



**POLITECHNIKA ŚLĄSKA**  
**WYDZIAŁ AUTOMATYKI, ELEKTRONIKI I INFORMATYKI**

**Dysertacja doktorska**

Zastosowanie systemów rozmytych do oceny jakości modeli na potrzeby wirtualnego rozruchu systemów automatyki przemysłowej

Autor: mgr inż. Łukasz Glodek

Kierujący pracą: dr hab. inż. Witold Nocoń, prof. Politechniki Śląskiej

Promotor pomocniczy: dr inż. Aneta Szyda

Gliwice, wrzesień 2023



# Spis treści

Spis tabel	3
Spis rysunków	5
Wykaz skrótów	9
<b>1 Wstęp</b>	<b>13</b>
1.1 Wstęp i opis problemu . . . . .	13
1.2 Cel pracy i zarys problemu . . . . .	15
<b>2 Przegląd literaturowy</b>	<b>17</b>
2.1 Nowe techniki symulacji i wizualizacji . . . . .	17
2.1.1 Cyfrowy bliźniak . . . . .	22
2.1.2 Cyfrowy cień . . . . .	27
2.1.3 Wirtualne uruchomienie . . . . .	27
2.1.4 Porównanie technik symulacji i wizualizacji . . . . .	35
2.2 Istniejące metody stosowane do oceny jakości modeli . . . . .	37
2.3 Logika rozmyta . . . . .	43
2.3.1 Rys historyczny . . . . .	43
2.3.2 Zbiory rozmyte . . . . .	44
2.3.3 Systemy rozmyte . . . . .	62
<b>3 Materiał i metody badawcze</b>	<b>69</b>
3.1 Charakterystyka zbiorów danych pomiarowych i obiektu badawczego . . . . .	69
3.1.1 Kaskada dwóch zbiorników . . . . .	69
3.1.2 Wahadło . . . . .	70
3.1.3 Przenośnik pasowy . . . . .	70
3.2 Analiza i wstępne przetwarzanie danych . . . . .	71
3.3 Współczynnik jakości modelu . . . . .	81

<b>4</b>	<b>Wyniki</b>	<b>95</b>
4.1	Kaskada dwóch zbiorników . . . . .	95
4.2	Wahadło . . . . .	100
4.3	Przenośnik paskowy . . . . .	105
<b>5</b>	<b>Dyskusja</b>	<b>115</b>
<b>6</b>	<b>Podsumowanie</b>	<b>123</b>
<b>7</b>	<b>Streszczenie</b>	<b>127</b>
<b>8</b>	<b>Abstract</b>	<b>129</b>
	<b>Bibliografia</b>	<b>131</b>

# Spis tabel

2.1	Porównanie cech cyfrowego bliźniaka, cyfrowego cienia oraz wirtualnego uruchomienia . . . . .	35
2.2	Zakres wartości przyjmowanych przez miary jakości modelu. . . . .	41
2.3	Najpopularniejsze $t$ -normy. . . . .	48
2.4	Najpopularniejsze $s$ -normy. . . . .	48
3.1	Szczegółowa lista podzespołów zastosowanych w przenośniku paskowym. . . . .	71
3.2	Ustawienia systemu TSK. . . . .	85
3.3	Wartości parametrów Gaussowskiej funkcji przynależności. . . . .	86
3.4	Wartości parametrów GA funkcji przynależności. . . . .	87
3.5	Wartości parametrów PSO funkcji przynależności. . . . .	88
3.6	Wartości parametrów SA funkcji przynależności. . . . .	89
3.7	Wartości parametrów $GPS$ funkcji przynależności. . . . .	90
3.8	Wielkość efektu $d$ Cohena. . . . .	91
4.1	Parametry modelu MAX. . . . .	99
4.2	Parametry modelu ARMA. . . . .	104
4.3	Wyniki testu Shapiro-Wilka. . . . .	106
4.4	Wyniki rozszerzonego testu Dickeya-Fullera. . . . .	108
4.5	Parametry modelu NARMAX. . . . .	111
4.6	Parametry modelu ARX. . . . .	113
5.1	Przykładowe wyniki dla modelu DOBREGO i ZŁEGO. . . . .	117
5.2	Wyniki testu Wilcoxona. . . . .	118
5.3	Wyniki poszczególnych miar dla modelu dobrze przyporządkowanego oraz dla dwóch źle przyporządkowanych do grupy $ZŁA$ . . . . .	120



# Spis rysunków

2.1	Graf połączeń sieciowych pomiędzy słowami kluczowymi „ <i>digital shadow</i> ”, „ <i>digital twin</i> ”, „ <i>virtual commissioning</i> ”, „ <i>industry 4.0</i> ” w latach 2017-2020 . . . . .	18
2.2	Rozmiar globalnego rynku cyfrowego bliźniaka w poszczególnych regionach świata, lata 2016 - 2027 (mln USD). . . . .	19
2.3	Diagram kołowy pokazujący przyczyny niewdrożenia <i>DT</i> w różnych rodzajach przemysłu. . . . .	19
2.4	Diagram kołowy przedstawiający procentowy rozkład respondentów mających plany wdrożenia <i>DT</i> bądź etapy wdrożenia <i>DT</i> . . . . .	20
2.5	Diagram słupkowy przedstawiający fazy wdrożenia <i>DT</i> z podziałem na procesy produkcji dyskretniej, wsadowej i procesowej. . . . .	20
2.6	Wpływ pandemii COVID-19 na kierunek i szybkość zmian rynku <i>DT</i> . . . . .	21
2.7	Wizja <i>Smart Manufacturing</i> ilustrująca miejsce cyfrowego bliźniaka w procesie produkcyjnym. . . . .	25
2.8	Przykładowe techniki modelowania. . . . .	26
2.9	Główna idea wirtualnego uruchomienia. . . . .	28
2.10	Liczba artykułów naukowych dotyczących wirtualnego uruchomienia na przestrzeni lat 2015-2022. Diagram został stworzony na podstawie danych pochodzących z platformy <i>Digital Science's Dimensions</i> [1]. . . . .	29
2.11	Wirtualne uruchomienie jako kluczowa składowa cyfrowego bliźniaka. . . . .	30
2.12	Sposoby uruchomienia systemów produkcyjnych. . . . .	31
2.13	Liczba publikacji dotyczących wirtualnego uruchomienia w poszczególnych obszarach badawczych ANZSRC 2020 na przestrzeni lat 2014-2022. Diagram został stworzony na podstawie danych pochodzących z platformy <i>Digital Science's Dimensions</i> [1]. . . . .	33
2.14	Wirtualne uruchomienie. . . . .	36
2.15	Cyfrowy cień. . . . .	36

2.16	Cyfrowy bliźniak. . . . .	36
2.17	Nośnik zbioru rozmytego. . . . .	46
2.18	Rdzeń zbioru rozmytego. . . . .	46
2.19	Szerokość zbioru rozmytego. . . . .	47
2.20	Trójkątna funkcja przynależności. . . . .	50
2.21	Trapezowa funkcja przynależności. . . . .	50
2.22	Prostokątna funkcja przynależności. . . . .	51
2.23	Gaussowska funkcja przynależności. . . . .	52
2.24	Złożona Gaussowska funkcja przynależności. . . . .	52
2.25	Uogólniona dzwonowa funkcja przynależności - zmiana parametru $\sigma$ . . . . .	53
2.26	Uogólniona dzwonowa funkcja przynależności - zmiana parametru $\gamma$ . . . . .	53
2.27	Sigmoidalna funkcja przynależności - $\beta < 0$ . . . . .	54
2.28	Sigmoidalna funkcja przynależności - $\beta > 0$ . . . . .	54
2.29	Funkcja przynależności typu S - wpływ parametru $a$ na kształt funkcji. . . . .	55
2.30	Funkcja przynależności typu S - wpływ parametru $c$ na kształt funkcji. . . . .	56
2.31	Funkcja przynależności typu Z - wpływ parametru $a$ na kształt funkcji. . . . .	56
2.32	Funkcja przynależności typu Z - wpływ parametru $c$ na kształt funkcji. . . . .	57
2.33	Funkcja przynależności typu PI. . . . .	57
2.34	Algorytm genetyczny - schemat. . . . .	58
2.35	Rój cząstek - schemat. . . . .	59
2.36	Algorytm wyszukiwania wzorca (T- Tak, N - Nie). . . . .	60
2.37	Algorytm symulowanego wyżarzania - schemat. . . . .	61
3.1	Zbiorniki w układzie kaskadowym. . . . .	69
3.2	Wahadło. . . . .	70
3.3	Przenośnik paskowy. . . . .	70
3.4	Proces wstępnego przetwarzania danych oraz wyboru modelu. . . . .	72
3.5	Przykładowy wykres pudełkowy. . . . .	73
3.6	Virtual Commissioning-Model-Fuzzy coefficient (VCMF). . . . .	81
3.7	Wykres gęstości prawdopodobieństwa - przykład współczynników różnicujących: $NRMSE$ (wykres górny), $MAE$ (środkowy) oraz $MIA$ (dolny). . . . .	82
3.8	Wykres gęstości prawdopodobieństwa - przykład współczynników nieróżnicujących: $PPMCC$ (wykres górny) oraz $RIA$ (dolny). . . . .	83
3.9	Struktura systemu wnioskowania rozmytego $VCMF$ . . . . .	84
3.10	Schemat doboru parametrów funkcji przynależności z użyciem algorytmów optymalizacji. . . . .	87



3.11	Wykres zbieżności kosztu optymalizacji od numeru iteracji. . . . .	88
3.12	Wykres zbieżności kosztu optymalizacji od numeru iteracji. . . . .	89
3.13	System rozmyty TSK o 4 wejściach, 1 wyjściu i 6 regułach. . . . .	92
3.14	Dekompozycja rozkładu wartości wyjściowych VCMF na składowe Gaus- sowskie. . . . .	93
4.1	Dane pomiarowe uzyskane dla kaskadowego układu dwóch zbiorników.	95
4.2	Wykres pudełkowy dla kaskady dwóch zbiorników. . . . .	96
4.3	Mapa cieplna korelacji rangowej Spearmana pomiędzy zmiennymi. . . .	96
4.4	Wynik dekompozycji szeregu czasowego. . . . .	97
4.5	Korelogram poziomu cieczy dolnego zbiornika (ACF). . . . .	98
4.6	Wykres korelacji cząstkowej poziomu cieczy dolnego zbiornika (PACF).	98
4.7	Wykres opóźnień (ang. <i>lag</i> ). . . . .	99
4.8	Kaskadowy układ dwóch zbiorników. . . . .	100
4.9	Dane pomiarowe uzyskane dla wahadła. . . . .	101
4.10	Wynik dekompozycji szeregu czasowego. . . . .	102
4.11	Korelogram kąta nachylenia wahadła (ACF). . . . .	102
4.12	Funkcja korelacji cząstkowej kąta nachylenia wahadła. . . . .	103
4.13	Wykres opóźnień (ang. <i>lag</i> ). . . . .	103
4.14	Wahadło. . . . .	104
4.15	Przebiegi czasowe dla prądu, prędkości oraz momentu obrotowego w trak- cie normalnej pracy. . . . .	105
4.16	Wykresy pudełkowe dla prądu, prędkości oraz momentu obrotowego, <i>rozmiar próbki = 500</i> . . . . .	106
4.17	Wykres zależności prądu, prędkości i momentu obrotowego. . . . .	107
4.18	Mapa cieplna korelacji rangowej Spearmana pomiędzy zmiennymi. . . .	108
4.19	Wynik dekompozycji szeregu czasowego. . . . .	109
4.20	Korelogram prądu (ACF). . . . .	110
4.21	Funkcja korelacji cząstkowej prądu (PACF). . . . .	110
4.22	Wykres opóźnień (ang. <i>lag</i> ) dla prądu. . . . .	111
4.23	Korelogram momentu obrotowego (ACF). . . . .	112
4.24	Funkcja korelacji cząstkowej momentu obrotowego (PACF). . . . .	112
4.25	Wykres opóźnień (ang. <i>lag</i> ) dla momentu obrotowego. . . . .	113
4.26	Porównanie dopasowania modeli do danych rzeczywistych. . . . .	114
5.1	Histogram MIA. . . . .	115

5.2	Histogram VCMF. . . . .	116
5.3	Wykres pudełkowy dla grupy złych modeli. . . . .	119
5.4	Wykres pudełkowy dla grupy dobrych modeli. . . . .	120
5.5	Dopasowanie modelu do danych rzeczywistych w sytuacji awaryjnej. . .	121

# Wykaz skrótów

**ACF** Funkcja autokorelacji (ang. *autocorrelation function*).

**AIC** Kryterium informacyjne Akaikiego (ang. *Akaike Information Criterion*).

**AR** Model autoregresyjny (ang. *Autoregressive Model*).

**ARIMA** Zintegrowany model autoregresji i średniej ruchomej (ang. *Autoregressive Integrated Moving Average Model*).

**BIC** Bayesowskie Kryterium Informacyjne (ang. *Bayesian Information Criterion*).

**COG** metoda środka ciężkości (ang. *Center of Gravity*).

**DM** cyfrowy model (ang. *Digital Model*).

**DS** cyfrowy cień (ang. *Digital Shadow*).

**DT** cyfrowy bliźniak (ang. *Digital Twin*).

**DTVC** realizacja wirtualnego uruchomienia oparta o technologię cyfrowego bliźniaka (ang. *Digital Twin Virtual Commissioning*).

**EDT** eksperymentalny cyfrowy bliźniak (ang. *Experimental Digital Twin*).

**EVS** ang. *Explained Variance Score*.

**FE** błąd prognozowania (ang. *Forecast Error*).

**FLC** rozmyty sterownik logiczny (ang. *Fuzzy Logic Controller*).

**GA** algorytm genetyczny (ang. *Genetic Algorithm*).

**GMM** Modelowanie Mieszanin Gaussowskich (ang. *Gaussian Mixture Modeling*).

- GPS** Algorytm wyszukiwania wzorca (ang. *Generalized Pattern Search*).
- HiL** ang. *Hardware in the Loop*.
- HM** metoda wysokości (ang. *Height Method*).
- HMI** panel operatorski (ang. *Human Machine Interface*).
- IO** wejście i wyjście (ang. *Inputs and Outputs*).
- MA** system rozmyty Mamdaniego-Assilana.
- MAE** średni błąd absolutny (ang. *Mean Absolute Error*).
- MAPE** średni procentowy błąd prognozy (ang. *Mean Absolute Percentage Error*).
- MBSE** cyfrowy bliźniak z inżynierią systemową opartą na modelu(ang. *Model-Based Systems Engineering*).
- MD** metoda maksimum (ang. *Maximum Defuzzifier*).
- ME** maksymalny błąd resztkowy (ang. *Maximum Residual Error*).
- MedAE** średni absolutny błąd medianowy (ang. *Median Absolute Error*).
- MFE** średni błąd prognozowania (ang. *Mean Forecast Error*).
- MIA** zmodyfikowany indeks zgodności (ang. *Modified Index of Agreement*).
- MSE** błąd średniokwadratowy (ang. *Mean-Squared Error*).
- MSLE** średniokwadratowy błąd logarytmiczny (ang. *Mean Squared Logarithmic Error*).
- NARMAX** nieliniowy model autoregresyjny średniej ruchomej z zewnętrznym pobudzeniem (ang. *Nonlinear AutoRegressive Moving Average with eXogenous input*).
- NC** sterowanie numeryczne, (ang. *Numerical Control*).
- NRMSE** znormalizowany pierwiastkowy błąd średniokwadratowy (ang. *Normalized Root Mean Squared Error*).
- PACF** funkcja korelacji cząstkowej (ang. *Partial Autocorrelation Function*).

- PLC** programowalny sterownik logiczny(ang. *Programmable Logic Controller*).
- PPMCC** współczynnik korelacji Pearsona (ang. *Pearson Product-Moment Correlation Coefficient*).
- PSO** optymalizacja za pomocą roju cząstek (ang. *Particle Swarm Optimization*).
- RIA** względny indeks zgodności (ang. *Relative Index of Agreement*).
- RiL** ang. *Reality in the Loop*.
- RMSE** pierwiastkowy błąd średniokwadratowy (ang. *Root Mean Squared Error*).
- RRSE** pierwiastek względnego błęd kwadratowego (ang. *Root Relative Squared Error*).
- SA** symulowane wyżarzanie (ang. *Simmulated Annealing Algorithm*).
- SiL** ang. *Software in the Loop*.
- SISO** jedno wejście, jedno wyjście (ang. *Single Input Single Output*).
- sMAPE** symetryczny średni procentowy błąd prognozy (ang. *Symmetric Mean Absolute Percentage Error*).
- TFS** system rozmyty Tsukamoto.
- TSK** system rozmyty Takagi-Sugeno-Kanga.
- VC** wirtualne uruchomienie (ang. *Virtual Commissioning*).
- VCMF** współczynnik jakości oparty na logice rozmytej (ang. *Virtual Commissioning-Model-Fuzzy coefficient*).



# Rozdział 1

## Wstęp

### 1.1 Wstęp i opis problemu

Złożoność nowoczesnych linii produkcyjnych nieustannie rośnie, a tym samym rosną wymagania stawiane systemom automatyki przemysłowej. Obecnie walidacja i testowanie systemu automatyki stanowi wymagające zadanie, które musi być zrealizowane w ściśle określonych, nierzadko bardzo krótkich, ramach czasowych i według ściśle określonych harmonogramów. Dlatego wykorzystanie technik symulacji do sprawdzenia systemu automatyki już na wczesnym etapie prac inżynierskich jest bardzo korzystne [2]. W chwili obecnej jedną z dynamicznie rozwijających się technik symulacji jest wirtualne uruchomienie, nazywane również *wirtualnym rozruchem*. W niniejszej pracy skupiono się na zastosowaniu wirtualnego uruchomienia do przebudowy istniejącej linii produkcyjnej oraz do szkolenia operatorów. Jednym z najważniejszych etapów wirtualnego uruchomienia opartego na modelu jest weryfikacja modelu matematycznego obiektu, który będzie uruchamiany. Z punktu widzenia wirtualnego rozruchu niezwykle ważne jest, aby model jak najwierniej odzwierciedlał zachowanie obiektu rzeczywistego z pewnym minimalnym dopuszczalnym błędem i reagował na wszystkie sygnały sterujące. Istnieje wiele miar stosowanych do oceny jakości modelu (szczegółowo opisane w *Rozdziale 2.2*), jednak każda z nich w inny sposób ocenia jakość dopasowania modelu do danych rzeczywistych, co implikuje trudność w wyborze odpowiedniej miary do jednoznacznej oceny jakości modelu pod kątem jego użycia na cele wirtualnego rozruchu. Dodatkowo, zakresy wartości przyjmowanych przez wspomniane miary różnią się od siebie, przy czym niektóre z miar nie mają ograniczonych zakresów. Dlatego też tak ważne jest usystematyzowanie wiedzy dotyczącej sposobu oceny jakości modelu oraz używanych w tym celu miar. Jedne z najnowszych prac dotyczących wirtualnego uru-

chomienia (rok 2022), takie jak [3], [4] oraz [5] wskazują, iż problem określenia jakości modelu i poprawności odwzorowania pierwowzoru nie został jeszcze w pełni zbadany. W niniejszej pracy podjęto próbę usystematyzowania wiedzy na temat powszechnie istniejących miar stosowanych do oceny jakości modelu, a także zaproponowano metodologię do wstępnego przetwarzania danych pomiarowych otrzymanych z różnych typów obiektów przemysłowych prowadzącą do wyboru klasy i typu modelu. Ponadto biorąc pod uwagę różne informacje, które są niesione przez różne miary stosowane do oceny jakości modelu, skonstruowano system wnioskowania rozmytego Takagi-Sugeno-Kanga. Taki typ systemu jest najczęściej używany do dyskretnych danych uzyskanych w sposób eksperymentalny [6]. Wspomniany system rozmyty pozwala również na zastosowanie wiedzy eksperckiej z zakresu wirtualnego rozruchu systemów automatyki przemysłowej. Jest to niezwykle istotne, ponieważ w dzisiejszych czasach rynek wirtualnego uruchomienia podlega ciągłym zmianom i rozwija się w sposób niezwykle dynamiczny. Badania wstępne zostały przeprowadzone na modelach kaskadowego układu zbiorników i wahadła, które zostały stworzone na podstawie danych symulacyjnych. Dodatkowo przeprowadzono studium przypadku dotyczące przenośnika paskowego, z którego zebrane zostały dane pomiarowe. Zebrane dane poddano szczegółowej analizie statystycznej oraz przetwarzaniu wstępnemu, w wyniku czego otrzymano modele. Następnie za pomocą zaproponowanego współczynnika jakości opartego na systemie rozmytym oceniono modele pod kątem ich przydatności na cele wirtualnego uruchomienia. Badania przedstawione w niniejszej pracy są oparte na połączeniu wiedzy z zakresu statystyki, modelowania, algorytmów optymalizacji, systemów rozmytych oraz wiedzy eksperckiej z zakresu wirtualnego uruchomienia.

Praca składa się z sześciu rozdziałów. W rozdziale pierwszym przedstawiono cel pracy oraz zarys problemu. Rozdział drugi zawiera szczegółowy przegląd literaturowy technik symulacji i wizualizacji, opisano w nim również istniejące metody stosowane do oceny jakości modeli oraz logikę rozmytą. Trzeci rozdział zawiera opis obiektu badawczego i danych pomiarowych oraz metodologię ich wstępnego przetwarzania i analizy, prowadzącą do wyboru klasy i typu modelu. W rozdziale tym zawarty jest również opis stworzonego współczynnika do oceny jakości modelu na cele wirtualnego uruchomienia. W rozdziale czwartym przedstawiono otrzymane wyniki i porównanie z istniejącymi metodami służącymi do oceny jakości modelu. W rozdziale piątym przedstawiono zalety oraz ograniczenia zaproponowanego współczynnika do oceny jakości modelu. Rozdział szósty stanowi podsumowanie niniejszej pracy.



## 1.2 Cel pracy i zarys problemu

Głównym celem badań przedstawionych w niniejszej dysertacji jest ocena jakości modeli stosowanych w wirtualnym uruchomieniu systemów automatyki przemysłowej przy użyciu systemów rozmytych. Dzięki zastosowanej metodzie oceny jakości modelu, istnieje możliwość szybkiego sprawdzenia przydatności modelu na potrzeby wirtualnego rozruchu. Metoda oparta na systemach wnioskowania rozmytego umożliwia łatwą rozbudowę, zgodnie z nowymi wytycznymi wprowadzanymi w przemyśle, a także nieustannie rozwijającą się wiedzą ekspertów. W ostatnich latach nastąpił znaczny wzrost zainteresowania wdrożeniem techniki wirtualnego uruchomienia w różnych obszarach badawczych, co zostało przedstawione w *Rozdziale 2.1.3*. Implikuje to konieczność zastosowania wiedzy eksperckiej z różnych dziedzin. Dlatego też niezwykle ważne jest stworzenie metody umożliwiającej łatwe i szybkie rozbudowanie o wiedzę ekspercką, co umożliwia zastosowanie systemów wnioskowania rozmytego.

Cel badawczy jest następujący: wdrożenie metody do oceny jakości modeli na potrzeby wirtualnego uruchomienia systemów automatyki przemysłowej z użyciem systemów wnioskowania rozmytego. Metoda ta pozwala na efektywną ocenę modelu na podstawie danych pomiarowych zebranych z systemu automatyki przemysłowej (linii produkcyjnej).

Niniejsza metoda pozwoli na optymalizację procesu wirtualnego rozruchu ciągłych systemów automatyki przemysłowej poprzez umożliwienie szybkiej oceny jakości modelu. Zaproponowana metoda została już wykorzystana w projekcie NCBiR realizowanym przez firmę PROPOINT S.A. pt. „Opracowanie innowacyjnej usługi przewidywania i wczesnego ostrzegania o możliwych awariach linii produkcyjnych”, co świadczy o niesionej przez nią wartości dodanej dla przedsiębiorstwa.

Cel zostanie osiągnięty poprzez:

1. stworzenie systemu wnioskowania rozmytego *VCMF* (ang. *Virtual Commissioning-Model-Fuzzy Coefficient*) w celu oceny jakości modelu
2. zastosowanie wiedzy eksperckiej z zakresu wirtualnego uruchomienia do stworzenia bazy wiedzy systemu rozmytego.



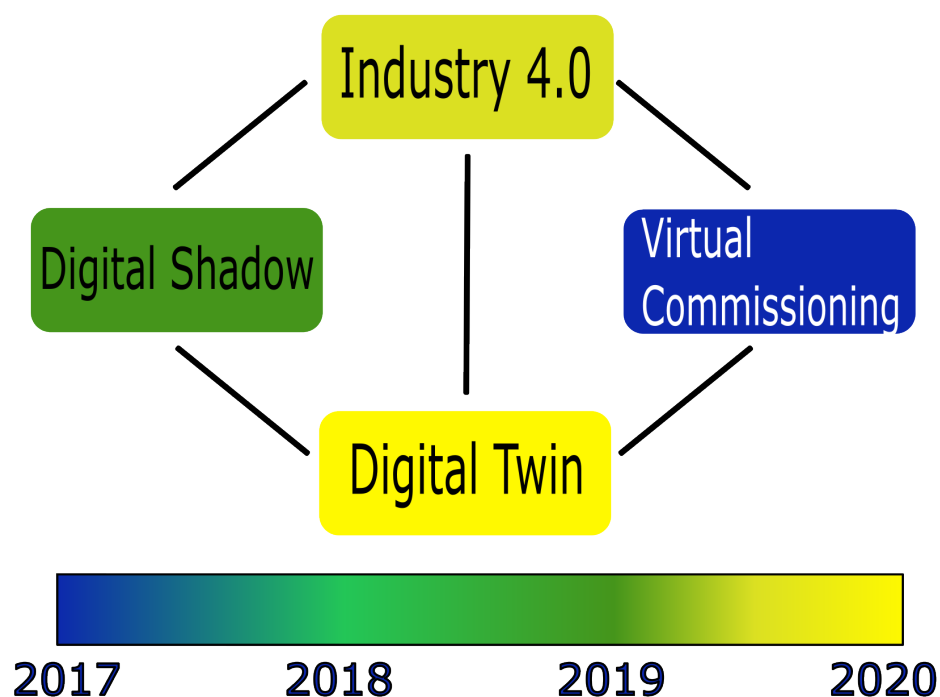
# Rozdział 2

## Przegląd literaturowy

### 2.1 Nowe techniki symulacji i wizualizacji

Nowe techniki symulacji są niezwykle istotne ze względu na ich szerokie zastosowanie w *Przemysle 4.0* oraz w procesie transformacji cyfrowej przedsiębiorstw. *Przemysł 4.0* opiera się na połączeniu środowiska fizycznego i cyfrowego ekosystemu [7], a jego najważniejszymi składowymi są technologie modelowania i symulacji [8]. Modelowanie jest kluczowym etapem przed uruchomieniem nowego procesu, służy do przeprowadzenia wielokryterialnej analizy, a symulacja pozwala na doskonalenie procesów operacyjnych [8]. Z *Przemysłu 4.0* wyłoniła się nowa idea pozwalająca na zwiększenie wydajności procesu produkcyjnego - *Smart Manufacturing* [9]. Jej kluczowym aspektem jest monitorowanie i sterowanie procesami fizycznymi poprzez systemy cyfrowe [9], co przyczyniło się do wzrostu zainteresowania ideą cyfrowego bliźniaka (*DT*, ang. *Digital Twin*). Cyfrowy bliźniak wyłonił się z połączenia idei cyfrowego cienia (*DS*, ang. *Digital Shadow*) z wirtualnym uruchomieniem (*VC*, ang. *Virtual Commissioning*). Wspomniane idee różnią się między sobą kierunkowością automatycznego przepływu danych pomiędzy obiektem rzeczywistym a jego cyfrowym odpowiednikiem - cyfrowy cień charakteryzuje się jednokierunkowym przepływem danych z obiektu rzeczywistego do cyfrowego odpowiednika, natomiast cyfrowy bliźniak cechuje dwukierunkowy przepływ danych (pomiar, sterowanie) [10] [11], czyli od obiektu do cyfrowego odpowiednika (ciągle) oraz od cyfrowego odpowiednika do obiektu (na żądanie). Cyfrowy odpowiednik składa się z co najmniej jednego modelu. Jednokierunkowy przepływ danych do cyfrowego cienia oraz brak modelu obiektu implikuje fakt, iż cyfrowy cień staje się wyłącznie techniką wizualizacji, a nie symulacji. Wirtualne uruchomienie, nazywane też *wirtualnym rozruchem*, polega na tworzeniu oprogramowania testowego na bazie wcześniej stworzonych modeli [10].

Implementacja nowoczesnych rozwiązań w procesie produkcyjnym jest możliwa dzięki zastosowaniu trzech wspomnianych idei razem. Po przeszukaniu bazy *Web of Science* pod kątem liczby artykułów naukowych zawierających słowa kluczowe „*digital shadow*”, „*digital twin*”, „*virtual commissioning*”, „*industry 4.0*” otrzymano 1631 artykułów naukowych. Na *Rysunku 2.1* przedstawiono graf połączeń sieciowych pomiędzy wspomnianymi słowami kluczowymi na przestrzeni lat 2017-2020 [11].

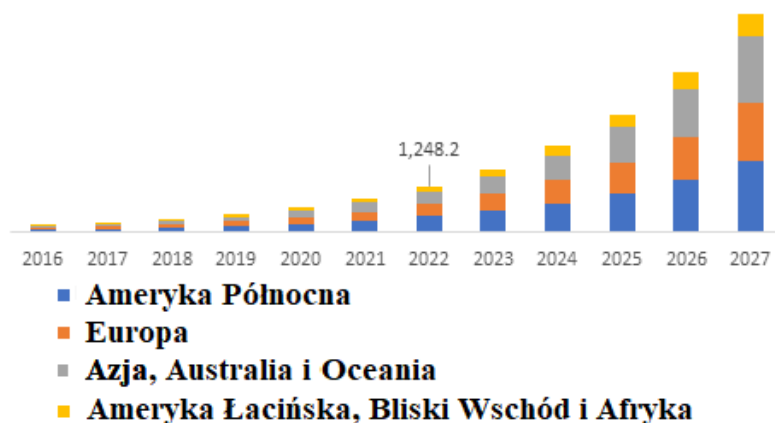


Rysunek 2.1: Graf połączeń sieciowych pomiędzy słowami kluczowymi „*digital shadow*”, „*digital twin*”, „*virtual commissioning*”, „*industry 4.0*” w latach 2017-2020 [12].

Analiza *Rysunku 2.1* pokazuje, że najwięcej prac dotyczy *DT*. Obecnie *DS* jest stopniowo wypierany przez *DT*. *VC* nigdy nie zostało jednocześnie opisane razem z *DS* i *DT*. Wirtualne uruchomienie wraz z ideą cyfrowego cienia tworzą ideę cyfrowego bliźniaka. W pewnym uproszczeniu można stwierdzić, iż cyfrowy bliźniak wyewoluował z idei wirtualnego uruchomienia. Dlatego wszelkie techniki służące do oceny modeli dla wirtualnego uruchomienia będą mogły zostać wykorzystane w ocenie cyfrowego bliźniaka [11].

W ostatnich latach można zaobserwować najbardziej dynamiczny rozwój koncepcji cyfrowego bliźniaka, wskutek czego pojawiają się raporty i prognozy marketingowe pozwalające na analizę najnowszych trendów rynkowych pod kątem tej techniki. Raport

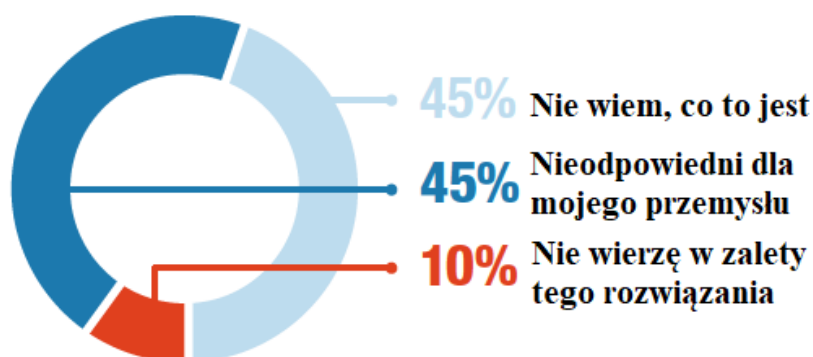
stworzony przez *Global Market Insights Inc.* w 2012 roku pokazuje, iż rynek cyfrowego bliźniaka przekroczy 50 miliardów USD do roku 2027 (*Rysunek 2.2*) [11] [13].




Rysunek 2.2: Rozmiar globalnego rynku cyfrowego bliźniaka w poszczególnych regionach świata, lata 2016 - 2027 [mld USD][13].

Autorzy wskazują również, że zainteresowanie cyfrowym bliźniakiem cechuje stopniowy wzrost z tego względu, iż dzięki zastosowaniu tej koncepcji w przedsiębiorstwie firma może przewidywać swoje wyniki biznesowe i monitorować wydajność różnych komponentów przemysłowych w poszczególnych obiektach [11] [13].

Z kolei analiza wyników ankiety przeprowadzonej przez *LNS Research* [14] (*Rysunek 2.3*, *Rysunek 2.4*) wykazała, iż idea cyfrowego bliźniaka nie jest w ogóle znana aż 45% respondentom, a pozostała część badanych uważa, że jego wprowadzenie nie będzie miało wymiernej korzyści w odniesieniu do ich przemysłu. Ponadto aż 25% przedsiębiorstw nie planuje wdrożenia cyfrowego bliźniaka [11].

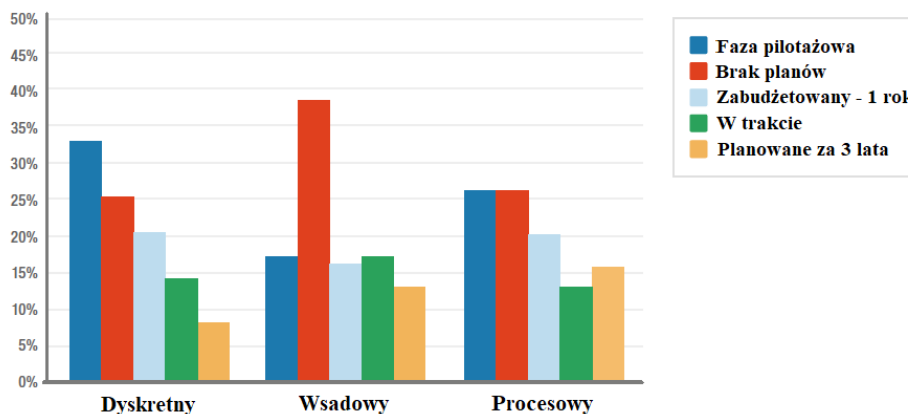


Rysunek 2.3: Diagram kołowy pokazujący przyczyny niewdrożenia DT w różnych rodzajach przemysłu [14].




Rysunek 2.4: Diagram kołowy przedstawiający procentowy rozkład respondentów mających plany wdrożenia *DT* bądź etapy wdrożenia *DT* [14].

Ponadto analizując *Rysunek 2.5* można zauważyć, iż w fabrykach wykorzystujących dyskretny proces produkcji dominuje faza pilotażowa, natomiast ponad 35% fabryk o procesie wsadowym nie ma planów wdrożenia cyfrowego bliźniaka. Z kolei fabryki stosujące procesowy typ produkcji cechują się równą liczbą (ponad 20%) fabryk będących w fazie pilotażowej wdrożenia cyfrowego bliźniaka oraz fabryk, które nie mają planów wdrożenia [11].



Rysunek 2.5: Diagram słupkowy przedstawiający fazy wdrożenia *DT* z podziałem na procesy produkcji dyskretnej, wsadowej i procesowej [14].

Pandemia COVID-19 miała wpływ również na tę część rynku automatyki. Analizując *Rysunek 2.6* można zauważyć, iż lawinowy wzrost został zapoczątkowany w roku 2022 i będzie trwał aż do roku 2026 [11] [15].



Rysunek 2.6: Wpływ pandemii COVID-19 na kierunek i szybkość zmian rynku *DT* [15].

Analiza wyników wyżej przytoczonych raportów, analiz i ankiet wykazała, że cyfrowy bliźniak zwiększa swoje znaczenie w gospodarce i przemyśle, ponieważ łączy środowisko fizyczne z wirtualnym. Jednakże wiedza na temat korzyści, jakie mogą płynąć z jego wdrożenia, nie jest powszechna [11]. Cyfrowy bliźniak oraz wirtualne uruchomienie mogą być stosowane w różnych gałęziach przemysłu.

Rynek wirtualnego uruchomienia opiewał w 2021 roku na 540,1 miliardów USD. Pandemia COVID-19 spowodowała niższy popyt niż oczekiwano, w porównaniu do lat sprzed pandemii, we wszystkich regionach świata. Raport przewiduje, że do roku 2028 rynek wirtualnego uruchomienia osiągnie wartość 1544,3 miliardów USD, a średnia roczna stopa wzrostu w przewidywanym okresie osiągnie poziom 16% [16]. Rynek wirtualnego uruchomienia jest podzielony na gałęzie przemysłu, takie jak: rynek lotniczy i obrona, rynek motoryzacyjny i transportowy, rynek produkcji maszyn oraz rynek energetyczny i mediów. Analizując poniższy raport można zauważyć, iż do roku 2028 rynek wirtualnego uruchomienia zdominuje przemysł motoryzacyjny i transportowy [16].

Przeгляд wspomnianych wyżej nowych technologii symulacji został opisany i opublikowany w [11].

### 2.1.1 Cyfrowy bliźniak

Cyfrowy bliźniak tworzą modele (typu *Black Box* - struktura modelu jest nieznana, jest to modelowanie tylko na podstawie wejść i wyjść; *Grey Box* - struktura modelu jest częściowo znana, parametry modelu są dopasowywane na podstawie sygnałów wejściowo-wyjściowych; typu *White Box* - liniowe/nieliniowe równania różniczkowe opierające się na prawach fizyki), które reprezentują obiekty fizyczne. Modele te stale dostosowują się do zmian operacyjnych w oparciu o dane zbierane bezpośrednio z obiektów fizycznych. *DT* można wdrożyć w systemach cyberfizycznych [5]. Od cyfrowych bliźniaków oczekuje się, że będą prognozować zmianę stanu obiektu fizycznego poprzez proces wymiany danych. Taka wymiana pomiędzy domeną fizyczną a wirtualną może być przeprowadzona zgodnie z ograniczeniami w czasie rzeczywistym. Przykładem cyfrowego bliźniaka może być robot przemysłowy wraz z kamerą cyfrową sprzęgnięty ze swoją wirtualną kopią (modelem). W wyniku zużywania się podzespołów robota (łożyska, silniki, etc.) po czasie robot nie osiąga zadanych współrzędnych w przestrzeni, wskutek czego pojawia się błąd. Istnieją takie zastosowania robotów, w których minimalny błąd w osiągnięciu zadanego punktu dyskwalifikuje robota z dalszej pracy. W celu wydłużenia przydatności robota, można połączyć go z jego cyfrowym bliźniakiem, który na bieżąco, w każdym cyklu pracy robota, sprawdza za pomocą kamery cyfrowej dokładność osiągniętych punktów. W momencie pojawienia się błędów, cyfrowy bliźniak jest w stanie na bieżąco wprowadzać poprawki w celu minimalizacji błędów. W niniejszym przykładzie, dane są przesyłane dwukierunkowo: z robota do cyfrowego bliźniaka oraz z cyfrowego bliźniaka do robota. Cyfrowe bliźniaki mogą również dostarczać do systemu informacje i status operacyjny, dostarczając możliwości tworzenia nowych modeli biznesowych oraz dokładniejszych prognoz. Inne zastosowania *DT* obejmują redukcję kosztów i ryzyka oraz poprawę wydajności, bezpieczeństwa i odporności [5]. Ponadto cyfrowy bliźniak umożliwia mniejsze zużycie materiału (np. różnego rodzaju odczynników w przemyśle farmaceutycznym bądź chemicznym), co prowadzi do zwiększenia wydajności procesu, zmniejszenia liczby eksperymentów koniecznych do przeprowadzenia [17] oraz eliminacji niepewności, niedokładności i rozbieżności poprzez wdrożenie rozwiązań z technik głębokiego uczenia bądź uczenia maszynowego [11].

Cyfrowe bliźniaki są szeroko stosowane w różnych gałęziach przemysłu, takich jak robotyka, automatyka, inteligentne miasta czy sieci 5G [18]. Wdrożenie *DT* zapew-



nia wiele korzyści w zarządzaniu obiektami fizycznymi. Na przykład, aby przewidzieć i zoptymalizować zachowanie systemu, tj. za pomocą modeli, a nawet technik uczenia maszynowego, można przewidzieć przyszłe zachowania systemu i poprawić produktywność procesu. *DT* może być wykorzystywany do automatycznego monitorowania stanu maszyn i urządzeń linii produkcyjnej, dzięki czemu dział utrzymania ruchu wcześniej otrzymuje informację o możliwym wystąpieniu sytuacji awaryjnej, która może skutkować zatrzymaniem procesu lub linii produkcyjnej. *DT* może być również używany do ciągłego monitorowania poprzez akwizycję danych w czasie rzeczywistym. Dzięki temu *DT* może dostarczać informacji w celu podejmowania lepszych decyzji biznesowych i kontrolowania systemu fizycznego. Cyfrowe bliźniaki mogą zapewnić platformę testową do weryfikacji różnych scenariuszy w celu wybrania najbardziej wydajnego i zwiększenia wydajności systemu. Innym powszechnym zastosowaniem *DT* jest poprawa bezpieczeństwa i odporności dzięki jego zdolności do wykrywania niepożądanych działań w systemie. Co więcej, jego zastosowanie pozwala na lepszą ocenę ryzyka w celu przetestowania różnych przypadków, które mogą mieć wpływ na obiekty fizyczne.

W przemyśle wykorzystuje się go do [11] [17] [19] [20]:

1. oceny złożonych problemów,
2. jako narzędzia do testowania i walidacji,
3. monitorowania i zarządzania procesem bądź obiektem w czasie rzeczywistym,
4. prognoz symulacyjnych,
5. oceny jakości produktu,
6. planowania produkcji,
7. kontroli współpracy pomiędzy człowiekiem a robotem,
8. szkolenia operatorów linii produkcyjnych, gdyż umożliwia im to obserwację zachowania systemu w sytuacjach awaryjnych.

W ciągu ostatnich kilku lat znacznie wzrosło zainteresowanie cyfrowym bliźniakiem zarówno w środowisku akademickim, jak i w przemyśle, zwłaszcza ze względu na jego przyszły potencjał i szeroki zakres użytecznych zastosowań [5]. Firma Gartner wymieniła *DT* jako jeden z dziesięciu najważniejszych trendów technologicznych w nadchodzących latach [21] i został on sklasyfikowany jako jeden z filarów technologicznych *Przemysłu 4.0* [22]. Tworzenie cyfrowego bliźniaka jest w dalszym ciągu

złożonym procesem, a uzyskanie funkcjonalnego systemu wymaga wielu etapów projektowania, modelowania i implementacji [5], jednak modelowanie *DT* nadal stanowi wyzwanie [23]. Przede wszystkim brakuje standardów dotyczących budowy *DT*, a także dojrzałych metodologii prowadzenia procesu od wstępnego projektu do symulacji całego systemu. Zaproponowano wiele podejść i technologii, jednak konieczne jest posiadanie procedury projektowania, która mogłaby wspierać wybór technik i narzędzi do budowy *DT* w oparciu o wymagania systemowe [5].

Po raz pierwszy terminu „*cyfrowy bliźniak*” użył w 2003 r. Michael Grieves [23] i dotyczył on zarządzania cyklem życiowym produktu [24]. Pierwsza definicja cyfrowego bliźniaka została podana w 2010 roku przez NASA: „*Cyfrowy bliźniak to zintegrowana, wielofizyczna, wieloskalowa symulacja pojazdu lub systemu, który używa najlepszych z dostępnych fizycznych modeli, aktualizacji czujników, historii floty, etc. w celu odzwierciedlenia działania odpowiadającego mu latającego bliźniaka*”. Prekursorem cyfrowego bliźniaka był program kosmiczny Apollo, gdyż po raz pierwszy została stworzona kopia produktu. Była to jednak kopia sprzętowa modułu kosmicznego, a nie cyfrowa [11] [20].

Istnieją również dwie inne definicje, które brzmią następująco [11] [25]:

1. „Cyfrowy bliźniak to zestaw wirtualnych konstrukcji, które w pełni opisują potencjalny lub wytworzony fizycznie produkt od poziomu mikroatomowego do makro poziomu geometrycznego. (...) To opisuje (...) stany operacyjne przechwycone z danych rzeczywistych, bieżących, przeszłych rzeczywistych i przewidywanych przyszłych (...) do różnych celów.”

„Koncepcja cyfrowego bliźniaka składa się z trzech głównych części:

- (a) fizycznych produktów w rzeczywistej przestrzeni,
- (b) wirtualnych produktów w wirtualnej przestrzeni,
- (c) dwukierunkowego połączenia danych i informacji, które łączą ze sobą produkty wirtualne i rzeczywiste”.

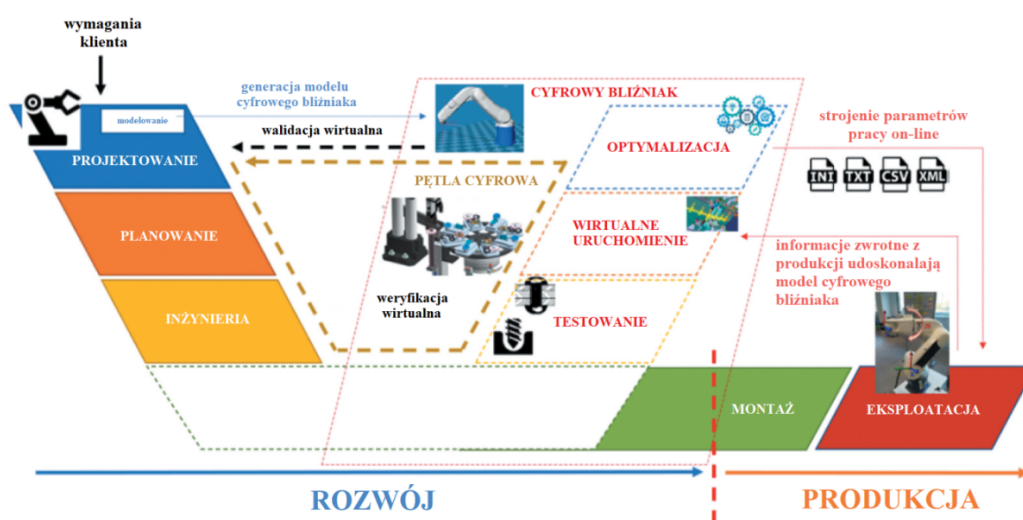
2. „Cyfrowy bliźniak składa się z trzech części: produktu fizycznego, produktu wirtualnego i połączonych danych, które łączą produkt fizyczny i wirtualny. (...). Wirtualna przestrzeń może utrzymywać dobrą synchronizację i wiernie odwzorowywać przestrzeń fizyczną.”

Definicje cyfrowego bliźniaka podlegają ciągłym zmianom i różnią się w zależności od przeznaczenia. W inżynierii opartej na symulacji cyfrowe bliźniaki ewoluowały do

eksperymentalnych cyfrowych bliźniaków (ang. *Experimental digital twins, EDT*) [11] [26]. *EDT* są to repliki wiernie odwzorowujące system rzeczywisty, zawierające wszystkie komponenty i aspekty związane z wykorzystaniem symulacji do celów inżynierskich. Koncepcja eksperymentalnych cyfrowych bliźniaków opiera się na koncepcji cyfrowych bliźniaków, czyli jednej z kluczowych idei *Przemysłu 4.0*. *EDT* stanowią połączenie idei cyfrowych bliźniaków z inżynierią systemową opartą na modelu (ang. *Model-Based Systems Engineering, MBSE*) oraz technologiami symulacji [26].

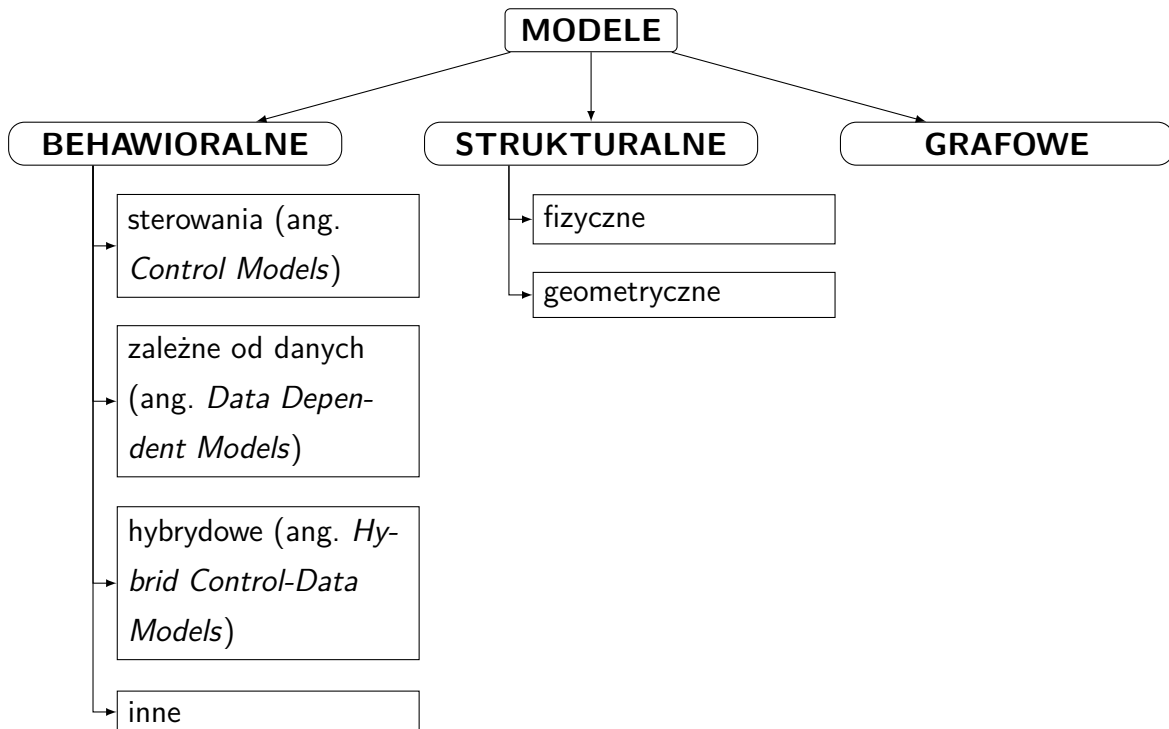
Cyfrowy bliźniak to cyfrowa reprezentacja (wirtualizacja) systemu fizycznego, czyli wirtualna kopia rzeczywistego obiektu lub procesu, oparta na zebranych danych. Jest wirtualnym substytutem swojego rzeczywistego pierwowzoru dzięki zastosowaniu wiedzy eksperckiej, wykorzystaniu danych rzeczywistych oraz symulacji zachowania obiektu w różnych punktach czasu [11] [20]. Dane są zbierane w czasie rzeczywistym - zmiana stanu obiektu rzeczywistego implikuje zmianę stanu obiektu cyfrowego i odwrotnie. Powoduje to, że przepływ danych jest dwukierunkowy (obiekt → model i model → obiekt) [11] [19]. Pozwala to na analizę bieżącego stanu, optymalizację wydajności i symulację stanu przyszłego [11] [17][20] [24]. W przypadku modeli bazujących na uczeniu maszynowym lub modeli adaptacyjnych, dane wejściowe mogą być wykorzystane do udoskonalenia modelu [11].

Cyfrowe bliźniaki dzielą się na: cyfrowe bliźniaki produktu, obiektu oraz procesu (do roku 2020 najwięcej praktycznych zastosowań, 85%, miał cyfrowy bliźniak urządzeń produkcyjnych, 11% cyfrowy bliźniak procesu, 4% stanowiły inne zastosowania [11] [27]).



Rysunek 2.7: Wizja *Smart Manufacturing* ilustrująca miejsce cyfrowego bliźniaka w procesie produkcyjnym [20].

Na *Rysunku 2.7* przedstawiono cyfrowy bliźniak procesu, który pozwala na optymalizację operacji i symulację zmian wprowadzanych do procesu produkcyjnego, a także wykorzystanie tej technologii do szkolenia operatorów produkcyjnych [11].



Rysunek 2.8: Przykładowe techniki modelowania [5].

W celu skonstruowania cyfrowego bliźniaka należy zamodelować właściwości statyczne systemu (wymagania i ograniczenia), przepływ danych i komunikację pomiędzy poszczególnymi elementami systemu, architekturę i strukturę logiczną systemu. Etapy konstruowania cyfrowego bliźniaka są następujące [5]:

1. Modelowanie właściwości statycznych systemu: określenie wymagań systemowych i ograniczeń, przepływów danych i komunikacji, architektury i struktury logicznej systemu oraz wymagań technicznych niezbędnych do wdrożenia rozwiązania (z uwzględnieniem części sprzętowej i oprogramowania). Ważną cechą *DT* jest ciągła synchronizacja z systemem produkcyjnym i jego ewolucja. Z tego powodu, podczas projektowania systemu należy zapewnić, aby system był elastyczny, potrafił zaadaptować się do aktualizowanych na bieżąco modeli, zmian inżynierskich lub zmian procesu [5].
2. Stworzenie wirtualnego modelu o wysokiej wierności odwzorowania pierwowzoru w celu odtworzenia geometrii, właściwości fizycznych, zachowań i zasad obiektu

rzeczywistego [5]. Fizyczna rzeczywistość musi zostać zamodelowana za pomocą abstrakcji. Metody modelowania obiektu przedstawiono na *Rysunku 2.8* [5]. Modele behawioralne są oparte na teorii sterowania, modele zależne od danych - na sztucznej inteligencji, hybrydowe łączą modele sterowania z modelami zależnymi od danych. Oprócz wyżej wymienionych istnieją również inne techniki oparte na relacjach z obiektami, ontologiach, procesie, czy też oparte o wiedzę [5].

3. Implementacja cyfrowego bliźniaka [5].

### 2.1.2 Cyfrowy cień

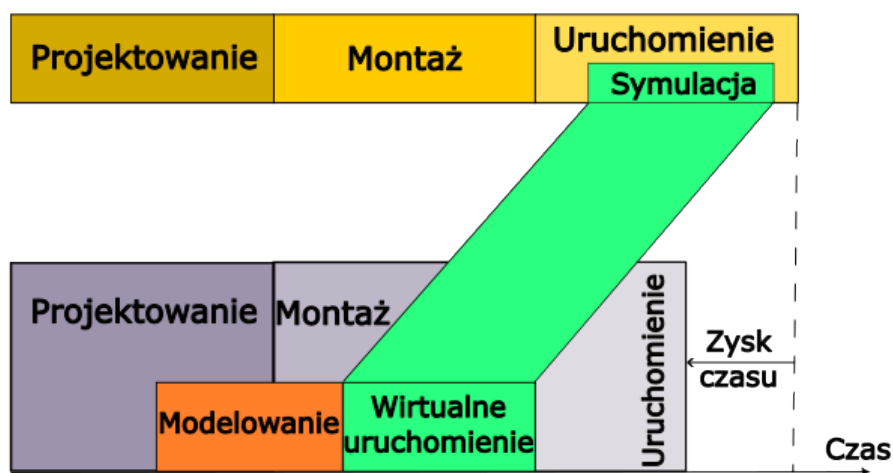
Cyfrowy cień to obraz obiektu rzeczywistego. Zbiera dane w czasie rzeczywistym, zawierające historyczne i aktualne statusy obiektu. Jest to proces jednokierunkowy - zmiana stanu rzeczywistego prowadzi do zmiany obiektu cyfrowego [11] [24] [28]. Cyfrowy cień umożliwia analizę i symulację skomplikowanych systemów produkcyjnych wirtualnie - przykładem może być wykorzystanie do zdalnego monitoringu [11] [29]. Dodatkowo jest stosowany w fazie serwisowej i utrzymania ruchu do śledzenia zmian i prognozowania zachowania produktu [11] [20].

### 2.1.3 Wirtualne uruchomienie

W ciągu ostatnich lat nastąpił znaczny wzrost zainteresowania techniką wirtualnego uruchomienia. Jednakże nadal wiele przedsiębiorstw korzysta z tradycyjnej formy uruchomienia obiektów, gdzie podczas uruchomienia często okazuje się, iż mechanika, elektryka i oprogramowanie nie są wystarczająco sprawdzone i pojawiają się liczne problemy. Problemów tych można by uniknąć korzystając z techniki wirtualnego rozruchu. Podczas tradycyjnego uruchomienia obiektu, oprogramowanie przygotowywane przez programistów *PLC* (programowalny sterownik logiczny, ang. *Programmable Logic Controller*) oraz programistów robotów jest dopiero sprawdzane na obiekcie rzeczywistym. Implikuje to opóźnienia w czasie uruchomienia i przekłada się na zwiększenie kosztów. Wdrożenie techniki wirtualnego uruchomienia do procesu produkcyjnego pozwala na zwiększenie jakości i wydajności przygotowanego oprogramowania, a także na skrócenie czasu uruchomienia na obiekcie rzeczywistym [30]. Kolejnym zastosowaniem wirtualnego uruchomienia są sytuacje, w których występują znaczne opóźnienia mechaniczne bądź logistyczne opóźniające etap rozruchu oprogramowania na obiekcie. Wdrożenie wirtualnego uruchomienia w przytoczonej sytuacji pozwoli na zmniejszenie opóźnienia poprzez równoległe prowadzenie prac. Większość błędów logicznych oraz

składniowych w oprogramowaniu może zostać wyrugowana już na etapie symulacji, co bezpośrednio przekłada się na skrócenie czasu uruchomienia obiektu. Kolejną zaletą wprowadzenia koncepcji wirtualnego rozruchu jest umożliwienie specjalistom pracy zdalnej w większym wymiarze godzin.

Pierwsza definicja uruchomienia, z której wyłonił się termin „*wirtualnego uruchomienia*” została podana w 1977 r. w normie *DIN 32541* pod tytułem „*Betreiben von Maschinen und vergleichbaren technischen Arbeitsmitteln: Begriffe [31]*” („*Eksploracja maszyn i porównywalne techniczne wyposażenie stanowiska pracy: terminologia związana z czynnościami wykonywanymi na stanowisku pracy*”) i brzmiała następująco: „oddanie do dyspozycji maszyny lub porównywalnego technicznego wyposażenia stanowiska pracy do użytku” [32]. Bardziej obszerna definicja została podana przez *BAUMANN & LOOSCHELDERS* w 1982 roku [32]: „Uruchomienie technicznego systemu wynikające z zakończenia montażu i zakończonych sukcesem operacyjnych testów funkcjonalności (...)” [33]. Definicje w kolejnych latach ulegały rozszerzeniu i w roku 1998 Zeugträger podał następującą definicję uruchomienia: „Zgodne z przypisaną funkcją włączenie instalacji w połączeniu z procesem i zwiększenie wydajności do wymaganego poziomu. Uruchomienie zapewnia gotowość funkcjonalną oraz funkcjonalną interakcję zainstalowanych wcześniej komponentów poszczególnych podzespołów, a także sprawdza poprawność poszczególnych funkcji i ich interakcje. Rezultatem uruchomienia jest gotowy do odbioru, technicznie sprawny system” [32].




Rysunek 2.9: Główna idea wirtualnego uruchomienia [32].

Termin „*wirtualne uruchomienie (wirtualny rozruch)*” podlegał ciągłej ewolucji na przestrzeni lat wraz z rozwojem cyfryzacji w fabrykach i opierał się na testach techniki

automatyzacji opartych na symulacji [32].

Na przestrzeni lat nastąpił znaczny wzrost zainteresowania techniką wirtualnego rozruchu, co można zaobserwować na *Rysunku 2.10* (spadek zanotowany w roku 2020 był prawdopodobnie spowodowany pandemią COVID-19). Technika wirtualnego uruchomienia (ang. *virtual commissioning*, *VC*) obecnie nadal się rozwija i zainteresowanie nią nieprzerwanie wzrasta.



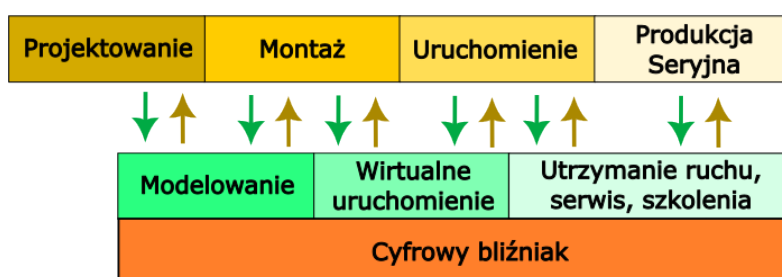
Rysunek 2.10: Liczba artykułów naukowych dotyczących wirtualnego uruchomienia na przestrzeni lat 2015-2022. Diagram został stworzony na podstawie danych pochodzących z platformy *Digital Science's Dimensions* [1].

Podstawowa zasada wirtualnego uruchomienia oprogramowania sterującego obejmuje wykorzystanie symulacji na stanowisku testowym [32] [34]. Symulacja może korzystać z modeli mechanicznych, hydraulicznych, pneumatycznych i elektrycznych. Wirtualne uruchomienie może być realizowane równoległe z montażem maszyn (*Rysunek 2.9*), co może pozwolić na wykrycie i wyeliminowanie z wyprzedzeniem błędów w zakresie oprogramowania sterującego [32]. Wirtualne uruchomienie jest definiowane jako wczesna walidacja kodu *PLC* oraz kodu sterującego pracą robota za pomocą modelu symulacyjnego [32]. Kod *PLC* steruje modelem wirtualnym, który odwzorowuje zachowanie maszyny rzeczywistej. Dlatego też, program *PLC* może być zwalidowany i zoptymalizowany przed rzeczywistym uruchomieniem [30] [35]. Podstawowym wymaganiem jest holistyczne podejście do modelowania maszyny i procesu [32].

Według *Zäh et al.* [32] [36], procedurę wirtualnego uruchomienia można scharakteryzować w trzech następujących krokach:

1. budowa modelu maszyn na podstawie dokumentacji elektrycznej i mechanicznej,
2. odwzorowanie przepływu materiałowego (wraz z czujnikami) w środowisku 3D na podstawie dokumentacji elektryczno-mechanicznej,
3. połączenie modelu ze środowiskiem 3D (np. za pomocą map pamięci Y200, ShM, itd.).

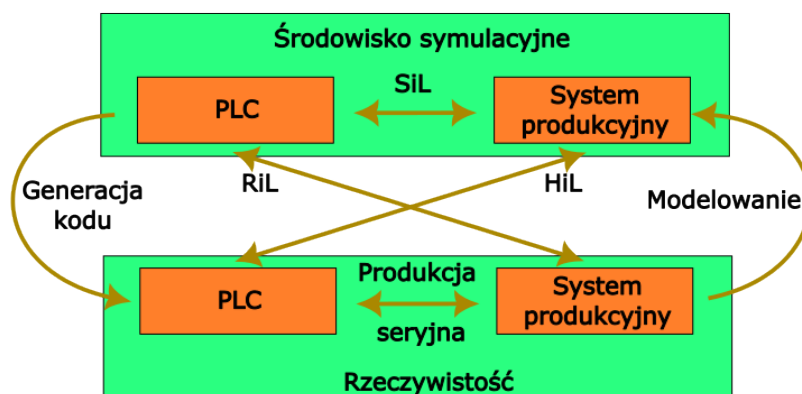
*Rysunek 2.9* przedstawia różnice pomiędzy uruchomieniem obiektu z wykorzystaniem wirtualnego uruchomienia oraz bez jego użycia. Pierwszym krokiem jest zamodelowanie systemu produkcyjnego. Jako że wirtualne uruchomienie może być realizowane równoległe z produkcją, to czas oczekiwania na proces uruchomienia może zostać skrócony poprzez wykorzystanie pętli optymalizacyjnych, które są zaznaczone na *Rysunku 2.11* strzałkami. Co więcej, wirtualne uruchomienie umożliwia bardziej bezpieczne uruchomienie, ponieważ błędy są wykrywane już przed rzeczywistym uruchomieniem [30] [37].



Rysunek 2.11: Wirtualne uruchomienie jako kluczowa składowa cyfrowego bliźniaka.

Wart podkreślenia jest również fakt, iż wirtualne uruchomienie znacznie skraca czas uruchomienia obiektu. Przykładem jest skrócenie czasu uruchomienia obiektu przez firmę Wipro PARI z branży samochodowej o 70%. Dzięki zastosowaniu wirtualnego uruchomienia czas produkcji silnika zmalał z 6-8 miesięcy do 3. miesięcy [38].





Rysunek 2.12: Sposoby uruchomienia systemów produkcyjnych.

Wszystkie procesy *VC* oparte są o wirtualny model, który jest połączony z *PLC* [30]. Istnieją różne sposoby wirtualnego uruchomienia systemów produkcyjnych (*Rysunek 2.12*):

1. Symulacja *HiL* (ang. *hardware-in-the-loop*) - *PLC* jest rzeczywistym sterownikiem [39]; symulacja *HiL* poprzez weryfikację i walidację rzeczywistych elementów sterowania takich jak *NC* (ang. *Numerical Control*, obrabiarka sterowana numerycznie) i *PLC* może służyć do wczesnego wykrywania błędów i optymalizacji [32].
2. Symulacja *SiL* (ang. *software-in-the-loop*) - *VC* może być zrealizowane na symulowanym *PLC*, np. *PLCSimAdvance* [30].
3. Symulacja *RiL* (ang. *reality-in-the-loop*) - połączenie symulowanego *PLC* z systemem produkcyjnym w celu przetestowania rzeczywistych składowych [40].

Wirtualne uruchomienie ma miejsce [41]:

1. przed montażem nowo zaplanowanej maszyny,
2. przed konfiguracją maszyny fizycznej,
3. po rekonfiguracji systemu wirtualnego,
4. po rekonfiguracji systemu fizycznego.,

Obecnie w przemyśle wyróżnia się trzy sposoby realizacji wirtualnego uruchomienia [41]:

1. ręczne: niezawierające modelu systemu [42],
2. oparte na modelu,
3. oparte o technologię cyfrowego bliźniaka (ang. *DTVC*).

Główną metodą realizacji *VC* jest stworzenie wirtualnej symulacji (z wizualizacją) reprezentującej system fizyczny z tymi samymi wejściami i wyjściami (*IO*, ang. *inputs and outputs*) jego mechanicznych komponentów, a następnie podłączenie go do wirtualnego lub rzeczywistego sterownika *PLC*. Uwidacznia to jedną z korzyści płynących z *VC*, jaką jest możliwość testowania dużej liczby różnych części w środowisku wirtualnym, co mogłoby być bardzo kosztowne podczas testowania na maszynie rzeczywistej. Ponadto możliwe jest przetestowanie istniejących modyfikacji systemu produkcyjnego, np. kiedy nowe stanowisko lub urządzenie trzeba zintegrować z linią produkcyjną, można je przetestować i zweryfikować w świecie wirtualnym. Wirtualny model reprezentuje geometrię i kinematykę maszyny fizycznej. Każdy element systemu cechuje jego własne zachowanie i sygnały wejścia-wyjścia. Następnie wirtualny model jest podłączany do *PLC* przy użyciu protokołu komunikacyjnego lub określonego sterownika, w którym emulowane są sygnały *PLC* i *IO* w celu obsługi wirtualnego modelu. Model wirtualny może być połączony z fizycznym (podejście *HiL*) lub wirtualnym sterownikiem *PLC* (podejście *SiL*). *PLC* steruje wirtualnym modelem poprzez wyzwalanie elementów wykonawczych i odbieranie informacji zwrotnej z wejść systemu wirtualnego. W pracy *Ko et al.* [43] zaproponowany został równoległy proces projektowania *VC* składający się z następujących etapów:

1. projekt procesu zawierający wyznaczenie sekwencji wyników operacji,
2. modelowanie urządzeń fizycznych i logicznych,
3. sterowanie systemem.

Wyniki tych kroków, wirtualna instalacja i logika *PLC* prowadzą do ostatniego etapu wirtualnego uruchomienia. Modelowanie wirtualnego systemu jest robione równoległe z rozwojem systemu, a wirtualne uruchomienie będzie miało miejsce przed fizycznym uruchomieniem. To pozwala na zdefiniowanie odpowiednich narzędzi, jakie powinny zostać użyte (np. sterownik numeryczny, *PLC* lub sterownik robota) w stosunku do


wejść/wyść i sterowania wirtualnym modelem, a tym samym na zdefiniowanie odpowiedniej analizy jako wyniku *VC*. Taka szczegółowa analiza jest potrzebna do identyfikacji wyników symulacji, co daje wartość dodaną dla całego procesu rozwoju [41].

W związku ze znacznym rozwojem wirtualnego uruchomienia w ostatnich latach, w przemyśle można obecnie wyróżnić trzy różne zastosowania *VC*:

1. do tworzenia nowej linii produkcyjnej,
2. do przebudowy istniejącej linii produkcyjnej,
3. do szkolenia operatorów.

**W niniejszej pracy skupiono się na zastosowaniu nr 2 i 3.**

Na podstawie diagramu słupkowego (*Rysunek 2.13*) przedstawiającego liczbę publikacji dotyczących wirtualnego uruchomienia na przestrzeni lat 2014-2022 w poszczególnych obszarach badawczych *ANZSRC 2020 Fields of Research (FoR)* [44] obserwuje się wzrost publikacji w każdym z przedstawionych na wykresie obszarów.



Rysunek 2.13: Liczba publikacji dotyczących wirtualnego uruchomienia w poszczególnych obszarach badawczych ANZSRC 2020 na przestrzeni lat 2014-2022. Diagram został stworzony na podstawie danych pochodzących z platformy *Digital Science's Dimensions* [1].

Powyższy wykres (*Rysunek 2.13*) pokazuje również, iż inżynieria była obszarem, w którym wirtualne uruchomienie było najczęściej stosowane w porównaniu do innych obszarów. Natomiast na przestrzeni lat 2014-2022 można zaobserwować znaczny wzrost zastosowań wirtualnego rozruchu w innych obszarach badawczych, takich jak informatyka czy inżynieria produkcji. Przykładem może być artykuł opublikowany przez M. Noga *et al.* w 2022 r., gdzie wprowadzono hybrydowe wirtualne uruchomienie, które umożliwia użycie rzeczywistych urządzeń już na etapie wirtualnego uruchomienia - robota z wizją maszynową sterowaną przez *PLC* w aplikacji *pick-and-place* [45]. Zazwyczaj wirtualne uruchomienie jest używane w systemach dynamicznych, inżynierii obiektu, czy logistyce, jednak w ostatnich latach nastąpił również wzrost wykorzystania tej techniki w informatyce. Przykładem z roku 2023 jest artykuł opublikowany przez J. Rosenberger *et al.* dotyczący *Internetu rzeczy* (ang. *Internet of Things*), w którym wirtualne uruchomienie zostało wykorzystane w systemach strumieniowego przetwarzania danych - stworzony został wieloagentowy system uczący się (ang. *multi-agent reinforcement learning system*) do inteligentnej alokacji zasobów brzegowych w połączeniu z fizycznym modelem symulacyjnym zakładu przemysłowego (*HiL*) [46]. Wyżej przytoczone przykłady potwierdzają interdyscyplinarność wykorzystywania techniki wirtualnego uruchomienia, co implikuje konieczność umożliwienia wdrożenia wiedzy eksperckiej do oceny jakości modelu.

### 2.1.4 Porównanie technik symulacji i wizualizacji

Techniki symulacji różnią się między sobą naturą i kierunkiem przepływu danych pomiędzy obiektem rzeczywistym a jego cyfrowym odpowiednikiem (*Tabela 2.1*).

Tabela 2.1: Porównanie cech cyfrowego bliźniaka, cyfrowego cienia oraz wirtualnego uruchomienia [11].


Cecha	Cyfrowy bliźniak	Cyfrowy cień	Wirtualne uruchomienie
Kopia rzeczywistego obiektu	+	+	+
Dane w czasie rzeczywistym	+	+	-
Kierunek procesu wymiany danych	dwukierunkowy	jednokierunkowy	nie dotyczy
Moment wdrożenia technologii symulacyjnej / wizualizacyjnej	po uruchomieniu obiektu	po uruchomieniu obiektu	przed uruchomieniem obiektu / w trakcie przebudowy linii produkcyjnej

Wyróżniamy również pojęcie „*cyfrowy model*” (*ang. digital model, DM*) - jest to cyfrowa wersja istniejącego lub planowanego obiektu rzeczywistego (fizycznego) i nie ma tutaj automatycznej wymiany danych pomiędzy obiektem rzeczywistym a modelem cyfrowym [5].

Poniżej przedstawiono krótkie podsumowanie technik symulacji i wizualizacji:


1. Wirtualne uruchomienie (*Rysunek 2.14*) różni się od cyfrowego bliźniaka wzajemnym połączeniem danych, które umożliwia wymianę informacji między obiektem rzeczywistym a obiektem cyfrowym, tj. symulacja przewiduje przyszłe stany systemu fizycznego na podstawie zestawu początkowych założeń. Często modele obliczeniowe używane do wnioskowania o bieżącym stanie obiektu rzeczywistego są tymi samymi modelami, które można wykorzystać w symulacji do przewidywania przyszłych stanów. Modele symulacyjne mogą dostarczyć dodatkowych informacji ułatwiających podejmowanie decyzji w celu optymalizacji przyszłych operacji,

prognozowania mechanizmów degradacji i przewidywania przyszłych awarii [5] [47].



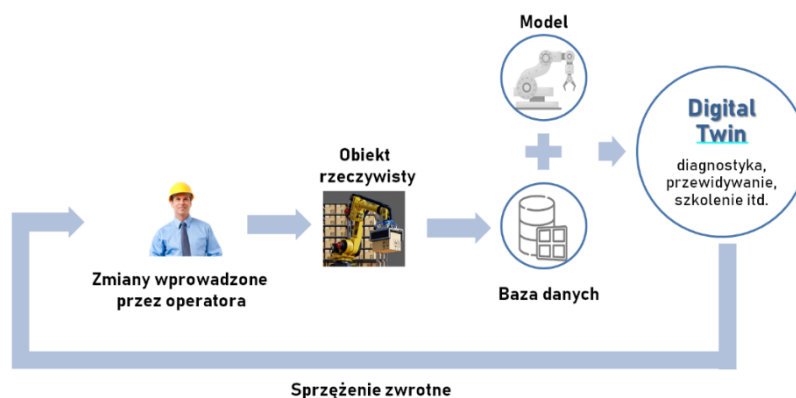
Rysunek 2.14: Wirtualne uruchomienie [11].

2. Cyfrowy cień (*Rysunek 2.15*) charakteryzuje się jednokierunkowym przepływem danych z obiektu rzeczywistego do cyfrowego modelu, wskutek czego model jest aktualizowany o nowe informacje płynące ze świata rzeczywistego [5].



Rysunek 2.15: Cyfrowy cień [11].

3. Cyfrowy bliźniak (*Rysunek 2.16*) charakteryzuje się dwukierunkową wymianą danych pomiędzy obiektem rzeczywistym a obiektem cyfrowym. Zmiana obiektu fizycznego wywołuje zmianę obiektu cyfrowego i odwrotnie.



Rysunek 2.16: Cyfrowy bliźniak [11].

W *DT* przepływ danych jest automatyczny i synchronizuje obiekt cyfrowy z aktualnym stanem obiektu fizycznego, przesyłając do niego również informacje sterujące [5].

## 2.2 Istniejące metody stosowane do oceny jakości modeli

Najnowsze publikacje naukowe zauważają potrzebę wypracowania metodyki służącej do oceny jakości modelu oraz danych na potrzeby wirtualnego uruchomienia. W artykule z roku 2022 [3] wskazano, iż istnieje potrzeba znalezienia metryk opisujących jakość danych wejściowych, które będą pomocne w wyborze odpowiedniej metody modelowania. W przemyśle coraz częściej stosuje się podejście oparte na danych (ang. *data-driven*) i modelowanie hybrydowe popularne w zakresie monitorowania, optymalizacji i sterowania procesami. Jednak dane gromadzone w zakładach przemysłowych podczas ich eksploatacji/działania, mimo że są dostępne w ogromnej ilości, to często zawierają niewiele informacji. Zebrane dane zazwyczaj reprezentują tylko pewne punkty pracy [3].

W celu uzyskania wiarygodnych wyników wirtualnego uruchomienia, z których można będzie wysnuć rzetelne wnioski, należy wziąć pod uwagę ograniczenia jakościowe modelu. Szczególnie trudnym problemem jest zapewnienie jakości modeli symulacyjnych dostarczanych przez firmy zewnętrzne. Modułowa instalacja procesowa integruje różne moduły, komponenty pochodzące od różnych producentów oraz modele symulacji pochodzące od różnych firm zewnętrznych. Dlatego też jednym z decydujących aspektów jest ocena jakości tych modeli w celu zapewnienia pewności co do jakości wirtualnego uruchomienia [4].

Dodatkowo, w artykule z trzeciego kwartału 2022 roku [5] autorzy wskazują, iż określenie, czy dany model jest wystarczająco dokładny i poprawny w odniesieniu do prawdziwej kopii, nie został jeszcze wystarczająco zbadany. Dlatego też, w niniejszej pracy zostanie zaproponowana metoda służąca do oceny jakości modeli pod kątem ich przydatności na cele wirtualnego uruchomienia systemów automatyki przemysłowej.

Analizując literaturę z zakresu modelowania można zauważyć, iż nie istnieje jedna, ujednolicona miara, która mogłaby być stosowana do oceny jakości modelu. Na potrzeby opisu metryk stosowanych do oceny jakości modelu wprowadza się następujące oznaczenia:

$y_i$  - wartość rzeczywista,

$\hat{y}_i$  - wartość przewidywana  $i$ -tej obserwacji,  
 $n$  - liczba obserwacji (punktów danych) [48] [49].

Wybrane miary powszechnie stosowane do oceny jakości modeli są następujące:

1. Błąd Prognozowania (ang. *Forecast Error, FE*) - różnica między wartością rzeczywistą a wartością przewidywaną; nie oznacza dosłownie "błędu", lecz nieprzewidywalną część obserwacji [50] (2.1):

$$FE = y_i - \hat{y}_i. \quad (2.1)$$

2. Średni Błąd Prognozowania (ang. *Mean Forecast Error, MFE*) (2.2) jest to średnia wartość błędów prognozowania [51]:

$$MFE = \bar{FE}. \quad (2.2)$$

3. Błąd Średniokwadratowy (ang. *Mean-Squared Error, MSE*) - średnia kwadratów błędów predykcji (różnicy między wartością rzeczywistą a wartością przewidywaną przez model) (2.3) [49]:

$$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}, \quad (2.3)$$

4. Pierwiastkowy Błąd Średniokwadratowy (ang. *Root Mean Squared Error, RMSE*) (2.4) [52] [53]:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}. \quad (2.4)$$

5. Znormalizowany Pierwiastkowy Błąd Średniokwadratowy (ang. *Normalized Root Mean Squared Error, NRMSE*) (2.5) [49]:

$$NRMSE = 1 - \frac{RMSE}{y_{max} - y_{min}}. \quad (2.5)$$



6. Pierwiastek Względego Błędu Kwadratowego (ang. *Root Relative Squared Error*, *RRSE*) jest to pierwiastek kwadratowy z sumy błędów modelu predykcyjnego, znormalizowanego przez sumę kwadratów błędów modelu (2.6) [54]:

$$RRSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}}. \quad (2.6)$$

7. Średni Błąd Absolutny (ang. *Mean Absolute Error*, *MAE*) oraz Średni Procentowy Błąd Prognozy (ang. *Mean Absolute Percentage Error*, *MAPE*) - średnia bezwzględnych błędów procentowych (*MAPE*) (2.7) [55]:

$$MAPE = \frac{1}{n} \sum_{i=0}^{n-1} \left| \frac{y_i - \hat{y}_i}{\max(\epsilon, |y_i|)} \right| * 100, \quad (2.7)$$

gdzie  $\epsilon$  jest dowolnie małą dodatnią liczbą, aby uniknąć niezdefiniowanych wyników, gdy  $y$  jest równe zero [49].

*MAPE* oblicza względny błąd procentowy w stosunku do rzeczywistej wartości wyjścia, natomiast *MAE* ignoruje małe wartości danej wielkości i jedynie odzwierciedla błąd w przewidywaniu największej wartości wielkości [49].

8. Średniokwadratowy Błąd Logarytmiczny (ang. *Mean Squared Logarithmic Error*, *MSLE*) jest to względna różnica między rzeczywistymi i przewidywanymi wartościami w skali logarytmicznej (logarytm naturalny); metryka ryzyka odpowiadająca oczekiwanej wartości kwadratu logarytmicznego błędu lub straty, stosowana przy wzroście eksponencjalnym (2.3) [49]:

$$MSLE = \frac{1}{n} \sum_{i=0}^{n-1} (\ln(1 + y_i) - \ln(1 + \hat{y}_i))^2. \quad (2.8)$$

9. Średni Absolutny Błąd Medianowy (*Median Absolute Error*, *MedAE*) - mediana różnic bezwzględnych między wartością rzeczywistą a przewidywaną (2.9) [49] [56]:

$$MedAE = \text{median}(|y_1 - \hat{y}_1|, \dots, |y_n - \hat{y}_n|). \quad (2.9)$$

10. *Explained Variance Score*, *EVS* - metryka ryzyka, która wyjaśnia rozproszenie błędów danego zbioru danych (2.10):

$$EVS = 1 - \frac{Var(y - \hat{y})}{Var(y)}, \quad (2.10)$$

gdzie  $Var(y - \hat{y})$  oraz  $Var(y)$  jest odpowiednio wariancją błędów predykcyjnych i wartości rzeczywistych [57].

11. Symetryczny Średni Procentowy Błąd Prognozy (ang. *Symmetric Mean Absolute Percentage Error, sMAPE*) - oblicza MAE pomiędzy predykowanymi wartościami a wartościami rzeczywistymi 2.11 [53] [58]:

$$sMAPE = \frac{100}{n} \sum_{i=0}^{n-1} \frac{|\hat{y}_i - y_i|}{(|y_i| + |\hat{y}_i|)/2}. \quad (2.11)$$

12. Maksymalny błąd resztkowy (ang. *Maximum Residual Error, ME*) - metryka, która przechwytuje najgorszy przypadek błędu między wartością przewidywaną a wartością prawdziwą (2.12) [49] [59] [60]:

$$ME = \max(|y_i - \hat{y}_i|). \quad (2.12)$$

13. Współczynnik determinacji (ang. *Coefficient of Determination, R<sup>2</sup>*) - interpretowany jest jako proporcja wariancji zmiennej zależnej, którą można przewidzieć na podstawie zmiennych niezależnych (2.13) [61] [62]:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (\bar{y} - y_i)^2} \quad (2.13)$$

14. Zmodyfikowany indeks zgodności (ang. *Modified Index of Agreement, MIA*) - wskaźnik zgodności, czyli miara stopnia błędu przewidywania modelu (2.14) [63] [64]:

$$MIA = 1 - \frac{\sum_{i=1}^n |y_i - \hat{y}_i|^j}{\sum_{i=1}^n (|\hat{y}_i - \bar{y}'| + |y_i - \bar{y}'|)^j}, \quad (2.14)$$

gdzie:

$j$  – zadana potęga (np. dodatnia liczba całkowita).

15. Względny indeks zgodności (ang. *Relative Index of Agreement*, RIA) [65] [66] (2.15):

$$RIA = 1 - \frac{\sum_{i=1}^n \left(\frac{y_i - \hat{y}_i}{y_i}\right)^2}{\sum_{i=1}^n \left(\frac{|\hat{y}_i - \bar{y}| + |y_i - \bar{y}|}{\bar{y}}\right)^2}. \quad (2.15)$$

16. Współczynnik korelacji Pearsona (ang. *Pearson Product-Moment Correlation Coefficient*, PPMCC) - mierzy liniowy związek pomiędzy wartością przewidywaną a wartością rzeczywistą [67](2.16):

$$PPMCC = \frac{\sum(y_i - \bar{y}_i)(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum(y_i - \bar{y}_i)^2 \sum(\hat{y}_i - \bar{\hat{y}})^2}}. \quad (2.16)$$

W Tabeli 2.2 przedstawiono zakres wartości przyjmowanych przez powyższe współczynniki.

Tabela 2.2: Zakres wartości przyjmowanych przez miary jakości modelu.

Nazwa	Wartość najgorsza	Wartość najlepsza
<i>FE</i>	0%	100%
<i>MFE</i>	$\mp\infty$	0
<i>MSE</i>	$+\infty$	0
<i>RMSE</i>	$+\infty$	0
<i>NRMSE</i>	0	1
<i>RRSE</i>	$+\infty$	0
<i>MAE</i>	$+\infty$	0
<i>MAPE</i>	$+\infty$	0
<i>MSLE</i>	$+\infty$	0
<i>MedAE</i>	$+\infty$	0
<i>EVS</i>	$-\infty$	1
<i>sMAPE</i>	200	0
<i>ME</i>	$+\infty$	0
$R^2$	$-\infty$	1
<i>MIA</i>	0	1
<i>RIA</i>	0	1
<i>PPMCC</i>	-1	1

Błąd średniokwadratowy oraz jego modyfikacje ( $MSE$ ,  $RMSE$ ), a także średni błąd bezwzględny ( $MAE$ ) oraz jego wariant procentowy ( $MAPE$ ) przyjmują wartości z zakresu od 0 do  $+\infty$ , co powoduje, że ich pojedyncza wartość nie niesie zbyt wiele informacji o wydajności regresji. Współczynnik determinacji ( $R^2$ ) oraz  $sMAPE$  osiągają wysokie wartości tylko wtedy, gdy większość pomiarów rzeczywistych została prawidłowo przewidziana. W [61] zostało udowodnione, że  $R^2$  jest bardziej informatywny i realistyczny niż  $sMAPE$  i nie ma ograniczeń interpretacyjnych, które mają  $MSE$ ,  $RMSE$ ,  $MAE$  i  $MAPE$  [61]. Warto wspomnieć, iż po analizie literatury dotyczącej wirtualnego uruchomienia, metrykami, które były brane do oceny jakości modeli symulacyjnych były  $RMSE$  (do oceny stosowności) oraz  $R^2$  (do oceny poprawności) [68]. Jednak w porównaniu z  $R^2$ , bardziej wiarygodną miarą statystyczną jest  $MIA$ , ponieważ jest bardziej wrażliwa na różnice między obserwowanymi a przewidywanymi wartościami średnich i wariancji, a także jest mniej wrażliwa na wartości ekstremalne [63].  $MAE$  ignoruje małe wartości i odzwierciedla jedynie błąd w przewidywaniu największej wartości, co powoduje, że nie może być stosowany jako samodzielna miara oceny jakości modelu. W celu obliczenia  $MFE$  należy spełnić założenie o pochodzeniu danych / szeregu czasowego z tej samej skali.  $ME$  pozwala na wyeliminowanie modeli, w których pojawia się jeden pik o wysokości znacznie przewyższającej pozostałe wartości, który mógłby powodować niezasadne pojawienie się ostrzeżeń lub błędów w wizualizacji  $HMI$  (ang. *Human Machine Interface*) dla pracującego stanowiska wirtualnego uruchomienia.

## 2.3 Logika rozmyta

### 2.3.1 Rys historyczny

Teoria zbiorów rozmytych powstała dzięki L. A. Zadehowi. Lotfi Asker Zadeh (1921 - 2017) to amerykański naukowiec, urodzony w Azerbejdżanie, twórca następujących teorii: zbiorów rozmytych, możliwości, obliczeń na słowach i obliczeń miękkich. Był laureatem wielu odznaczeń naukowych, został uhonorowany również tytułem *honoris causa* Politechniki Śląskiej w Gliwicach. W opublikowanym w 1961 r. artykule pt. „Od teorii obwodów do teorii systemów” wskazał on na znaczną rozbieżność między systemami żywymi a technicznymi. Zasugerował, iż przyczyną takiej rozbieżności jest nieodpowiedniość klasycznej matematyki z tego względu, iż opisuje ona określone punkty, zbiory, czy też funkcje w sposób bardzo precyzyjny. Natomiast systemy biologiczne, w przeciwieństwie do systemów technicznych, są bardzo skomplikowane i nie sposób je opisać w sposób prosty i precyzyjny, dlatego też do ich opisu używa się matematyki pojęć rozmytych, nieostrych, nieopartych na teorii prawdopodobieństwa. Rezultatem wspomnianych przemyśleń była książka pt. „Teoria systemów liniowych: podejście przestrzeniastanowe”, której współautorem był C.A. Desoer [69].

Pojęcie „zbiorów rozmytych” zostało przez Zadeha wprowadzone w 1965 r. w artykule pt. „Fuzzy sets. Information and Control” [70]. Genezę zbiorów rozmytych w kontekście analizy systemowej i teorii możliwości przedstawił J. Kacprzyk w swojej książce pt. „Zbiory rozmyte w analizie systemowej” [69] [71]. Po raz pierwszy teoria zbiorów rozmytych została zastosowana w 1969 r. do grupowania danych, opisanych przez Ruspinię [69] [72]. Następnie, w 1973 r. L. A. Zadeh zaproponował „wnioskowanie przybliżone” w [73], w której to pracy wprowadził również pojęcie „zmiennej lingwistycznej”, zasadę niekompatybilności („Jeżeli skomplikowanie systemu wzrasta, nasza zdolność formułowania precyzyjnych i wciąż wiarygodnych stwierdzeń o jego zachowaniu zmniejsza się, a po przekroczeniu pewnego skomplikowania precyzja i wiarygodność wzajemnie się wykluczają” [73]) oraz rozmyte reguły „jeżeli-to” w celu reprezentacji wiedzy człowieka [69]. Na podstawie tej pracy w 1975 r. Mamdani i Assilan zaprojektowali regulator rozmyty sterujący silnikiem parowym [69], co można uznać za pierwsze praktyczne zastosowanie teorii zbiorów rozmytych do celów przemysłowych. Lata osiemdziesiąte XX wieku przyniosły ze sobą rozkwit przemysłowych zastosowań teorii zbiorów rozmytych. Przykładem takich wdrożeń teorii w przemysł, gdy dokładny model matematyczny zjawiska nie jest znany, co stanowi bezpośrednią przyczynę niemożliwości zastosowania klasycznej teorii sterowania, są: sterowanie uzdatnianiem wody,

sterowanie metrem i sterowanie ramieniem robota [74].

Obecnie regulatory rozmyte są powszechnie stosowane w przemyśle, w szczególności w sprzętach takich jak pralki automatyczne, czy kamery cyfrowe (do stabilizacji obrazu) oraz w przemyśle samochodowym [69].

### 2.3.2 Zbiory rozmyte

Wnioskowanie rozmyte oparte na teorii zbiorów rozmytych pozwala zapisać w sposób formalny proces wnioskowania dla modeli opisujących złożoną rzeczywistość, które zostały opisane przez człowieka w języku naturalnym z zastosowaniem nieprecyzyjnych określeń [69].

Teoria zbiorów rozmytych zakłada, że istnieje możliwość częściowej przynależności elementu do zbioru. Natomiast w teorii zbiorów klasycznych, zaproponowanej przez G. Cantora, element może przynależeć do zbioru całkowicie lub w ogóle do niego nie przynależeć.

Podział teorii zbiorów rozmytych [69] [74]:

- matematyka rozmyta - zbiory klasyczne są zastępowane przez zbiory rozmyte,
- logika rozmyta - szczególnie przydatna do tworzenia systemów eksperckich; logika klasyczna rozszerzona o pojęcia niepewne,
- systemy rozmyte - systemy przetwarzania obrazów i sygnałów, podejmowania decyzji, transmisji danych są projektowane z zastosowaniem zbiorów rozmytych,
- optymalizacja rozmyta - stosuje się rozmyte ograniczenia,
- rozmyta niepewność i informacja - poddaje się analizie różne rodzaje niepewności, miary rozmytości i pojęcie możliwości.

#### Zbiór rozmyty

1. Sposoby opisu zbioru rozmytego  $A$  na przestrzeni  $\mathbb{X}$  [69]:

- a) bezpośrednio przez podanie funkcji przynależności (ang. *membership function*), która może przyjmować wartości z przedziału  $[0, 1]$ , z tego względu, iż możliwa jest „częściowa” przynależność do zbioru (2.17) [70]. Wartość funkcji przynależności  $\mu_A(x) = 0$  oznacza brak przynależności do zbioru, natomiast wartość 1 oznacza całkowitą przynależność do zbioru rozmytego.

$$\mu_A(x) : \mathbb{X} \rightarrow [0, 1] \quad (2.17)$$

Funkcja przynależności zbioru rozmytego  $A$  może być również oznaczona przez  $A(x)$  [75].

- b) pośrednio jako uporządkowane pary  $(x, \mu_A(x))$  (2.18),

$$A = \{(x, \mu_A(x)) | x \in \mathbb{X}, \mu_A(x) \in [0, 1]\} \quad (2.18)$$

gdzie:

$\mu_A(x)$  – stopień przynależności obiektu  $x$  do zbioru rozmytego  $A$ .

- c) dla przestrzeni  $X$  dyskretnej, mogącej zawierać obiekty uporządkowane oraz nieuporządkowane (2.19) [73]:

$$A = \sum_{x \in \mathbb{X}} \mu_A(x) / x \quad (2.19)$$

- d) dla przestrzeni  $X$  ciągłej (2.20) [73]:

$$A = \int_{\mathbb{X}} \mu_A(x) / x \quad (2.20)$$

W podpunktach c) i d)  $\sum, \int$  oznacza sumę elementów  $x$  mających stopień przynależności  $\mu_A(x)$ .

## 2. Własności zbiorów rozmytych [69]

Zbiory rozmyte oznaczamy jako  $A$  i  $B$ .

- a) Równość zbiorów rozmytych (2.21):


$$\forall_{x \in \mathbb{X}} \mu_A(x) = \mu_B(x) \quad (2.21)$$

- b) Zbiór rozmyty  $A$  jest podzbiorem zbioru rozmytego  $B$ :  $A$  zawiera się w  $B$  (2.22):

$$\forall_{x \in \mathbb{X}} \mu_A(x) \leq \mu_B(x) \quad (2.22)$$

- c) Nośnik (ang. *support*) zbioru rozmytego  $A$ : klasyczny zbiór obiektów o dodatniej funkcji przynależności (2.23) (*Rysunek 2.17*):

$$Supp(A) = \{x \in \mathbb{X} | \mu_A(x) > 0\} \quad (2.23)$$




Rysunek 2.17: Nośnik zbioru rozmytego.

- d) Rdzeń: klasyczny zbiór obiektów o funkcji przynależności równej jeden (2.24)  
(Rysunek 2.18):

$$\text{Core}(A) = \{x \in \mathbb{X} \mid \mu_A(x) = 1\} \quad (2.24)$$

Zbiór cechujący się niepustym rdzeniem nazywa się zbiorem *normalnym*.

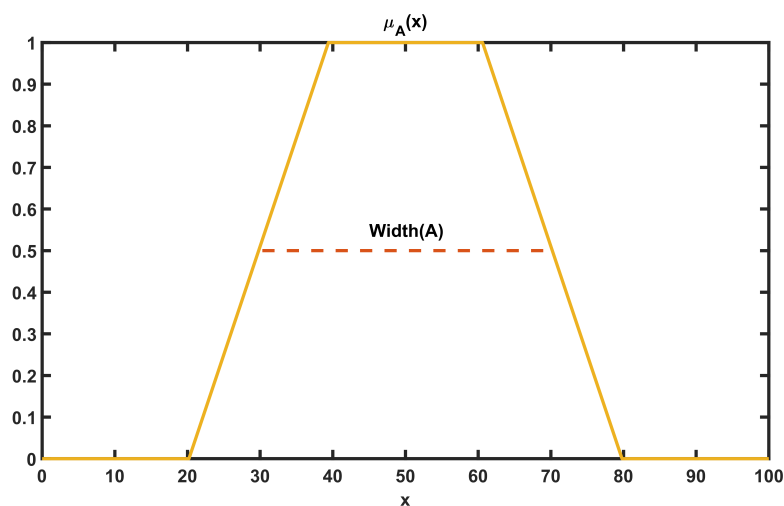


Rysunek 2.18: Rdzeń zbioru rozmytego.



e) Szerokość zbioru rozmytego (ang. *width*) (2.25) (Rysunek 2.19):

$$Width(A) = |x_2 - x_1| \quad (2.25)$$



Rysunek 2.19: Szerokość zbioru rozmytego.

f) Punkt krzyżowania (ang. *crossover*) (2.26):

$$Crossover(A) = \{x \in \mathbb{X} \mid \mu_A(x) = \frac{1}{2}\} \quad (2.26)$$

### 3. Operacje na zbiorach rozmytych

a) Iloczyn zbiorów rozmytych  $A$  i  $B$  (2.27):

$$\forall_{x \in \mathbb{X}} \quad \mu_{A \cap_T B}(x) = \mu_A(x) \star_T \mu_B(x) = T[\mu_A(x), \mu_B(x)] \quad (2.27)$$

gdzie:

$T$  lub  $\star T$  – operator  $t$ -normy.

W Tabelicy 2.3 przedstawiono najpopularniejsze  $t$ -normy.

Tabela 2.3: Najpopularniejsze  $t$ -normy.

Nazwa	$t$ -norma
Zadeha	$M(x, y) = \min(x, y)$
Algebraiczna	$\Pi(x, y) = xy$
Łukasiewicza	$W(x, y) = \max(x + y - 1, 0)$
Fodora	$\min_0(x, y) = \begin{cases} \min(x, y), & x + y > 1 \\ 0, & x + y \leq 1 \end{cases}$
Drastyczna	$Z(x, y) = \begin{cases} \min(x, y), & \max(x, y) = 1 \\ 0, & \text{dla pozostałych} \end{cases}$
Einsteina	$E(x, y) = \frac{xy}{2-(x+y-xy)}$

b) Suma zbiorów rozmytych  $A$  i  $B$  (2.28):

$$\forall_{x \in X} \mu_{A \cap_S B}(x) = \mu_A(x) \star_S \mu_B(x) = T[\mu_A(x), \mu_B(x)] \quad (2.28)$$

gdzie:

$S$  lub  $\star_S$  – operator  $s$ -normy.

W Tabelicy 2.4 przedstawiono najpopularniejsze  $s$ -normy.

Tabela 2.4: Najpopularniejsze  $s$ -normy.

Nazwa	$s$ -norma
Zadeha	$M'(x, y) = \max(x, y)$
Probabilistyczna	$\Pi'(x, y) = x + y - xy$
Łukasiewicza	$W'(x, y) = \min(x + y, 1)$
Fodora	$\max_1(x, y) = \begin{cases} \max(x, y), & x + y < 1 \\ 1, & x + y \geq 1 \end{cases}$
Drastyczna	$Z'(x, y) = \begin{cases} \max(x, y), & \min(x, y) = 0 \\ 1, & \text{dla pozostałych} \end{cases}$
Einsteina	$E'(x, y) = \frac{x+y}{1+xy}$

### Funkcje przynależności

Funkcja przynależności opisuje zbiór rozmyty w sposób jednoznaczny [69].

Interpretacja wartości funkcji przynależności [69][76]:

- stopień podobieństwa:  $\mu_A(x)$  - miara bliskości elementu  $x$  do wzorca zbioru rozmytego  $A$ ,
- stopień preferencji: zbiór rozmyty  $A$  stanowi zbiór bardziej lub mniej preferowanych obiektów;  $\mu_A(x)$  odzwierciedla intensywność preferencji dotyczącą obiektu  $x$ ,
- stopień niepewności:  $\mu_A(x)$  - stopień możliwości przypisania zmiennej  $X$  wartości  $x$ , gdy jedyną wiedzą jaką posiadamy jest stwierdzenie, że „ $X$  jest  $A$ ”; [77].

Wyznaczanie funkcji przynależności odbywa się w następujący sposób, z tego względu, iż nie ma możliwości jej bezpośredniego pomiaru [69]:


- Pomiar odległości: funkcja przynależności jest traktowana jak stopień podobieństwa  $x'$  - wzorcowy element zbioru rozmytego  $A$   $\mu_A(x)$  - malejąca funkcja odległości  $d(x, x')$ ,
- Pomiar częstości: funkcja przynależności  $\mu_A(x)$  jest wprost proporcjonalna do  $P(A/x)$ , czyli do prawdopodobieństwa - częstości, z jaką w losowym eksperymencie element  $x$  był uznawany za należący do zbioru  $A$ ,
- Pomiar kosztu: funkcja przynależności  $\mu_A(x)$  jest odwrotnie proporcjonalna do kosztu, jaki należy ponieść za uznanie, że element  $x$  należy do zbioru  $A$ .

Najczęściej występujące klasy funkcji przynależności [69] [78]:

- Trójkątna (2.29) (*Rysunek 2.20*):

$$\mu_A(x; a, b, c) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a < x \leq b \\ \frac{c-x}{c-b}, & b < x \leq c \\ 0, & x > c \end{cases} \quad (2.29)$$

$a, b, c$  – parametry ( $a \leq b \leq c$ ).

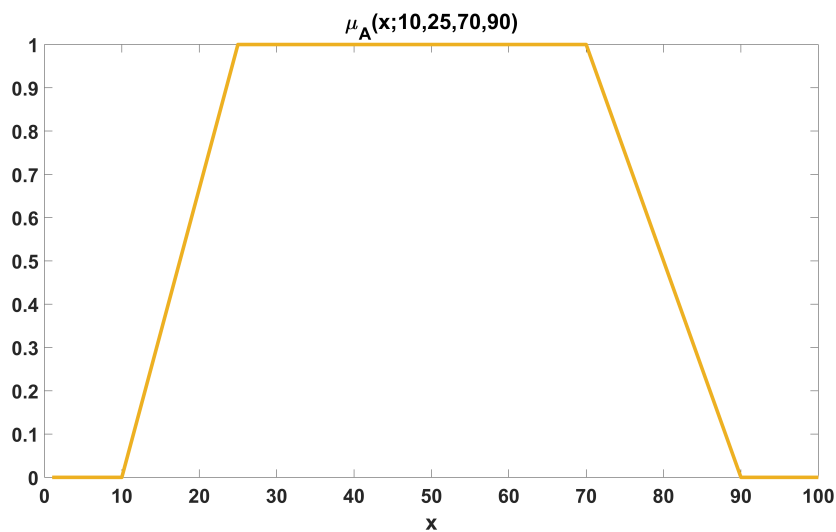


Rysunek 2.20: Trójkątna funkcja przynależności.

- Trapezowa (2.30) (Rysunek 2.21):

$$\mu_A(x; a, b, c, d) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a < x \leq b \\ 1, & b < x \leq c \\ \frac{d-x}{d-c}, & c < x \leq d \\ 0, & x > d \end{cases} \quad (2.30)$$

$a, b, c, d$  – parametry ( $a \leq b \leq c \leq d$ ).




Rysunek 2.21: Trapezowa funkcja przynależności.

- Prostokątna (przedziałowa) (2.31) (*Rysunek 2.22*):

$$\mu_A(x; a, b) = \begin{cases} 0, & x \leq a \\ 1, & a < x \leq b \\ 0, & x > b \end{cases} \quad (2.31)$$

$a, b$  – parametry ( $a \leq b$ ).



Rysunek 2.22: Prostokątna funkcja przynależności.


- Gaussowska (2.32) (*Rysunek 2.23*):

$$\mu_A(x; m, \sigma) = e^{-\frac{(x-m)^2}{2\sigma^2}} \quad (2.32)$$

$m, \sigma$  – parametry,

$\sigma > 0$  – definiuje szerokość zbioru rozmytego.

$\sigma$  wpływa na kształt funkcji przynależności.




Rysunek 2.23: Gaussowska funkcja przynależności.

- Złożona Gaussowska funkcja przynależności: każda z funkcji definiuje kształt jednej ze stron funkcji przynależności (2.33) (2.24):

$$\mu_A(x; \sigma_1, c_1, \sigma_2, c_2) = \begin{cases} e^{-\frac{(x-c_1)^2}{2\sigma_1^2}}, & x \leq c_1 \\ 1, & c_1 < x \leq c_2 \\ e^{-\frac{(x-c_2)^2}{2\sigma_2^2}}, & x > c_2 \end{cases} \quad (2.33)$$

$\sigma_1, \sigma_2$  – odchylenie standardowe,  
 $c_1, c_2$  – średnia każdej z funkcji.




Rysunek 2.24: Złożona Gaussowska funkcja przynależności.


- Uogólniona dzwonowa (2.34) (Rysunek 2.25, Rysunek 2.26):

$$\mu_A(x; m, \sigma, \gamma) = \frac{1}{1 + \left|\frac{x-m}{\sigma}\right|^{2\gamma}} \quad (2.34)$$

$m, \sigma > 0, \gamma > 0$  – parametry.



Rysunek 2.25: Uogólniona dzwonowa funkcja przynależności - zmiana parametru  $\sigma$ .



Rysunek 2.26: Uogólniona dzwonowa funkcja przynależności - zmiana parametru  $\gamma$ .


- Sigmoidalna (2.35) (*Rysunek 2.27, Rysunek 2.28*):

$$\mu_A(x; c, \beta) = \frac{1}{1 + \exp[-\beta(x - c)]} \quad (2.35)$$


$c, \beta$  – parametry,

$c$  – punkt krzyżowania,

$\beta$  – nachylenie funkcji przynależności.



Rysunek 2.27: Sigmoidalna funkcja przynależności -  $\beta < 0$ .



Rysunek 2.28: Sigmoidalna funkcja przynależności -  $\beta > 0$ .



- Rozmyty singleton (2.36):

$$\mu_A(x; x_0) = \delta_{x, x_0} = \begin{cases} 1, & x = x_0 \\ 0, & x \neq x_0 \end{cases} \quad (2.36)$$


$\delta_{x, x_0}$  – symbol (jedyńka) Kroneckera,  
 $x_0$  – położenie singletonu.

- Funkcja typu S (2.37) (*Rysunek 2.29, Rysunek 2.30*):


$$\mu_A(x; a, c) = \begin{cases} 0, & x \leq a \\ 2 \left(\frac{x-a}{c-a}\right)^2, & a < x \leq b \\ 1 - 2 \left(\frac{x-c}{c-a}\right)^2, & b < x \leq c \\ 1, & x > c \end{cases} \quad (2.37)$$

$$b = (a + c)/2 \quad (2.38)$$

$a, c$  – parametry,  
 $b$  – punkt krzyżowania.



Rysunek 2.29: Funkcja przynależności typu S - wpływ parametru  $a$  na kształt funkcji.




Rysunek 2.30: Funkcja przynależności typu S - wpływ parametru  $c$  na kształt funkcji.


- Funkcja typu Z (2.39) (Rysunek 2.31, Rysunek 2.32):

$$Z(x; a, c) \triangleq 1 - S(x; a, c) \quad (2.39)$$

$a, c$  – parametry.



Rysunek 2.31: Funkcja przynależności typu Z - wpływ parametru  $a$  na kształt funkcji.


Rysunek 2.32: Funkcja przynależności typu Z - wpływ parametru  $c$  na kształt funkcji.

- Funkcja typu PI (2.40) (*Rysunek 2.33*):

$$\mu_A(x; a, b) = \begin{cases} S(x; b - a, b), & x \leq b \\ 1 - S(x; b, b + a), & x > b \end{cases} \quad (2.40)$$

$a, b$  – parametry,

$a$  – szerokość zbioru rozmytego.



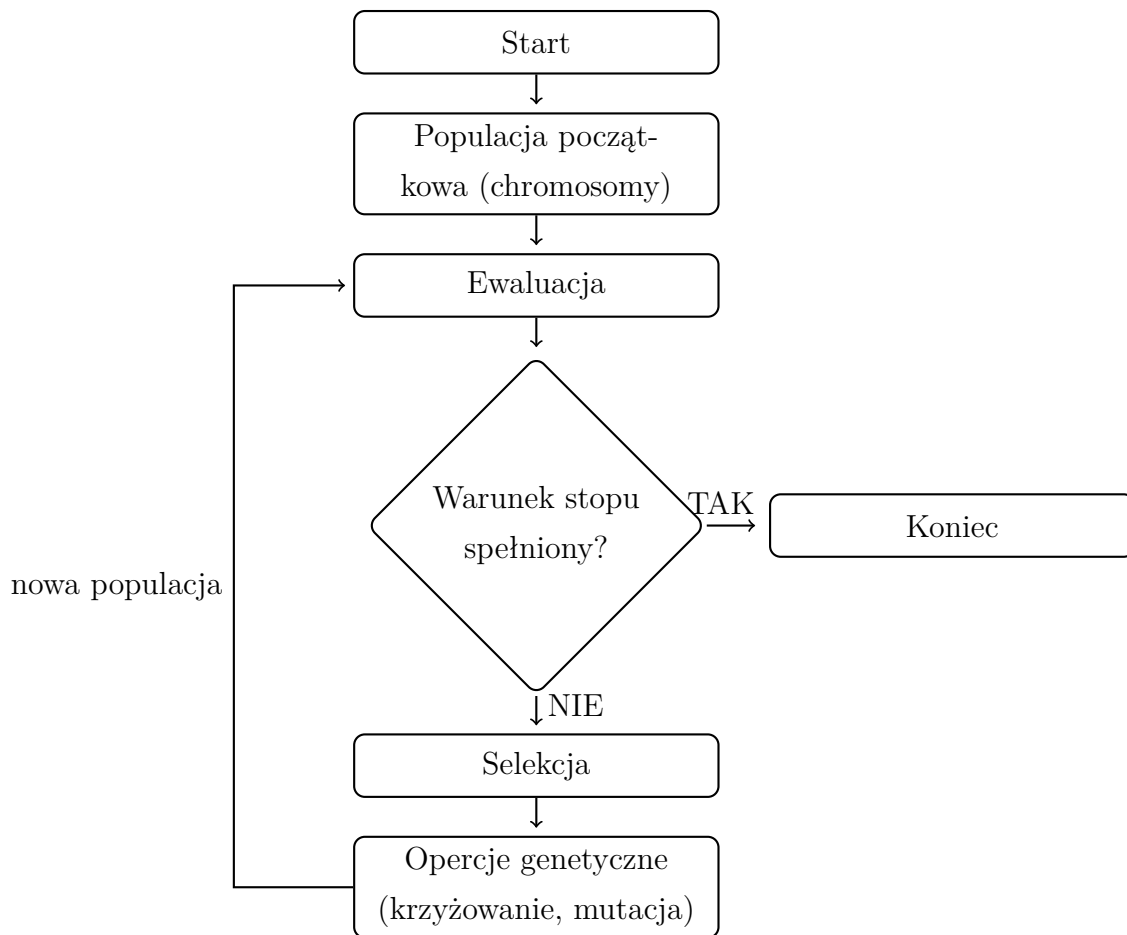
Rysunek 2.33: Funkcja przynależności typu PI.

Funkcje przynależności mają znaczący wpływ na wynik działania systemu rozmytego, dlatego tak ważnym aspektem jest ich odpowiedni dobór. Istnieją dwa podejścia

do wyznaczania funkcji przynależności: oparte na wiedzy ekspertów oraz oparte na zebranych danych. Pierwszym etapem jest określenie struktury funkcji, a następnie dobierane są parametry funkcji przynależności na podstawie danych [74]. Wybrane metody służące do parametryzacji funkcji przynależności to:

- Algorytm genetyczny (ang. *Genetic algorithm, GA*)

Jest to adaptacyjna technika wyszukiwania oparta na doborze naturalnym i regulach genetycznych, używana do znalezienia optymalnego rozwiązania. Do określenia funkcji przynależności została po raz pierwszy użyta w 1991 roku przez Karra, do projektowania rozmytego sterownika (ang. *fuzzy logic controller, FLC*) [79].



Rysunek 2.34: Algorytm genetyczny - schemat [80].

Na *Rysunku 2.34* przedstawiono typowy schemat algorytmu genetycznego, który składa się z następujących kroków [80] [81] [82] [83] [84]:

Krok 1: Dobór populacji początkowej w sposób pseudolosowy bądź heurystyczny z uwzględnieniem kodowania binarnego

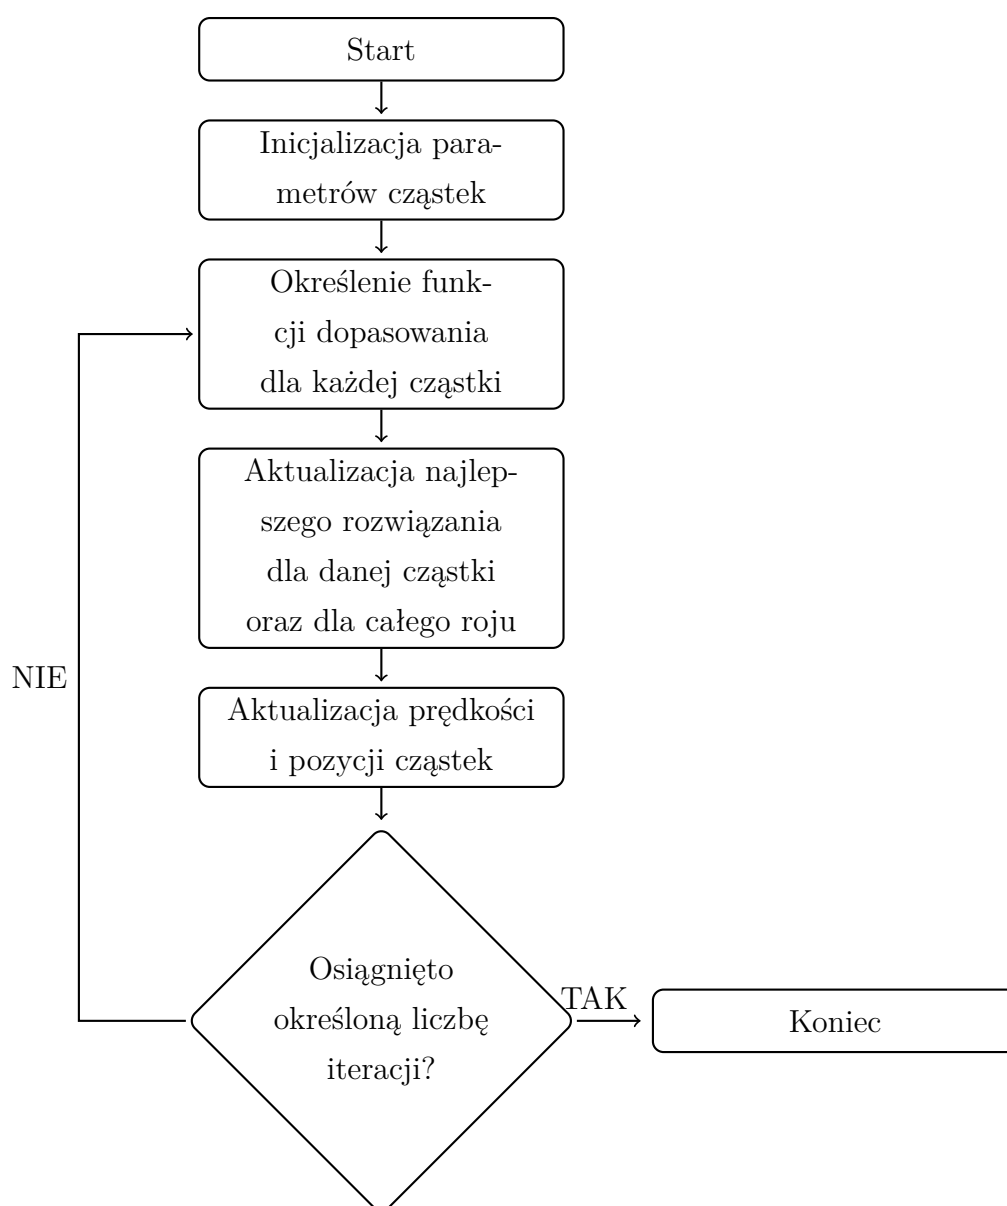
Krok 2: Ewaluacja (wyznaczanie wartości funkcji przystosowania osobników)

Krok 3: Selekcja osobników-rodziców z populacji, które będą wykorzystane do krzyżowania w celu wydania potomstwa (wybierane są osobniki o dobrych wartościach funkcji przystosowania, gdyż zakłada się, że w efekcie krzyżowania dają potomstwo o co najmniej takiej samej wartości funkcji przystosowania)

Krok 4: Mutacja polega na losowej zmianie jednego genu osobnika.

- Optymalizacja za pomocą roju cząstek (ang. *Particle swarm optimization, PSO*)

Schemat działania algorytmu został przedstawiony na *Rysunku 2.35*:

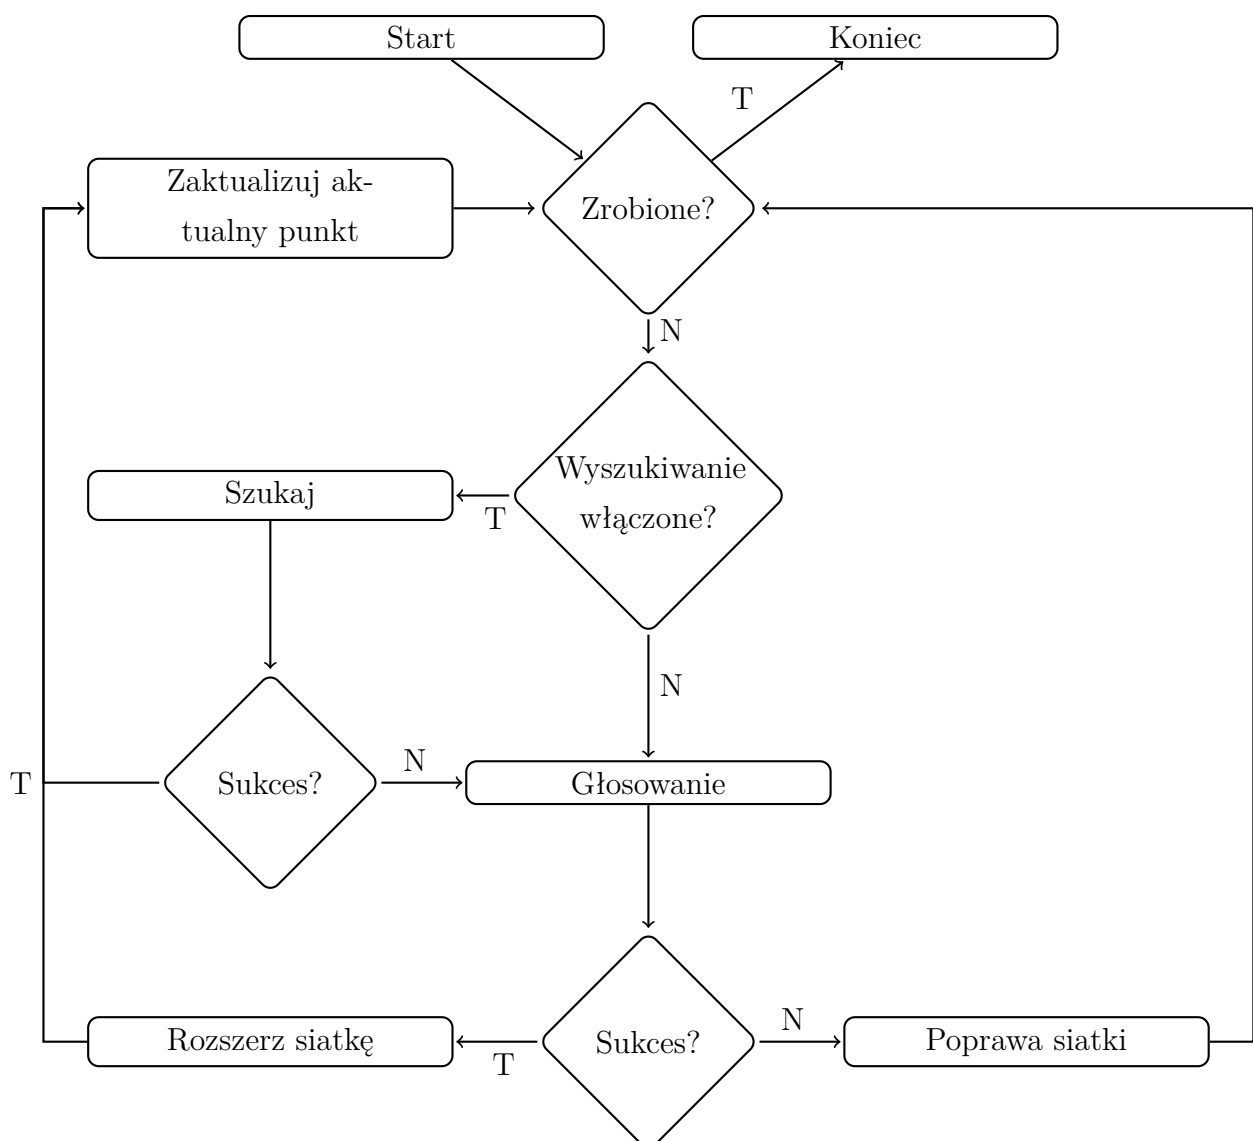


Rysunek 2.35: Rój cząstek - schemat [85].

Algorytm ten odzwierciedla zachowanie przemieszczającego się stada ptaków. Opiera się on na poszukiwaniu lepszych rozwiązań wraz z kolejnymi iteracjami (pokoleniami). Populacja nazywana jest rojem, a każdy członek - cząstką opisaną przez pozycję w przestrzeni rozwiązań, prędkość i kierunek, w którym się porusza. W każdej iteracji parametry cząstki są aktualizowane na podstawie doświadczeń jej własnych oraz sąsiadów.

- Algorytm wyszukiwania wzorca (ang. *Generalized pattern search, GPS*)

Schemat blokowy algorytmu przedstawiono na *Rysunku 2.36*:



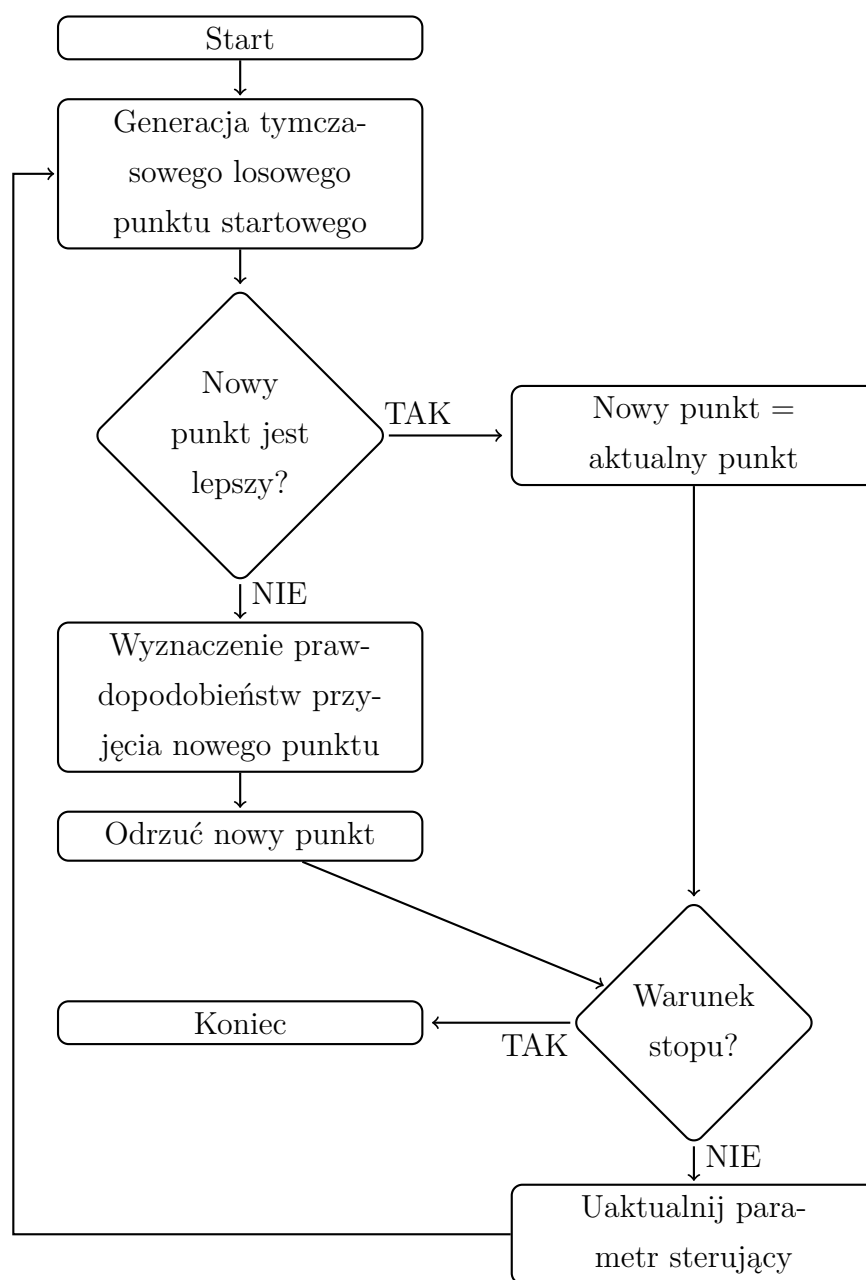
Rysunek 2.36: Algorytm wyszukiwania wzorca (T- Tak, N - Nie) [86].

Jest to algorytm optymalizacji oparty na poszukiwaniu lokalnego charakteru

funkcji celu w przestrzeni i poruszaniu się w korzystnym kierunku [87]. W kolejnych iteracjach wartości funkcji celu nie rosną, a każda z iteracji jest podzielona na dwie fazy: opcjonalnego przeszukiwania (*SEARCH*) i lokalnego głosowania (*POLL*) [88].

- Symulowane wyżarzanie (ang. *Simulated annealing algorithm, SA*)

Schemat blokowy algorytmu przedstawiony jest na *Rysunku 2.37*.



Rysunek 2.37: Algorytm symulowanego wyżarzania - schemat [89].

W każdej iteracji algorytmu jest generowany losowo nowy punkt. Odległość nowego punktu od aktualnego opiera się na rozkładzie prawdopodobieństwa ze skalą proporcjonalną do temperatury, która w pierwotnym algorytmie była parametrem sterującym (oryginalny algorytm był inspirowany metalurgią) [90].

### 2.3.3 Systemy rozmyte

Działanie systemu rozmytego oparte jest na przekształcaniu wartości wejściowych na wartości wyjściowe. Zawiera on *bazę wiedzy* zapisaną w postaci rozmytych reguł warunkowych *jeżeli-to* oraz mechanizm wnioskowania przybliżonego opartego na wnioskowaniu rozmytym i teorii zbiorów rozmytych (tzw. *motor wnioskowania rozmytego*) [69].

Systemy rozmyte znajdują zastosowanie w wielu dziedzinach nauki oraz przemysłu. Są one stosowane między innymi w sterowaniu automatycznym, przetwarzaniu sygnałów i obrazów, telekomunikacji, predykcji szeregów czasowych, identyfikacji systemów oraz modeli, budowie systemów eksperckich, klasyfikacji obiektów [69].

Wartości wejściowe systemu rozmytego mogą być następujące [69]:

- wartości lingwistyczne (przedstawione w postaci zbiorów rozmytych),
- wartości numeryczne - należy dla nich zastosować *operacje rozmywania* lub należy je rozumieć jako *rozmyte singletony*.

W wielu zastosowaniach dane wejściowe systemów rozmytych definiowane są jako dane liczbowe. Jednak wnioskowanie przybliżone wymaga, aby dane wejściowe były reprezentowane jako zbiory rozmyte. Proces mapowania wartości rzeczywistych na zbiory rozmyte jest nazywany **rozmywaniem** (ang. *fuzzification*) [91].

Rozmywanie pozwala na wprowadzenie na wejścia systemu wnioskowania rozmytego wartości numerycznych, pochodzących na przykład z czujników pomiarowych. Najczęściej stosuje się rozmywanie każdego elementu, po czym następuje łączenie uzyskanych zbiorów rozmytych za pomocą modelowania *t*-normą, łącznika „I”, minimum lub iloczynem zbiorów algebraicznych [69].

Motor wnioskowania rozmytego (ang. *fuzzy inference engine*) łączy wiedzę zawartą w rozmytych regułach *jeżeli-to* i przekształca wartości zmiennych wejściowych systemu na wartości jego zmiennych wyjściowych za pomocą metod wnioskowania przybliżonego. Wnioskowanie przybliżone prowadzi do uzyskania zbioru rozmytego [69].

Baza wiedzy jest zapisana w postaci rozmytych reguł warunkowych *jeżeli-to* [69]. Może być ona pozyskiwana w następujący sposób:



- od eksperta w danej dziedzinie wiedzy, posiadającego wiedzę na temat praw rządzących modelowanym zjawiskiem,
- automatyczne wydobywanie (ekstrakcja) reguł na podstawie danych numerycznych o wejściach i wyjściach modelowanego zjawiska,
- mieszane - część pochodzi od eksperta, a druga część - z automatycznego wydobywania.

Reguły *jeżeli-to* reprezentują zależności wejściowo-wyjściowe. Przesłanka reguły określa rozmyty obszar jej działania. Konkluzja definiuje wyjście systemu dla obszaru działania reguły [69].

Zbiór rozmyty może przedstawiać znaczenie lingwistyczne, jednak w niektórych zastosowaniach systemów rozmytych (np. klasyfikacja obiektów, automatyczne sterowanie), wymagane jest uzyskanie na wyjściu wartości numerycznej. Z tego względu stosuje się operację **wyostrzania** (ang. *defuzzification*) [69].

Najczęściej stosowane metody rozmywania są następujące [69]:

- Metoda środka ciężkości (ang. *Center of Gravity, COG*) - w wyniku otrzymuje się środek ciężkości figury pod funkcją przynależności (2.41):

$$y_0 = \frac{\int_{\mathbb{Y}} y \mu_{B'}(y) dy}{\int_{\mathbb{Y}} \mu_{B'}(y) dy}. \quad (2.41)$$

- Metoda indeksowanego środka ciężkości (ang. *Indexed COG<sub>α</sub>, ICOG<sub>α</sub>*) - stosowana w przypadku, gdy jest potrzeba wyeliminowania fragmentów funkcji przynależności, które mają wartości mniejsze niż parametr  $\alpha \in [0, 1]$  (2.42):

$$y_0 = \frac{\int_{\mathbb{Y}_\alpha} y \mu_B(y) dy}{\int_{\mathbb{Y}_\alpha} \mu_B(y) dy}. \quad (2.42)$$

- Modyfikowana metoda indeksowanego środka ciężkości (ang. *Modified ICOG<sub>α</sub>, MICOG<sub>α</sub>*) - w metodzie tej funkcja przynależności jest traktowana jako suma dwóch figur, których linią podziału jest  $\mu_B(y) = \alpha$ . Figura znajdująca się nad poziomem  $\alpha$  nazywana jest informatywną, podczas gdy figura leżąca pod - nieinformatywną:

$$y_0 = \frac{\int_{\mathbb{Y}_\alpha} y [\mu_B(y) - \alpha] dy}{\int_{\mathbb{Y}_\alpha} [\mu_B(y) - \alpha] dy}. \quad (2.43)$$

- Metoda maksimum (ang. *Maximum Defuzzifier, MD*) - ze zbioru wartości argumentów funkcji przynależności wybierana jest wartość numeryczna, która dla tych argumentów przyjmuje wartość maksymalną. Średnia z maksimumów zbioru  $M(B)$  jest definiowana jako (2.44):

$$y_0 = \frac{\int_{M(B)} y dy}{\int_{M(B)} dy}. \quad (2.44)$$

- Metoda wysokości (ang. *Height Method, HM*) - na podstawie wyników wnioskowania dla każdej reguły *jeżeli-to* uzyskuje się wyjściową wartość numeryczną (2.45):

$$y_0 = \frac{\sum_{i=1}^I \tau_i y^{(i)}}{\sum_{i=1}^I \tau_i}, \quad (2.45)$$

gdzie  $y^{(i)}$  to położenie środka ciężkości danego zbioru rozmytego, a  $\tau_i$  to maksymalna wartość funkcji przynależności.

- Modyfikowana metoda wysokości (ang. *Modified Height Method, MHM $_{\alpha}$* ) - analogicznie do modyfikowanej metody środka ciężkości, usuwa się nieinformatywną część zbioru rozmytego ( $\alpha_i$ ), który podlegał wyostrzaniu (2.46):

$$y_0 = \frac{\sum_{i=1}^I (\tau_i - \alpha_i) y^{(i)}}{\sum_{i=1}^I (\tau_i - \alpha_i)}. \quad (2.46)$$

Główną cechą różniącą różne typy systemów rozmytych od siebie jest typ konkluzji zastosowanej w rozmytych regułach warunkowych *jeżeli-to*. Większość z wymienionych wyżej systemów rozmytych to systemy statyczne (w których historia wartości wejściowych nie ma wpływu na aktualną wartość wyjścia). Istnieje jednak możliwość stworzenia systemu dynamicznego poprzez zwiększenie liczby wejść systemu rozmytego [69]. W niniejszej pracy do celów badawczych użyty został system rozmyty Takagi-Sugeno-Kanga (*TSK*), dlatego zostanie on opisany w sposób szczegółowy.

Istnieje wiele rodzajów systemów rozmytych, takich jak [69]:

- System rozmyty Mamdaniego-Assilana, MA - pierwszy system rozmyty, wykorzystany w 1975 roku do sterowania.

- **System rozmyty Takagi-Sugeno-Kanga (TSK)**

Baza wiedzy systemu (2.47):

$$\mathcal{R} = \left\{ \mathcal{R} \right\}_{i=1}^I = \left\{ \text{jeżeli } \bigwedge_{n=1}^N x_{0n} \text{ jest } A_n^{(i)}, \text{ to } y = f_i(\mathbf{x}_0) \right\}_{i=1}^I \quad (2.47)$$

- $I$  – liczba reguł w bazie wiedzy,  
 $x_{0n}$  – singleton wejściowy  $\mathbf{x}_0 = [x_{01}, x_{02}, \dots, x_{0n}]^T$ ,  
 $A_n^{(i)}$  – wartość lingwistyczna przesłanki,  
 $y = f_i(\mathbf{x}_0)$ , – funkcja w konkluzji  $i$ -tej reguły *jeżeli-to*.

Rozmyte reguły warunkowe (2.48) [69, 78]:

$$\text{JEŻELI } X \text{ jest } A \text{ i } Y \text{ jest } B, \text{ TO } z = f(x, y) \quad (2.48)$$

gdzie  $A$  i  $B$  to zbiory rozmyte z funkcjami przynależności  $\mu A(x)$  i  $\mu B(x)$  w poprzedniku i  $Z = f(x, y)$  jest funkcją rzeczywistą.

Końcowe wyjście systemu jest średnią ważoną wszystkich reguł wyjść [78] (2.49):

$$\text{Końcowe wyjście systemu} = \frac{\sum_{i=1}^N w_i z_i}{\sum_{i=1}^N w_i} \quad (2.49)$$

Poziom końcowy każdej reguły  $z_i$  jest ważony przez siłę  $w_i$  reguły. Funkcje przynależności wyjścia w systemie *TSK* mogą być jedynie liniowe lub stałe [92].

Rozmyte wartości wejściowe są dodawane za pomocą operatora „I” i są określane jako iloczyn rozmytych wejść, podczas gdy operator „LUB” stosowany do dodawania rozmytych wartości wejścia to probabilistyczny „LUB” rozmytych wartości wejściowych [92].

- System rozmyty z parametrycznymi konkluzjami - parametry zbiorów rozmytych w konkluzjach reguł zależą od pewnych parametrów wejściowych zbiorów rozmytych (np. położenie środka ciężkości) [69].
- System rozmyty Tsukamoto (*TFS*) - główną różnicą pomiędzy *TSK* a *TFS* jest sposób określania położenia singletonu w konkluzji reguły rozmytej oraz stopnia aktywacji reguły (w *TFS* jest definiowane jako funkcja monotoniczna) [69] [91].
- System rozmyty Baldwina - opiera się na innym podejściu niż Zadeha - na rozszerzeniu wnioskowania w logice dwuwartościowej opisanego *funkcją prawdy* [69] [91].

- System rozmyty typu-2 - wprowadzony w 1999 roku przez J. M. Mendla, aby umożliwić zamodelowanie niepewności wynikającej z różnego definiowania zmiennych lingwistycznych przez ekspertów. Zbiory rozmyte *typu-1* nie umożliwiają tego, ponieważ charakter funkcji przynależności nie jest rozmyty. Natomiast wartość funkcji przynależności zbiorów rozmytych *typu-2* jest reprezentowana przez inną funkcję przynależności, co implikuje jej rozmyty charakter [69].
- System rozmyty oparty na przedziałowych zbiorach rozmytych (ang. *interval value fuzzy set*) - jest to szczególny przypadek zbioru rozmytego *typu-2* [69].
- System rozmyty oparty na podobieństwie zbiorów - w systemie tym wyznacza się wnioski poprzez modyfikację zbioru rozmytego w konkluzji reguły warunkowej na podstawie podobieństwa zbiorów rozmytych [69].
- Systemy neuronowo-rozmyte (ang. *neuro-fuzzy systems*) stanowią połączenie sztucznych sieci neuronowych (wykorzystywanych do automatycznego uzyskiwania rozmytych reguł warunkowych oraz systemów rozmytych). Najbardziej popularne systemy neuronowo-rozmyte: Janga, oparty na rozmytym modelu *c*-regresji, adaptacyjny system neuronowo-rozmyty Cho-Wanga, ANBLIR, ewolucyjno-rozmyty oparty na trójetapowej metodzie uczenia, ewolucyjno-neuronowo-rozmyty z uczeniem opartym na algorytmach genetycznych i metodzie najmniejszych kwadratów, ewolucyjno-rozmyty ze zmiennymi typami funkcji przynależności [69].

System rozmyty Mamdaniego-Assilana używa maksimum i minimum w defuzyfikacji, podczas gdy system rozmyty Takagi-Sugeno-Kanga do obliczenia wartości wyjściowej systemu używa średniej ważonej bezpośrednio do wyników zastosowania operatorów minimum. *TSK* cechuje się również prostszą architekturą niż *MA*. System rozmyty *TSK* jest często stosowany ze względu na mały nakład obliczeniowy, który jest potrzebny do wyznaczenia wartości wyjściowej systemu - powodem jest brak operacji wyostrzania. Jednak warto wspomnieć, iż nie ma w nim możliwości zastosowania rozmytych reguł warunkowych *jeżeli-to* oraz operatorów agregacji, z powodu występowania singletonów w konkluzjach reguł *jeżeli-to*. System rozmyty Tsukamoto jest rzadko używany ze względu na trudność w otrzymywaniu warunkowych reguł *jeżeli-to* z wiedzy eksperta w skomplikowanej postaci. Z tego samego powodu system rozmyty Baldwina jest trudny do zastosowania w praktyce, a ponadto wymagany jest duży nakład obliczeniowy do wyznaczenia lingwistycznych określeń prawdy; jest jednak „czystszy” z logicznego punktu widzenia, ponieważ opiera się na uogólnieniu reguł logiki dwuwartościowej opisanej za pomocą funkcji prawdy. System rozmyty z parametrycznymi konkluzjami

pozwała na zastosowanie różnych interpretacji rozmytych reguł warunkowych *jeżeli-to* i operacji agregacji, jednak cechuje się trudnością uzyskania reguł z parametrycznymi konkluzjami bezpośrednio od eksperta [69] [91].



# Rozdział 3

## Materiał i metody badawcze

### 3.1 Charakterystyka zbiorów danych pomiarowych i obiektu badawczego


Niniejszy rozdział zawiera opis danych pomiarowych powszechnie dostępnych pochodzących z kaskady dwóch zbiorników oraz wahadła, a także opis obiektu badawczego - przenośnika paskowego, z którego dane zostały zebrane przez autora niniejszej rozprawy doktorskiej. Instalacja jest autorskim stanowiskiem badawczym firmy.

Pierwsze dwa zbiory pomiarowe służą do testowania metody oraz współczynnika  $VCMF$  na prostych modelach. Natomiast dane pochodzące z obiektu badawczego służą do weryfikacji wypracowanej metody.

#### 3.1.1 Kaskada dwóch zbiorników

Zbiór danych pochodzi z symulacji instalacji składającej się z dwóch zbiorników połączonych w układ kaskadowy (*Rysunek 3.1*). Oba zbiorniki posiadają stałe nieregulowane wypływy. Strumień wejściowy pierwszego zbiornika jest regulowany za pomocą elektrozaworu. Zmiana napięcia  $u(t)$  powoduje zmianę wielkości strumienia wejściowego. Zmiana ta ma bezpośredni wpływ na podwyższenie lub obniżenie wysokości cieczy w obu zbiornikach  $h_1(t)$ ,  $h_2(t)$ .


Zbiór danych składa się z 3000 próbek wejścia  $u(t)$ , wyjścia  $h_2(t)$ . Dane zbierane były z częstotliwością 0,2



Rysunek 3.1: Zbiorniki w układzie kaskadowym.

sekundy, a następnie zostały znormalizowane do zakresu 0-1. Dane pochodzą z [93].

### 3.1.2 Wahadło



Rysunek 3.2: Wahadło.

Zbiór danych pochodzi z symulacji stanowiska klasycznego wahadła, na końcu którego zawieszono kuliste obciążenie o masie  $m = 1$  kg. Długość wahadła wynosi  $l = 1$  m (Rysunek 3.2). Wahadło w chwili  $t = 0$  zostaje wychylone o kąt  $\alpha$ . Następnie w wyniku działania siły grawitacji, wahadło zaczyna poruszać się ruchem o charakterze gasnących oscylacji. Sygnałem wyjściowym jest pozycja wahadła. Zbiór danych składa się z 1001 próbek

wyjścia  $\alpha(t)$  zbieranych z częstotliwością 0,1 s. Dane pochodzą z [93].

### 3.1.3 Przenośnik pasowy

Stanowisko przenośnika pasowego zaprezentowane na Rysunku 3.3 jest laboratoryjną instalacją składającą się z równoległego połączenia trzech modułów.



Rysunek 3.3: Przenośnik pasowy.

Pojedynczy moduł składa się z silnika, falownika, koła pasowego oraz pasów transportowych. Każdy z tych elementów został dobrany uwzględniając najczęściej występujące modele w przemyśle motoryzacyjnym (spawalnie, lakiernie) oraz ciągłym. Wymóg korzystania z danego modelu urządzenia bardzo często jest opisany w standardzie projektowania dla danego koncernu lub fabryki (np. standard VASS V6, Daimler Integra 6).

Szczegółową listę zastosowanych podzespołów zawiera Tablica 3.1. Zadaniem instalacji laboratoryjnej jest jak najdokładniejsze odwzorowanie systemów transportowych. W przemyśle motoryzacyjnym wykonuje się transport pojedynczych elementów karoserii w ramach pojedynczej celi produkcyjnej, jak również transport całej karoserii pomiędzy celami produkcyjnymi. W prze-

myśle ciągłym przenośnikami wykonuje się między innymi transport materiałów sypkich z silosów (stanowiących magazyn materiałowy) do zbiornika, w którym następuje mieszanie substancji.



Tabela 3.1: Szczegółowa lista podzespołów zastosowanych w przenośniku paskowym.

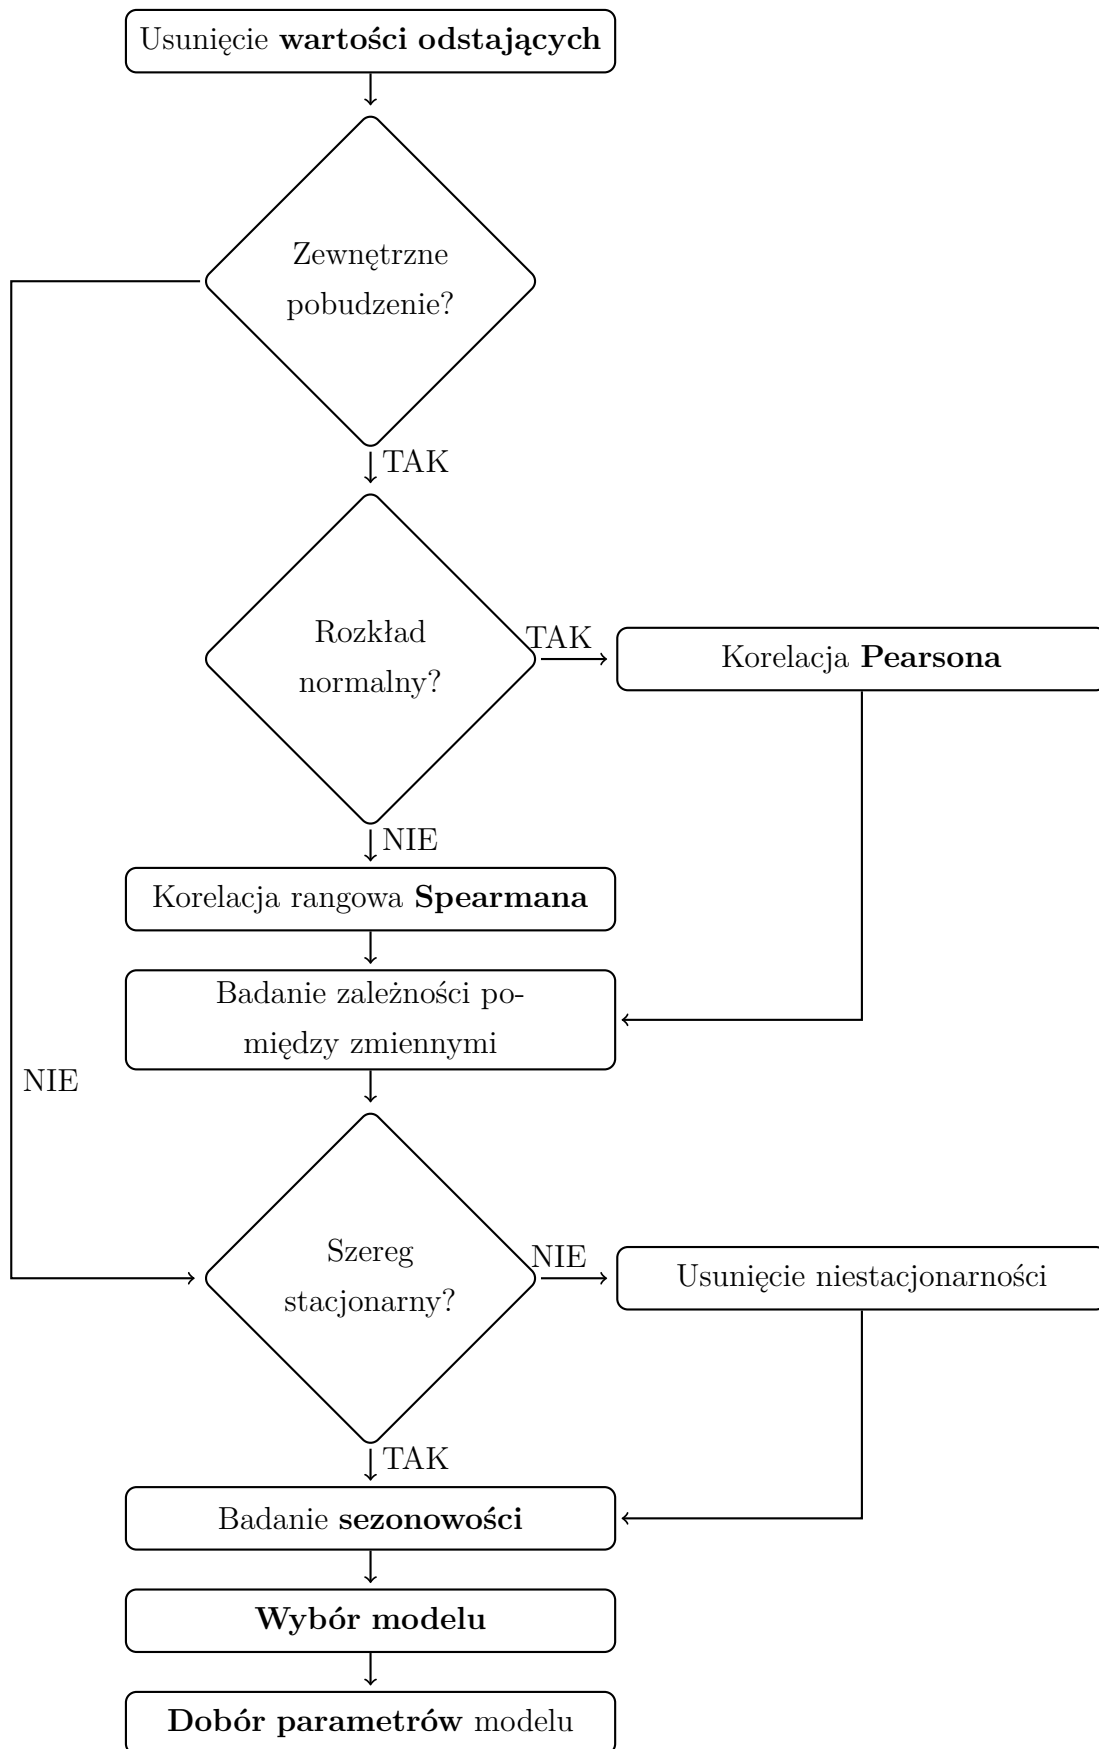
ID	1 (NORD)	2 (SEW)	3 (Siemens)
Silnik	63S/4 TF	WA20 DR63S4	1LA7060-4AB12
Falownik	nordac 500e	DFE32B	G120-CU250S
Koło pasowe	SPA 118X1 1610	SPA 118X1 1610	SPA 118X1 1610
Pas transportowy	SPA 1282	SPA 1282	SPA 1282

Sterowanie poszczególnymi elementami zostało zrealizowane przy wykorzystaniu sterownika PLC Siemens S7-300. *HMI* zostało wykonane na komputerze stacjonarnym połączonym ze sterownikiem za pomocą sieci Ethernet.

Dane zebrane podczas pracy przenośnika paskowego składają się z 40 serii pomiarowych prędkości, prądu i momentu obrotowego. Przykładowe przebiegi czasowe dla jednej serii pomiarowej zostały przedstawione na *Rysunku 4.15*. Dla każdej serii pomiarowej stworzono model typu *Grey Box*. Przez eksperta 20 modeli zostało ocenionych jako modele dobre (dobrze dopasowane), a pozostałe 20 jako modele złe (źle dopasowane).

## 3.2 Analiza i wstępne przetwarzanie danych oraz modelowanie obiektu przemysłowego

W celu zbadania jakości danych pochodzących z obiektu przemysłowego oraz ich wstępnego przetwarzania zastosowano proces oparty na statystycznej analizie danych oraz analizie przebiegów czasowych (*Rysunek 3.4*), który w efekcie końcowym pozwala na wybór klasy i typu modelu danego obiektu w konkretnych punktach pracy.

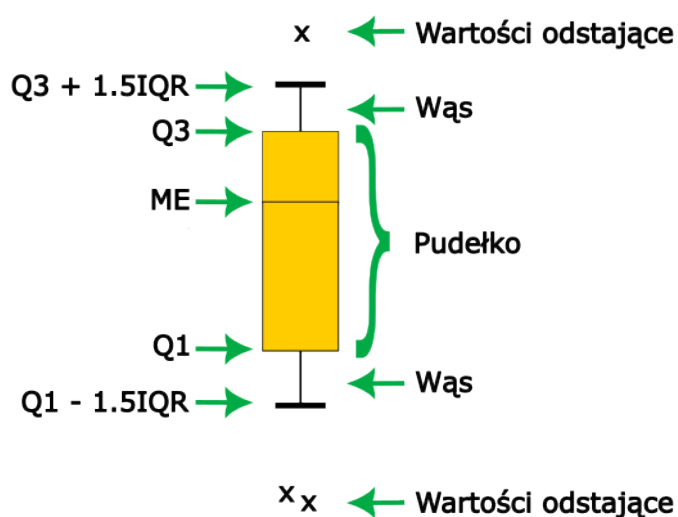


Rysunek 3.4: Proces wstępnego przetwarzania danych oraz wyboru modelu.

Kolejne etapy zaproponowanej metody przetwarzania wstępnych danych pomiarowych uzyskanych z obiektu przemysłowego zostały opisane w kolejnych punktach.

### 1. Sprawdzenie, czy w danych występują wartości odstające (ang. *outliers*) na podstawie wykresu pudełkowego

Tego kroku nie wykonuje się w przypadku, w którym w danych pochodzących z obiektu nie ma zewnętrznego pobudzenia cechującego się gasnącymi oscylacjami, ponieważ dla tego typu charakterystyki na wykresie pudełkowym wiele pomiarów zostanie niesłusznie przedstawionych jako odstające.



Rysunek 3.5: Przykładowy wykres pudełkowy [94].

Wykres pudełkowy jest przydatnym narzędziem wizualizacji danych składających się z co najmniej pięciu pomiarów, umożliwia bowiem porównanie próbek między sobą.

Rysunek 3.5 przedstawia przykładowy wykres pudełkowy, który odzwierciedla zmienność próbki opisywaną przez następujące miary: dolny kwartył  $Q1$ , medianę  $ME$ , górny kwartył  $Q3$ , rozstęp międzykwartyłowy  $IQR = Q3 - Q1$ ,  $maximum = Q3 + 1.5 IQR$ ,  $minimum = Q1 - 1.5 IQR$  [95].

W celu zidentyfikowania wartości odstających, określenia, czy dane cechują się skośnością oraz zdefiniowania zakresu danych należy wykonać wykres pudełkowy (ang. *box plot*) [96]. W przypadku wystąpienia wartości odstających należy je usunąć ze zbioru danych.

## 2. Badanie normalności rozkładu danych za pomocą testu Shapiro-Wilka

Test Shapiro-Wilka służy do sprawdzenia hipotezy, czy dana próbka pochodzi z rozkładu normalnego o nieznannej średniej i nieznannej wariancji. Statystyka testowa  $W$  do testowania normalności jest zdefiniowana w następujący sposób (3.1), (3.2) [95]:

$$W = \frac{(\sum_{i=1}^n (a_i y_i))^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.1)$$

$$(a_1, \dots, a_n) = \frac{m' v^{-1}}{(m' V^{-1} V^{-1} m)^{1/2}} \quad (3.2)$$

gdzie:

$a_i$  - współczynniki,

$y_i$  - wektor uporządkowanych losowych obserwacji próbki  $x_1 \leq x_2 \leq \dots x_n$ ,

$\bar{y}$  - średnia,

$V$  - macierz kowariancji o wymiarach  $n \times n$ ,

$m' = (m_1, m_2, \dots, m_n)$  - wektor wartości oczekiwanych rzędu standardowego rozkładu normalnego.

Testujemy hipotezę zerową:  $H_0$ : próba badawcza pochodzi z populacji o rozkładzie normalnym [97].

Jeśli  $p$ -wartość  $< 0,05$  (poziom  $\alpha$ ), wówczas odrzucana jest hipoteza zerowa i oznacza to, że dana próba badawcza nie pochodzi z rozkładu normalnego i prawdziwa jest hipoteza alternatywna ( $H_1$ : próba badawcza nie pochodzi z populacji o rozkładzie normalnym) [97].

## 3. Badanie zależności pomiędzy zmiennymi

Dla zmiennych cechujących się rozkładem normalnym należy obliczyć współczynnik korelacji Pearsona, a dla pozostałych - Spearmana. W celu wizualnej oceny związku pomiędzy każdą parą zmiennych numerycznych można wykreślić je na wykresie, który przedstawia korelacje pomiędzy zmiennymi w formie wykresu punktowego, a przekątna przedstawia rozkład każdej zmiennej za pomocą histogramu.

Rangowy współczynnik korelacji Spearmana ma postać (3.3) [98][99][100]:

$$r_s = \frac{\sum_{i=1}^n (Q_i - \bar{Q})(R_i - \bar{R})}{\sqrt{\sum_{i=1}^n (Q_i - \bar{Q})^2} \sqrt{\sum_{i=1}^n (R_i - \bar{R})^2}} \quad (3.3)$$

gdzie:

$n$  - rozmiar próbki,

$(X_i, Y_i)$  - próby przekształcone do  $(Q_i, R_i)$ ,  $X_i = X_1, X_2, \dots, X_n$ ,

$Q_i$  - ranga obserwacji  $Y_i$  w próbie  $Y_1, Y_2, \dots, Y_n$ ,

$\bar{Q}, \bar{R}$  - średnie próbkowe w odpowiednich próbach rang.

Współczynnik korelacji Pearsona ma postać (3.4) [67]:

$$r_s = \frac{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\left(\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \frac{1}{n-1} \sum_{i=1}^n (Y_i - \bar{Y})^2\right)^{1/2}} \quad (3.4)$$

gdzie:

$n$  - rozmiar próbki,

$(X_i, Y_i)$  - wartości prób losowych zmiennych,

$\bar{Q}, \bar{R}$  - wartości średnie z prób.

Wartość korelacji pomiędzy zmiennymi na niskim poziomie mówi, że dwie zmienne nie wpływają bezpośrednio na siebie. Zatem zależność ta nie powinna być brana pod uwagę w modelu.

#### 4. Badanie stacjonarności z użyciem testu Dickeya-Fullera

Szereg czasowy jest uważany za stacjonarny, jeśli jego właściwości nie zależą od czasu, w którym obserwowany jest szereg. Zatem szeregi czasowe zawierające trend lub sezonowość nie są stacjonarne, ponieważ składowe szeregu (składowa sezonowa, trend) będą miały wpływ na wartość szeregu w różnych momentach. Stacjonarne szeregi czasowe nie będą miały przewidywalnych wzorców w długim okresie [50]. Stacjonarność cechuje się stałą wariancją i średnią w czasie, a także niezmiennością właściwości statystycznych szeregu czasowego. Przesunięcie okna obserwacji czasu o stałą szerokości wzdłuż ściśle stacjonarnego szeregu zawsze daje ten sam rozkład wielowymiarowy [101].

W celu statystycznego zbadania stacjonarności należy przeprowadzić rozszerzony test pierwiastka jednostkowego Dickeya-Fullera (ang. *Augmented Dickey-Fuller Test*). Test Dickeya-Fullera [102] [103]:

Hipoteza zerowa ( $H_0$ ):  $\Phi = 1$ : szereg jest niestacjonarny

Hipoteza alternatywna ( $H_1$ ):  $abs(\Phi) < 1$ : szereg jest stacjonarny

$$y_t = \beta' D|t + \phi y_{t-1} \quad (3.5)$$

gdzie:

$y_t$  - przebieg czasowy,

$D_t$  - wektor składowych deterministycznych (np. trendu),

$p$  - opóźnienia,

$\Delta y_{t-j}$  - różnica w szeregu w czasie ( $t-j$ ),

$SE$  - oszacowanie zwykłego błędu standardowego.

Jeśli szereg jest niestacjonarny, to należy usunąć niestacjonarność poprzez różnicowanie. Różnicowanie polega na zamianie szeregu czasowego (zawierającego wartości) na szereg, który zawiera ich różnicę obliczoną pomiędzy punktami w czasie (przykładowo: wartości w czasie  $t$  zostaje przypisana wartość w  $t - 1$ ). Różnicowania czasem można dokonywać wielokrotnie tak, aby wyeliminować trend i wprowadzić stacjonarność [104].

## 5. Badanie sezonowości

Szeregi czasowe składają się ze składowych, takich jak: trend, cykl, sezonowość oraz część resztkowa [105], wskutek czego przed wyborem metody przewidywania, należy zidentyfikować wzorce powtarzające się w danych, takie jak trend (istnieje wtedy, gdy występuje długoterminowy wzrost lub spadek danych; nie musi być liniowy), cykl (ma miejsce, gdy w danych występują wzrosty i spadki, które nie mają ustalonej częstotliwości) albo sezonowość. Sezonowość występuje wtedy, gdy na szereg czasowy mają wpływ czynniki sezonowe, takie jak na przykład pora dnia i określa wzorzec pojawiający się w danych w regularnym odstępie czasu. Sezonowość ma zawsze stałą i znaną częstotliwość [50]. Sezonowość zaburza interpretację zmian zjawiska w danych okresach ze względu na zaniżanie bądź

zawyzanie wartości danego zjawiska w okresach tego samego typu, wskutek czego należy ją wyeliminować z szeregu czasowego [105].

W celu zbadania ogólnych właściwości szeregu czasowego należy dokonać addytywnej dekompozycji szeregu czasowego (3.6) [50].

$$y_t = S_t + T_t + R_t, \quad (3.6)$$

gdzie:

$y_t$  - dane pomiarowe,

$S_t$  - składowa sezonowa (po odjęciu składowej trendu od szeregu czasowego oblicza się wartości średnie tak powstałego szeregu czasowego dla każdego okresu),

$T_t$  - składowa opisująca trend (obliczana na podstawie scentrowanej średniej ruchomej (kroczącej) szeregu czasowego),

$R_t$  - część resztkowa, która pokazuje, co pozostało po odjęciu od danych składowej sezonowej i opisującej trend.

## 6. Wybór modelu i dobór parametrów modelu

Popularne modele szeregów czasowych są następujące:

- AR (ang. *Autoregressive Model*): model autoregresyjny (3.7 [106]) opiera się na założeniu, że wartość w momencie  $t$  to funkcja wartości we wcześniejszych chwilach czasu [104]:

$$y_t = \phi_0 + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \epsilon_t \quad (3.7)$$

gdzie:

$e_t$  - błędy (reszty) modelu w okresach  $t, t-1, \dots, t-q$ ,

$\epsilon_t$  - biały szum,

$p$  - wielkość opóźnienia (rzęd modelu).

- MA (ang. *Moving Average Model*): model ze średnią ruchomą (3.8 [106]) opiera się na założeniu, że wartość w danej chwili czasu opisuje funkcja ostatnich wartości składników „błędu” (reszt) (niezależnych od siebie) [104]:

$$y_t = \theta_0 + e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} \quad (3.8)$$

gdzie:

$e_t$  - błędy (reszty) modelu w okresach  $t, t-1, \dots, t-q$ ,

$q$  - wielkość opóźnienia.

- ARIMA (ang. *Autoregressive Integrated Moving Average Model*): zintegrowany model autoregresji i średniej ruchomej uwzględnia własności AR i MA, a także operację różnicowania [104]. Model ARMA jest opisany następującym równaniem (3.9 [106]):

$$y_t = \phi_0 + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \epsilon_t + \theta_0 + e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} \quad (3.9)$$

- NARMAX (ang. *AutoRegressive Moving Average with Exogenous Input*) - nieliniowy model autoregresyjny średniej ruchomej z zewnętrznym pobudzeniem [107].

Model przedstawiony jest w postaci równania różnicowego (3.10) [108] [109]:

$$y_k = F[Y_{k-1}, \dots, y_{k-n_y}, u_{k-d}, u_{k-d-1}, \dots, u_{k-d-n_u} + e_{k-1}, \dots, e_{k-n_e}] + e_k \quad (3.10)$$

gdzie:

$n_{y,x,e} \in \mathbb{N}$  – maksymalne opóźnienia dla wejścia i wyjścia systemu,

$k \in \mathbb{N}^n$  – czas dyskretny,

$u_k \in \mathbb{R}^{n_u}$  – wejście systemu,

$y_k \in \mathbb{R}^{n_y}$  – wyjście systemu w czasie dyskretnym  $k$ ,

$e_k \in \mathbb{R}^{n_e}$  – odzwierciedla niepewności i możliwy szum w czasie dyskretnym  $k$ ,

$F$  – nieliniowa funkcja regresorów wejścia i wyjścia,

$d$  – czas opóźnienia.

Modele te mogą być rozbudowywane w zależności od dostępnych danych. W przypadku, gdy na model ma oddziaływać zewnętrzne wejście pobudzające, nazwa modelu rozszerza się o składową  $X$  (ang. *exogenous input*), np. model ARX, ARMAX, itp. Jeżeli po przeprowadzeniu analizy dotyczącej sezonowości w punkcie 5. *Badanie sezonowości* okazało się, że w danych występuje zjawisko sezonowości, wówczas model jest rozszerzany o składową  $S$  (ang. *seasonal*), np. SARIMA.

Funkcja autokorelacji mierzy liniowy związek pomiędzy wartościami opóźnionymi (ang. *lagged values*) ciągu czasowego [50] (wartościami bieżącymi i przeszłymi).



Każdemu panelowi wykresu wartości opóźnienia odpowiada kilka współczynników autokorelacji. Przykładowo:  $r_1$  mierzy zależność pomiędzy  $y_t$  i  $y_{t-1}$ , a  $r_2$  mierzy zależność pomiędzy  $y_t$  i  $y_{t-2}$ . Wartość współczynnika autokorelacji  $r_k$  określa następujące równanie (3.11) [50]:

$$r_k = \frac{(\sum_{t=k+1}^T (y_t - \bar{y})(y_{t-k} - \bar{y}))}{\sum_{t=1}^T (y_t - \bar{y})^2}, \quad (3.11)$$

gdzie:

$k$  - przesunięcie,

$T$  - długość ciągu czasowego.

Współczynniki autokorelacji tworzą wykres funkcji autokorelacji (ang. *autocorrelation function, ACF*), który jest również nazywany *korelogramem* [50]. Z kolei funkcja korelacji cząstkowej (ang. *partial autocorrelation function, PACF*) bada związek pomiędzy  $y_t$  a  $y_{t-k}$  po usunięciu wpływu opóźnień 1, 2, 3, ...,  $k-1$  [50].

Jedną z metod wyboru rzędu (parametrów) modelu jest analiza wykresów ACF i PACF (inną metodą jest minimalizacja kryterium informacyjnego Akaikego, *AIC*). Z wykresu PACF można odczytać empiryczne wskazówki odnoszące się do wartości parametru  $p$  modelu AR( $p$ ) - wartość opóźnienia, dla której następuje odcięcie (przekroczenie przedziału ufności) [104]. Liczba opóźnień znajdujących się poza przedziałem ufności określa stopień modelu. Czasami zdarza się, że po występowaniu istotnych korelacji znajdują się nieznaczące korelacje, ale po nich widoczna jest jedna autokorelacja znacząca - wówczas można taką wartość zignorować, ponieważ dąży się do uproszczenia modelu [50]. Z kolei w celu doboru parametrów modelu ze średnią ruchomą MA( $q$ ) należy użyć wykresu ACF [104]. Należy również sprawdzić, czy w danych występuje średnia ruchoma za pomocą funkcji autokorelacji (ACF) - jeśli w danych widoczny jest duży skok, który zmniejsza się w kolejnych opóźnieniach to świadczy to o obecności ruchomej średniej w danych. Następnie należy sprawdzić, czy istnieje składowa autoregresyjna na wykresie PACF, o której obecności świadczy istnienie istotnych korelacji w pierwszych opóźnieniach, po których następują statystycznie niskie zero, mieszczące się w przedziale ufności (który jest wskaźnikiem progu istotności) nieznaczące korelacje [110].

Aby wybrać odpowiedni model, który dobrze opisywałby dynamikę systemu, należy zwrócić uwagę na charakterystyczne cechy wykresów ACF i PACF dla po-

szczególnych typów modeli (w celu określenia typu modelu cechy charakterystyczne dla ACF lub PACF muszą być spełnione dla jednego z nich) [50] [104] [110] [111]:

- **AR(p)**

ACF: tendencja spadkowa, maleje wykładniczo (bezpośrednio lub oscylując) do zera wraz ze wzrostem opóźnień, **wartości maleją powoli**

PACF: znaczące korelacje przy pierwszym lub drugim opóźnieniu, po których następują nieznaczące korelacje; znaczący pik przy opóźnieniu  $p$ , który wskazuje rząd  $p$ , **ostry spadek po minięciu opóźnienia  $p$**

- **MA(q)**

ACF: dąży do zera; znaczący pik przy opóźnieniu  $q$ , który wskazuje rząd  $q$ , po którym następuje ostre odcięcie dla dowolnych wartości większych niż  $q$  (**ostry spadek po minięciu opóźnienia  $q$** )

PACF: duży pik przy pierwszym opóźnieniu, który **powoli maleje** po kilku opóźnieniach; tendencja spadkowa (maleje wykładniczo)

- **ARMA(p, q)**

ACF: tendencja spadkowa (maleje wykładniczo), szybko opada; znaczący pik przy opóźnieniu  $q$ ; **brak wyraźnego punktu odcięcia**

PACF: tendencja spadkowa (maleje wykładniczo); znaczący pik przy opóźnieniu  $p$ ; **brak wyraźnego punktu odcięcia**


Dodatkowo należy sprawdzić, czy w danych pomiarowych istnieje nieliniowość. Można to zrobić poprzez analizę wykresów opóźnień (ang. *lag plots*) pod kątem tego, czy dane są liniowo rozdzielne. Wykresy opóźnień pozwalają również na wykrycie wartości odstających [112]. Uzyskane w powyższy sposób informacje pozwalają na logiczny dobór modelu do danych.

Parametry modelu są estymowane za pomocą sieci neuronowych (typ: wielowarstwowy perceptron, ang. *Multilayer Perceptron, MLP*). Sieć neuronowa składa się z warstwy wejściowej, trzech warstw ukrytych (składających się odpowiednio z 8, 16 i 16 neuronów) oraz warstwy wyjściowej (1 neuron), 20 epok. Każdy neuron jest połączony z wszystkimi neuronami znajdującymi się w warstwie poprzedniej oraz warstwie następnej. Jako funkcji aktywacji użyto *ReLU* (ang. *rectified linear unit*), która jest powszechnie stosowana w metodach głębokiego uczenia (ang. *deep learning*) ze względu na jej zdolność do radzenia sobie z nieliniowością. W każdej iteracji bieżący model jest porównywany z najlepszym dotychczas

wybrany za pomocą współczynnika *VCMF*. W przypadku, gdy jest on lepszy - staje się on nowym najlepszym modelem. W przeciwnym razie jest odrzucany. Liczba iteracji jest równa liczbie epok.

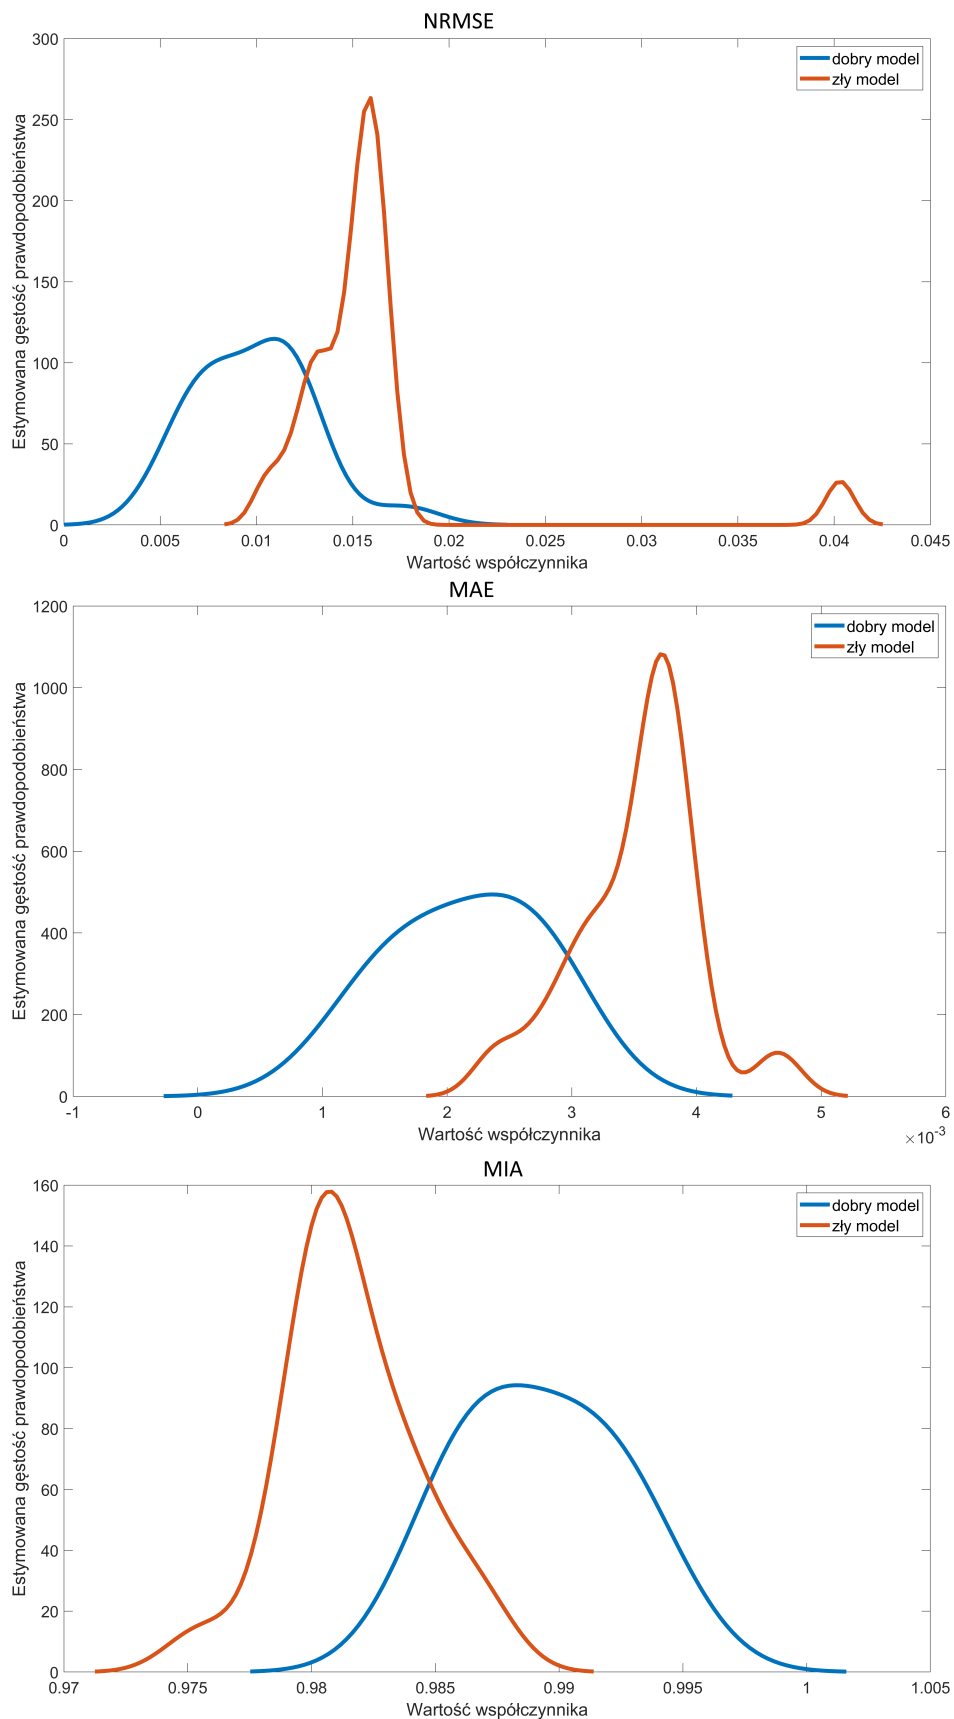
### 3.3 Współczynnik jakości modelu oparty na logice rozmytej (*VCMF*)

W celu oceny jakości modelu stworzono współczynnik jakości oparty na logice rozmytej (*ang. Virtual Commissioning-Model-Fuzzy coefficient, VCMF*) (*Rysunek 3.6*), który bierze pod uwagę cztery powszechnie stosowane metody oceny jakości modelu: *NRMSE*, *ME*, *MAE* oraz *MIA* opisane w *Rozdziale 2.2*. Logika rozmyta bierze pod uwagę wiedzę ekspercką, która często jest nieprecyzyjna i nie jest wyrażona w wartościach numerycznych.

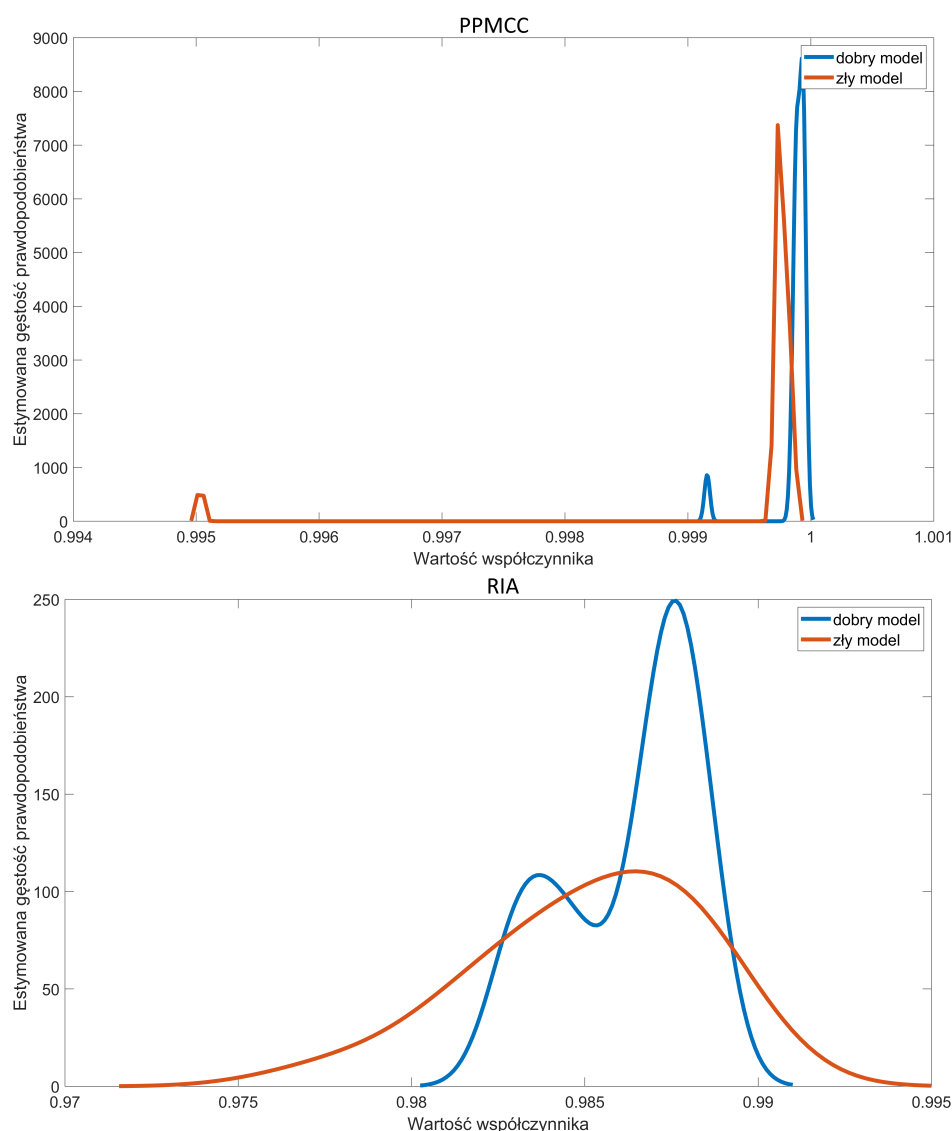


Rysunek 3.6: Virtual Commissioning-Model-Fuzzy coefficient (*VCMF*).

Analizując wyżej przedstawione miary stosowane do oceny jakości modeli (*Rozdział 2.2*) można zauważyć, iż żadna z miar nie jest wystarczająca do pełnej oceny jakości modelu na potrzeby jego zastosowania w wirtualnym uruchomieniu, a część z nich niesie z sobą redundantne informacje. Dodatkowo przeprowadzono analizę rozkładów gęstości prawdopodobieństwa wszystkich przytoczonych miar dla przenośnika paskowego. Wykresy gęstości prawdopodobieństwa pokazują, że jedynie niektóre miary różnicują pomiary na dwie wyraźne grupy (3.7). Dla pozostałych miar opisanych w *Rozdziale 2.2*) nie obserwuje się różnic pomiędzy modelem dobrym a złym, czego przykładem są miary *PPMCC* oraz *RIA* (3.8).



Rysunek 3.7: Wykres gęstości prawdopodobieństwa - przykład współczynników różnicujących: *NRMSE* (wykres górny), *MAE* (środkowy) oraz *MIA* (dolny).

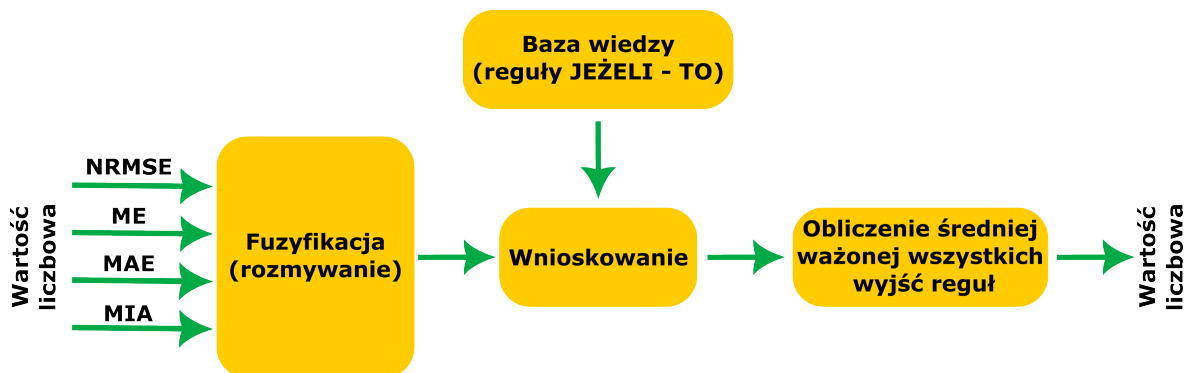


Rysunek 3.8: Wykres gęstości prawdopodobieństwa - przykład współczynników nieróżnicujących: *PPMCC* (wykres górny) oraz *RIA* (dolny).

W niniejszej pracy zaproponowano system rozmyty Takagi-Sugeno-Kanga (*TSK*). Istnieje wiele różnych typów systemów rozmytych (Mamdani-Assilan [69, 113], Tsukamoto [69], Baldwin [69], system rozmyty z parametrycznymi konkluzjami [69] etc.), jak przedstawiono w *Rozdziale 2.3*. Zdecydowano się na system Takagi-Sugeno-Kanga [69, 78, 113], ponieważ cechuje się on dobrą wydajnością obliczeniową oraz zapewnia ciągłość powierzchni wyjścia [78]. Ponadto może być on traktowany jako konsylium ekspertów, gdzie każdy ekspert wyraża swoją opinię na temat związku pomiędzy wyjściem a wejściem systemu dla konkretnego zakresu wejść systemu. Każdy ekspert jest modelowany przez jedną regułę *jeżeli-to*. Na wagi mają wpływ wartości wejściowe systemu, w wyniku czego otrzymywane jest dynamiczne konsylium ekspertów [69]. System

rozmyty pozwala na uwzględnienie wiedzy eksperckiej w procesie podejmowania decyzji.

Stworzony system rozmyty Takagi-Sugeno-Kanga (współczynnik jakości dopasowania modelu do danych - *VCMF*) jest przedstawiony na *Rysunku 3.9*.



Rysunek 3.9: Struktura systemu wnioskowania rozmytego *VCMF*.

Jako wartości wejściowe system przyjmuje zmienne numeryczne, dlatego pierwszym etapem, który ma miejsce w systemie rozmytym jest fuzyfikacja, czyli proces rozmywania wejść (*NRMSE*, *ME*, *MAE*, *MIA*), podczas którego te wartości wejść są odwzorowywane na wartości z przedziału  $<0; 1>$  za pomocą funkcji przynależności. Baza wiedzy systemu rozmytego składa się z rozmytych reguł *jeżeli-to*. Pozwala ona na użycie zmiennych lingwistycznych jako przesłanek i konkluzji systemu. Przesłanki reguł odzwierciedlają niepewność lub brak precyzyjności, która zostanie spełniona w konkluzji. Reguły warunkowe zostały stworzone na podstawie wiedzy eksperckiej z zakresu wirtualnego rozruchu oraz systemów automatyki przemysłowej, a także z założeń występujących w kontraktach biznesowych. Ekspert nie zna dokładnych wartości, jakie powinny przyjmować współczynniki opisujące jakość dopasowania modelu do danych, wskutek czego posługuje się nieprecyzyjnymi stwierdzeniami, takimi jak „Wartość *ME* powinna być stosunkowo mała i jednocześnie nigdy nie powinna przekraczać pewnej wartości, aby nie spowodować nieuzasadnionego przekroczenia progu alarmowego”. Takie rozmyte wartości trudno jest przełożyć na wejścia do algorytmów, ponieważ trudno im przypisać jedną określoną wartość. Rozmyte reguły warunkowe w zaproponowanym systemie *TSK* przedstawiają się następująco (3.12):

$$\left. \begin{array}{l}
 \text{jeśli } ME \text{ jest ZŁE to JAKOŚĆ jest ZŁA} \\
 \\
 \text{jeśli } NRMSE \text{ jest ZŁE to JAKOŚĆ jest ZŁA} \\
 \\
 \text{jeśli } NRMSE \text{ jest ZŁE i } ME \text{ jest ZŁE i } MAE \\
 \text{jest ZŁE i } MIA \text{ jest ZŁE to JAKOŚĆ jest ZŁA} \\
 \\
 \text{jeśli } NRMSE \text{ jest DOBRE i } ME \text{ jest DOBRE i } MAE \\
 \text{jest DOBRE i } MIA \text{ jest DOBRE to JAKOŚĆ jest DOBRA} \\
 \\
 \text{jeśli } NRMSE \text{ jest DOBRE i } ME \text{ jest DOBRE i } MIA \\
 \text{jest DOBRE to JAKOŚĆ jest DOBRA} \\
 \\
 \text{jeśli } NRMSE \text{ jest DOBRE i } ME \text{ jest DOBRE i } MAE \\
 \text{jest DOBRE to JAKOŚĆ jest DOBRA}
 \end{array} \right\} (3.12)$$

Następnie, otrzymane w ten sposób wejścia rozmyte są agregowane poprzez obliczenie siły reguły. W celu obliczenia siły reguły, do połączenia funkcji przynależności stosuje się rozmyte „I” (iloczyn) oraz „LUB” (probabilistyczny „LUB” - sumę algebraiczną). W Tabeli 3.2 przedstawiono operatory logiczne oraz użyte metody agregacji, implikacji i wyostrzania podczas projektowania systemu rozmytego. Łączniki „I” oraz „LUB” służą do połączenia rozmytych wartości wejściowych w przesłankach reguł.

Tabela 3.2: Ustawienia systemu TSK.

<b>Łącznik „I”</b>	iloczyn
<b>Łącznik „LUB”</b>	probabilistyczne „LUB” (suma algebraiczna)
<b>Implikacja</b>	min
<b>Agregacja</b>	max
<b>Wyostrzanie</b>	średnia ważona wyjść

Wyjściowa wartość systemu jest obliczana za pomocą średniej ważonej wszystkich wyjść reguł [78]. Wyjście systemu rozmytego jest obliczane na podstawie bieżących wartości zmiennych wejściowych [69] i oznacza decyzję, czy model jest *ZŁY* lub *DOBRY* (wartości z zakresu 0-1).

Do zdefiniowania funkcji przynależności została wykorzystana wiedza ekspercka z zakresu wirtualnego rozruchu. Przez eksperta został określony dopuszczalny błąd oraz kształt funkcji przynależności. Jako funkcję przynależności wszystkich wejść wybrano złożoną Gaussowską funkcję przynależności (ang. *Gaussian combination membership function*).

W celu dobrego doboru parametrów funkcji przeprowadzono wybór parametrów za pomocą pięciu metod: statystycznej, algorytmu genetycznego, optymalizacji za pomocą roju cząstek, algorytmu wyszukiwania wzorca oraz symulowanego wyżarzania, opisanych szczegółowo w *Rozdziale 2.3*. Następnie porównano otrzymane funkcje przynależności za pomocą wymienionych metod i dokonano wyboru najlepszej poprzez analizę rozmiaru efektu. Bazując na wiedzy eksperckiej z zakresu wirtualnego uruchomienia założono, że wejście *ME* ma mieć znaczący wpływ na wartość współczynnika *VCMF*. Ma to na celu eliminację modeli, których działanie dopuszczałoby nieuzasadnione przekroczenie progów alarmowych. Dlatego też zdecydowano się nie dobierać parametrów funkcji przynależności dla wejścia *ME* za pomocą algorytmów optymalizacji.

#### 1. Dobór parametrów funkcji przynależności metodą statystyczną

Na podstawie wykresów funkcji gęstości prawdopodobieństwa współczynników *NRMSE*, *ME*, *MAE* oraz *MIA* (*Rysunek 3.7*) wybrano punkt przecięcia się dwóch grup (dobry model, zły model), który stanowi punkt przecięcia funkcji przynależności.

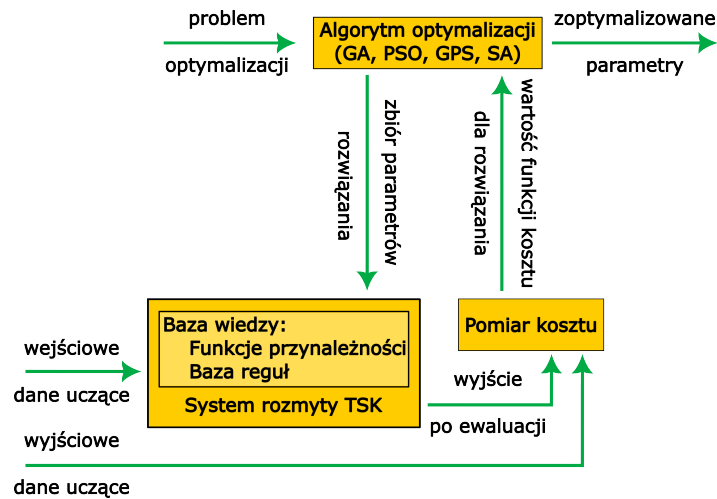
W tabeli 3.3 przedstawiono wartości parametrów Gaussowskiej złożonej funkcji przynależności:

	$\sigma_1$	$c_1$	$\sigma_2$	$c_2$
NRMSE - DOBRY	0,00756	-0,00949	0,00423	0,00463
NRMSE - ZŁY	0,00446	0,22350	0,00329	0,10420
ME - DOBRY	0,31600	-1,98000	4,14200	2,77800
ME - ZŁY	14,40000	35,85000	5,31000	107,50000
MAE - DOBRY	0,00142	-0,00042	0,00142	0,00141
MAE - ZŁY	0,00170	0,00503	0,000004	0,01300
MIA - DOBRY	0,04680	1,04100	0,14200	1,23200
MIA - ZŁY	0,06440	-0,27470	0,14200	0,74300

Tabela 3.3: Wartości parametrów Gaussowskiej funkcji przynależności.



2. Dobór parametrów funkcji przynależności za pomocą algorytmów optymalizacji  
Idea doboru parametrów funkcji przynależności za pomocą algorytmów optymalizacji została przedstawiona na *Rysunku 3.10* [114]:



Rysunek 3.10: Schemat doboru parametrów funkcji przynależności z użyciem algorytmów optymalizacji.

- (a) Dobór parametrów funkcji przynależności za pomocą algorytmu genetycznego (*GA*)

Funkcje przynależności są zakodowane binarnie (jako ciągi bitów) [78]. Populacja początkowa składała się z 200 osobników. Osobniki do krzyżowania zostały wybrane na podstawie selekcji turniejowej. Przy współczynniku krzyżowania równym 0,8 otrzymano 10 osobników potomnych cechujących się najlepszymi wartościami funkcji przystosowania.


Tabela 3.4: Wartości parametrów GA funkcji przynależności.

	$\sigma_1$	$c_1$	$\sigma_2$	$c_2$
NRMSE - DOBRY	0,05419	0,00476	0,00697	0,02412
NRMSE - ZŁY	0,00467	0,01990	0,00274	0,01010
ME - DOBRY	0,31600	-1,98000	4,14200	2,77800
ME - ZŁY	14,40000	35,85000	5,31000	107,50000
MAE - DOBRY	0,00999	0,00098	0,00008	0,00281
MAE - ZŁY	0,00995	0,00135	0,00851	0,01090
MIA - DOBRY	0,02675	0,04140	0,03332	0,54720
MIA - ZŁY	0,01920	0,75400	0,00002	0,98500

Otrzymane wartości funkcji przynależności za pomocą algorytmu genetycznego zostały przedstawione w *Tablicy 3.4*.

- (b) Dobór parametrów funkcji przynależności za pomocą algorytmu roju cząstek (*PSO*)

Na każdym etapie algorytm ocenia funkcję celu dla każdej cząstki. Następnie algorytm decyduje o nowej prędkości każdej cząstki.



Rysunek 3.11: Wykres zbieżności kosztu optymalizacji od numeru iteracji.

Na *Rysunku 3.11* można zauważyć, że koszt optymalizacji osiągnął wartość minimalną po 40 iteracjach.


Tabela 3.5: Wartości parametrów PSO funkcji przynależności.

	$\sigma_1$	$c_1$	$\sigma_2$	$c_2$
NRMSE - DOBRY	0,00756	-0,00949	0,00423	0,00463
NRMSE - ZŁY	0,00446	0,02235	0,00329	0,10420
ME - DOBRY	0,31600	-1,98000	4,14200	2,77800
ME - ZŁY	14,40000	35,85000	5,31000	107,50000
MAE - DOBRY	0,00142	-0,00042	0,00142	0,00141
MAE - ZŁY	0,00995	0,00336	0,01000	0,01015
MIA - DOBRY	0,00003	0,98470	0,92010	1,17400
MIA - ZŁY	0,98330	0,62230	1,00000	0,98210

W *Tablicy 3.5* przedstawiono parametry funkcji przynależności dobrane za pomocą algorytmu *PSO*.

- (c) Dobór parametrów funkcji przynależności za pomocą algorytmu symulowanego wyżarzania (*SA*)

Na *Rysunku 3.12* można zauważyć, iż po przekroczeniu 105 iteracji funkcja kosztu osiąga wartość optymalną.



Rysunek 3.12: Wykres zbieżności kosztu optymalizacji od numeru iteracji.

W *Tabeli 3.6* przedstawiono wartości parametrów Gaussowskiej złożonej funkcji przynależności dobrane za pomocą algorytmu symulowanego wyżarzania.

Tabela 3.6: Wartości parametrów SA funkcji przynależności.

	$\sigma_1$	$c_1$	$\sigma_2$	$c_2$
NRMSE - DOBRY	0,07547	-0,00001	0,08841	0,02236
NRMSE - ZŁY	0,02899	0,07821	0,07364	0,09027
ME - DOBRY	0,31600	-1,98000	4,14200	2,77800
ME - ZŁY	14,40000	35,85000	5,31000	107,50000
MAE - DOBRY	0,00027	0,00047	0,00001	0,00289
MAE - ZŁY	0,00354	0,00845	0,00371	0,00340
MIA - DOBRY	0,32530	0,80050	0,03354	0,27290
MIA - ZŁY	0,44720	-0,13330	0,21420	0,97580

- (d) Dobór parametrów funkcji przynależności za pomocą algorytmu wyszukiwania wzorca (*GPS*)

Algorytm szuka sekwencji punktów zbliżających się do punktu optymalnego. Po przeprowadzeniu 26 iteracji algorytm zatrzymał się, ponieważ rozmiar oczka siatki (ang. *mesh*) stał się mniejszy ( $9,5367 \times 10^{-7}$ ) niż wartość tolerancji rozmiaru oczka ( $10^{-6}$ ).

W Tabeli 3.7 przedstawiono wartości parametrów funkcji przynależności dobrane za pomocą algorytmu wyszukiwania wzorca.

Tabela 3.7: Wartości parametrów *GPS* funkcji przynależności.

	$\sigma_1$	$c_1$	$\sigma_2$	$c_2$
NRMSE - DOBRY	0,00756	-0,00949	0,07454	0,06615
NRMSE - ZŁY	0,00531	0,09571	0,00329	0,10420
ME - DOBRY	0,31600	-1,98000	4,14200	2,77800
ME - ZŁY	14,40000	35,85000	5,31000	107,50000
MAE - DOBRY	0,00142	-0,00042	0,00001	0,00287
MAE - ZŁY	0,00001	0,00296	0,00004	0,01300
MIA - DOBRY	0,98430	0,04128	0,07950	0,22450
MIA - ZŁY	0,06440	-0,27470	0,00138	0,98520

W celu ostatecznego wyboru parametrów złożonej Gaussowskiej funkcji przynależności obliczono wielkość efektu Cohena (ang. *Cohen's d effect size* [115]) dla każdej z grup *DOBRA* oraz *ZŁA*. Dla grupy *DOBRA* wielkość efektu pomiędzy danymi a wartościami idealnymi (równymi 100) przedstawiona jest równaniem 3.13 [116]:

$$d_{DOBRA} = \frac{\mu_{DI} - \mu_D}{s_{Dpooled}} \quad (3.13)$$

gdzie:

$\mu_{DI}, \mu_D$  – odpowiednio średnie z grupy *DOBRA IDEALNA* oraz *DOBRA*,

$s_{Dpooled}$  – ang. *pooled standard deviation* - średnia ważona odchyłeń standardowych dla danej próbki.

W analogiczny sposób została obliczona wielkość efektu dla grupy *ZŁA* oraz wartościami idealnymi *ZŁA IDEALNA* równymi 0 (3.14) [116]:

$$d_{ZLA} = \frac{\mu_{ZI} - \mu_Z}{s_{Zpooled}} \quad (3.14)$$

gdzie:

$\mu_{ZI}, \mu_Z$  – odpowiednio średnie z grupy *ZŁA IDEALNA* oraz *ZŁA*,  
 $s_{Zpooled}$  – ang. *pooled standard deviation* - średnia ważona odchyłeń standardowych dla danej próbki.

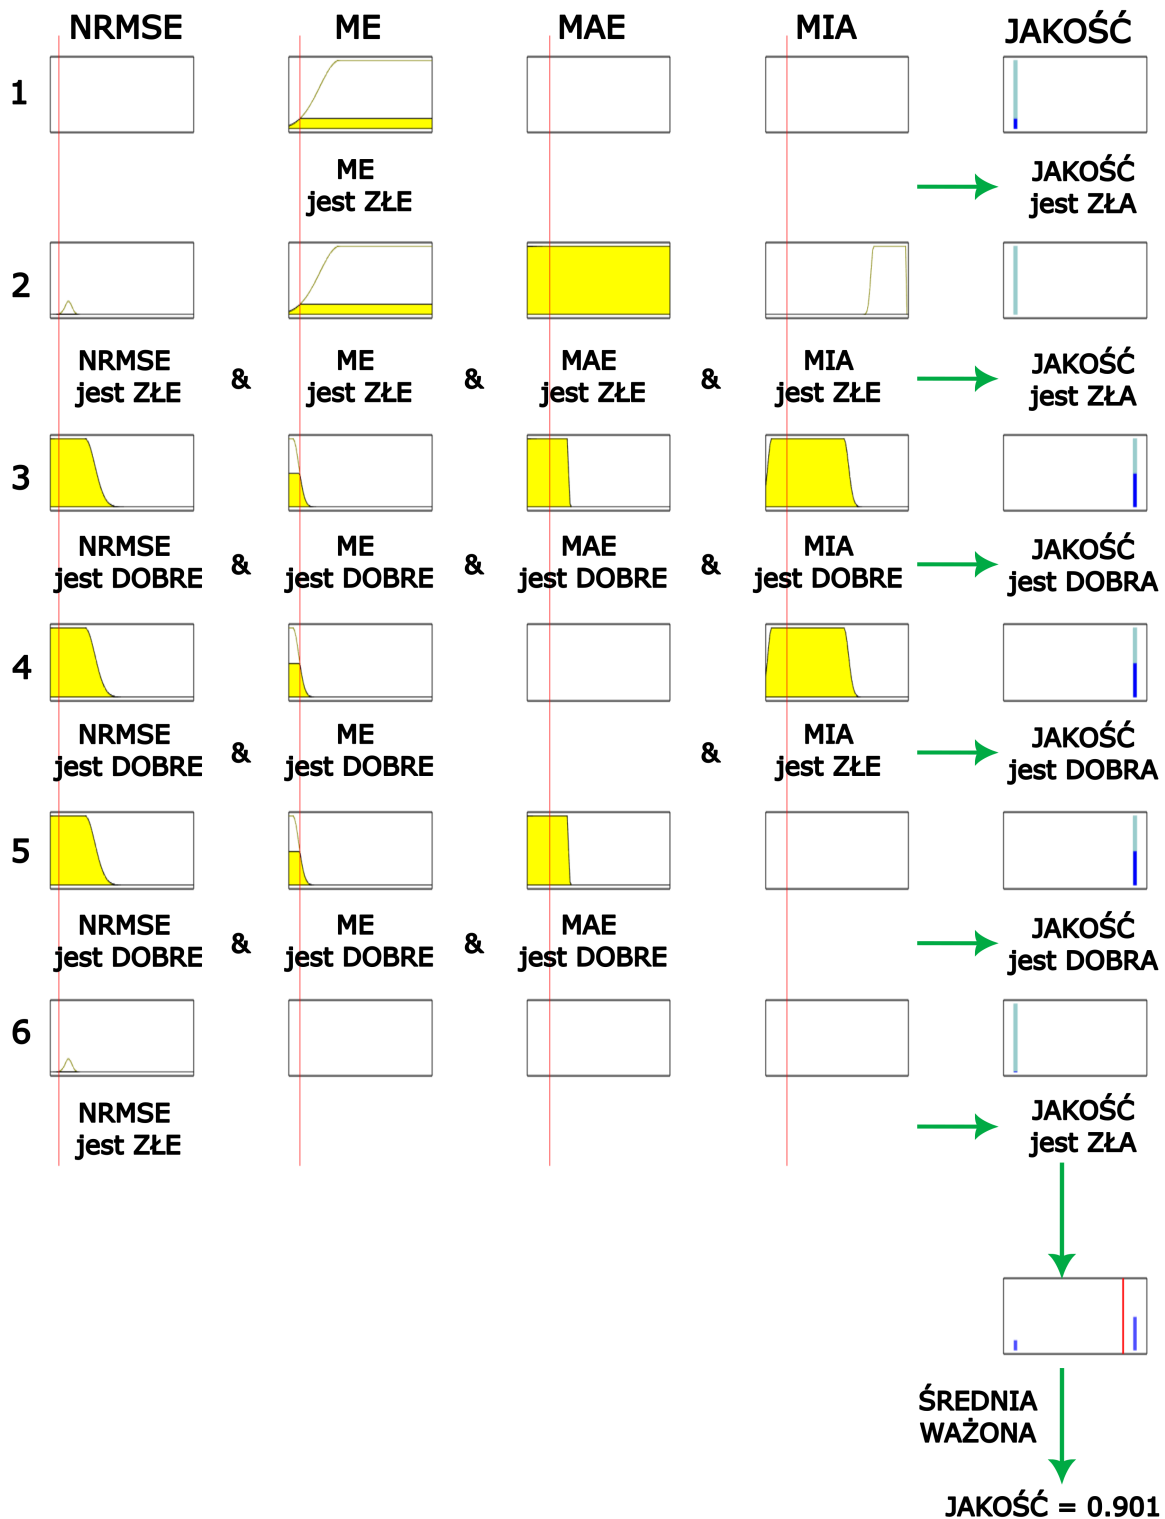
W *Tablicy 3.8* przedstawiono wartości wielkości efektu obliczone dla grup *DOBRA* oraz *ZŁA* dla każdego algorytmu wykorzystanego do wyznaczenia parametrów złożonej Gaussowskiej funkcji przynależności. Wielkość efektu oznacza jaka jest różnica pomiędzy średnimi poszczególnych grup. Im mniejsza różnica między grupami (*DOBRA* i *DOBRA IDEALNA* oraz *ZŁA* i *ZŁA IDEALNA*), tym w analizowanym przypadku lepiej. Oznacza to, że grupy są bardziej zbliżone do siebie. Na podstawie otrzymanych wyników wybrano parametry dostrojone za pomocą algorytmu genetycznego (*GA*) z tego względu, iż cechują się one najniższą średnią wartością wielkości efektu.

Tabela 3.8: Wielkość efektu  $d$  Cohena.

wielkość efektu	dobra	zła	średnia
metoda statystyczna	1,33490	1,09110	1,21300
<b>GA</b>	<b>0,87887</b>	<b>0,81763</b>	<b>0,84825</b>
PSO	2,74348	0,53995	1,64172
GPS	291,58893	0,45033	146,01963
SA	10,28767	0,45033	5,36900

Stworzony współczynnik *VCMF* służący do oceny jakości modelu może być wykorzystywany do oceny jakości modelu pod kątem jego możliwości wykorzystania w wirtualnym uruchomieniu.

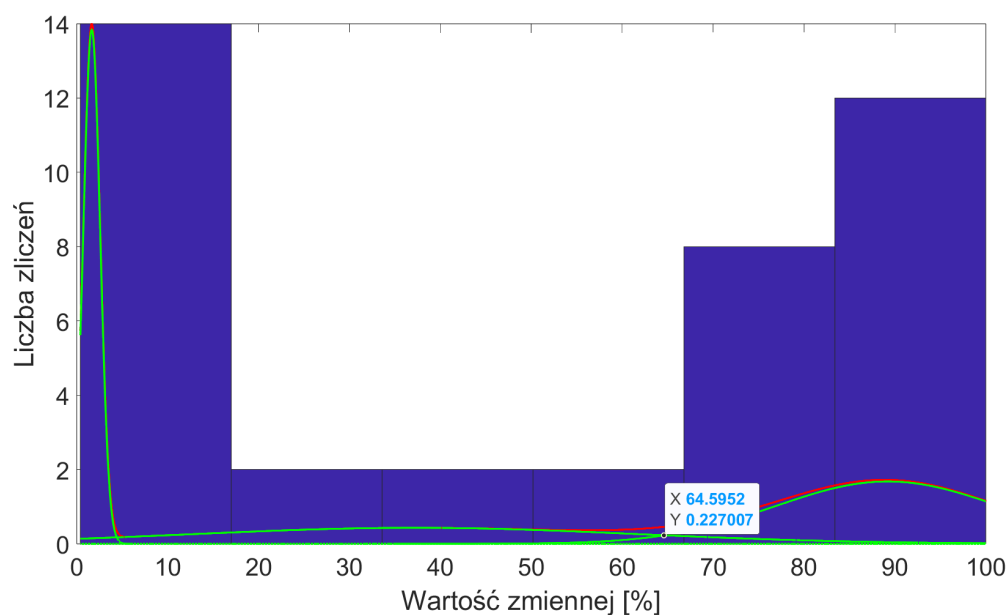
System rozmyty działa w następujący sposób (Rysunek 3.13):



Rysunek 3.13: System rozmyty TSK o 4 wejściach, 1 wyjściu i 6 regułach.

Na samym początku obliczane są wartości współczynników  $NRMSE$ ,  $ME$ ,  $MAE$  oraz  $MIA$ . Następnie wartości współczynników zaznaczane są na wykresie za pomocą czerwonej linii. Ma miejsce proces rozmywania (fuzyfikacji), czyli określenia wartości funkcji przynależności dla konkretnej wartości wejściowej (miejsce przecięcia czerwonej linii z wykresem funkcji przynależności). Kolejny krok to analiza reguł *jeżeli-to*. W każdym z wierszy 1-6 jest zawarta jedna reguła. Reguły są przedstawione za pomocą funkcji przynależności. W przypadku reguł łączonych za pomocą logicznego „I” należy wybrać wartość minimalną z poszczególnych wierszy. Wartości z każdego wiersza przedstawione są w ostatniej kolumnie za pomocą ciemnoniebieskiego koloru. Kolejnym etapem jest agregacja za pomocą obliczenia średniej ważonej wszystkich wyjść reguł. Dla współczynnika  $VCMF$  końcowa wartość jest mnożona razy 100.

W celu zdefiniowania progu odcięcia, powyżej którego wartości wyjściowe systemu wnioskowania rozmytego oznaczają model dobrze dopasowany, a poniżej - źle dopasowany, dokonano przybliżenia rozkładu wartości wyjściowych za pomocą trzech składowych (komponent) cechujących się normalnym rozkładem prawdopodobieństwa (liczba trzech składowych wynika z kryterium  $BIC$  (ang. *Bayesian Information Criterion* [117], które dla 3 przyjmuje najmniejszą wartość) za pomocą algorytmu  $GMM$  (modelowanie mieszanin Gaussowskich, ang. *Gaussian Mixture Modelling*) [118]. Na *Rysunku 3.14* przedstawiono rozkład na składowe Gaussowskie i zaznaczono wartość progu odcięcia równą 64,6.



Rysunek 3.14: Dekompozycja rozkładu wartości wyjściowych VCMF na składowe Gaussowskie.






# Rozdział 4

## Wyniki

### 4.1 Kaskada dwóch zbiorników


Dane pomiarowe otrzymane dla kaskadowego układu dwóch zbiorników zawierają znormalizowany poziom cieczy dolnego zbiornika [m] oraz znormalizowane napięcie pompy [V] (Rysunek 4.1).



Rysunek 4.1: Dane pomiarowe uzyskane dla kaskadowego układu dwóch zbiorników.

- **Usunięcie wartości odstających**

Na podstawie stworzonego wykresu pudełkowego można stwierdzić, iż w danych nie ma wartości odstających (*Rysunek 4.2*).




Rysunek 4.2: Wykres pudełkowy dla kaskady dwóch zbiorników.

- **Badanie rozkładu normalnego danych**

$p$ -wartość otrzymana w wyniku przeprowadzenia testu Shapiro-Wilka jest równa w przybliżeniu  $2,57 * 10^{-36}$ , co oznacza, że dane nie pochodzą z rozkładu normalnego.

- **Badanie zależności pomiędzy zmiennymi**

Pomiędzy zmiennymi występują silne korelacje, co oznacza silny wpływ wejść pomiarowych na wyjścia (*Rysunek 4.3*).



Rysunek 4.3: Mapa ciepła korelacji rangowej Spearmana pomiędzy zmiennymi.


- **Badanie stacjonarności szeregu czasowego**

W celu zbadania stacjonarności szeregu czasowego przeprowadzono rozszerzony test Dickeya-Fullera i otrzymano następujące wyniki:

- wartość statystyki testowej: -2,87
- p-wartość: 0,049

co dowodzi, że szereg jest stacjonarny.

- **Badanie sezonowości szeregu czasowego**




Rysunek 4.4: Wynik dekompozycji szeregu czasowego.

Analizując *Rysunek 4.4* można zauważyć, że amplituda sezonowości jest stała, niezmienna w czasie, a trend ma charakter horyzontalny, część resztkowa - odzwierciedla przypadkowe wahania szeregu czasowego.


- **Wybór typu modelu i dobór parametrów modelu**

Liczba opóźnień znajdujących się poza przedziałem ufności na wykresie ACF (*Rysunek 4.5*) świadczy o stopniach wielomianu modelu: 10. W danych występuje składowa MA (przy opóźnieniu  $lag = 10$  widoczny jest duży skok zmniejszający się w kolejnych opóźnieniach), wskutek czego wybrano model **MAX(10)** z zewnętrznym pobudzeniem w postaci napięcia pompy.




Rysunek 4.5: Korelogram poziomu cieczy dolnego zbiornika (ACF).

Na wykresie PACF jest widoczny duży pik przy pierwszym opóźnieniu, który maleje w kolejnych opóźnieniach (*Rysunek 4.6*).



Rysunek 4.6: Wykres korelacji cząstkowej poziomu cieczy dolnego zbiornika (PACF).

Wykres opóźnień szeregu czasowego względem opóźnienia pokazuje (*Rysunek 4.7*), że dane są liniowo rozdzielne, więc nie ma potrzeby wyboru modelu nieliniowego.




Rysunek 4.7: Wykres opóźnień (ang. *lag*).

Za pomocą sieci neuronowej były dobierane parametry modeli. Iteracyjnie było tworzonych 20 modeli o różnych parametrach. Za pomocą współczynnika *VCMF* modele były między sobą porównywane - model o najwyższej wartości współczynnika *VCMF* został wybrany jako model reprezentujący układ zbiorników. W *Tabeli 4.1* przedstawiono wartości parametrów najlepszego modelu dobrane za pomocą sieci neuronowej.

Tabela 4.1: Parametry modelu MAX.

$\theta_0$	$\theta_1$	$\theta_2$	$\theta_3$	$\theta_4$
3,3125	6,7677	10,4544	12,9922	13,4054
$\theta_5$	$\theta_6$	$\theta_7$	$\theta_8$	$\theta_9$
11,5591	8,2346	4,6809	1,9573	0,4789

Dopasowanie stworzonego modelu do danych rzeczywistych przedstawiono na *Rysunku 4.8*.




Rysunek 4.8: Kaskadowy układ dwóch zbiorników.

- **Współczynnik  $VCMF$**

Dla układu kaskadowego zbiorników obliczono wartość współczynnika  $VCMF$ , która wyniosła 81,4%. Biorąc pod uwagę wartość progu odcięcia wyznaczoną za pomocą algorytmu  $GMM$ , wartość współczynnika  $VCMF$  jest większa od wartości progu odcięcia, co oznacza, że obiekt został opisany dobrze dopasowanym modelem do danych rzeczywistych i może zostać użyty do celów wirtualnego rozruchu.

## 4.2 Wahadło

Układ wahadła ma tylko jedno pobudzenie w chwili zero (*Rysunek 4.9*), wskutek czego rezygnuje się w tym przypadku z badania korelacji pomiędzy zmiennymi. Ze względu na występowanie gasnących oscylacji nie przeprowadza się badania na obecność wartości odstających.



Rysunek 4.9: Dane pomiarowe uzyskane dla wahadła.

- **Badanie stacjonarności szeregu czasowego**


W celu zbadania stacjonarności szeregu czasowego przeprowadzono rozszerzony test Dickeya-Fullera i otrzymano następujące wyniki:

- wartość statystyki testowej: -15,81
- p-wartość: 0,01

co dowodzi, że szereg jest stacjonarny.

- **Badanie sezonowości szeregu czasowego**


Analizując *Rysunek 4.10* można zauważyć, że amplituda sezonowości jest stała, niezmienna w czasie, a trend ma charakter malejący, a część resztkowa odzwierciedla przypadkowe wahania szeregu czasowego.



Rysunek 4.10: Wynik dekompozycji szeregu czasowego.

- **Wybór typu modelu i dobór parametrów modelu**


Analizując wykresy ACF i PACF można zauważyć, że wartości ACF oscylują i maleją do zera wraz ze wzrostem opóźnień, a na wykresie PACF (*Rysunek 4.12*) widoczny jest duży pik przy opóźnieniu nr 1, który powoli maleje w kolejnych opóźnieniach.



Rysunek 4.11: Korelogram kąta nachylenia wahadła (ACF).




Wartość znaczącą obserwuje się przy opóźnieniu równym 9, więc  $p = 9$  (*Rysunek 4.12*). Okres ( $T$ ) jest równy 21. W wyniku przeprowadzonej analizy otrzymano model **ARMA(21, 9)**.



Rysunek 4.12: Funkcja korelacji cząstkowej kąta nachylenia wahadła.

Na wykresach opóźnień zauważa się wzór liniowy (*Rysunek 4.13*).




Rysunek 4.13: Wykres opóźnień (ang. *lag*).

W *Tabeli 4.2* przedstawiono wartości parametrów modelu ARMA dobrane za pomocą sieci neuronowej.

Tabela 4.2: Parametry modelu ARMA.

$\theta_0$	$\theta_1$	$\theta_2$	$\theta_3$	$\theta_4$
1,7866	2,1347	1,6203	0,4141	-0,9352
$\theta_5$	$\theta_6$	$\theta_7$	$\theta_8$	$\phi_0$
-1,8297	-1,8928	-1,3203	-0,5412	-1,1606
$\phi_1$	$\phi_2$	$\phi_3$	$\phi_4$	$\phi_5$
-0,9235	-0,2579	0,4508	0,7901	0,6604
$\phi_6$	$\phi_7$	$\phi_8$	$\phi_9$	$\phi_{10}$
0,1718	-0,2914	-0,5046	-0,5451	-0,4505
$\phi_{11}$	$\phi_{12}$	$\phi_{13}$	$\phi_{14}$	$\phi_{15}$
-0,7269	-0,7185	-0,2921	0,2642	0,6436
$\phi_{16}$	$\phi_{17}$	$\phi_{18}$	$\phi_{19}$	$\phi_{20}$
0,5898	0,3552	-0,0289	-0,1910	-0,1866

Na *Rysunku 4.14* przedstawiono dopasowanie modelu do wartości rzeczywistych układu wahadła.




Rysunek 4.14: Wahadło.

- **Współczynnik  $VCMF$**

Następnie obliczono wartość współczynnika  $VCMF$  dla układu, która jest równa 65,5%. Jest to wartość większa od wartości progu odcięcia, która pozwala zaklasyfikować modele jako dobre i złe, więc model może zostać użyty na cele wirtualnego rozruchu.

### 4.3 Przenośnik paskowy


Dane pochodzące z obiektu przemysłowego będącego przenośnikiem paskowym podane analizie i wstępnemu przetwarzaniu. Na *Rysunku 4.15* przedstawiono przebiegi czasowe prądu, prędkości oraz momentu obrotowego przenośnika paskowego. Modelowania dokonano dla konkretnego punktu pracy.



Rysunek 4.15: Przebiegi czasowe dla prądu, prędkości oraz momentu obrotowego w trakcie normalnej pracy.

- **Usunięcie wartości odstających**

W celu sprawdzenia, czy w danych występują wartości odstające wykonano wykresy pudełkowe.



Rysunek 4.16: Wykresy pudełkowe dla prądu, prędkości oraz momentu obrotowego, *rozmiar próbki = 500*.

Analizując *Rysunek 4.16* można zauważyć, iż wykresy pudełkowe dla poszczególnych próbek znajdują się w tym zakresie oraz są widoczne różnice w wartości median. Zatem można stwierdzić, że istnieją różnice pomiędzy poszczególnymi próbkami. Mediany prądu oraz prędkości są podobne. Pudełka są wysokie, co wskazuje na większą zmienność danych w próbce. Maksymalna wartość prądu jest równa trzeciemu kwartyłowi ( $Q_3$ ), co oznacza, że średnia wartość pomiędzy medianą a największą wartością jest równa wartości maksymalnej. **W danych nie występują wartości odstające.**

- **Badanie rozkładu normalnego danych**

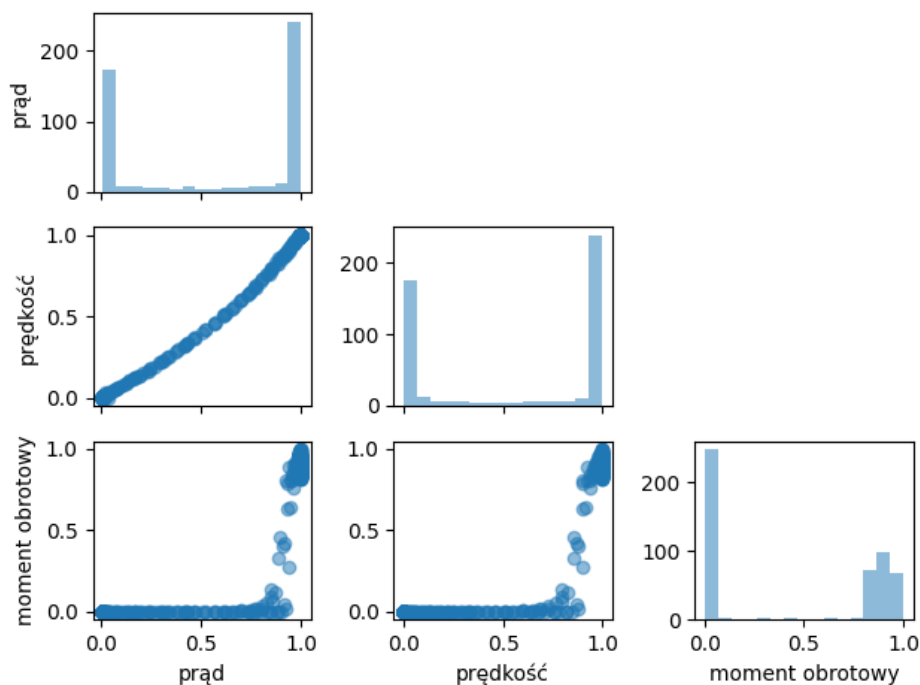
Za pomocą testu Shapiro-Wilka sprawdzono hipotezę, czy dana próbka pochodzi z rozkładu normalnego o nieznanym średniej i nieznanym wariancji [95] [97]. Na podstawie wyników przedstawionych w *Tabeli 4.3* można zauważyć, iż danych nie cechuje rozkład normalny (otrzymane  $p$ -wartości dla każdej zmiennej są mniejsze od 0,05).

Tabela 4.3: Wyniki testu Shapiro-Wilka.

	p-wartość
prąd	$1,39 * 10^{-28}$
prędkość	$1,93 * 10^{-28}$
moment obrotowy	$4,37 * 10^{-29}$

- **Badanie zależności pomiędzy zmiennymi**


Na *Rysunku 4.17* przedstawiono zależności pomiędzy zmiennymi.



Rysunek 4.17: Wykres zależności prądu, prędkości i momentu obrotowego.

Analizując powyższe wykresy można zauważyć, iż **zależności pomiędzy zmiennymi mają charakter monotoniczny**. W poprzednim punkcie zostało również sprawdzone, że dane nie pochodzą z rozkładu normalnego. Implikuje to sposób przeprowadzania dalszych etapów analizy - wyboru współczynnika korelacji. Wykres prądu w funkcji prędkości jest zbliżony do wykresu liniowego, wykres prądu / prędkości w funkcji momentu obrotowego jest nieliniowy. W nawiązaniu do powyższej analizy wykresów, do wyznaczenia korelacji pomiędzy zmiennymi należy użyć korelacji rangowej Spearmana.

Analizując mapę cieplną korelacji cech (*Rysunek 4.18*) można zauważyć, iż pomiędzy sygnałami prądu, prędkości i momentu obrotowego występuje silna zależność. Wartość współczynnika korelacji dla prądu i prędkości jest równa 0,9, co oznacza bardzo silną zależność - wraz ze wzrostem wartości prądu, rośnie wartość prędkości. Moment obrotowy cechuje ta sama wartość korelacji z prądem oraz z prędkością równa 0,83 (silna korelacja). Najniższą wartością korelacji cechuje się moment obrotowy z prądem (0,75), co oznacza silną korelację [119].



Rysunek 4.18: Mapa cieplna korelacji rangowej Spearmana pomiędzy zmiennymi.

Na podstawie wartości współczynnika korelacji rangowej Spearmana pomiędzy poszczególnymi zmiennymi wnioskujemy, że wystarczy utworzyć dwa modele ze względu na dużą redundancję zmiennych reprezentujących prąd oraz prędkość:

$$\text{prąd} = f(\text{prędkości})$$

$$\text{momentObrotowy} = f(\text{prędkości})$$

- **Badanie stacjonarności szeregu czasowego**

W celu określenia stacjonarności szeregu czasowego wykonano rozszerzony test Dickeya-Fullera, którego wyniki przedstawiono w Tabeli 4.4.


Tabela 4.4: Wyniki rozszerzonego testu Dickeya-Fullera.

	wartość statystyki testowej	p-wartość
prąd	-3,03	0,03
prędkość	-2,82	0,06
moment obrotowy	-2,50	0,12

Można zauważyć, iż jedynie **przebieg czasowy prądu jest stacjonarny** ( $p$ -wartość  $< 0,05$ ), a **przebiegi czasowe prędkości i momentu obrotowego są niestacjonarne**, ponieważ  $p$ -wartość  $> 0,05$ .

- **Badanie sezonowości szeregu czasowego**


Kolejnym ważnym aspektem jest analiza danych pod kątem występowania w nich składowej sezonowej. W tym celu dokonano addytywnej dekompozycji szeregu czasowego. Analizując *Rysunek 4.19* można zauważyć, iż część resztkowa pokazuje cyklicznie pojawiające się okresy o dużej zmienności. Trend cechuje się monotoniczną zmiennością. **Sezonowość nie zmienia się w czasie, jej amplituda jest stała, dlatego nie trzeba usuwać z szeregu składowej sezonowej.**



Rysunek 4.19: Wynik dekompozycji szeregu czasowego.


- **Wybór typu modelu i dobór parametrów modelu**

Funkcję autokorelacji prądu cechuje tendencja spadkowa - spadek jest szybki i nie ma wyraźnego punktu odcięcia (*Rysunek 4.20*).



Rysunek 4.20: Korelogram prądu (ACF).


Analizując funkcję korelacji cząstkowej można zauważyć, iż dla prądu (*Rysunek 4.21*) widoczny jest duży skok przy opóźnieniu nr 1, zmniejszający się w kolejnych opóźnieniach, co wskazuje na występowanie ruchomej średniej w danych. Występowanie kilku autokorelacji istotnie niezerowych świadczy o tym, że szereg czasowy nie jest losowy.



Rysunek 4.21: Funkcja korelacji cząstkowej prądu (PACF).



Na podstawie liczby opóźnień znajdujących się poza przedziałem ufności (oraz opóźnienia nr 1 będącego autokorelacją) wyznaczono stopnie wielomianów modelu:  $p = 5$ ,  $q = 10$ .



Rysunek 4.22: Wykres opóźnień (ang. *lag*) dla prądu.


Zbadano również, czy w danych pomiarowych istnieje nieliniowość. W tym celu wykonano wykresy opóźnień (wykresy punktowe szeregu czasowego względem opóźnienia), które pozwalają określić, czy dane są liniowo rozdzielne. Na *Rysunku 4.22* można zauważyć, iż otrzymanych punktów nie da się przybliżyć regresją liniową, co wskazuje na nieliniowość.

Biorąc pod uwagę powyższe wnioski, stworzono model **NARMAX**. Z uwzględnieniem stopni wielomianów jest to  $\text{NAR}(5)\text{MA}(10)\text{X}$ . W *Tabeli 4.5* przedstawiono wartości parametrów modelu dobrane za pomocą sieci neuronowych.

Tabela 4.5: Parametry modelu NARMAX.


$\theta_0$	$\theta_1$	$\theta_2$	$\theta_3$	$\theta_4$
0,2837	0,3603	0,5901	0,3791	0,3782
$\theta_5$	$\theta_6$	$\theta_7$	$\theta_8$	$\theta_9$
0,4519	0,3274	0,1720	0,1812	0,0861
$\phi_0$	$\phi_1$	$\phi_2$	$\phi_3$	$\phi_4$
1,1886	-0,1155	-0,4539	0,3704	-0,1294

Funkcja autokorelacji momentu obrotowego maleje wykładniczo do zera (*Rysunek 4.23*).



Rysunek 4.23: Korelogram momentu obrotowego (ACF).


Funkcja częściowej korelacji momentu obrotowego dąży do zera (*Rysunek 4.24*), po opóźnieniu nr 3 następuje ostre odcięcie. Dlatego też stopień wielomianu  $p = 3$ .



Rysunek 4.24: Funkcja korelacji cząstkowej momentu obrotowego (PACF).

Na *Rysunku 4.24* obserwuje się istotne korelacje w pierwszym, drugim i trzecim opóźnieniu, po których występują nieznaczące korelacje (statystycznie bliskie zero), co wskazuje na istnienie składowej autoregresyjnej. Opóźnienie nr 2 i 3 cechuje się dużą wartością autokorelacji [110].

Na wykresie opóźnień (*Rysunek 4.25*) nie obserwuje się nieliniowości. Wobec powyższych wniosków skonstruowano model **ARX** (z uwzględnieniem rzędu modelu: AR(3)X).



Rysunek 4.25: Wykres opóźnień (ang. *lag*) dla momentu obrotowego.


W *Tabeli 4.6* przedstawiono wartości parametrów modelu dobrane za pomocą sieci neuronowych.

Tabela 4.6: Parametry modelu ARX.

$\phi_0$	$\phi_1$	$\phi_2$
1,4975	-0,6484	0,0698

Po etapie przetwarzania wstępnego danych skonstruowano dwa modele matematyczne przenośnika paskowego (model typu *Grey Box*) o jednym wejściu i jednym wyjściu (*SISO*, ang. *Single Input Single Output*): (prędkość, prąd) oraz (prędkość, moment obrotowy). Biorąc pod uwagę wnioski płynące z analizy funkcji korelacji cząstkowej (uwzględnienie średniej ruchomej oraz składowej autoregresyjnej i nieliniowości) skonstruowano **model NARMAX dla prądu** oraz **ARX dla momentu obrotowego**.

Na *Rysunku 4.26* można zaobserwować dobre pokrycie wartości przewidywanych przez obydwie modele (prądu i momentu obrotowego) z danymi rzeczywistymi.



Rysunek 4.26: Porównanie dopasowania modeli do danych rzeczywistych.

- **Współczynnik  $VCMF$**

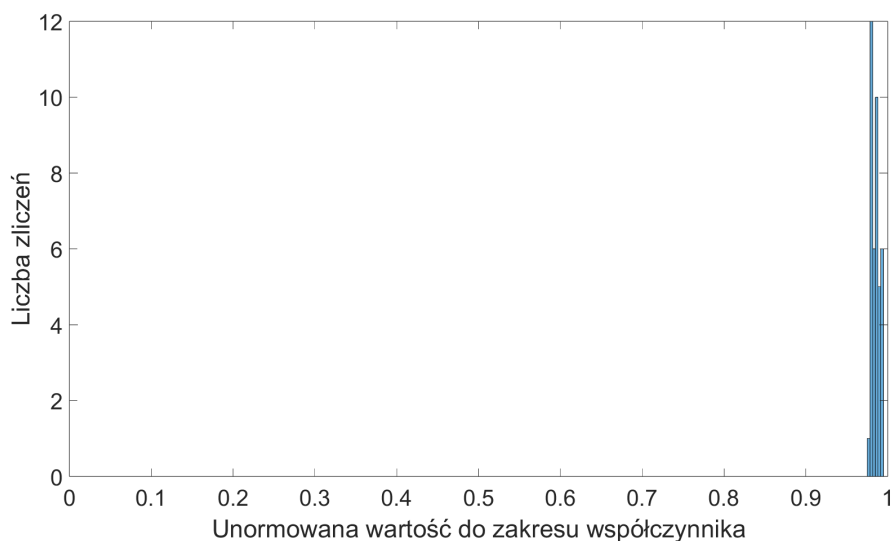
Współczynnik  $VCMF$  przyporządkował 20 z 20 modeli z grupy DOBRE jako modele dobrze dopasowane do danych rzeczywistych. Natomiast 18 z 20 modeli z grupy ZŁE przyporządkował prawidłowo, a 2 modele zostały przyporządkowane błędnie.

# Rozdział 5

## Dyskusja

W niniejszym rozdziale przeprowadzono dyskusję zalet oraz ograniczeń zaproponowanej metody do oceny jakości modelu na cele wirtualnego rozruchu - współczynnika *VCMF*.

Otrzymane wyniki, które zaprezentowano w *Rozdziale 4* udowodniły, że zaproponowany współczynnik umożliwia lepszą ocenę jakości modelu w porównaniu z przytoczonymi miarami oceny jakości modelu z tego względu, iż zakres przyjmowanych przez niego wartości jest szeroki, co umożliwia zróżnicowanie na grupy modeli o dobrym dopasowaniu do rzeczywistych danych pomiarowych oraz o złym dopasowaniu. Przykładem może być analiza rozkładu wyników otrzymanych za pomocą miary *MIA* oraz *VCMF* dla przenośnika paskowego.




Rysunek 5.1: Histogram MIA.

Analizując histogram miary *MIA* (*Rysunek 5.1*) można zauważyć, iż pomimo tego,

że współczynnik jest w stanie zróżnicować między sobą dwie grupy, to jednak uwzględniając cały zakres wartości przyjmowanych przez tę miarę (0 - 1), wszystkie wyniki są skupione blisko wartości maksymalnej (równej 1), co powoduje brak rozrzutu wyników w całym zakresie, a o przynależności do grupy *DOBRA* lub *ZŁA* decydują niewielkie zmiany wartości miary. Jest to jedna z typowych wad miary MIA, co zostało opisane w [65] (relatywnie duże wartości są przypisywane modelom o słabej jakości dopasowania).

Natomiast histogram współczynnika *VCMF* (Rysunek 5.2) pokazuje, że zaproponowany współczynnik *VCMF* nie posiada wyżej opisanej wady.



Rysunek 5.2: Histogram *VCMF*.

Dla modeli przenośnika paskowego (opisanych w *Rozdziale 3.1*) obliczono wartości miar opisanych w *Rozdziale 2.2* oraz współczynnika jakości *VCMF*. Przykładowe wyniki zostały przedstawione dla jednego modelu dobrego i jednego złego w *Tabeli 5.1*. Do porównania nie wzięto pod uwagę miary *FE* z tego względu, iż jest to wektor wartości.

Tabela 5.1: Przykładowe wyniki dla modelu DOBREGO i ZŁEGO.

nazwa współczynnika	DOBRY	ZŁY
MFE	-0,00256	-0,00320
MSE	$1,01487 * 10^{-5}$	$1,42476 * 10^{-5}$
RMSE	0,00319	0,00377
NRMSE	0,01127	0,01338
RRSE	0,02880	0,03594
MSLE	$7,37715 * 10^{-6}$	$9,86277 * 10^{-6}$
MAE	0,00258	0,00322
MSLE	$7,37715 * 10^{-6}$	$9,862773 * 10^{-6}$
MedAE	0,002514	0,003256
MedAE	0,002514	0,003256
EVS	0,99970	0,99963
sMAPE	12,35637	7,58459
ME	-0,00256	-0,00320
$R^2$	0,99978	0,99971
MIA	0,98702	0,98274
RIA	0,98748	0,98820
PPMCC	0,99989	0,99986
VCMF	82,90642	26,01790

Dla każdej miary oraz współczynnika *VCMF* przeprowadzono test nieparametryczny Wilcoxon - sumy rang, ponieważ jak opisano w *Rozdziale 4.3*, dane nie pochodzą z rozkładu normalnego [120].

Hipoteza zerowa ( $H_0$ ): dane z dwóch grup (*DOBRA* oraz *ZŁA*) pochodzą z rozkładu ciągłego i ich mediany są równe [121].

Hipoteza alternatywna ( $H_1$ ): dane z dwóch grup (*DOBRA* oraz *ZŁA*) nie pochodzą z rozkładu ciągłego, a ich mediany nie są równe [121].

Tabela 5.2: Wyniki testu Wilcoxona.


nazwa współczynnika	$p$ -wartość	$H_0$ odrzucić? (1 - tak, 0 - nie)
<b>VCMF</b>	$2,95975 * 10^{-7}$	1
MIA	$3,41558 * 10^{-7}$	1
MAE	$3,93881 * 10^{-7}$	1
MedAE	$7,94795 * 10^{-7}$	1
EVS	$1,20089 * 10^{-6}$	1
PPMCC	$1,37606 * 10^{-6}$	1
sMAPE	$2,06159 * 10^{-6}$	1
MFE	$3,06910 * 10^{-6}$	1
RRSE	$3,06910 * 10^{-6}$	1
MSE	$3,98735 * 10^{-6}$	1
RMSE	$3,98735 * 10^{-6}$	1
NRMSE	$4,54007 * 10^{-6}$	1
RIA	$0,28530 * 10^{-6}$	0
ME	$0,40935 * 10^{-6}$	0
MSLE	$6,67365 * 10^{-6}$	0
$R^2$	$1,37606 * 10^{-6}$	0

Analizując wyniki testu Wilcoxona przedstawione w Tabeli 5.2 dla miar *RIA*, *ME*, *MSLE* oraz  $R^2$   $p$ -wartości przyjmują wartości większe od poziomu istotności (0,05) co oznacza, że różnice między medianami dwóch grup nie są znacząco różne, wskutek czego nie odrzuca się hipotezy zerowej. Wynik ten pokazuje, że wskazane miary nie są w stanie zróżnicować grup, dlatego też nie są informatywne, ponieważ nie mogą odróżnić modelu dobrego od złego. Z kolei dla miar takich jak **VCMF**, *MIA*, *MAE*, *MedAE*, *EVS*, *PPMCC*, *sMAPE*, *MFE*, *RRSE*, *MSE*, *RMSE* i *NRMSE*  $p$ -wartości



są mniejsze od założonego przedziału ufności (0,05), co oznacza, że różnica pomiędzy medianami dwóch grup jest znacząca i należy odrzucić hipotezę zerową. Im mniejsza  $p$ -wartość, tym dwie grupy są bardziej zróżnicowane. Oznacza to, że miary potrafią zróżnicować dane na dwie grupy.


Dodatkowo przeprowadzono analizę informacji zawartych na wykresach pudełkowych unormowanych miar ( $NRMSE$ ,  $sMAPE$ ,  $PPMCC$ ,  $MIA$ ,  $RIA$ ,  $VCMF$ ).



Rysunek 5.3: Wykres pudełkowy dla grupy złych modeli.

*Rysunek 5.3* przedstawia wykresy pudełkowe dla grupy źle dopasowanych modeli (grupa *ZŁA*). Analizując otrzymane wykresy można zauważyć, iż  $NRMSE$  i  $VCMF$  oraz  $MIA$  i  $RIA$  mają podobne wartości mediany. Jedynie pudełko  $VCMF$  jest wysokie, co świadczy o większej zmienności wyników aniżeli mają pozostałe miary mające niskie pudełka.

Analizując *Rysunek 5.4* dla grupy dobrze dopasowanych modeli (grupa *DOBRA*) można zauważyć, że pudełko  $VCMF$  zmieniło swoje położenie w stosunku do położenia, jakie zajmowało dla grupy źle dopasowanych modeli (*Rysunek 5.3*). Porównując położenia pudełek dla różnych grup można zaobserwować, iż jedynie  $VCMF$  bardzo mocno różnicuje wyniki pomiędzy grupami, wartość mediany to dla grupy *DOBRA* jest poniżej 0,1, a dla grupy *ZŁA* jest powyżej 0,9.



Rysunek 5.4: Wykres pudełkowy dla grupy dobrych modeli.

Analizie poddano jeden przypadek dobrego dopasowania modelu do grupy *ZŁA* oraz dwa przypadki błędnego przyporządkowania modelu do grupy *ZŁA* przez współczynnik *VCMF*.


Tabela 5.3: Wyniki poszczególnych miar dla modelu dobrze przyporządkowanego oraz dla dwóch źle przyporządkowanych do grupy *ZŁA*.

<b>NRMSE</b>	<b>ME</b>	<b>MAE</b>	<b>MIA</b>	<b>VCMF</b>
0,01640	3,47620	0,00380	0,97930	0,00000
0,01060	5,26970	0,00240	0,98710	84,39650
0,01190	2,67250	0,00270	0,98610	80,60220

W Tabeli 5.3 przedstawiono wartości poszczególnych miar wchodzących w skład systemu rozmytego *VCMF*. Pierwszy wiersz zawiera wyniki otrzymane dla przypadku, w którym współczynnik *VCMF* przyporządkował model do grupy *ZŁA* prawidłowo. W drugim i trzecim wierszu przedstawione są wyniki *VCMF*, które zostały nieprawidłowo przyporządkowane do grupy *ZŁA*. Analizując wspomniane dwa wiersze można zauważyć, iż wpływ na przyporządkowanie miała miara *MAE*. W stworzonym systemie wnioskowania rozmytego, funkcja przynależności *MAE* ma bardzo stromy przebieg, co implikuje pojawienie się małej różnicy pomiędzy grupą *DOBRA* a *ZŁA*. Ponadto

w modelach, które należą do grupy *DOBRA* znajdują się modele, dla których wartość *MAE* jest mniejsza od 0,00300 i jednocześnie większa od 0,00270. W celu poprawy jakości współczynnika *VCMF* należałoby zmodyfikować kształt funkcji przynależności, co jednak spowoduje, że w grupie *DOBRA* znajdują się nieprawidłowo przyporządkowane modele.

Jedną z dodatkowych możliwości (poza oceną modelu) może być wykorzystanie współczynnika *VCMF* do automatycznej detekcji sytuacji awaryjnych. Przykładem takiego wykorzystania może być linia automatycznego transportu. W skład takiej linii najczęściej wchodzi falowniki oraz silniki jednego producenta. Takich zestawów w dużej linii transportowej jest kilkadziesiąt. Dział utrzymania ruchu najczęściej dowiaduje się o wystąpieniu sytuacji awaryjnej w momencie zatrzymania linii transportowej. Często występującymi sytuacjami awaryjnymi na takiej linii produkcyjnej są: zakleszczenie transportowanego materiału, zużycie łożysk. Przy konfiguracji zakładającej utrzymanie stałej prędkości przez falowniki, obie sytuacje skutkują zwiększeniem momentu obrotowego i prądu. Wykorzystując technologię *DT* można za pomocą modelu nieustannie porównywać wyjście modelu z wyjściem obiektu rzeczywistego. Do porównania można użyć współczynnika *VCMF*. Jeżeli wartość współczynnika *VCMF* obniży się poniżej progu odcięcia wyznaczonego za pomocą dekompozycji *GMM* można automatycznie wysłać powiadomienia do działu utrzymania ruchu, aby skontrolował dany odcinek linii transportowej.



Rysunek 5.5: Dopasowanie modelu do danych rzeczywistych w sytuacji awaryjnej.

Na *Rysunku 5.5* przedstawiono fragment danych pomiarowych zebranych podczas pracy przenośnika paskowego, na którym widoczne są anomalia pracy. Wartość współczynnika *VCMF* wyniosła 49,4 % (poniżej progu odcięcia równego 64,6 %). Oznacza to, że współczynnik *VCMF* pozwala na szybkie wykrycie sytuacji awaryjnej.

# Rozdział 6

## Podsumowanie

Niniejsza praca doktorska przedstawia zagadnienie związane z metodami oceny jakości modelu na potrzeby wirtualnego rozruchu systemów automatyki przemysłowej. Pierwszym celem pracy było przedstawienie aktualnie istniejących wyzwań i perspektyw w dziedzinie oceny jakości modelu przy uwzględnieniu jego zastosowania na cele wirtualnego uruchomienia. Przedstawiona rozprawa doktorska porusza zagadnienia związane z oceną przydatności modelu na cele użycia w nowych technikach symulacji, wprowadzając elementy analizy szeregów czasowych, modelowania, systemów wnioskowania rozmytego oraz statystycznej analizy danych od samego początku procesu, w którym dane zostają pozyskane z obiektu przemysłowego. W *Rozdziale 2.1* nowe techniki symulacji zostały w gruntowny sposób opisane, z uwzględnieniem najnowszej wiedzy w tej dziedzinie automatyki przemysłowej. Natomiast w *Rozdziale 2.2* opisano niezbędną wiedzę na temat powszechnie wykorzystywanych miar do oceny jakości modelu. Ze względu na wysoką specyficzną model (ważnych jego aspektów z punktu widzenia wirtualnego rozruchu) oraz nieustannie rozwijającej się wiedzy eksperckiej z zakresu wirtualnego rozruchu systemów automatyki przemysłowej zaproponowano własną metodologię przetwarzania danych otrzymanych z obiektu przemysłowego aż do stworzenia modelu i oceny jego jakości. Kluczowym elementem pracy jest stworzenie współczynnika jakości oceny modelu *VCMF* opartego na systemie wnioskowania rozmytego Takagi-Sugeno-Kanga.

W celu zapewnienia dobrej jakości danych pomiarowych zebranych z obiektu przemysłowego (przenośnika paskowego), a także danych symulacyjnych (kaskadowy układ zbiorników, wahadło klasyczne) zaproponowano proces przetwarzania wstępnego i analizy danych. Etapy oparte były na analizie statystycznej i badaniu własności szeregów czasowych i doprowadziły do wyboru modelu. Jednakże główną wartością dodaną niniejszej pracy, będącą zarazem jej drugim celem, jest zaproponowanie metody do oceny

jakości modelu opartej na systemie wnioskowania rozmytego (współczynnik  $VCMF$ ). Miara ta pozwala na zagregowanie informacji niesionych przez różne miary jakości modelu, a także zastosowanie wiedzy eksperckiej z zakresu wirtualnego uruchomienia dzięki zastosowaniu systemu wnioskowania rozmytego. Dodatkowo przebadany został sposób doboru funkcji przynależności za pomocą algorytmów optymalizacji, co wskazuje na interdyscyplinarność wypracowanej metody. W wyniku takiego podejścia uwiadcza się atut zaproponowanej metodologii oceny jakości modelu w postaci elastyczności i możliwości nieustannej adaptacji do ciągle zmieniających się wymagań przemysłu, rozwijających się technik symulacji i nowej wiedzy eksperckiej z zakresu modelowania. Ponadto zdefiniowanie progu odcięcia, powyżej którego wartości przyjmowane przez współczynnik  $VCMF$  oznaczają model dobrze odwzorowujący dane rzeczywiste, który może zostać wykorzystany w procesie wirtualnego uruchomienia, zostało oparte na modelowaniu mieszanin Gaussowskich. Dla danych pomiarowych zebranych podczas pracy przenośnika paskowego współczynnik  $VCMF$  20 z 20 modeli przyporządkował jako modele o dobrym dopasowaniu, natomiast 18 z 20 modeli zaklasyfikował jako modele o niepoprawnym dopasowaniu. Analiza otrzymanych wyników pozwala stwierdzić, iż zaproponowany współczynnik jakości  $VCMF$  pozwala na różnicowanie modeli na modele dobre z punktu wirtualnego uruchomienia oraz niepoprawne, a przyjmowane przez niego wartości cechują się szerokim zakresem, co pozwala na otrzymanie zróżnicowanych wyników. Modele oceniane jako dobre w dziedzinie wirtualnego rozruchu cechują się wiernym odwzorowaniem zachowania obiektu rzeczywistego (reagowaniem na sygnały sterujące) z błędem dopuszczalnym określonym przy użyciu dekompozycji histogramu otrzymanych wartości współczynnika  $VCMF$  za pomocą mieszanin Gaussowskich ( $GMM$ ). Dodatkowo działanie współczynnika  $VCMF$  zostało również przetestowane na danych pochodzących z obiektów innego typu - dwóch zbiorników w układzie kaskadowym oraz wahadła. Pokazuje to, iż niniejszy współczynnik  $VCMF$  jest uniwersalny i może być stosowany do różnych rodzajów układów automatyki przemysłowej. Zaproponowana metoda cechuje się dużym potencjałem adaptacyjnym do nieustannie ewoluującej wiedzy z zakresu wirtualnego uruchomienia systemów automatyki przemysłowej.

Zaproponowana w niniejszej pracy metodologia oceny jakości modelu na cele wirtualnego rozruchu cechuje się połączeniem wiedzy z różnych dziedzin nauki, takich jak statystyka i metody analizy danych, analiza szeregów czasowych, systemy rozmyte, algorytmy optymalizacji, metody identyfikacji modeli oraz wiedzy eksperckiej i aktualnych doniesień literaturowych z zakresu wirtualnego rozruchu systemów automatyki przemysłowej. Metoda ta może być stosowana w wirtualnym rozruchu systemów

automatyki przemysłowej, realizowanego podczas przebudowy istniejącej linii produkcyjnej, a także na potrzeby szkolenia operatorów. Wartością dodaną niniejszej pracy jest również fakt, iż zaproponowany współczynnik  $VCMF$  może służyć do szybkiego wykrywania sytuacji awaryjnych.





# Rozdział 7

## Streszczenie

Nowoczesne linie produkcyjne stają się coraz bardziej złożone, co przekłada się na konieczność szybkiego testowania i walidacji systemów automatyki przemysłowej. Odpowiedzią na takie zapotrzebowanie jest wykorzystanie technik symulacji, takich jak wirtualne uruchomienie (zwane również wirtualnym rozruchem), które już na wczesnym etapie przebudowy linii produkcyjnej pozwala na analizę działania różnych podzespołów oraz identyfikację wąskich gardeł całego procesu produkcyjnego. Dodatkowo wirtualne uruchomienie jest coraz częściej wykorzystywane do szkolenia operatorów linii produkcyjnych.

Ważnym etapem wirtualnego uruchomienia jest weryfikacja jakości modelu matematycznego uruchamianego obiektu. Do oceny jakości modelu są stosowane różne miary, jednak każda z nich cechuje się różnym zakresem przyjmowanych wartości oraz interpretacją. Wskutek tego, wybór najbardziej adekwatnej miary do oceny jakości modelu nie jest rzeczą łatwą, a czasem informacje niesione przez kilka miar byłyby potrzebne do całościowej oceny jakości modelu. Dodatkowo, prace naukowe z 2022 roku o tematyce wirtualnego uruchomienia wskazują, iż istnieje potrzeba określenia jakości modelu.

W niniejszej pracy usystematyzowano wiedzę na temat powszechnie stosowanych miar do oceny jakości modelu. Ponadto stworzony został system rozmyty Takagi-Sugeno-Kanga do oceny jakości modelu (*VCMF*, ang. *Virtual-Commissioning-Fuzzy coefficient*), który pozwala na zagregowanie informacji niesionych przez różne miary, a także dynamiczną rozbudowę dzięki możliwości zastosowania wiedzy eksperckiej z zakresu wirtualnego rozruchu systemów automatyki przemysłowej. Zaproponowany współczynnik został przetestowany na danych pomiarowych zebranych podczas pracy przenośnika paskowego, które zostały poddane procesowi przetwarzania wstępnego z użyciem różnych metod statystycznej analizy danych oraz na danych symulacyjnych układu

kaskadowego dwóch zbiorników i wahadła. Współczynnik  $VCMF$  pozwolił na przyporządkowanie modeli do grupy modeli dobrze dopasowanych do danych oraz grupy niepoprawnie przyporządkowanych. Próg odcięcia, poniżej którego modele uznaje się za modele o zbyt niskiej jakości na potrzeby wirtualnego uruchomienia, został wybrany za pomocą modelowania mieszanin Gaussowskich (ang. *GMM*). Otrzymane wyniki zostały zanalizowane i porównane z opisanymi miarami powszechnie stosowanymi do oceny jakości modeli.

# Rozdział 8

## Abstract

The complexity of modern plants is continuously growing, which leads to the necessity of rapid testing and validation of industrial automation systems. The answer to this demand is the use of simulation techniques, such as virtual commissioning, which at an early stage of the production line reconstruction, allows for analyzing the operation of various components and identifying bottlenecks of the entire production process. In addition, virtual commissioning is increasingly used to train production line operators.

One of the crucial stages of virtual commissioning is verifying the quality of the mathematical model of the commissioned object. A plethora of measures are used to assess the quality of the model, but each of them is characterized by a different range of values and interpretations. As a result, selecting the adequate measure to assess model quality takes work, and sometimes the information carried by several measures would be needed to assess the overall quality of the model. In addition, scientific articles from 2022 on the subject of virtual commissioning indicate that there is a need to determine the quality of the model.

This work systematizes the knowledge about commonly used measures to assess the quality of the model. In addition, the Takagi-Sugeno-Kang fuzzy system was created to evaluate the quality of the model (*VCMF*, *Virtual-Commissioning-Fuzzy coefficient*), which allows for the aggregation of information carried by various measures, as well as dynamic expansion thanks to the possibility of using expert knowledge in the field of virtual commissioning of industrial automation systems. The proposed coefficient was tested on measurement data collected during the belt conveyor operation, which was subjected to the pre-processing process using various statistical data analysis methods and on two simulated datasets: two tank system and classical pendulum. The *VCMF* coefficient allowed the models to be assigned to a group of models well matched to the data and a group of incorrectly assigned ones. The cut-off threshold below which

models are considered too low quality for the virtual commissioning was selected using Gaussian Mixture Modeling (*GMM*). The obtained results were analyzed and compared with the described measures commonly used to assess the quality of models.

# Bibliografia

- [1] Digital Science. Dimensions [Software]. `app.dimensions.ai`, 2018. Dostęp: 2023-07-11.
- [2] M. Oppelt, G. Wolf, O. Drumm, B. Lutz, M. Stöß, L. Urbas. Automatic Model Generation for Virtual Commissioning based on Plant Engineering Data. W *IFAC Proceedings Volumes*, 47, 11635–11640, 2014.
- [3] I. Viedt, J. Maedler, V. Khaydarov, L. Urbas. Prescriptive and descriptive quality metrics for the quality assessment of operational data. W *INFORMATIK 2022, Lecture Notes in Informatics (LNI)*, 1061, 2022.
- [4] I. Viedt, J. Maedler, J. Lorenz, L. Urbas. Requirements for the quality assessment of virtual commissioning models for modular process plants. W *Proceedings of the 14th International Symposium on Process Systems Engineering - PSE 2021+*, 1, 2022.
- [5] M. Segovia, J. Garcia-Alfaro. Design, Modeling and Implementation of Digital Twins. *Sensors (Basel)*, 22(14:5396), 2022.
- [6] Jan Chojcan, Jacek Łęski. *Zbiory rozmyte i ich zastosowania*. Wydawnictwo Politechniki Śląskiej, Gliwice, Polska, 2001.
- [7] S. M. E. Sepasgozar. Differentiating Digital Twin from Digital Shadow: Elucidating a Paradigm Shift to Expedite a Smart, Sustainable Built Environment. *Buildings*, 11(151), 2021.
- [8] E. Oztemel, S. Gursev. A Taxonomy of Industry 4.0 and Related Technologies. In J. Hamilton Ortiz, editor, *Industry 4.0. Current Status and Future Trends*. IntechOpen, 2020.

- [9] G. Chen, P. Wang, B. Feng, Y. Li, D. Liu. The framework design of smart factory in discrete manufacturing industry based on cyber-physical system. *International Journal of Computer Integrated Manufacturing*, 33(1):79–101, 2020.
- [10] A. Ladj, Z. Wang, O. Meski, F. Belkadi, M. Ritou, C. Da Cunha. A knowledge-based digital shadow for matching industry in a digital twin perspective. *Journal of Manufacturing Systems*, 58(B):168–179, 2021.
- [11] **Ł. Glodek**, W. Nocoń, S. Bysko. Nowe technologie symulacji odpowiedzią na potrzeby przemysłu 4.0. W *AUTOMATYZACJA PROCESÓW DYSKRETNYCH. Teoria i zastosowania. Tom I*. Wydawnictwo Politechniki Śląskiej, Gliwice, Polska, 2022.
- [12] N. J. Van Eck, L. Waltman. Software survey: VOSviewer, a computer program for bibliometric mapping. *Scientometrics*, 84(2):523–538, 2010.
- [13] O. Wadhvani, S. Loomba. Digital Twin Market Size By Application (Product Design & Development, Machine & Equipment Health Monitoring, Process Support & Service), By End Use (Manufacturing, Healthcare, Automotive, Aerospace & Defense, Energy & Utility, Infrastructure Buildings, Retail & Consumer Goods), Industry Analysis Report, Regional Outlook, Growth Potential, Competitive Market Share & Forecast, 2021 - 2027. *Scientometrics*, 84(2):523–538, 2021.
- [14] A. Hughes. *Forging the Digital Twin in Discrete Manufacturing: A Vision for Unity in the Virtual and Real Worlds*. LNS Research, Cambridge, USA, 2018.
- [15] MarketsandMarkets Inc. Digital Twin Market by Technology, Type (Product, Process, and System), Application (predictive maintenance, and others), Industry (Aerospace & Defense, Automotive & Transportation, Healthcare, and others), and Geography - Global Forecast to 2026. W *Market Research Report*. MarketsandMarkets Inc., 2020.
- [16] Business Research. INSIGHTS. Virtual Commissioning Market Size, Share, Growth, And Industry Growth By Type (Plant and Process Simulation, Robotics and Automation Simulation, and Others), By Application (Aerospace and Defense, Automotive and Transportation, Machine Manufacturing, Energy and Utilities, and Others), and Regional Forecast to 2028. W *Market Reports*. Business Research. INSIGHTS, 2022.

- [17] P. Bossuyt, C. Raemdonck. Digital process twin - how to implement digital twin solutions for the pharmaceutical industry. Siemens - webinar, 2021.
- [18] Y. Wu, K. Zhang, Y. Zhang. Digital Twin Networks: A Survey. *IEEE Internet of Things Journal*, PP(3):1–1, 2021.
- [19] Simio. [www.simio.com/blog/2021/07/12/virtual-models-digital-shadows-digital-twin-applications-manufacturing](http://www.simio.com/blog/2021/07/12/virtual-models-digital-shadows-digital-twin-applications-manufacturing). Dostęp: 2023-02-23.
- [20] L. Lattanzi, R. Raffaelli, M. Peruzzini, M. Pellicciari. Digital twin for smart manufacturing: a review of concepts towards a practical industrial implementation. *International Journal of Computer Integrated Manufacturing*, 34(3):1–31, 2021.
- [21] Gartner, Inc. Gartner identifies the top 10 strategic technology trends for 2019. [www.gartner.com/en/newsroom/press-releases/2018-10-15-gartner-identifies-the-top-10-strategic-technology-trends-for-2019](http://www.gartner.com/en/newsroom/press-releases/2018-10-15-gartner-identifies-the-top-10-strategic-technology-trends-for-2019). Dostęp: 2023-02-22.
- [22] G. Tsaramirsis, A. Kantaros, I. Al-Darraj, D. Piromalis, C. Apostolopoulos, A. Pavlopoulou, M. Alrammal, Z. Ismail, S. M. Buhari, M. Stojmenovic, H. Tamimi, P. Randhawa, A. Patel, F. Qudus Khan. A Modern Approach towards an Industry 4.0 Model: From Driving Technologies to Management. *Journal of Sensors*, 2022(5023011), 2022.
- [23] A. Fuller, Z. Fan, C. Day, C. Barlow. Digital twin: Enabling Technologies, Challenges and Open Research. *IEEE Access*, 8:108952–108971, 2020.
- [24] A. Ladj, Z. Wang, O. Meski, F. Belkadi, M. Ritou, C. Da Cunha. A knowledge-based Digital Shadow for machine industry in a Digital Twin perspective. *Journal of Manufacturing Systems*, 58(B):168–179, 2021.
- [25] H. van Der Walk, H. Haße, F. Möller, M. Arbter, J.-L. Henning, B. Otto. A taxonomy of digital twins. *W 26th Americas Conference on Information Systems (AMCIS)*, Salt Lake City, USA, 2020.
- [26] M. Schluse, M. Priggemeyer, L. Atorf, J. Romann. Experimentable Digital Twins - Streamlining Simulation-Based Systems Engineering for Industry 4.0. *IEEE Transactions on Industrial Informatics*, 14(4), 2018.

- [27] Y. Lu, C. Liu, K. Wang, H. Huang, X. Xu. Digital Twin-Driven Smart Manufacturing Connotation, Reference Model, Applications and Research Issues. *Robotics and Computer-Integrated Manufacturing*, 61(101837), 2020.
- [28] KUKA Aktiengesellschaft. Hello industrie 4.0 - glossary, 2016.
- [29] FLAIR. [www.hkflair.org/our-programmes/digital-shadows-for-distributed-manufacturing/](http://www.hkflair.org/our-programmes/digital-shadows-for-distributed-manufacturing/). Dostęp: 2023-03-01.
- [30] T. Lechler, E. Fischer, M. Metzner, A. Mayr, J. Franke. Virtual Commissioning - Scientific review and exploratory use cases in advanced production systems. *Procedia CIRP*, 81:1125–1130, 2019.
- [31] G. Wünsch. *DIN 32541:1977-05 Betreiben von Maschinen und vergleichbaren technischen Arbeitsmitteln; Begriffe für Tätigkeiten*. Beuth, Niemcy, 1977.
- [32] G. Wünsch. *Methoden für die virtuelle Inbetriebnahme automatisierter Produktionssysteme*. Herbert Utz Verlag, München, Niemcy, 2008.
- [33] H. G. Baumann, K. H. Looschelders. *Systematisches Projektieren und Konstruieren : Grundlagen und Regeln für Studium und Praxis*. Springer, Heidelberg, Niemcy, 1982.
- [34] M. F. Zäh, F. Grätz, G. Wünsch. *Mechatronik. Trends in der interdisziplinären Entwicklung von Werkzeugmaschinen*, chapter Entwicklung mechatronischer Produktionssysteme - eine interdisziplinäre Herausforderung. Herbert Utz Verlag, München, Niemcy, 2005.
- [35] D. Thapa, C. Mok Park, S. Dangol, G.-N. Wang. III-Phase Verification and Validation of IEC Standard Programmable Logic Controller. W *2006 International Conference on Computational Intelligence for Modelling Control and Automation and International Conference on Intelligent Agents Web Technologies and International Commerce (CIMCA'06)*. CIMCA 2006/IAWTIC 2006, 2006.
- [36] Michael Zäh, M. Spitzweg, U. Munzert, W. Vogel. Realistic machine behaviour in virtual reality. W *Virtual Concept 2005*. Springer, France, 2005.
- [37] J. Brökelmann. *Systematik der virtuellen Inbetriebnahme von automatisierten Produktionssystemen*. Verlagshaus Monsenstein und Vannerdat OHG Druck Buch Verlag, Paderborn, Niemcy, 2014.



- [38] L. C. Krishnan. Using virtual commissioning to reduce commissioning time by 70 percent. [resources.sw.siemens.com/en-US/case-study-wipro-pari](https://resources.sw.siemens.com/en-US/case-study-wipro-pari). Dostęp: 2023-02-20.
- [39] M. Oppelt, G. Wolf, L. Urbas. The Role of Simulation within the Life-Cycle of a Process Plant - Results of a global online survey, 2015.
- [40] Chi G. Lee, Sang C. Park. Survey on the virtual commissioning of manufacturing systems. *Journal of Computational Design and Engineering*, 1:213–222, 2014.
- [41] S. Konstantinov, F. Assad, B. Ahmad, D. Vera, R. Harrison. Virtual Engineering and Commissioning to Support the Lifecycle of a Manufacturing Assembly System. *Machines*, 10(939), 2022.
- [42] M. Schamp, S. Hoedt, A. Claeys, E. H. Aghezzaf, J. Cottyn. Impact of a virtual twin on commissioning time and quality. *IFAC-PapersOnLine*, 51:1047–1052, 2018.
- [43] M. Ko, E. Ahn, S. C. Park. A concurrent design methodology of a production system for virtual commissioning. *Concurrent Engineering Research and Applications*, 21(2):129–140, 2013.
- [44] Australian Bureau of Statistics. Australian and New Zealand Standard Research Classification (ANZSRC). [www.abs.gov.au/statistics/classifications/australian-and-new-zealand-standard-research-classification-anzsrc/latest-release](http://www.abs.gov.au/statistics/classifications/australian-and-new-zealand-standard-research-classification-anzsrc/latest-release), 2020. Dostęp: 2023-07-11.
- [45] M. Noga, M. Juhas, M. Gulan. Hybrid Virtual Commissioning of a Robotic Manipulator with Machine Vision Using a Single Controller. *Sensors*, 22:1621, 2022.
- [46] J. Rosenberger, A. Selig, M. Ristic, M. Bühren, D. Schramm. Virtual Commissioning of Distributed Systems in the Industrial Internet of Things. *Sensors*, 23:3545, 2023.
- [47] E. VanDerHorn, S. Mahadevan. Digital Twin: Generalization, characterization and implementation. *Decision Support Systems*, 145(113524), 2021.
- [48] G. I. Webb, C. Sammut. Mean Squared Error. W *Encyclopedia of Machine Learning*. Springer, Boston, USA, 2011.

- [49] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, E. Duchesnay. Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12:2825–2830, 2011.
- [50] R. J. Hyndman, G. Athanasopoulos. *Forecasting: Principles and Practice*. Texts, Melbourne, Australia, 2021.
- [51] J. Brownlee. *Introduction to Time Series Forecasting with Python: How to Prepare Data and Develop Models to Predict the Future*. MACHINE LEARNING MASTERY, 2020.
- [52] A. H. Baghanam, V. Nourani, K. Shakoori. Long-Term Solid Waste Quantity Prediction Using AI-Based Models, Considering Climate Change Impact - A Case Study. In R. R. Karri, G. Ravindran, M. H. Dehghani, edytor, *Soft Computing Techniques in Solid Waste and Wastewater Management*, 337–348. Elsevier, Boston, USA, 2021.
- [53] M. Shcherbakov, A. Brebels, N. Shcherbakova, A. Tyukov, T. Janovsky, V. Kamaev. A Survey of Forecast Error Measures. *World Applied Sciences Journal 24 (Information Technologies in Modern Industry, Education & Society)*, 171–176, 2013.
- [54] A. Botchkarev. Performance Metrics (Error Measures) in Machine Learning Regression, Forecasting and Prognostics: Properties and Typology. *ArXiv*, 2018.
- [55] S. Kim, H. Kim. A new metric of absolute percentage error for intermittent demand forecasts. *International Journal of Forecasting*, 32(3):669–679, 2016.
- [56] R. Bonnin. *Machine Learning for Developers*. Packt Publishing, 2017.
- [57] J. M. Weiming. *Mastering Python for Finance*. Packt Publishing, Birmingham, Wielka Brytania, 2019.
- [58] J. S. Armstrong. *Long-range Forecasting From Crystal Ball to Computer*. Wiley, 1985.
- [59] F. Westbrink, A. Schwung. Virtual Commissioning Approach based on the Discrete Element Method. W *Proceedings of the 16th International Conference of Industrial Informatics (INDIN)*. IEEE, 2018.

- [60] R. G. Brereton. Degrees-of-freedom, errors, and replicates. *Journal of Chemometrics*, 32, 2018.
- [61] D. Chikko, M. J. Warrens, G. Jurman. The coefficient of determination R-squared is more informative than sMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7(e623), 2021.
- [62] S. Wright. Correlation and causation. *Journal of Agricultural Research*, XX(7):557–585, 1921.
- [63] J. M. Koehne, B. P. Mohanty, J. Simunek. Inverse Dual-Permeability Modeling of Preferential Water Flow in a Soil Column and Implications for Field-Scale Solute Transport. *Vadose Zone Journal*, 5(1), 2006.
- [64] D. R. Legates, G. J. McCabe. Evaluating the use of “goodness-of-fit” measures in hydrologic and hydroclimatic model validation. *Water Resources Research*, 35(1):233–241, 1999.
- [65] P. Krause, D. P. Boyle, F. Base. Comparison of different efficiency criteria for hydrological model assessment. *Advances in Geosciences*, 5:89–97, 2005.
- [66] C. J. Willmott. On the validation of models. *Physical Geography*, 2:184–194, 1981.
- [67] D. Freedman, R. Pisani, R. Purves. *Statistics (4th Edition International Student Edition)*. WW Norton & Company, Nowy Jork, USA, 2007.
- [68] J. Maedler, I. Viedt, L. Urbas. Applying quality assurance concepts from software development to simulation model assessment in smart equipment. *W Proceedings of the 31st European Symposium on Computer Aided Process Engineering (ESCAPE31)*, 1, 2021.
- [69] J. Łęski. *Systemy neuronowo-rozmyte*. Wydawnictwo Naukowo-Techniczne, Warszawa, Polska, 2008.
- [70] L. A. Zadeh. Fuzzy sets. *Information and Control*, 8(3):338–353, 1965.
- [71] J. Kacprzyk. *Zbiory rozmyte w analizie systemowej*. PWN, Warszawa, Polska, 1987.
- [72] E. H. Ruspini. A new approach to clustering. *Information and Control*, 15(1):22–32, 1969.

- [73] L. A. Zadeh. Outline of a new approach to the analysis of complex systems and decision processes. *IEEE Transactions on Systems, Man, and Cybernetics*, 3(1):28–44, 1973.
- [74] Li-Xin Wang. *A course in fuzzy systems and control*. Prentice Hall, Nowy Jork, USA, 1998.
- [75] W. Pedrycz. *Fuzzy Control and Fuzzy Systems*. John Wiley and Sons, Nowy Jork, USA, 1993.
- [76] D. Dubois, H. Prade. The three semantics of fuzzy sets. *Fuzzy Sets and Systems*, 90(2):141–150, 1997.
- [77] L. A. Zadeh. Fuzzy sets as a basis for a theory of possibility. *Fuzzy Sets and Systems*, 100(1):2–28, 1978.
- [78] S. N. Sivanandam, S. Sumathi, S. N. Deepa. *Introduction to Fuzzy Logic using Matlab*. Springer-Verlag, Berlin, Heidelberg, Niemcy, 2010.
- [79] C. I. Karr. Design of an adaptive fuzzy controller using a genetic algorithm. *Proceedings of 4th International Conference on Genetic Algorithms*, 1991.
- [80] T. Primke. Algorytmy ewolucyjne. Instrukcja do laboratorium, 2011.
- [81] A. Arslan, M. Kaya. Determination of fuzzy logic membership functions using genetic algorithms. *Fuzzy Sets and Systems*, 118:297–306, 2001.
- [82] J. Arabas. *Wykłady z algorytmów ewolucyjnych*. WNT, Warszawa, Polska, 2001.
- [83] D. E. Goldberg. *Algorytmy genetyczne i ich zastosowania*. WNT, Warszawa, Polska, 1998.
- [84] Z. Michalewicz. *Algorytmy genetyczne + struktury danych = programy ewolucyjne*. WNT, Warszawa, Polska, 1999.
- [85] G. Ren, S. Wen, Z. Yan, R. Hu, Z. Zeng, Y. Cao. Power load forecasting based on support vector machine and particle swarm optimization. W *2016 12th World Congress on Intelligent Control and Automation (WCICA)*, 2003–2008, 2016.
- [86] Q. Fu, B. Jiang, C. Wang, X. Zhou. A Novel Deblocking Quantization Table for Luminance Component in Baseline JPEG. *Journal of Communications*, 10(8):629–637, 2015.

- [87] Y. S. Sherif, B. A. Boice. Optimization by pattern search. *European Journal of Operational Research*, 78:277–303, 1994.
- [88] C. Audet, J. E. Dennis. ANALYSIS OF GENERALIZED PATTERN SEARCHES. *SIAM Journal on Optimization*, 13(3):889–903, 2003.
- [89] W. Odziemczyk. Application of simulated annealing algorithm for 3d coordinate transformation problem solution. *Open Geosciences*, 12(1):491–502, 2020.
- [90] A. Debudaj-Grabysz, S. Deorowicz, . Widuch. *Algorytmy i struktury danych. Wybór zaawansowanych metod*. Wydawnictwo Politechniki Śląskiej, Gliwice, Polska, 2012.
- [91] R. Czabanski, M. Jezewski, J. Leski. Introduction to fuzzy systems. W *Theory and Applications of Ordered Fuzzy Numbers. Studies in Fuzziness and Soft Computing*, 356. Springer, Cham, 2017.
- [92] The MathWorks. *Fuzzy Logic Toolbox User's Guide For Use with MATLAB (2nd.ed.)*. The MathWorks, Inc., Natick, USA, 2001.
- [93] Mathworks. [www.mathworks.com/help/](http://www.mathworks.com/help/).
- [94] J. H. Zar. *Biostatistical Analysis*. Pearson Education Limited, Essex, Anglia, 2014.
- [95] S. S. Shapiro, M. Wilk. An analysis of variance test for normality (complete samples). *Biometrika*, 52(3-4):591–611, 1965.
- [96] M. Krzywinski, N. Altman. Visualizing samples with box plots. *Nature Methods*, 11(2):119–120, 2014.
- [97] JMP. Statistical Discovery. How do I interpret the Shapiro-Wilk test for normality in JMP? [www.jmp.com/support/notes/35/406.html](http://www.jmp.com/support/notes/35/406.html), 2023. Dostęp: 2023-02-24.
- [98] J. Koronacki, J. Mielniczuk. *Statystyka dla studentów kierunków technicznych i przyrodniczych*. Wydawnictwa Naukowo-Techniczne, Warszawa, Polska, 2006.
- [99] C. Spearman. The proof and measurement of association between two things. *American Journal of Psychology*, 15:72–101, 1904.
- [100] C. Spearman. Footrule for measuring correlation. *British Journal of Psychology*, 2:89–108, 1906.

- [101] J. K. Lindsey. *Statistical Analysis of Stochastic Processes in Time*. Cambridge University Press, Nowy Jork, USA, 2004.
- [102] S. J. Taylor. *Modelling Financial Time Series with S-PLUS*. World Scientific, 2006.
- [103] G. Kirchgässner, J. Wolters. *Introduction to Modern Time Series Analysis*. Springer-Verlag, Berlin Heidelberg, Niemcy, 2007.
- [104] A. Nielsen. *Szeregi czasowe. Praktyczna analiza i predykcja z wykorzystaniem statystyki i uczenia maszynowego*. Helion, Gliwice, Polska, 2020.
- [105] Główny Urząd Statystyczny. Szeregi czasowe. [stat.gov.pl/metainformacje/szeregi-czasowe-4712/](http://stat.gov.pl/metainformacje/szeregi-czasowe-4712/), 2023. Dostęp: 2023-03-03.
- [106] Jerzy Stefanowski. Analiza szeregów czasowych. time Series Analysis. część 2. <http://www.cs.put.poznan.pl/jstefanowski/pse/Analizaszeregowczasowych2.pdf>, 2020. Dostęp: 2023-09-05.
- [107] J. Kasprzyk, E. Bielińska, J. Figwer, T. Legierski, Z. Ogonowski, M. Pawełczyk. *Identyfikacja procesów*. Wydawnictwo Politechniki Śląskiej, Warszawa, Polska, 2002.
- [108] W. R. Lacerda Junior, L. P. da Costa Andrade, S. C. Pessoa Oliveira, S. A. Milani Martins. SysIdentPy: A Python package for System Identification using NARMAX models. *The Journal of Open Source Software*, 5(54):2384, 2020.
- [109] S. A. Billings, I. J. Leontaritis. Parameter estimation techniques for nonlinear systems. *ICAF Proceedings Volumes*, 15(4):505–510, 1982.
- [110] Minitab. Interpret the partial autocorrelation function (PACF). [support.minitab.com/en-us/minitab/21/help-and-how-to/statistical-modeling/time-series/how-to/partial-autocorrelation/interpret-the-results/partial-autocorrelation-function-pacf/](https://support.minitab.com/en-us/minitab/21/help-and-how-to/statistical-modeling/time-series/how-to/partial-autocorrelation/interpret-the-results/partial-autocorrelation-function-pacf/). Dostęp: 2023-05-15.
- [111] Eberly College of Science Penn State. STAT 510, Applied Time Series Analysis. [online.stat.psu.edu/stat510/](https://online.stat.psu.edu/stat510/), 2023. Dostęp: 2023-08-31.
- [112] NIST/SEMATECH. *e-Handbook of Statistical Methods*. NIST/SEMATECH, USA, 2012.

- [113] E. Czogała, J. Łęski. *Fuzzy and Neuro-Fuzzy Intelligent Systems*. Physica-Verlag, Heidelberg, Niemcy, 2000.
- [114] The MathWorks Inc. Statistics and machine learning toolbox. [www.mathworks.com/help/stats/index.html](http://www.mathworks.com/help/stats/index.html), 2022. Dostęp: 2023-05-10.
- [115] J. Cohen. *Statistical power analysis*. Hillsdale NJ: Erlbaum, 1988.
- [116] T. Baguley. Standardized or simple effect size: what should be reported? *British Journal of Psychology*, 100(3):603–617, 2009.
- [117] D. F. Findley. Counterexamples to parsimony and BIC. *Annals of the Institute of Statistical Mathematics*, 43:505–514, 1991.
- [118] A. Polański, M. Marczyk, M. Pietrowska, P. Widłak, J. Polańska. Signal Partitioning Algorithm for Highly Efficient Gaussian Mixture Modeling in Mass Spectrometry. *PLOS ONE*, 10, 2015.
- [119] P. Schober, C. Boer, L. A. Schwarte. Correlation coefficients: Appropriate use and interpretation. *Anesthesia & Analgesia*, 126(5):1763–1768, 2018.
- [120] P. Mishra, C. M. Pandey, U. Singh, A. Keshri, M. Sabaretnam. Selection of Appropriate Statistical Methods for Data Analysis. *Annals of Cardiac Anaesthesia*, 22(3):297–301, 2019.
- [121] F. Wilcoxon. Individual comparisons by ranking methods. *Biometrics*, 1:80–83, 1945.