

**Politechnika Śląska
Wydział Mechaniczny Technologiczny
Katedra Podstaw Konstrukcji Maszyn**

Piotr Tomasik

**Metody identyfikacji
modeli procesów wolnozmiennych
dla potrzeb diagnostyki technicznej**

Gliwice 2007

Recenzenci

Dr hab. inż. Wiesław Miczulski, prof. Uniwersytetu Zielonogórskiego
Prof. dr hab. inż. Wojciech Cholewa, Politechnika Śląska w Gliwicach

Redaktor zeszytów

Wojciech Cholewa

Redaktor techniczny

Marek Wyleźoń

Projekt okładki

Wojciech Cholewa, Marek Wyleźoń

ISBN 978-83-60759-01-1

Wydawca

Katedra Podstaw Konstrukcji Maszyn
Wydział Mechaniczny Technologiczny
Politechnika Śląska
ul. Konarskiego 18a, 44-100 Gliwice
tel. (32) 237-14-67, fax (32) 237-13-60
<https://kpk.m.polsl.pl>

Od autora

Zeszyt został opracowany na podstawie mojej rozprawy doktorskiej, wykonanej pod kierunkiem prof. dra hab. Wojciecha Moczulskiego. Publiczna obrona rozprawy odbyła się 21 lutego 2007 roku przed Komisją powołaną przez Radę Wydziału Mechanicznego Technologicznego. W opracowaniu zostały uwzględnione uwagi Panów Recenzentów rozprawy doktorskiej: Prof. Wiesława Miczulskiego i Prof. Wojciecha Cholewy.

Niniejszą książkę dedykuję mojej żonie Ewelinie w podzięce za wyrozumiałość i cierpliwość. Składam serdeczne podziękowania Koleżankom i Kolegom z Katedry Podstaw Konstrukcji Maszyn Politechniki Śląskiej za okazaną mi pomoc i życzliwość w czasie wykonywania pracy. Szczególnie zaś dziękuję prof. dr. hab. Wojciechowi Moczulskiemu za nieocenioną pomoc w realizacji badań oraz cenne uwagi krytyczne.

Gliwice, kwiecień 2007

Piotr Tomasik

Spis treści

Od autora	3
Rozdział 1. Wstęp	7
Rozdział 2. Modelowanie procesów wolnozmiennych	11
2.1. Modele procesów do detekcji uszkodzeń	12
2.1.1. Równania fizyczne	12
2.1.2. Transmitancja, równania stanu obiektów i obserwatory stanu	12
2.1.3. Modele neuronowe	15
2.1.4. Modele rozmyte	16
2.1.5. Rozmyte sieci neuronowe	18
2.2. Modele do lokalizacji uszkodzeń	19
2.2.1. Modele odwzorowujące binarne sygnały diagnostyczne	19
2.2.2. Modele odwzorowujące wielowartościowe sygnały diagnostyczne	21
2.2.3. Modele odwzorowujące ciągłe sygnały diagnostyczne	22
2.3. Sekwencje zdarzeń	22
2.4. Metody odkrywania wiedzy w bazach danych	23
2.4.1. Tablice kontyngencji	25
2.4.2. Odkrywanie równań	27
2.4.3. Dynamiczne modele jakościowe	27
2.5. Baza wiedzy jako model procesu	28
2.5.1. Reguły diagnostyczne	28
2.5.2. Przybliżone reguły diagnostyczne	29
2.5.3. Drzewa decyzyjne	29
2.5.4. Sieci przekonań (Bayesa)	30
2.5.5. Sieci stwierdzeń	31
2.5.6. Ramy	32
2.6. Modele szeregów czasowych	33
2.7. Podsumowanie	36
Rozdział 3. Cel, teza i zakres rozprawy	37
3.1. Cel pracy	37
3.2. Teza	38
3.3. Zakres rozprawy	38

Rozdział 4. Metody pozyskiwania wiedzy z bazy danych procesowych	39
4.1. Charakterystyka rozpatrywanych danych procesowych	39
4.2. Wybór atrybutów i przygotowanie danych do przeprowadzenia badania	41
4.3. Normalizacja czasowa przebiegów ciągłych parametrów procesowych	42
4.4. Sposoby wielomianowej aproksymacji przebiegów	42
4.5. Metoda określania podobieństw dla odległości bezwzględnych	43
4.5.1. Podobieństwo wielkości wejściowych i wyjściowych	46
4.6. Metoda sekwencji znakowych	48
4.7. Metoda określania podobieństw dla odległości względnych	54
4.8. Modyfikacje gęstości rozkładu podobieństw atrybutów	56
4.9. Wyznaczanie wag istotności atrybutów	62
4.10. Sposób prezentacji wyników	64
4.11. Sposób oceny opracowanych metod	65
Rozdział 5. Weryfikacja metod	69
5.1. Plan weryfikacji	69
5.2. Wybór danych do badań	70
5.3. Określenie parametrów weryfikowanych metod	73
5.4. Wyznaczenie wartości odległości	76
5.5. Wyznaczenie wartości podobieństw	77
5.6. Przykłady wyszukiwania podobnych realizacji	91
5.7. Prezentacja wyników wyszukiwania podobnych cykli	99
5.8. Ocena wyników badań uzyskanych za pomocą opracowanych metod	102
5.9. Podsumowanie wyników weryfikacji	103
Rozdział 6. Podsumowanie i wnioski	105
6.1. Podsumowanie	105
6.2. Wnioski	106
6.3. Kierunki dalszych badań	106
Streszczenie	116
Summary	117

Rozdział 1

Wstęp

Dane zgromadzone podczas monitorowania przebiegu złożonych procesów przemysłowych o cyklicznym charakterze mogą być nośnikiem informacji o sposobie sterowania procesem w celu uzyskania zamierzonych wyników końcowych dla danego etapu produkcji.

Dane te są gromadzone w bazach danych i odpowiadają one automatycznym odczytom z czujników rejestrujących różne parametry procesowe takie jak moc, napięcia, temperatury, ciśnienia itp. dla różnych urządzeń tworzących ciąg technologiczny dla danego procesu przemysłowego. Dodatkowo część zapisów jest prowadzona bezpośrednio (manualnie) przez obsługę danego urządzenia czy instalacji i dotyczy przede wszystkim spostrzeżeń o stanie maszyn i prawidłowości sterowania procesem. Zbiory obu powyższych typów zapisów tworzą archiwum danych historycznych rozpatrywanego procesu. Z powodu stosowania różnych metod gromadzenia danych i informacji możemy mieć do czynienia z niską jakością tak powstałych baz danych archiwalnych. Powstają często „luki” w zapisach, brak danych z czujników dla niektórych parametrów, nie ujęte w zapisach obsługi i in.

Taki stan zmusza do przeprowadzenia dodatkowej weryfikacji zawartości baz danych, usunięcia błędnych zapisów, zaznaczenia zapisów niekompletnych itp.

Sterowanie takim złożonym procesem, jakiego przykładem może być obsługa pieca elektrycznego do redukcji miedzi z żużla, jest z reguły realizowane przez przeszkolony personel - operatorów różnych etapów danego procesu przemysłowego. Jakość prowadzenia procesu zależy w znacznym stopniu od wiedzy i doświadczenia tej obsługi. Operatorzy dobierają parametry sterowania w zależności od wielkości wejściowych (surowce przetwarzane) oraz znajomości przybliżonych czasów trwania poszczególnych faz danego cyklu, wymaganych do otrzymania wielkości wyjściowych. Liczba parametrów procesowych jest bardzo duża, więc obsługa musi przede wszystkim koncentrować się na tych najbardziej istotnych parametrach. Niestety nie zawsze jest określona dostatecznie sformalizowana procedura prowadzenia takiego procesu, a informacje co do sposobu prowadzenia procesu pochodzące od obsługi często nie pokrywają się w istotnych punktach.

Osoby obsługujące proces nie potrafią przekazać swojej wiedzy w sposób, który pozwalałby zidentyfikować taką procedurę optymalnego sterowania obiektem/procesem. Można przyjąć, że każdy operator posiada własną drogę postępowania, która różni się

od sposobu postępowania innych operatorów procesu.

Dodatkowe zadania realizowane przez operatorów podczas sterowania obejmują utrzymywanie poszczególnych parametrów w określonych zakresach, których przekroczenie zarówno dla wartości jak i czasu trwania takiego stanu może bardzo niekorzystnie wpływać na stan danego obiektu przemysłowego i/lub spowodować niekorzystny wpływ na pozostałe obiekty tworzące ciąg produkcyjny. Podczas trwania cyklu produkcyjnego wymagane jest zachowanie synchronizacji pomiędzy poszczególnymi obiektami procesu, co wynika z ciągłego przepływu materii pomiędzy tymi obiektami.

Przedmiotem pracy są metody modelowania procesów wolnozmiennych. Dla potrzeb pracy przyjęto, że pod pojęciem procesu wolnozmiennego będzie rozumiany proces charakteryzujący się następującymi cechami:

- występują długie okresy, gdy wartości niektórych atrybutów stanu lub sterowań są stałe lub wolno się zmieniają z widocznym kierunkiem trendu,
- nie występują nagłe zmiany wartości atrybutów stanu lub sterowań w trakcie prowadzenia procesu,
- występuje korzystny stosunek wartości skutecznej sygnału do wartości skutecznej szumu (wynikającego z różnych zakłóceń procesowych),
- liczba zdarzeń opisujących zmianę wartości atrybutu w czasie cyklu jest niewielka, a czasy trwania poszczególnych zdarzeń są długie w stosunku do czasu trwania całego cyklu.

W wyniku przeglądu istniejącego stanu w zakresie metod modelowania procesów wolnozmiennych stwierdzono, że przydatne do modelowania takich procesów mogą być metody bazujące na prostych sposobach przetwarzania danych. W ramach pracy zaproponowano nowe metody modelowania procesów reprezentowanych za pomocą wielowymiarowych szeregów czasowych. Metody te bazują na miarach odległości oraz sekwencjach znakowych stosowanych do wyznaczania stopnia podobieństwa pomiędzy poszczególnymi realizacjami procesu. Uzyskane modele poszczególnych cykli procesu mają charakter globalny. Mogą być one wykorzystane w rozumowaniu opartym na przykładach (ang. Case-Based Reasoning, CBR).

Rozumowanie bazujące na przykładach jest jedną z metod wnioskowania [1, 5]. Metoda ta nie wymaga znajomości modeli matematycznych obiektu i zależności pomiędzy atrybutami procesowymi. Nośnikiem wiedzy jest tutaj baza odpowiednio dobranych przykładów realizacji archiwalnych. Aby móc wnioskować za pomocą tej metody konieczne jest odpowiednie zdefiniowanie właściwej miary podobieństwa pomiędzy przykładami.

W metodzie tej zakłada się, że rozwiązanie nowych problemów można osiągnąć bazując na zdobytym doświadczeniu w rozwiązywaniu wcześniej zaistniałych sytuacji. Metoda ta polega więc na wyszukaniu w bazie realizacji archiwalnych przykładów jak najbardziej (lub dostatecznie) podobnych do aktualnego przykładu i na zastosowaniu ich do rozwiązania tego przykładu. Stadiami metody są: wyszukiwanie podobnych przykładów, użycie wyszukanych przykładów do rozwiązania nowego przykładu, sprawdzenie poprawności wyników oraz zapis nowego przykładu do bazy.

Metody poddano weryfikacji na danych pochodzących z rzeczywistego obiektu technicznego dla różnych wartości parametrów opracowanych metod. Wyniki weryfikacji potwierdzają skuteczność opracowanych metod oraz ich przydatność do budowy bazy wiedzy systemu doradczego wykorzystującego wnioskowanie metodą analogii (zwane także rozumowaniem opartym na przykładach) do wspomagania podejmowania decyzji przez obsługę złożonego obiektu technicznego (proponując systemów doradczych dla takiego obiektu zostały opisane w [7–10, 87]).

Tematyka pracy dotyczy współcześnie rozwijającej się dziedziny naukowej jaką jest diagnostyka procesów przemysłowych. Badania opisane w pracy częściowo wykonano w ramach projektu badawczego *PBU – 73/RMT6/2004* pt. „Metodyka heurystycznego modelowania obiektów i procesów dynamicznych w diagnostyce i sterowaniu”, finansowanego przez Ministerstwo Nauki i Szkolnictwa Wyższego.

Rozdział 2

Modelowanie procesów wolnozmiennych

W diagnostyce technicznej różnych klas obiektów i procesów stosowane są liczne metody modelowania [45, 73]. Trudność, a niejednokrotnie wręcz niemożność uzyskania ogólnego opisu obiektu uwzględniającego wpływ uszkodzeń powodują, że najczęściej identyfikowane są modele uproszczone. Wyróżnia się przy tym modele do detekcji uszkodzeń oraz modele do lokalizacji uszkodzeń lub rozpoznawania stanu obiektu czy procesu [45, 73]. Spośród modeli do detekcji uszkodzeń największe znaczenie mają modele analityczne, rozmyte oraz neuronowe. Natomiast do lokalizacji uszkodzeń lub rozpoznawania stanu obiektu liczba możliwych do zastosowania modeli jest znacznie większa.

W zależności od złożoności problemu wykorzystanie poszczególnych metod modelowania powiązane jest z pewnymi wymaganiami co do sposobu prowadzenia analiz i budowy modeli. Modele wymagają różnej reprezentacji danych o obiekcie lub procesie. Modele te są nośnikami wiedzy o obiekcie. Ta wiedza może być gromadzona w bazach wiedzy np. w postaci reguł utworzonych na podstawie informacji pozyskanych od specjalistów lub może być określona w postaci zależności funkcyjnych, zidentyfikowanych na podstawie danych zgromadzonych podczas monitorowania takiego obiektu lub procesu.

Omawiane metody modelowania mogą być stosowane indywidualnie do rozwiązywania całych złożonych zadań lub można wykorzystać pewne grupy tych metod do określonych etapów takiego zadania ze względu na różną efektywność poszczególnych metod dla określonych typów istniejących zadań.

W poniższym rozdziale omówiono najczęściej stosowane metody modelowania procesów według klasyfikacji przyjętej w [45] oraz podano przykłady ich zastosowań w diagnostyce technicznej.

2.1. Modele procesów do detekcji uszkodzeń

Do detekcji uszkodzeń stosowana jest redundancja analityczna [43,45] polegająca na wyznaczeniu dodatkowych wartości zmiennych procesowych na podstawie modelu matematycznego. Pozwala ona na wyznaczanie wartości residuów pomiędzy sygnałami mierzonymi i wyliczonymi. Taki model obiektu lub procesu diagnozowanego opisuje wszystkie związki między zmiennymi procesowymi.

W grupie analitycznych modeli do detekcji uszkodzeń można wyróżnić [45]:

- modele fizyczne, np. równania ruchu, równania bilansowe itp.,
- modele liniowe typu *wejście-wyście* (transmitancje ciągłe lub dyskretne),
- liniowe równania stanu,
- obserwatory stanu.

Oprócz modeli analitycznych, w dostępnej literaturze opisuje się najczęściej zastosowania takich modeli, jak:

- modele neuronowe,
- modele rozmyte,
- modele neuronowo-rozmyte.

2.1.1. Równania fizyczne

Równania fizyczne otrzymuje się poprzez modelowanie matematyczne dynamiki obiektów lub procesów [84]. Uszkodzenia obiektów dynamicznych o jednym wejściu i jednym wyjściu opisuje się wówczas za pomocą nieliniowych równań różniczkowych [45,73]:

$$\Psi(y, y', y'', \dots, y^{(n)}, u, u', u'', \dots, u^{(m)}) = 0. \quad (2.1)$$

Uszkodzenia te można wykrywać poprzez oceny wartości residuów wyliczanych z tych równań:

$$r = \Psi(y, y', y'', \dots, y^{(n)}, u, u', u'', \dots, u^{(m)}). \quad (2.2)$$

Modele takie dobrze nadają się do opisu związków między zmiennymi procesowymi i umożliwiają wykrywanie nawet bardzo małych uszkodzeń. Jednak opracowanie równań fizycznych jest często bardzo trudne, co ogranicza ich stosowanie jedynie do prostych obiektów lub procesów.

2.1.2. Transmitancja, równania stanu obiektów i obserwatory stanu

Do detekcji często stosowane są modele liniowe obiektów [84]. Ponieważ ich struktura jest stała, to tworzenie tych modeli polega na określeniu wartości parametrów. Obie formy tych modeli, czyli transmitancja operatorowa i równania stanu są stosowane do opisu stacjonarnych modeli liniowych. Dla układów nieliniowych ich własności

dynamiczne wyznacza się tylko w otoczeniu punktu pracy.

Równania stanu obiektu liniowego

Dynamiczny stacjonarny układ liniowy o p wejściach oraz o q wyjściach może być opisany równaniami stanu i wyjść z czasem ciągłym [45]:

$$\begin{aligned}\dot{\mathbf{x}}(t) &= \mathbf{A}\mathbf{x}(t) + \mathbf{B}\mathbf{u}(t), \\ \mathbf{y}(t) &= \mathbf{C}\mathbf{x}(t) + \mathbf{D}\mathbf{u}(t),\end{aligned}\tag{2.3}$$

lub dyskretnym

$$\begin{aligned}\mathbf{x}(k+1) &= \mathbf{A}\mathbf{x}(k) + \mathbf{B}\mathbf{u}(k), \\ \mathbf{y}(k) &= \mathbf{C}\mathbf{x}(k) + \mathbf{D}\mathbf{u}(k),\end{aligned}\tag{2.4}$$

gdzie:

$\mathbf{x}(t)$ - n -wymiarowy wektor stanu,

$\mathbf{u}(t)$ - p -wymiarowy wektor wejść,

$\mathbf{y}(t)$ - q -wymiarowy wektor wyjść,

\mathbf{A} - macierz układu (procesu) o wymiarze $n \times n$,

\mathbf{B} - macierz sterowania (wejścia) o wymiarze $n \times p$,

\mathbf{C} - macierz odpowiedzi (wyjścia) o wymiarze $q \times n$,

\mathbf{D} - macierz o wymiarze $q \times p$.

Opis obiektu uzyskany w postaci równań stanu jest wykorzystywany do generacji residuów na podstawie redundancji czasowej (Cow i Willsky, 1984).

Obserwatory stanu

Dla równań stanu z czasem dyskretnym (2.4), gdzie $\mathbf{D}\mathbf{u}(k) = 0$ można konstruować obserwatory diagnostyczne [45]. Obserwator jest algorytmem stosowanym do przybliżania stanu obiektu lub procesu dynamicznego na podstawie sygnałów wejściowych i wyjściowych. Macierz obserwatora wyznacza się z równania:

$$\begin{aligned}\hat{\mathbf{x}}(k+1) &= \mathbf{A}\hat{\mathbf{x}}(k) + \mathbf{B}\mathbf{u}(k) + \mathbf{H}[\mathbf{y}(k) - \mathbf{C}\hat{\mathbf{x}}(k)] \\ \hat{\mathbf{y}}(k) &= \mathbf{C}\hat{\mathbf{x}}(k)\end{aligned}\tag{2.5}$$

gdzie:

$\hat{\mathbf{x}}$ - przybliżenie stanu,

$\hat{\mathbf{y}}$ - przybliżenie wyjścia,

\mathbf{H} - macierz sprzężenia zwrotnego obserwatora.

Wektor residuów opisany jest zależnością:

$$\mathbf{r}(k) = \mathbf{y}(k) - \hat{\mathbf{y}}(k) = \mathbf{y}(k) - \mathbf{C}\hat{\mathbf{x}}(k). \quad (2.6)$$

W wyniku modelowania uszkodzeń \mathbf{f} oraz zakłóceń \mathbf{d} w równaniach stanu i wyjść, konstruowany obserwator przyjmuje postać:

$$\hat{\mathbf{x}}(k+1) = \mathbf{A}\hat{\mathbf{x}}(k) + \mathbf{B}\mathbf{u}(k) + \mathbf{H}[y(k) - \mathbf{C}\hat{\mathbf{x}}(k)] + \mathbf{E}\mathbf{d}(k) + \mathbf{F}\mathbf{f}(k), \quad (2.7)$$

$$\hat{\mathbf{y}}(k) = \mathbf{C}\hat{\mathbf{x}}(k) + \Delta \mathbf{y},$$

gdzie:

\mathbf{E} - macierz wejścia zakłóceń,

\mathbf{F} - macierz wejścia uszkodzeń,

$\Delta \mathbf{y}$ - uszkodzenia torów pomiarowych.

Transmitancja obiektu liniowego

Do opisu układów dynamicznych stosuje się często transmitancje operatorowe, określone jako stosunek transformaty Laplace'a sygnału wyjściowego $Y(s)$ do transformaty Laplace'a sygnału wejściowego $U(s)$, przy zerowych warunkach początkowych [41]:

$$G(s) = \frac{Y(s)}{U(s)}. \quad (2.8)$$

Dla opisanie dynamiki wielowymiarowego układu liniowego o p wejściach i q wyjściach stosuje się transmitancję operatorową zapisaną w postaci macierzowej:

$$\mathbf{G}(s) = \frac{\mathbf{Y}(s)}{\mathbf{U}(s)} = \begin{bmatrix} G_{11}(s) & G_{12}(s) & \dots & G_{1p}(s) \\ G_{21}(s) & G_{22}(s) & \dots & G_{2p}(s) \\ \dots & \dots & \dots & \dots \\ G_{q1}(s) & G_{q2}(s) & \dots & G_{qp}(s) \end{bmatrix}, \quad (2.9)$$

gdzie:

$G_{ij}(s) = Y_i(s)/U_j(s)$, $i = 1, 2, \dots, q$; $j = 1, 2, \dots, p$ - transmitancja operatorowa między i -tym wejściem i j -tym wyjściem układu.

Dla układów z czasem dyskretnym wyznaczana jest transmitancja dyskretna, będąca stosunkiem transformaty Z sygnału wyjściowego $Y(z)$ do transformaty Z sygnału wejściowego $U(z)$, przy zerowych warunkach początkowych [45]:

$$G(z) = \frac{Y(z)}{U(z)}. \quad (2.10)$$

Przy obliczaniu transmitancji operatorowych objawiają się trudności z uzyskaniem odpowiednich własności residuów. Wartości te powinny być wrażliwe na wystąpienie uszkodzeń i powinny być niewrażliwe, gdy pojawią się naturalne zakłócenia procesu, błędy modelowania, zmiany punktów pracy [43].

2.1.3. Modele neuronowe

Do modelowania i identyfikacji obiektów dynamicznych są coraz częściej stosowane modele neuronowe reprezentowane za pomocą sieci neuronowych. Sieci te charakteryzują przede wszystkim dużą odporność na zakłócenia oraz możliwość modelowania różnych nieliniowości. W układach diagnostyki procesów sieci te można stosować także jako moduły do podejmowania decyzji o stanach awaryjnych [45].

Bardzo ważną cechą sieci neuronowych jest zdolność do uczenia się i adaptacji. Podczas tworzenia sieci konieczne jest określenie jej struktury (tj. liczby warstw sieci, liczby neuronów w każdej warstwie), wybór funkcji aktywacji neuronu (liniowa, signum, sigmoidalna lub tangens hiperboliczny) oraz dobór wartości wag. Wartości wag są wyznaczone w procesie trenowania sieci, które może być prowadzone z nadzorem lub bez nadzoru. Wejściami sieci mogą być residua wyznaczone za pomocą modeli obiektów, zmienne procesowe lub cechy sygnałów. Wartości wag oraz struktura sieci określają zawartą w sieci wiedzę.

Do modelowania obiektów dynamicznych najczęściej stosuje się [22, 46]:

- **Sieci typu perceptronu wielowarstwowego**, które zawierają warstwę wejściową, jedną lub więcej warstw ukrytą oraz warstwę wyjściową,
- **Sieci radialne (RBF)**, które stanowią alternatywny wybór dla sieci perceptronowych. Stosowane są często na potrzeby detekcji uszkodzeń w badanych obiektach,
- **Sieci typu GMDH**, które działają w oparciu o algorytm grupowej obróbki danych Iwachnienko [22, 67] pozwalający na ewolucyjne kreowanie struktury sieci,
- **Sieci rekurencyjne**, które posiadają sprzężenia zwrotne w architekturze sieci występujące wewnątrz pojedynczych modeli neuronów (sieci lokalnie rekurencyjne) lub pomiędzy neuronami różnych warstw lub tej samej warstwy (sieci globalnie rekurencyjne). Przykładem takiej najbardziej ogólnej sieci jest sieć rekurencyjna czasu rzeczywistego stosowana do przetwarzania sygnałów w czasie rzeczywistym,
- **Sieci dynamiczne**, gdzie własności dynamiczne uzyskuje się poprzez wprowadzenie odpowiednich wewnętrznych sprzężeń zwrotnych (aktywacyjne, sprzężenie w synapsie, sprzężenie wyjściowe),
- **Sieci Kohonena** stosowane do odkrywania wzorców na podstawie wyszukiwania wzajemnych właściwości, regularności i powiązań we wzorcach uczących. Cechują się nienadzorowanym procesem uczenia oraz samoorganizacją struktury sieci,
- **Wielosieci** zwane także układem wielu ekspertów tworzone z kilku sieci niezależnie trenowanych, które stanowią fragmenty ogólnego odwzorowania modelu. Odpowiedzi układu są wyznaczone za pomocą bloku decyzyjnego.

Sieci neuronowe wymagają zgromadzenia odpowiednio dużych zbiorów danych uczących. Jest to bardzo krytyczne zadanie rzutujące bezpośrednio na jakość sieci. Od typu

sieci i jej rozmiarów zależy długość czasu uczenia się sieci. Można częściowo rozwiązać ten problem przez stosowanie wielosieci, których sieci składowe są mniejsze (posiadają mniej neuronów w poszczególnych warstwach, mniej warstw ukrytych), ale bardziej złożony jest cały model.

Ponieważ liczba możliwych zastosowań sieci neuronowych jest bardzo szeroka, to przekłada się to na liczbę publikacji związanych z tą tematyką.

Podstawowe informacje wprowadzające w ten temat można znaleźć w [22, 44–46, 89]. Zawarte są w nich przede wszystkim informacje o typach powszechnie stosowanych sieci oraz przykłady ich zastosowania w praktyce np. do detekcji uszkodzeń [30, 45] czy fuzji danych z czujników [26].

Sieci neuronowe znalazły szerokie zastosowanie w aplikacjach baz danych [31], t.j. aproksymacji funkcji i opisu dynamiki systemu. Aproksymacja funkcji jest dziedziną, w której podstawy teoretyczne sieci neuronowych są w miarę dobrze ugruntowane i gdzie opracowano efektywne algorytmy obliczeniowe. Jest ona potrzebna również przy modelowaniu systemów dynamicznych, w predykcji lub sterowaniu. Coraz powszechniejsze są systemy hurtowni danych, gromadzące dane historyczne opisujące działalność firmy, zachowania jej klientów itp. Można na ich podstawie, wykorzystując sieci neuronowe, konstruować nieliniowe modele dynamiczne służące np. do klasyfikacji i prognozowania [45, 87].

Przeprowadzono próby zastosowania sieci neuronowych do identyfikacji dynamicznych modeli nieliniowych obiektów i procesów [76]. W tym podejściu określono sposób połączenia modelowania neuronowego, myślenia twórczego oraz algorytmów genetycznych.

Sieci neuronowe zostały także zastosowane jako modele wstępnego przetwarzania w procesie testowania wielomodelu zaproponowanego przez J. Wojtusika [99]. Wielomodel składa się z co najmniej dwóch, stosowanych łącznie, modeli składowych, które mogą być identyfikowane oddzielnie, najczęściej z zastosowaniem różnych metod i kryteriów. Wielomodel został przygotowany i testowany dla danych diagnostycznych pochodzących z maszyny wirnikowej.

Sieci te są także wykorzystywane w prowadzonych w Katedrze Podstaw Konstrukcji Maszyn Politechniki Śląskiej badaniach z zakresu diagnostyki maszyn i procesów. Jednym z nich jest projekt inteligentnego systemu do monitorowania lokalnych sieci wodociągowych [100]. W procesie identyfikacji modelu wykorzystuje się zarówno sieci neuronowe jak i neuronowo-rozmyte.

2.1.4. Modele rozmyte

Modele rozmyte pozwalają w naturalny sposób opisać działanie danego systemu (obiektu) w postaci zbioru reguł „jeżeli - to”. Bazują one na logice rozmytej zaproponowanej przez L. Zadeha [101]. Modele rozmyte mogą być stosowane do opisu różnych zagadnień w sposób przybliżony lub nieprecyzyjny analogicznie do rozumowania człowieka. Znalazły zastosowanie m.in. w identyfikacji modeli obiektów [28], diagnozowaniu

maszyn [15], identyfikacji klasyfikatorów stanu w sterowaniu [69, 74], optymalizacji, estymacji zmiennych pomiarowo niedostępnych oraz w procesie wykrywania uszkodzeń. Można je stosować dla obiektów nieliniowych. Bardzo dobrze nadają się do przetwarzania informacji niepewnej i nieprecyzyjnej. Ich przydatność jest duża w przypadkach gdy zbiory informacji są mało liczne i nie sprawdzają się w takiej sytuacji modele bazujące na wartościach dyskretnych.

Przy budowie modeli rozmytych istotne jest połączenie wiedzy ekspertów i dostępnych danych pomiarowych. Wiedza pochodząca od ekspertów służy do określenia struktury oraz początkowych wartości parametrów modelu (rozmieszczenie funkcji przynależności). Dane pomiarowe są wykorzystywane do strojenia modelu. Jeżeli wiedza eksperta jest błędna lub niepełna, to utworzony model może być nieprawidłowy.

Przy modelowaniu rozmytym każdemu sygnałowi wejściowemu i wyjściowemu przyporządkowane są zbiory rozmyte, którym odpowiadają wartości lingwistyczne. Do ich określenia stosowane są różne funkcje przynależności (trapezowe, trójkątne, krzywa Gaussa).

Struktura modelu rozmytego zawiera trzy bloki [75]:

- **blok rozmywania** (wyznaczanie przynależności sygnałów wejściowych do poszczególnych zbiorów rozmytych),
- **blok wnioskowania** (wyznaczanie wynikowej funkcji przynależności wyjścia na podstawie stopni przynależności wejść),
- **blok wyostrzania** (wyznaczanie dokładnej wartości wyjścia na podstawie wynikowej funkcji przynależności).

Wynikiem modelowania rozmytego jest baza reguł (model rozmyty), która opisuje związki pomiędzy wejściami i wyjściami identyfikowanego obiektu.

Spośród technik modelowania rozmytego, które mogą być zastosowane do tworzenia rozmytych modeli obiektów, stosowane są najczęściej [45]:

- metoda Wanga i Mendela pozwalająca identyfikować rozmyte modele dynamiczne,
- zastosowanie rozmytych sieci neuronowych.

Proces identyfikacji modelu składa się z następujących czterech etapów:

- zdefiniowanie zmiennych lingwistycznych,
- generowanie reguł na podstawie eksperymentu,
- przyporządkowanie wagi każdej regule,
- utworzenie bazy reguł.

Podstawy modelowania rozmytego oraz zbiorów rozmytych można znaleźć w [39]. Szeroko opisano ten typ modelowania w [75].

Modele rozmyte stosowane są także w sterowaniu obiektami i procesami. Wyróżnia się tu sterowanie deskryptywne i preskryptywne [40].

Wykorzystywane powszechnie sterowanie rozmyte - deskryptywne - zostało zaproponowane przez Mamdaniego(1974) i opierało się na podejściu lingwistycznym zaproponowanym przez Zadeha (1973).

Sterowanie deskryptywne występuje, gdy nieznan jest model procesu sterowanego, ale operatorzy i eksperci potrafią sterować tym procesem. Wiedza o sterowaniu procesem może być zapisana w postaci reguł postępowania w określonych przypadkach. Sterowanie rozmyte deskryptywne bazuje na wiedzy pozyskanej od ekspertów [40]. Opracowana na jej podstawie baza wiedzy określa jak należy sterować systemem, aby uzyskiwać właściwe wyniki. Tak opisany sposób sterowania pozwala poprawnie sterować systemem, ale nie musi być optymalny dla danego systemu. Wadą podejścia deskryptywnego jest jego wrażliwość na zmianę wymagań co do procesu sterowania.

Nowym podejściem do sterowania jest sterowanie preskryptywne [40], które nie opisuje jak steruje się znanym procesem, ale jak należy nim sterować, aby uzyskiwać optymalne wyniki w zależności od zaistniałej sytuacji. Sterowanie preskryptywne opiera się na znajomości modelu układu sterowania oraz znajomości funkcji celu i wymagań nałożonych na proces sterowania. Sterowanie optymalne wyznacza się na podstawie różnych algorytmów. Rozmytość podejścia preskryptywnego przejawia się w określeniu ograniczeń rozmytych (otoczenia), określeniu celów rozmytych oraz określeniu modelu, czyli dynamiki przejść sterowanego układu. Połączenie celów rozmytych i ograniczeń rozmytych stanowi funkcję celu. Stany mogą być określone nieprecyzyjnie (za pomocą zmiennych decyzyjnych) lub też sama dynamika może być znana w sposób nieprecyzyjny. Za pomocą podejścia preskryptywnego można optymalizować algorytm sterowania, który operuje na zmiennych rozmytych. Stosowanie podejścia deskryptywnego polega na wykorzystywaniu wiedzy ludzkiej do określenia sposobu sterowania. W podejściu preskryptywnym tę wiedzę wykorzystuje się do określania dynamiki zachowania systemu oraz opisu wymagań, które mają być spełnione.

2.1.5. Rozmyte sieci neuronowe

Sieci FNN (Fuzzy Neural Network) są hybrydą modelowania rozmytego oraz sieci neuronowych. W diagnostyce procesów mogą być stosowane do rozmytej oceny wartości residuów oraz wnioskowania diagnostycznego. Rozmyte sieci neuronowe zostały zaproponowane przez Horikawę. Mają one strukturę reprezentującą proces wnioskowania rozmytego. Podczas tworzenia sieci można wykorzystać wiedzę eksperta do określenia liczby reguł, funkcji przynależności poszczególnych reguł oraz rodzaju danych wykorzystywanych do uczenia sieci. Model otrzymany poprzez zastosowanie tych sieci nie ma charakteru czarnej skrzynki, lecz daje się zapisać w postaci reguł.

Wyróżnia się cztery typy rozmytych sieci neuronowych [43, 75]:

- z wyjściami w postaci singletonów,
- z wyjściami stanowiącymi liniową kombinację wejść,
- typu TSK (Takagi-Sugeno-Kanga),
- z wyjściami w postaci liczby rozmytej.

Identyfikacja parametrów rozmytych sieci neuronowych jest przeprowadzana za pomocą metody wstecznej propagacji błędów (dla sieci neuronowych). Sieci te znalazły zastosowanie w diagnostyce technicznej do detekcji [48] i lokalizacji uszkodzeń [35].

2.2. Modele do lokalizacji uszkodzeń

Podczas stosowania modeli do lokalizacji uszkodzeń powinny być rozpoznawane zmiany stanu spowodowane uszkodzeniami. Określenie czy zaistniała zmiana stanu będąca uszkodzeniem, odbywa się na podstawie sygnałów diagnostycznych generowanych przez algorytmy detekcyjne. Aby móc poprawnie wykrywać uszkodzenia, konieczna jest znajomość relacji między sygnałami diagnostycznymi a uszkodzeniami lub stanami technicznymi obiektu.

Modele stosowane do lokalizacji uszkodzeń lub rozpoznawania stanu obiektu odwzorowują przestrzeń wartości sygnałów diagnostycznych w dyskretną przestrzeń uszkodzeń lub stanów obiektu.

Wyróżnia się następujące rodzaje modeli (według klasyfikacji opisanej w [43]), odwzorowujące:

- przestrzeń binarnych sygnałów diagnostycznych w przestrzeń uszkodzeń lub stanów obiektu,
- przestrzeń wielowartościowych sygnałów diagnostycznych w przestrzeń uszkodzeń lub stanów obiektu,
- przestrzeń ciągłych sygnałów diagnostycznych w przestrzeń uszkodzeń lub stanów obiektu.

2.2.1. Modele odwzorowujące binarne sygnały diagnostyczne

Binarne sygnały diagnostyczne $s_j \in \{0, 1\}$ powstają w wyniku dwuwartościowej oceny residuów albo cech sygnałów lub zmiennych procesowych [45]. Wśród modeli do lokalizacji uszkodzeń oraz wykorzystujących binarne sygnały diagnostyczne można wymienić:

- binarne macierze diagnostyczne,
- binarne drzewa i grafy diagnostyczne,
- zbiory reguł i funkcje logiczne.

Binarna macierz diagnostyczna

Jest ona określana jako relacja na iloczynie kartezjańskim zbiorów uszkodzeń $F = \{f_k : k = 1, 2, \dots, K\}$ i sygnałów diagnostycznych $S = \{s_j : j = 1, 2, \dots, J\}$:

$$R_{FS} \subset F \times S. \quad (2.11)$$

Jeżeli wystąpi uwzględniane uszkodzenie, to pojawi się sygnał diagnostyczny s_j o wartości 1, w przeciwnym wypadku - sygnał s_j ma wartość 0.

Binarną macierz diagnostyczną można określić na podstawie wiedzy eksperckiej, w trakcie analizowania jak wpływają poszczególne uszkodzenia na wartości sygnałów diagnostycznych.

Binarne drzewa diagnostyczne

Binarne drzewa diagnostyczne można określić na podstawie binarnej macierzy diagnostycznej (z jednej macierzy można utworzyć wiele drzew) lub bezpośrednio na podstawie wiedzy eksperckiej.

Drzewa diagnostyczne składają się z następujących elementów [43]:

- korzeń drzewa \rightarrow sygnał analizowany jako pierwszy,
- wierzchołki drzewa \rightarrow sygnały diagnostyczne (testy),
- gałęzie drzewa (dwie z każdego wierzchołka) \rightarrow dwie wartości sygnału (pozytywna i negatywna).

Stosuje się także drzewa, w których rozpatruje się niebinarne sygnały diagnostyczne. Wówczas z każdego wierzchołka drzewa można wyprowadzić tyle gałęzi, ile wartości przyjmuje sygnał przypisany do tego wierzchołka. W najbardziej ogólnym przypadku, gdy rozpatrywane są sygnały ciągłe, liczba gałęzi wychodzących z wierzchołka wynika z przyjętej liczby przedziałów dyskretyzacji tego sygnału diagnostycznego.

Reguły diagnostyczne

Za pomocą reguł można zapisywać związki między uszkodzeniami a wartościami binarnych sygnałów diagnostycznych. Do tego celu stosuje się dwa rodzaje postaci reguł:

$$\text{Jeżeli } (s_1 = 0) \wedge \dots \wedge (s_j = 1) \wedge \dots \wedge (s_J = 1) \text{ to uszkodzenie } f_k; \quad (2.12)$$

$$\text{Jeżeli } (s_j = 1) \text{ to uszkodzenie } f_a \vee \dots \vee f_k \vee f_n.$$

Reguły (2.12) określają kolumny binarnej macierzy oraz wiersze tej macierzy. Reguły typu (2.12) są stosowane do wnioskowania w rozmytych systemach diagnostycznych, gdzie zamiast oceny progowej jest wykorzystywana dwuwartościowa rozmyta ocena residuów.

2.2.2. Modele odwzorowujące wielowartościowe sygnały diagnostyczne

Wielowartościowe sygnały diagnostyczne $s_j \in V_j$ otrzymuje się w wyniku kwantyzacji wartości residuów lub cech sygnałów, lub też można je otrzymać na podstawie kontroli ograniczeń zmiennych procesowych dla kilku wartości granicznych. Dodatkowo zakłada się, że każdemu sygnałowi diagnostycznemu może odpowiadać inny podzbiór wartości V_j [43, 45].

Głównie do opisu tego typu modeli stosuje się systemy informacyjne, na podstawie których tworzy się wielowartościowe drzewa i reguły diagnostyczne.

System informacyjny

System informacyjny jest pojęciem teorii zbiorów przybliżonych opracowanej przez Z. Pawlaka [71]. Jest on określany za pomocą następującej czwórki [43]:

$$SI = \langle X, A, V_S, r \rangle, \quad (2.13)$$

gdzie:

X - skończony zbiór obiektów,

A - skończony zbiór atrybutów,

$V_S = \bigcup_{a \in A} V_a$ - zbiór wartości atrybutów,

V_a - dziedzina atrybutu a ,

r - funkcja całkowita ($r : X \times A \rightarrow V_S$), $r(x, a) \in V_a$ dla każdego $x \in X$ oraz $a \in A$.

System informacyjny zapisuje się najczęściej w postaci tablicy, w której:

- *wiersze* odpowiadają zgromadzonym przypadkom opisanym przez wartości wszystkich badanych atrybutów,
- *kolumny* odpowiadają atrybutom.

Dla potrzeb lokalizacji uszkodzeń stosuje się przybliżony system informacyjny (PSI), w którym wartości atrybutów dla danego obiektu nie da się dokładnie określić. Został on zdefiniowany jako następująca czwórka [45]:

$$PSI = \langle F, S, V_S, r \rangle, \quad (2.14)$$

gdzie:

F - skończony zbiór uszkodzeń,

S - skończony zbiór sygnałów diagnostycznych,

$V_S = \bigcup_{s_j \in S} V_j$ - suma wszystkich sygnałów diagnostycznych,

r - funkcja całkowita ($r : F \times S \rightarrow \Phi(V_S)$).

System taki jest uogólnieniem binarnej macierzy diagnostycznej. Rozszerzeniem tego systemu w stosunku do takiej macierzy jest to, że:

- dla każdego sygnału diagnostycznego może istnieć indywidualny zbiór jego wartości,
- zbiór V_j może być wielowartościowy,
- dowolny element systemu PSI może zawierać jedną wartość sygnału diagnostycznego lub podzbiór wartości tego sygnału.

Temporalny system informacyjny

Jest on szczególnym przypadkiem systemu informacyjnego, który jest określany dla atrybutów, których wartości są zmienne w czasie. Można go określić za pomocą następującej piątki [98]:

$$TSI = \langle X, A \cup \{t\}, V_s, r, \prec \rangle, \quad (2.15)$$

gdzie:

X - skończony zbiór obiektów,

A - skończony zbiór atrybutów,

V_s - zbiór wartości atrybutów,

r - funkcja całkowita,

t - atrybut określający kolejność zdarzeń ($t \notin A$),

\prec - relacja porządkująca dla atrybutu t ($\prec = \{(x, y) : x, y \in N \text{ oraz } x < y\}$).

Temporalny system informacyjny został wprowadzony w celu reprezentowania danych opisujących zachowanie się systemów dynamicznych i realizowanych przez nie procesów.

2.2.3. Modele odwzorowujące ciągłe sygnały diagnostyczne

Ciągłe sygnały diagnostyczne to w tym przypadku wartości residuów generowanych na podstawie modeli obiektu lub procesu, cechy sygnałów oraz zmienne procesowe [72, 73]. Poszczególnym uszkodzeniom lub stanom obiektu odpowiadają w przestrzeni ciągłych sygnałów diagnostycznych określone obszary wzorcowe. Do modelowania tego typu zależności oraz rozpoznawania uszkodzeń lub stanów stosuje się różne metody klasyfikacji. Klasyfikatory budowane są zazwyczaj za pomocą metod uczenia maszynowego, rozpoznawania obrazów oraz sieci neuronowych i rozmytych sieci neuronowych [43, 46].

2.3. Sekwencje zdarzeń

Zdarzenie reprezentuje opis czegoś, co zaszło w określonej chwili lub przedziale czasu. Zbiór możliwych zdarzeń zależy od rozpatrywanego obiektu. W przypadku obiektu, jakim jest piec do redukcji miedzi z żużla, zdarzeniami mogą być np.:

- dosypanie do pieca substancji wspomagających proces redukcji,
- wystąpienie awarii układu pomiarowego,

- wystąpienie/wygenerowanie alarmu,
- sterowanie z jednakową mocą czynną przez pewien okres czasu,
- przeprowadzenie analizy chemicznej próbki żużla, pobranej w trakcie cyklu.

Sekwencje zdarzeń są natomiast zbiorami zdarzeń takiego samego lub różnego typu uporządkowanymi w czasie (np. w czasie trwania cyklu) wg kolejności ich wystąpienia. Sekwencje zdarzeń znalazły zastosowanie m.in. do:

- opisu przebiegu awarii, jak np. w reaktorze atomowym w Czarnobylu [59],
- rozpoznawania zmian sygnałów diagnostycznych maszyn na podstawie określanych sekwencji charakterystycznych [12, 13],
- modelowania procesów wolnozmiennych w diagnostyce procesów [91, 92].

Zastosowanie sekwencji zdarzeń do opisu ciągłych sygnałów diagnostycznych wymaga przeprowadzenia ich kwantyzacji oraz określenia słownika zdarzeń. Słownik taki opisuje zachowanie poszczególnych par kolejnych wartości takiego sygnału, rozpatrywanych jako początek i koniec wektora na nich opisanego. Wektor ten jest skierowany zazwyczaj od pierwszej wartości danej pary do wartości drugiej, czyli zgodnie z czasem ich wystąpienia (zarejestrowania). Pojęcie słownika sekwencji znakowych może bazować np. na tzw. kodach Freemana [88].

Dla określonych sekwencji zdarzeń stosowanych do modelowania przebiegów procesów wolnozmiennych konieczne jest ustalenie sposobu obliczania wartości podobieństwa poszczególnych opisanych przebiegów parametrów procesowych [92].

Inne podejście do budowy modeli bazujących na sekwencjach zdarzeń zostało opracowane przez R. Szulima [87]. Wprowadził on pojęcie sekwencji zdarzeń rozmytych do opisu sposobu sterowania procesem. Założeniem jego metody było zbudowanie bazy wiedzy z odpowiednio wybranych przykładowych realizacji procesu, reprezentowanych w sposób rozmyty. Opracowana baza przykładów posłużyła utworzeniu systemu rozumowania bazującego na przykładach, który mógłby wspierać personel podczas sterowania przebiegiem procesu.

2.4. Metody odkrywania wiedzy w bazach danych

Rozwój tych metod (ang. Knowledge Discovery in Databases) został zapoczątkowany w latach 90. ubiegłego wieku [24]. Wywołał go bardzo szybki rozwój technologii gromadzenia dużych zbiorów danych, do analizy których metody tradycyjne okazały się mało efektywne [2, 47, 70, 83, 95]. Metody te stanowią połączenie metod statystyki matematycznej, sztucznej inteligencji oraz wizualizacji danych. Główny nacisk w przypadku nowo powstających metod został położony na wymaganą dużą szybkość działania w stosunku do ilości przetwarzanych danych w porównaniu z metodami dotychczas stosowanymi. Metody te służą przede wszystkim do pozyskiwania wiedzy deklaratywnej odkrywanej w postaci różnych potencjalnie ważnych wzorców występujących w danych.

Proces postępowania zgodnie z tymi metodami ma charakter procesu wieloetapowego o wyraźnie zarysowanej kolejności działań. Metody te wymagają znaczącej ingerencji użytkownika podczas procesu analizy danych. Dąży się jednak do rozwinięcia metod umożliwiających działanie w jak największym stopniu w sposób autonomiczny [103].

W procesie odkrywania wiedzy można wyróżnić następujące etapy [24, 25]:

- a) przygotowanie zbioru danych do analizy,
- b) wstępne przetwarzanie danych - czyszczenie danych z szumu, usunięcie danych niepoprawnych itp.,
- c) redukcja i projekcja danych - wybór atrybutów relewantnych,
- d) określenie zadań eksploracji danych, tj. wybór typu poszukiwanych zależności,
- e) określenie metody eksploracji danych,
- f) eksploracja danych,
- g) interpretacja i ewaluacja odkrytej wiedzy.

Wyróżnia się dwa podstawowe zadania odkrywania wiedzy [24, 32, 90]:

- **analizę predykcyjną** - przewidywanie nieznanych lub przyszłych wartości pewnej określonej zmiennej na podstawie pozostałych zmiennych w badanym zbiorze danych,
- **analizę opisową** - wyszukiwanie wzorców opisujących i podsumowujących dane, co pozwala na lepszą interpretację odkrywanych regularności.

W odróżnieniu od *uczenia maszynowego*, gdzie pozyskiwana jest wiedza wcześniej odkryta, automatyczne odkrywanie wiedzy pozwala na pozyskiwanie nowej, jeszcze nie znanej porcji wiedzy [103]. Celem tej metody jest identyfikacja regularności, jakie mogą występować w zbiorze danych [60] określanych mianem wzorców oraz zakresów, dla których taki wzorzec obowiązuje [60, 102]. Wzorcami takimi mogą być m.in. tablice kontyngencji, równania, reguły asocjacyjne oraz równoważności logiczne. Zakres występowania wzorców jest ustalany na podstawie dekompozycji danych.

Jednym z pierwszych systemów odkrywania wiedzy diagnostycznej był system ENIGMA przeznaczony do odkrywania zależności przyczynowo - skutkowych między uszkodzeniami, jakie mogą występować w agregatach elektromechanicznych [29].

Prace z zakresu odkrywania wiedzy były także prowadzone przez J. Żytkowa oraz W. Moczulskiego [65]. Celem tych badań było odkrycie zależności funkcyjnych jakie występują w bazie danych, utworzonej w wyniku eksperymentu numerycznego. Wyznaczono w nim cechy sygnałów obserwowanych w wyróżnionych punktach układu wirnik-łożyska-podpory-fundament dla określonych typów niewyrównoważenia przy znanych warunkach działania układu. W wyniku badań odkryto układy równań przyczynowo-skutkowych pomiędzy zmiennymi wejściowymi a zmiennymi wyjściowymi [63, 64].

D. Wachła prowadził badania nad odkrywaniem zależności dynamicznych w bazach danych [98] z użyciem metod odkrywania zależności statystycznych połączonych z transformacją atrybutów poprzez ich projekcję w wielowymiarową przestrzeń regresorów oraz

selekcji atrybutów z zastosowaniem algorytmów genetycznych i metody wektorów wspomagających. Wcześniej prowadził on także badania nad odkrywaniem odwrotnych zależności dynamicznych z zastosowaniem metody dekompozycji macierzy SVD metodą Newtona-Raphsona [96], oraz algorytmów genetycznych [97].

2.4.1. Tablice kontyngencji

Tablice kontyngencji są formą reprezentacji zależności pomiędzy dwoma zmiennymi losowymi stosowaną powszechnie w statystyce [2].

Odkrywane tablice są oceniane za pomocą miary istotności Q , określonej jako prawdopodobieństwo losowego wygenerowania danego obrazu dla zmiennych (cech), które są niezależne. Jeżeli w tablicy kontyngencji występuje istotna zależność, to prawdopodobieństwo Q zdarzenia, że rozpatrywana zależność jest istotna, jest odpowiednio małe. Stwierdzono, że należy stosować wartości $Q < 10^{-5}$, czyli bardzo małe prawdopodobieństwo, że wykryte obrazy mogły powstać w sposób losowy. Większe wartości Q powodują, że system odkryć identyfikuje bardzo wiele regularności, wśród których jedynie nieliczne są faktycznie interesujące ze względu na małą wartość istotności. Powoduje to trudności dotyczące dalszego selekcjonowania regularności i wydłuża czas działania systemu odkryć [103].

Do wyznaczenia Q wykorzystywana jest statystyka χ^2 :

$$\chi^2 = \sum_{i,j} \frac{(A_{ij} - E_{ij})^2}{E_{ij}}, \quad (2.16)$$

gdzie:

A_{ij} - częstości z próby,

E_{ij} - częstości oczekiwane w przypadku prawdziwości hipotezy zerowej o braku jakichkolwiek zależności pomiędzy dwoma zmiennymi.

Rozkład E_{ij} z próby jest wyznaczany z następującej zależności:

$$E_{ij} = \frac{n_{x_i} \cdot n_{y_j}}{N}, \quad (2.17)$$

gdzie:

n_{x_i} - suma rekordów dla i -tej kolumny tablicy kontyngencji,

n_{y_j} - suma rekordów dla j -tego wiersza tablicy kontyngencji,

N - całkowita liczba rekordów.

Najczęściej istotność danej tablicy kontyngencji oceniana jest za pomocą:

- Miary Cramera V [102], określanej jako:

$$V = \sqrt{\frac{\chi^2}{N \cdot \min\{(M_{row} - 1), (M_{col} - 1)\}}} \in [0, 1]. \quad (2.18)$$

Im większa wartość miary V , tym bardziej unikalne zależności można uzyskać na podstawie rozpatrywanej tablicy kontyngencji. Ważną cechą miary V jest jej niezależność od rozmiarów tablicy oraz od liczby rekordów. Dla $V > 0.9$ zależność reprezentowana przez tablicę może być uznana za równoważność.

- Współczynnika kontyngencji C Pearsona [102]

$$C = \sqrt{\frac{\chi^2}{\chi^2 + N}}. \quad (2.19)$$

Współczynnik C może przyjmować wartości z przedziału liczbowego od 0 do 1 (gdy liczba pól w tablicy wzrasta do nieskończoności). Wartość C jest równa 0 jeżeli nie ma korelacji. Współczynnik C można stosować tylko do porównywania tablic o takich samych rozmiarach. Górna granica przedziału wartości współczynnika C zależy od liczby wierszy i kolumn w tablicy kontyngencji. Im wierszy i kolumn jest więcej, tym wartość współczynnika C jest większa, dlatego też otrzymaną z obliczeń wartość współczynnika C należy rozpatrywać w stosunku do jego wartości maksymalnej (C_{\max}) dla danej tablicy kontyngencji.

W przypadku tablicy kwadratowej maksymalna wartość współczynnika C wynosi:

$$C_{\max} = \sqrt{\frac{\{M_{row}, M_{col}\} - 1}{\{M_{row}, M_{col}\}}}. \quad (2.20)$$

Dla tablic prostokątnych przybliżoną maksymalną wartość współczynnika kontyngencji C można otrzymać ze wzoru:

$$C_{\max} = \frac{\sqrt{\frac{M_{row}-1}{M_{row}}} + \sqrt{\frac{M_{col}-1}{M_{col}}}}{2}. \quad (2.21)$$

Skorygowaną wartość współczynnika C obliczamy ze wzoru:

$$C_{kor} = \frac{C}{C_{\max}}. \quad (2.22)$$

- Współczynnika zbieżności Czuprowa

Współczynnik ten jest określany jako [83]:

$$T = \sqrt{\frac{\chi^2}{N \cdot \sqrt{(M_{row} - 1) \cdot (M_{col} - 1)}}}. \quad (2.23)$$

Przyjmuje on wartości z przedziału $[0, 1]$. Gdy $T = 0$, to badane atrybuty są stochastycznie niezależne, natomiast gdy $T = 1$, atrybuty są zależne funkcyjnie. Im współczynnik zbieżności jest bliższy zeru, tym zależność między atrybutami jest słabsza. Przy wyznaczaniu współczynnika zbieżności nie jest istotne, który atrybut traktuje się jako zależny, a który jako niezależny, co jest istotne przy badaniu zależności w sensie korelacyjnym. Tę właściwość współczynnika zbieżności określa

się mianem symetryczności [83]. Zaletą tego współczynnika jest to, że może być stosowany do mierzenia współzależności zarówno cech mierzalnych, jak i niemierzalnych. Jego wadą jest natomiast to, że nie wskazuje on kierunku korelacji (jest zawsze nieujemny).

2.4.2. Odkrywanie równań

Zależności wykryte przy zastosowaniu tablic kontyngencji służą następnie do poszukiwania równań. Równania te są poszukiwane w takim zbiorze danych, dla którego zachodzi następująca relacja funkcjonalności [62, 65]:

$$D \subset X \times Y,$$

$$D = \{(x_i, y_i) | x_i \in X \wedge y_i \in Y \wedge i = 1, \dots, N\},$$

$$\bigwedge_{x_i \in X} \bigwedge_{y_{i1}, y_{i2}} [(x_i, y_{i1}) \in D \wedge (x_i, y_{i2}) \in D \Rightarrow y_{i1} = y_{i2}].$$

Dla danego zbioru par zmiennych (atrybutów) y jest funkcją x wtedy i tylko wtedy, gdy dla każdego x_0 należącego do X istnieje tylko jedno y_0 , takie że (x_0, y_0) należy do D .

Równania umożliwiają określenie stanów, w jakich może znajdować się badany obiekt.

Poszukiwanie równań jest wykonywane w sposób automatyczny na podstawie pewnych określonych zbiorów reguł heurystycznych. Jednym z pierwszych systemów do takiego automatycznego odkrywania równań był system odkryć BACON [51–54] oparty na czterech regułach heurystycznych [6, 20]. Wprowadzono w nim już nowe zaawansowane heurystyki pozwalające na odkrywanie zależności wielomianowych oraz odkrywanie złożonych zależności, jeżeli występuje większa liczba zmiennych w badanym zbiorze danych.

2.4.3. Dynamiczne modele jakościowe

Jedną z metod modelowania jakościowego jest metoda zaproponowana przez B. Kuipersa zwana metodą QSIM (Qualitative SIMulation) [49, 50]. Metoda ta opiera się na jakościowych równaniach różniczkowych QDE (Qualitative Differential Equations) budowanych z wykorzystaniem ograniczeń jakościowych reprezentowanych za pomocą pewnych określonych predykatów (Tablica 2.1) oraz na podstawie danego układu równań różniczkowych opisujących modelowany obiekt.

Do jakościowego opisu systemu wymagana jest:

- zamiana reprezentacji dziedziny ilościowej na jakościową dla każdej z rozpatrywanych zmiennych systemowych $v : [a, b] \rightarrow R^2$,
- określenie stanów jakościowych $QS(v, t)$,
- określenie reguł definiujących sposób przejścia zmiennej jakościowej v z jednego stanu jakościowego QS do drugiego.

Tab. 2.1. Ograniczenia dla modeli jakościowych [49]

Predykat	Objaśnienie znaczenia
$\text{const}(v)$	zmienna v ma stałą wartość dla danego przedziału czasowego
$\text{deriv}(v_1, v_2)$	v_2 jest pochodną v_1
$\text{minus}(v_1, v_2)$	$v_1 = -v_2$
$\text{add}(v_1, v_2, v_3)$	$v_1 + v_2 = v_3$
$\text{mult}(v_1, v_2, v_3)$	$v_1 \cdot v_2 = v_3$
$M^+(v_1, v_2)$	v_1 rośnie monotonicznie razem z v_2
$M^-(v_1, v_2)$	v_1 maleje monotonicznie razem z v_2

W wyniku symulacji metodą QSIM zostaje utworzone drzewo stanów opisujących wszystkie możliwe jakościowe stany systemu. Drzewa stanów mogą być wykorzystane do modelowania działania obiektów. Podczas modelowania działania złożonych obiektów za pomocą metody QSIM uzyskuje się złożone struktury generowanych drzew. Za pomocą metody QSIM można także odkrywać jakościowe równania różniczkowe [23].

2.5. Baza wiedzy jako model procesu

Bazy wiedzy stanowią jeden z głównych elementów systemów doradczych [19, 33, 66]. W bazie tej zapisana jest wiedza dotycząca rozpatrywanej dziedziny. Wiedza zapisana w bazie może obejmować zarówno wiedzę deklaratywną (orzeczenia o faktach), jak i proceduralną (dotyczy działania obiektów i ogólnych sposobów postępowania). Wiedza może być pozyskiwana z różnych źródeł [60, 61] (specjaliści, bazy danych, wyniki badań symulacyjnych). Poniżej opisano środki reprezentacji wiedzy najczęściej stosowane do budowy baz wiedzy wykorzystywanych w diagnostyce technicznej.

2.5.1. Reguły diagnostyczne

W początkowym okresie rozwoju systemów doradczych najczęściej stosowano wnioskowanie bazujące na logice klasycznej. Baza wiedzy składa się wówczas z reguł zapisanych w postaci [17, 19]:

$$\text{JEŻELI } \textit{przesłanka} \text{ TO } \textit{konkluzja}, \quad (2.24)$$

gdzie *przesłanka* stanowi wyrażenie logiczne.

Przy wnioskowaniu na podstawie logiki klasycznej stosuje się dwa podstawowe schematy:

- *wnioskowanie w przód*: na podstawie dostępnych reguł i faktów generuje się nowe fakty tak długo, aż wśród wygenerowanych faktów znajdzie się postawiona hipoteza,
- *wnioskowanie wstecz*: polega na wykazaniu prawdziwości hipotezy głównej na podstawie prawdziwości przesłanek; rozpoczyna się od hipotezy i szuka dowodów na jej potwierdzenie lub odrzucenie, korzystając z reguł zgromadzonych w bazie wiedzy.

2.5.2. Przybliżone reguły diagnostyczne

Ponieważ źródłem wiedzy mogą być nie tylko dokładnie dające się określić prawa i fakty, gromadzona wiedza może również uwzględniać niedokładne opinie specjalistów, wyniki symulacji za pomocą przybliżonych modeli oraz niepewnych wyników obserwacji. Zastosowanie takiej wiedzy wymaga użycia przybliżonych reguł, przesłanek i konkluzji.

Najczęściej stosuje się dwie klasy przybliżonych metod wnioskowania, bazujących na [14]:

- koncepcji zbiorów i relacji rozmytych,
- różnych kategorii stopni pewności lub stopni prawdziwości elementów w postaci przesłanek, konkluzji lub reguł, określanych jako prawdopodobieństwa zdarzeń lub przekonania o tym, że dany element jest prawdziwy.

Stopnie prawdziwości reguł i przesłanek określa się zwykle na podstawie subiektywnych opinii specjalistów z rozpatrywanej dziedziny. Modyfikowanie stopni prawdziwości określane jest mianem strojenia systemu i jest przeprowadzane z wykorzystaniem odpowiednich zbiorów danych. Dla systemów, których bazy wiedzy zawierają bardzo liczne zbiory reguł przybliżonych, taki proces strojenia jest bardzo trudny do realizacji [14].

2.5.3. Drzewa decyzyjne

Przez drzewo decyzyjne [20] rozumie się strukturę złożoną z węzłów, z których wychodzą gałęzie prowadzące do innych węzłów lub liści. W drzewie decyzyjnym węzłom odpowiadają testy na wartościach atrybutów przykładów, a liściom przypisywane są kategorie. Dla każdego z możliwych wyników testu z węzła prowadzi odpowiadająca mu gałąź do pewnego poddrzewa. W ten sposób mogą być reprezentowane dowolne hipotezy dopuszczalne dla danego zestawu atrybutów.

Wyznaczenie kategorii przykładu za pomocą drzewa decyzyjnego polega na przejściu ścieżki od korzenia drzewa do jednego z jego liści, poprzez wykonywanie w odwiedzanych kolejno węzłach umieszczonych w nich testów i przemieszczanie się wzdłuż gałęzi odpowiadających uzyskiwanym wynikom [78].

Drzewa decyzyjne charakteryzują się następującymi cechami [20]:

- Mogą reprezentować złożone pojęcia, jeżeli ich definicje można wyrazić w zależności od atrybutów używanych do opisu przykładów. Za pomocą drzewa decyzyjnego może być reprezentowana dowolna dopuszczalna hipoteza;
- Umożliwiają efektywną implementację procesu klasyfikowania przykładów (stosowania hipotezy uzyskanej w wyniku uczenia się);
- Są stosunkowo łatwo zrozumiałą reprezentacją wiedzy dla człowieka (gdy ich rozmiary nie są zbyt duże i nie są złożone);
- Umożliwiają łatwe przejście od drzewa decyzyjnego do reprezentacji regułowej;
- W przypadku indukcji drzew decyzyjnych może dojść do nadmiernego dopasowania do danych trenujących. Nadmiernie dopasowane drzewo ma mały błąd próbki na zbiorze trenującym, lecz duży błąd rzeczywisty. Stosując zasadę brzytwy Ockhama błąd rzeczywisty nadmiernie dopasowanych drzew można zmniejszyć przez ich przycięcie (powiększając jednocześnie - zwykle nieznacznie - błąd klasyfikatora na zbiorze trenującym);
- Uzyskane po przycięciu drzewo będzie mniejsze i prostsze, co ułatwia interpretację przez człowieka, daje oszczędność pamięci i większą efektywność obliczeniową procesu klasyfikacji przez skrócenie ścieżek łączących korzeń drzewa z liśćmi;
- Złożone hipotezy, powodują że drzewa decyzyjne mogą być również złożone, co znacznie pogarsza ich zrozumiałość.

Istnieje wiele algorytmów uczenia wykorzystujących drzewa decyzyjne do reprezentacji hipotez dążących do uzyskania drzewa decyzyjnego klasyfikującego przykłady trenujące z niewielkim błędem próbki i o niewielkim rozmiarze tego drzewa.

Często stosowanym algorytmem indukcji drzew decyzyjnych jest ID3. Istotą algorytmu jest wybór atrybutów, dla których generowane są węzły, z uwzględnieniem kryterium maksymalnego przyrostu informacji. Szczegółowy opis algorytmu można znaleźć w [6, 77–79].

2.5.4. Sieci przekonań (Bayesa)

Sieci te stanowią jeden ze środków wykorzystywanych do wnioskowania przybliżonego bazującego na pojęciu prawdopodobieństwa warunkowego [45]. Wywodzą się one z metod statystycznych wnioskowania opartych o model Bayesa, teorię podejmowania decyzji oraz metody weryfikacji hipotez [21, 45]. Sieć przekonań jest acyklicznym grafem skierowanym, składającym się z węzłów (reprezentują one zmienne procesowe) oraz łączących je gałęzi skierowanych (reprezentują zależności pomiędzy tymi zmiennymi) [36, 37].

Sieci przekonań spotykają się z coraz większym uznaniem, jako skuteczne narzędzie stosowane do wnioskowania przybliżonego.

Wnioskowanie z zastosowaniem sieci przekonań polega na uzgadnianiu prawdopodobieństw przypisanych kolejnym węzłom, aż do wyznaczenia stanu równowagi sieci. Każdy

węzeł sieci może być wejściem procesu wnioskowania. Wnioskowanie może przebiegać dwukierunkowo od przyczyn do skutków i od skutków do przyczyn. Stosuje się także bardziej złożone schematy wnioskowania. Sieci przekonań znajdują zastosowanie m.in. w rozpoznawaniu obrazów [34] i diagnostyce technicznej [45] i medycznej. Duże znaczenie odgrywają w zagadnieniach sztucznej inteligencji związanych z wnioskowaniem przybliżonym [16].

Badania nad tymi sieciami prowadził M. Bednarski w ramach swojej pracy doktorskiej. Zajmował się on optymalizacją struktury sieci przekonań za względu na wpływ wrażliwości węzłów sieci na otrzymywane wyniki. Prowadzone przez niego badania miały też odniesienie do obiektu rzeczywistego jakim są reaktory nuklearne i związane z nimi zagadnienie ich bezpieczeństwa eksploatacji [4].

Sieci przekonań znalazły zastosowania między innymi w diagnostyce medycznej [55, 68], diagnostyce procesów [45] (w tym jako znaczący element wykorzystywany w systemach doradczych [81, 82] oraz robotyce [57, 58]).

2.5.5. Sieci stwierdzeń

W systemach przeznaczonych do wspomaganie diagnostyki technicznej bardzo przydatne jest zapisywanie reguł i przesłanek w postaci stwierdzeń [14].

Jako stwierdzenie określa się informację o uznaniu wypowiedzi orzekającej o obserwowanych faktach lub reprezentującej określoną opinię. Stwierdzenie s może zostać zapisane w postaci:

$$s = \langle c, b \rangle, \quad (2.25)$$

gdzie:

- c - treść stwierdzenia (wypowiedź, że wskazanemu obiektowi przysługuje określony atrybut o określonej wartości),
- b - wartość stwierdzenia określona jako stopień prawdziwości lub stopień przekonania o prawdziwości wypowiedzi będącej treścią stwierdzenia.

W modelu sieci stwierdzeń przyjmuje się, że stwierdzenia są punktami materialnymi, mogącymi się przemieszczać wyłącznie w kierunku pionowym (ich odległości w kierunku poziomym są zerowe) [14]. Wysokość, na jakiej zostały zlokalizowane poszczególne punkty odpowiada wartości stwierdzenia przypisanej do danego punktu. Wartość tej wysokości należy do przedziału $[0, 1]$. Stwierdzenia, które zostały uznane za w pełni prawdziwe, są reprezentowane przez punkty położone na wysokości równej 1, a uznane za fałszywe przez punkty położone na wysokości 0. Wnioskowanie w takim modelu sieci stwierdzeń polega na poszukiwaniu stanu równowagi, czyli minimalnej energii potencjalnej E (sumaryczny koszt sprzeczności jakie istnieją pomiędzy elementami bazy wiedzy interpretowany jako energia potencjalna rozpatrywanego zbioru punktów) [14].

Wnioskowanie w sieci stwierdzeń dynamicznych trzeba przedstawić natomiast jako poszukiwanie równowagi układu punktów materialnych o określonych położeniach, masach i bezwładnościach. Wnioskowanie jest prowadzone na podstawie propagacji zmian

wartości stwierżeń rozpatrywanych jako przemieszczenia oddziaływujących na siebie punktów materialnych o określonych masach. Szczegółowy opis zastosowania sieci stwierżeń można znaleźć w [14].

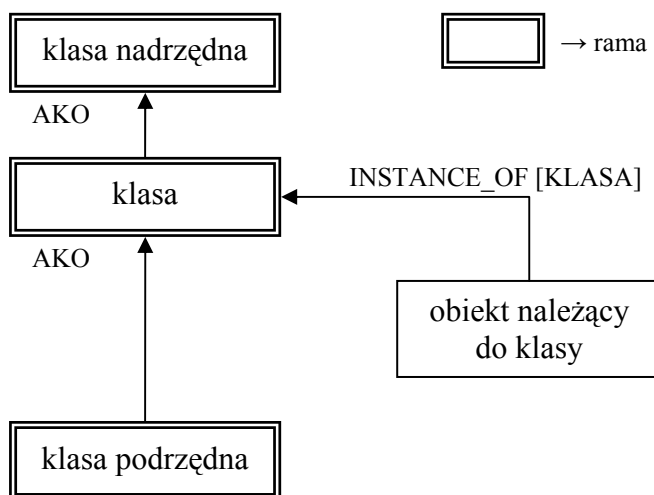
2.5.6. Ramy

Zastosowanie ram (ang. frame) pozwala na uogólnianie, klasyfikowanie oraz generowanie klas abstrakcji w porównaniu do klasycznego opisu obiektu za pomocą trójki uporządkowanej (*obiekt-atrybut-wartość*). Pojęcie ram po raz pierwszy zaproponował Minsky dla określenia schematu logicznego baz wiedzy pozwalających na realizowanie wnioskowania zdroworozsądkowego [17].

Ramy są sposobem opisu obiektu wiążącym wiedzę deklaratywną i proceduralną o obiekcie. Zawierają one:

- **sloty** - reprezentujące atrybuty przysługujące obiektom,
- **fasety** - związane z wartościami, w tym wartościami domyślnymi i/lub procedurami (demonami) pozwalającymi na wyznaczenie tych wartości.

Elementy ram są identyfikowane przez ich nazwy, co oznacza konieczność stosowania nazw indywidualnych i lokalnie unikalnych (dla rozpatrywanego slotu) [17]. Globalna unikalność nie jest wymagana. Zastosowanie ram pozwala na uzyskanie wysokiej efektywności procesu obliczeń. Ramy można porządkować w struktury hierarchiczne przez wprowadzenie powiązań nazywanych ISA (ang. is a) lub AKO (ang. a kind of) co powoduje dziedziczenie przez ramy podrzędne. Dziedziczenie pozwala na eliminację nadmiarowości danych, kodów programów. Pozwala ono także na wprowadzanie wartości domyślnych, zastępujących niekompletne dane wejściowe.



Rys. 2.1. Schemat struktury hierarchicznej [17]

Proste struktury ram są drzewami (czas poszukiwań rośnie liniowo ze wzrostem liczby węzłów), a dla złożonych struktur ram trzeba określić odpowiednie wyznaczania wartości slotów (czas ten rośnie wykładniczo ze wzrostem liczby węzłów) [17].

2.6. Modele wartości szeregów czasowych cech sygnałów diagnostycznych

Szeregi czasowe są sekwencjami wartości symptomów diagnostycznych zapisanymi w postaci uporządkowanej w czasie makro [17]. Uporządkowanie zachodzi w dziedzinie czasu. Warunkiem koniecznym dla określenia szeregu czasowego jest istnienie zmiennej lub funkcji porządkującej taki szereg oraz zachowanie stałości kroku czasowego Δt . Jako krok czasowy jest rozumiana „odległość” dwóch kolejnych elementów szeregu w dziedzinie zmiennej indeksującej (2.26):

$$x_j = x(j\Delta t) \quad (2.26)$$

Wynika to z tego, że wyprzedzenie czasowe obliczanej prognozy może być wyłącznie całkowitą krotnością kroku czasowego. W badaniach diagnostycznych wybór wielkości kroku czasowego w szeregach wartości symptomów ma wpływ na [17] licznosc zbiorów gromadzonych danych, zwłaszcza gdy rozpatruje się większą liczbę symptomów oraz występują długie (względem przyjętego kroku) cykle działania obiektu.

Szeregi czasowe przeznaczone do badań tworzone są z danych pozyskiwanych poprzez:

- ciągłe przetwarzanie analogowo-cyfrowe sygnałów rejestrowanych przez czujniki,
- przetwarzanie zarejestrowanych sygnałów analogowych technikami cyfrowymi,
- generowanie danych z modelu obiektu lub procesu.

Elementami szeregów czasowych są liczby stanowiące dyskretne wartości analizowanych zmiennych procesowych w poszczególnych odpowiednich chwilach czasu - krokach czasowych.

Do modelowania szeregów czasowych stosuje się najczęściej klasę liniowych modeli, określanych jako modele autoregresji i/lub średniej ruchomej (ARMA) [17, 42], nieliniowych modeli regresyjnych NARMA, modeli regresyjnych liniowych (ARMAX) i nieliniowych (NARMAX) dla procesów dynamicznych.

Metoda ta została zaproponowana przez Boxa i Jenkinsa [11] w latach siedemdziesiątych 20. wieku i była intensywnie rozwijana w latach następnych. Istotą tej metody jest możliwość traktowania dowolnego szeregu czasowego jako opisu wyjścia filtru liniowego Yule'a, wzbudzanego przez wejściowy szereg czasowy, będący dyskretną reprezentacją procesu typu biały szum [17].

Zgodnie z założeniem przyjętym przez Boxa i Jenkinsa, element y_t „wyjściowego” szeregu czasowego Y_t jest przedstawiany jako liniowa kombinacja skończonej liczby p elementów $\{y_{t-1} : i = 1, \dots, p\}$ szeregu czasowego Y_t i/lub skończonej liczby q elementów $\{\varepsilon_{t-j} : j = 1, \dots, q\}$ „wejściowego” szeregu czasowego E_t , ważonych przez wartości odpowiednich współczynników (2.27):

$$y'_t = a_1 y'_{t-1} + \dots + a_p y'_{t-p} + \varepsilon_t - b_1 \varepsilon_{t-1} - \dots - b_q \varepsilon_{t-q} \quad (2.27)$$

gdzie:

$$y'_t = y_t - \bar{y},$$

\bar{y} - wartość średnia w szeregu czasowym Y_t ,

$a = \{a_1, a_2, \dots, a_p\}$ - macierz wartości współczynników autoregresji (AR) w modelu ARMA,

$b = \{b_1, b_2, \dots, b_q\}$ - macierz wartości współczynników średniej ruchomej (MA) w modelu ARMA.

Model ARMA (p, q) jest stosowany do modelowania stacjonarnych procesów losowych $Z(t)$. W przypadku procesów niestacjonarnych stosuje się model ARIMA (p, d, q) (ang. AutoRegressive Integrated Moving Average), w którym użyto operatora różnicowego ∇ stopnia $d > 0$ do przekształcenia szeregu $Y(t)$ w $Z_{t,d}$ (2.28):

$$z'_{t,d} = a_1 z'_{t-1,d} + \dots + a_p z'_{t-p,d} + \varepsilon_t - b_1 \varepsilon_{t-1} - \dots - b_q \varepsilon_{t-q} \quad (2.28)$$

gdzie:

$$z'_{t,d} = z_{t,d} - \bar{z},$$

\bar{z}_d - wartość średnia w szeregu czasowym $Z_{t,d}$.

Aby wygenerować model ARMA/ARIMA (Rys. 2.2) dla danego szeregu czasowego należy przeprowadzić [42]:

1. **Identyfikację parametrów** modelu ARMA/ARIMA szeregu czasowego Y_t za pomocą funkcji autokorelacji i autokorelacji częściowej,
2. **Estymację współczynników** modelu ARMA/ARIMA poprzez rozwiązanie układu równań normalnych (równań liniowych Yule'a-Walkera),
3. **Testowanie** modelu polegające na sprawdzeniu, czy w szeregu czasowym reszt (różnic między rzeczywistymi wartościami elementów analizowanego szeregu czasowego i wartościami wyliczonymi z modelu) nie występuje stała tendencja dodatnia lub ujemna.

Do modelowania nieliniowości układów dynamicznych stosuje się nieliniowy model regresyjny NARMAX, który dla układu o jednym wejściu i jednym wyjściu może być określony jako (2.29) [94]:

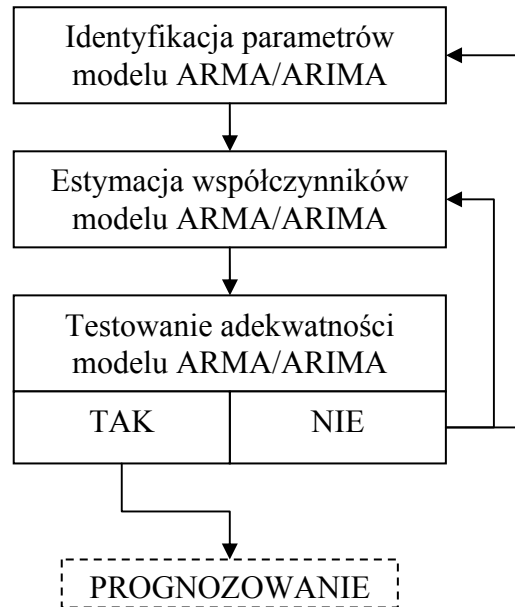
$$y(k) = \alpha + F_l \left((y(k-1), \dots, y(k-n_y), u(k-1), \dots, u(k-n_x), \varepsilon(k-1), \dots, \varepsilon(k-n_\varepsilon)) \right) + \varepsilon(k) \quad (2.29)$$

gdzie:

$u(k), y(k), \varepsilon(k)$ - próbkowane wejście, wyjście i błąd predykcji,

l - stopień nieliniowości,

α - stała,



Rys. 2.2. Schemat algorytmu budowy modeli ARMA/ARIMA szeregu czasowego [17]

F_l - nieliniowa funkcja o dowolnej postaci, zwykle będąca wielomianem o stopniu > 1 .
Postać tej funkcji musi zostać określona na początku procesu identyfikacji modelu.

Zaletą modelowania typu NARMAX w porównaniu do modelowania typu ARMA jest uwzględnienie przeszłych wyjść $y(k)$ i wejść $u(k)$ w postaci funkcji nieliniowych [94]. Metoda ta dostarcza także informacji o modelu zakłóceń. Modelowania NARMAX nie stosuje się dla modeli o nieciągłych charakterystykach elementów strukturalnych (np. tarcie suche, luz) [94].

Bardzo prostym środkiem modelowania szeregów czasowych jest średnia ruchoma. Jest ona stosowana do ukazywania powolnych, regularnych i systematycznych zmian określonego zjawiska w czasie, wynikających z działania przyczyny głównej. Przy badaniu z wykorzystaniem średniej ruchomej wyniki są tym pewniejsze, im dłuższy jest analizowany okres.

W literaturze [17, 42] można znaleźć wiele różnie zdefiniowanych średnich ruchomych:

- **prosta średnia ruchoma** (ang. Simple Moving Average) jest wyliczana na podstawie poniższej zależności z N kolejnych pomiarów:

$$\bar{y} = \frac{1}{N}(y_{(0)} + y_{(-1)} + \dots + y_{(-N+1)}); \quad (2.30)$$

- **liniowo ważona** średnia ruchoma (ang. Weighted Moving Average) - waga zmienia się wprost proporcjonalnie ze wzrostem N :

$$\bar{y} = \frac{y_{(0)} \cdot N + y_{(-1)} \cdot (N - 1) + \dots + y_{(-N+1)} \cdot 1}{N + (N - 1) + \dots + 1}; \quad (2.31)$$

- **wykładnicza średnia ruchoma** (ang. Exponential Moving Average) - jest modyfikacją liniowo ważonej średniej (wagi nie zmieniają się liniowo):

$$\bar{y} = \frac{y(0) + a \cdot y(-1) + a^2 \cdot y(-2) \dots + a^{(N-1)} \cdot y(-N+1)}{1 + a + a^2 + \dots + a^{(N-1)}} \quad (2.32)$$

gdzie $a > 1$.

2.7. Podsumowanie

W rozdziale omówiono grupy metod modelowania mających najszersze pole zastosowań w diagnostyce technicznej. Przedstawiono krótkie opisy najważniejszych rodzajów modeli procesów stosowanych do opisu związków pomiędzy sygnałami diagnostycznymi i uszkodzeniami oraz inne metody modelowania bazujące na sekwencjach zdarzeń, metodach odkrywania wiedzy w bazach danych, metodach budowy baz wiedzy stosowanych do modelowania procesów oraz metodach modelowania szeregów czasowych.

Istniejące problemy oraz pojawiające się nowe zadania w tej dziedzinie wymagają dużej wiedzy specjalistycznej, by dokonać odpowiedniego wyboru i zastosowania jednej z opisanych metod modelowania. Rozwiązanie wielu problemów wymaga zastosowania kilku połączonych metod modelowania w celu jak najlepszego opisanego obiektu. Przysparza to sporych trudności podczas implementacji takich modeli złożonych i często wymaga współpracy kilku specjalistów z danej dziedziny.

Każda z przedstawionych metod ma zalety, ale także wady. Zalety dotyczą przede wszystkim efektów modelowania, jakie można uzyskać stosując daną metodę. Możliwości obliczeniowe wielu metod są bardzo duże, a jakość dopasowania uzyskanych w wyniku nich modeli jest wysoka. Wady odnoszą się głównie do trudności właściwej identyfikacji i estymacji parametrów tych metod modelowania. Mniejszy wpływ mają możliwości obliczeniowe stosowanych komputerów. Im większa złożoność problemu, tym większe wymagania związane z przechowywaniem danych i wyników (hurtownie danych o ogromnych rozmiarach) oraz szybkości działania oprogramowania w danym środowisku programowym i sprzętowym.

Istniejące metody wymagają niekiedy wielkich nakładów obliczeniowych. Przy ograniczonej liczbie przykładów nie uzyskuje się modeli wystarczająco reprezentatywnych dla danych nieuwzględnionych w procesie uczenia. Istnieją także trudności z modelowaniem zjawisk dynamicznych.

Z tych powodów zdecydowano się na wybór wnioskowania CBR i inną grupę modeli, bazujących na opisie wielowymiarowych przebiegów cykli za pomocą stosunkowo ogólnych środków reprezentacji. Metody te mają swoje ograniczenia - mogą być stosowane tylko do diagnostyki procesu ze względu na mniejszą dokładność identyfikowanych modeli. Autor postanowił podjąć badania w zakresie rozwoju nowych metod, umożliwiających budowę modeli stosunkowo prostych, lecz reprezentujących istotne własności sygnałów.

Opracowane przez autora nowe metody modelowania procesów wolnozmiennych zostaną przedstawione w dalszej części rozprawy.

Rozdział 3

Cel, teza i zakres rozprawy

Współczesne systemy monitorowania procesów przemysłowych i obiektów o charakterze krytycznym gromadzą zwykle wielkie ilości danych. Są nimi wartości atrybutów wejścia (wymuszenia) i wyjścia (odpowiedzi) oraz niektóre atrybuty stanu. Wiadomo, że dane te mogą być nośnikiem użytecznych informacji dotyczących sposobu sterowania obiektem lub procesem. Szybko rosnące rozmiary zbiorów danych wymuszają opracowanie i stosowanie coraz bardziej zaawansowanych technik przetwarzania danych w celu uzyskania jak największej ilości informacji. W ramach badań prowadzonych w Katedrze Podstaw Konstrukcji Maszyn Politechniki Śląskiej w zakresie wnioskowania diagnostycznego realizowanego w inteligentnych systemach monitorowania i diagnostyki maszyn i procesów stwierdzono, że istnieje potrzeba opracowania odpowiednich metod modelowania procesów wolnozmiennych. Metody te umożliwiłyby budowę modeli pozwalających na efektywne diagnozowanie maszyny lub procesu.

3.1. Cel pracy

Celem opisanych badań było opracowanie metod przetwarzania i analizy danych pochodzących ze złożonego wolnozmiennego procesu przemysłowego, w wyniku zastosowania których można byłoby otrzymać modele tego procesu. Uzyskane modele winny umożliwić poprawę jakości sterowania tym procesem poprzez dostarczenie operatorom procesu nowych użytecznych informacji dotyczących zależności zachodzących pomiędzy zmiennymi tego procesu.

Głównym wymaganiem odnośnie opracowywanych metod było spełnienie przez uzyskiwane modele warunku wyprowadzonego z kryterium sterowalności, mówiącego że: "dla dostatecznie podobnych wejść/stanów i wystarczająco podobnego sterowania uzyskuje się dostatecznie podobne wyjście" [87].

Opracowane metody winny stanowić logicznie ze sobą powiązane sekwencje stadiów dla wybranych i stosowanych sposobów oraz algorytmów przetwarzania danych. Metody powinny umożliwiać działania w sposób automatyczny lub z niewielkim udziałem specjalisty, nadzorującego proces pozyskiwania wiedzy o sterowaniu procesem lub obiektem. Wejściem procesu pozyskiwania wiedzy są dane pochodzące z obiektów rzeczywistych.

3.2. Teza

Opracowane metody globalnego modelowania procesów wolnozmiennych umożliwiają budowę bazy wiedzy, która może być zastosowana do wnioskowania diagnostycznego bazującego na przykładach (CBR).

3.3. Zakres rozprawy

Praca obejmuje opisy metod identyfikacji modeli procesów wolnozmiennych dla potrzeb diagnostyki technicznej. W pierwszym rozdziale zawarto krótkie wprowadzenie do tematyki omawianej w pracy oraz opisano problem badawczy, jakim jest potrzeba opracowania nowych, prostych w zastosowaniu metod identyfikacji modeli procesów wolnozmiennych. Do identyfikacji mogą być wykorzystane dane archiwalne gromadzone w przemysłowych bazach danych.

W rozdziale drugim przedstawiono przegląd istniejących metod modelowania procesów, które znajdują szerokie zastosowanie w diagnostyce procesów przemysłowych i diagnostyce obiektów (maszyn i urządzeń). W rozdziale omówiono metody identyfikacji modeli odpowiednie do zastosowania w przypadku procesów wolnozmiennych. Do przeprowadzenia przeglądu przyjęto podział modeli według klasyfikacji stosowanej w diagnostyce procesów przemysłowych.

Rozdział czwarty zawiera opisy opracowanych w ramach pracy metod identyfikacji modeli procesów wolnozmiennych. Opisy te mają charakter ogólny. Przedstawiono założenia przyjęte w odniesieniu do danych pochodzących z procesów lub obiektów, które mogą być analizowane z zastosowaniem omawianych metod. W dalszej części rozdziału przedstawiono poszczególne stadia opracowanych metod. Omówiono sposób normalizacji analizowanych cykli procesowych oraz sposoby definiowania miary podobieństwa pomiędzy poszczególnymi cyklami. W końcowej części rozdziału opisano sposób modyfikacji rozkładu wartości podobieństw oraz przedstawiono zastosowanie algorytmu ewolucyjnego do określania wag istotności dla badanych parametrów procesowych.

W rozdziale piątym przedstawiono opis weryfikacji opracowanych metod na podstawie danych pochodzących z istniejącego obiektu przemysłowego. W pierwszej części rozdziału przedstawiono plan badań weryfikacyjnych opracowanych metod. Następnie opisano dostępną bazę danych, którą wykorzystano do weryfikacji, oraz przedstawiono dane wybrane do procesu weryfikacji. W kolejnej części rozdziału omówiono założenia przyjęte dla potrzeb weryfikacji względem wybranych danych oraz przeprowadzono szczegółową weryfikację działania poszczególnych opracowanych metod. W dalszej części rozdziału przedstawiono wyniki weryfikacji opracowanych metod oraz oceny skuteczności działania opracowanych metod względem przyjętych założeń. Rozdział kończy podsumowanie wyników przeprowadzonej weryfikacji.

W ostatnim rozdziale zawarto podsumowanie badań przeprowadzonych w ramach pracy doktorskiej, wnioski płynące z przeprowadzonych badań oraz kierunki przyszłych badań.

Rozdział 4

Metody pozyskiwania wiedzy z bazy danych procesowych

W poniższym rozdziale przedstawione zostały opracowane metody identyfikacji modeli procesów wolnozmiennych [91–93]. Metody te przeznaczone są dla procesów wolnozmiennych o cyklicznym charakterze.

4.1. Charakterystyka rozpatrywanych danych procesowych

Przy opracowaniu metod pozyskiwania wiedzy przyjęto, że wejściem procesu pozyskiwania wiedzy są odpowiednio liczne dane, mogące być nośnikami informacji o niektórych wejściach (w tym sterowaniach), stanach i wyjściach procesu. Obiekty lub procesy winny charakteryzować się następującymi cechami:

1. Ze względu na obiekt:
 - a) Proces jest sterowalny, z czego wynika że dla podobnych wejść da się określić podobne sterowania dla których otrzymuje się podobne wyjścia.
 - b) Sterowanie obiektem lub procesem ma charakter cykliczny dający się zidentyfikować (co najmniej w przybliżeniu) na podstawie dostępnych danych.
 - c) Cykle mogą składać się z faz.
 - d) Liczba powtarzalnych faz przypadających na pojedynczy cykl jest dowolna, ponieważ za pomocą opracowanych metod można identyfikować modele na podstawie całych cykli jak i w rozbiciu tych cykli na fazy. Konieczne jest, aby liczba tych faz była taka sama dla każdego badanego cyklu.
 - e) Czasy trwania poszczególnych faz cykli lub całych cykli mogą być różne.
 - f) Liczba atrybutów opisujących sposób sterowania obiektem lub procesem może być znaczna, gdyż do identyfikacji wybiera się atrybuty na podstawie wcze-

śniejszej ich klasyfikacji przeprowadzonej np. przy udziale specjalisty w danym zakresie lub za pomocą odpowiednich metod analizy danych (np. PCA).

g) Wartości poszczególnych atrybutów zmieniają się czasie trwania procesu.

2. Ze względu na dane:

a) Istnieje zbiór atrybutów wejściowych i wyjściowych opisujących wejścia i wyjścia obiektu lub procesu, w postaci danych ilościowych (i ew. jakościowych) zgromadzonych w bazie danych archiwalnych.

b) Dane dotyczące sterowań, stanów i wyjść reprezentowane są w postaci szeregów czasowych zdyskretyzowanych wartości, mierzonych przez analogowe czujniki wielkości fizycznych.

c) Dla sygnałów ciągłych, odpowiadających zmiennym procesowym, krok dyskretyzacji jest stały, a jego długość i sposób wyznaczenia wartości dyskretnej dobrane zostały odpowiednio do tego, aby możliwe było odtworzenie istotnych zmian sygnału w funkcji czasu.

d) Wartości atrybutów procesowych mogą być określane dyskretnie w chwilach rozpoczęcia realizacji cyklu, a także w chwilach podczas trwania tego cyklu, przy czym chwile określania tych wartości mogą wynikać np. z realizowanego procesu technologicznego (dotyczy to atrybutów, których wartości określane są w wyniku pomiarów lub obserwacji prowadzonych sporadycznie podczas trwania danego cyklu procesu).

e) Istnieje informacja pośrednia (liczba próbek pomiarowych) lub bezpośrednia (dodatkowy atrybut) o czasie trwania poszczególnych faz lub całych cykli.

f) Dopuszczalne jest występowanie typowych błędów w szeregach czasowych, jak: przekłamania pojedynczych wartości, spowodowane błędnym działaniem części analogowej toru pomiarowego lub toru transmisji sygnału cyfrowego (lub pamięci/nośnika danych), brak wartości atrybutu itp.

g) W celu zastosowania opracowanych metod konieczne jest pozyskanie odpowiednio licznego i kompletnego zbioru danych archiwalnych.

Omówione metody pozwalają na zbudowanie bazy modeli przebiegów atrybutów procesowych. Do budowy bazy modeli, mającej charakter bazy wiedzy systemu doradczego wykorzystującego rozumowanie oparte na przypadkach, stosuje się dane zgromadzone w archiwalnych bazach danych. Rozumowanie bazujące na przypadkach wymaga określenia miar podobieństwa. Wyznaczone miary podobieństw mogą zostać zastosowane do wyboru sposobu sterowania procesem w celu usprawnienia sposobów sterowania stosowanych przez obsługę na podstawie określonych kryteriów.

Zaproponowane metody identyfikacji modeli mogą być stosowane także do identyfikowania modeli obiektów (omówione w rozprawie metody mają charakter ogólny). Istotne jest aby charakterystyka modelowanego obiektu była zgodna z przyjętymi dla omawianych metod założeniami dotyczącymi obiektów i danych z nich pochodzących. Np. możliwe

jest za pomocą tych metod opracowanie bazy wzorców zużywania się zmęczeniowego obiektu, rozwoju uszkodzenia i innych. Dla takiego przypadku cykl byłby rozumiany jako okres życia jednego obiektu danego typu. Cykl działania obiektu może być też rozumiany jako cykl roboczy działania tego obiektu (np. proces toczenia elementu, zużywanie się narzędzia itp.) lub dla celów diagnostyki kontrolnej jako np. rozruch silnika elektrycznego małej mocy. Wymagane byłoby posiadanie archiwalnej bazy danych dla rozpatrywanego typu obiektu z zarejestrowanymi zmianami stanu odpowiednio licznej i reprezentatywnej grupy takich obiektów.

4.2. Wybór atrybutów i przygotowanie danych do przeprowadzenia badania

Zastosowanie opracowanych metod wymaga w pierwszej kolejności odpowiedniego przygotowania danych zgromadzonych w bazie danych archiwalnych oraz wyboru atrybutów mających największy wpływ na sposób sterowania obiektem lub procesem.

Przyjęto, że dane z bazy danych archiwalnych wybrane do badań winny spełniać poniższe wymagania:

- Zgromadzone zbiory danych powinny charakteryzować się kompletnością danych dla poszczególnych atrybutów w dziedzinie czasu.
- Zarejestrowane okresy pracy obiektu (np. pomiędzy remontami) winny być jak najdłuższe. Duża liczba zapisanych cykli następujących po sobie pozwala prowadzić badania uwzględniające długoczasowe zmiany stanu obiektu, wpływ różnego rodzaju zakłóceń itp.
- Zapisane dane powinny być danymi numerycznymi (ilościowymi).
- Liczba zapisanych kompletnych cykli (jednakowa dla analizowanych atrybutów) winna być jak największa.
- Powinny być spełnione założone wcześniej wymagania dla poszczególnych cykli dotyczące ich stałej struktury (liczba faz) dla każdego cyklu.

Dla atrybutów procesowych wybranych do badań zmiana wartości atrybutu niezależnego powinna powodować proporcjonalnie dużą zmianę wartości atrybutu zależnego w podobnym okresie czasu.

Do badań z zastosowaniem opracowanych metod można wybrać atrybuty z różnych klas parametrów procesowych (np. parametry elektryczne, wartości temperatur, wartości ciśnień).

4.3. Normalizacja czasowa przebiegów ciągłych parametrów procesowych

Normalizacja czasowa dotyczy sposobu rozwiązania problemu związanego z koniecznością porównywania cykli lub faz cykli o różnych czasach trwania.

W przypadku rozpatrywania cykli złożonych z powtarzających się faz zaproponowano, że normalizacja czasowa będzie dotyczyła cząstkowych faz poprzez wyznaczenie przyjętego parametru podziałki dla każdej z faz na podstawie poniższej zależności:

$$PodzT^n(j, k) = \frac{T^n(j)}{T^n(k)} \quad (4.1)$$

gdzie:

k - indeks cyklu porównywanego,

j - indeks cyklu odniesienia, wzorcowego (cyklu względem którego porównujemy),

n - indeks fazy cyklu,

$PodzT^n(k, j)$ - podziałka czasowa pomiędzy poszczególnymi cyklami o indeksach (k, j) dla danej fazy cyklu o indeksie n ,

$T^n(j); T^n(k)$ - czas trwania cyklu porównywanego o indeksie (j) oraz cyklu odniesienia lub cyklu wzorcowego o indeksie (k) dla danej fazy cyklu o indeksie n .

Jeżeli rozpatrujemy cały cykl, wówczas wartość n przyjmuje się równą 0.

Zastosowanie tak zdefiniowanej podziałki powoduje, że:

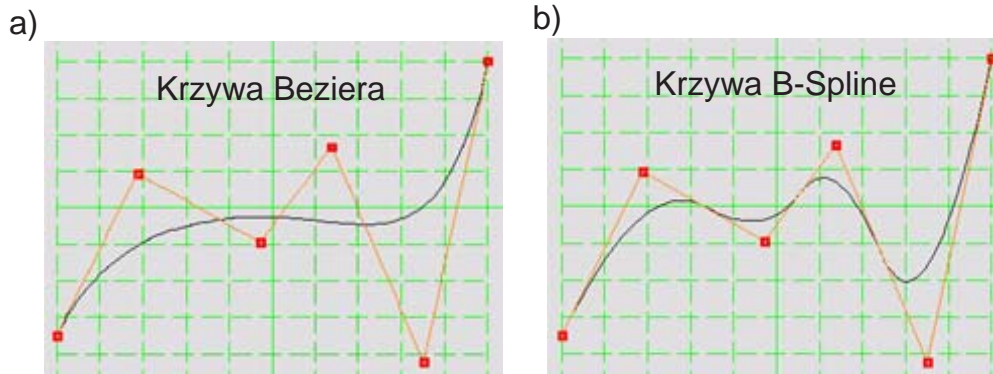
- Dla cykli lub faz dłuższych od wzorca uzyskano podziałkę mniejszą od 1,
- Dla cykli lub faz krótszych od wzorca uzyskano podziałkę większą od 1 (zmniejszenie częstotliwości próbkowania wartości atrybutu).

Efekt zwiększenia lub zmniejszenia częstotliwości próbkowania badanych cykli poprzez wprowadzenie ustalonej podziałki odnosi się do aproksymacji danych dla badanych cykli (porównywanego i odniesienia), powodując stałą liczbę punktów aproksymujących dany cykl (lub jego określoną fazę) w grupie badanych cykli.

4.4. Sposoby wielomianowej aproksymacji przebiegów

W celu przybliżonej reprezentacji cykli dla atrybutów procesowych zdecydowano się na zastosowanie dwóch różnych metod aproksymacji (Rys. 4.1):

- krzywe Beziera (krzywe swobodne) Rys. 4.1a [38, 80],
- krzywe typu B-Spline (krzywe paraboliczne) Rys. 4.1b [38, 56].



Rys. 4.1. Krzywe wybrane do aproksymacji wielomianowej

Metody te zostały wybrane ze względu na łatwość ich implementacji programowej oraz dużą liczbę dostępnych publikacji opisujących ich zastosowanie. Istnieje wiele dostępnych opisów algorytmów ich stosowania a procedury, w których zastosowano metody aproksymacji tymi krzywymi do opisu cykli, cechują się dużą szybkością działania.

Ze względu na wartość podziałki, liczbę punktów aproksymujących poszczególne cykle można przyjmować zgodnie z jednym z poniższych rozwiązań:

1. Liczba ta może być ustalona globalnie np. na podstawie analizy zbioru badanych cykli.
2. Liczba ta może być przyjmowana indywidualnie dla każdej pary porównywanych cykli. Dla tak dobranej liczby punktów aproksymujących porównywane cykle dostajemy najlepsze przybliżenie obu cykli.

Przedstawiony powyżej sposób doboru liczby punktów aproksymujących przebiegi obowiązuje zarówno gdy rozpatrujemy cykle jako całość, jak i gdy rozpatrujemy każdą fazę cyklu osobno.

4.5. Metoda określania podobieństw bazująca na mierze euklidesowej dla odległości bezwzględnej

Przedstawiona metoda służy do określania wartości podobieństw pomiędzy porównywanymi cyklami z zastosowaniem miary bazującej na odległości Euklidesa [18]. Odległości wyznaczone są na podstawie wzoru ogólnego:

$$D_2(X, Y) = \left[\sum_{j=1}^N (X_j - Y_j)^2 \right]^{\frac{1}{2}}, \quad (4.2)$$

który dla zadanego problemu w granicach poszczególnych faz przebiegów przyjął następującą postać:

$$D_{2i}^n(k, j) = \left[\sum_{p=1}^P (Y(k)_{p,i}^n - Y(j)_{p,i}^n)^2 \right]^{\frac{1}{2}}, \quad (4.3)$$

gdzie:

i - indeks atrybutu procesowego,

p - indeks punktu aproksymującego cykl ($p = 1 \dots P$),

P - liczba punktów aproksymujących fazę, dla której jest obliczana odległość euklidesowa,

$D_{2i}^n(k, j)$ - odległość euklidesowa określana dla danego atrybutu o indeksie i dla danej fazy cyklu o indeksie n pomiędzy wykresami cykli o indeksach (k, j) ,

$Y(k)_i^n; Y(j)_i^n$ - wartości danego atrybutu o indeksie i w poszczególnych punktach aproksymacji dla cykli o indeksach (k, j) i danej fazy cyklu o indeksie n .

Pojęcie odległości bezwzględnej i względnej dotyczy sposobu wyznaczania wartości odległości pomiędzy poszczególnymi punktami aproksymującymi przebiegi wartości atrybutów. Tutaj są one wyznaczone jako różnice wartości współrzędnych tych punktów (próbek) w przyjętym układzie odniesienia. W przypadku odległości bezwzględnej dotyczy ono sposobu wyznaczania wartości odległości pomiędzy poszczególnymi odpowiadającymi sobie punktami aproksymującymi dwóch porównywanych cykli, a w przypadku odległości względnej dotyczy ono sposobu wyznaczania odległości pomiędzy poszczególnymi kolejnymi punktami aproksymującymi dany cykl.

Na podstawie tak wyznaczonej odległości euklidesowej określa się wartości podobieństw pomiędzy cyklami o indeksach (k, j) dla danego atrybutu o indeksie i oraz danej fazy cyklu o indeksie n na podstawie zdefiniowanej poniżej miary podobieństwa (4.4):

$$\begin{aligned} \Pi_i^n(k, j) &= 1 - \frac{D_{2i}^n(k, j)}{\max(D_{2i}^n(k, j))} && \text{dla } \max(D_{2i}^n(k, j)) \neq 0, \\ \Pi_i^n(k, j) &= 1 && \text{dla } \max(D_{2i}^n(k, j)) = 0, \end{aligned} \quad (4.4)$$

gdzie:

Π_i^n - podobieństwo pomiędzy poszczególnymi cyklami o indeksach (k, j) w obrębie danej fazy cyklu o indeksie n dla danego atrybutu o indeksie i ,

$\max(D_{2i}^n(k, j))$ - największa odległość euklidesowa dla danego atrybutu o indeksie i oraz danej fazy cyklu o indeksie n dla cykli o indeksach (k, j) .

Wartość $\max(D_{2i}^n(k, j))$ jest największą wartością odległości wyznaczoną pomiędzy cyklem odniesienia i cyklami porównywanymi w zbiorze badanych cykli.

Zastosowana miara określania podobieństwa jest jedną z wielu możliwości wyznaczania wartości podobieństw pomiędzy cyklami na podstawie wyznaczonych wartości odległości. Można zauważyć, że wprowadzona miara określania podobieństw daje liniową zmianę wartości podobieństw w funkcji odległości. Taka prosta miara podobieństwa została przyjęta dla ułatwienia późniejszej modyfikacji podobieństw za pomocą funkcji opisanych w rozdziale 4.8.

Dla tak wyznaczonych wartości podobieństw dla poszczególnych faz porównywanych cykli określa się wartości podobieństw całkowitych na podstawie zależności:

$$\begin{aligned} \Pi C_i(k, j) &= \frac{1}{N} \sum_{n=1}^N w_n \cdot \Pi_i^n(k, j), \\ \sum_{n=1}^N w_n &= N, \end{aligned} \quad (4.5)$$

gdzie:

$\Pi C_i(k, j)$ - podobieństwo całkowite pomiędzy poszczególnymi cyklami o indeksach (k, j) dla danego atrybutu o indeksie i ,

N - liczba faz badanego cyklu,

w_n - wagi zależne od fazy cyklu, mogą być przyjęte na podstawie opinii eksperta lub jeżeli nie są znane przyjmują wartość $w_n = 1$ (gdzie $n = 1, \dots, N$); wagi te określają wpływ danej fazy cyklu na cały cykl.

Ponieważ dla takiego sposobu wyznaczania wartości podobieństw pomiędzy cyklami o indeksach (k, j) dla danej fazy o indeksie n może się zdarzyć, że:

$$\Pi C_i(k, j) \neq \Pi C_i(j, k), \quad (4.6)$$

to aby został spełniony aksjomat symetrii wartości podobieństwa: $\Pi C_i(k, j) = \Pi C_i(j, k)$ wprowadzono pojęcie wartości podobieństwa średniego $\Pi S C_i(k, j)$ wyrażonego zależnością:

$$\Pi S C_i(k, j) = \Pi S C_i(j, k) = \frac{\Pi C_i(k, j) + \Pi C_i(j, k)}{2}, \quad (4.7)$$

gdzie:

$\Pi S C_i(k, j), \Pi S C_i(j, k)$ - podobieństwo średnie całkowite, pomiędzy poszczególnymi cyklami o indeksach (k, j) dla danego atrybutu o indeksie i .

Wartość podobieństwa całkowitego pomiędzy poszczególnymi cyklami o indeksach (k, j) dla wszystkich wybranych atrybutów wyznacza się na podstawie zależności:

$$\begin{aligned} \Pi_{CALK}(k, j) &= \frac{1}{I} \sum_{i=1}^I w_i \cdot \Pi S C_i(k, j), \\ \sum_{i=1}^I w_i &= I, \end{aligned} \quad (4.8)$$

gdzie:

$\Pi_{CALK}(k, j)$ - podobieństwo całkowite pomiędzy cyklami o indeksach (k, j) dla wszystkich wybranych atrybutów ($i = 1, \dots, I$),

I - liczba atrybutów procesowych wybranych do badań,

w_i - wagi dla poszczególnych atrybutów procesowych ($i = 1, \dots, I$).

Opisany powyżej etap kończy określanie podobieństw dla grupy wybranych atrybutów procesowych w zbiorze cykli wybranych do badań. Kolejny etap dotyczy określania podobieństw dla ilościowych statycznych wielkości wejściowych, wyjściowych oraz czasów trwania poszczególnych cykli (lub faz cykli).

4.5.1. Podobieństwo wielkości wejściowych i wyjściowych

Podobnie jak poprzednio zastosowano tutaj sposób określenia miary podobieństwa bazującego na odległości Euklidesa (4.9). W tym przypadku jest to miara odległości jednopunktowa, gdyż istnieje tylko jedna wartość dla każdej wybranej wielkości wejściowej, wyjściowej i parametru opisującego czas trwania danego cyklu/fazy:

$$D_{2s}^{WE}(k, j) = [(Y(k)_s^{WE} - Y(j)_s^{WE})^2]^{\frac{1}{2}}, \quad (4.9)$$

gdzie:

s - indeks atrybutu wejściowego,

$D_{2s}^{WE}(k, j)$ - odległość euklidesowa określana dla wybranych atrybutów wejściowych ($s = 1, \dots, S$) procesu pomiędzy poszczególnymi badanymi cyklami o indeksach (k, j) ,

$Y(k)_s^{WE}; Y(j)_s^{WE}$ - wartości danego atrybutu wejściowego o indeksie s dla badanych cykli o indeksach (k, j) .

Podobieństwo pomiędzy poszczególnymi przebiegami dla wybranych atrybutów wejściowych określone jest na podstawie następującej zależności:

$$\Pi_s^{WE}(k, j) = 1 - \frac{D_{2s}^{WE}(k, j)}{\max(D_{2s}^{WE}(k, j))} \quad (4.10)$$

gdzie:

$\Pi_s^{WE}(k, j)$ - podobieństwo pomiędzy poszczególnymi badanymi cyklami o indeksach (k, j) dla danego atrybutu wejściowego o indeksie s ,

$\max(D_{2s}^{WE}(k, j))$ - największa odległość euklidesowa pomiędzy cyklami o indeksach (k, j) dla danego atrybutu wejściowego o indeksie s .

Podobnie jak poprzednio konieczne jest wyznaczenie podobieństwa średniego (4.11) ze względu na to, że może zachodzić $\Pi_s^{WE}(k, j) \neq \Pi_s^{WE}(j, k)$:

$$\Pi S_s^{WE}(k, j) = \Pi S_s^{IN}(j, k) = \frac{\Pi_s^{WE}(k, j) + \Pi_s^{WE}(j, k)}{2}, \quad (4.11)$$

gdzie:

$\Pi S_s^{WE}(k, j)$ - podobieństwo średnie pomiędzy poszczególnymi cyklami o indeksach (k, j) dla danego atrybutu wejściowego o indeksie s .

Podobieństwo całkowite dla wybranych atrybutów wejściowych jest opisane zależnością:

$$\Pi_{CALK}^{WE}(k, j) = \frac{1}{S} \sum_{s=1}^S w_s \cdot \Pi S_s^{WE}(k, j), \quad (4.12)$$

$$\sum_{s=1}^S w_s = S,$$

gdzie:

S - liczba wybranych do badań atrybutów wejściowych procesu,

$\Pi_{CALK}^{WE}(k, j)$ - podobieństwo całkowite pomiędzy badanymi cyklami o indeksach (k, j) dla wszystkich wybranych atrybutów wejściowych ($s = 1, \dots, S$),

w_s - wagi dla poszczególnych wejściowych atrybutów procesowych ($s = 1, \dots, S$).

Podobny sposób można zastosować do wyznaczenia podobieństw atrybutów wyjściowych (4.13) i podobieństw czasów trwania poszczególnych, badanych cykli procesowych (4.14):

- zależność na podobieństwo atrybutów wyjściowych:

$$\Pi_{CALK}^{WY}(k, j) = \frac{1}{M} \sum_{m=1}^M w_m \cdot \Pi S_m^{WY}(k, j), \quad (4.13)$$

$$\sum_{m=1}^M w_m = M,$$

gdzie:

M - liczba wybranych do badań atrybutów wyjściowych procesu,

$\Pi_{CALK}^{WY}(k, j)$ - podobieństwo całkowite pomiędzy badanymi cyklami o indeksach (k, j) dla wszystkich wybranych atrybutów wyjściowych ($m = 1, \dots, M$),

w_m - wagi dla poszczególnych wejściowych atrybutów procesowych ($m = 1, \dots, M$);

- zależność na podobieństwo czasów trwania poszczególnych, badanych cykli:

$$\Pi_{CALK}^{CZAS}(k, j) = \frac{1}{N} \sum_{n=1}^N w_n \cdot \Pi S_n^{CZAS}(k, j), \quad (4.14)$$

$$\sum_{n=1}^N w_n = N,$$

gdzie:

N - liczba faz cyklu,

w_n - wagi dla poszczególnych faz cyklu ($n = 1, \dots, N$).


4.6. Metoda sekwencji znakowych

Należy zauważyć, że metoda odległościowa bazująca na mierze Euklidesa w wyznaczonej wartości podobieństwa nie uwzględnia wpływu kształtu przebiegów porównywanych cykli, a jedynie różnice pomiędzy odpowiadającymi sobie wartościami danych opisujących cykl.


Aby wyrazić podobieństwo kształtu krzywych opisujących analizowane przebiegi, opracowano metodę polegającą na dyskretyzacji opisu przebiegu krzywych za pomocą odcinków prostych, których liczba jest równa $(P - 1)$, gdzie P - liczba punktów aproksymujących (patrz Rozdz. 4.4). Każde dwa kolejne punkty aproksymacji wyznaczają jeden odcinek takiego opisu. Im większa liczba punktów aproksymacji, tym więcej odcinków i tym dokładniejsze jest przybliżenie przebiegu opisującego dany cykl.

Autor przyjął, że przy określaniu podobieństwa pomiędzy odpowiadającymi sobie odcinkami z dwóch porównywanych przebiegów będzie wykorzystywany kąt nachylenia poszczególnych odcinków do osi odciętych (osi czasu). Każdy odcinek może być nachylony względem tej osi pod kątem zawierającym się w przedziale $(-\frac{\pi}{2}, +\frac{\pi}{2})$.

Aby móc opisać miarę podobieństwa, wprowadzono pewien słownik opisujący przynależność danego kąta nachylenia odcinka do zdyskretyzowanego zbioru przedziałów (LP_r) , opisanych za pomocą znaków alfabetu [27]. Założono nieparzystą liczbę przedziałów (Rys. 4.2). Oznacza to, że dla $LP_r = 3$ mamy do czynienia z trzema przedziałami $(-\frac{\pi}{2}; \beta_1]$, $(\beta_1; \beta_2]$ oraz $(\beta_2; +\frac{\pi}{2})$ - por. Rys. 4.2. Przedział określony wokół wartości 0, powstały w wyniku przyjęcia nieparzystej liczby przedziałów, jest bardzo istotny dla modelowania procesów wolnozmiennych. Wynika to z tego, że przebiegi wolnozmiennie charakteryzują się długimi przedziałami, w których nie występują żadne zmiany wartości atrybutów lub jedynie bardzo małe zmiany wartości wynikające z istniejących zakłóceń (zakłócenia pomiarowe, niewielkie fluktuacje wartości spowodowane innymi czynnikami). Dlatego zdarzenie, gdy „nic się nie dzieje” w procesie, występuje nie tylko dla wartości 0 ale zawiera się także w pewnym określonym przedziale wartości wokół osi odciętych. Te małe fluktuacje nachylenia odcinków opisujących przebiegi wokół położenia 0, nie powodują zmiany znaku w tworzonej sekwencji znakowej opisującej cały przebieg, więc także w opisie zachowany jest charakter wolnozmienności procesu. Dzięki temu łatwiejsze jest porównanie utworzonych sekwencji, które opisują cykle o niewielkich zmianach wartości atrybutów w poszczególnych chwilach czasu.



Rys. 4.2. Przedziały przynależności kątów nachylenia odcinków



Rys. 4.3. Opis przebiegu krzywej za pomocą sekwencji znaków

Na rys. 4.2 przedstawiono sposób określenia przedziałów (LPr), do których przypisuje się wyznaczone wartości kątów α_{p-1} . Im więcej mamy przedziałów, tym mniejsze zmiany przebiegu możemy uwzględnić w wyznaczonych podobieństwach.

Opis za pomocą odcinków jest sprowadzany do sekwencji znaków (Rys. 4.3). Długość sekwencji jest zależna od liczby punktów aproksymacji P i wynosi ona $(P - 1)$. Natomiast znaki, jakie są wykorzystane w sekwencji, są zależne od liczby przedziałów LPr . Dla $LPr = 3$ znaki są ze zbioru (A, B, C) , dla $LPr = 7$ z przedziału $A - G$, (A, B, \dots, F, G) .


Porównywanie odpowiednich znaków w sekwencji jest oparte o kody ASCII tych znaków, natomiast wartości podobieństw są przypisywane zgodnie z zależnością opisaną za pomocą (4.15). Dla przedstawionej zależności wartość podobieństwa poszczególnych znaków przyjętego słownika, została wyznaczona względem znaku A. Podobnie jak w poprzednio omawianej metodzie przyjęto prostą, liniową miarę podobieństwa, aby ułatwić późniejszą jego modyfikację.

<i>Znaki</i>		<i>Podobieństwo</i>	
<i>A</i>	→	(1)	
<i>B</i>	→	$1 - (\frac{1}{LPr-1})$	
<i>C</i>	→	$1 - [2 \cdot (\frac{1}{LPr-1})]$	(4.15)
⋮		⋮	
$ZN(LPr - 1)$	→	$1 - [(LPr - 2) \cdot (\frac{1}{LPr-1})]$	
$ZN(LPr)$	→	(0)	

gdzie:

$ZN(LPr)$ - znak końcowy zależny od liczby przedziałów (np. $LPr = 3 \rightarrow ZN(LPr) = C$ por. Rys. 4.4)

Na rys. 4.4 przedstawiono sposób wyznaczenia liczbowej wartości podobieństw poszczególnych znaków sekwencji opisujących przedstawione przebiegi (Krzywa 1, Krzywa 2) względem znaku A.



Rys. 4.4. Wartości podobieństwa znaków sekwencji względem znaku A

Na rys. 4.5 przedstawiono przykład wyznaczenia podobieństwa pomiędzy Krzywą 1 i Krzywą 2. Obrazuje on w jaki sposób przebiega określanie podobieństw cząstkowych pomiędzy sekwencjami opisującymi obie krzywe. Dodatkowym założeniem jest porównywanie sekwencji znakowych o takiej samej długości.


Bardzo istotną cechą opisaną powyżej metody sekwencji znakowych jest możliwość stwierdzenia, czy dla danego atrybutu procesowego zachodzi odpowiednio wysokie podobieństwo kształtu przebiegu tego atrybutu w funkcji czasu.

Krzywa 1	Krzywa 2		
D → A		$1 - 0,25 - 1,00 $	0,25
C → C		$1 - 0,50 - 0,50 $	1
D → D		$1 - 0,25 - 0,25 $	1
C → C		$1 - 0,50 - 0,50 $	1
A → C	⇒	$1 - 1,00 - 0,50 $	0,50
C → B		$1 - 0,50 - 0,75 $	0,75
C → C		$1 - 0,50 - 0,50 $	1
C → B		$1 - 0,50 - 0,75 $	0,75
			6,25
			↓ / (P-1)
			$\Pi_{K1-K2} = 0,78$

Rys. 4.5. Przykład wyznaczenia podobieństwa dla krzywych Krzywa 1 i Krzywa 2 przedstawionych na rys. 4.4

Różnice w podobieństwach wyznaczanych opisanymi metodami

Na rys. 4.6 przedstawiono dwa fragmenty przebiegów zmiennych procesowych K1 i K2 o początkowych punktach P11 i P21 oraz K3 i K4 o początkowych punktach P31 i P41. Dla tych punktów zostanie przedstawiona różnica w zastosowaniu opisywanych metod oraz algorytm wyznaczania podobieństwa uogólnionego.



Rys. 4.6. Fragmenty przebiegów sterowań K1 i K2 oraz K3 i K4

Punkty (P11, P12), (P21, P22), (P31, P32) oraz (P41, P42) przybliżono odcinkami zgodnie z wcześniej opisaną metodą. W pierwszym kroku wyznaczono podobieństwo bazujące na odległości (4.16). Wyznaczone podobieństwo jest identyczne dla obu przebiegów:

$$\begin{aligned}
 ODL_{P11-P21} &= \sqrt{(2-1)^2} = 1 \\
 ODL_{P21-P22} &= \sqrt{(2-1)^2} = 1 \\
 ODL_{P31-P41} &= \sqrt{(2-1)^2} = 1 \\
 ODL_{P32-P42} &= \sqrt{(3-2)^2} = 1
 \end{aligned} \tag{4.16}$$

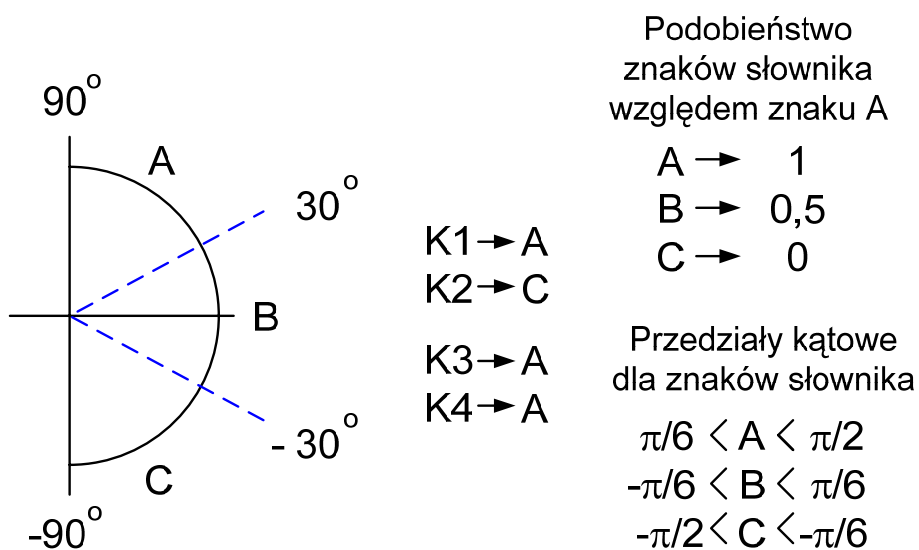
$$Sum(ODL)_{K1,K2} = ODL_{P11-P12} + ODL_{P21-P22} = 2$$

$$Sum(ODL)_{K3,K4} = ODL_{P31-P41} + ODL_{P32-P42} = 2$$

$$\prod_{K1,K2}^{M1}(Sum(ODL)_{K1,K2}) = \prod_{K3,K4}^{M1}(Sum(ODL)_{K3,K4})$$

Żeby rozróżnić te dwie krzywe zastosowano metodę sekwencji znakowych, dla której wprowadzono słownik zgodnie z rys. 4.7. Dla tak określonej sekwencji znakowej (o długości jednego znaku) wyznaczono podobieństwo pomiędzy odcinkami przebiegów K1 i K2 (4.17).

$$\begin{aligned}
 \prod_{K1,K2}^{M2} &= 1 - |1 - 0| = 0, \\
 \prod_{K3,K4}^{M2} &= 1 - |1 - 1| = 1.
 \end{aligned} \tag{4.17}$$



Rys. 4.7. Określenie słownika i przynależności odcinków krzywych do przedziałów

$$\begin{aligned}\prod_{K_1, K_2}^{M_1} &= \prod_{K_3, K_4}^{M_1}, \\ \prod_{K_1, K_2}^{M_2} &\neq \prod_{K_3, K_4}^{M_2}.\end{aligned}\tag{4.18}$$

Aby wprowadzić rozróżnialność odcinków krzywych zastosowano zdefiniowane podobieństwo uśrednione według zależności:

$$\begin{aligned}\prod_{K_1, K_2}^{Sr} &= \frac{\prod_{K_1, K_2}^{M_1} + \prod_{K_1, K_2}^{M_2}}{2}, \\ \prod_{K_3, K_4}^{Sr} &= \frac{\prod_{K_3, K_4}^{M_1} + \prod_{K_3, K_4}^{M_2}}{2}.\end{aligned}\tag{4.19}$$

Tak wyznaczone podobieństwo uśrednione \prod^{Sr} niesie ze sobą informację o podobieństwie porównywanych fragmentów krzywych, zawierające podobieństwo kształtu i podobieństwo wartości ilościowych atrybutów procesowych.

4.7. Metoda określenia podobieństw bazująca na mierze euklidesowej dla odległości względnej

Opisana w rozdziale 4.5 metoda określania podobieństwa przebiegów sterowań atrybutami procesowymi bazowała na określaniu podobieństwa na mierze euklidesowej dla odległości bezwzględnych.


Opisane poniżej dwa sposoby tworzące omawianą metodę, wykorzystują do wyznaczenia podobieństwa porównywanych cykli wartości odległości względnych. W pierwszym omawianym sposobie stosuje się odległości względne pomiędzy poszczególnymi punktami aproksymacji dwóch porównywanych cykli dla danego atrybutu procesowego (Rys. 4.8). W drugim sposobie wykorzystywane są wartości odległości względnych kątów nachylenia odcinków łączących dwa kolejne punkty aproksymacji dwóch porównywanych cykli dla danego atrybutu procesowego (Rys. 4.10).

Tak jak w przypadku wyznaczania podobieństwa w metodzie opisanej w rozdziale 4.5 ogólna zależność (4.4) na wyznaczanie podobieństw porównywanych cykli tam wprowadzona obowiązuje też w tej metodzie.


Dla sposobu wyznaczania podobieństwa bazującego na odległościach względnych pomiędzy kolejnymi punktami porównywanych cykli zależność ta przyjmuje postać jak we wzorze (4.20):

$$\Pi O_i^{KS}(k, j) = 1 - \frac{O_i^{KS}(k, j)}{\max(O_i^{KS}(k, j))} \quad \text{dla } \max(O_i^{KS}(k, j)) \neq 0, \quad (4.20)$$

$$\Pi O_i^{KS}(k, j) = 1 \quad \text{dla } \max(O_i^{KS}(k, j)) = 0.$$



Rys. 4.8. Sposób wyznaczania podobieństwa oparty na wartościach odległości względnych



Rys. 4.9. Przypadki wzajemnego położenia punktów dwóch porównywanych cykli

W zależności od różnego względnego rozmieszczenia poszczególnych punktów aproksymacji wprowadzono dwie zależności na wyznaczanie odległości pomiędzy tymi punktami dla krzywych K i S przedstawionych na rys. 4.8, zgodnie z przyjętym słownikiem mogących wystąpić wzajemnych położenia punktów aproksymacji dwóch porównywanych cykli (Rys. 4.9):

$$O_i^K = Y_{i,p}^K - Y_{i,(p+1)}^K, \quad (4.21)$$

$$O_i^S = Y_{i,p}^S - Y_{i,(p+1)}^S.$$

gdzie:

O_i^K, O_i^S - wartości różnic odległości bezwzględnych punktów o indeksach p i $(p+1)$ opisujących przebieg atrybutu o indeksie i dla krzywych K i S (Rys. 4.9),

$Y_{i,p}^K, Y_{i,(p+1)}^K, Y_{i,p}^S, Y_{i,(p+1)}^S$ - wartość atrybutu o indeksie i w punktach aproksymujących o indeksach p i $(p+1)$ dla krzywych K i S opisujących porównywane cykle.

Zależność 1

gdy $O_K < 0$ i $O_S > 0$ oraz $O_K > 0$ i $O_S < 0$ - por. Rys. 4.9 (a,b):

$$O_i^{KS} = |O_i^K| + |O_i^S|; \quad (4.22)$$

Zależność 2

gdy $O_K < 0$ i $O_S < 0$ oraz $O_K > 0$ i $O_S > 0$ - por. Rys. 4.9 (c,d):

$$O_i^{KS} = |O_i^K| - |O_i^S|, \quad (4.23)$$


gdzie:

O_i^{KS} - odległość względna pomiędzy porównywanymi odcinkami krzywych K i S dla atrybutu o indeksie i .

Dla sposobu drugiego bazującego na wartościach odległości względnych kątów nachylenia poszczególnych odcinków łączących kolejne punkty aproksymacji danego cyklu dla wybranego atrybutu procesowego, zależność na wyznaczanie podobieństwa podaje wzór (4.24) określany na podstawie zależności (4.4) omówionej w rozdziale 4.5:

$$\Pi\alpha_i^{KS}(k, j) = 1 - \frac{\alpha_i^{KS}(k, j)}{\max(\alpha_i^{KS}(k, j))} \quad \text{dla } \max(\alpha_i^{KS}(k, j)) \neq 0, \quad (4.24)$$

$$\Pi\alpha_i^{KS}(k, j) = 1 \quad \text{dla } \max(\alpha_i^{KS}(k, j)) = 0.$$



Rys. 4.10. Sposób wyznaczania podobieństwa oparty na wartościach kątów lokalnych. Względna odległość pomiędzy kątami nachylenia dwóch odpowiadających sobie odcinków badanych krzywych opisujących porównywane przebiegi (Rys. 4.10) danego atrybutu procesowego, jest wyznaczana z zależności:

$$\alpha_i^{KS} = |\alpha_i^K - \alpha_i^S|. \quad (4.25)$$

4.8. Sposoby modyfikacji gęstości rozkładu podobieństw atrybutów procesowych

Opisane we wcześniejszych rozdziałach metody wyznaczania podobieństw realizacji określonych atrybutów procesowych pomiędzy wybranymi zbiorami cykli pozwalają wyznaczyć wartości podobieństw, które umożliwiają jedynie średnią lub słabą rozróżnialność pomiędzy wyznaczonymi cyklami. Taki stan powstaje na przykład wtedy, gdy najmniejsza wyznaczona odległość $\min(D_{2i}^n(k, j))$ dla porównywanych cykli jest dużo mniejsza od największej wyznaczonej odległości $\max(D_{2i}^n(k, j))$ dla tych cykli, natomiast pozostałe

odległości mało różnią się od $\max(D_{2i}^n(k, j))$. Powoduje to, że większość z wyznaczonych wartości podobieństw według zależności (4.4) jest skupiona w jednym wąskim podprzedziale przedziału $[0, 1]$ gęstości rozkładu podobieństwa. Pojawia się wówczas bardzo dużo cykli mało lub średnio podobnych do zadanego, natomiast cykli bardzo podobnych jest stosunkowo mało.

Aby zwiększyć rozróżnialność pomiędzy cyklami procesu, zastosowano modyfikowanie wyznaczonych wartości podobieństwa za pomocą wartości zaproponowanych funkcji modyfikujących o tak dobranych parametrach, że gęstość rozkładu empirycznego podobieństwa zmieni się w ten sposób, że:

- zwiększona zostanie rozróżnialność pomiędzy cyklami,
- znacząco zmniejszą się wartości podobieństw cykli o najmniejszych wartościach podobieństw względem zadanego cyklu odniesienia,
- nieznacznie zmienią się wartości podobieństw cykli ze środkowych przedziałów wartości wyznaczonych podobieństw względem cyklu odniesienia,
- zwiększona zostanie liczba cykli bardzo podobnych do zadanego cyklu odniesienia, w zakresie wysokich wartości podobieństwa $(0, 9 - 1, 0)$.

Wymagania dla funkcji modyfikujących są następujące:

1. $[0; 1] \xrightarrow{f_{mod}} [0; 1]$,
2. f_{mod} - monotoniczna/niemalejąca,
3. $f(0)_{mod} = 0$,
4. $f(1)_{mod} = 1$.

Stosując zaproponowane poniżej funkcje modyfikujące można odpowiednio kształtować gęstość rozkładu empirycznego wyznaczonych wartości podobieństw tak, aby uzyskać odpowiednią rozróżnialność pomiędzy cyklami.

Do modyfikacji zastosowano następujące funkcje:

1. Funkcja modyfikująca rozkład podobieństwa sigmoidalna unipolarna:

$$\Pi_{mod}(k, j) = f_{mod}(\Pi(k, j)) = \frac{1}{1 + e^{-2\beta\Pi(k, j) - \alpha}},$$

$$\Pi_{mod}(k, j) = \frac{\Pi_{mod}(k, j)}{\max(\Pi_{mod}(k, j))}, \quad (4.26)$$

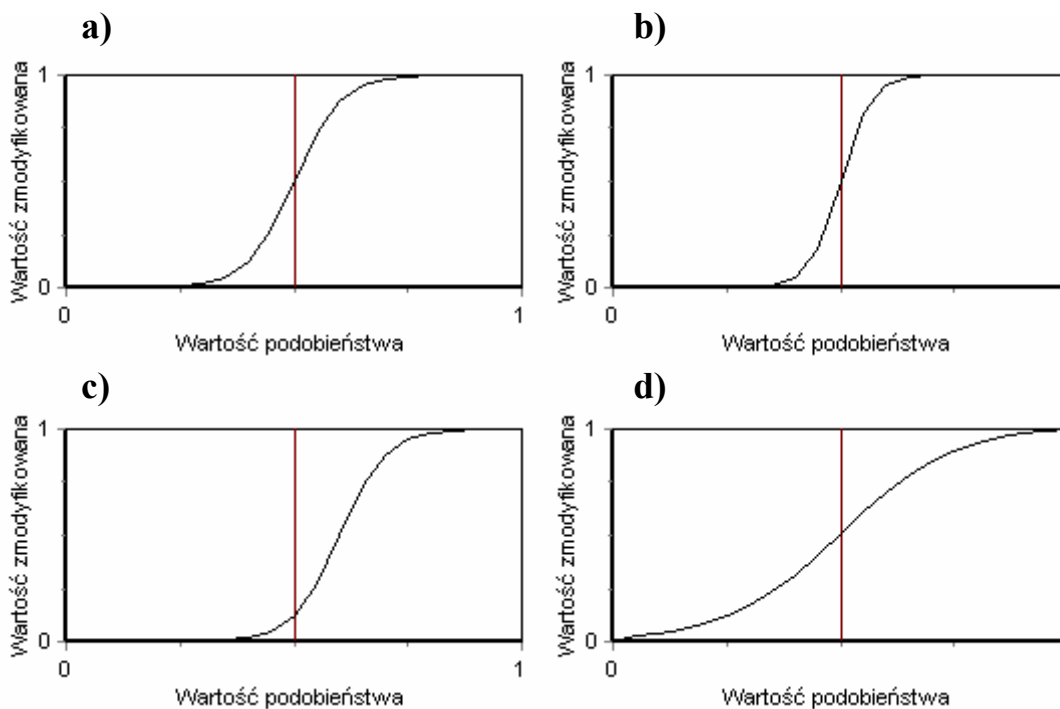
$$\min(\Pi_{mod}(k, j)) = 0,$$

gdzie:

α, β - parametry decydujące o kształcie krzywej;

2. Funkcja modyfikująca rozkład podobieństwa $\cos()$:

$$\Pi_{mod}(k, j) = f_{mod}(\Pi(k, j)) = \frac{1}{2}[1 + \cos(\pi \cdot (1 + \Pi(k, j)))], \quad (4.27)$$



Rys. 4.11. Funkcja modyfikująca sigmoidalna a) $\alpha = 1, \beta = 10$; b) $\alpha = 1, \beta = 15$; c) $\alpha = 1.1, \beta = 10$; d) $\alpha = 1, \beta = 4$



Rys. 4.12. Funkcja modyfikująca $\cos()$

3. Funkcja modyfikująca rozkład podobieństwa sinus hiperboliczny $\sinh()$:

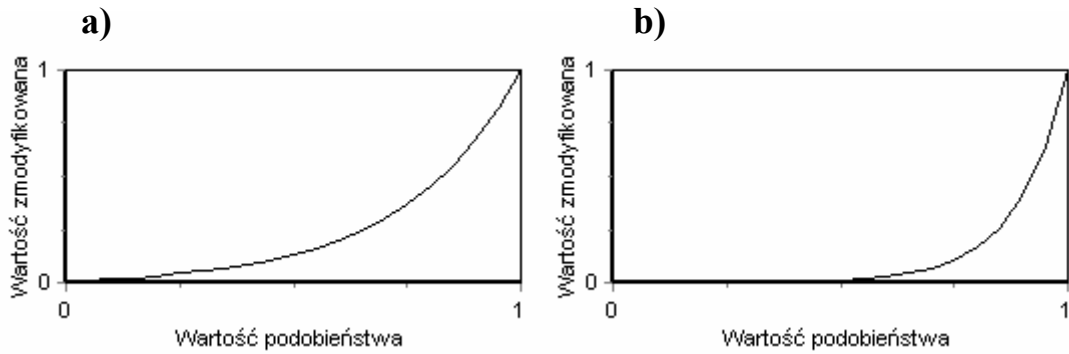
$$\Pi_{mod}(k, j) = f_{mod}(\Pi(k, j)) = \frac{e^{(\alpha \cdot \Pi(k, j))} - e^{(-\alpha \cdot \Pi(k, j))}}{2},$$

$$\Pi_{mod}(k, j) = \frac{\Pi_{mod}(k, j)}{\max(\Pi_{mod}(k, j))}, \quad (4.28)$$

$$\min(\Pi_{mod}(k, j)) = 0,$$

gdzie:

α - współczynnik kształtu krzywej;

Rys. 4.13. Funkcja modyfikująca $\sinh()$ a) $\alpha = 4$; b) $\alpha = 9$


4. Funkcja modyfikująca rozkład podobieństwa Weibulla $R()$:

$$\begin{aligned} \Pi_{mod}(k, j) &= f_{mod}(\Pi(k, j)) = 1 - R(\Pi(k, j)) = 1 - e^{-\beta \cdot \Pi(k, j)^\alpha}, \\ \Pi_{mod}(k, j) &= \frac{\Pi_{mod}(k, j)}{\max(\Pi_{mod}(k, j))}, \end{aligned} \quad (4.29)$$

$$\min(\Pi_{mod}(k, j)) = 0,$$

gdzie:

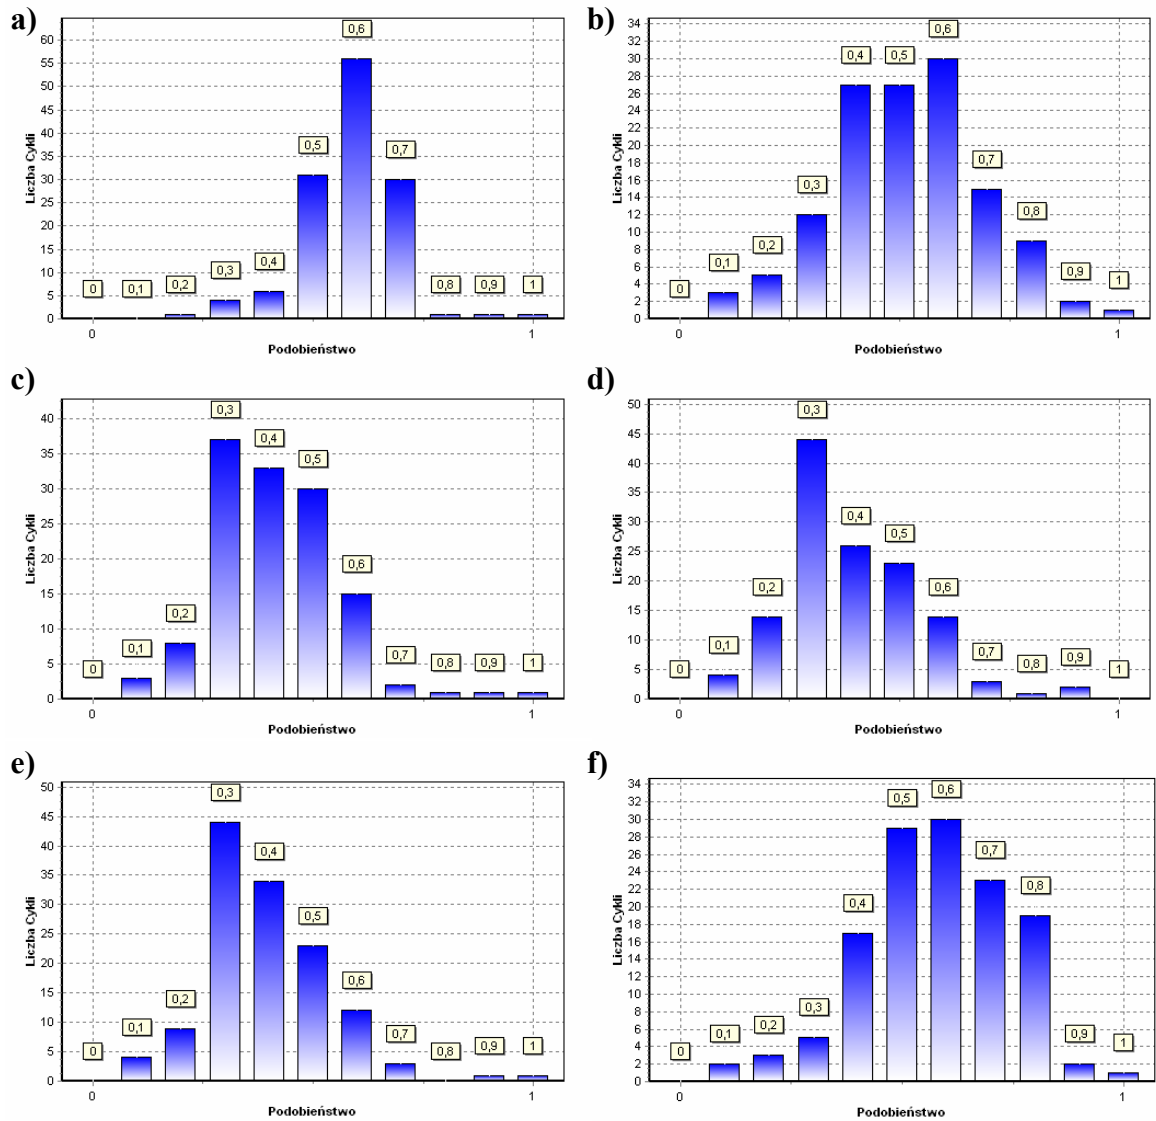
α, β - parametry decydujące o kształcie krzywej.

Rys. 4.14. Funkcja modyfikująca Weibulla a) $\alpha = 4, \beta = 2$; b) $\alpha = 0.2, \beta = 4$

Opisane powyżej funkcje modyfikujące umożliwiają uzyskanie odpowiednich gęstości rozkładów podobieństw dla różnych badanych atrybutów procesowych. Poniżej przedstawiono przykładowe modyfikacje histogramów gęstości rozkładu podobieństw. Dla przedstawionego przykładowego atrybutu uzyskana gęstość rozkładu empirycznego wyznaczonej wartości podobieństwa daje bardzo małą rozróżnialność pomiędzy poszczególnymi cyklami (rys. 4.15 a) i konieczne jest zastosowanie modyfikacji wartości tych podobieństw, aby dawały lepszą rozróżnialność. Jak widać na tym rysunku, różne funkcje modyfikujące mają odmienny wpływ na uzyskiwane wyniki.

Modyfikacje wartości podobieństw pozwalają na zastosowanie prostych miar podobieństwa (opisanych w pracy), które dają liniowe podobieństwo pomiędzy cyklami i powodują zwiększenie rozróżnialności pomiędzy tymi cyklami. Podobny efekt można by uzyskać definiując bardzo skomplikowane miary podobieństwa. Zaproponowany sposób wyznaczania podobieństwa polega na splataniu funkcji modyfikującej z prostą miarą podobieństwa co powinno dawać podobne wyniki jak przy zastosowaniu złożonej funkcji podobieństwa. Wprowadzone modyfikacje nie powodują zmiany obrazu podobieństwa pomiędzy cyklem odniesienia a cyklami badanymi. Zmienia się tylko skala wyznaczonej wartości, natomiast nie zmienia się uporządkowanie wyznaczonych za pomocą zdefiniowanych miar podobieństw pomiędzy poszczególnymi cyklami.

Modyfikacje te mają duże znaczenie podczas zastosowania opracowanych metod: sekwencji znakowych oraz odległościowych (bezwzględnych i względnych). Jak stwierdzono podczas badań wstępnych, w wyniku zastosowania tych metod obliczane są podobieństwa, które zapewniają niewystarczającą rozróżnialność pomiędzy cyklami. Wprowadzenie modyfikacji otrzymywanych wartości podobieństw znacząco poprawia tę rozróżnialność.



Rys. 4.15. Przykładowe histogramy podobieństw dla różnych funkcji modyfikujących:
 a) bez modyfikacji; b) funkcja sigmoidalna; c) funkcja $\cos()$; d) funkcja $\sinh(), \alpha = 4$;
 e) funkcja $\sinh(), \alpha = 2$; f) funkcja Weibulla ($\alpha = 2, \beta = 0.0003$)

4.9. Sposób wyznaczania wag istotności dla atrybutów procesowych

Wpływ poszczególnych, wybranych do badań, atrybutów na proces sterowania nie jest znany. Można go w przybliżony sposób określić poprzez skorzystanie z wiedzy specjalistów. Jednak w niektórych przypadkach wiedza ta jest sprzeczna (gdy np. korzystamy z pomocy kilku specjalistów mających odmienne poglądy na sposób sterowania procesem).

Postanowiono dla potrzeb opracowanych metod określić wpływ poszczególnych atrybutów procesowych na wyznaczone wartości podobieństw pomiędzy poszczególnymi cyklami. W tym celu wprowadzono wagi. Przeprowadzono próbę dostrojenia wag dla tych atrybutów na drodze eksperymentu genetycznego. Zdecydowano się na zastosowanie eksperymentu genetycznego, ponieważ trudno jest zdefiniować odpowiednią funkcję kryterialną, która umożliwiłaby znalezienie optimum za pomocą klasycznych metod optymalizacji.

W ogólnym przypadku wagi atrybutów powinny być określone indywidualnie w każdej chwili t_p znormalizowanego cyklu. Ponieważ każdy cykl dla danego atrybutu został opisany przez P punktów aproksymacji, to $t_p \in (1, \dots, P)$. Liczba atrybutów zależy od liczby atrybutów przyjętych do badań ($i = 1, \dots, I$). Więc dla całego znormalizowanego cyklu (przy założeniu że każdy cykl każdego atrybutu został opisany taką samą liczbą punktów aproksymacji) macierz wag ma w tym wypadku wymiary $I \times P$ (4.30):

$$[w_i(t_p)]_{i=1, \dots, I; p=1, \dots, P} \quad (4.30)$$

Aby można było określić wagi, trzeba byłoby dysponować odpowiednio liczną bazą danych. Niestety założenie takie było niemożliwe do spełnienia w przypadku dostępnych autorowi baz danych procesowych oraz ze względu na wymagania obliczeniowe jakie musiałyby być spełnione aby wyznaczone wagi były funkcją znormalizowanego czasu i mogły się zmieniać dynamicznie podczas przebiegu procesu. Dla potrzeb przeprowadzanego eksperymentu przyjęto znaczące uproszczenie polegające na tym, że wpływ podobieństw poszczególnych zmiennych procesowych jest określony stałymi wartościami wag, a więc jest stały podczas całego cyklu.

Celem eksperymentu jest określenie wag dla podobieństw pomiędzy poszczególnymi cyklami o indeksach (k, j) dla wybranych atrybutów procesowych $i = (1, \dots, I)$ (4.8).

Dla przeprowadzonego eksperymentu genetycznego wymagane było przyjęcie szczegółowych rozwiązań takich elementów, jak [3]:

- kodowanie chromosomu,
- liczba osobników w populacji,
- współczynnik selekcji,
- metody krzyżowania,
- prawdopodobieństwo mutacji i metody mutacji,

- współczynniki sukcesji i metody sukcesji,
- warunki zakończenia działania algorytmu.

Przyjęto, że długość chromosomu będzie równa liczbie atrybutów procesowych zastosowanych do określania podobieństw całkowitych pomiędzy cyklami o indeksach (k, j) . Elementy chromosomu będą stanowiły wagi dla poszczególnych podobieństw atrybutów:

$$[w_1; w_2; \dots; w_I]. \quad (4.31)$$

Przyjęto reprezentowanie wag w postaci liczb zmiennoprzecinkowych - kodowanie zmiennoprzecinkowe np. $[0.5; 0.3; \dots 0.4]$. Zakres zmienności poszczególnych wag zawiera się w przedziale $[0; 1]$.

Dla potrzeb eksperymentu założono (na podstawie przeprowadzonych wcześniej prób), że:

- pokolenie będzie składało się z 50 osobników generowanych losowo,
- kryterium zakończenia działania algorytmu genetycznego będzie osiągnięcie liczby pokoleń równej 500.

Eksperyment ewolucyjny przeprowadzono dla szeregu różnych zmiennych parametrów algorytmu [3]:

- zastosowano krzyżowanie jednopunktowe i uśredniające,
- zastosowano sukcesję elitarną i elitarną trypoziomową,
- zastosowano mutację losową-równomierną oraz rzeczywistoliczbową.

Zaproponowana przez autora sukcesja elitarna trypoziomowa, w odróżnieniu od sukcesji elitarniej [3] (pokolenie „T+1” powstaje z najlepszych osobników z pokolenia „T” [%] oraz pozostałe osobniki z pokolenia „T” i „T+1”), tworzy pokolenie „T+1” w trzech etapach:

- najlepsze osobniki z pokolenia „T” [%],
- najlepsze osobniki z pokolenia „T” i „T+1” [%],
- pozostałe osobniki wygenerowane losowo.

W następnej kolejności określono funkcję przystosowania danego osobnika według następującego kryterium (4.32).

$$\min\left[\left(\sum_{i=1}^I w_i \cdot \Pi SC_i(k, j)\right) - \Pi_{CALK}^{PARAM}(k, j)\right] \approx 0 \quad (4.32)$$

gdzie:

PARAM - parametry wejściowe (WE), parametry wyjściowe (WY) lub parametry czasów trwania poszczególnych cykli (CZAS).


Zostało tutaj zastosowane strojenie względem podobieństw atrybutów statycznych (wejść, wyjść oraz wartości parametru czasu trwania poszczególnych cykli) według przyjętej zasady, która mówi że różnica pomiędzy ważoną sumą podobieństw poszczególnych

atrybutów procesowych i podobieństw wybranych atrybutów wejściowych (WE), wyjściowych (WY) lub atrybutów czasu trwania badanych cykli (CZAS) powinna być bliska zeru.

4.10. Sposób prezentacji wyników otrzymanych za pomocą opracowanych metod

Opisane wcześniej metody służą do modelowania wolnozmiennych przebiegów atrybutów procesów technologicznych. Sposób prezentacji wyników otrzymanych zgodnie z tymi metodami powinien zawierać informacje użyteczne dla obsługi rozpatrywanego obiektu lub procesu w zakresie podejmowania decyzji o sposobie sterowania tymi parametrami.

W tym celu postanowiono zastosować wykresy radiowe. Wykres taki ma postać wieloboku, o liczbie boków zależnej od liczby atrybutów, które mają być na nim opisane. Przyjęcie zbyt dużej liczby atrybutów dla jednego wykresu będzie powodowało, że będzie on mało czytelny, a wielobok będzie bardziej przypominał okrąg opisany wieloma odcinkami.




Rys. 4.16. Przykład prezentacji wyników za pomocą czterech, sześciu i ośmiu atrybutów P_i

Wykres taki jest najbardziej czytelny, jeżeli prezentujemy na nim wyniki porównania tylko dwóch cykli opisanych co najwyżej sześcioma atrybutami (Rys. 4.17).

Stwierdzono, że dla proponowanych metod można za pomocą takich wykresów prezentować dla dwóch porównywanych cykli:

- wartości podobieństw średnich całkowitych wyznaczonych dla wybranych atrybutów procesowych wolnozmiennych,
- wartości średnie, zarejestrowane dla wybranych atrybutów procesowych wolnozmiennych,
- wartości maksymalne lub minimalne, zarejestrowane dla wybranych atrybutów procesowych wolnozmiennych,
- wartości podobieństw dla poszczególnych klas atrybutów, wyznaczone podczas wyszukiwania podobnych realizacji,



Rys. 4.17. Przykład prezentacji wartości parametrów statycznych sześciu i ośmiu atrybutów P_i , odnoszące się do dwóch różnych cykli

- wartości podobieństw średnich całkowitych wyznaczone dla wybranych atrybutów procesowych statycznych,
- wartości wybranych atrybutów procesowych statycznych.

W przypadku prezentowania wartości zarejestrowanych dla wybranych atrybutów wolnozmiennych lub statycznych, konieczne jest przeprowadzenie ich normalizacji. Normalizacja polega na przeskalowaniu wartości atrybutów przeznaczonych do prezentowania, do przedziału $[0; 1]$. Normalizację można przeprowadzić względem prezentowanej wartości średniej atrybutu lub względem jego wartości największej dla danego zbioru jego wartości. Dla prezentowanych wartości podobieństw wybranych atrybutów nie przeprowadza się już dodatkowej normalizacji.

4.11. Sposób oceny wyników badań uzyskanych za pomocą opracowanych metod

Poniżej opisano zastosowany sposób oceny opracowanych w ramach pracy doktorskiej metod modelowania procesów wolnozmiennych. Zaproponowany sposób bazuje na założeniu że badany proces jest sterowalny oraz opracowane miary wyznaczania wartości podobieństw zostały poprawnie zdefiniowane. Przyjmując, że te założenia są prawdziwe, możliwe będzie wykazanie słuszności hipotezy, że dla cykli o dostatecznie podobnych wejściach i dostatecznie podobnych sterowaniach, wyjścia będą także dostatecznie podobne. Dla potrzeby oceny zdefiniowano estymator bazujący na określonych:

- granicach przedziałów przynależności wyznaczonych wartości podobieństw realizacji cykli badanych klas atrybutów opisanych zależnością:

$$PRZ_{WE}^{\pi} \geq PRZ_{STER}^{\pi} \geq PRZ_{WY}^{\pi}; \quad (4.33)$$

- granicach licznosci wyszukanych realizacji cykli według założonych przedziałów dla poszczególnych klas badanych atrybutów opisanych zależnością (4.34).

$$LICZ_{WE} \geq LICZ_{STER} \quad (4.34)$$

gdzie:

PRZ_{WE}^{π} - dolna granica przedziału wartości podobieństw dla atrybutów wejść (statycznych),

PRZ_{STER}^{π} - dolna granica przedziału wartości podobieństw dla atrybutów wolnozmiennych (sterowań),

PRZ_{WY}^{π} - dolna granica przedziału wartości podobieństw dla atrybutów wyjść (statycznych),

$LICZ_{WE}$ - graniczna licznosc realizacji cykli dla atrybutów wejść (statycznych),

$LICZ_{STER}$ - graniczna licznosc realizacji cykli dla atrybutów wolnozmiennych (sterowań).

Zdefiniowany estymator określony jest jako:

$$O_{EST} = \left(\frac{L_{SUKC}}{L_{PROB}} \right) \cdot 100\%, \quad (4.35)$$

gdzie:

O_{EST} - procentowy estymator oceny badanych metod,

L_{SUKC} - liczba sukcesów wyszukania realizacji cykli spełniających założone wymagania (4.33) i (4.34),

L_{PROB} - liczba wykonanych prób wyszukiwania realizacji cykli.

Algorytm określenia wartości estymatora (4.35) został przedstawiony na rys. 4.18 (L_{CYKL} - liczba cykli wybranych do badań).

Jako dodatkową miarę oceny opracowanych metod wykorzystano test t [95] (4.36):

przyjęto prawdziwość hipotezy zerowej $H_0 : \mu = m$, gdzie $m = 1$:

$$t = \frac{|\bar{x} - m|}{s(\bar{x})}, \quad (4.36)$$

gdzie:

m - założona wartość średniej z populacji ($m = 1$),

\bar{x} - rzeczywista wartość średniej z populacji,

$s(\bar{x})$ - oszacowany błąd standardowy.

Zastosowany test t posłużył w opisywanym przypadku do sprawdzenia, czy wyznaczona średnia wartość estymatora $O_{EST}(L_{SUKC})$ dla wszystkich przeprowadzonych prób L_{PROB} różni się istotnie od wartości przyjętej hipotezy zerowej $m = 1$.

Rozdział 5

Weryfikacja metod

Opracowane metody modelowania procesów wolnozmiennych zostały poddane weryfikacji [91–93], do której wykorzystano dane zgromadzone przez system SCADA, w który wyposażony został piec do redukcji miedzi z żużla. Obiekt badań szerzej został opisany w [85, 86]. Wykorzystanie do badań weryfikacyjnych tylko jednej bazy danych wynikało z trudności związanych z pozyskaniem takich baz danych. Zwykle dane takie nie są udostępniane do powszechnych badań przez dysponentów tych danych. Dzieje się tak pomimo korzyści jakie mogłyby być odniesione w przyszłości na skutek nowo opracowanych metod wspomagania prowadzenia takich procesów lub ich diagnostyki. Pomimo tego opracowane metody nadają się do modelowania innych procesów wolnozmiennych, jakie mogą być prowadzone nie tylko w zakładach przemysłowych. Ogólny opis formalny tych metod zawarty w rozdziale 4 pozwala na zastosowanie opracowanych metod do innych procesów o podobnym charakterze.

Przeprowadzone badania obejmowały takie elementy, jak przygotowanie oprogramowania działającego według zaproponowanych metod, pozyskanie odpowiednich baz danych i przygotowanie ich do badań weryfikacyjnych metod, wybór zbiorów danych do badań weryfikacyjnych, przeprowadzenie weryfikacji oraz zebranie i omówienie wyników badań.

5.1. Plan weryfikacji

Opracowane metody zostały poddane weryfikacji w następujących etapach:

1. Wybór danych do badań (atrybuty, zbiory cykli archiwalnych).
2. Dobór parametrów badanych metod.
3. Wyznaczenie wartości odległości dla zbioru badanych cykli w grupie poszczególnych, wybranych atrybutów.
4. Wyznaczenie wartości podobieństw dla zbioru badanych cykli w grupie poszczególnych, wybranych atrybutów.
5. Zastosowanie opracowanych sposobów modyfikacji wyznaczonych wartości podobieństw.

6. Przeprowadzenie procesu wyszukiwania podobnych realizacji.
7. Zastosowanie opracowanego sposobu określania wag istotności poszczególnych, wybranych atrybutów.
8. Ponowne przeprowadzenie procesu wyszukiwania podobnych realizacji.
9. Przeprowadzenie oceny otrzymanych wyników według przyjętego kryterium, w celu potwierdzenia tezy.
10. Zebranie wyników badań.
11. Krytyczna ocena zebranych wyników, sformułowanie wniosków wynikających z przeprowadzonych badań oraz podsumowanie badań weryfikacyjnych.

Szczegółowe zestawienie wyników badań weryfikacyjnych będzie przedstawione począwszy od etapu 4. Przebieg badań weryfikacyjnych dla wcześniejszych etapów zostanie opisany jedynie dla kilku przykładowych, wybranych wyników badań, gdyż są one jedynie wstępnymi etapami przygotowania danych zastosowanych do potwierdzenia prawdziwości postawionej tezy.

5.2. Wybór danych do badań

Do badań weryfikacyjnych wykorzystano bazę danych archiwalnych zarejestrowanych dla parametrów statycznych i wolnozmiennych pieca do redukcji miedzi z żużla. Ta baza danych była wykorzystywana także do badań prowadzonych przez R. Szulima [62, 87] w ramach pracy doktorskiej, oraz jest wykorzystywana do badań prowadzonych w Katedrze Podstaw Konstrukcji Maszyn w ramach projektu badawczego pt. „Metodyka heurystycznego modelowania obiektów i procesów dynamicznych w diagnostyce i sterowaniu” przez wieloosobowy zespół naukowy, w tym przez autora rozprawy.

W wykorzystanej bazie danych są zgromadzone dane procesowe dla kilkudziesięciu atrybutów procesowych dotyczących tego obiektu, zarejestrowanych przez system SCADA działający na tym obiekcie, oraz dane pochodzące od obsługi pieca, wprowadzone z formularzy wypełnianych przez osoby nadzorujące i sterujące procesem. Wyściowa baza danych została przygotowana przez R. Szulima [87].

W bazie znajduje się ponad 1500 cykli archiwalnych przebiegów sterowań, z czego do grupy użytecznych cykli można zakwalifikować 580 cykli (na podstawie analizy kompletności danych zgromadzonych cykli). W drodze dalszej analizy wyselekcjonowano 360 cykli [87]. Wśród tych 360 cykli można wyróżnić dwie grupy cykli po 180 cykli każda, pomiędzy którymi istnieje długa przerwa czasowa w zapisie (około 3-miesięczna), która może świadczyć o przeprowadzonym remoncie pieca.

Do badań została wybrana pierwsza grupa cykli (do czasu prawdopodobnego wystąpienia przerwy remontowej), z której po dalszej analizie kompletności zapisów pozostało tylko 130 cykli, które posiadały pełne zapisy dla poszczególnych, wybranych atrybutów procesowych.

W bazie danych zostały zgromadzone dane o trzech podstawowych typach atrybutów procesowych zwanych dalej wolnozmiennymi parametrami procesowymi.

Pierwszą grupę stanowią wolnozmiennie parametry elektryczne dotyczące mocy, napięć, natężeń prądu dla głównych obwodów zasilających pieca elektrycznego. W grupie tej znalazły się także parametry prądowe urządzeń peryferyjnych pieca takich, jak wentylatory, dane o położeniu elektrod oraz o stosowanym zaczeple transformatora.

Parametry dotyczące mocy, napięć, natężeń prądu w pracy zastały określone jako wolnozmiennie ze względu na charakter procesu dla którego były rejestrowane. Na podstawie dostępnych zapisów przebiegów wartości tych atrybutów można zauważyć że posiadają one cechy odpowiadające przyjętym założeniom dla procesu wolnozmiennego, tzn. występują długie okresy czasu gdy ich wartości są ustalone lub zmieniają się wolno w stosunku do czasu trwania całego procesu (cyklu procesu) z widocznym kierunkiem trendu, nie występują nagłe zmiany wartości tych atrybutów w trakcie prowadzenia procesu oraz występuje korzystny stosunek wartości skutecznej sygnału do wartości skutecznej szumu, liczba zdarzeń opisujących zmianę wartości takiego atrybutu w cyklu jest mała oraz czas trwania pojedynczego zdarzenia jest stosunkowo długi względem czasu trwania całego cyklu.

Grupę drugą tworzą wolnozmiennie parametry ciśnienia pieca i jego obwodów zasilania w wodę chłodzącą. Ostatnią grupę tworzą wolnozmiennie parametry temperatur pieca.

Do analizy postanowiono wybrać parametry, które wykazują zauważalne zmiany swoich wartości w czasie trwania poszczególnych cykli, czyli parametry elektryczne i ciśnienia. Pominięto tutaj parametry temperaturowe ze względu na przyjęcie ich jako parametrów stanu cechujących się bardzo małą szybkością zmian ich wartości w czasie. W tablicy 5.1 przedstawiono opis wybranych parametrów.

W tablicy 5.2 przedstawiono wybrane parametry wejść i wyjść procesu oraz czasy trwania poszczególnych faz cykli. Są to parametry o charakterze statycznym. Przyjęto, że są one wartościami punktowymi z początku i końca każdego cyklu. Dla parametru czasów trwania poszczególnych faz cykli wykorzystano tylko czasy ich zakończenia. Nie uwzględniono w badaniach chwil przeprowadzenia analiz chemicznych żużla podczas poszczególnych cykli oraz wartości badanych podczas analiz parametrów. Nie uwzględniono także wartości parametrów opisujących dodatki substancji regulujących proces redukcji miedzi, dodawanych do kąpieli w trakcie prowadzenia procesu.

Omawiane parametry procesowe zostały bardziej szczegółowo omówione w [86, 87].

Tab. 5.1. Wolnozmiennie parametry procesowe wybrane do badań

Identyfikator parametru	Wielkość mierzona
<i>P52043</i>	ciśnienie w piecu elektrycznym
<i>i_0_trafo</i>	prąd zerowy transformatora
<i>p_czy_zas</i>	zasilanie - moc czynna
<i>p_bie_zas</i>	zasilanie - moc bierna
<i>poz_el1</i>	położenie elektrody 1 w piecu
<i>poz_el2</i>	położenie elektrody 2 w piecu
<i>poz_el3</i>	położenie elektrody 3 w piecu
<i>p_czy_el_r</i>	moc czynna pobierana przez elektrodę 1
<i>p_czy_el_s</i>	moc czynna pobierana przez elektrodę 2
<i>p_czy_el_t</i>	moc czynna pobierana przez elektrodę 3
<i>p_bie_el_r</i>	moc bierna pobierana przez elektrodę 1
<i>p_bie_el_s</i>	moc bierna pobierana przez elektrodę 2
<i>p_bie_el_t</i>	moc bierna pobierana przez elektrodę 3
<i>i_zas_r</i>	prąd zasilania elektrody 1
<i>i_zas_s</i>	prąd zasilania elektrody 2
<i>i_zas_t</i>	prąd zasilania elektrody 3
<i>i_el_r</i>	prąd w obwodzie elektrody 1
<i>i_el_s</i>	prąd w obwodzie elektrody 2
<i>i_el_t</i>	prąd w obwodzie elektrody 3
<i>u_el_r</i>	napięcie elektrody 1
<i>u_el_s</i>	napięcie elektrody 2
<i>u_el_t</i>	napięcie elektrody 3
<i>i_pas_12e</i>	prąd 4
<i>i_pas_12g</i>	prąd 5
<i>i_pas_13g</i>	prąd 6
<i>zaczep_poz</i>	pozycja zaczeptu transformatora

Tab. 5.2. Statyczne parametry procesowe wybrane do badań

PARAMETRY WEJŚĆ PROCESU	
Żużel PK [Mg]	ilość żużla z pieca konwertorowego
Żużel PZ [Mg]	ilość żużla z pieca zawieszinowego
Cu [%]	zawartość miedzi w żużlu
Pb [%]	zawartość ołowiu w żużlu
Fe [%]	zawartość żelaza w żużlu
CaO [%]	zawartość tlenku wapnia w żużlu
PARAMETRY WYJŚĆ PROCESU	
Żużel PE [Mg]	ilość żużla w piecu elektrycznym
Energia [MWh]	ilość energii zużytej podczas cyklu
Cu [%]	zawartość miedzi w żużlu
Pb [%]	zawartość ołowiu w żużlu
Fe [%]	zawartość żelaza w żużlu
CaO [%]	zawartość tlenku wapnia w żużlu
CZASY TRWANIA FAZ CYKLI	
Faza 1 [min]	czas trwania fazy 1
Faza 2 [min]	czas trwania fazy 2
Faza 3 [min]	czas trwania fazy 3

5.3. Określenie parametrów weryfikowanych metod

Opracowane metody wymagają określenia wartości wielu zmiennych parametrów. Przyjęte wartości opisano poniżej.

Odstęp próbkowania zarejestrowanych danych wynosi jedną minutę. Czas trwania cyklu wzorcowego wynosi 480 [min]. Każdy cykl składa się z trzech faz [87]:

- zalewanie - czas trwania 90 min,
- redukcja - czas trwania 300 min,
- spust - czas trwania 90 min.

Wymienione powyżej etapy zostały opisane szczegółowo w [86]:

- **zalewanie** (załadunek) - napełnianie pieca elektrycznego żużlem, wsadowanie koksu, żużla stałego, kamienia wapiennego i ciekłego żużla konwertorowego, rozpoczęcie procesu redukcji tlenków przez doprowadzenie dużej ilości energii elektrycznej,
- **redukcja** - kontynuacja procesu redukcji tlenków aż do stwierdzenia na podstawie przeprowadzanych analiz chemicznych, że ilość miedzi w żużlu jest odpowiednio niska i można rozpocząć fazę spustu,
- **spust** - z pieca spuszcza się żużel z zawartością miedzi poniżej 0,8% oraz prowadzone są przygotowania do rozpoczęcia kolejnego cyklu.

Opisane czasy trwania poszczególnych faz cykli odnoszą się do cyklu wzorcowego procesu. Czasy trwania rzeczywistych cykli zwykle różnią się od podanych wartości [86]. Te różnice wynikają z tego, że:

- sterowanie procesem w trakcie różnych cykli było prowadzone przez różnych operatorów (w bazie danych nie zostały zapisane informacje o tym, kto w danym czasie sterował badanym obiektem),
- czasami nie da się określić, kiedy kończy się dany cykl a zaczyna nowy, faza zalewania jest często prowadzona jeszcze w czasie trwania spustu odmiedziowanego żuźla,
- występują różne (czasami znacząco) składy chemiczne żuźla na wejściu procesu, co wymaga dłuższego lub krótszego czasu redukcji,
- wprowadzane substancje dodatkowe wpływają na czas prowadzenia wytopu,
- ponieważ obiekt, z którego pochodzą dane, jest jednym z elementów złożonego ciągu technologicznego, to różne zakłócenia wynikające z działania obiektów połączonych z tym badanym obiektem, wymuszają konieczne operacje powodujące opóźnienie lub przyspieszenie spustu żuźla i zakończenia danego cyklu,
- ze względu na zalecenia eksploatacyjne dotyczące pieca (temperatura pieca, grubość wymurówki, stan elektrod) wprowadzane są dodatkowe zmiany czasu trwania poszczególnych faz cykli,
- podczas działania pieca mogą wystąpić inne zakłócenia występujące na badanym obiekcie (wywołane przez obsługę, uszkodzenia osprzętu pieca itp.).

Ponieważ wybrane do badań cykle różnią się czasami trwania (różne czasy trwania faz i całych cykli), konieczne było przeprowadzenie normalizacji czasowej poszczególnych faz cykli opisanej w rozdziale 4.3, aby móc dokonać porównania poszczególnych cykli (faz).

Zdecydowano, że normalizacja zostanie przeprowadzona dla poszczególnych faz względem najkrócej trwających faz wybranych cykli. Przyjęto, że cykl odniesienia będzie się składał z faz o najkrótszych czasach trwania, określonych w zbiorze cykli wybranych do badań.

Aproksymację przebiegów parametrów procesowych przeprowadzono zatem w następującej liczbie punktów aproksymacji:

- 60 punktów dla fazy zalewania,
- 145 punktów dla fazy redukcji,
- 80 punktów dla fazy spustu.

Tak zdefiniowany cykl wzorcowy będzie dalej stosowany w prowadzonej weryfikacji.

Wartości podziałki były wyznaczane za każdym razem, w każdej fazie cyklu i dla każdej rozpatrywanej pary porównywanych cykli o indeksach (k, j) . Dzięki takiemu założeniu fazy o czasie trwania dłuższym niż fazy cyklu odniesienia, były opisywane za pomocą liczby punktów aproksymacji mniejszej niż rzeczywista liczba próbek zarejestrowanych

podczas trwania danej fazy porównywanego cyklu. Wartości podziałki dla tak określonego cyklu odniesienia zawsze były mniejsze od 1, zgodnie ze zdefiniowaną zależnością (4.1).

Opracowana metoda normalizacji czasowej nie wymaga, aby przy budowie wzorcowego cyklu uwzględniać najkrócej trwające fazy.

W tabelicy 5.3 zestawiono przykładowe, wyznaczone wartości podziałki dla zdefiniowanego wcześniej cyklu odniesienia.

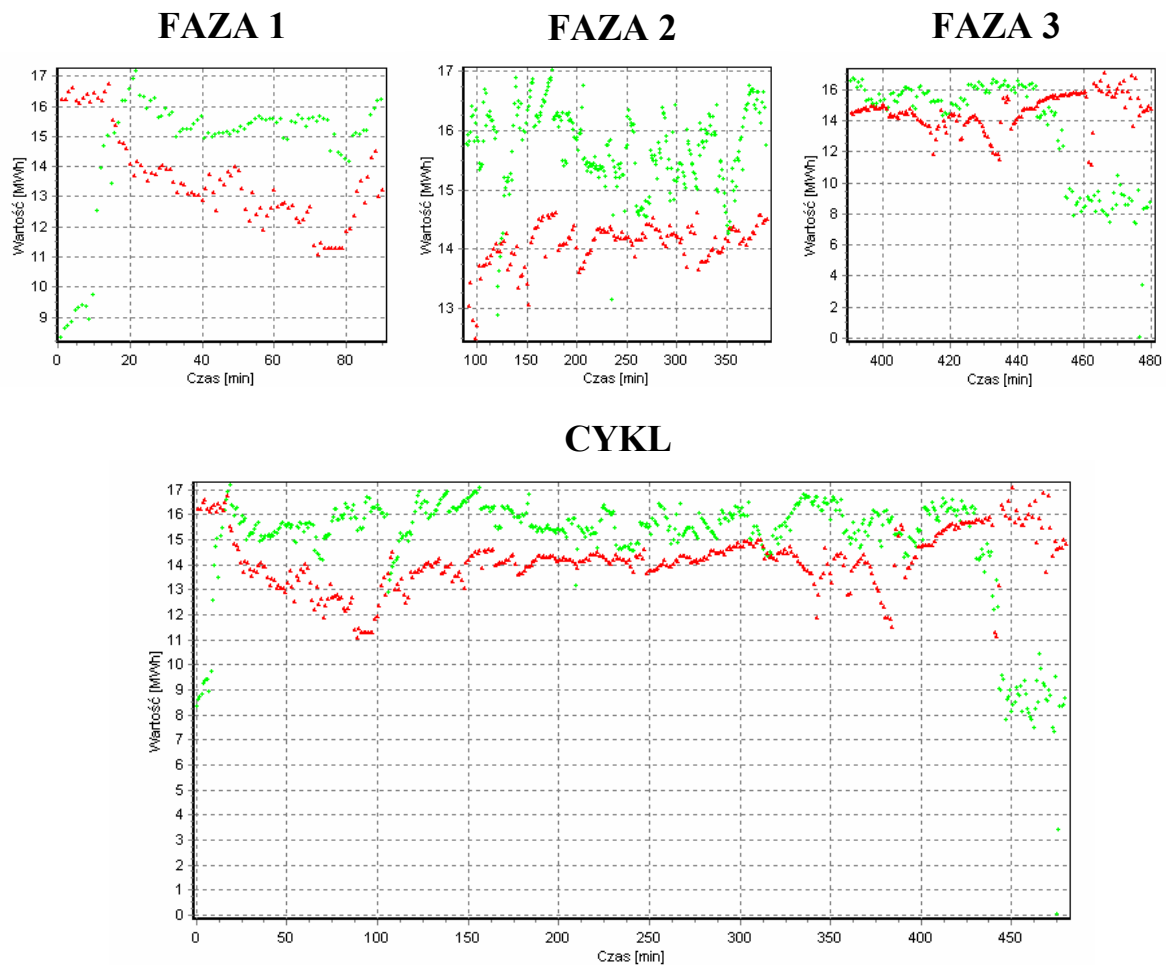
Tab. 5.3. Przykładowe wartości podziałki dla wybranych cykli

ID Cyklu	Cecha	Faza1 [min]	Faza2 [min]	Faza3 [min]	Cykl [min]
Cykl wzorcowy	Czas trwania [min]	60	145	80	285
1534	Czas trwania [min]	90	315	150	555
	Podziałka	0,66	0,46	0,53	0,51
4531	Czas trwania [min]	75	315	125	515
	Podziałka	0,8	0,46	0,53	0,64

Przyjęto, że liczba punktów aproksymacji dla każdej fazy badanych cykli będzie ustalona na poziomie wynikającym z czasów trwania poszczególnych faz przyjętego cyklu odniesienia.

Założono, że w trakcie wyznaczania wartości podobieństw przebiegów rozpatrywanych atrybutów procesowych zostaną określone wartości odległości i podobieństw dla poszczególnych faz i na ich podstawie, zgodnie z zależnościami zdefiniowanymi w rozdziale 4, zostanie określone podobieństwo całego cyklu które dalej będzie stosowane w procesie weryfikacji opracowanych metod.

Na rys. 5.1 przedstawiono przebiegi przykładowego parametru procesowego *p_czy_zas* (Tab. 5.1) dla dwóch wybranych cykli 1534 i 1480.



Rys. 5.1. Wykresy przebiegów wybranych cykli (ID=1534 i ID=1480) dla parametru p_czy_zas

5.4. Wyznaczenie wartości odległości pomiędzy wykresami wybranych parametrów procesowych

Następnym krokiem po określeniu parametrów weryfikowanych metod było wyznaczenie wartości odległości dla punktów aproksymacji przyjętych dla poszczególnych faz wybranych cykli i parametrów procesowych. W tej części weryfikacji metod, zostały przedstawione tylko przykładowe wyniki wyznaczonych wartości odległości bezwzględnych dla metody opisanej w rozdziale 4.5 i rozdziale 4.6. Wartości odległości względnych stosowanych w metodzie opisanej w rozdziale 4.7 nie były tutaj przedstawione, gdyż sposób ich wyznaczania jest podobny i został omówiony już we wcześniejszym rozdziale.

W tabelicy 5.4 przedstawiono wyniki wyznaczenia wartości odległości dla trzech wybranych cykli spośród 130 cykli badanych, dla parametru procesowego p_czy_zas (Tab. 5.1). W tabelicy zestawiono cykle, dla których wyznaczono największe i najmniejsze wartości odległości względem przykładowego, wybranego cyklu o numerze 1534. Badanie przeprowadzono dla rozpatrywanych w rozdziale 4.4 krzywych wielomianowych. Normaliza-

cja została przeprowadzona dla poszczególnych faz względem najkrócej trwających faz wybranych cykli. Przyjęto, że cyklem odniesienia został cykl, który składał się z faz o najkrótszych czasach trwania, określonych w zbiorze cykli wybranych do badań.

Tab. 5.4. Wartości odległości dla wybranych cykli wyznaczone za pomocą metody bazującej na odległościach bezwzględnych

ID Cyklu	Faza1		Faza2		Faza3		Cykl	
	Bezier	B-Spline	Bezier	B-Spline	Bezier	B-Spline	Bezier	B-Spline
4582	12,99	13,69	4,93	6,74	10,18	10,93	9,32	10,61
...
4531	12,36	18,59	5,30	7,81	31,93	31,37	18,03	18,97
...
286	29,60	30,22	21,98	22,55	47,66	49,72	29,10	31,86

5.5. Wyznaczenie wartości podobieństw cykli wybranych parametrów procesowych

Na podstawie wyznaczonych w poprzednim etapie wartości odległości pomiędzy poszczególnymi punktami aproksymującymi przebiegi poszczególnych, porównywanych faz cykli, dla wybranych parametrów procesowych określono wartości podobieństw pomiędzy cyklami dla poszczególnych ich faz. Poniżej zestawiono wyniki uzyskanych podobieństw dla wybranych parametrów procesowych statycznych (wejścia, wyjścia i parametry czasu trwania poszczególnych faz cykli) oraz dla oryginalnych i zmodyfikowanych podobieństw średnich całkowitych (rozdział 4).


W tablicy 5.5 przedstawiono przykładowe wyniki dla wyznaczonych wartości podobieństw w zakresie poszczególnych faz badanych cykli dla parametru *p_czy_zas*. Im mniejsza była wartość sumy wyznaczonych wcześniej odległości pomiędzy punktami aproksymującymi przebiegi sterowań dla porównywanych faz cykli, tym większa jest wartość podobieństwa tych cykli pomiędzy sobą, wyznaczonego w dalszej części badań.

Na rys. 5.2 przedstawiono histogram wartości podobieństw dla grupy badanych cykli względem cyklu 1534. Jak widać na tym histogramie, najbardziej liczny podzbiór cykli ma podobieństwo o wartości około 0,6.

W przedstawionych poniżej tablicach zestawiono przykładowe wyniki wyznaczonych wartości podobieństw dla parametrów wejściowych (Tab. 5.6), wyjściowych (Tab. 5.7) oraz czasów trwania poszczególnych faz cykli (Tab. 5.8).

Tab. 5.5. Wartości podobieństw do cyklu 1534 dla poszczególnych faz wybranych cykli


ID Cyklu	Krzywe Beziera	Krzywe B-Spline
Faza1		
4582	0,73	0,71
4531	0,75	0,61
286	0,38	0,38
Faza2		
4582	0,86	0,82
4531	0,85	0,79
286	0,38	0,39
Faza3		
4582	0,85	0,83
4531	0,54	0,54
286	0,31	0,28

Rys. 5.2. Histogram wartości podobieństw dla badanych 130 cykli względem cyklu 1534, dla parametru *p_czy_zas*

Przykładowe histogramy (Rys. 5.3, 5.4, 5.6) dotyczą wartości wyznaczonych podobieństw w grupie 130 badanych cykli dla parametrów statycznych. Jak widać na tych histogramach, najliczniejszą klasę stanowią cykle o wartościach podobieństw około 0,6, podobnie jak w przypadku wartości wyznaczonego podobieństwa dla parametrów dynamicznych wolnozmiennych (Rys. 5.2).

Tab. 5.6. Podobieństwa wielkości wejściowych wybranych cykli względem cyklu 1534


IDCyklu	Podobieństwa						ΠISC_{CALK}^{WE}
	ŻPK[Mg]	ŻPZ[Mg]	Cu[%]	Pb[%]	Fe[%]	CaO[%]	
4531	1,0	1,0	0,93	0,64	0,62	0,45	0,78
286	0,5	0,55	0,53	0,71	0,70	0,39	0,58
4582	0,5	0,55	0,43	0,38	0,54	0,41	0,48



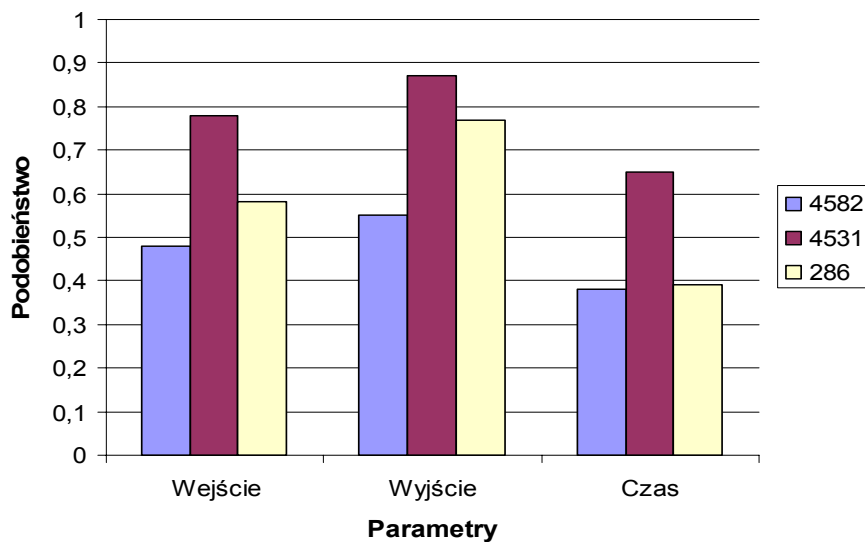
Rys. 5.3. Histogram wartości podobieństw dla parametrów wejściowych (130 cykli) względem cyklu 1534

Tab. 5.7. Podobieństwa wielkości wyjściowych wybranych cykli względem cyklu 1534

IDCyklu	Podobieństwa						ΠISC_{CALK}^{WY}
	Energia[MWh]	ŻPE[Mg]	Cu[%]	Pb[%]	Fe[%]	CaO[%]	
4531	0,88	1,0	0,78	1,0	0,71	0,83	0,87
286	0,88	1,0	0,39	0,77	0,80	0,85	0,77
4582	0,24	0,50	0,86	0,83	0,25	0,55	0,55




Rys. 5.4. Histogram wartości podobieństw dla parametrów wyjściowych (130 cykli) względem cyklu 1534



Rys. 5.5. Podobieństwa parametrów statycznych wybranych cykli względem cyklu 1534

Tab. 5.8. Podobieństwa parametrów czasowych wybranych cykli względem cyklu 1534

ID Cyklu	Podobieństwa			ΠSC_{CALK}^{CZAS}
	Zalewanie	Redukcja	Spust	
4531	0,50	1,0	0,46	0,65
286	0,42	0,28	0,41	0,39
4582	0,42	0,32	0,27	0,38



Rys. 5.6. Histogram wartości podobieństw dla parametrów czasowych (130 cykli) względem cyklu 1534

W poniżej przedstawionych tablicach zestawiono wyniki porównania w grupie 130 cykli dla wybranego parametru procesowego (p_czy_zas) przy założeniu że cyklem, względem którego określane są podobieństwa, jest cykl 1534. Przedstawione dane zostały otrzymane z zastosowaniem poniższych metod, bazujących:

- na mierze euklidesowej dla odległości bezwzględnej (Tab. 5.9) według zależności (4.4),
- na mierze euklidesowej dla odległości względnej (Tab. 5.10) według zależności (4.20) oraz na odległościach względnych kątowych (Tab. 5.11) według zależności (4.24),
- na sekwencjach znakowych (Tab. 5.12 do 5.14) według zależności (4.15).

Wyznaczone podobieństwa są podobieństwami średnimi całkowitymi określonymi zgodnie z zależnością (4.7).

W tablicach zestawiono wyniki dla wybranych cykli w trzech klasach wartości podobieństw (największe, średnie i najmniejsze wartości podobieństwa) względem cyklu odniesienia 1534, uzyskanych w wyniku zastosowania danej metody z zastosowaniem modyfikacji wartości wyznaczonych podobieństw oraz bez modyfikacji. Liczba punktów aproksymacji została ustalona według wcześniej przyjętych założeń. Zdecydowano,

że do dalszych badań weryfikacyjnych zostaną wykorzystane tylko podobieństwa wyznaczone dla wielomianowej aproksymacji przebiegów krzywymi Beziera (Rozdz. 4.4), ponieważ wyniki otrzymane dla krzywych B-Spline były zbliżone do tych uzyskanych metodą aproksymacji krzywymi Beziera i nie wносиły one żadnych istotnych informacji dla dalszej weryfikacji opracowanych metod. Poza tym stwierdzono w trakcie badań że operacje wykonywane z wykorzystaniem krzywych Beziera wymagają o wiele mniej nakładów obliczeniowych. Z tych względów zdecydowano się na kontynuowanie obliczeń weryfikacyjnych jedynie dla jednej metody aproksymacji.

Zastosowanie funkcji modyfikującej wartości podobieństw w grupie badanych przebiegów (tutaj funkcja sigmoidalna) powoduje, że zwiększa się rozróżnialność pomiędzy poszczególnymi cyklami. Oryginalny histogram wartości wyznaczonych podobieństw jest bardzo skoncentrowany w środkowej części przedziału wartości podobieństwa. Oznacza to, że w zbiorze podobieństw występuje dużo cykli o średniej wartości podobieństw i bardzo mało cykli o bardzo małej lub bardzo dużej wartości podobieństwa. Ponieważ modyfikacja zachodzi już na etapie wyznaczania podobieństw dla poszczególnych faz cyklu, to wpływa to na kolejność cykli w grupie badanych cykli (względem oryginalnych i zmodyfikowanych wartości podobieństw). Nie zmienia się natomiast przynależność cyklu względem klasy wartości podobieństwa (wysokie, średnie, niskie).

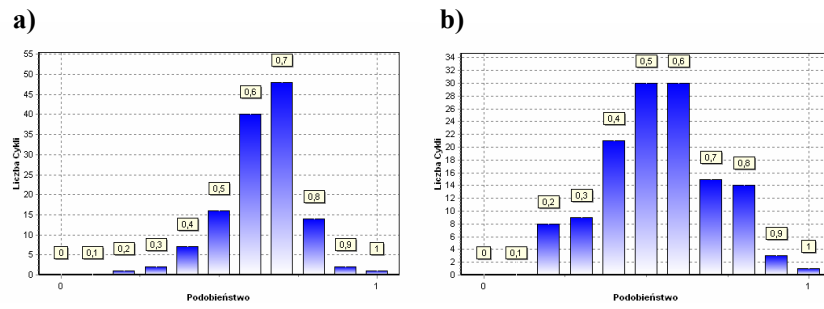
Dodatkowo w przypadku wartości podobieństw wyliczonych z metod bazujących na odległościach względnych (Tab. 5.10 do 5.11), oryginalne wartości podobieństw są jeszcze bardziej skoncentrowane w środkowej części przedziału wartości podobieństwa, co powoduje, że porównywane cykle są bardzo słabo rozróżnialne w razie niezastosowania funkcji modyfikujących.

W przypadku metody sekwencji znakowych istotny wpływ na wartość podobieństwa ma długość rozpatrywanej sekwencji. Im dłuższa jest sekwencja znakowa, tym mniej rozróżnialne są cykle, oraz wartości wyznaczanych podobieństw gwałtownie maleją (Tab. 5.12 do 5.14). Niezależnie od tego konieczne jest zastosowanie funkcji modyfikujących wartości podobieństw (Rozdz. 4.8).

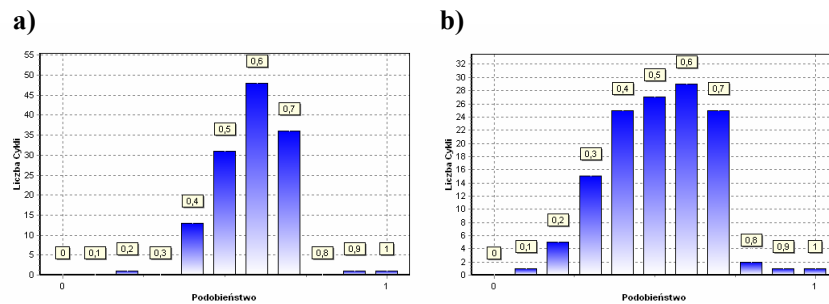
Na histogramach - Rys. 5.7 do 5.10 - przedstawiono gęstości rozkładu empirycznego wartości wyznaczonych podobieństw oryginalnych i zmodyfikowanych dla wybranych cykli i parametrów.

Tab. 5.9. Wartości wyznaczonych podobieństw wybranych cykli do cyklu o indeksie 1534 dla metody bazującej na mierze euklidesowej i odległości bezwzględnej (podobieństwa obliczane dla parametru *p_czy_zas*)

ID Cyklu	Wartości podobieństw	
	oryginalne	zmodyfikowane
4582	0,819	0,902
4537	0,789	0,856
1600	0,776	0,871
238	0,766	0,831
1462	0,759	0,830
1531	0,758	0,799
382	0,749	0,828
4579	0,746	0,810
...
1	0,665	0,658
1549	0,665	0,590
1567	0,665	0,601
1561	0,663	0,602
2191	0,662	0,602
2113	0,662	0,600
1576	0,661	0,619
1513	0,660	0,574
...
2125	0,437	0,339
1495	0,320	0,304
4564	0,485	0,287
2119	0,483	0,282
1456	0,502	0,277
364	0,457	0,250
2128	0,342	0,199
286	0,362	0,186



Rys. 5.7. Histogramy wartości podobieństw dla metody bazującej na odległości bezwzględnej dla parametru p_czy_zas : a) podobieństwo niezmodyfikowane, b) podobieństwo zmodyfikowane



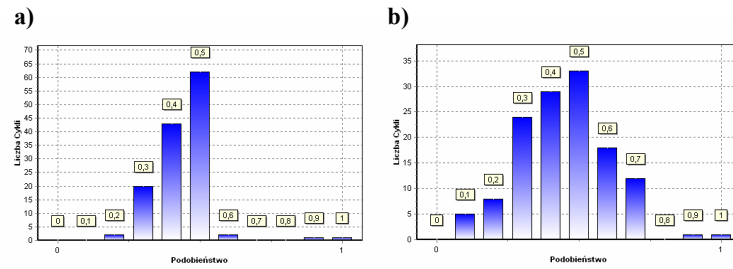
Rys. 5.8. Histogramy wartości podobieństw dla metody bazującej na odległości względnej dla parametru p_czy_zas : a) podobieństwo niezmodyfikowane, b) podobieństwo zmodyfikowane

Tab. 5.10. Wartości wyznaczonych podobieństw wybranych cykli do cyklu o indeksie 1534 dla metody bazującej na mierze euklidesowej i odległości względnej (podobieństwa obliczane dla parametru p_czy_zas)

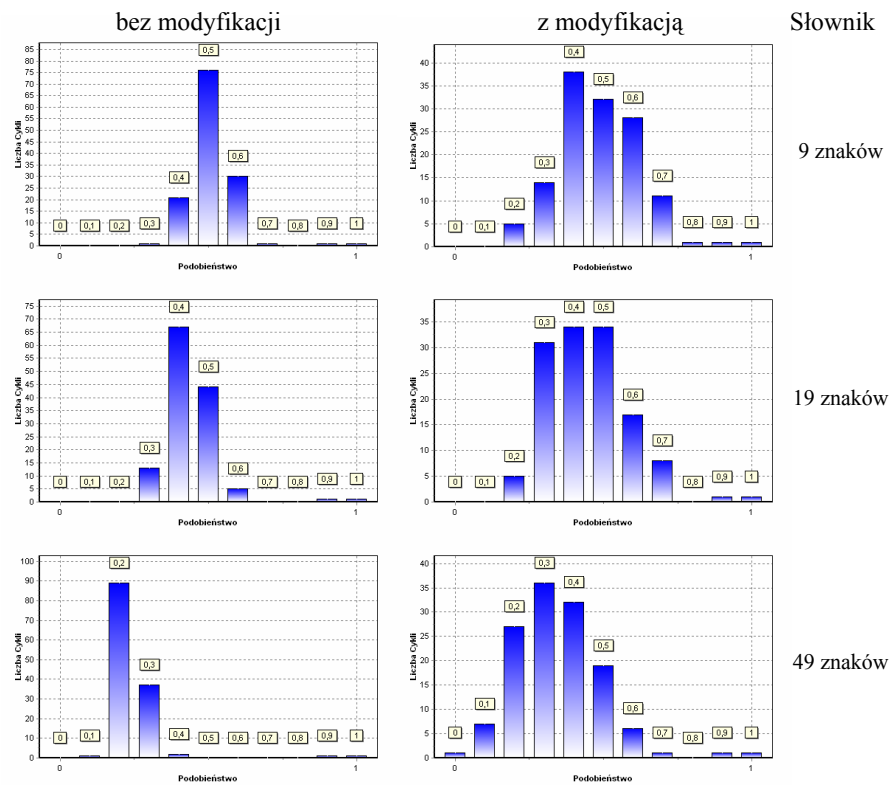
ID Cyklu	Wartości podobieństw	
	oryginalne	zmodyfikowane
4576	0,666	0,786
1474	0,666	0,823
268	0,657	0,803
1567	0,648	0,785
4597	0,647	0,734
1549	0,646	0,724
1492	0,645	0,782
4537	0,641	0,700
...
1558	0,585	0,555
130	0,585	0,569
262	0,585	0,594
238	0,584	0,612
1480	0,583	0,570
247	0,582	0,536
1531	0,581	0,560
1471	0,581	0,548
...
1594	0,458	0,276
1603	0,422	0,273
1597	0,365	0,254
259	0,403	0,237
244	0,385	0,230
4615	0,347	0,228
286	0,407	0,226
2128	0,372	0,199

Tab. 5.11. Wartości wyznaczonych podobieństw wybranych cykli do cyklu o indeksie 1534 dla metody bazującej na mierze euklidesowej i odległości względnej kątowej (podobieństwa obliczane dla parametru p_czy_zas)

ID Cyklu	Wartości podobieństw	
	oryginalne	zmodyfikowane
4576	0,612	0,767
1474	0,611	0,794
268	0,600	0,772
4597	0,599	0,739
1567	0,592	0,761
1549	0,589	0,706
4582	0,586	0,713
1492	0,585	0,749
...
280	0,518	0,504
241	0,517	0,521
4534	0,516	0,516
391	0,515	0,528
262	0,514	0,541
1480	0,514	0,515
247	0,514	0,496
130	0,513	0,518
...
1501	0,335	0,254
1603	0,371	0,252
1525	0,336	0,243
1597	0,312	0,222
259	0,324	0,252
244	0,315	0,262
286	0,330	0,268
2128	0,269	0,200



Rys. 5.9. Histogramy wartości podobieństw dla metody bazującej na odległości względnej kątowej dla parametru *p_czy_zas*: a) podobieństwo niezmodyfikowane, b) podobieństwo zmodyfikowane



Rys. 5.10. Histogramy wartości podobieństw dla metody bazującej na sekwencjach znakowych ze słownikiem o różnej liczbie znaków dla parametru *p_czy_zas* (podobieństwo niezmodyfikowane i zmodyfikowane)

Tab. 5.12. Wartości wyznaczonych podobieństw wybranych cykli do cyklu o indeksie 1534 dla metody bazującej na sekwencjach znakowych ze słownikiem 9-znakowym (podobieństwa obliczane dla parametru p_czy_zas)

ID Cyklu	Wartości podobieństw	
	oryginalne	zmodyfikowane
4597	0,654	0,813
280	0,635	0,795
1570	0,621	0,767
1504	0,617	0,769
1	0,614	0,666
4564	0,608	0,701
1660	0,608	0,643
1576	0,604	0,757
...
1561	0,546	0,565
70	0,544	0,570
238	0,543	0,588
4519	0,540	0,580
2125	0,539	0,509
2146	0,537	0,579
1591	0,536	0,490
232	0,536	0,518
...
241	0,457	0,329
259	0,439	0,326
1459	0,473	0,314
4561	0,455	0,306
76	0,436	0,294
1573	0,458	0,293
1456	0,433	0,278
235	0,411	0,222

Tab. 5.13. Wartości wyznaczonych podobieństw wybranych cykli do cyklu o indeksie 1534 dla metody bazującej na sekwencjach znakowych ze słownikiem 19-znakowym (podobieństwa obliczane dla parametru p_czy_zas)

ID Cyklu	Wartości podobieństw	
	oryginalne	zmodyfikowane
1	0,538	0,722
4597	0,526	0,748
1570	0,501	0,717
280	0,494	0,716
130	0,488	0,671
268	0,487	0,626
1663	0,484	0,654
1660	0,477	0,558
...
1564	0,429	0,539
2143	0,427	0,527
220	0,425	0,526
361	0,425	0,448
283	0,425	0,520
391	0,424	0,474
1498	0,423	0,482
4516	0,421	0,443
...
76	0,339	0,278
1651	0,349	0,268
2128	0,358	0,265
1459	0,357	0,265
1600	0,354	0,251
1573	0,339	0,233
1456	0,343	0,230
373	0,336	0,213

Tab. 5.14. Wartości wyznaczonych podobieństw wybranych cykli do cyklu o indeksie 1534 dla metody bazującej na sekwencjach znakowych ze słownikiem 49-znakowym (podobieństwa obliczane dla parametru p_czy_zas)

ID Cyklu	Wartości podobieństw	
	oryginalne	zmodyfikowane
1	0,362	0,538
1567	0,361	0,654
4576	0,329	0,630
4597	0,324	0,620
130	0,309	0,616
4	0,308	0,567
1492	0,302	0,568
2092	0,299	0,443
...
1564	0,255	0,372
4603	0,252	0,374
385	0,250	0,412
1528	0,250	0,419
283	0,250	0,373
1654	0,250	0,424
1546	0,250	0,441
1543	0,250	0,414
...
2095	0,457	0,329
2191	0,439	0,326
4561	0,473	0,314
1600	0,455	0,306
1573	0,436	0,294
1501	0,458	0,293
4522	0,433	0,278
2098	0,411	0,222

5.6. Przykłady wyszukiwania podobnych realizacji

W poniższym etapie przeprowadzono zadanie wyszukiwania zbiorów podobnych cykli przy założeniu jednakowo istotnych wybranych parametrów procesowych oraz dla parametrów procesowych z określonymi wagami istotności wybranych parametrów na podstawie zależności omówionych w rozdziale 4.9. Dodatkowo zbadano celowość uwzględniania parametru czasowego (uśrednione wartości podobieństw dla czasów trwania poszczególnych faz porównywanych cykli wyznaczone na podstawie zależności (4.14)).

Przedstawione wyniki wyszukanych podobnych cykli zostały zestawione dla jednego wybranego cyklu o numerze ID=1534.

W przeprowadzonych badaniach mamy do czynienia z trzema klasami parametrów:

- parametry wejściowe,
- parametry wolnozmiennie,
- parametry wyjściowe.

Zestawione wartości podobieństw wyszukanych cykli procesu są wartościami znormalizowanymi dla każdej klasy badanych parametrów względem:

- uśrednionych wartości podobieństw parametrów wejściowych,
- uśrednionych wartości podobieństw parametrów wolnozmiennych,
- uśrednionych wartości podobieństw parametrów wyjściowych.

Uśrednione wartości podobieństw parametrów wejściowych i wyjściowych wyznaczono jako średnią arytmetyczną sumy wartości podobieństw pomiędzy poszczególnymi cyklami atrybutów w rozpatrywanej klasie tych atrybutów (wejściowe, wyjściowe). W przypadku uśrednionych wartości podobieństw parametrów wolnozmiennych zastosowano średnią ważoną. Wagi dla poszczególnych atrybutów zostały wyznaczone w procesie ewolucyjnym opisanym w rozprawie.

Normalizację przeprowadzono na podstawie następującej zależności (5.1):

$$\Pi_{KLS}^{Norm}(k, j) = \frac{\Pi_{KLS}(k, j)}{\max(\Pi_{KLS}(k, j))} \quad (5.1)$$

gdzie:

$\Pi_{KLS}^{Norm}(k, j)$ - wartość podobieństwa znormalizowanego dla zbioru badanych cykli o indeksach (k, j) z danej klasy parametrów,

$\Pi_{KLS}(k, j)$ - wartość uśrednionego podobieństwa wyznaczonego we wcześniejszym etapie, dla zbioru badanych cykli o indeksach (k, j) z danej klasy parametrów,

$\max(\Pi_{KLS}(k, j))$ - maksymalna wartość uśrednionego podobieństwa wyznaczonego we wcześniejszym etapie, dla zbioru badanych cykli o indeksach (k, j) z danej klasy parametrów,

KLS - klasa badanych parametrów (wejścia, parametrów wolnozmiennych, wyjścia).

Taka normalizacja powoduje, że w danej klasie parametrów, najwyższe podobieństwo równe 1 ma realizacja procesu, która miała uprzednio najwyższe podobieństwo (mniejsze od 1). Podobieństwo najniższe równe 0, w danej klasie parametrów ma realizacja procesu, która miała uprzednio najniższe podobieństwo (większe od 0).

W tablicach zestawiono wyniki dla wartości badanych realizacji procesowych w następujących kategoriach:

- podobieństwo wejść - uśrednione podobieństwo cykli wybranych parametrów procesowych statycznych wejściowych,
- podobieństwo parametrów wolnozmiennych - uśrednione podobieństwo cykli wybranych parametrów procesowych wolnozmiennych,
- podobieństwo wyjść - uśrednione podobieństwo cykli wybranych parametrów procesowych statycznych wyjściowych,
- podobieństwo całkowite - uśrednione podobieństwo wybranych cykli dla poszczególnych klas parametrów.

Proces wyszukiwania podobnych cykli przeprowadzono dla podobieństw wyznaczonych za pomocą każdej badanej metody osobno i zestawiono w tablicach:

- metoda bazująca na mierze euklidesowej dla odległości globalnej (Tab. 5.15 do 5.17),
- metoda bazująca na mierze euklidesowej dla odległości lokalnych (Tab. 5.18 do 5.20) i odległości lokalnych kątowych (Tab. 5.21 do 5.23),
- metoda bazująca na sekwencjach znakowych (Tab. 5.24 do 5.26).

W każdej tablicy przedstawiono trzy grupy podobieństw cykli:

- najbardziej podobnych do cyklu 1534,
- średnio podobnych do cyklu 1534,
- najmniej podobnych do cyklu 1534.

Na końcu przedstawiono zestawienie wyliczonych średnich wartości podobieństw realizacji wyznaczonych dla wszystkich weryfikowanych metod (Tab. 5.27).

Tab. 5.15. Wyszukany zbiór cykli o różnych podobieństwach do cyklu 1534 (jednakowa istotność parametrów, nie uwzględniono parametru czasu) dla metody bazującej na odległościach bezwzględnych

ID Cyklu	Podobieństwa			
	Wejścia	Parametry wolnozmiennie	Wyjścia	Całkowite
4531	0,97	0,87	1,00	0,95
1543	0,81	0,90	0,89	0,87
1579	1,00	0,9	0,68	0,86
...
1492	0,63	0,84	0,63	0,70
2191	0,54	0,77	0,78	0,70
...
1603	0,76	0,50	0,45	0,57
1456	0,55	0,64	0,49	0,56
1459	0,41	0,72	0,45	0,53

Tab. 5.16. Wyszukany zbiór cykli o różnych podobieństwach do cyklu 1534 (jednakowa istotność parametrów, uwzględniono parametr czasu) dla metody bazującej na odległościach bezwzględnych

ID Cyklu	Podobieństwa			
	Wejścia	Parametry wolnozmiennie	Wyjścia	Całkowite
4531	0,97	0,87	1,00	0,95
1543	0,81	0,91	0,89	0,87
1579	1,00	0,91	0,68	0,86
...
1492	0,63	0,84	0,63	0,70
2191	0,54	0,78	0,78	0,70
...
1603	0,76	0,50	0,45	0,57
1456	0,55	0,65	0,49	0,57
1459	0,41	0,74	0,45	0,53

Tab. 5.17. Wyszukany zbiór cykli o różnych podobieństwach do cyklu 1534 (ważona istotność parametrów, uwzględniono parametr czasu) dla metody bazującej na odległościach bezwzględnych

ID Cyklu	Podobieństwa			Całkowite
	Wejścia	Parametry wolnozmiennie	Wyjścia	
4531	0,97	0,86	1,00	0,94
1579	1,00	0,86	0,68	0,85
1543	0,81	0,82	0,89	0,84
...
1492	0,63	0,84	0,63	0,70
2191	0,54	0,78	0,78	0,70
...
1456	0,55	0,58	0,49	0,54
1603	0,76	0,40	0,45	0,54
1459	0,41	0,71	0,45	0,52

Tab. 5.18. Wyszukany zbiór cykli o różnych podobieństwach do cyklu 1534 (jednakowa istotność parametrów, nie uwzględniono parametru czasu) dla metody bazującej na odległościach względnych.

ID Cyklu	Podobieństwa			Całkowite
	Wejścia	Parametry wolnozmiennie	Wyjścia	
4531	0,97	0,75	1,00	0,91
1660	0,92	0,87	0,86	0,89
4573	0,74	0,82	0,93	0,83
...
130	0,66	0,68	0,75	0,70
1561	0,75	0,81	0,54	0,70
...
1459	0,41	0,70	0,45	0,52
4615	0,57	0,53	0,45	0,52
1456	0,55	0,49	0,49	0,51

Tab. 5.19. Wyszukany zbiór cykli o różnych podobieństwach do cyklu 1534 (jednakowa istotność parametrów, uwzględniono parametr czasu) dla metody bazującej na odległościach względnych

ID Cyklu	Podobieństwa			
	Wejścia	Parametry wolnozmiennie	Wyjścia	Całkowite
4531	0,97	0,77	1,00	0,92
1660	0,92	0,89	0,86	0,89
1570	0,87	0,88	0,74	0,83
...
130	0,66	0,70	0,75	0,71
1561	0,75	0,83	0,54	0,71
...
1459	0,41	0,73	0,45	0,53
1456	0,55	0,52	0,49	0,52
4516	0,57	0,53	0,45	0,52

Tab. 5.20. Wyszukany zbiór cykli o różnych podobieństwach do cyklu 1534 (ważona istotność parametrów, uwzględniono parametr czasu) dla metody bazującej na odległościach względnych

ID Cyklu	Podobieństwa			
	Wejścia	Parametry wolnozmiennie	Wyjścia	Całkowite
4531	0,97	0,77	1,00	0,92
1660	0,92	0,89	0,86	0,89
1570	0,87	0,88	0,74	0,83
...
130	0,66	0,70	0,75	0,71
1561	0,75	0,83	0,54	0,71
...
1459	0,41	0,73	0,45	0,53
4615	0,57	0,53	0,45	0,52
1456	0,55	0,51	0,49	0,52

Tab. 5.21. Wyszukany zbiór cykli o różnych podobieństwach do cyklu 1534 (jednakowa istotność parametrów, nie uwzględniono parametru czasu) dla metody bazującej na odległościach względnych kątowych

ID Cyklu	Podobieństwa			Całkowite
	Wejścia	Parametry wolnozmiennie	Wyjścia	
4531	0,97	0,79	1,00	0,92
1660	0,92	0,87	0,86	0,88
1579	1,00	0,88	0,68	0,85
...
2113	0,71	0,84	0,56	0,70
1492	0,63	0,83	0,63	0,70
...
4615	0,57	0,67	0,45	0,56
1459	0,41	0,80	0,45	0,56
1456	0,55	0,59	0,49	0,54

Tab. 5.22. Wyszukany zbiór cykli o różnych podobieństwach do cyklu 1534 (jednakowa istotność parametrów, uwzględniono parametr czasu) dla metody bazującej na odległościach względnych kątowych

ID Cyklu	Podobieństwa			Całkowite
	Wejścia	Parametry wolnozmiennie	Wyjścia	
4531	0,97	0,81	1,00	0,93
1660	0,92	0,88	0,86	0,89
1579	1,00	0,89	0,68	0,86
...
2113	0,71	0,86	0,56	0,71
1492	0,63	0,85	0,63	0,70
...
4615	0,57	0,67	0,45	0,56
1459	0,41	0,82	0,45	0,56
1456	0,55	0,61	0,49	0,55

Tab. 5.23. Wyszukany zbiór cykli o różnych podobieństwach do cyklu 1534 (ważona istotność parametrów, uwzględniono parametr czasu) dla metody bazującej na odległościach względnych kątowych

ID Cyklu	Podobieństwa			
	Wejścia	Parametry wolnozmiennie	Wyjścia	Całkowite
4531	0,97	0,84	1,00	0,94
1660	0,92	0,86	0,86	0,88
4573	74	0,80	0,93	0,82
...
2113	0,71	0,86	0,56	0,71
1492	0,63	0,85	0,63	0,70
...
4615	0,57	0,62	0,45	0,55
1456	0,55	0,55	0,49	0,53
1459	0,41	0,64	0,45	0,50

Tab. 5.24. Wyszukany zbiór cykli o różnych podobieństwach do cyklu 1534 (ważona istotność parametrów, uwzględniono parametr czasu) dla metody bazującej na sekwencjach znakowych ze słownikiem 9-znakowym

ID Cyklu	Podobieństwa			
	Wejścia	Parametry wolnozmiennie	Wyjścia	Całkowite
4531	0,97	0,83	1	0,93
1660	0,92	0,90	0,86	0,89
2104	0,93	0,85	0,85	0,88
...
361	0,78	0,91	0,47	0,72
1465	0,55	0,93	0,68	0,72
...
4615	0,57	0,80	0,45	0,61
4	0,47	0,82	0,50	0,60
1459	0,41	0,89	0,45	0,58

Tab. 5.25. Wyszukany zbiór cykli o różnych podobieństwach do cyklu 1534 (ważona istotność parametrów, uwzględniono parametr czasu) dla metody bazującej na sekwencjach znakowych ze słownikiem 19-znakowym

ID Cyklu	Podobieństwa			Całkowite
	Wejścia	Parametry wolnozmiennie	Wyjścia	
4531	0,97	0,88	1	0,95
1660	0,92	0,92	0,86	0,90
2104	0,93	0,87	0,85	0,88
...
361	0,78	0,91	0,47	0,72
1465	0,55	0,95	0,68	0,73
...
1648	0,50	0,75	0,6	0,62
4	0,47	0,83	0,50	0,60
1459	0,41	0,85	0,45	0,57

Tab. 5.26. Wyszukany zbiór cykli o różnych podobieństwach do cyklu 1534 (ważona istotność parametrów, uwzględniono parametr czasu) dla metody bazującej na sekwencjach znakowych ze słownikiem 49-znakowym

ID Cyklu	Podobieństwa			Całkowite
	Wejścia	Parametry wolnozmiennie	Wyjścia	
4531	0,97	0,90	1	0,96
1660	0,92	0,90	0,86	0,89
2104	0,93	0,83	0,85	0,87
...
361	0,78	0,91	0,47	0,72
1465	0,55	0,93	0,68	0,72
...
2143	0,70	0,73	0,39	0,60
4	0,47	0,83	0,50	0,60
1459	0,41	0,85	0,45	0,57

Tab. 5.27. Wyszukany zbiór cykli o różnych podobieństwach do cyklu 1534 (ważona istotność parametrów, uwzględniono parametr czasu) dla uśrednionych wartości podobieństw badanych cykli wyznaczonych za pomocą weryfikowanych metod

ID Cyklu	Podobieństwa			
	Wejścia	Parametry wolnozmiennie	Wyjścia	Całkowite
4531	0,97	0,84	1	0,94
1660	0,92	0,86	0,86	0,88
2104	0,93	0,76	0,85	0,85
...
1474	0,67	0,85	0,67	0,71
1513	0,63	0,81	0,65	0,71
...
4615	0,57	0,73	0,45	0,59
1456	0,55	0,71	0,49	0,58
1459	0,41	0,78	0,45	0,55

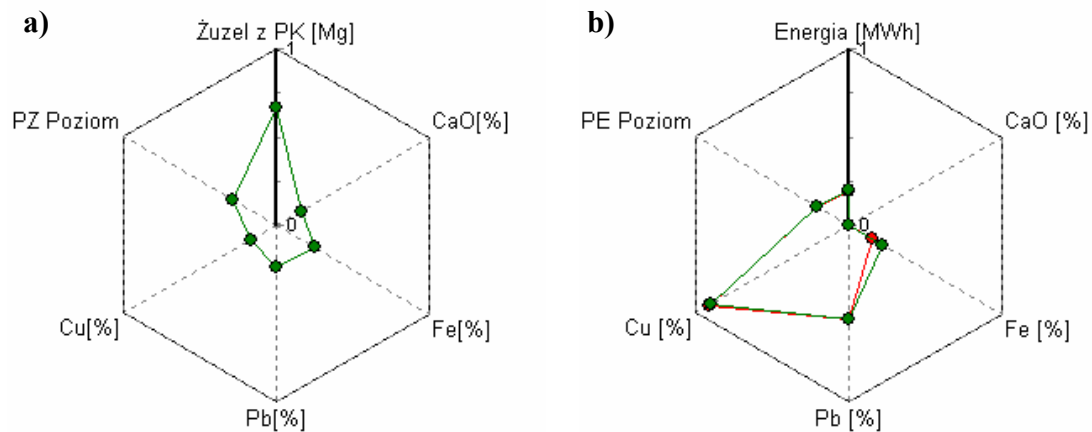
5.7. Prezentacja wyników wyszukiwania podobnych cykli

Wyniki dotyczące zbioru wyszukanych podobnych cykli można przedstawiać w sposób omówiony w rozdziale 4.10. Zaproponowane wykresy radiowe służą do prezentacji wyszukanych cykli stanowiących informacje pomocnicze dla obsługi procesu w podejmowaniu decyzji o sposobie sterowania poszczególnymi parametrami procesowymi.

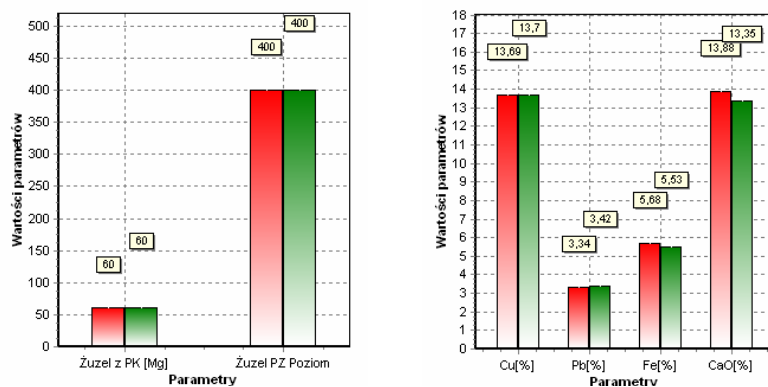
Poniżej przedstawiono przykładowe wykresy radiowe wybranych cykli, najbardziej i najmniej podobnych do cyklu o ID=1534.

Na wykresach radiowych (Rys. 5.11 i 5.15) przedstawiono w formie wieloboków różnice w wartościach parametrów wejściowych i wyjściowych pomiędzy wyszukаныmi cyklami. Im wyznaczone podobieństwo pomiędzy cyklami wyszukany i odniesienia jest większe, tym bardziej podobne są do siebie wieloboki reprezentujące wartości poszczególnych parametrów wejściowych i wyjściowych, co widać na wykresach wartości tych parametrów (Rys. 5.12, 5.13, 5.15, 5.16).

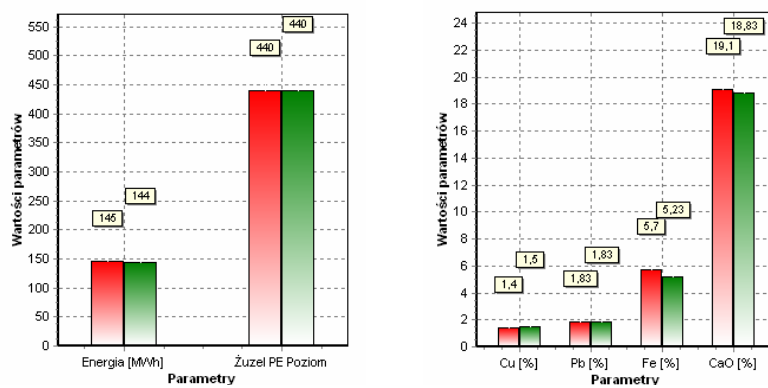
Sposób takiego przedstawienia różnic pomiędzy cyklami w porównaniu do wykresów słupkowych, pozwala na szybką ocenę jakości dopasowania wyszukanych cykli. Na rys. 5.11 przedstawiono cykl (ID=4531) najbardziej podobny do cyklu 1534. Wieloboki reprezentujące wartości poszczególnych parametrów prawie się pokrywają. Na rys. 5.14 przedstawiono cykl (ID=1459) najmniej podobny do cyklu 1534. Wieloboki reprezentujące wartości poszczególnych parametrów znacząco różnią się od siebie.



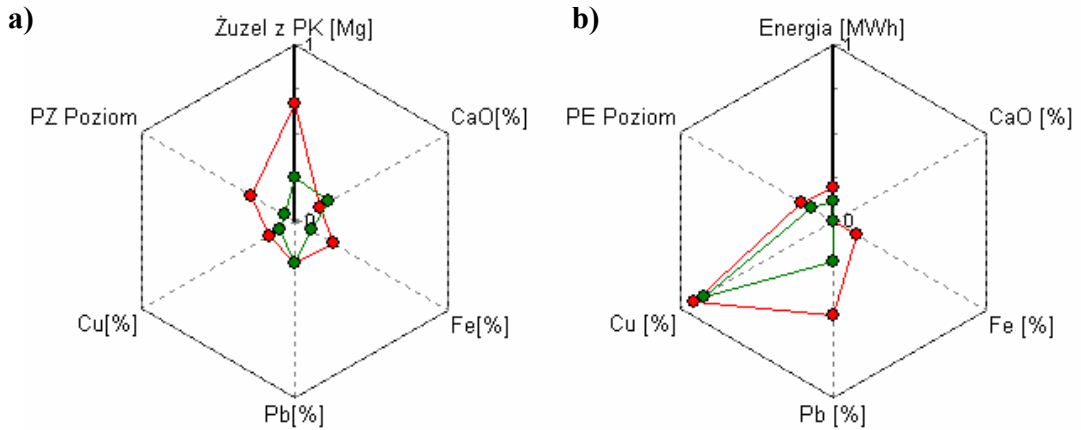
Rys. 5.11. Porównanie wartości parametrów a) wejściowych i b) wyjściowych cykli 1534 i 4531



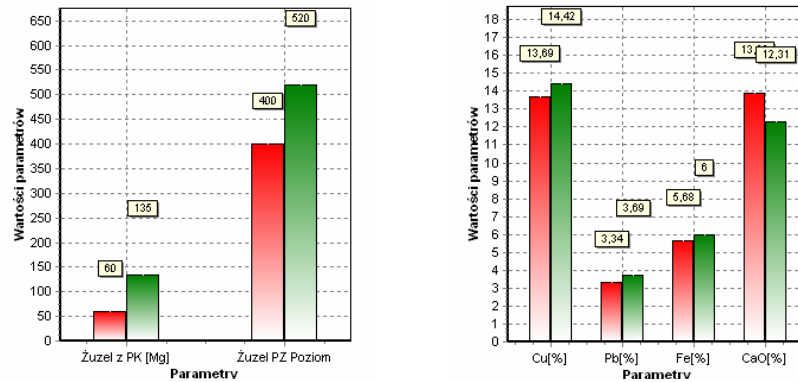
Rys. 5.12. Wartości parametrów wejściowych cykli 1534 i 4531




Rys. 5.13. Wartości parametrów wyjściowych cykli 1534 i 4531



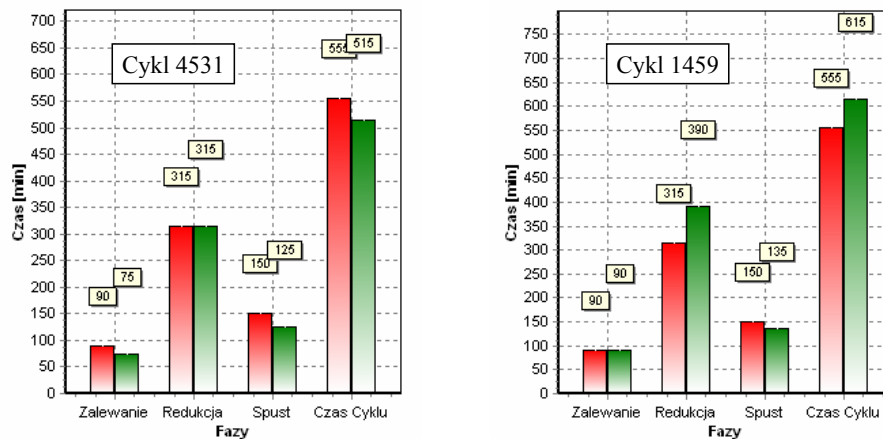
Rys. 5.14. Porównanie wartości parametrów a) wejściowych i b) wyjściowych cykli 1534 i 1459



Rys. 5.15. Wartości parametrów wejściowych cykli 1534 i 4531



Rys. 5.16. Wartości parametrów wyjściowych cykli 1534 i 4531



Rys. 5.17. Wartości czasów trwania poszczególnych etapów procesu cykli 4531 i 1459 względem cyklu 1534

5.8. Ocena wyników badań uzyskanych za pomocą opracowanych metod

W poniższym rozdziale opisano wyniki oceny opracowanych elementów systemu wnioskowania opartego na przykładach wg sposobu opisanego w rozdz. 4.11.

Oceniono wyniki uzyskane z uśrednionych wartości podobieństw wyznaczonych za pomocą opracowanych metod. Gęstość rozkładu empirycznego wartości podobieństwa zmodyfikowano za pomocą funkcji modyfikującej sigmoidalnej, tak aby uzyskać odpowiednio liczną reprezentację cykli podobnych do zadanego w różnych obszarach podobieństwa.

Dla tak zmodyfikowanych wartości przeprowadzono ocenę wg następującego kryterium:

Jeżeli w zbiorze cykli reprezentowanym za pomocą opracowanych metod da się określić podzbiór cykli o dostatecznie wysokich podobieństwach stanów wejściowych który będzie dostatecznie liczny i w tym podzbiórze da się określić podzbiór cykli o dostatecznie wysokich podobieństwach sterowań i dostatecznie dużej liczności, to w tym ostatnim podzbiórze także będą dostatecznie wysokie podobieństwa stanów wyjściowych.

W tabelicy 5.28 zestawiono wyniki przeprowadzonego badania dla różnych wartości progowych podobieństw poszczególnych klas parametrów oraz różnych licznosci progowych dla tych parametrów. Miarą oceny opracowanych elementów systemu CBR była wartość średnia zdefiniowanego współczynnika \bar{O}_{EST} (4.35) z poszczególnych prób.

Na podstawie wyników można stwierdzić, że przyjęte kryterium jest spełnione dla tak przygotowanego zbioru przykładów cykli. Otrzymane wysokie wartości estymatora pozwalają stwierdzić, że zbudowane elementy systemu wnioskowania opartego na przykładach, tj. sposób reprezentacji przykładów i miara podobieństwa przykładów, umożliwiają wystarczająco skuteczny wybór podobnych cykli procesu.

Tab. 5.28. Wyniki oceny opracowanych elementów systemu CBR

Wejścia		Sterowania		Wyjścia	Liczba prób	Estymator
$\Pi_{WE} \geq$	$L_{WE} \geq$	$\Pi_{STER} \geq$	$L_{STER} \geq$	$\Pi_{WY} \geq$	L_{PROB}	$\bar{O}_{EST}[\%]$
0,9	20	0,8	10	0,7	21	83
0,9	20	0,8	5	0,7	66	85
0,9	20	0,85	10	0,75	5	85
0,9	20	0,8	10	0,75	21	78
0,9	20	0,8	10	0,8	21	71

Hipoteza zerowa przyjęta w rozdz. 4.11 dla testu t -Studenta została odrzucona, gdyż wyznaczona średnia wartość estymatora dla wszystkich prób była istotnie niższa od 1. Wynika to z tego, że wartość odchylenia standardowego wartości estymatora uzyskana dla poszczególnych prób jest bardzo niewielka. Taki stan może być wynikiem nieuwzględnienia w procesie obliczania wartości podobieństw wielu zarejestrowanych czynników, które wpływają na proces sterowania (dodatki wprowadzane podczas wytopu, wpływ sterowania przez różnych pracowników) oraz czynników, które nie są rejestrowane a także wpływają na proces sterowania (skład chemiczny złomu wprowadzanego do pieca, nie-rejestrowane temperatury pieca i wiele innych).

5.9. Podsumowanie wyników weryfikacji

Celem weryfikacji z użyciem danych pochodzących z obiektu rzeczywistego było wykazanie poprawności zaproponowanych metod w zakresie modelowania procesów wolnozmiennych oraz możliwości zastosowania tych modeli w procesie wyszukiwania podobnych cykli względem cyklu zadanego.

Przeprowadzone badania weryfikacyjne wykazały, że przy odpowiednim doborze parametrów proponowanych metod można uzyskać poprawne wyniki. Jest to szczególnie widoczne w przypadku wyszukiwania realizacji podobnych do zadanej na podstawie wyznaczonych wartości podobieństw poszczególnych klas parametrów.

Dla każdej zaproponowanej metody wyznaczone wartości podobieństw wymagały zastosowania funkcji modyfikujących wartości wyznaczanych podobieństw, aby poprawić rozróżnialność cykli o różnym stopniu podobieństwa do wybranego cyklu. Wprowadzone modyfikacje spowodowały, że wartości podobieństw cykli o największych podobieństwach dla oryginalnej gęstości rozkładu empirycznego ich wartości zostały zwiększone, natomiast dla cykli o najmniejszych wartościach podobieństw zostały te wartości dodatkowo zmniejszone, co spowodowało zwiększenie stopnia rozróżnialności cykli.

Dla metody sekwencji znakowych liczba znaków w słowniku, reprezentujących przedziały kątowne nachylenia odcinków aproksymujących przebieg parametru procesowego, wpływa znacząco na wyznaczone wartości podobieństw. Jest to szczególnie widoczne dla gęstości rozkładu empirycznego wartości podobieństw niezmodyfikowanych.

Różnice w wartościach podobieństw wyznaczonych opracowanymi metodami świadczą o tym, że najlepszy opis podobieństwa cykli może zostać osiągnięty w wyniku wyznaczenia podobieństwa uśrednionego z opowiadających sobie wartości podobieństw wyznaczonych za pomocą tych metod.

Podczas wyszukiwania podobnych cykli wyniki uzyskane dla poszczególnych metod są zbliżone. Wyszukane cykle najbardziej i najmniej podobne względem cyklu zadanego są takie same dla wszystkich metod (z niewielkimi przesunięciami w grupie cykli o podobnych podobieństwach).

Wprowadzenie parametru opisującego uśrednione podobieństwa czasów trwania poszczególnych etapów badanych cykli, powoduje zwiększenie wartości podobieństw cykli o zbliżonych czasach trwania poszczególnych faz oraz zmniejszenie wartości podobieństw cykli o różniących się czasach trwania poszczególnych faz.

Wprowadzone wagi istotności poszczególnych parametrów procesowych wpływają na podobieństwa wyszukiwanych cykli. Powodują one zmniejszenie lub zwiększenie wartości podobieństw klasy parametrów wolnozmiennych w kierunku wartości podobieństw klasy parametrów, względem których odbywało się strojenie wag (wejściowych lub wyjściowych).

Wykresy radiowe zastosowane do prezentacji wyników wyszukiwania, pozwalają na szybkie zidentyfikowanie stopnia podobieństwa poszczególnych parametrów porównywanych cykli.

Przeprowadzona ocena otrzymanych wyników wyszukiwania potwierdza skuteczność opracowanych metod modelowania dla przyjętych założeń.

Zaproponowane metody modelowania procesów wolnozmiennych mogą być zastosowane do utworzenia bazy wiedzy w postaci zbioru przykładów, który może być wykorzystany w module CBR systemu wspomagania podejmowania decyzji.

Rozdział 6

Podsumowanie i wnioski

Przedstawiona praca jest wynikiem badań autora związanych z metodami modelowania przebiegów różnych ciągłych parametrów procesowych dla wolnozmiennych złożonych procesów technologicznych.

6.1. Podsumowanie

Bazy danych np. systemów SCADA zawierające duże ilości danych dla wielu różnych atrybutów stanowią źródło potencjalnie użytecznej wiedzy o związkach pomiędzy parametrami tego procesu. Wiedzę tę można wydobyć z danych np. w postaci przebiegów zmienności poszczególnych parametrów w różnych fazach procesu. Istnieje wiele metod modelowania procesów stosowanych w diagnostyce procesów. Autor przedstawił nowe metody modelowania procesów wolnozmiennych, które pozwalają modelować przebiegi parametrów dynamicznych dla złożonych wolnozmiennych procesów technologicznych o charakterze cyklicznym.

Sformułowany cel pracy został osiągnięty przez:

1. szczegółowy przegląd metod modelowania procesów stosowanych w diagnostyce technicznej,
2. opracowanie algorytmów metod modelowania procesów wolnozmiennych,
3. weryfikację opracowanych metod dla danych pochodzących z rzeczywistego obiektu,
4. ocenę skuteczności opracowanych metod.

Opracowane w ramach pracy metody dotyczą wielu etapów modelowania przebiegów wybranych parametrów wolnozmiennych. Przydatność tych metod potwierdza przeprowadzona ich wieloetapowa weryfikacja. Uzyskanie odpowiednich rezultatów wymaga właściwego doboru wielu parametrów tych metod oraz przygotowania badanej bazy danych i wyboru odpowiednich parametrów procesowych.

6.2. Wnioski

Na podstawie przeprowadzonych badań i uzyskanych wyników można sformułować następujące wnioski:

1. Opracowane metody bazują na prostych sposobach analizy danych oraz zdefiniowanych prostych miarach podobieństwa, co umożliwia łatwą implementację programową oraz dużą szybkość działania tych programów.
2. Metody te łączą wiele różnych sposobów modelowania stosowanych w modelowaniu obiektów i/lub procesów, dzięki czemu wyniki uzyskiwane za ich pomocą mogą być bardziej wiarygodne i miarodajne niż w przypadku stosowania tylko jednej z opracowanych metod.
3. Metody bazujące na sekwencjach znakowych i odległościach kątowych względnych, odwzorowują podobieństwo kształtu krzywych opisanych na poszczególnych punktach aproksymowanych przebiegów atrybutów procesowych.
4. Stosowanie metod określania podobieństw przebiegów, które bazują na odległościach i na sekwencjach znakowych, umożliwia skuteczne wyszukiwanie podobnych cykli procesu.
5. Przedstawione sposoby modyfikacji wyliczanych wartości podobieństw pozwalają na określenie takiej funkcji podobieństwa, która ułatwia wyszukanie podobnych realizacji procesu.
6. Zastosowanie procesu ewolucyjnego do określenia wag badanych parametrów umożliwia ich identyfikację bez udziału eksperta.
7. Wykresy radiowe z powodu dużej czytelności oraz łatwości interpretacji tak przedstawionych danych mogą znaleźć zastosowanie do budowy interfejsów użytkownika w systemach doradczych.

6.3. Kierunki dalszych badań

Problematyka modelowania procesów wolnozmiennych ma duże znaczenie dla rozwoju metod diagnostyki maszyn i diagnostyki procesów. Autor chciałby kontynuować podjęte badania w następujących kierunkach:

1. W zakresie metody:
 - a) opracowanie nowych sposobów normalizacji przebiegów o różnych czasach trwania,
 - b) udoskonalenie algorytmu ewolucyjnego do określania współczynników wagowych istotności atrybutów procesowych,
 - c) zwiększenia uniwersalności opracowanych metod (lepszą parametryzacją),
 - d) rozwój metod wykorzystujących sekwencje zdarzeń,

- e) opracowanie nowych metod modelowania procesów wolnozmiennych, które byłyby uzupełnieniem przedstawionych metod,
 - f) rozwój koncepcji jakościowej metody modelowania przebiegów oraz przeprowadzenie weryfikacji tej metody dla danych pochodzących z rzeczywistego obiektu,
 - g) identyfikacja zależności (relacji) zachodzących pomiędzy parametrami poprzez opracowanie nowych heurystyk do określania tych relacji.
2. W zakresie weryfikacji metod:
- a) pozyskanie bardziej szczegółowych informacji na temat badanego obiektu dotyczących wpływu poszczególnych atrybutów na proces,
 - b) uwzględnienie wpływu dodatków wprowadzanych do pieca w trakcie procesu oraz wyników przeprowadzanych analiz składu chemicznego kąpieli żuźlowej,
 - c) uwzględnienie wpływu innych czynników występujących w trakcie procesu,
 - d) pozyskanie nowych baz danych w celu sprawdzenia skuteczności opracowanych metod,
 - e) budowa modeli uwzględniających wolnozmienną dynamikę obiektu, a zwłaszcza wpływ sposobu prowadzenia danych cykli na cykle po nich następujące.

Bibliografia

- [1] Aamodt A., Plaza E.: *Case-based reasoning: Foundational issues, methodological variations and system approaches. ACom - Artificial Intelligence Communications*. IOS Press, Nr 7, 1994.
- [2] Aczel A. D.: *Statystyka w zarządzaniu*. PWN, Warszawa, 2000.
- [3] Arabas J.: *Wykłady z algorytmów ewolucyjnych*. WNT, Warszawa, 2001.
- [4] Bednarski M., Cholewa W., Frid W., Galek M.: *Simulation of nuclear reactors accidents*. Katedra Podstaw Konstrukcji Maszyn, Politechnika Śląska, Nr 124, Gliwice, 2004.
- [5] Bergmann R., Althoff K.: *Methodology for building CBR applications. Case Based Reasoning Technology*, 1998.
- [6] Bolc L., Zaremba P.: *Wprowadzenie do uczenia się maszyn*. Akademicka Oficyna Wydawnicza, Warszawa, 1992.
- [7] Bolikowski J., Sarafin M., Michta E., Miczulski W.: *System ekspercki wspomagający prowadzenie procesu odmiedziowania żużła zawieszinowego w piecu elektrycznym*. Metalurgia miedzi - kierunki rozwoju: Międzynarodowa Konferencja, s. 364–372, Świeradów Zdrój, Polska, 1998. Instytut Metali Nieżelaznych - Gliwice, KGHM Polska Miedź S.A. - Lublin.
- [8] Bolikowski J., Sarafin M., Michta E., Miczulski W.: *Wybrane problemy projektowania systemów eksperckich wspomagających prowadzenie procesów technologicznych*. Systemy pomiarowe w badaniach naukowych i w przemyśle - SP '98: II Konferencja, s. 25–36, Zielona Góra, Polska, 1998. Instytut Metrologii Elektrycznej Politechniki Zielonogórskiej, Zielona Góra, Wydaw. PZ.
- [9] Bolikowski J., Sarafin M., Michta E., Miczulski W.: *Diagnostyka stanu złożonych obiektów przemysłowych z wykorzystaniem systemów ekspertowych*. Diagnostyka Procesów Przemysłowych - DPP '99: IV Krajowa Konferencja Naukowo-Techniczna, s. 179–184, Kazimierz Dolny, Polska, 1999. Instytut Automatyki i Robotyki Politechniki Warszawskiej, Instytut Robotyki i Inżynierii Oprogramowania Politechniki Zielonogórskiej, Wydział Elektroniki Telekomunikacji i Informatyki Politechniki Gdańskiej, Warszawa, Instytut Automatyki i Robotyki Politechniki Warszawskiej.
- [10] Bolikowski J., Sarafin M., Michta E., Miczulski W., Szulim R.: *System ekspertowy wspomagający prowadzenie procesu redukcji żużła*. Inżynieria wiedzy i systemy

- ekspertowe: IV Krajowa Konferencja Naukowa, T. 2, s. 229–236, Wrocław, Polska, 2000. Wrocław, Oficyna Wydaw. Politechniki Wrocławskiej.
- [11] Box G., Jenkins G.: *Analiza szeregów czasowych: prognozowanie i sterowanie*. PWN, Warszawa, 1997.
- [12] Cholewa A.: *Reprezentacja sekwencji zdarzeń dla potrzeb wnioskowania w diagnostyce technicznej*. Pr. doktorska, Politechnika Śląska: Wydział Mechaniczny Technologiczny, Gliwice, 2004.
- [13] Cholewa A.: *Zastosowanie sekwencji zdarzeń do monitorowania procesów*. VII Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych, DPP'05, Rajgród, 12-14 września 2005.
- [14] Cholewa W.: *Sieci stwierdzeń w diagnostyce technicznej*. Diagnostyka Nr 2(38)/2006.
- [15] Cholewa W.: *Metoda diagnozowania maszyn z zastosowaniem zbiorów rozmytych*. ZN Pol. Śląskiej nr 764. Nr 79 in Mechanika. Politechnika Śląska, Gliwice, 1983.
- [16] Cholewa W.: *Doskonalenie sieci bayesowskich dla potrzeb diagnostyki technicznej*. VI Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych, DPP'03, s. 363–366, Władysławowo k/Gdańska, 15-17 września 2003.
- [17] Cholewa W., Kaźmierczak J.: *Diagnostyka techniczna maszyn - Przetwarzanie cech sygnałów*. Wydawnictwo Politechniki Śląskiej, Skrypty Uczelniane, Nr 1904, Gliwice, 1997.
- [18] Cholewa W., Kiciński J. i inni: *Diagnostyka techniczna. Odwrotne modele diagnostyczne*. Wydawnictwo Politechniki Śląskiej, Gliwice, 1997.
- [19] Cholewa W., Pedrycz W.: *Systemy doradcze. Skrypt nr 1447*. Politechnika Śląska, Gliwice, 1987.
- [20] Cichosz P.: *Systemy uczące się*. WNT, Warszawa, 2000.
- [21] Das B.: *Representing Uncertainties Using Bayesian Networks*. Information Technology Division Electronics and Surveillance Research Laboratory, DSTO-TR-0918, 1999.
- [22] Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R.: *Sieci neuronowe*. Biocybernetyka i inżynieria biomedyczna, Nr 6, Akademicka Oficyna Wydawnicza EXIT, Warszawa, 2000.
- [23] Džeroski S., Todorovski L.: *Discovering Dynamics: From Inductive Logic Programming to Machine Discovery*. Journal of Intelligent Information Systems, 3:1–20, 1994.
- [24] Fayyad U., Piatetsky-Shapiro G., Smyth P.: *From data mining to knowledge discovery in databases*. AI Magazine, 17:37–54, 1996.
- [25] Fayyad U. M., Piatetsky-Shapiro G., Smyth P., Uthurusamy R.: *From data mining to knowledge discovery: an overview*. Fayyad U. M., Piatetsky-Shapiro G., Smyth P., Uthurusamy R. (red.). *Advances in knowledge discovery and data mining*, s. 1–34. AAAI Press / The MIT Press, 1996.

- [26] Filippidis A.: *Data Fusion using sensor data and a priori information*. 1995.
- [27] Freeman H.: *On the encoding of arbitrary geometric configurations*. IEEE Trans. Electron. Comput. EC-10, s. 260–268, 1961.
- [28] Gibiec M.: *Identyfikacja obciążeń eksploatacyjnych w oparciu o metody sztucznej inteligencji*. Korbicz J., Pieczyński A. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych, DPP'01, s. 195–198, Łągów Lubuski, Wrzesień 2001.
- [29] Giordana A., Saitta L., Bergadano F., Brancadori F., De Marchi D.: *ENIGMA: A System that Learns Diagnostic Knowledge*. IEEE Trans. on Knowledge and Data Engineering, 5(1):15–28, Feb. 1993.
- [30] Głowacki G., Patan K.: *Fault detection in electrical drive by means of artificial neural networks*. Diagnostyka, Nr 2(38)/2006.
- [31] Graham J., Zurada J.: *Wykorzystanie algorytmów sieci neuronowych w aplikacjach bazy danych Oracle*. V Konferencja PLOUG, Zakopane, Październik 1999.
- [32] Hand D., Mannila H., Smyth P.: *Eksploracja danych*. WNT, Warszawa, 2005.
- [33] Hopgood A.: *Intelligent Systems for Engineers and Scientists*. CRC Press, 2000.
- [34] Huang Y., Chan K., Zhang Z.: *Texture Classification by multi-model feature integration using Bayesian Networks*. Pattern Recognition Letters, 24(1-3), s. 393–401, January 2003.
- [35] Jastriebow A., Gad S., Słoń G., Łaskawski M.: *Neuronowo-rozmyte metody lokalizacji uszkodzeń elektrycznego wyposażenia samochodu*. VII Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych, DPP'05, Rajgród, 12-14 września 2005.
- [36] Jensen F.: *An Introduction to Bayesian Networks*. UCL Press and Springer Verlag, New York, 1996.
- [37] Jensen F.: *Bayesian Networks and Decision Graphs*. UCL Press and Springer Verlag, New York, 2001.
- [38] Joy K. I.: *Bernstein polynomials*. Computer Science Department, University of California, Davis, USA, 2000.
- [39] Kacprzyk J.: *Zbiory rozmyte w analizie systemowej*. PWN, Warszawa, 1986.
- [40] Kacprzyk J.: *Wieloetapowe sterowanie rozmyte*. Wydawnictwo Naukowo Techniczne, Warszawa, 2001.
- [41] Kaczorek T.: *Teoria sterowania i systemów*. PWN, Warszawa, 1999.
- [42] Kaźmierczak J.: *Zastosowanie liniowych modeli procesów losowych do prognozowania w diagnostyce maszyn*. Wydawnictwo Politechniki Śląskiej, Zeszyty Naukowe Politechniki Śląskiej, Zeszyt 95, Gliwice, 1989.
- [43] Kościelny J. M.: *Diagnostyka zautomatyzowanych procesów przemysłowych*. Problemy Współczesnej Nauki - Teoria i Zastosowania: Automatyka, Akademicka Oficyna Wydawnicza EXIT, Warszawa, 2001.

- [44] Korbicz J.: *Sztuczne sieci neuronowe*. Akademicka Oficyna Wydawnicza, Warszawa, 1994.
- [45] Korbicz J., Kościelny J. M., Kowalczyk Z., Cholewa W.: *Diagnostyka procesów. Modele. Metody sztucznej inteligencji. Zastosowania*. WNT, Diagnostyka procesów, Nr 3, Warszawa, 2002.
- [46] Korbicz J., Obuchowicz A., Uciński D.: *Sztuczne sieci neuronowe: podstawy i zastosowania*. Akademicka Oficyna Wydawnicza PLJ, Problemy Współczesnej Nauki - Teoria i Zastosowania: Informatyka, Warszawa, 1994.
- [47] Koronacki J., Mielniczuk J.: *Statystyka dla studentów kierunków technicznych i przyrodniczych*. WNT, Warszawa, 2001.
- [48] Kowal M., Korbicz J.: *Odporna detekcja uszkodzeń przy niepewności modelu rozmyto-neuronowego*. VII Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych, DPP'05, Rajgród, 12-14 września 2005.
- [49] Kuipers B.: *Qualitative Simulation*. Artificial Intelligence, 26:289–338, 1986. Reprinted in Qualitative Reasoning about Physical Systems, edycja: Daniel Weld i J. De Kleer, Morgan Kaufmann, 1990, p.236-260.
- [50] Kuipers B.: *Qualitative Reasoning: Modeling and Simulation with Incomplete Knowledge*. MIT Press, Cambridge, MA, 1994.
- [51] Langley P.: *BACON.1: A general discovery system*. The Second National Conference of the Canadian Society for Computational Studies of Intelligence, s. 173–180, 1978.
- [52] Langley P.: *Rediscovering physics with BACON.3*. The Sixth International Joint Conference on Artificial Intelligence, s. 505–507, 1979.
- [53] Langley P., Bradshaw G., Simon H. A.: *BACON.4: The discovery of intrinsic properties*. The Third National Conference of the Canadian Society for Computational Studies of Intelligence, s. 19–25, 1980.
- [54] Langley P., Bradshaw G., Simon H. A.: *BACON.5: The Discovery of Conservation Laws*. The Seventh International Joint Conference on Artificial Intelligence, s. 121–126, 1981.
- [55] Leibovici L., Fishman M., Schonheyder H., Riekehr C., Kristinsen B., Shraga I., Andreassen S.: *A Casual Probabilistic Network for Optimal Treatment of Bacterial Infections*. IEEE: Transaction on Knowledge and Data Engineering, Vol.12, Issue 4, s. 517–528, July-August 2000.
- [56] Majchrzak E., Mochnacki B.: *Metody numeryczne. Podstawy teoretyczne, aspekty praktyczne i algorytmy*. Wydawnictwo Politechniki Śląskiej, Gliwice, 2004.
- [57] Mekhnacha K., Mazer E., Bessiere P.: *A Robotic CAD system using a Bayesian framework*. The IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2000), Vol.3, s. 1597–1604, October-November 2000.

- [58] Mekhnacha K., Mazer E., Bessiere P.: *The design and implemetation of Bayesian CAD modeler for robotic applications*. Advance Robotics, Vol.15, No.1, s. 45–69, 2001.
- [59] Metivier H.: *Chernobyl - an assessment of radiological and healt impact*. Nuclear energy agency organisation for economic co-operation and development, <http://www.nea.fr/html/rp/chernobyl.html>, 2003.
- [60] Moczulski W.: *Metody pozyskiwania wiedzy dla potrzeb diagnostyki maszyn*. Wydawnictwo Politechniki Śląskiej, Zeszyty Naukowe Politechniki Śląskiej, Zeszyt 130, Gliwice, 1997.
- [61] Moczulski W.: *Pozyskiwanie wiedzy deklaratywnej i proceduralnej*. Symposium on Methods of Artificial Intelligence in Mechanics and Mechanical Engineering AI-MECH'2000, Proceedings of the Workshop on Applications of Artificial Intelligence in Mechanics and Mechanical Engineering, 1 - Invited Papers, s. 55–73, Gliwice, 15-17.11. 2000.
- [62] Moczulski W., Szulim R.: *On case-based control of dynamic industrial processes with the use of fuzzy representation*. Engineering Applications of Artificial Intelligence, Nr 17, (4):371–381, 2004.
- [63] Moczulski W., Tomasik P., Wachla D.: *Odkrywanie wiedzy w diagnostycznych bazach danych*. XXIX Ogólnopolskie Sympozjum "Diagnostyka Maszyn", s. 261–272, Węgierska Górka, 4-9.03. 2002.
- [64] Moczulski W., Wachla D.: *Acquisition of Diagnostic Knowledge Using Discoveries in Databases*. V Krajowa Konferencja Naukowo-Techniczna "Diagnostyka Procesów Przemysłowych" DPP'01, Łagów, s. 219–224, Uniwersytet Zielonogórski, 2001.
- [65] Moczulski W., Żytkow J. M.: *Discovery of Diagnostic Knowledge from Multi-Sensor Data*. AeroSense - SPIE's 15th International Symposium on Aerospace/Defense Sensing, Simulation, and Controls, "Data Mining and Knowledge Discovery: Theory, Tools, and Technology III", 4384, s. 104–115, Orlando, FL, 16-20.04. 2001. Proceedings of SPIE.
- [66] Morawski K., Żaboklicki S.: *Systemy ekspertowe*. WNT, 1996.
- [67] Mrugalski M., Korbicz J.: *Detekcja uszkodzeń odporna na niepewność modelu neuronowego*. VII Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych, DPP'05, Rajgród, 12-14 września 2005.
- [68] Nikovski D.: *Constructing Bayesian Networks for Medical Diagnosis from Incomplete and Partially Correct Statistics*. IEEE: Transaction on Knowledge and Data Engineering, Vol.12, Issue 4, s. 509–516, July-August 2000.
- [69] Niloa V., Oliviero R., Quaremba G.: *Fuzzy logic for the classification of a complex signal analyzed by wavelets*. Acoustical and Vibratory Surveillance Methods and Diagnostic Techniques, Senlis, Francja, 11-13 October 2004.

- [70] Oktaba W.: *Elementy statystyki matematycznej i metodyka doświadczalnictwa*. PWN, Warszawa, 1980.
- [71] Pawlak Z.: *Rough Sets: Theoretical aspects of reasoning about data*. Kluwer, Dordrecht, 1991.
- [72] Pieczyński A.: *Komputerowe systemy diagnostyczne procesów przemysłowych*. Politechnika Zielonogórska, Zielona Góra, 1999.
- [73] Pieczyński A.: *Reprezentacja wiedzy w diagnostycznym systemie ekspertowym*. Lubuskie Towarzystwo Naukowe, Zielona Góra, 2003.
- [74] Pieczyński A., Korbicz J.: *Rozmyty klasyfikator w diagnostyce procesów przemysłowych*. V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych, DPP'01, s. 185–188, Łągów Lubuski, Wrzesień 2001.
- [75] Piegat A.: *Modelowanie i sterowanie rozmyte*. Problemy Współczesnej Nauki - Teoria i Zastosowania: Informatyka, Akademicka Oficyna Wydawnicza EXIT, Warszawa, 1998.
- [76] Przyszałka P., Moczulski W.: *Koncepcja metodyki tworzenia heurystycznych modeli obiektów przemysłowych*. VII Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych, DPP'05, Rajgród, 12-14 września 2005.
- [77] Quinlan J.: *Building Classification Models: ID3 i C4.5*.
- [78] Quinlan J.: *Induction of decision trees*. Machine Learning 1, s. 81–106, 1986.
- [79] Quinlan J.: *C4.5: Programs for Machine Learning*. Morgan Kaufmann, 1993.
- [80] Źródło internetowe: *Komputerowe modelowanie geometryczne*. <http://iair.mchtr.pw.edu.pl>.
- [81] Sarkar S., Murthy I.: *Criteria to evaluate approximate belief network representations in expert systems*. Decision Support Systems, Vol.15, Issue 4, s. 323–350, December 1995.
- [82] Sarkar S., Sriram R. S., Joykuttu S., Murthy I.: *An information theoretic technique to design belief network based expert systems*. Decision Support Systems, Vol.17, Issue 1, s. 13–60, April 1996.
- [83] Sobczyk M.: *Statystyka*. PWN, Warszawa, 2000.
- [84] Söderström T., Stoica P.: *Identyfikacja systemów*. PWN, Warszawa, 1997.
- [85] Szulim R.: *Koncepcja systemu doradczego do wspomaganie obsługi w prowadzeniu złożonego procesu przemysłowego*. VI Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych, DPP'03, 15.
- [86] Szulim R.: *Opis obiektu, procesów i danych pomiarowych hutniczego pieca elektrycznego*. XXIX Ogólnopolskie Sympozjum "Diagnostyka Maszyn", Zielona Góra, 2002.
- [87] Szulim R.: *Metoda pozyskiwania wiedzy do wspomaganie prowadzenia złożonego procesu technologicznego*. Pr. doktorska, Uniwersytet Zielonogórski: Wydział Elektroniki, Informatyki i Telekomunikacji, Zielona Góra, 2004.

- [88] Tadeusiewicz R.: *Rozpoznawanie obrazów*. 1991.
- [89] Tadeusiewicz R.: *Sieci neuronowe*. Problemy Współczesnej Nauki i Techniki: Informatyka, Akademicka Oficyna Wydawnicza RM, Warszawa, 1993.
- [90] Tan P. N., Steinbach M., Kumar V.: *Introduction to Data Mining*. Addison Wesley, 2005.
- [91] Tomasik P.: *Koncepcja systemu do diagnostyki złożonego procesu przemysłowego*. VII Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych, DPP'05, Rajgród, 12-14 września 2005.
- [92] Tomasik P.: *Methods to determine control similarities of complex process realization*. AI-METH 2005 - Artificial Intelligence Methods, Silesian University of Technology, Gliwice, 16-18 November 2005.
- [93] Tomasik P.: *Metody regresyjne modelowania procesów*. SEMINARIUM HMP-2006 - Heurystyczne modele procesów w utrzymaniu ruchu kompleksu ścianowego, Gliwice, 15 marca 2006.
- [94] Uhl T.: *Komputerowo wspomagana identyfikacja modeli konstrukcji mechanicznych*. Wspomaganie Komputerowe CAD/CAM, WNT, 1997.
- [95] Volk W.: *Statystyka stosowana dla inżynierów*. WNT, Warszawa, 1973.
- [96] Wachla D.: *The idea of method of searching for global inverse models in machinery diagnostics*. AI-MECH: Proceedings of the Symposium on Applications of Artificial Intelligence in Mechanics and Mechanical Engineering, s. 291–294, Gliwice, 14-16.11. 2001.
- [97] Wachla D.: *An Example of genetic algorithm application in knowledge discovery in databases*. AI-MECH: Proceedings of the Symposium on Methods of Artificial Intelligence, s. 429–432, Gliwice, 13-15.11. 2002.
- [98] Wachla D.: *Identyfikacja dynamicznych modeli diagnostycznych metodami odkryć wiedzy w bazach danych*. Pr. doktorska, Politechnika Śląska: Wydział Mechaniczny Technologiczny, Gliwice, 2005.
- [99] Wojtusik J.: *Wielomodele diagnostyczne maszyn wirnikowych*. Pr. doktorska, Politechnika Śląska: Wydział Mechaniczny Technologiczny, Gliwice, 2005.
- [100] Wyczółkowski R., Moczulski W.: *Concept of intelligent monitoring of local water supply system*. AI-METH 2005 - Artificial Intelligence Methods, Silesian University of Technology, Gliwice, 16-18 November 2005.
- [101] Zadeh L.: *Fuzzy sets*. Inf. and Control, 2, 1965.
- [102] Zembowicz R., Żytkow J.: *Database Exploration in Search of Regularities*. Journal of Intelligent Information Systems, 2:39–81, 1993.
- [103] Żytkow J. M., Zembowicz R.: *Mining Patterns at Each Scale in Massive Data*. Raś Z. W., Michalewicz M. (red.). *Foundations of Intelligent Systems*, nr 1079 in Lecture Notes in Artificial Intelligence, Proc. of 9th Int. Symposium ISMIS'96, Zakopane 1996, s. 139–148. Springer-Verlag, Berlin-Heidelberg, 1996.

Metody identyfikacji modeli procesów wolnozmiennych dla potrzeb diagnostyki technicznej

Praca doktorska – streszczenie

Autor: mgr inż. Piotr Tomasik

Promotor: prof. dr hab. Wojciech Moczulski

Politechnika Śląska w Gliwicach, Wydział Mechaniczny Technologiczny

W dziedzinie diagnostyki procesów przemysłowych coraz częściej stosuje się modele obiektów i procesów, a ponadto ze względu na upowszechnienie się systemów monitorowania i nadzoru wyposażonych w podsystemy SCADA gromadzi się wiele danych, które mogą być nośnikiem użytecznych informacji. Wiele problemów nastęrcza analizowanie tych danych ze względu na trudności związane z gromadzeniem kompletnej realizacji procesowych. Często istnieje bardzo mało kompletnej realizacji zapisanych w bazach danych oraz występują dodatkowe utrudnienia związane z analizowaniem przebiegów o różnych czasach trwania.

W wyniku przeglądu istniejącego stanu w zakresie metod modelowania procesów wolnozmiennych stwierdzono, że metody bazujące na prostych sposobach przetwarzania danych nie są stosowane. Celem pracy było opracowanie nowych metod przetwarzania danych pochodzących ze złożonego wolnozmiennego procesu przemysłowego o charakterze cyklicznym, w wyniku zastosowania których można byłoby otrzymać modele tych procesów. Uzyskane modele winny umożliwić diagnostykę procesu oraz dostarczenie operatorom procesu nowych użytecznych informacji dotyczących zależności zachodzących pomiędzy zmiennymi tego procesu.

Sformułowano zatem tezę, że opracowane metody globalnego modelowania procesów wolnozmiennych umożliwiają budowę bazy wiedzy, która może być zastosowana do wnioskowania diagnostycznego bazującego na przykładach (CBR).

W celu wykazania tej tezy opracowano trzy metody modelowania takich procesów, dwie bazujące na mierze euklidesowej oraz jedną bazującą na sekwencjach znakowych. Dla opracowanych metod określono odpowiednie sposoby przetwarzania zgromadzonych danych w poszczególnych etapach związanych z: normalizacją przebiegów i ich aproksymacją, wyznaczeniem wartości odległości pomiędzy poszczególnymi punktami aproksymacji (metody odległościowe), określeniem kątowej reprezentacji poszczególnych odcinków przebiegów i przyjęciem odpowiedniego słownika zdarzeń (metoda bazująca na sekwencjach znakowych) oraz wyznaczeniem wartości podobieństw.

Weryfikację opracowanych metod i ocenę ich skuteczności przeprowadzono dla bazy danych pochodzącej z rzeczywistego obiektu technicznego (piec do redukcji miedzi z żużla). Dla poszczególnych etapów przetwarzania danych wymagane było określenie wartości parametrów opracowanych metod.

Przy założeniu, że proces redukcji miedzi jest sterowalny, weryfikacja polegała na indukcyjnym wykazaniu słuszności hipotezy, że dla cykli o dostatecznie podobnym wejściu i dostatecznie podobnym sterowaniu uzyskuje się dostatecznie podobne wyjście. Zrealizowano złożony plan badań weryfikacyjnych, uzyskując w przypadku najbardziej korzystnych parametrów, potwierdzenie tak sformułowanej hipotezy dla około 85% cykli.

Słowa kluczowe: modelowanie procesów, aproksymacja przebiegów, miary podobieństwa, diagnostyka procesów przemysłowych, wnioskowanie bazujące na przykładach (CBR)

Methods of the identification of models of slowly changing processes for technical diagnostics

PhD dissertation (Summary)

Author: Piotr Tomasik, MSc (Mech. Eng.)

Supervisor: Prof. Wojciech Moczulski, DSc., PhD (Mech. Eng.)

Silesian University of Technology, Department of Fundamentals of Machinery Design

In the domain of technical diagnostics of processes ever more and more frequently models of objects and processes are used. Moreover, since SCADA systems become over more and more popular, data is collected that may be carrier of useful information. Analyzing this data causes many problems due to the fact that complete realizations of processes are needed. In many cases there exist too less complete realizations of processes stored in databases. Additional difficulties are connected with analyzing realizations of differing durations.

As a result of research of state-of-the-art in methods of modeling slowly varying processes it was stated that methods that are based upon simple ways of data processing are not applied. Therefore, the goal of this dissertation has been formulated as the development of new methods of data processing acquired from a complex slowly varying process of cyclic character, whose application would result in obtaining models of these processes. The models that would be to obtain should allow process diagnostics and provide the process operator with new and useful information concerning relations occurring between different process variables.

This goal was a basis for the hypothesis that the methods of global modeling of slowly varying processes to be elaborated could allow building knowledge base that could be applied In diagnostic reasoning based on examples (Case-based Reasoning - CBR).

To prove his hypothesis three methods of modeling such processes were elaborated. Two of them are based on Euclidean distance measure, while the last one uses sequences of events encoded by alphabetic characters. For the sake of these methods adequate ways of processing collected data were defined, including standardization of process cycles, and their approximation, estimation of distances between subsequent approximation nodes (for distance-based methods), estimation of angular representation of individual segments of realizations and defining respective dictionary of events (for the method of sequences of events), and calculation of similarity values.

The verification of developer methods and assessment of their efficiency were carried out for the data base collected from real technical object (the furnace for reducing copper from slag). Determination of parameters of the methods for the elaborated methods was necessary for individual stages of the methodology. Assuming that the process of reducing copper from slag is controllable, one could stated that verification of correctness of the method consisted in inductive proving that the following hypothesis is sound: for cycles whose input is sufficiently similar and control actions are sufficiently similar, too, one gets sufficiently similar outputs of these process realizations. To this end, a complex plan of verification has been accomplished, which for the most favorable parameter values allowed confirming the hypothesis for about 85 per cent of total amount of cycles.

Key words: process modelling, methods of approximation, measures of similarity, diagnostic of industrial processes, Case-Based Reasoning (CBR)

