshad H. State-of-the-art in artificial neural network applications: A survey. *Heliyon*. 2018;4(11):e00938. Published 2018 Nov 23. doi:10.1016/j.heliyon.2018.e00938
- [54] Vachik D.S., K. Dutta. "Neural network based models for software effort estimation: a review." *Artificial Intelligence Review* 42 (2014): 295-307.
- [55] HE H., Garcia E.A. Learning from imbalanced data. *IEEE Trans. Knowl. Data Eng.* 2009;21(9):1263–1284. [Google Scholar]
- [56] MOZZAFFARI, A., Emami M., Fathi A. A comprehensive investigation into the performance, robustness, scalability and convergence of chaos-enhanced evolutionary algorithms with boundary constraints. *Artif. Intell. Rev.* 2018:1–62. [Google Scholar]
- [57] JAHNAVI, M. Jul 9, 2017. Introduction to Neural Networks, Advantages and Applications, towards Data Science. [www.deeplearningtrack.comhttps://towardsdatascience.com/introduction-to-neural-networks-advantages-and-applications-96851bd1a207](https://www.deeplearningtrack.com/towardsdatascience.com/introduction-to-neural-networks-advantages-and-applications-96851bd1a207) Available at: [Google Scholar]
- [58] IZBOUDJEN, N., Larbes C., Farah A. A new classification approach for neural networks hardware: from standards chips to embedded systems on chip. *Artif. Intell. Rev.* 2014;41(4):491–534. [Google Scholar]
- [59] WANG D., He H., Liu D. Intelligent optimal control with critic learning for a nonlinear overhead crane system. *IEEE Transact. Ind. Inf.* 2018;14(7):2932–2940. [Google Scholar]
- [60] STATSOFT, Internetowy Podręcznik Statystyki, Sieci neuronowe, Copyright StatSoft, Inc., 2011, Odwiedzono dnia: 27.07.2021r.
https://www.statsoft.pl/textbook/stathome_stat.html?https%3A%2F%2Fwww.statsoft.pl%2Ftextbook%2Fstneunet.html
- [61] KHAN Academy, Biologia, Neuron i układ nerwowy człowieka, Synapsy. Odwiedzono 27.07.2021, adres: <https://pl.khanacademy.org/science/biology/human-biology/neuron-nervous-system/a/the-synapse>
- [62] OPENSTAX College, Biology. "How Neurons Communicate." OpenStax CNX. Ostatnio zmieniony 29 lutego 2016. http://cnx.org/contents/GFy_h8cu@10.4:cs_Pb-GW@5/How-Neurons-Communicate.

- [63] BISHOP, C.M., Neural Networks for Pattern Recognition, Institute for Adaptive and Neural Computation Division of Informatics, Edinburgh University, Oxford University Press, ISBN 0 19 853864 2, 1995.
- [64] MARCUS, G., Freeman, J., Contributions by May-Britt Moser Edvard I. Moser, The Future of the Brain: Essays by the World's Leading Neuroscientists, ISBN: 9780691173313, 2014, Princeton University Press, Princeton and Oxford.
- [65] KHAN, I., Nahavandi, S., Frayman, Y.. High-Pressure Die-Casting Process Modelling Using Neural Networks. 2006. Artificial Neural Networks in Finance and Manufacturing. 182-198. 10.4018/978-1-59140-670-9.ch011.
- [66] RUIZ, E., Ferreno, D., Cuartas, M., Lopez, A., Arroyo, W., Gutierrez-Solana, F., Machine learning algorithms for prediction of the strength of steel rods: an example of data-driven manufacturing in steelmaking. International Journal of Computer Integrated Manufacturing, vol 33, 2020, issue 9, <https://doi.org/10.1080/0951192X.2020.1803505>
- [67] JAKUBSKI, J., Dobosz, S.M., Zastosowanie sieci neuronowych do sterowania jakością mas formierskich., Wydział Odlewnictwa AGH, XXXIII Konferencja Naukowa z okazji Ogólnopolskiego Dnia Odlewnika 2009.
- [68] PERZYK M., Kochański A. W.: Prediction of ductile cast iron quality by artificial neural networks. Journal of Material Processing Technology, 109, 2001, p. 305-307
- [69] PERZYK, M., Sztuczne sieci neuronowe w analizie procesów odlewniczych., Politechnika Warszawska, METRO, Metalurgiczny Trening Online, Edukacja i Kultura, 2005,
- [70] TADEUSIEWICZ R., Problem wyboru właściwej architektury sieci neuronowej. Informatyka w Technologii Materiałów, nr 1, tom 1, ss. 3-22, 2001.
- [71] RYBAK, A., Modelowanie matematyczne, Rozwiązywanie problemów przy pomocy modelowania matematycznego, Instytut Informatyki, Uniwersytet w Białymstoku, 2011, <http://zshe.nazwa.pl/innowacyjnenauczanie/index.php/materialy-szkoleniowe/matematyka/91-modelowanie-matematyczne>
- [72] LEWANDOWSKI, S., Drobin, R., Grecka, A., Sztuczne sieci neuronowe i kierunki ich zastosowań w nauce, gospodarce, rolnictwie i przemyśle, Przegląd włókienniczy – włókno, odzież, skóra, Rocznik 2016 – zeszyt 6, 10.15199/60.2016.06.1
- [73] TADEUSIEWICZ, R, 2009. "O celowości zastosowania sieci neuronowych w problemach związanych z elektrotechniką". Przegląd Elektrotechniczny 85 (2). Kraków: Akademia Górniczo-Hutnicza ISSN 0033-2097.

- [74]PERZYK M., Biernacki R., Kochański A.: Modeling of manufacturing processes by learning systems: The naïve Bayesian classifier versus artificial neural networks. Journal of Material Processing Technology, 164–165,2005, p. 430–1435.
- [75]DATTA, S., Extraction of knowledge from high strength steel data using soft computing techniques—an overview, Statistical Analysis and Data Mining: The ASA Data Science Journal Volume 1, Issue 6 p. 329-337 2009, <https://doi.org/10.1002/sam.10024>
- [76]MIJWIL, M.M., Artificial Neural Networks Advantages and Disadvantages. Opublikowano: 27.01.2018, Wyświetlono dn. 29.07.2021r. <https://www.linkedin.com/pulse/artificial-neural-networks-advantages-disadvantages-maad-m-mijwel>
- [77]BARTMAN, J. Nowoczesne techniki informatyczne – Ćwiczenie 5: Uczenie wielowarstwowej sieci jednokierunkowej. Uczenie sieci wielowarstwowych Metoda wstecznej propagacji błędu, Katedra inżynierii komputerowej, Uniwersytet Rzeszowski, 2016.
- [78]KLIMEK M., Sieci Hopfielda dla problemu komiwojażera, Wydawnictwa AGH, Zagadnienia Techniczno-Ekonomiczne, Tom 50, z.1, s. 65-75, 2005
- [79]GRABSKA-CHRZĄSTOWSKA J., Sieci Radialne, wykład AGH, wyświetlono dnia 07.08.2021r., http://home.agh.edu.pl/~asior/stud/doc/RBF_12.pdf
- [80]DUDEK G., Sztuczna inteligencja, Wykład 8: Sztuczne sieci neuronowe – Inne architektury, Wydział Elektryczny, Politechnika Częstochowska, 2014, wyświetlono dnia: 07.08.2021r. https://gdudek.el.pcz.pl/files/SI/SI_wyklad8.pdf
- [81]PRACZYK, T., Probabilistic neural network application to warship radio station identification, Computational Methods in Science and Technology, CMST 13(1) pp 53-58, 2007
- [82]OSOWSKI, S., Sieci neuronowe do przetwarzania informacji, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.
- [83]STATSOFT, Automatyczne sieci neuronowe, Copyright StatSoft, Inc., Odwiedzono dnia: 27.07.2022 r. <https://www.statsoft.pl/programy/ogolna-charakterystyka/moduly-analityczne/automatyczne-sieci-neuronowe/>
- [84]DREYFUS, G.: Neural Networks - Methodology and Applications. Springer, Heidelberg (2005)
- [85]TADEUSIEWICZ, R., Szaleniec, M., Leksykon sieci neuronowych, Wrocław, 2015, ISBN: 978-83-63270-10-0

- [86]LAWRENCE, S., Giles,C.,L., Tsoi,A.,C.: What Size Neural Network Gives Optimal Generalization? Convergence Properties of Backpropagation. Technical Report UMIACS-TR-96-22 and CS-TR-3617. Institute for Advanced Computer Studies, University of Maryland. College Park, MD 20742 (1996)
- [87]PERZYK M., Kochański A., Kaczkowski W., Oprogramowanie do przewidywania własności żeliwa sferoidalnego w procesie wytopu wykorzystujące sztuczne sieci neuronowe. Program Priorytetowy Nowe Technologie, Prace Naukowe, Zeszyt 3, Politechnika Warszawska, Warszawa 2000.
- [88]MASTERS, T., Sieci neuronowe w praktyce. WNT Warszawa, 1996
- [89]MARIN, M., Marin, F.B., Potecasu F., Potecasu, O., Prediction of mechanical properties of some iron-based powder metallurgy materials using artificial neural network, International Multidisciplinary Scientific GeoConference: SGEM, Sofia, Tom 17, 2017, DOI:10.5593/sgem2017/61
- [90]GRZEGORZEWSKI P., Kochański. From Data to Reasoning, Studies in Systems, Decision and Control 183, Springer Nature Switzerland DOI: 10.1007/978-3-030-03201-2_1., 2019.
- [91]SIMPSON, J., Weiner E., Murray J., Oxford English Dictionary, Oxford University Press, ISBN: 978-0-19-861186-8
- [92]UYAN Tekin & Otto, Kevin & Silva, Maria & Vilaça, Pedro & Armakan, Elvan. (2022). Industry 4.0 Foundry Data Management and Supervised Machine Learning in Low-Pressure Die Casting Quality Improvement. International Journal of Metalcasting. 1-16. 10.1007/s40962-022-00783-z.
- [93]CHRYSSOLOURIS G, Lee M, Domroese M. The use of neural networks in determining operational policies for manufacturing systems. Journal of Manufacturing Systems. 1991;10(2):166-175
- [94]MOON YB, Chi SC. Generalized part family formation using neural network techniques. Journal of Manufacturing Systems. 1992;1(3):149-159
- [95]MOON YB. Establishment of a neurocomputing model for part family/machine group identification. Journal of Intelligent Manufacturing. 1992;3:173-182
- [96]KAPARTHI S, Suresh NC. Machine-component cell formation in group technology: A neural network approach. International Journal of Production Research. 1992;30(6):1353-1367
- [97]WU B. An introduction to neural networks and their applications in manufacturing. Journal of Intelligent Manufacturing. 1992;3:391-403

- [98] YIH Y, Liang T-P, Moskowitz H. Robot scheduling in a circuit board production line: A hybrid OR/ANN approach. *ZZE Transactions*. 1993;25(2):26-33
- [99] COOK DF, Shannon RE. A predictive neural network modelling system for manufacturing process parameters. *International Journal of Production Research*. 1992;30(7):1537-1550
- [100] BHADESHIA H.K.D.H., *Neural Networks in Materials Science*. ISIJ International, 39, s. 966, 1999.
- [101] FUJII H., Bhadeshia H. K. D. H., *Application of Neural Network Analysis in Materials* 1. Science. ISIJ International, Vol. 39, No. 10, Page. 965, 1999.
- [102] MAKI Y., Loparo K. A., A neural - network approach to fault detection and diagnosis in industrial process. *Control Systems Technology, IEEE Transactions on* Vol: 5, Issue: 6, 529-541, 1997.
- [103] PERZYK, Marcin & Kochanski, Andrzej. (2003). Detection of causes of casting defects assisted by artificial neural networks. *Proceedings of The Institution of Mechanical Engineers Part B-journal of Engineering Manufacture - PROC INST MECH ENG B-J ENG MA*. 217. 1279-1284. 10.1243/095440503322420205.
- [104] SHAFYEI A., S.H.M. Anijdan, A. Bahrami, Prediction of porosity percent in Al-Si casting alloys using ANN. *Mater. Sci. Eng. A* 431(1-2), 206-210 (2006)
- [105] KRIMPENIS, P.G. Benardos, G.C. Vosniakos, A. Koukouvitaki, Simulation-based selection of optimum pressure die-casting process parameters using neural nets and genetic algorithms. *Int. J. Adv. Manuf. Technol.* 27(5), 509-517 (2006)
- [106] RAI J.K. A.M. Lajimi, P. Xirouchakis, An intelligent system for predicting HPDC process variables In interactive environment. *J. Mater. Process. Technol.* 203(1-3), 72-79 (2008)
- [107] ZHENG, Q. Wang, P. Zhao, C. Wu, Optimization of high-pressure die-casting process parameters using artificial neural network. *Int. J. Adv. Manuf. Technol.* 44(7), 667-674 (2009)
- [108] KITTUR, J.K., Manjunath Patel, G.C. & Parappagoudar, M.B. Modeling of Pressure Die Casting Process: An Artificial Intelligence Approach. *Inter Metalcast* 10, 70-87 (2016). <https://doi.org/10.1007/s40962-015-0001-7>
- [109] CICA, D., Kramar, D. Intelligent Process Modeling and Optimization of Porosity Formation in High-Pressure Die Casting. *Inter Metalcast* 12, 814-824 (2018). <https://doi.org/10.1007/s40962-018-0213-8>

- [110] WILKINSON L., Tree structured data analysis: AID, CHAID and CART, Department of Statistics, Northwestern University, Evanston, 1992
- [111] HUNT, E. B., Marin, J., & Stone, P. J. (1966). Experiments in induction. New York: Academic
- [112] EXPLORIUM, The Complete Guide to Decision Tree Analysis, Udostępniono 2019. Pobrano 09.2022: <https://www.explorium.ai/blog/the-complete-guide-to-decision-trees/>
- [113] QUINLAN, J.R., Induction of Decision Trees. Machine Learning, 1, 81-106. <http://dx.doi.org/10.1007/BF00116251>, 1986
- [114] BUREGWA-CZUMA S., Metody stosowania wiedzy dziedzinowej do poprawiania jakości klasyfikatorów. Praca doktorska. Katowice Uniwersytet Śląski, 2017
- [115] HAN J., M. Kamber, J. Pei. Data Mining: Concepts and Techniques. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA, 3rd ed., 2011.
- [116] HUE, Sullivan & Hurlin, Christophe & Tokpavi, Sessi. (2017). Machine Learning for Credit Scoring: Improving Logistic Regression with Non Linear Decision Tree Effects. European Journal of Operational Research. 297. 10.1016/j.ejor.2021.06.053
- [117] DUMITRESCU Elena, Sullivan Hué, Christophe Hurlin, Sessi Tokpavi. Machine Learning or Econometrics for Credit Scoring: Let's Get the Best of Both Worlds. 2020. ffhal-02507499v2f
- [118] POLACEK, Tomáš & Žákovská, Martina. (2018). Decision in Implementation of Production Capacity Planning Determinated by Usage of Sensitive Analysis. Trends Economics and Management. 12. 57. 10.13164/trends.2018.31.57.
- [119] TSO, Geoffrey & Yau, Kelvin. (2007). Predicting electricity energy consumption: A comparison of regression analysis, decision tree and neural networks. Energy. 32. 1761-1768. 10.1016/j.energy.2006.11.010.
- [120] PODGORELEC V, Kokol P, Stiglic B, Rozman I. Decision trees: an overview and their use in medicine. J Med Syst. 2002 Oct;26(5):445-63. doi: 10.1023/a:1016409317640. PMID: 12182209.
- [121] BARRIENTOS MRE, Cruz RN, Acosta MHG, et al. Decision trees as a tool in the medical diagnosis. Rev Med UV. 2009;9(2):19-24.
- [122] MORAYE, Kiran & Pavate, Aruna & Nikam, Suyog & Thakkar, Smit. (2021). Crop Yield Prediction Using Random Forest Algorithm for Major Cities in Maharashtra State. International Journal of Innovative Research in Computer Science & Technology. 9. 40-44. 10.21276/ijircst.2021.9.2.7.

- [123] PRZYWARA, D. (2007). Drzewa decyzyjne, metody budowania, zastosowania. Wrocław: Wyd. Politechniki Wrocławskiej.
- [124] SIRIRUK P., Yaikratok T., Factors Analysis and Prediction in Die-casting Process for Defects Reduction. Proceedings of the International Conference on Industrial Engineering and Operations Management Istanbul, Turkey, March 7-10, 2022
- [125] KIM, J., Die-Casting Defect Prediction and Diagnosis System using Process Condition Data, Procedia Manufacturing, 2020, 51. 359-364. 10.1016/j.promfg.2020.10.051
- [126] SANGWOO P., Changgyun, Kim & Youm, Sekyoung. (2019). Establishment of an IoT-based smart factory and data analysis model for the quality management of SMEs die-casting companies in Korea. International Journal of Distributed Sensor Networks. 15. 155014771987937. 10.1177/1550147719879378.
- [127] BREIMAN, L.: Random Forests, Machine Learning, vol. 45, 5–32, 2001
- [128] ARONSZAJN N., Theory of Reproducing Kernels, Transactions of the American Mathematical Society Vol. 68, No. 3 (May, 1950), pp. 337-404, American Mathematical Society, <https://doi.org/10.2307/1990404>
- [129] VAPNIK, V., and A. Lerner. Pattern recognition using generalized portrait method. Automation and Remote Control, 24, 774–780, 1963.
- [130] BOSER, B., Guyon I., Vapnik V. A training algorithm for optimal margin classifiers. In: COLT '92: Proceedings of the Fifth Annual Workshop on Computational Learning Theory. New York, NY, USA: ACM Press, pp. 144–152, 1992.
- [131] VAPNIK, V. 1995. The Nature of Statistical Learning Theory. New York, NY: Springer-Verlag.
- [132] Stefanowski J., SVM – Support Vector Machines Metoda wektorów nośnych, 2022, Institute of Computing Sciences, Politechnika Poznańska, <http://www.cs.put.poznan.pl/jstefanowski/ml/SVM.pdf>
- [133] STATSOFT, Support Vector Method., Internetowy Podręcznik Statystyki, Odwiedzono dnia:27.07.2022 r. https://www.statsoft.pl/textbook/stathome_stat.html?https%3A%2F%2Fwww.statsoft.pl%2Ftextbook%2Fstsvm.html
- [134] JANKOWSKI N. 2003. Ontogeniczne sieci neuronowe. O sieciach zmieniających swoją strukturę, Akademicka Oficyna Wydawnicza EXIT, Warszawa.
- [135] BOIŃSKI P., Wykład pt. SVM, Instytut Informatyki, Politechnika Poznańska <http://www.cs.put.poznan.pl/pboinski/files/ED/SVM.pdf>, 2022

- [136] KOPPER A., R. Karkare, R.C. Paffenroth, D. Apelian, Model selection and evaluation for machine learning: deep learning in materials processing. *Integr. Mater.Manuf. Innov.* 9(3), 287–300 (2020)
- [137] KOPPER, A., i.in. Predicting quality of castings via supervised learning method. American Foundry Society, 2021, <https://doi.org/10.1007/s40962-021-00606-7>
- [138] KOPPER A., N. Sun, R. Karkare, R.C. Paffenroth, D. Apelian, Machine learning pathway for harnessing knowledge and data in material processing. *Int. J. Metalcast.* 15(2), 398–410 (2021). <https://doi.org/10.1007/s40962-020-00506-2>
- [139] DUCIC, N.; Jovičić, A.; Manasijević, S.; Radiša, R.; Čojbašić, Ž.; Savković, B. Application of Machine Learning in the Control of Metal Melting Production Process. *Appl. Sci.* 2020, 10, 6048. <https://doi.org/10.3390/app10176048>
- [140] CHENG Y., i in., Data and knowledge mining with big datas towards smart production. *China Journal of Industrial Information Integration*. Vol. 9. 2018, p.1-13
- [141] PUGGINI L., i in., Fault diagnosis of manufacturing systems using data mining techniques, *International Conference on Control, Decision and Information Technologies*, 2018.
- [142] WENXIANG X., A novel quality defects diagnosis method for the manufacturing process of large equipment based on product gene theory, *Symmetry Journal*, 2019, 10.3390/sym11050685
- [143] FAN P., S.L. Cockcroft, D.M. Maijer, L. Yao, C. Reilly, A.B. Phillion, Porosity prediction in A356 wheel casting. *Metall. Mater. Trans. B. Sci.* 50, 2421–2425 (2019)
- [144] BLONDHEIM D., A. Monroe, Macro porosity formation: a study in high pressure die casting. *Int. J. Metalcast.* 16(1), 330–341 (2022). <https://doi.org/10.1007/s40962-021-00602-x>
- [145] CHEN S.; Kaufmann, T. Development of Data-Driven Machine Learning Models for the Prediction of Casting Surface Defects. *Metals* 2022, 12, 1. <https://doi.org/10.3390/met12010001>
- [146] STACKOVERFLOW, forum publiczne, opublikowano: 14.04.2020r., wyświetlono: 01.11.2021r. <https://stackoverflow.com/questions/61200410/replace-outliers-in-a-dataframe-with-the-theoretical-min-max>
- [147] STEFANOWSKI J., Przetwarzanie wstępne danych, Projekt Eksploracji Danych, Wykład 3 – transformacje i dyskretyzacja, 2020, Instytut Informatyki Politechniki Poznańskiej <http://www.cs.put.poznan.pl/jstefanowski/pse/DMprepro-dyskretyzacja.pdf>

- [148] KORONACKI J., J. Mielniczuk "Statystyka dla studentów kierunków technicznych i przyrodniczych", WNT (str. 209-210, 458), 2018
- [149] PERZYK M., Dybowski B., Kozłowski J., Introducing Advanced Data Analytics in Perspective of Industry 4.0. in Die Casting Foundry. Archives of Foundry Engineering, ISSN (1897-3310), Vol. 19, Issue 1/2019, p. 53-57, 2019.
- [150] STATSOFT, Drzewa klasyfikacyjne, Internetowy Podręcznik Statystyki, Odwiedzono dnia:27.07.2022 r.,
https://www.statsoft.pl/textbook/stathome_stat.html?https%3A%2F%2Fwww.statsoft.pl%2Ftextbook%2Fstclatre.html
- [151] PERZYK M, Biernacki R, Kozłowski J. Data mining in manufacturing: Significance analysis of process parameters. Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture. 2008;222(11):1503-1516. doi:10.1243/09544054JEM1182
- [152] GARSON, D. Implementing neural network connection weights. AI Expert, 1991, 6(4), 45–51
- [153] PERZYK, M., Kochanski, A., and Kozłowski, J. Relative importance of input signals of neural network (in Polish, English abstract). Computer Meth. Mater. Sci., 3(3–4), 172–179.