

POLITECHNIKA WROCŁAWSKA
WYDZIAŁ INFORMATYKI I ZARZĄDZANIA

PRACA DOKTORSKA

Marek Krótkiewicz

Tytuł: *Rozpoznawanie obiektów w zastosowaniach
inżynierii procesowej i mechanoskopii*

Promotor:
dr hab. inż. Roman Ulbrich
profesor Politechniki Opolskiej

Wrocław, kwiecień 2001

Spis treści

1. WSTĘP	3
2. GŁÓWNA TEZA PRACY	7
2.1. POJĘCIA STOSOWANE W PRACY	7
2.1.1. <i>Pojęcia z dziedziny rozpoznawania obrazów</i>	7
2.1.2. <i>Pojęcia z dziedziny inżynierii procesowej</i>	8
2.1.3. <i>Pojęcia z dziedziny kryminalistyki</i>	8
2.1.4. <i>Pojęcia zdefiniowane na potrzeby pracy</i>	9
2.2. SFORMUŁOWANIE TEZY	10
3. GŁÓWNY CEL PRACY	12
3.1. ELEMENTY ORYGINALNE ZWARTE W PRACY	13
4. PODSTAWOWE INFORMACJE Z ZAKRESU ROZPOZNAWANIA OBIEKTÓW	14
4.1. OGÓLNY OPIS ZAGADNIENIA	14
4.1.1. <i>Akwizycja informacji</i>	15
4.1.2. <i>Wstępna filtracja informacji nadmiarowej</i>	16
4.1.3. <i>Korekcja błędów akwizycji</i>	17
4.1.4. <i>Selekcja obiektów</i>	18
4.1.5. <i>Wyznaczanie cech obiektów</i>	20
4.1.5.1. <i>Definiowanie cech obiektów</i>	20
4.1.5.2. <i>Wyznaczanie wartości cech</i>	25
4.2. OPIS FORMALNY	28
5. UMIEJSCOWIENIE PROBLEMATYKI W OBSZARZE ROZPOZNAWANIA OBIEKTÓW	43
5.1. PODSTAWOWY PODZIAŁ METODOLOGICZNY	43
5.2. SPRECYZOWANIE OBSZARU PROWADZONYCH BADAŃ	44
6. OPIS OPRACOWANEJ METODY ROZPOZNAWANIA OBIEKTÓW	45
6.1. PODSTAWOWE ZAGADNIENIA	45
6.2. OPIS METODY	46
6.2.1. <i>Podstawy teoretyczne</i>	46
6.2.1.1. <i>Pojęcia podstawowe</i>	47
6.2.1.2. <i>Istotne metody przetwarzania obrazów graficznych</i>	50
6.2.2. <i>Problemy rozpoznawania struktur przepływu dwufazowego</i>	63
6.2.3. <i>Opis formalny</i>	67
7. ROZPOZNAWANIE STRUKTURY PRZEPŁYWU WIELOFAZOWEGO	91
7.1. WPROWADZENIE	91
7.2. OKREŚLENIA I DEFINICJE	94
7.3. PRZEGLĄD METOD BADAWCZYCH	99
7.4. UZASADNIENIE PODJĘCIA TEMATU PRACY – CEL PRACY	104
8. PRAKTYCZNE ZASTOSOWANIE METODY ROZPOZNAWANIA PRZEPŁYWU MIESZANIN DWUFAZOWYCH	105
8.1. OGÓLNY OPIS REALIZACJI METODY	105

8.2.	PRAKTYCZNA REALIZACJA METODY	106
8.3.	OBSZAR AKWIZYCJI DANYCH	110
8.4.	DEFINICJE OPRACOWANYCH CECH	113
8.4.1.	<i>Średni udział jednej z faz</i>	114
8.4.2.	<i>Długość linii brzegowej</i>	115
8.4.3.	<i>Gradient lokalny</i>	115
8.4.4.	<i>Wariancja</i>	116
8.4.5.	<i>Posumowanie własności cech</i>	116
8.5.	SPOSÓB PRZETWARZANIA INFORMACJI ORAZ WYNIKI BADAŃ	117
8.5.1.	<i>Badane obiekty</i>	118
8.5.2.	<i>Wstępne przetwarzanie danych</i>	119
8.5.3.	<i>Klasyfikacja impulsów</i>	124
8.5.4.	<i>Obiekty badań</i>	127
8.5.5.	<i>Wyniki prowadzonych badań</i>	129
8.5.5.1.	Analiza wyników dla cechy <i>M</i> i podobszarów 10x30	130
8.5.5.2.	Analiza wyników dla cechy <i>E</i> i podobszarów 50x30	133
8.5.5.3.	Analiza wyników dla cechy <i>G</i> i podobszarów 50x30	136
8.5.5.4.	Analiza wyników dla cechy <i>V</i> i podobszarów 10x10	139
8.6.	WNIOSKI W ZAKRESIE ROZPOZNAWANIA STRUKTUR PRZEPŁYWU	142
8.7.	ZASTOSOWANE NARZĘDZIA	145
9.	PRAKTYCZNE ZASTOSOWANIE METODY ROZPOZNAWANIA ŚLADÓW DYNAMICZNYCH	148
9.1.	WSTĘP	148
9.2.	OBIEKTY BADAŃ	149
9.3.	OGÓLNY OPIS METODY	151
9.4.	WNIOSKI W ZAKRESIE ROZPOZNAWANIA ŚLADÓW DYNAMICZNYCH	164
9.5.	ZASTOSOWANE NARZĘDZIA	165
10.	PODSUMOWANIE	167
11.	LISTA SYMBOLI	171
12.	SPIS RYSUNKÓW	174
13.	BIBLIOGRAFIA	179

1. WSTĘP

Rozpoznawanie obiektów jest jednym z najczęściej występujących procesów w przyrodzie. Dla przykładu, czytanie tekstu niniejszej pracy polega na rozpoznawaniu liter i wyrazów. Równolegle rozpoznawane są inne obiekty, których istnienie manifestowane jest w sposób umożliwiający rejestrację sygnałów za pomocą pozostałych zmysłów. Oczywiście jest to dopiero początek bardzo skomplikowanych procesów myślowych mających na celu interpretację docierających informacji, lecz prawidłowość rozpoznania determinuje skuteczność dalszych funkcji.

Powszechność rozpoznawania obiektów wynika z faktu, iż aby jakakolwiek istota żywa mogła funkcjonować, musi nieustannie dokonywać klasyfikacji obiektów znajdujących się w jej otoczeniu. W świecie zwierzęcym poprawne rozpoznawanie oznacza większe szanse na przeżycie. Natura już dawno doszła do tego wniosku i wyposażała rośliny i zwierzęta w niezwykle wyrafinowane mechanizmy służące do sprawnej oceny otoczenia.

Błędna ocena możliwości obronnych potencjalnego pożywku może doprowadzić do całkowitego odwrócenia sytuacji. W świecie ekonomii i zarządzania pracuje się na olbrzymiej ilości danych analitycznych [75]. Coraz częściej zauważa się, iż w którymś momencie istnieje konieczność rezygnacji ze szczegółowego opisu na rzecz jednoznacznej klasyfikacji obiektów. Informatyka już dawno opisała cechy wartościowej informacji. Pozostałe nauki powoli zaczynają wprowadzać w życie elementarne zasady z dziedziny teorii informacji. Formułowane są metody na bazie dosyć oczywistego twierdzenia, iż w przypadku informacji, jej ilość nie jest jedynym miernikiem wartości. Rozpoznawanie obiektów jest w tym przypadku bardzo użytecznym narzędziem, gdyż nie zamienia danych analitycznych w dane syntetyczne, które z kolei podlegają dalszej agregacji, aż do uzyskania kilku podstawowych parametrów. Mechanizm rozpoznawania polega na zupełnie innym działaniu. Jedną z ciekawszych właściwości rozpoznawania obiektów jest przetwarzanie dużej ilości danych do postaci pojedynczego numeru klasy. Nie

zawsze czyni się to w jednym kroku, lecz efektem końcowym jest przypisanie obiektu do numeru klasy. Tendencja do takiego działania jest bardzo powszechna w życiu codziennym, choć raczej nie kojarzy się jej z rozpoznawaniem. Umysł ludzki działa na ogromnej ilości informacji. Chcąc uporać się z tym zadaniem wypracował on metody, które pozwalają na skupieniu się na informacjach potrzebnych w danym momencie do podjęcia decyzji. Dlatego też, bardzo często spotyka się efekt „szufladkowania”. Jest to typowy przykład klasyfikacji. W pewnym uproszczeniu wygląda to w następujący sposób. Każdy obiekt, niech to będzie na przykład człowiek, znany wcześniej lub właśnie poznany jawi się nam jako zbiór cech opisujących go. Wybór cech, które są godne zapamiętania i przetwarzania jest to szeroki i ważny temat, który zostanie omówiony w dalszej części pracy.

Na potrzeby tego rozważania należy przyjąć, że nasza percepcja pozwala nam na dokonanie „pomiaru” szeregu cech. Część z nich zostaje odrzucona już na wstępie. Jeżeli ktoś zapyta nas o odrzuconą cechę, mówimy wtedy, że nie zwróciliśmy na nią uwagi. Prawdopodobnie nie jest to do końca właściwe określenie, gdyż udowodniono, iż w stanie hipnozy jesteśmy w stanie podać dużo więcej szczegółów, których w normalnie nie pamiętamy. Oczywiście pamięć, do której sięgamy w stanie hipnozy jest pamięcią o raczej trudnym dostępie, ale skoro selekcja cech polega na podziale na łatwo i trudno dostępne, a nie na odrzucaniu, to czy nie warto spróbować zastosować tego rozwiązania w sztucznych systemach rozpoznawania?

Niezależnie od odpowiedzi na to pytanie, można stwierdzić, że nasz mózg minimalizuje ilość cech, którymi się będzie posługiwał na bieżąco. Jest to ważna, ale i ryzykowna czynność, gdyż może się okazać, iż redukujemy cechy, które są istotne. Stąd też wynika częsta trudność odpowiedzi na pytanie oczekujące na wskazanie cechy, która uległa zmianie w znanym nam obiekcie. Prawdziwy problem zaczyna się wtedy, gdy obiekt jest nam bardzo dobrze znany, więc ilość cech rejestrowanych przez nas drastycznie spada. Dzieje się tak, gdyż dobrze znane obiekty klasyfikujemy bardzo szybko na podstawie „jednego rzutu oka”, czyli małego zbioru dobrze wyselekcjonowanych cech. Kłopoty zaczynają się, gdy obiekt

zmienił jedną ze swoich cech, która wprawdzie nie wpływa na poprawność naszego rozpoznania, lecz sam obiekt domaga się wyraźnego zgłoszenia różnic.

Oprócz redukcji ilości cech, bardzo atrakcyjne dla naszego mózgu jest redukcowanie całych obiektów do postaci przypisać do odpowiedniej klasy. Jeżeli nasz znajomy posiada samochód to często nie pamiętamy szczegółów, a wolimy skrócić jego opis do podania marki. O danej marce samochodu wiemy zazwyczaj na tyle dużo, że informacje te nam wystarczą. Poza tym unikamy redundancji polegającej w tym przypadku na tym, że jeżeli kilku znajomych posiada ten sam typ samochodu, to nastąpiłoby powtarzanie zapamiętywanych informacji, a tego bardzo nie lubimy. Automatycznie zmieniamy strukturę przechowywanych informacji do postaci opisu klasy, który zawiera opis dużej ilości cech oraz powiązania do innych obiektów.

W toku prowadzonych prac wypracowane zostało twierdzenie, iż powiązania te są podstawowym mechanizmem, na którym oparta jest praca ludzkiego mózgu. Nie jest to główna teza niniejszej pracy, jednak wydaje się być istotną z punktu widzenia genezy, opisanych w dalszej części, metod i algorytmów.

Opracowując metody rozwiązania problemów naukowych, budując algorytmy i procedury oraz konstruując różnego rodzaju procesy, świadomie lub podświadomie wykonujemy to na bazie zasad, jakimi rządzi się nasz mózg. Wyraźnym przykładem jest wspomniana powyżej metoda powiązań między obiektami, służąca redukcji koniecznych do zapamiętania informacji. Powiązania te w psychologii są nazywane skojarzeniami, w inżynierii oprogramowania są to referencje lub adresy, w relacyjnych bazach danych indeksy, w dokumentach np. typu HTML linki lub odnośniki. Mechanizm ten jest prosty, skuteczny i we wszystkich przypadkach analogiczny. Zastosowanie go wymaga jednak znalezienia prawidłowego przypisania.

Zdolność do „szufladkowania” obiektów zapewnia nam szereg korzyści takich jak np. zmniejszenie ilości informacji, które należy zapamiętać, czy też skrócenie czasu ich wyszukiwania. Istnieją jednak niepożądane efekty uboczne. Jednym z nich jest tendencja do upraszczania obrazu rzeczywistości. W ten sposób

tworzą się stereotypy postrzegania. Stereotypy te są chętnie przez nasz mózg wykorzystywane, gdyż nie wymagają analizowania cech specyficznych dla danego obiektu, zadowalamy się opisem klasy, do której zakwalifikowaliśmy obiekt. Skoro odpowiednie stereotypy zostały wytworzone, to należy przyjąć, iż nie są one bezpodstawne. Problem tylko w tym abyśmy byli świadomi faktu, że opisują one rzeczywistość w sposób uproszczony, a więc i niepełny. Klasycznym przykładem stereotypu postrzegania jest zakładanie pewnych cech osobowościowych u różnych osób na podstawie ich wyglądu zewnętrznego, lub przynależności do grupy zawodowej. Ze stereotypami nie należy walczyć, gdyż są one dla nas czymś bardzo naturalnym i potrzebnym, trzeba być jednak świadomym, iż to proste i szybkie narzędzie jest stosunkowo niepewne i przydatne tylko w pierwszym etapie rozpoznawania.

W sztucznej inteligencji występuje analogiczne zjawisko. Istnieją proste i wygodne narzędzia rozpoznawania działające na zasadzie powierzchownej analizy łatwo mierzalnych cech. Cechy te są dostępne, wymierne, precyzyjne, jednoznaczne, unormowane, jednak powinny one spełniać podstawowy postulat: **wszystkie cechy biorące udział w rozpoznawaniu powinny opisywać obiekty w sposób właściwy dla danego kryterium podziału na klasy.** Właściwy sposób oznacza taki dobór cech, aby grupowały one obiekty wg zadanego kryterium klasyfikacji. Wiąże się to ściśle z główną tezą niniejszej pracy.

2. GŁÓWNA TEZA PRACY

2.1. Pojęcia stosowane w pracy

W celu usystematyzowania używanej w pracy terminologii oraz uniknięcia niejednoznaczności, w przypadku pojęć zdefiniowanych na potrzeby niniejszego opracowania, przedstawiony zostanie poniżej szereg definicji i określeń oraz ich opisów [56][92][31].

2.1.1. Pojęcia z dziedziny rozpoznawania obrazów

<i>Obiekt</i> –	Podmiot rozpoznawania posiadający interpretację związaną ze specyfiką rozpatrywanego zadania. Obiekt może mieć charakter fizyczny, lub abstrakcyjny, może to być przedmiot, zjawisko, stan natury lub dowolne inne pojęcie, któremu można przypisać mierzalne atrybuty.
<i>Klasa</i> –	Pojęcie grupujące obiekty wg przyjętych kryteriów.
<i>Klasyfikacja</i> –	Działanie mające na celu przypisanie obiektowi podlegającemu klasyfikacji numeru klasy.
<i>Cechy</i> –	Mierzalne atrybuty obiektów tj. wielkości poddające się obserwacji lub pomiarowi.
<i>Wektor cech</i> –	Wartości cech ujęte w uporządkowany sposób.
<i>Przestrzeń cech</i> –	Zbór wszystkich wartości, jakie mogą przyjmować cechy obiektów.
<i>Rozpoznawanie obiektów</i> –	Procedura obejmująca pomiar wartości cech, wstępne przetwarzanie, selekcję oraz klasyfikację mającą na celu przypisywanie obiektom konkretnego znaczenia na podstawie pewnych charakterystycznych właściwości.

Próba ucząca – Zbór sklasyfikowanych obiektów, których wektory cech są znane systemowi rozpoznawania.

2.1.2. Pojęcia z dziedziny inżynierii procesowej

Przepływ dwufazowy – Zjawisko polegające na przemieszczaniu się w kanale medium lub mediów o dwóch różnych stanach skupienia.

Struktura przepływu – Przestrzenny rozkład koncentracji faz podczas przepływu mieszanin.

2.1.3. Pojęcia z dziedziny kryminalistyki

Ślad – Ślad w znaczeniu kryminalistycznym jest to zmiana w obiektywnej rzeczywistości, która spostrzegana jako znamiono po zdarzeniach będących przedmiotem postępowania, może stanowić podstawę do odtworzenia i ustalenia przebiegu tych zdarzeń zgodnie z rzeczywistością.

Ślad dynamiczny – Ślad powstały w wyniku działania narzędzia na podłoże pod kątem różnym od kąta prostego, w wyniku którego następuje jego przesuw powodujący naruszenie ciągłości struktury materiału.

2.1.4. Pojęcia zdefiniowane na potrzeby pracy¹

<i>Obiekt statyczny –</i>	Obiekt o ustalonej ilości badanych cech, które są wartościami stałymi.
<i>Obiekt dynamiczny –</i>	Obiekt, którego przynajmniej jedna z cech jest funkcją innej wielkości niezależnej.

¹ Pojęcia zdefiniowane na potrzeby pracy należy interpretować zgodnie z podaną definicją, gdyż różne dziedziny nauki takie jak informatyka, matematyka, automatyka, teoria sterowania, inżynieria procesowa oraz pokrewne, mogą i często używają tych pojęć stosując odmienne znaczenie od podanego.

2.2. Sformułowanie tezy

W przypadku wielu rodzajów obiektów cechy opisujące je dają się łatwiej lub trudniej sprowadzić do unormowanych wartości liczbowych, które następnie mogą być porównywane wg zdefiniowanych miar podobieństwa. Istota różnic między obiektami tkwi w wartościach wyznaczonych cech. W takim przypadku można stosować wiele już zdefiniowanych miar podobieństwa, lub zdefiniować nowe, a następnie wybrać jedną z metod klasyfikacji. Zagadnienia te są znane od wielu lat i doczekały się bardzo obszernego omówienia w olbrzymiej ilości opracowań naukowych. Z tego też powodu nie będą one przedmiotem niniejszej pracy.

Obiekty leżące w obszarze zainteresowań tego opracowania posiadają dosyć rozpowszechnioną właściwość. Cechy świadczące o ich specyfice, w sensie przynależności do danej klasy, są zależne od innej wielkości. Innymi słowy cechy nie są wartościami liczbowymi, lecz funkcjami. Najistotniejszy jest jednak fakt, iż to właśnie przebieg zmienności tej funkcji stanowi cechę.

Oczywiście samo rozpoznawanie obiektów opisanych za pomocą przebiegu funkcji nie jest niczym nowym. Przykładem może być rozpoznawanie EKG. Sam zapis formalny traktujący przebieg np. EKG jako pojedynczą cechę zmienną w czasie, a nie jako wektor cech o elementach odpowiadających kolejnym punktom czasowym, niczego nowego nie wnosi. Istotne jest to w jaki sposób jest dalej traktowana ta funkcja.

Jeżeli wyznaczy się z niej szereg parametrów i dalej będzie się prowadzić proces klasyfikacji na podstawie obliczonych kilku wartości, to oznacza, iż zadanie zostało sprowadzone do postaci rozpoznawania, gdzie cechy są wartościami liczbowymi, a nie funkcjami. W takim przypadku nadal można stosować znane miary podobieństwa, gdyż porównywane są bezpośrednio liczby.

W przypadku rozpoznawania EKG oraz wielu innych przebiegów takie podejście jest właściwe i skuteczne, co zostało wielokrotnie dowiedzione. Jest jednak cała grupa zagadnień, w których istotą obiektu jest charakterystyka

zmienności jego cech. Sprowadzenie tych funkcji do postaci szeregu parametrów nie daje zamierzonych rezultatów. Istota podobieństwa obiektów leży w podobieństwie funkcji opisujących ich cechy.

W niniejszej pracy przedstawiono metody rozpoznawania obiektów z dwóch dziedzin: inżynierii procesowej a w szczególności przepływów wielofazowych oraz mechanoskopii (kryminalistyki). W pierwszym przypadku obiektem jest przepływ mieszaniny typu gaz-ciecz, gaz-ciało stałe w kanale, w drugim ślad dynamiczny. W obydwu przypadkach zastosowano bezpośrednie porównywanie funkcji opisujących cechy.

W celu sformułowania głównej tezy pracy należy poczynić następujące założenia:

- Nie są znane cechy będące stałymi wartościami liczbowymi, za których pomocą można dokonać poprawnej klasyfikacji obiektów.
- Cechy rozpoznawanych obiektów są funkcjami wielkości niezależnych.
- Przebieg zmienności wybranych cech właściwie różnicuje obiekty dla danego kryterium podziału na klasy.

Główna teza pracy:

Jeżeli spełnione są ww. założenia tzn. specyfika podziału na klasy leży w sposobie zmienności funkcji opisujących obiekty, to w celu określenia podobieństwa obiektów, należy stosować miary odległości przebiegów zmienności cech.

Praktyczna realizacja sformułowanej powyższej tezy zdeterminowała konieczność opracowania grupy zagadnień teoretycznych oraz rozwiązania szeregu problemów na poziomie metodologicznym i algorytmicznym.

3. GŁÓWNY CEL PRACY

Praca ma na celu opracowanie metod i algorytmów rozpoznawania obiektów opisanych za pomocą cech zmiennych w dowolnej dziedzinie np. czasu, częstotliwości, wymiaru dowolnie zdefiniowanej przestrzeni itd., przy założeniu bezpośredniego² porównywania cech.

Rozpoznawanie obiektów rozumiane jest jako przypisywanie im konkretnego znaczenia (numeru klasy) na podstawie pewnych charakterystycznych właściwości zwanych dalej cechami.

W klasycznym zagadnieniu rozpoznawania wyznacza się odległość (stopień podobieństwa) między dwoma wektorami cech opisujących obiekty [56]. Obiekty są statyczne tzn. ich cechy są wartościami niezależnymi. W praktyce stan większości obiektów tzn. wartości zawartych w wektorze cech, jest zależny od pewnych wielkości niezależnych.

Przyjmując jako przykład dziedzinę czasu, rozpoznawany obiekt przestaje być statyczny. Jego cechy są funkcją czasu. Aby dokonać skutecznego rozpoznania należy opracować miarę podobieństwa funkcji, gdyż istota obiektu nie tkwi w jego chwilowym stanie, lecz wynika z dynamiki zmian jego cech [13].

W celu wykazania prawdziwości głównej tezy pracy rozwiązano szereg problemów teoretycznych i praktycznych. W efekcie opracowano metody i algorytmy rozpoznawania przepływów mieszanin wielofazowych oraz śladów dynamicznych³.

Najistotniejsze dla przeprowadzonych badań było podejście mające na celu uzyskanie najwięcej informacji z dynamiki badanych obiektów. Zagadnieniem leżącym u podstaw wszystkich opracowanych metod i algorytmów było zdefiniowanie miar podobieństwa funkcji. Ze względu na fakt, iż cyfrowe

² Bezpośredniość polega na nie sprowadzaniu przebiegu zmienności cechy do grupy parametrów opisujących.

³ Ślad dynamiczny oznacza ślad powstały w wyniku przesuwania się narzędzia po płaszczyźnie i nie ma on nic wspólnego z pojęciem obiektu dynamicznego.

urządzenia pomiarowe działają w sposób dyskretny, zadanie to zostało sprowadzone do postaci zdefiniowania miar podobieństwa ciągów liczbowych. Zagadnienie to zasługuje na szczególne podkreślenie, gdyż ma charakter ogólny i wykracza poza zakres aplikacyjny poruszany w pracy.

3.1. Elementy oryginalne zawarte w pracy

Do elementów oryginalnych opracowanych w ramach prowadzonych badań należy:

- Metoda akwizycji i kodowania cech obiektów dla rozpatrywanych przykładów zastosowań.
- Segmentacja cechy na podciągi liczbowe (impulsy) stanowiące samodzielne obiekty podlegające klasyfikacji.
- Algorytm wyznaczania wektora cech obiektów powstałych z wyznaczonych podciągów liczbowych (impulsów).
- Selekcja i kodowanie cech impulsów.
- Miary podobieństwa impulsów.
- Miary podobieństwa ciągów impulsów.
- Metody rozpoznawania obiektów o parametrach zmiennych w czasie zrealizowana na bazie rozpoznawania dwuetapowego.

4. PODSTAWOWE INFORMACJE Z ZAKRESU ROZPOZNAWANIA OBIEKTÓW

4.1. Ogólny opis zagadnienia

Niezależnie od metody oraz stosowanych narzędzi, rozpoznawanie jest procesem, na który składa się kilka elementów [72]:


- akwizycja informacji,
- wstępna filtracja informacji nadmiarowej,
- korekcja błędów akwizycji,
- selekcja obiektów,
- wyznaczenie cech obiektów,
- klasyfikacja obiektów.

Należy dodać, iż kolejność wykonywania ww. czynności nie musi być identyczna z przedstawioną. Zależy ona od przyjętej metody rozpoznawania. W bardziej złożonych metodach nie występuje prosty - sekwencyjny układ wykonywanych operacji. Struktura przebiegu procesu rozpoznawania zawiera zarówno iteracje jak i operacje warunkowe.

Poniżej zostaną skrótowo omówione ww. etapy, przy czym komentarze, które zostały im przypisane należy traktować jako ogólny opis ich specyfiki. Oznacza to, iż są one zgodne w większości zagadnień, dot. rozpoznawania, jednak można podać przykłady specyficznych zadań, dla których ich opis należałoby w pewnym stopniu zmodyfikować.

4.1.1. Akwizycja informacji

Akwizycja informacji jest pierwszym elementem procesu rozpoznawania obiektów. Rysunek 1. przedstawia schemat układu akwizycji danych stosowany podczas prowadzonych badań. Błędy i ograniczenia powstające na tym etapie mają bardzo wyraźny wpływ na efekt końcowy. Jest to element, który okazał się szczególnie istotny podczas prowadzonych badań i eksperymentów. Ewentualne braki występujące podczas akwizycji są nie do odrobienia w dalszym postępowaniu. Z tego też powodu np. zwierzęta zostały wyposażone w niezwykle czujniki zwane zmysłami. Dla przykładu wzrok wielu zwierząt posiada zdolności, które z trudem udaje się uzyskać przy pomocy bardzo skomplikowanych układów. Wiąże się to z wielkimi nakładami finansowymi oraz pracą specjalistów z wielu dziedzin, a i tak często nie udaje się uzyskać żądanych parametrów nie wspominając o niezawodności i miniaturyzacji. Świadczy to o tym, iż nadal w tej dziedzinie jest bardzo wiele do zrobienia. Aktualnie następuje ogromne nasilenie prac związanych z czujnikami i układami pomiarowymi. Wydaje się, że głównym motorem postępu np. w dziedzinie układów wizyjnych jest możliwość przetwarzania coraz większej ilości danych.




Rysunek 1. Schemat układu akwizycji danych wizyjnych stosowanego podczas prowadzonych badań.

4.1.2. Wstępna filtracja informacji nadmiarowej

Wstępna filtracja informacji nadmiarowej jest operacją, w której następuje odrzucenie informacji, którą w sposób jednoznaczny można określić jako nieistotną dla dalszego rozpoznawania. Powoduje to wyraźny wzrost wydajności algorytmu, gdyż stosunkowo niskim kosztem, można odrzucić duże ilości niepotrzebnej informacji. Przykładem tego typu działania może być, w przypadku rozpoznawania obiektów graficznych, usunięcie z analizowanej sceny fragmentów, które jednoznacznie i łatwo można zakwalifikować jako nie należące do rozpoznawanego obiektu [1][22]. Może to być np. kontrastowe tło lub po prostu obszar, który a priori nie należy do obiektu. Innym przykładem jest sprowadzenie obrazu o 32-bitowej głębi kolorów do postaci odpowiadającej 8-bitowej skali poziomów jasności [40][44][70]. Są to bardzo proste czynności, podczas których następuje znaczące obniżenie ilości danych, które będą przetwarzane w dalszych krokach, więc należy pamiętać, aby możliwie skutecznie wykorzystać ten etap.

Zazwyczaj bardzo niski koszt tej operacji znacznie poprawia jej efektywność. W dalszych etapach redukcja danych będzie już mniej znacząca i dużo trudniejsza.

Rysunek 2. przedstawia przykład redukcji informacji poprzez zawężenie obszaru przeznaczonego do dalszego przetwarzania.




Rysunek 2. Przykład redukcji informacji poprzez odrzucenie obszaru nie biorącego udziału w rozpoznawaniu przepływów dwufazowych.

4.1.3. Korekcja błędów akwizycji

Korekcja błędów akwizycji ma na celu takie przetworzenie informacji o obiekcie, aby usunąć część błędów powstałych podczas akwizycji. Działania tego typu mogą mieć bardzo różnoraki charakter. Rodzaj operacji wykonywanych na tym etapie silnie zależy od rodzaju rozpoznawanego obiektu oraz od fizycznej interpretacji danych, które podlegały akwizycji. Dla przykładu, jeżeli wartościami mierzonymi są sygnały, częstymi operacjami dot. korekcji błędów jest znana w teorii sygnałów bardzo szeroka gama filtrów [79]. Dla obrazów graficznych można stosować analogiczne metody traktując obraz jako sygnał dwuwymiarowy. Dodatkowo istnieje duża ilość metod korekcji błędów specyficznych dla obrazów graficznych [73].

Etap nie ma na celu redukcji danych, lecz ich przetworzenie w taki sposób, aby wyeliminować błędy wynikające z natury metody akwizycji, niedoskonałości toru pomiarowego oraz zakłóceń występujących w otoczeniu rozpoznawanego obiektu lub w samym obiekcie. Podjęte działania zależą od charakteru źródła zakłóceń oraz metody dalszego przetwarzania danych. Rysunek 3. przedstawia przykład korekty dokonanej na sygnale wejściowym.




Rysunek 3. Przykład korekty błędów akwizycji danych.

4.1.4. Selekcja obiektów


Selekcja obiektów ma na celu odrzucenie wszystkich informacji nie należących do rozpoznawanych obiektów. Jest to etap konieczny ze względu na fakt, iż przed wyznaczaniem cech obiektów należy precyzyjnie odpowiedzieć na pytanie, które z posiadanych informacji opisują obiekt, a które należą do jego otoczenia. Etap korekcji błędów miał m.in. na celu ułatwienie dokonania tej operacji.

Podczas akwizycji danych zbierane są informacje zarówno o samym obiekcie, jak i te, które nic o nim nie mówią. Uniknięcie tego zjawiska jest prawie niemożliwe, a w przypadku obrazów graficznych całkowicie niewykonalne. Stopień trudności tego zadania może być bardzo różny. Jeżeli zadaniem byłoby dokonanie selekcji z obrazu binarnego figury geometrycznej znajdującej się na mim, to można powiedzieć, że nie będzie to nastroczało żadnych problemów technicznych i metodologicznych. Rysunek 4. przedstawia przykład sceny binarnej z figurą geometryczną.




Rysunek 4. Figura geometryczna na scenie binarnej.

Brak problemu z selekcją tego obiektu wynika z faktu, iż tylko jeden obiekt znajduje się na scenie i ze względu na jego idealny kontrast w stosunku do tła wystarczy zbadać kolory wszystkich pikseli i wydzielić z niej grupę o kolorze czarnym. Dalsza segmentacja obiektu również nie będzie nastroczała problemów.



Jeżeli na scenie znajdują się rozpoznawane obiekty w różnych kolorach oraz występuje również kolorowe tło, to zadanie może się w pewnym stopniu skomplikować. Rysunek 5. przedstawia właśnie taką sytuację. Część pikseli należących do obiektów może mieć identyczny kolor z pikselami tła. W tej sytuacji prosta selekcja realizowana na podstawie odrzucenia pikseli o danym kolorze nie jest skuteczna. Konieczne jest opracowanie bardziej precyzyjnego narzędzia wydzielającego obiekty ze sceny.



W przypadku, gdy selekcja dotyczyłaby określenia granic pęcherzyków powietrza znajdujących na scenie z 8-bitową gradacją odcieni szarości, to zadanie mogłoby się stać bardzo złożone.

Rysunek 6. przedstawia sytuację przepływu mieszaniny gaz-ciecz w przestrzeni międzyrurowej. Ze względu na wiele zjawisk optycznych mających miejsce podczas akwizycji tego typu obrazów, granice obiektów są często rozmyte lub całkowicie niewidoczne. Kolejnym problemem jest nakładanie się obiektów na siebie, ich duża ilość, zmienność kształtów oraz nieregularność krawędzi.

4.1.5. Wyznaczanie cech obiektów

Zagadnienie to należy podzielić na dwa różne zadania:


- definiowanie cech obiektów,
- wyznaczanie wartości zdefiniowanych cech obiektów.

4.1.5.1. Definiowanie cech obiektów

Definiowanie cech obiektów odbywa się na etapie projektowania systemu rozpoznawania. Właściwy dobór cech na podstawie, których nastąpi rozpoznanie jest niezwykle ważny [24]. Wszystkie cechy powinny charakteryzować się poniższymi właściwościami:

Dobra ***separowalność obiektów*** należących do różnych klas. Cechy należy tak konstruować, aby grupowały one obiekty należące do tej samej klasy oraz separowały obiekty różnych klas. W języku potocznym mówi się o *cechach charakterystycznych* tzn. takich których wartości są właściwe dla danej grupy obiektów. Dla przykładu firmy ubezpieczeniowe klasyfikują swoich klientów wg stopnia ryzyka. Dla ubezpieczeń komunikacyjnych istotną cechą klienta jest ryzyko spowodowania przez niego wypadku. Jest to wielkość niemierzalna w bezpośredni sposób. Na podstawie analiz statystycznych firmy te doszły do przekonania, iż istnieje korelacja między wiekiem klienta, a prawdopodobieństwem, iż stanie się on sprawcą wypadku. Nie jest to cecha wyznaczająca ostrą granicę między sprawcami

wypadków i klientami nie powodującymi ich, ale pozwala w pewnym stopniu rozpoznawać potencjalne źródła wyższych kosztów dla tych firm. Dodając do tego inne cechy takie jak np. długość bezszkodowej jazdy, wiek i markę pojazdu itd. można pokusić się o mniej lub bardziej skuteczną klasyfikację klientów na grupy wg stopnia ryzyka.



Rysunek 7. Graficzna reprezentacja zagadnienia zdolności cech do separowania obiektów różnych klas.

Rysunek 7. przedstawia graficzną reprezentację klas na płaszczyźnie cech, gdzie cecha oznaczona jako $x^{(2)}$ nie separuje jednoznacznie i w ogólnym przypadku obiektów klasy 1 i 2. Natomiast cecha $x^{(1)}$ posiada na tyle duże zdolności do separowania obiektów tych dwóch klas, że za jej pomocą można dokonać klasyfikacji bez konieczności stosowania cechy $x^{(2)}$.

Niezależność cech jest istotna, gdyż tworzenie cech, które są zależne od niektórych innych cech może doprowadzić do zachwiania systemu wag. Jeżeli jakaś cecha jest zależna od innej cechy, to jej udział w końcowej klasyfikacji został pośrednio zmieniony. Innymi słowy, zmiana wartości tej cechy pociąga za sobą zmianę wartości innej lub innych cech. W ten sposób jej waga wzrasta w sposób niezamierzony i często ten fakt nie jest zauważany przez projektantów systemów rozpoznawania. Cechy sprzężone zależnie od wzajemnych relacji między nimi mogą

posiadać dużą siłę klasyfikacyjną lub wzajemnie się znosić, co jest jednak zdecydowanie rzadszym zjawiskiem.

Koszt wyznaczenia wartości danej cechy jest kolejną istotną właściwością cechy. Często pokusą jest stosowanie cech dobrze separujących i niezależnych, ale o wysokich kosztach wyznaczenia jej wartości. Jeżeli koszt realizacji zadania nie ma dużego znaczenia, wtedy jest to sprawa poboczna. Należy jednak zwrócić uwagę na niebezpieczeństwo związane możliwością wystąpienia konieczności zwiększenia ilości rozpoznawanych obiektów. Jeżeli wystąpi taka sytuacja może się okazać, że cały system jest niewydolny, a jego praktyczna funkcjonalność drastycznie spada lub wręcz staje się on całkowicie bezużyteczny.

Odpowiednia **dokładność wyznaczenia** wartości cechy może mieć znaczenie w przypadku ograniczonych możliwości pomiarowych. Wartości cechy obarczone dużymi błędami mogą bardzo niekorzystnie wpływać na efekt działania całego systemu. Analizując wektor cech oraz dobrane wagi należy przeprowadzić pewne czynności związane z rachunkiem błędów. W niektórych przypadkach zadanie to staje się trywialne, są jednak sytuacje, w których wartości zmierzone trafiają z systemu rozpoznawania w stosunkowo bezpośredni sposób. Wpływ dokładności pomiaru na efektywność klasyfikacji może się wówczas okazać równie bezpośredni. Dobierając lub definiując cechy należy brać pod uwagę zawartość informacyjną, jaką one ze sobą niosą. Jednym z podstawowych parametrów informacji jest jej wiarygodność oraz stopień szczegółowości. Z dosyć oczywistych względów zwiększając stopień szczegółowości, rośnie prawdopodobieństwo podania informacji nieprawdziwych. W ten sposób informacje zbyt szczegółowe tracą na wiarygodności. Wynika to z faktu, iż każdy system pomiarowy ma ograniczone parametry w zakresie rozdzielczości, redukcji szumów itd. Należy wyznaczyć satysfakcjonujący poziom precyzji podawanych przez system pomiarowy wartości, dla którego możemy przyjąć, że wiarygodność jest adekwatna do założonej. W praktyce może to oznaczać, iż np. nie ma potrzeby rozpoznawać obiektów na scenie o 24-bitowej głębi kolorów, jeżeli zachodzi przypadek, gdy ograniczenia sprzętowe pozwalają na precyzyjne rozróżnienie tylko 16 kolorów. Wnioskiem może być możliwość 6-krotnej redukcji przetwarzanej informacji

(w obrębie tej cechy), nadanie odpowiednio niskiej wagi lub rezygnacja z korzystania z tej cechy ze względu na niską dokładność. Sztuczne podnoszenie „dokładności” ma czasami miejsce w systemach wizyjnych. Odbywa się to często w ten sposób, iż całość systemu przygotowana jest do przetwarzania poziomów jasności w zakresie 0—255, a akwizycja rzeczywistych danych pomiarowych wskazuje, iż 100% wartości mieści się np. w zakresie 153—165. W bardzo prosty sposób można doprowadzić do „rozciągnięcia” histogramu na zakres 0—255

$g_1(x, y)$ - modyfikowany obraz,

$g_2(x, y)$ - obraz po transformacji,

$g_2(x, y) = T[g_1(x, y)]$ - transformacja obrazu. (1)

W opisywanym przypadku należy zastosować superpozycję funkcją liniową:

$$g_2(x, y) = (g_1(x, y) + t_1)t_2 \quad (2)$$

gdzie:

$$t_1 = g_2^{\min} - g_1^{\min}, \quad (3)$$

$$t_2 = \frac{g_2^{\max} - g_2^{\min}}{g_1^{\max} - g_1^{\min}}, \quad (4)$$

$< g_1^{\min}, g_1^{\max} >$ - zakres poziomów jasności obrazu modyfikowanego,

$< g_2^{\min}, g_2^{\max} >$ - zakres poziomów jasności obrazu po transformacji.

Jest to jednak zabieg czysto formalny i niczego nie wnosi do samej dokładności. Jeżeli przykładową wartością otrzymaną w wyniku pomiaru poziomu jasności jakiegoś piksela jest $6F_{(16)}$, to wiarygodność cyfry o wadze 16 jest nieporównywalnie większa niż cyfry o wadze 1. W efekcie i tak możemy brać pod uwagę tylko najbardziej znaczącą cyfrę, co oznacza, że wracamy do punktu wyjścia, czyli niskiej dokładności zmierzonych wartości. Należy się zastanowić czy cecha o niskiej dokładności stanowi istotną wartość informacyjną, którą można brać pod uwagę podczas klasyfikacji. Rozważenie tego problemu pozwala czasami na uniknięcie rozczarowania efektami klasyfikacji.

Reasumując rozważania na temat zagadnienia definiowania cech obiektów należy zwrócić uwagę, że duża ilość cech nie zawsze poprawia skuteczność klasyfikacji. Ważna jest jakość stosowanych cech. Zaproponowane podstawowe kryteria oceny jakości cech:

- separowalność obiektów,
- niezależność,
- koszt wyznaczenia,
- dokładność wyznaczenia,

pozwalają uniknąć definiowania lub wyboru cech, których udział nie podnosi skuteczności. Każda cecha posiada jakąś wagę, oznacza to, iż włączając do wektora cechę o słabej efektywności, osłabiamy działanie pozostałych cech. Czasami można zauważyć tendencję do dokładania do wektora wielu cech na zasadzie „*Może nie pomoże, ale nie zaszkodzi.*”. Dosyć oczywistą prawdą jest fakt, iż staranność przy doborze nowych cech procentuje nie osłabianiem tych, które są w rzeczywistości wartościowe. W praktyce okazuje się też, iż bardzo łatwo można poprawić skuteczność klasyfikacji rezygnując z pewnych cech. Jest to zadanie stosunkowo proste, lecz można się spodziewać oporu ze strony projektanta systemu, który poświęcił nierzadko wiele wysiłku na opracowanie danej cechy i ciężko jest mu się „rozstać” z częścią swojego dzieła.

Innym przypadkiem jest sytuacja, w której w wyniku analizy cech oraz ich wzajemnych relacji okazuje się, że można wydzielić grupy cech dobrze współpracujących ze sobą. Wymaga to znacznie głębszego podejścia do problemu, zrozumienia wielu aspektów rozpoznawanego obiektu systemu pomiarowego, metody rozpoznawania oraz samych cech.

4.1.5.2. Wyznaczanie wartości cech

Wyznaczanie wartości wektora cech ma następujące podstawowe aspekty:

- metrologiczny,
- matematyczny.

Z metrologicznego punktu widzenia należy stosować szereg zasad oraz przestrzegać reguł dokonywania pomiaru lub wyznaczania wartości mierzonych. Akwizycja obrazu graficznego jest zagadnieniem złożonym, a w przypadku sekwencji wideo pojawiają się dodatkowe problemy związane z dynamiką.

Uzyskanie wyniku pomiaru pewnej wielkości najczęściej nie kończy etapu wyznaczania wartości cechy. Zmierzona lub wyznaczona cecha musi zostać przetworzona w sposób, który zapewni możliwość jej porównywania z innymi cechami. Nie wchodząc na tym etapie w zagadnienia teoretyczne dot. miar odległości oraz algorytmów klasyfikacji można podać następujący przykład. Zadaniem jest ocena podobieństwa⁴ obiektów (w tym przykładzie są to osoby). Tabela 1. zawiera zmierzone lub wyznaczone cechy obiektów.

Tabela 1.

Przykładowe cechy obiektów

<i>Cecha</i>	<i><u>Obiekt 1:</u></i>	<i><u>Obiekt 2:</u></i>	<i><u>Obiekt 3:</u></i>
$x^{(1)}$ <i>wzrost</i>	<i>1.78 m</i>	<i>1.70</i>	<i>1.85 m</i>
$x^{(2)}$ <i>masa</i>	<i>75 kg</i>	<i>68 kg</i>	<i>72 kg</i>
$x^{(3)}$ <i>wiek</i>	<i>38 lat</i>	<i>25 lat</i>	<i>32 lata</i>
$x^{(4)}$ <i>pleć</i>	<i>mężczyzna</i>	<i>kobieta</i>	<i>mężczyzna</i>

Bez dokonywania wstępnych przekształceń matematycznych ich wektory cech wyglądałyby następująco⁵:

⁴ Określenie stopnia podobieństwa umożliwia porównywanie obiektów, a więc i ich klasyfikację.

⁵ Przy założeniu kodowania cechy *pleć*: 0 – kobieta, 1 – mężczyzna.

$$x_1 = [1.78, 75, 38, 1]^T,$$

$$x_2 = [1.70, 68, 25, 0]^T,$$

$$x_3 = [1.85, 72, 32, 1]^T.$$

Nadal nie zajmując się budowaniem miar podobieństwa oraz algorytmów klasyfikacji można zadawać następujące pytania. Co stanowi mniejszą różnicę: różnica wzrostu o 0.08 m, czy różnica wieku o 6 lat, różnica masy o 3 kg, czy różnica płci.

Pytania te wiążą się zagadnieniem normalizacji oraz wyznaczaniem wag. Sprawa wag dotyczy innego problemu i nie będzie w tym kontekście rozważana.

Niezależnie od złożoności obiektu oraz charakteru opisujących go cech, wynikiem porównania dwóch obiektów musi być pojedyncza wartość określająca stopień ich podobieństwa. Wynika stąd, iż nie można ominąć odpowiedzi na ww. pytania. Dlatego też normalizacja jest zadaniem koniecznym. Wprowadzenie wartości różnych cech do jednego równania określającego odległość (podobieństwo) obiektów wymaga sprowadzenia ich do jednej skali. Sposoby normalizacji zależą ściśle od fizycznej reprezentacji cech oraz opracowanej metody rozpoznawania.

Dla powyższego przykładu można zaproponować następującą normalizację:

dla $j \in \{1, 2, 3, 4\}$

dla $i \in \{1, 2, 3\}$

$$x_i'^{(j)} = \frac{x_i^{(j)}}{\max_{i=1..3}(x_i^{(j)})}. \quad (5)$$

W wyniku przeprowadzenia powyższej normalizacji powstają następujące wektory cech:

$$x'_1 = [0.9621, 1, 1, 1]^T,$$

$$x'_2 = [0.5454, 0.9066, 0.6578, 0]^T,$$


$$x'_3 = [1, 0.96, 0.8421, 1]^T.$$

Niezależnie od przyjętych wag oraz algorytmu klasyfikacji, możliwe stało się porównywanie np. różnicy wieku z różnicą wzrostu czy masy. Zaproponowana normalizacja jest tylko przykładem i rozpatrywanie jej praktycznej skuteczności nie stanowi celu dalszych rozważań.

4.2. Opis formalny

W rozdziale tym zostanie przedstawiony formalny opis zagadnienia rozpoznawania obiektów [56].

Zgodnie przyjętą w rozdziale 2.1.1. definicją, rozpoznawanie obrazów jest procedurą obejmującą pomiar wartości cech, wstępne przetwarzanie, selekcję oraz klasyfikację mającą na celu przypisywanie obiektom konkretnego znaczenia na podstawie pewnych charakterystycznych właściwości. Rysunek 8. prezentuje istotę rozpoznawania obiektów.



Rysunek 8. Ogólna idea systemu rozpoznawania obiektów.

Sposób, w jaki następuje przypisanie obiektów do odpowiednich numerów klas określa się mianem algorytmu rozpoznawania ψ . Algorytm rozpoznawania ψ odwzorowuje przestrzeń cech X w zbiór numerów klas M

$$\psi : X \rightarrow M. \quad (6)$$

Przestrzeń cech X jest podzbiorem d -wymiarowej przestrzeni $\mathbb{R}^d$

$$X \subseteq \mathbb{R}^d. \quad (7)$$

Zbiór numerów M klas jest zbiorem kolejnych liczb naturalnych od 1 do M , będącym całkowitą ilością numerów klas

$$M \in \{1, 2, \dots, M\}. \quad (8)$$

Rozpoznawane obiekty są reprezentowane poprzez wektor x wartości cech $x^{(1)}, x^{(2)}, \dots, x^{(d)}$

$$x = [x^{(1)}, x^{(2)}, \dots, x^{(d)}]^T. \quad (9)$$

Algorytm rozpoznawania ψ przypisuje każdemu wektorowi zmierzonych cech x należącemu do przestrzeni cech X numer klasy i należący do zbioru numerów klas M .


$$x \in X, \quad (10)$$

$$\psi(x) = i, \quad (11)$$

$$i \in M. \quad (12)$$

Innymi słowy algorytm rozpoznawania ψ generuje rozkład przestrzeni cech X na obszary decyzyjne $D_x^{(i)}$

$$D_x^{(i)} = \{x \in X : \psi(x) = i\}. \quad (13)$$



Rysunek 9. Przykład rozkładu obszarów decyzyjnych na płaszczyźnie 2D.

Rysunek 9. przedstawia graficzną reprezentację przykładowego rozkładu obszarów decyzyjnych. Rozkład przestrzeni oznacza rozłączną i pokrywającą całą przestrzeń rodzinę zbiorów

$$\forall_{i,j(\neq i) \in M} D_x^{(i)} \cap D_x^{(j)} = \emptyset, \quad (14)$$

$$\bigcup_{i \in M} D_x^{(i)} = X. \quad (15)$$

Obszary decyzyjne są oddzielone powierzchniami decyzyjnymi. Określają one algorytm rozpoznawania ψ . Istnieje, więc możliwość definiowania algorytmu ψ poprzez wyznaczenie powierzchni rozdzielającej obszary decyzyjne. Z praktycznego punktu widzenia jest to zadanie dosyć niewygodne, a więc raczej rzadko stosowane.

Algorytm rozpoznawania ψ można opisać za pomocą funkcji dyskryminujących g_i

$$g_i : X \rightarrow R. \quad (16)$$

Funkcje dyskryminujące należy tak dobrać, aby na i -tym obszarze decyzyjnym wartość i -tej funkcji klasyfikującej była największa


$$\forall_{i \in M} \forall_{x \in D_x^{(i)}} g_i(x) = \max_{k \in M} g_k(x). \quad (17)$$

Ogólna idea dotycząca funkcji klasyfikujących mówi, iż dla wektora x należącego do danego obszaru decyzyjnego $D_x^{(i)}$ wartości funkcji $g_i(x)$ stanowi wyróżnik w stosunku do wartości funkcji dla innych obszarów decyzyjnych. Formułę $\forall_{i \in M} \forall_{x \in D_x^{(i)}} g_i(x) = \max_{k \in M} g_k(x)$ należy traktować jedynie jako przykład takiego rodzaju rozróżnienia.

Z praktycznego punktu widzenia wygodnie jest stosować opis algorytmu rozpoznawania wyrażony poniższą formułą:

$$\psi(x) = i, \text{ gdy } g_i(x) = \max_{k \in M} g_k(x). \quad (18)$$

Oznacza ona, iż algorytm rozpoznawania przypisuje obiektowi reprezentowanemu przez wektor x numer klasy i , gdy wartość i -tej funkcji dyskryminacyjnej jest największa ze zbioru wszystkich funkcji dyskryminacyjnych.



Rysunek 10. Schemat struktury klasyfikatora opisanego funkcjami dyskryminacyjnymi.

Rysunek 10. przedstawia strukturę klasyfikatora opisanego funkcjami dyskryminacyjnymi.


Istnieje wiele algorytmów rozpoznawania [56]. Jednym z nich jest algorytm liniowy, który zawdzięcza swoją nazwę postaci funkcji dyskryminującej

$$g_i(x) = w_i^T x + w_i^{(0)} = w_i^{(1)} x^{(1)} + w_i^{(2)} x^{(2)} + \dots + w_i^{(d)} x^{(d)} + w_i^{(0)}, \quad (19)$$

lub inaczej

$$g_i(x) = \sum_{k=1}^d w_i^{(k)} x^{(k)} + w_i^{(0)}. \quad (20)$$

Symbol $w^{(k)}$ oznacza wagi określające relatywne znaczenie poszczególnych składowych wektora x . Rysunek 11. przedstawia strukturę klasyfikatora liniowego.



Rysunek 11. Schemat struktury klasyfikatora liniowego.

W algorytmie kwadratowym funkcje dyskryminacyjne są funkcjami kwadratowymi

$$g_i(x) = x^T w_i x + w_i^T x + w_i^{(0)}. \quad (21)$$

Uogólnieniem algorytmu liniowego jest algorytm liniowy względem parametrów

$$g_i(x) = x^T \Phi(x) + w_i^{(0)}. \quad (22)$$

Algorytm sigmoidalny wprowadza pojęcie funkcji σ o następujących własnościach:

$$\sigma(x) \rightarrow -1, \text{ gdy } x \rightarrow -\infty,$$


$$\sigma(x) \rightarrow 1, \text{ gdy } x \rightarrow \infty.$$

Formalny zapis algorytmu sigmoidalnego posiada następującą postać:

$$g(x) = w^{(0)} + \sum_{i=1}^k w^{(i)} \sigma[g_i(x)]. \quad (23)$$

$$\psi(x) = i, \text{ gdy } \|x - \bar{x}_i\| = \min_{k \in M} \|x - \bar{x}_k\|. \quad (29)$$

Metoda obiektu „typowego” $\bar{x}$ polega na znalezieniu takiego obiektu w zbiorze wszystkich obiektów danej klasy, który najlepiej ją reprezentuje. Następnie należy znaleźć, który z obiektów „typowych” jest najbliższy obiektowi rozpoznawanemu i przypisać numer jego klasy do rozpoznawanego obiektu. Rysunek 12. przedstawia graficzną reprezentację algorytmu minimalno-odległościowego dla metody wyboru obiektu „typowego”.




Rysunek 12. Graficzna reprezentacja algorytmu minimalno-odległościowego, dla metody wyboru obiektu „typowego”.

Zasada najlepszej reprezentacji może oznaczać bardzo różne podejścia formalne. Wynika to z faktu, iż pojęcie obiektu „typowego” można definiować na bardzo różne sposoby. Poniżej zostaną przedstawione wybrane metody wyboru obiektu reprezentującego klasę.

$$\psi(x) = i, \text{ gdy } \|x - \bar{x}_i\| = \min_{k \in M} \|x - \bar{x}_k\|. \quad (29)$$

Metoda obiektu „typowego” $\bar{x}$ polega na znalezieniu takiego obiektu w zbiorze wszystkich obiektów danej klasy, który najlepiej ją reprezentuje. Następnie należy znaleźć, który z obiektów „typowych” jest najbliższy obiektowi rozpoznawanemu i przypisać numer jego klasy do rozpoznawanego obiektu. Rysunek 12. przedstawia graficzną reprezentację algorytmu minimalno-odległościowego dla metody wyboru obiektu „typowego”.



Zasada najlepszej reprezentacji może oznaczać bardzo różne podejścia formalne. Wynika to z faktu, iż pojęcie obiektu „typowego” można definiować na bardzo różne sposoby. Poniżej zostaną przedstawione wybrane metody wyboru obiektu reprezentującego klasę.

W celu przedstawienia algorytmów przyjęto następujące oznaczenia:

- $x_j^{(k)}$ obiekt x_j należy do klasy o numerze i , $\psi(x_j) = i$, a symbol $^{(k)}$ oznacza numer cechy,
- m_i oznacza liczebność klasy o numerze i ,
- $\bar{x}_i^{(k)}$ oznacza reprezentatywną wartość cechy o numerze k dla klasy o numerze i .

Metoda wartości średniej polega na wyznaczeniu obiektu reprezentanta jako nowego obiektu, dla którego kolejne elementy wektora cech są obliczane jako średnie arytmetyczne wartości cech ze wszystkich obiektów danej klasy.

Poniższy algorytm przedstawia formalny zapis metody średniej arytmetycznej

$$i = 1..M$$

$$k = 1..d$$

$$\bar{x}_i^{(k)} = \frac{1}{m_i} \sum_{j=1}^{m_i} x_j^{(k)} . \quad (30)$$


Metoda mediany wyznacza obiekt „typowy” jako nowy obiekt, którego kolejne elementy wektora cech są medianami wartości cech ze wszystkich obiektów danej klasy.

Poniższy algorytm przedstawia formalny zapis metody mediany.


$$i = 1..M$$

$$k = 1..d$$


$$\bar{x}_i^{(k)} = \frac{\max_{j \in \{1, \dots, m_i\}} (x_j^{(k)}) + \min_{j \in \{1, \dots, m_i\}} (x_j^{(k)})}{2} . \quad (31)$$




Rysunek 13. Graficzna reprezentacja metody wyznaczania nowego obiektu „typowego” wg średniej arytmetycznej.



Rysunek 14. Graficzna reprezentacja metody wyznaczania nowego obiektu „typowego” wg mediany.



Rysunek 15. Graficzna reprezentacja metody wyznaczania obiektu „typowego” jako najbliższego obiektowi obliczonemu wg średniej arytmetycznej.



Rysunek 16. Graficzna reprezentacja metody wyznaczania obiektu „typowego” jako najbliższego obiektowi obliczonemu wg mediany.


Metoda najbliższego sąsiada polega na wyznaczeniu w każdej klasie obiektu, który leży najbliżej obiektu rozpoznawanego

$$\psi(x) = i, \text{ gdy } \|x - x_i\| = \min_{j \in N} \|x - x_j\|. \quad (36)$$

Zbór numerów obiektów, N jest zbiorem kolejnych liczb naturalnych od 1 do N , będącego całkowitą ilością obiektów


$$N \in \{1, 2, \dots, N\}. \quad (37)$$

Rysunek 17. przedstawia graficzną reprezentację wyboru obiektu reprezentanta wg metody najbliższego sąsiada.



Rysunek 17. Graficzna reprezentacja algorytmu minimalno-odległościowego, dla metody najbliższego sąsiada.


Uogólnieniem metody najbliższego sąsiada jest metoda n -najbliższych sąsiadów. Jej istotą jest wyszukanie w każdej klasie n najbliższych sąsiadów rozpoznawanego obiektu.



Rysunek 18. Graficzna reprezentacja algorytmu minimalno-odległościowego, dla metody n -najbliższych sąsiadów.

Rysunek 18. przedstawia graficzną reprezentację metody polegającej na wyszukaniu większej ilości obiektów i obliczeniu ich średniej odległości od rozpoznawanego obiektu. Unika się w ten sposób sytuacji, gdy jeden z obiektów leżący blisko decyduje o klasyfikacji. Zyskuje się tym samym większy obiektywizm rozpoznania. Może się zdarzyć sytuacja, gdy obiekt danej klasy leży blisko obiektu rozpoznawanego, ale nie odzwierciedla on właściwie tej klasy. Rozpoznanie takie staje się wtedy dosyć przypadkowe. W sytuacji obliczania średniej odległości kilku obiektów trudno już mówić o takiej przypadkowości, gdyż można założyć, że skoro kilka obiektów miało wpływ na wyniki klasyfikacji, to rozpoznanie jest, w dużej mierze, pozbawione elementu wpływu błędów próby uczącej.

Bardzo istotnym pojęciem algorytmu minimalno-odległościowego jest **miara odległości** [56]. Sposób jej określenia determinuje wyniki rozpoznania. Miara odległości określa stopień podobieństwa obiektów.



Rysunek 19. Interpretacja graficzna różnych miar odległości.

Rysunek 19. przedstawia graficzną reprezentację różnych miar odległości. W tym miejscu warto zauważyć, iż dla normy euklidesowej algorytm minimalno-odległościowy staje się algorytmem liniowym. Klasyczna miara odległości dwóch obiektów x w przestrzeni euklidesowej wyraża się poniższym wzorem [56][20]

$$f(x_i, x_j) = \|x_i - x_j\| = \sqrt{\sum_{k=1}^d |x_i^{(k)} - x_j^{(k)}|^2}. \quad (38)$$

Jest to najkrótsza droga łącząca dwa punkty w przestrzeni euklidesowej. Należy zauważyć, iż nie jest to jedyna możliwa przestrzeń. Istnieje wiele przykładów, dla których stosowanie przestrzeni euklidesowej jest niewłaściwie, gdyż nie uwzględnia ona w sposób właściwy charakteru opisywanego zjawiska. Klasycznym przykładem jest obliczanie odległości w sensie dystansu liniowego na wolnej przestrzeni np. na morzu oraz w mieście. W uproszczeniu można powiedzieć że, na otwartym morzu lub w powietrzu, odległość między dwoma punktami określa się jako najkrótszy dystans, jaki trzeba przebyć z jednego punktu do

drugiego. Jest to po prostu długość wektora łączącego te punkty. Dla odległości liczonej w mieście należy brać pod uwagę fakt, iż w przypadku ogólnym, nie możemy się poruszać wzdłuż linii prostej łączącej dwa punkty. Konieczne jest poruszanie się po odcinkach prostych ułożonych względem siebie pod kątem prostym.

Odległość w sensie rozpoznawania obiektów może być definiowana w różny sposób i nie konieczne musi oznaczać fizyczną długość drogi [20]. Może to być np. czas potrzebny na przemieszczenie się z jednego punktu do drugiego lub np. koszt takiego przemieszczenia. Sam koszt może również być różnie interpretowany, jako koszt czasowy, energetyczny lub np. finansowy. Przestrzeń euklidesowa posiada szereg własności. Jedną z nich jest to, że odległość z punktu a do punktu b jest równa odległości z punktu b do punktu a :

$$\|a - b\| = \|b - a\|. \quad (39)$$

W innych przestrzeniach ta zasada nie musi być spełniona. W praktyce może to być przypadek, w którym odległością jest czas potrzebny na przebycie drogi łączącej dwa punkty w mieście. Biorąc pod uwagę, że część ulic jest jednokierunkowa, w tak zdefiniowanej odległości:

$$\|a - b\| \neq \|b - a\|. \quad (40)$$

Spostrzeżenie to jest o tyle istotne, iż trudno sobie wyobrazić sytuację, gdy w sensie rozpoznawania obiektów odległość między obiektami się różni w zależności od tego czy porównujemy obiekt a z b czy też b z a . Wybierając czy też definiując przestrzeń oraz miarę odległości należy zadbać, aby odległość w obie strony była taka sama. W przypadku przestrzeni nieeuklidesowej możliwe są inne postaci miary odległości. Dla przykładu, poniższa formuła przedstawia często stosowaną metrykę dla wartości dyskretnych

$$f(x_i, x_j) = \|x_i - x_j\| = \sum_{k=1}^d |x_i^{(k)} - x_j^{(k)}|. \quad (41)$$

Wybór metryki jest uzależniony od charakteru zadania rozpoznawania.

5. UMIEJSCOWIENIE PROBLEMATYKI W OBSZARZE ROZPOZNAWANIA OBIEKTÓW

5.1. Podstawowy podział metodologiczny

Rozpoznawanie obiektów jest dziedziną nauki, która dopracowała się wielu sposobów patrzenia na to zagadnienie [56]. W rozdziale tym zostanie przedstawiony bardzo ogólny podział, którego celem jest umiejscowienie opisu proponowanej metody w niezwykle bogatym obszarze związanym tematycznie z rozpoznawaniem obiektów.

Istnieją dwa podstawowe kryteria podziału kierunków rozwoju rozpoznawania obiektów:

1. charakter wiedzy na podstawie, której dokonywane jest rozpoznawanie,
2. sposób budowania algorytmów.

W zakresie pierwszego kryterium można wyróżnić metody realizowane na bazie:

- reguł [11][12],
- skojarzeń ze znanymi obiektami.

Drugie kryterium wyznacza dwa nurty:

- biocybernetyczny (*naśladowanie procesów myślowych* [42][46][87]),
- algorytmiczny (*formalne, matematyczne metody opisu zadania rozpoznawania*)

W nurcie algorytmicznym istnieją dwa kierunki:

- strukturalny (*zwany również lingwistycznym lub syntaktycznym*),
- decyzyjno-teoretyczny.

Istnieją dwa modele opisu zadania rozpoznawanie w kierunku decyzyjno-teoretycznym:

- statystyczny (*związki pomiędzy klasą i opisującym go wektorem wartości cech są rozpatrywane w kategoriach probabilistyki* [63][56])
- deterministyczny.

Rozważane i stosowane są również rozwiązania mieszane, realizujące zadania metodami kombinowanymi [34].

5.2. Sprecyzowanie obszaru prowadzonych badań

Proponowana metoda została opracowana w wyniku badań nad rozpoznawaniem obiektów prowadzonym na bazie **skojarzeń ze znanymi obiektami**, w nurcie **algorytmicznym**, w kierunku **decyzyjno-teoretycznym** przy **deterministycznym** opisie zadania.

Istnieje wiele przyczyn, które złożyły się na pokierowanie prac właśnie na taki tor. Niewątpliwie duże znaczenie miał fakt chęci kontynuacji prowadzonych uprzednio badań [48]. Nie bez znaczenia też jest charakter, sformułowanych na wstępie, zadań praktycznych. Rozwiązanie ich stanowiło podstawowe źródło oceny poprawności metod i algorytmów. Praktyczna weryfikacja była już na wstępie kluczowym elementem wszelkich działań. Mimo dużego nacisku na praktyczną stronę zadania należało znaleźć obszar, w którym możliwe byłoby opracowanie oryginalnej metody i algorytmów o właściwym ciężarze gatunkowym oraz odpowiednim stopniu ogólności.

W efekcie został wyznaczony kierunek i w miarę postępu prac stawał się on coraz bardziej wyraźny i spójny. Nie oznacza to, iż przyjęcie innego toru rozwoju metody nie pozwoliłoby na uzyskanie zamierzonego efektu. Wiele innych kierunków, często w zdecydowanie odmiennych nurtach rozumowania, jawiło się równie interesujące, lecz aby doprowadzić działania do końca należało przyjąć jedną drogę rozwoju.

6. OPIS OPRACOWANEJ METODY ROZPOZNAWANIA OBIEKTÓW

6.1. Podstawowe zagadnienia

Zadanie rozpoznawania obiektów można przedstawić w postaci następującej struktury zagadnień:

1. Określenie przedmiotu rozpoznawania (*zdefiniowanie pojęcia: obiekt rozpoznawania*).
2. Wyznaczenie wektora cech.
 - a) Zdefiniowanie cech opisujących obiekty.
 - b) Wyznaczenie wartości cech.
 - i) Określenie procedur i technik pomiarowych (*np. pomiar fizycznych parametrów obiektów*)
 - ii) Kodowanie cech (*sposób cyfrowej reprezentacji cech*)
 - iii) Operacje matematyczne umożliwiające porównywanie cech (*np. normalizacja*)
3. Selekcja cech
 - a) Określenie ilości cech.
 - b) Wybór cech istotnych.
 - c) Wyznaczenie wektora wag.
4. Wyznaczenie klas, (jeżeli *metoda rozpoznawania umożliwia określenie klas np. na podstawie dostępnej próby uczącej lub informacji a priori*)
5. Klasyfikacja (*rozumiana jako czynność decyzyjna polegająca na przypisaniu obiektowi numeru klasy*)

W praktyce proponowana metodologia postępowania podczas rozwiązywania zagadnień rozpoznawania obrazów ma na celu zapewnić kompleksowe i uporządkowane podejście do problemu.

6.2. Opis metody

Opracowana metoda rozpoznawania obiektów opiera się na bezpośrednim porównywaniu ciągów liczbowych opisujących zmienność cech. Praktyczne zadania, których rozwiązania przedstawiono w niniejszej rozprawie dotyczą rozpoznawania:

- struktur przepływu mieszanin dwufazowych,
- śladów dynamicznych.

Tematyka tych zadań jest bardzo odległa stąd też sposób podejścia do nich może się wydawać pozornie znacząco różny. Punkt wspólny obu tematów leży na poziomie metod i algorytmów określania podobieństwa ciągów liczbowych opisujących charakter rozpoznawanych obiektów oraz w stwierdzeniu zawartym w tezie pracy.

Mimo, iż istnieją bardzo wyraźne punkty wspólne obu podejść aplikacyjnych to problemy, jakie rozwiązano realizując zadania rozpoznawania w dużym stopniu zależały od ich specyfiki. Prace nad nimi prowadzono w różnych okresach czasu, a opracowane wnioski, metody i algorytmy o charakterze ogólniejszym powstały jako element syntezy doświadczeń oraz uogólnień wypracowanego materiału.

W związku z tym w dalszej części zostaną opisane metody i algorytmy oraz opis prowadzonych badań i eksperymentów zarówno dla zagadnienia rozpoznawania struktur przepływu mieszanin dwufazowych oraz rozpoznawania śladów dynamicznych.

6.2.1. Podstawy teoretyczne

W obu tematach aplikacyjnych rozpoznawane obiekty posiadają postać graficzną. Z tego względu procedura wyznaczania cech obiektów stanowi samodzielny problem. Znaczenie poprawnego rozwiązania tego zadania jest kluczowe dla możliwości opracowywania i stosowania metod klasyfikacji obiektów.

W związku z tym poniżej zostaną przedstawione wybrane zagadnienia teoretyczne i praktyczne, które stanowiły istotny element opracowywanych algorytmów.

Wiele definicji, własności i twierdzeń obowiązujących w geometrii ciągłej nie może być przeniesione na grunt płaszczyzny dyskretnej. Dostępna technologia wymusza pracę na płaszczyznach dyskretnych. Opracowane metody musiały brać to pod uwagę oraz zawierać rozwiązanie szeregu problemów z tym związanych.

Podczas przejścia z płaszczyzny ciągłej na dyskretną pojawia się wiele niejednoznaczności, co zmusza do ponownego definiowania pojęć. Uwagi te odnoszą się nawet do podstawowych definicji.

6.2.1.1. Pojęcia podstawowe

Zbiór danych może być interpretowany przez algorytmy w dowolny sposób [81]. Od algorytmu zależy, jakie znaczenie im zostanie przypisane. Dopiero po określeniu znaczenia wszystkich danych można mówić o przetwarzaniu i dalej o rozpoznawaniu obrazów. Ciąg bajtów zapisanych w określonej strukturze danych może być obrazem kolorowym lub zawierać tylko odcienie szarości i tylko interpretacja kolejnych bitów informacji zapewnia traktowanie danego obrazu w ten czy inny sposób [27][37][68].

Przedstawiony poniżej podział na cztery klasy określa sposób przetwarzania i reprezentacji obrazu [69].

Klasa 1: Obrazy o pełnej gradacji kontrastów i obrazy kolorowe

Obrazy klasy **1** są postacią typowych obrazów telewizyjnych. Dokładnie przedstawiają "rzeczywistość". Są one reprezentowane jako macierze z elementami całkowitymi. Informacje o kolorach są przechowywane w postaci rozłożonej na trzy podstawowe barwy. Tabela 2. przedstawia zależność między ilością bitów na piksel, dostępną paletą barw oraz zajętością pamięci.

Tabela 2.

Zależność zajętości pamięci od palety kolorów

<i>Ilość bitów na kolor (RGB)</i>	<i>Zajętość pamięci [bity/piksel]</i>	<i>Paleta kolorów</i>
R:2 G:1 B:1	4	16
R:3 G:3 B:2	8	256
R:6 G:5 B:5	16	65.536
R:8 G:8 B:8	24	16.777.216

Klasa 2: Obrazy dwupoziomowe

Obrazy tej klasy mogą być reprezentowane jako macierze z jednym bitem na element. Dwupoziomowe obrazy nie występują w świecie naturalnym, są one abstrakcyjną reprezentacją obiektów powstałą np. przez transformację obrazów klasy **1**. Binarna mapa bitowa zawiera informacje o kształcie obiektów, ich wielkości, położeniu względem siebie, ale nie można nic na jej podstawie powiedzieć np. o oświetleniu obiektów.

Klasa 3: Krzywe ciągłe i linie proste

Dane są ciągami punktów, które mogą być reprezentowane przez ich współrzędne (x, y) . Przykładem obrazów klasy **3** są kontury obszarów lub ich szkielety. Wydajną reprezentacją danych o obrazie klasy **3** są *kody łańcuchowe*, w których wektor łączący dwa kolejne punkty jest określony jednym symbolem ze skończonego ich zbioru.

3	2	1
4		0
5	6	7

Rysunek 20. Osiem wyróżnionych kierunków na dwuwymiarowej siatce kwadratowej.

Rysunek 20. przedstawia interpretacje ośmiu kierunków używanych w kodzie łańcuchowym. Jeśli punkty zostały wybrane z sąsiednich elementów macierzy obrazu, to ich reprezentacja za pomocą przyrostów indeksów macierzy będzie wymagała czterech bitów na punkt.

Klasa 4: Punkty lub wieloboki

Obrazy klasy **4** składają się ze zbiorów oddzielnych punktów, które są tak od siebie oddalone, że nie mogą być reprezentowane przez zwykły kod łańcuchowy. W zamian należy zastosować tablicę ich współrzędnych (x, y) . Punkty mogą być połączone liniami prostymi lub nieskomplikowanymi krzywymi. Odróżnienie tej klasy od poprzedniej nie jest proste i ma dopiero wówczas znaczenie, gdy uwzględni się sposoby reprezentacji danych. W dalszym ciągu można użyć kodów łańcuchowych z więcej niż jednym elementem na punkt, wyboru między reprezentacjami należy dokonać uwzględniając statystyczny rozkład odległości między punktami.


Dla potrzeb rozpoznawania najkorzystniejszą formą danych jest obraz klasy **2**. Aby obraz mógł być poddany procesowi rozpoznawania konieczne jest przetworzenie go w taki sposób, aby możliwa była jego dalsza analiza.

Obrazem wejściowym jest mapa bitowa. Stanowi ona dyskretną płaszczyznę zawierającą reprezentację rastrową obiektów. Aby analizować kształt konieczne jest pozostawienie tylko tych elementów obrazu, które zawierają istotną dla nas informację o nim.

6.2.1.2. Istotne metody przetwarzania obrazów graficznych


Ścienianie

Jedną z metod pozwalających na odfiltrowanie zbędnych elementów obrazu jest "*ścienianie*" danej figury [97]. Algorytmy ścieniania są dobrym przykładem prób adaptacji definicji zaczerpniętych z płaszczyzny ciągłej na płaszczyznę dyskretną. Okazuje się, że przejście takie nie zawsze jest rzeczą prostą. Dzieje się tak, dlatego, że wiele matematycznych definicji traci w grafice rastrowej swoją jednoznaczność [20]. Przykładem może być określenie linii prostej jako najkrótszego odcinka między dwoma punktami. Rysunek 21. przedstawia obraz, na którym widać, że płaszczyzna dyskretna pozwala na przeprowadzenie dwóch odcinków o równej długości, łączących dwa punkty.



Rysunek 21. Linie proste łączące dwa punkty.

Jeżeli przyjmiemy definicję, że linią cienką jest linia o grubości jednego piksela, to powstaje problem ścienienia linii, której grubość wynosi dwa punkty. Rysunek 22. przedstawia linię o grubości dwóch punktów, na której zaznaczone punkty o symbolu **1** oraz **2**.



Rysunek 22. Linia o grubości dwóch punktów.

Zarówno punkty oznaczone numerem (**1**) jak i punkty oznaczone numerem (**2**) są równouprawnione. Podjęcie decyzji o usunięciu jednych albo drugich (jedne i tylko jedno z nich muszą być wygaszone) jest niemożliwe bez wyróżnienia jednego z kierunków.

Dla algorytmów ścieniania ważna jest definicja *"Szkieletu"*.

Definicja szkieletu:

Szkieletem zbioru R elementów obrazu jest zbiór wyznaczony w następujący sposób [1]. Na początku w zbiorze R należy określić szkieletowe i konturowe elementy obrazu. Następnie usuwa się wszystkie konturowe elementy obrazu, które nie są szkieletowymi, po czym otrzymanym w ten sposób zbiorem zastępuje się zbiór R . Proces ten jest powtarzany aż do uzyskania zbioru zawierającego jedynie szkieletowe elementy obrazu.

Istnieje wiele algorytmów ścieniania. Problem ten nie został do końca rozwiązany, dlatego też opracowuje się wiele nowych rozwiązań lub modyfikacji poprzednich przystosowanych do konkretnych zastosowań. Dzieje się tak, dlatego

że ścienianie odgrywa wielką rolę w przetwarzaniu i rozpoznawaniu obrazów. Ścienianie redukuje wielkość pamięci potrzebną do zapamiętania istoty kształtu obiektów. Jak dotąd w literaturze nie ma zgody, co do określenia, czym właściwie jest ścienianie. Wiele definicji i kryteriów może prowadzić do różnych algorytmów. Algorytmy te, stosowane do tych samych obrazów powodują różne skutki.


Wyznaczanie krawędzi

Wyznaczanie krawędzi jest transformacją obrazu polegającą na usunięciu wszystkich elementów obrazu nie należących do brzegów obiektów znajdujących się na nim [86]. Operacja taka pozwala na uzyskanie obrazu zawierającego krzywe, których analiza pozwoli na określenie rodzaju krawędzi, jakie posiadał dany obiekt [69]. Po określeniu kształtu linii brzegowych można np. wnioskować o klasie rozpoznawanego obiektu. Funkcjonalnie wyznaczanie krawędzi pełni podobną rolę do ścieniania. Obie te transformacje służą do usunięcia zbędnych w dalszej obróbce lub analizie elementów obrazu.

Definicja brzegu na płaszczyźnie analogowej

Brzeg zbioru płaskiego na płaszczyźnie analogowej jest to zbiór wszystkich punktów mających tę własność, że niezależnie od tego, jak małe ich sąsiedztwo rozważamy, zawiera on zarówno punkty znajdujące się wewnątrz, jak i na zewnątrz zbioru.

W przypadku płaszczyzny dyskretnej definicja musi zostać zmodyfikowana ze względu na to, że nie istnieje nieskończone małe sąsiedztwo danego punktu. Najbliższe sąsiedztwo, o jakim można mówić są to punkty bezpośrednio przylegające do danego punktu. Rysunek 23. przedstawia graficzną reprezentację najbliższego sąsiedztwa punktu na płaszczyźnie dyskretnej.




Rysunek 23. Najbliższe sąsiedztwo punktu.


Biorąc ten fakt pod uwagę można dostosować podaną definicję do własności płaszczyzny dyskretnej.

Definicja konturu na płaszczyźnie dyskretnej

Kontur spójnego zbioru elementów obrazu jest to zbiór wszystkich elementów obrazu w tym zbiorze, mających przynajmniej jednego sąsiada nie należącego do tego zbioru. W zależności od definicji pojęcia sąsiada, kontur danej figury może przyjąć kształt jak na rysunkach 24-25.




Rysunek 24. Kontur obiektu na płaszczyźnie czterokierunkowej.




Rysunek 25. Kontur obiektu na płaszczyźnie ośmiokierunkowej.

Rysunek 24. pokazuje przypadek, gdy jako bezpośrednie sąsiedztwo danego punktu zostały uznane wszystkie punkty stykające się z nim (również w narożnikach). Konsekwencje takiej definicji widać patrząc na prawą część rysunku. Najpoważniejszym następstwem jest fakt, że kontur nie jest linią cienką. Sytuacja ta staje się zupełnie oczywista, gdy rozważymy problem interpretacji płaszczyzny pod kątem ilości rozróżnianych kierunków. Na przykładzie definicji konturów przedstawiono różnice i błędy wynikające z ewentualnego braku konsekwencji w interpretacji obrazu oraz skutki popełnienia takich niejednoznaczności. Rysunek 26. przedstawia fragment linii prostej (cienkiej) narysowanej na płaszczyźnie ośmiokierunkowej. Rysunek 27. odnosi się natomiast do prostej na płaszczyźnie czterokierunkowej.



Rysunek 26. Linia prosta na płaszczyźnie ośmiokierunkowej.




Rysunek 27. Linia prosta na płaszczyźnie czterokierunkowej.

Jak widać, linia interpretowana jako czterokierunkowa staje się zbiorem nie związanych ze sobą punktów lub linii przebiegających poziomo lub pionowo. Jeżeli linię z rysunku przedstawionego wyżej potraktujemy z kolei jako ośmiokierunkową, to staje się ona linią grubą o grubości dwóch punktów. Kierunkowość płaszczyzny dyskretnej możemy określić jako ilość możliwych do wybrania kierunków przy "przechodzeniu" z jednego punktu na drugi. Oprócz płaszczyzny z czterema i ośmioma kierunkami w literaturze omawia się również płaszczyznę heksagonalną. Ma ona tę zaletę, że wszystkie komórki sąsiadujące z daną komórką stykają się z nią w taki sam sposób i odległości między ich środkami są takie same. Siatka kwadratowa nie posiada tych zalet, ale wszystkie urządzenia rastrowe działają na tej zasadzie. Siatka heksagonalna jest rzadko stosowana przy rozwiązywaniu praktycznych problemów.


Przykłady wyznaczonych parametrów obrazów dla rzeczywistych obiektów badawczych

Powyższe rozważania zostały praktycznie wdrożone podczas opracowywania algorytmów przetwarzania obrazów przepływów dwufazowych oraz w obszarze mechanoskopii. Z uwagi na specyfikę związaną z przepływami wielofazowymi postanowiono już w tym miejscu poruszyć pewne problemy. Jednym z przykładów może być analiza obrazów zmian struktury pierścieniowo-dyspersyjnej w przekroju poprzecznym, zarejestrowanych przy pomocy kamery z szybkością 1000 fps. Rysunek 28. przedstawia serię obrazów przepływu mieszaniny gaz-ciecz w kanale pionowym.



Rysunek 28. Obraz zmian struktury pierścieniowo-dyspersyjnej w przekroju poprzecznym [29].

Analizy dokonano przy zastosowaniu opracowanego w tym celu programu pozwalającego na wyliczenie podstawowych parametrów badanych obrazów. Wyznaczano dwa podstawowe parametry: udział objętościowy oraz powierzchnię międzyfazową. Przepływ mieszaniny gaz-ciecz odbywał się w kanale pionowym. Udział objętościowy jest, z punktu widzenia analizy obrazu, stosunkiem pikseli czarnych do białych. Ze względu na przyjęcie założenia, że struktura w całym kanale jest niezmienna, przyjęto określenie tego parametru jako udział objętościowy, a nie udział powierzchniowy jak wynikałoby z przedstawionych rysunków. Analogicznie zostało zinterpretowane pojęcie powierzchni międzyfazowej.



Rysunek 29. Przetwarzanie obrazu i detekcja granicy faz.

Tabela 3. zawiera wartości udziału objętościowego fazy ciekłej oraz względnej powierzchni międzyfazowej dla 9 kolejnych obrazów. Liczby napisane małą czcionką odnoszą się do ilości zliczonych punktów.

Tabela 3.

Udział objętościowy fazy ciekłej oraz względna powierzchnia międzyfazowa.

Nr	Udział objętościowy fazy ciekłej (cecha 1)	Obwód kontaktu / Obwodu rury (cecha 2)
1	21.09 % 13550	3.512 6323
2	21.36 % 13725	3.674 6615
3	24.26 % 15587	4.353 7837
4	31.02 % 19928	4.939 8892
5	32.13 % 20638	4.834 8704
6	33.24 % 21355	3.687 6638
7	25.73 % 16527	4.016 7230
8	25.32 % 16265	4.131 7438
9	29.85 % 19176	4.152 7476
śr.	27.11 % 17417	4.152 7461

Tabela 4. obrazuje charakter zmian wartości zamieszczonych dla poszczególnych scen, rejestrowanych w odstępie, co 1 ms [49]. Na podstawie tego


wykresu można wnioskować, że częstotliwość zmian opisywanych cech dla analizowanego procesu jest rzędu $100 \div 200$ Hz. Inną ważną własnością jest zakres zmian obu cech.

Tabela 4.

Wartości ekstremalne zmian cech.

Nr cechy	Wartość minimalna	Wartość maksymalna	Amplituda zmian	
1	21.09	33.24	12.15	36.6 %
2	3.512	4.939	1.427	28.9 %

Innym przykładem przetwarzania obrazów realizowanego za pomocą algorytmów opartych na przedstawionych w tym rozdziale zasad i definicji jest wyznaczanie krawędzi dla przepływów dwufazowych w przestrzeni międzyrurowej. Z punktu widzenia zachodzących procesów jest to niezwykle istotne zjawisko dot. np. zagadnienia wymiany ciepła. Praca wymienników ciepła zbudowanych na tej zasadzie jest oparta na wielu parametrach, o których decyduje struktura przepływu mieszaniny gaz-ciecz. Struktura przepływu definiowana jako przestrzenny rozkład faz musi zostać rozszerzona o element czasu. Rysunek 30. przedstawia przykładowe struktury przepływu w rurze pionowej. Parametry takie jak udział objętościowy i powierzchnia międzyfazowa mieszanin wielofazowych mają wpływ na zjawisko transportu ciepła i masy. A zatem śledzenie ich dostarcza informacji o poprawności pracy urządzeń jak np. generatorów pary w blokach kotłów energetycznych czy układach chłodzenia reaktorów jądrowych.




Rysunek 30. Struktury przepływu gaz-ciecz w rurze pionowej: cienki film, zafalowany film, struktura dyspersyjna.


Wyniki prowadzonych badań jednoznacznie świadczą o fakcie niemożności skutecznego rozróżnienia struktury na podstawie pojedynczego obrazu. Odwołując się do głównej tezy pracy należy podkreślić, że **mówiąc o strukturze przepływu należy mieć na uwadze specyficzny dla danej struktury sposób zmiany rozkładu przestrzennego faz odbywający się w dziedzinie czasu.**

Wniosek ten powstał w wyniku badań i analizy szeregu różnych przepływów. Dowód na poparcie tej tezy stanowi niniejsze opracowanie, w którym opisane zostały metody, algorytmy realizujące takie podejście do problemu. Jedną z metod analizy struktur przepływu dwufazowego było badanie zmienności powierzchni międzyfazowej. W tym celu należało wyznaczyć krawędzie na obrazach tych struktur.

Rysunki 31-32 przedstawiają przykładowe obrazy, które powstały w wyniku wykorzystania algorytmów bazujących na zasadach i regułach dot. płaszczyzny dyskretnej.




Rysunek 31. Obraz struktury pęcherzykowej (oryginalny).




Rysunek 32. Obraz struktury pęcherzykowej (po wyznaczeniu krawędzi).

Obiekty znajdujące się na rysunkach zostały sprowadzone do obrysów, ale ze względu na pewne własności, linie brzegowe często nie są liniami zamkniętymi. Wynika to z faktu, że pęcherzyki gazu stykają się, nakładają, przenikają oraz tworzą dodatkowe efekty optyczne związane np. z załamaniem czy odbiciem światła. Zakłócenia powstałe w wyniku tych zjawisk powodują, że uzyskany obraz nie zawsze stanowi wierne odzwierciedlenie rzeczywistości.


Pociąga to za sobą konieczność opracowania bardziej wyrafinowanych metod zastosowanych na etapie eksperymentu jak i analizy oraz rozpoznawania obrazów.




Rysunek 33. Przykład przepływu pulsacyjnego w przestrzeni międzyrurowej (obraz oryginalny).



Rysunek 34. Przykład przepływu pulsacyjnego w przestrzeni międzyrurowej (obraz po wyznaczeniu krawędzi).




Rysunek 35. Struktura pęcherzykowa (faza 1).




Rysunek 36. Struktura pęcherzykowa (faza 2).


Rysunki 37-39 przedstawiają trzy kolejne klatki filmu, na których zarejestrowano przepływ dwufazowy. Obrazy te zostały poddane wstępnej obróbce, która pozwoliła na wyostrenie krawędzi i podniesienie kontrastu. Pomimo tych operacji jest dość trudno wyselekcjonowanie pojedynczych obiektów.



Rysunek 37. Przepływ dwufazowy (faza 1).



Rysunek 38. Przepływ dwufazowy (faza 2).



Rysunek 39. Przepływ dwufazowy (faza 3).

6.2.2. Problemy rozpoznawania struktur przepływu dwufazowego

Rozpoznawanie struktur przepływu jest bardzo istotnym zagadnieniem z punktu widzenia inżynierii procesowej. Rodzaj struktury jest podstawowym

parametrem wpływającym na intensywność transportu ciepła i masy, a zatem pozwalającym obliczać strumienie ciepła i masy.

W praktyce klasyfikacja odbywa się bardzo często na drodze czysto subiektywnej oceny wizualnej. Wynik rozpoznania dokonanego przez eksperta ma charakter jakościowy. Subiektywna ocena eksperta pociąga za sobą możliwość otrzymania różnych opinii wydanych przez różnych ekspertów. Dużo ważniejszym problemem jest niemożliwość porównywania, tak sklasyfikowanych, struktur. Bardzo wiele różnych procesów może zostać zakwalifikowana to tej samej klasy, mimo iż różnice między nimi bywają duże. Dzieje się tak, gdyż selektywność oceny eksperta jest bardzo ograniczona. Podając wynik rozpoznania powinien on uzupełnić go o pewne dodatkowe informacje będące zauważonymi cechami. Taki opis stałby się bardziej szczegółowy i dokładny, ale jeszcze bardziej subiektywny. W dalszym ciągu nie można go porównywać z ocenami innych ekspertów, ze względu na całkowicie jakościowy charakter opisu.

Dodatkową i bardzo poważną trudnością, jaką napotyka się podczas próby rozpoznawania struktury przepływu jest prędkość obserwowanego zjawiska. Oko ludzkie ma ograniczone możliwości percepcji w zakresie, zarówno ilości obrazów na sekundę jak i zakresu długości fali odbieranej. Ponadto oko jest czujnikiem nie liniowo przetwarzającym poziom natężenia światła. Sygnał powstały w oku jest przesyłany do mózgu, który automatycznie tzn. bez udziału procesów myślowych dokonuje pewnych operacji. Polegają one m.in. na uśrednianiu w dziedzinie czasu, interpolacji, ekstrapolacji, korekcji barw oraz poziomów jaskrawości. Są to niezwykle skomplikowane operacje zależne od wielu parametrów sygnału oraz innych niezależnych od niego wielkości. W efekcie ekspert rozpoznaje na podstawie danych wysoce przetworzonych, co jeszcze pogłębia subiektywność oceny. Trzeba też mieć świadomość, że rozpoznanie może nastąpić poprawnie tylko wtedy, gdy całe zjawisko odbywa się w zakresie widzialnym oraz jego szybkość nie przekracza możliwości percepcji oka.

Metody wizyjne posiadają pewne cechy charakterystyczne:

- Elementy obrazu są rozróżniane wg intensywności promieniowania odbitego (metody aktywne) lub emitowanego (metody pasywne).
- Rodzaj promieniowania jest zależny od użytych czujników. Z fizykalnego punktu widzenia najczęściej, choć nie tylko, jest używane promieniowanie elektromagnetyczne (w różnych zakresach częstotliwości), jak również ultradźwięki i promienie X.
- Metody wizyjne są nieinwazyjne. Jeżeli promieniowanie, którego użyto do oświetlenia obiektu nie ma wpływu na przebieg procesu, to nie wystąpi problem zakłócania wartości mierzonej.
- Obrazowi o rozdzielczości np. 400 x 400 pikseli i 256 odcieniach szarości odpowiada 1.28 Mbitów informacji. W przypadku chęci zastosowania klasycznych czujników i osiągnięcia podobnych warunków pomiarowych, istniałaby konieczność użycia aż 160 tysięcy takich urządzeń na powierzchni, którą badamy.
- Istnieje konieczność stosowania specjalizowanych stacji graficznych, które są w stanie umożliwić transmisję i konwersję analogowego sygnału wizyjnego na postać cyfrową oraz przetworzyć i zinterpretować otrzymany obraz. Dla sekwencji o przykładowych parametrach: rozdzielczość - 768 x 576 punktów (PAL), głębokość kolorów - 24 bity, prędkość akwizycji obrazów: 25 fps, konieczne jest zastosowanie kanału informacyjnego o przepustowości ponad 265 Mbodów (31.64 MB/s).
- Źródłem informacji jest nie tylko kolor (lub poziom jasności) każdego z punktów, ale i ich wzajemne położenie, oraz zmiany w/w elementów w czasie.
- Obrazy można rejestrować przy użyciu kamery wideo. Ten sposób zapewnia możliwość przechowywania dużej ilości danych przy stosunkowo niskich kosztach nośnika oraz oprzyrządowania

Rozwój elektroniki umożliwił realizację urządzeń pozwalających na rejestrację, zapis oraz zamianę na postać cyfrową obrazu wizyjnego. Z punktu widzenia przetwarzania danych mamy do czynienia z dużą ilością informacji, którą należy poddać przetwarzaniu w celu:

- filtracji zakłóceń,
- filtracji elementów nie istotnych dla danego zagadnienia,
- interpretacji obrazów.

6.2.3. Opis formalny

Zgodnie przeprowadzonymi badaniami informacja o strukturze przepływu znajduje się nie tyle na samych klatkach zarejestrowanych w sekwencjach wideo, co w sposobie zmiany wybranych cech wyznaczonych na ich podstawie. **Odwołując się do głównej tezy pracy należy podkreślić, że w celu dokonania rozpoznania przeprowadza się analizę charakteru zmian cech nie zajmując się pojedynczymi scenami.** Wynika to z wypracowanej definicji struktury przepływu, której sedno odnosi się do stwierdzenia, że pojęcie struktury odnosi się nie tylko do rozkładu faz w przestrzeni, ale przede wszystkim do dynamiki, a więc zmiany pewnych parametrów w czasie. Jeżeli próbuje się określić strukturę przepływu na podstawie pojedynczej klatki, to tak jakby na giełdzie papierów wartościowych próbowało się wnioskować o bessie lub hossie na podstawie notowania z jednego dnia.

W zakresie zapisu formalnego można przyjąć notację i interpretację klasyczną tzn. danej strukturze przypisywany jest wektor cech składający się z liczb opisujących zmiany poszczególnych cech

$$\omega = [\overbrace{\omega_1^{(1)}, \omega_2^{(1)}, \omega_3^{(1)}, \dots, \omega_{n_1}^{(1)}}^{\text{pierwsza cecha}}, \overbrace{\omega_1^{(2)}, \omega_2^{(2)}, \omega_3^{(2)}, \dots, \omega_{n_2}^{(2)}}^{\text{druga cecha}}, \overbrace{\omega_1^{(3)}, \omega_2^{(3)}, \omega_3^{(3)}, \dots, \omega_{n_3}^{(3)}, \dots}^{\text{trzecia cecha}}]^T \quad (42)$$

Powyższa postać zapisu jest rozbudowana i w toku dalszych rozważań jej przekształcanie wiąże się z pewnym całkowicie niepotrzebnym rozwinięciem wyrażeń opisujących metodę. W związku z tym zrezygnowano z niego na rzecz notacji, w której każdy element wektora cech jest ciągiem opisującym zmiany danej cechy w czasie⁶. Dla samej metody taki sposób zapisu nie wnosi nic nowego i nie powoduje żadnych zmian jakościowych w zakresie rozpoznawania obiektów. Jest to jedynie zabieg formalny służący poprawieniu czytelności formalnego opisu metody nie zawierający żadnego elementu nowości w podejściu do zagadnień rozpoznawania obiektów. Elementem nowości jest natomiast sposób rozpoznawania obiektów polegający na bezpośrednim określaniu odległości między

⁶ W ogólnym przypadku ciąg dla danej cechy może opisywać jej zmiany w dowolnej dziedzinie i niekoniecznie jest to dziedzina czasu.

ciągami liczb reprezentującymi charakterystykę zmian cech w określonej dziedzinie. Zastosowana poniżej notacja jest zgodna z tą ideą i ma służyć jedynie poprawieniu czytelności zapisu formalnego.

Stosując notację zgodną z klasyczną obiekty są reprezentowane poprzez wektor postaci:

$$\omega = [\omega^{(1)}, \omega^{(2)}, \dots, \omega^{(d)}]^T, \quad (43)$$

gdzie:

$\omega^{(i)}$ dla $i \in 1, 2, \dots, d$ - cechy opisujące obiekt,

d – wymiar przestrzeni cech.

Ze względu na fakt, iż w prowadzonych badaniach cechy stanowią ciągi liczbowe, $\omega^{(i)}$ oznaczać będzie ciąg reprezentujący sposób zmiany i -tej cechy. Z przyczyn opisanych powyżej zachowana zostanie notacja podstawowa $\omega = [\omega^{(1)}, \omega^{(2)}, \dots, \omega^{(d)}]^T$, z tą różnicą, iż $\omega^{(i)}$ nie oznacza liczby, lecz ciąg liczb.

Jeżeli wektorem cech jest $\omega = [\omega^{(1)}, \omega^{(2)}, \dots, \omega^{(d)}]^T$ to elementy tego wektora przyjmują następującą postać:

$$\omega^{(1)} = \{\omega_1^{(1)}, \omega_2^{(1)}, \dots, \omega_m^{(1)}\}, \quad (44)$$

$$\omega^{(2)} = \{\omega_1^{(2)}, \omega_2^{(2)}, \dots, \omega_m^{(2)}\}, \quad (45)$$

.....,

$$\omega^{(d)} = \{\omega_1^{(d)}, \omega_2^{(d)}, \dots, \omega_m^{(d)}\}, \quad (46)$$

gdzie:

m – długość ciągów $\omega^{(i)}$ dla $i \in 1, 2, \dots, d$,

d – wymiar przestrzeni cech.

Biorąc pod uwagę taką reprezentację rozpoznawanych obiektów możliwe jest sformułowanie dwóch zadań:

1. Wyznaczenie obiektu, dla którego odległość od obiektu rozpoznawanego jest najmniejsza dla danego przesunięcia.
2. Określenie przesunięcia, dla którego odległość między obiektami jest minimalna.

Wyznaczenie obiektu, dla którego odległość od obiektu rozpoznawanego jest najmniejsza dla danego przesunięcia oznacza przyjęcie wartości przesunięcia i poszukiwanie zgodnie z założoną miarą odległości obiektu najbardziej podobnego. Określenie przesunięcia, dla którego odległość między obiektami jest minimalna dotyczy porównywania dwóch obiektów i poszukiwania takiego przesunięcia, dla którego obiekty te są najbliższe sobie.

Odległość oznacza stopień podobieństwa, natomiast pojęcie „przesunięcia” pojawia się ze względu na dodanie drugiego wymiaru do macierzy reprezentującej obiekty. Klasyczna miara odległości dwóch obiektów a i b w przestrzeni euklidesowej d -wymiarowej wyraża się poniższym wzorem:

$$f(a,b) = \|a - b\| = \sqrt{\sum_{k=1}^d |a^{(k)} - b^{(k)}|^2}, \quad (47)$$

gdzie:

$a^{(k)}$ – wartość k -tej cechy obiektu nr 1,

$b^{(k)}$ – wartość k -tej cechy obiektu nr 2.

W przypadku, gdy cechy są liczbami obliczenie wartości wyrażenia: $a^{(k)} - b^{(k)}$ nie stanowi problemu. W opisywanej metodzie traktuje się jednak $a^{(k)}$ oraz $b^{(k)}$ jako ciągi liczbowe

$$a^{(k)} = \{a_1^{(k)}, a_2^{(k)}, a_3^{(k)}, \dots, a_m^{(k)}\}, \quad (48)$$

$$b^{(k)} = \{b_1^{(k)}, b_2^{(k)}, b_3^{(k)}, \dots, b_m^{(k)}\}, \quad (49)$$

gdzie:

m – oznacza długość ciągów $a^{(k)}$ i $b^{(k)}$.

Powstaje podstawowe pytanie jak wyznaczyć odległość między tymi ciągami i jak interpretować poniższy zapis

$$f(a^{(k)}, b^{(k)}) = \{a_1^{(k)}, a_2^{(k)}, a_3^{(k)}, \dots, a_m^{(k)}\} - \{b_1^{(k)}, b_2^{(k)}, b_3^{(k)}, \dots, b_m^{(k)}\}. \quad (50)$$

Można, np. przyjąć, iż

$$f(a^{(k)}, b^{(k)}) = \frac{1}{m} \sum_{i=1}^m |a_i^{(k)} - b_i^{(k)}|. \quad (51)$$

Zastosowanie tej miary jest jednak bardzo ograniczone. Dzieje się tak, ponieważ następuje porównanie odpowiadających sobie elementów ciągów liczbowych. Innymi słowy obliczana jest różnica pomiędzy elementami o tych samych indeksach. Jeżeli założymy dwa prawie identyczne ciągi liczbowe różniące się tylko nieznacznym przesunięciem indeksów względem siebie to wynik ich porównania wskazywałby na znaczące różnice między nimi

$$a^{(k)} = \{1, 8, 6, 7, 5, 3, 2, 5, 8, 9, 3, 2, 5\}, \quad (52)$$

$$b^{(k)} = \{6, 1, 8, 6, 7, 5, 3, 2, 5, 8, 9, 3, 2\}. \quad (53)$$

Jeżeli nastąpi przesunięcie ciągu $b^{(k)}$ o jedną pozycję w lewo, to wynik porównania będzie zgodny z oczekiwaniami. Oznacza to konieczność wprowadzania dodatkowego parametru oznaczającego przesunięcie, dla którego następuje obliczenie odległości. Jest to działanie analogiczne jak w przypadku obliczania funkcji korelacji wzajemnej.

Wzajemne przesuwanie porównywanych ciągów generuje dodatkowy efekt. Wraz ze wzrostem przesunięcia maleje ilość elementów ciągów podlegających porównywaniu, oznacza to, iż coraz mniej elementów ma wpływ na wynik

końcowy. Istnieje konieczność brania tego faktu pod uwagę podczas interpretacji wyników

$$f(a^{(k)}, b^{(k)}, p) = \|a^{(k)} - b^{(k)}\|, \quad (54)$$

gdzie:

p – oznacza przesunięcie.

Ogólnie można zapisać, iż

$$r = m - p, \quad (55)$$


gdzie:

m – długość ciągów,

p – przesunięcie wzajemne ciągów,

r – ilość elementów ciągu biorących udział w obliczeniach.

W efekcie wynikiem obliczenia podobieństwa ciągów jest para liczb oznaczająca odległość oraz ilość elementów biorących udział w obliczeniach.



Rysunek 40. Mapa zagadnień klasyfikacji dla dwóch parametrów: odległości oraz ilości elementów biorących udział w obliczeniach.


Rysunek 40. przedstawia mapę zagadnień klasyfikacji, która stanowi pewną podstawę do dyskusji na temat interpretacji wyników porównań. Ważne jest określenie stopnia istotności maksymalizacji długości porównywanych ciągów przy jednoczesnym zachowaniu dużego podobieństwa między nimi. Można tego dokonać jedynie na podstawie analizy konkretnego zastosowania metody. Należy sobie zdawać sprawę, iż dosyć naturalne dążenie do tego, aby ciągi były możliwie duże, a odległość między nimi możliwie mała **(1)**, nie zawsze posiada wystarczające uzasadnienie praktyczne dla danego zastosowania. Obszar oznaczony jako **(2)** reprezentuje sytuację gdy brane są pod uwagę stosunkowo duże fragmenty ciągów liczbowych, lecz ich podobieństwo jest niewielkie. Może to wynikać z faktu, iż badane ciągi są podobne do siebie tylko lokalnie i obszary różniące je wpływają znacząco na odległości między nimi. Obszar **(3)** obrazuje stan, w którym krótkie fragmenty ciągów są mało podobne do siebie. W tym przypadku wynik rozpoznania jest negatywny. W obszarze **(4)** znajdują się przypadki, gdzie krótkie podciągi liczbowe są podobne do siebie. Jeżeli dla dłuższych fragmentów podobieństwo wyraźnie spada, to można założyć, że ciągi są podobne, ale nastąpiły znaczące zakłócenia pomiarowe.

Zbliżając się w tych rozważaniach do zagadnień aplikacyjnych coraz bardziej nieużyteczne zaczynają się okazywać proste metody i miary określania podobieństwa. Wynika to z faktu, iż „podobieństwo” w sensie oceny dokonywanej przez człowieka jest pojęciem nieostrym. Dlatego też opracowując metody rozpoznawania obiektów należy pójść dalej, starając się zbliżyć się do istoty mechanizmu klasyfikacji dokonywanej przez człowieka. Metoda ta jest skuteczna dla pewnej klasy zagadnień praktycznych, lecz leży bardzo blisko ścisłego, matematycznego spojrzenia na rzeczywistość, dlatego też, przy nieco bardziej wymagających przypadkach okazuje się nieskuteczna. Mechanizmy porównywania, których używa człowiek były inspiracją i wzorcem dalszych prac nad omawianymi zagadnieniami.

Podczas omawiania zagadnienia selekcji cech zwrócono uwagę na sposób ich doboru, który powinien być zgodny z zasadą, iż należy wybierać i definiować cechy w taki sposób, aby oddawały one charakter rozpoznawanych obiektów. Podobnie należy postępować podczas określania miar podobieństwa cech. Stosowanie znanych i powszechnie stosowanych miar i metod jest wygodne ze względu na dopracowany aparat matematyczny oraz możliwość powoływania się na szereg własności, których nie trzeba ani odkrywać, ani opisywać. Operowanie na kombinacji znanych zależności matematycznych może doprowadzić do powstania nowej wartości w postaci metody lub algorytmu oraz do uzyskania nowych własności użytecznych przy danym zagadnieniu. W obszarze badań metod algorytmicznych takie podejście jest ponadto bardzo naturalne i uzasadnione.

W niniejszej pracy nadal jednak będzie dominowało podejście mające na celu oderwanie się od tego typu sposobu działania, mimo utrzymania się w nurcie algorytmicznym. Nie oznacza to próby dewaluacji istniejących miar metod i algorytmów, ani chęci całkowitej rezygnacji z nich, lecz próbę innego spojrzenia na zagadnienia rozpoznawania obiektów. Przechodząc do opisu formalnego proponowanych miar, algorytmów i metod łatwo można pozostawić w tle wyrażen matematycznych istotę przewijającego się przez całe opracowanie podejścia. Dlatego też właśnie w tym miejscu należy podać dyskusji pewne tematy, które na kolejnych stronach zostaną ujęte w zapis matematyczny.

Zajmując się zagadnieniem określenia miary podobieństwa obiektów opisanych cechami zmiennymi w jakiejś dziedzinie istotne jest zastanowienie się, co skłania człowieka do określenia, że jedne ciągi liczbowe są bardziej podobne do drugich, a inne mniej. Ze względu na sposób percepcji człowieka przykładem będą funkcje przedstawione na wykresie dwuwymiarowym. Rysunek 41. przedstawia wykres trzech przebiegów zmienności dowolnego parametru. Wszystkie przebiegi są różne jednak prawie natychmiast można zauważyć pewne podobieństwa między nimi.



Rysunek 41. Przykładowy przebieg zmienności pewnej cechy dla trzech różnych obiektów.

Po pierwszej analizie powyższego rysunku można zdecydowanie stwierdzić, iż przebieg czerwony wykazuje duże podobieństwo do niebieskiego. Nie są one identyczne, ale mimo to bez wykonywania obliczeń można postawić taką diagnozę.

Porównanie jest jednak dużo łatwiejsze niż wyartykułowanie metody, jaka posłużyła do podania takiej diagnozy. Najbardziej złożone jest jednak uogólnienie tej metody oraz opisanie jej w postaci formalnie zapisanego algorytmu.

Prowadzone badania doprowadziły do następujących wniosków:

- „podobny” oznacza: zawiera dostateczną ilość **elementów podobnych**. Zdanie to posiada wyraźnie rekurencyjny charakter, co stanowi pewną trudność w zdefiniowaniu badanego pojęcia,
- rozpoznawany obiekt jest analizowany, czyli **dzielony** na mniejsze elementy, które podlegają klasyfikacji,
- analiza opiera się na wyznaczeniu **punktów charakterystycznych**,
- takie parametry poszczególnych elementów wykresu jak **przesunięcie** wzdłuż osi x lub y nie mają znaczącego wpływu na ocenę stopnia podobieństwa.

Przeprowadzone rozważania dotyczą wielowymiarowej przestrzeni cech, jednak dla uproszczenia zapisu oraz ułatwienia analizy samej metody, w dalszej części zapis formalny oraz jego opis będzie dotyczył jednego wymiaru przestrzeni.

Na podstawie powyższych wniosków kontynuacja prac doprowadziła do opracowania metody polegającej na podziale ciągów liczbowych reprezentujących przebieg zmienności cech na elementy składowe.

Dane wejściowe stanowią dwa ciągi liczb

$$\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_m\} \quad (56)$$

$$\beta = \{\beta_1, \beta_2, \dots, \beta_n\} \quad (57)$$

gdzie:

α, β – oznaczają wejściowe ciągi liczbowe,

m, n – długości ciągów α oraz β .

Sposób wyznaczenia ciągów wejściowych zależy od obszaru zastosowania i został omówiony w rozdziałach poświęconych praktycznej realizacji metody.

Ciągi α, β są dzielone na podciągi. Podstawą podziału są punkty charakterystyczne przebiegu, jakimi są ekstrema lokalne. Wykonywanie jest następujące przekształcenie:

$$\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_m\} \rightarrow \xi = \{\xi_1, \xi_2, \dots, \xi_{m-1}\}, \quad (58)$$

$$\beta = \{\beta_1, \beta_2, \dots, \beta_n\} \rightarrow \zeta = \{\zeta_1, \zeta_2, \dots, \zeta_{n-1}\}. \quad (59)$$

Analogicznie do metody badania zmienności funkcji w zakresie badania znaku pierwszej pochodnej, dla ciągów liczbowych zastosowano:

$$i = 1 \dots m - 1;$$

$$\xi_i = \text{sign}(\alpha_i - \alpha_{i+1}), \quad (60)$$

$$j = 1 \dots n - 1;$$

$$\zeta_j = \text{sign}(\beta_j - \beta_{j+1}). \quad (61)$$

gdzie:

i, j – indeksy iteracji,

α_i – element ciągu wejściowego α o indeksie i ,

β_j – element ciągu wejściowego β o indeksie j ,

ξ, ζ – ciąg znaków różnic między kolejnymi elementami ciągów α, β .

Ciągi liczbowe ξ oraz ζ zostają następnie przekształcone odpowiednio w wektory χ oraz δ zawierające ciągi par liczb interpretowanych jako współrzędne punktów charakterystycznych (ekstremów lokalnych)

$$\xi = \{\xi_1, \xi_2, \dots, \xi_{m-1}\} \rightarrow \chi = \{\chi_1, \chi_2, \dots, \chi_{m_\chi}\} , \quad (62)$$

$$\zeta = \{\zeta_1, \zeta_2, \dots, \zeta_{n-1}\} \rightarrow \delta = \{\delta_1, \delta_2, \dots, \delta_{n_\delta}\} . \quad (63)$$

gdzie:

m_χ – długość ciągu χ ,

n_δ – długość ciągu δ .

Podciągi χ oraz δ zawierają pary liczb:

$$\chi_i = \{x_i^{(\chi)}, y_i^{(\chi)}\} , \quad (64)$$

$$\delta_j = \{x_j^{(\delta)}, y_j^{(\delta)}\} , \quad (65)$$

gdzie:

χ_i – element ciągu χ o indeksie i ,

δ_j – element ciągu δ o indeksie j ,

$x_i^{(\chi)}$ – położenie (numer indeksu) ekstremum dla ciągu χ_i ,

$y_i^{(\chi)}$ – wartość ekstremum dla ciągu χ_i ,

$x_j^{(\delta)}$ – położenie (numer indeksu) ekstremum dla ciągu δ_j ,

$y_j^{(\delta)}$ – wartość ekstremum dla ciągu δ_j .

Wartości ciągów χ_k oraz δ_k wyznaczane są w następujący sposób:

jeżeli $\xi_i \neq \xi_{i+1}$ to $x_k^{(\chi)} = i$, $y_k^{(\chi)} = \alpha_i$, $\chi_k = \{x_k^{(\chi)}, y_k^{(\chi)}\} \in \chi$,

jeżeli $\zeta_j \neq \zeta_{j+1}$ to $x_k^{(\delta)} = j$, $y_k^{(\delta)} = \beta_j$, $\delta_k = \{x_k^{(\delta)}, y_k^{(\delta)}\} \in \delta$,

gdzie:

k - indeks iteracji,

$\chi_k = \{x_k^{(\chi)}, y_k^{(\chi)}\}$ - para liczb określająca parametry ekstremum dla χ_k ,

$\delta_k = \{x_k^{(\delta)}, y_k^{(\delta)}\}$ - para liczb określająca parametry ekstremum dla δ_k .

Ciągi ekstremów lokalnych χ oraz δ zostają następnie przekształcone w ciągi impulsów κ oraz λ .


$$\chi = \{\chi_1, \chi_2, \dots, \chi_{m_\chi}\} \rightarrow \kappa = \{\kappa_1, \kappa_2, \dots, \kappa_{m_\kappa}\}, \quad (66)$$

$$\delta = \{\delta_1, \delta_2, \dots, \delta_{n_\delta}\} \rightarrow \lambda = \{\lambda_1, \lambda_2, \dots, \lambda_{n_\lambda}\}. \quad (67)$$

gdzie:

m_κ , n_λ – odpowiednio długości ciągów: κ , λ .

Elementami tych ciągów są wektory cech impulsów. Rysunek 42. przedstawia interpretację graficzną cech impulsów.



Rysunek 42. Interpretacja graficzna pojęcia *impuls*.

Każdy z impulsów zaczyna się od minimum lokalnego, osiąga swoje maksimum i kończy się na następnym minimum lokalnym przebiegu. Impulsy opisywane są za pomocą trzech punktów: $a(x_1, y_1)$, $b(x_2, y_2)$, $c(x_3, y_3)$.

Wyznaczono następujące podstawowe parametry impulsu:

$$A = y_2 - y_1 - \text{amplituda wzrostu}, \quad (68)$$

$$B = y_2 - y_3 - \text{amplituda opadania}, \quad (69)$$

$$w = x_2 - x_1 - \text{czas wzrostu impulsu}, \quad (70)$$

$$v = x_3 - x_2 - \text{czas opadania impulsu}. \quad (71)$$

W impulsie wyróżnione zostają następujące cechy:

x – położenie impulsu w ciągu wejściowym,

A – amplituda wznoszenia,

B – amplituda opadania,

w – odległość od początku impulsu do jego maksimum,

v – odległość od maksimum do końca impulsu.

Impulsy są reprezentowane przez następujące wektory cech:

$$\kappa_i = [x_i^{(\kappa)}, w_i^{(\kappa)}, v_i^{(\kappa)}, A_i^{(\kappa)}, B_i^{(\kappa)}]^T \quad (72)$$

$$\lambda_j = [x_j^{(\lambda)}, w_j^{(\lambda)}, v_j^{(\lambda)}, A_j^{(\lambda)}, B_j^{(\lambda)}]^T \quad (73)$$

Wartości cech wektorów impulsów obliczane są w następujący sposób:

$$i = 1 \dots m_\chi - 2$$

$$x_i^{(\kappa)} = x_{i+1}^{(\chi)} \quad (74)$$

$$w_i^{(\kappa)} = x_{i+1}^{(\chi)} - x_i^{(\chi)} \quad (75)$$

$$v_i^{(\kappa)} = x_{i+2}^{(\chi)} - x_{i+1}^{(\chi)} \quad (76)$$

$$A_i^{(\kappa)} = y_{i+1}^{(\chi)} - y_i^{(\chi)} \quad (77)$$

$$B_i^{(\kappa)} = y_{i+2}^{(\lambda)} - y_{i+1}^{(\lambda)} \quad (78)$$

$$i = 1 \dots n_\delta - 2 ;$$

$$x_i^{(\lambda)} = x_{i+1}^{(\delta)} \quad (79)$$

$$w_i^{(\lambda)} = x_{i+1}^{(\delta)} - x_i^{(\delta)} \quad (80)$$

$$v_i^{(\lambda)} = x_{i+2}^{(\delta)} - x_{i+1}^{(\delta)} \quad (81)$$

$$A_i^{(\lambda)} = y_{i+1}^{(\delta)} - y_i^{(\delta)} \quad (82)$$

$$B_i^{(\lambda)} = y_{i+2}^{(\delta)} - y_{i+1}^{(\delta)} \quad (83)$$

Dla uproszczenia dalszych opisów formalnych przyjmuje się oznaczenia:

m_κ - długość ciągu impulsów κ ,

n_λ - długość ciągu impulsów λ .

Poniżej przedstawiono algorytm przekształcenia $\alpha \rightarrow \kappa$ oraz $\beta \rightarrow \lambda$ obrazujący metodę przetwarzania danych wejściowych w ciągi impulsów.

Dane wejściowe: dwa ciągi liczb α, β .

Dla ciągów wejściowych: $\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_m\}$ oraz $\beta = \{\beta_1, \beta_2, \dots, \beta_n\}$:

1. L -krotne wygładzanie procedurą obliczania średniej przesuwanej

dla $i = 1 \dots L$;

gdzie:

i, j, k – indeksy iteracji,

W – szerokość okna uśredniania,

dla $j = 1 \dots m - W$;

$$\alpha_j = \frac{1}{W} \sum_{k=j}^{j+W} \alpha_k ;$$

dla $j = 1 \dots n - W$;

$$\beta_j = \frac{1}{W} \sum_{k=j}^{j+W} \beta_k ;$$

2. Normalizacja

dla $j = 1 \dots m$;

$$\alpha_j = \frac{\alpha_j}{\max(\alpha)};$$

dla $j = 1 \dots n$;

$$\beta_j = \frac{\beta_j}{\max(\beta)};$$

3. Podział ciągów liczbowych na impulsy:

3.1. wyznaczenie ekstremów lokalnych

$k = 1$;

dla $j = 2 \dots m - 1$;

jeżeli $\text{sign}(\alpha_{j-1} - \alpha_j) \neq \text{sign}(\alpha_j - \alpha_{j+1}) \Rightarrow j$ - indeks ekstremum lokalnego

$\chi_k = \{j, \alpha_j\}$ - ekstrema lokalne;

$k = k + 1$;

$k = 1$;

dla $j = 2 \dots n - 1$;

jeżeli $\text{sign}(\beta_{j-1} - \beta_j) \neq \text{sign}(\beta_j - \beta_{j+1}) \Rightarrow j$ - indeks ekstremum lokalnego

$\delta_k = \{j, \beta_j\}$ - ekstrema lokalne.

$k = k + 1$;

3.2. Podział ciągu na impulsy

$i = 1$;

dla $k = 1 \dots m_\chi - 2$;

jeżeli $\chi_{k+1,2} - \chi_{k,2} \geq 0 \Rightarrow$ początek impulsu (*minimum*)

$$x_i^{(\kappa)} = \chi_{k+1,1};$$

$$w_i^{(\kappa)} = \chi_{k+1,1} - \chi_{k,1};$$

$$v_i^{(\kappa)} = \chi_{k+2,1} - \chi_{k+1,1};$$

$$A_i^{(\kappa)} = \chi_{k+1,2} - \chi_{k,2};$$

$$A_i^{(\kappa)} = \chi_{k+2,2} - \chi_{k+1,2};$$

$$i = i + 1 ;$$

$$j = 1 ;$$

$$\text{dla } k = 1 \dots n_\delta - 2 ;$$

$$\text{jeżeli } \delta_{k+1,2} - \delta_{k,2} \geq 0 \Rightarrow \text{początek impulsu (minimum)}$$

$$x_j^{(\lambda)} = \delta_{k+1,1} ;$$

$$w_j^{(\lambda)} = \delta_{k+1,1} - \delta_{k,1} ;$$

$$v_j^{(\lambda)} = \delta_{k+2,1} - \delta_{k+1,1} ;$$

$$A_j^{(\lambda)} = \delta_{k+1,2} - \delta_{k,2} ;$$

$$A_j^{(\lambda)} = \delta_{k+2,2} - \delta_{k+1,2} ;$$

$$j = j + 1 ;$$

4. Utworzenie wektorów impulsów postaci:

$$\kappa_i = [x_i^{(\kappa)}, w_i^{(\kappa)}, v_i^{(\kappa)}, A_i^{(\kappa)}, B_i^{(\kappa)}]^T ;$$

$$\lambda_j = [x_j^{(\lambda)}, w_j^{(\lambda)}, v_j^{(\lambda)}, A_j^{(\lambda)}, B_j^{(\lambda)}]^T ;$$

5. Koniec algorytmu.

W wyniku działania powyższego algorytmu następuje przekształcenie wektora wejściowego zawierającego ciągi liczbowe opisujące przebiegi zmienności cechy do postaci ciągu, którego elementami są wektory parametrów impulsów

$$\alpha \rightarrow \xi \rightarrow \chi \rightarrow \kappa , \quad (84)$$

$$\beta \rightarrow \zeta \rightarrow \delta \rightarrow \lambda . \quad (85)$$

Prowadzone badania wykazały, iż dla potrzeb tego zastosowania istotne są następujące elementy wektora cech:

w_i – czas narastania impulsu,

v_i – czas opadania impulsu,

A_i – amplituda narastania impulsu,

B_i – amplituda opadania impulsu,

dla $i \in \{1, \dots, \Pi\}$,

gdzie:

Π – długość ciągu impulsów.

Cecha oznaczona jako x_i , reprezentująca położenie maksimum impulsu o indeksie i w ciągu wejściowym α , nie jest istotna, gdyż z punktu widzenia badania zjawisk przepływów, ważny jest sam fakt pojawienia się obiektu danego typu a , nie jego umiejscowienie czasowe. Cechy reprezentujące czas narastania oraz czas opadania zostały sprowadzone do pojedynczej cechy reprezentującej czas trwania impulsu i oznaczony

$$\forall_{i=1 \dots \Pi} u_i = w_i + v_i. \quad (86)$$

Amplituda narastania oraz amplituda opadania została przekształcona w amplitudę impulsu reprezentowaną przez

$$\forall_{i=1 \dots \Pi} C_i = \max(A_i, B_i). \quad (87)$$

Wynika to z faktu, że dla badanych zjawisk istotne jest określenie wielkości zmian danej cechy, nie zaś kierunek tych zmian.

Cechami biorącymi udział w klasyfikacji pozostały: C oraz u . Płaszczyzna decyzyjna $C-u$ zostaje następnie podzielona na obszary decyzyjne. Podział ten powinien być dokonany w sposób, który zapewni rozróżnialność badanych obiektów. Sposób podziału ściśle zależy od rodzaju cechy jaka jest badana oraz od parametrów przetwarzania wstępnego takich jak szerokość okna uśredniania oraz ilości iteracji uśredniania. Każdy z impulsów poddawany jest klasyfikacji zgodnej z jego położeniem na płaszczyźnie decyzyjnej. W ten sposób dla każdego obszaru określona zostaje ilość obiektów, które leżą w jego obrębie. Elementem wyróżniającym struktury przepływu są różne ilości impulsów, które znajdują się w poszczególnych obszarach decyzyjnych. Przykłady obszarów decyzyjnych zostaną zaprezentowane bardziej szczegółowo w rozdziale poświęconym praktycznej realizacji metody.

Dla zastosowań mechanoskopii algorytm rozpoznawania śladów dynamicznych również wymaga wyznaczenia ciągu impulsów, jednak dalszy sposób jego interpretacji wymaga podejścia właściwego dla tego zagadnienia.

W wyniku przetwarzania struktur danych $\alpha \rightarrow \kappa$ oraz $\beta \rightarrow \lambda$, konieczność porównywania ciągów liczbowych została zastąpiona koniecznością porównywania ciągów impulsów. Zgodnie z przytoczonym wcześniej postulatem rozpoznawanie odbywa się na zasadzie rozpoznawania elementów składowych obiektu. Rozpoznawany obiekt jest traktowany jako ciąg impulsów.

W tym miejscu należy rozwiązać następujące problemy:

1. Jak podejść do zagadnienia porównywania impulsów w aspekcie ich wzajemnych przesunięć? Jest to analogiczny problem do tego, który wystąpił podczas próby porównywania ciągów liczbowych.
2. Jak zdefiniować miarę podobieństwa dla obiektów typu impuls?
3. Jak uwzględnić w powyższych problemach różną szerokość impulsów?

Przedstawione w dalszej części algorytmy stanowią rozwiązania tych problemów.

Istotne jest, aby wyraźnie podkreślić, iż w kolejnym etapie opisu metody podstawowym obiektem jest impuls i on leży w centrum zainteresowania. W związku z problemem opisanym powyżej, opracowano dwie miary podobieństwa ciągów impulsów oznaczane dalej M_1 oraz M_2 .

Algorytm pierwszej miary (M_1) oparty jest na wzajemnym przesuwaniu ciągu impulsów o jeden punkt, a następnie szukaniu dla każdego impulsu jego najbliższego sąsiada w drugim ciągu i określanie podobieństwa tych impulsów. Zmierzona cecha stanowi ciąg punktów pomiarowych, które zostały pogrupowane w obiekty zwane impulsami. Wzajemne przesuwanie porównywanych ciągów odbywa się w algorytmie M_1 z krokiem równym jeden punkt pomiarowy, ale właściwe porównywanie odbywa się na poziomie impulsów. Najbliższy sąsiad

danego impulsu (w drugim ciągu) określony jest jako impuls, którego maksimum leży najbliżej maksimum rozpatrywanego impulsu.

Algorytm wyznaczania miary M_1 .

1. Wyznaczenie wartości funkcji dyskryminacyjnej dla kolejnych przesunięć t .

dla $t \in 0,1,\dots,T$

gdzie: T oznacza maksymalne przesunięcie,

1.1. Dla kolejnych impulsów zawartych w wektorze κ :

dla $i \in 1,2,\dots,m_\kappa$

gdzie: m_κ oznacza ilość impulsów z ciągu κ ,

$$\kappa_i = [x_i^{(\kappa)}, w_i^{(\kappa)}, v_i^{(\kappa)}, A_i^{(\kappa)}, B_i^{(\kappa)}].$$

1.1.1. Szukanie najbliższego impulsu λ_p w wektorze λ :

dla $j \in 1,2,\dots,n_\lambda$

gdzie: n_λ oznacza ilość impulsów z ciągu λ ,

$$\lambda_j = [x_j^{(\lambda)}, w_j^{(\lambda)}, v_j^{(\lambda)}, A_j^{(\lambda)}, B_j^{(\lambda)}]$$

$$\text{jeżeli } |x_i^{(\kappa)} - x_p^{(\lambda)} + t| = \min_{j \in 1,2,\dots,m} |x_i^{(\kappa)} - x_j^{(\lambda)} + t|, \quad (88)$$

$$\text{to } \kappa_i \approx \lambda_p^7.$$

1.1.2. Obliczenie przesunięcia względem siebie maksimów znalezionych impulsów:

$$l = |x_i^{(\kappa)} - x_p^{(\lambda)} + t|.$$

1.1.3. Obliczenie obszaru pokrywania się impulsów:

$$s = \min(x_i^{(\kappa)} + v_i^{(\kappa)}, x_p^{(\lambda)} + v_p^{(\lambda)} + t) - \max(x_i^{(\kappa)} - w_i^{(\kappa)}, x_p^{(\lambda)} - w_p^{(\lambda)} + t).$$

1.1.4. Obliczenie podobieństwa impulsów wg określonej miary D :

$$d = D(\kappa_i, \lambda_p).$$

⁷ Symbolem $\approx$ oznaczono relację „najbliższy”

1.1.5. Obliczenie wartości funkcji dyskryminującej

$$f : (a_1, a_2, a_3) \mapsto P.$$

gdzie:

$$a_1 = b_1 \cdot s,$$

$$a_2 = b_2 \cdot l,$$

$$a_3 = b_3 \cdot d,$$

$$b_1, b_2, b_3 \in [0,1] \quad - \text{ oznaczają współczynniki wagowe,}$$

$$P = f(a_1, a_2, a_3),$$

funkcji dyskryminującej:

$$P = \frac{a_1}{1 + a_2 + a_3}.$$

1.1.6. Wpisanie wyniku porównania do ciągu μ na pozycji równej przesunięciu

$$\mu_t = P;$$

2. Wyznaczenie ciągu maksimów lokalnych:

$$\Omega = \{\Omega^1, \Omega^2, \dots, \Omega^F\};$$

gdzie:

$$\Omega^i = \{t^i, \mu_t^i\}, \quad i \in \{1, 2, \dots, F\}; \quad F - \text{ oznacza ilość znalezionych maksimów lokalnych,}$$

3. Posortowanie listy maksimów lokalnych wg wartości μ_t^i ,
4. Wygenerowanie odpowiedzi w postaci listy przesunięć t na podstawie posortowanej listy maksimów.
5. Koniec algorytmu.

Cechą charakterystyczną powyższego algorytmu jest określanie stopnia podobieństwa dwóch ciągów impulsów, dla przesunięć których podstawową

jednostką jest pojedynczy punkt. W algorytmie wyznaczania miary podobieństwa oznaczonym jako M_2 przyjęto inne rozwiązanie. Krokiem przesunąć ciągów są kolejne impulsy. Nastąpiło więc kwantowanie skoku, co wymusza odmienne podejście do wyniku obliczeń.

Algorytm wyznaczania stopnia podobieństwa ciągów impulsów M_2 .

1. Dla kolejnych impulsów z pierwszego ciągu:

dla $i \in 1, 2, \dots, m_\kappa$;

$$\kappa_i = [x_i^{(\kappa)}, w_i^{(\kappa)}, v_i^{(\kappa)}, A_i^{(\kappa)}, B_i^{(\kappa)}];$$

1.1. Dla kolejnych impulsów z pierwszego ciągu

dla $j \in 1, 2, \dots, n_\lambda$;

$$\lambda_j = [x_j^{(\lambda)}, w_j^{(\lambda)}, v_j^{(\lambda)}, A_j^{(\lambda)}, B_j^{(\lambda)}];$$

1.1.1. Wyznaczenie przesunięcia t , dla którego maksima impulsów pokrywają się

$$t = x_i^{(\kappa)} - x_j^{(\lambda)};$$

1.1.2. Obliczenie minimalnej szerokości

$$s = \min(w_i^{(\kappa)} + v_i^{(\kappa)}, w_j^{(\lambda)} + v_j^{(\lambda)}); \quad (89)$$

1.1.3. Obliczenie podobieństwa impulsów wg zadanej miary

$$d = D(\kappa_i, \lambda_j);$$

1.1.4. Obliczenie wartości funkcji dyskryminującej

$$f : (a_1, a_2) \mapsto P;$$

gdzie:

$$a_1 = b_1 \cdot s;$$

$$a_2 = b_2 \cdot d;$$

$$b_1, b_2 \in [0, 1]; \text{ oznaczają współczynniki wagowe,}$$

$$P = f(a_1, a_2);$$

$$P = \frac{a_1}{1 + a_2}; \quad \text{funkcji dyskryminacyjna,}$$

1.1.5. Wpisanie wyniku porównania do wektora μ na pozycji równej przesunięciu:

$$\mu_t = P;$$

1.2. zadaną ilość razy L , dla zadanej szerokości okna W obliczenie średniej przesuwanej wektora wyników μ :

dla $i = 1 \dots L$;

dla $j = 1 \dots T$;

$$\mu_j = \frac{1}{W} \sum_{k=j}^{j+W} \mu_k;$$

gdzie:

i, j, k – indeksy iteracji,

W – szerokość okna uśredniania,

T – maksymalne przesunięcie.

2. Wyznaczenie listy maksimów lokalnych:

$$\Omega = [\Omega^1, \Omega^2, \dots, \Omega^F];$$

gdzie:

$$\Omega^i = \{t^i, \mu_t^i\}, \quad i \in \{1, 2, \dots, F\}; \quad F - \text{oznacza ilość znalezionych maksimów lokalnych,}$$

3. Posortowanie listy maksimów lokalnych wg wartości μ_t^i .

4. Wygenerowanie odpowiedzi w postaci listy przesunięć t na podstawie posortowanej listy maksimów.

5. Koniec algorytmu.

Sposób interpretacji wyników generowanych przez powyższe algorytmy zostanie przedstawiony w rozdziale poświęconym praktycznej realizacji metody.

Miary podobieństwa impulsów:

W algorytmach obliczania odległości między ciągami impulsów pojawia się pojęcie miary podobieństwa impulsów: $d = D(\kappa_i, \lambda_j)$.

Rysunek 42. przedstawia impuls, który jest reprezentowany przez 5 cech:

$$\kappa_i = [x_i^{(\kappa)}, w_i^{(\kappa)}, v_i^{(\kappa)}, A_i^{(\kappa)}, B_i^{(\kappa)}],$$

$$\lambda_j = [x_j^{(\lambda)}, w_j^{(\lambda)}, v_j^{(\lambda)}, A_j^{(\lambda)}, B_j^{(\lambda)}],$$

gdzie:

x – położenie impulsu w ciągu wejściowym,

w – odległość od początku impulsu do jego ekstremum,

v – odległość od ekstremum do końca impulsu,

A – amplituda wznoszenia,

B – amplituda opadania.

Cecha oznaczona jako x oznacza jedynie położenie impulsu w ciągu wejściowym, więc nie zawiera w sobie istotnej informacji i własności samego impulsu. W związku z tym nie była brana pod uwagę podczas opracowywania miar.

Zdefiniowane miary mają na celu zapewnić możliwie szeroki zakres ich zastosowań, więc nie są one dedykowane konkretnie danej aplikacji. Mimo ich praktycznego stosowania w oprogramowaniu realizującego przedstawione algorytmy rozpoznawania, należy podkreślić ich stopień uniwersalności potwierdzony zakresem udanych zastosowań.

Wszystkie poniższe miary opierają się na kwadracie różnicy odpowiadających sobie parametrów w porównywanych impulsach.

$$1. \quad D(\kappa_i, \lambda_j) = \sqrt{(A_i^{(\kappa)} - A_j^{(\lambda)})^2 + (B_i^{(\kappa)} - B_j^{(\lambda)})^2 + (w_i^{(\kappa)} - w_j^{(\lambda)})^2 + (v_i^{(\kappa)} - v_j^{(\lambda)})^2} \quad (90)$$

Powyższe wyrażenie przedstawia miarę będącą pierwiastkiem kwadratowym sumy kwadratów różnic parametrów: A , B , w , v . Cechą charakterystyczną jest to, że wszystkie parametry mają ten sam wpływ na wynik. W związku z tym należy ją stosować, gdy różnice we wszystkich wymiarach są równie istotne z punktu widzenia fizycznej interpretacji wektora cech opisującego impulsy.

$$2. \quad D(\kappa_i, \lambda_j) = \sqrt{(A_i^{(\kappa)} - A_j^{(\lambda)})^2 + (B_i^{(\kappa)} - B_j^{(\lambda)})^2} \quad (91)$$

Miara ta uwzględnia tylko amplitudy, całkowicie ignorując szerokości impulsów, więc doskonale spełnia swoje zadanie, gdy zawartość informacyjna o zjawisku tkwi głównie lub całkowicie w tej sferze.

$$3. \quad D(\kappa_i, \lambda_j) = \sqrt{(w_i^{(\kappa)} - w_j^{(\lambda)})^2 + (v_i^{(\kappa)} - v_j^{(\lambda)})^2} \quad (92)$$

W tej mierze barana jest pod uwagę tylko szerokość impulsów, co determinuje jej zakres zastosowań do sytuacji, w której istotne są głównie odległości między punktami ekstremalnymi przebiegu, a nie ich wartości.

$$4. \quad D(\kappa_i, \lambda_j) = \sqrt{((A_i^{(\kappa)} - A_j^{(\lambda)})^2 + (B_i^{(\kappa)} - B_j^{(\lambda)})^2) \cdot ((w_i^{(\kappa)} - w_j^{(\lambda)})^2 + (v_i^{(\kappa)} - v_j^{(\lambda)})^2)} \quad (93)$$

Miara przedstawiona powyżej zawiera wszystkie amplitudy i szerokości. Jest ona bardzo podobna do pierwszej miary, lecz zawiera pewną różnicę. Parametry A i B oraz w i v zostały pogrupowane i rozdzielone operatorem mnożenia. Spowodowało to sytuację, w której już nie jest obojętne które parametry ulegną zmianie, gdyż odległość między dwoma impulsami wzrasta najszybciej, gdy amplitudy A i B oraz szerokości w i v grupami rosną równomiernie. Można stwierdzić, iż w stosunku do miary 1 nastąpiło pewne wyczulenie na sytuację, w której różnice amplitud i różnice szerokości zwiększają swoją wartość w tym samym czasie.

Przyjmując oznaczenia:

$$\Phi = (A_i^{(\kappa)} - A_j^{(\lambda)})^2 + (B_i^{(\kappa)} - B_j^{(\lambda)})^2, \quad (94)$$

$$\Psi = (w_i^{(\kappa)} - w_j^{(\lambda)})^2 + (v_i^{(\kappa)} - v_j^{(\lambda)})^2, \quad (95)$$

powyższe miary przyjmują następującą postać:

$$1. \quad D(\kappa_i, \lambda_j) = \sqrt{\Phi + \Psi},$$

$$2. \quad D(\kappa_i, \lambda_j) = \sqrt{\Phi},$$

$$3. \quad D(\kappa_i, \lambda_j) = \sqrt{\Psi},$$

$$4. \quad D(\kappa_i, \lambda_j) = \sqrt{\Phi \cdot \Psi}.$$

Tabela 5. przedstawia wpływ różnego rodzaju zmian amplitud i szerokości dla różnych miar odległości między impulsami.

Tabela 5.

Wpływ zmian amplitud i szerokości dla różnych miar odległości

Miara	$D(\Phi, \Psi)$ $\Phi=1; \Psi=1$	$D(\Phi, \Psi)$ $\Phi=3; \Psi=3$	$D(\Phi, \Psi)$ $\Phi=2; \Psi=4$
1	1.414	2.450	2.450
2	1	1.732	1.414
3	1	1.732	2
4	1	3	2.828

Z analizy wynika, iż dla miary 4. istotne jest czy różnice w grupach Φ i Ψ są zbliżone do siebie, czy tak nie jest. Miara 1. nie „zauważa” takich zależności. Reasumując można stwierdzić, iż wg miary 4. impulsy są do siebie tym mniej podobne im różnice ich parametrów w grupie amplitud (Φ) i szerokości (Ψ) są zbliżone do siebie. W związku z tym wszystkie miary znajdują zastosowanie, jednak dla różnego rodzaju danych wejściowych.

7. ROZPOZNAWANIE STRUKTURY PRZEPŁYWU WIELOFAZOWEGO


7.1. Wprowadzenie

W środowisku naturalnym człowieka a także w bardzo wielu dziedzinach przemysłu ma miejsce równoczesny przepływ kilku faz, np. cieczy i gazu. Padający deszcz to nic innego jak przepływ dyspersyjny kropli cieczy i powietrza. Już ten przykład może być najlepszym uzasadnieniem ważności problemu. Otóż istnieje dość poważny problem z indukowaniem drgań układów mechanicznych, wywołany przepływem płynu. W ostatnich stu latach doszło do wielu spektakularnych zniszczeń mostów wiszących, zniszczenia konstrukcji wież, dźwigów pod wpływem wiatru. Nieprzypadkowo awarie te miały miejsce w czasie silnych wiatrów i deszczu. Do dzisiaj nie wiadomo czy przyczyną tych awarii był bardziej silny wiatr czy też natura przepływu mieszaniny dwufazowej: powietrza i wody. Innymi przykładami mogą być np. burze piaskowe, przepływ zafalowanego filmu cieczy na szybie samochodu, przepływ zapyłonego powietrza w kominie, barbotaż warstwy cieczy pęcherzykami powietrza w oczyszczalni ścieków.

Czasem przepływ wielofazowy jest przypadkowym a czasem, i tak zwykle jest w zastosowaniach przemysłowych, jest działaniem zamierzonym. Na przykładzie klasycznej elektrowni z przepływem mieszanin wielofazowych spotykamy się podczas spalania paliwa stałego w kotle fluidalnym, dostarczania tego paliwa rurociągami do pieców pyłowych, transportu hydraulicznego żużla na składowisko czy też podczas wrzenia wody w rurach oraz podczas kondensacji pary w kondensatorach.

Wiedza z zakresu operacji jednostkowych, a szerzej - inżynierii procesowej (często poprzez wprowadzenie ograniczenia do obszaru chemii, nazywanej inżynierią chemiczną) wskazuje, że wiele procesów związanych z wymianą ciepła lub masy, może być prowadzona w zakresie przepływu wielofazowego. Stwierdzono także, i właściwie jest to motorem działania, że procesy te


charakteryzują się dużą intensywnością wymiany ciepła i/lub masy. Np. w reaktorach jądrowych, ich intensywne chłodzenie odbywa się często przy przepływie mieszaniny woda-para wodna, metal-para metalu; osiągane są wtedy nawet o kilka rzędów wyższe, niż w tradycyjnych wymiennikach, wartości współczynnika wnikania ciepła. Także wiele reakcji chemicznych prowadzonych jest w układach wielofazowych. Rysunek 43. przedstawia obszerny przegląd aparatów do kontaktowania gazu i cieczy w bardzo różnych obszarach zastosowań.



Rysunek 43. Przykłady aparatów do kontaktowania gazu i cieczy: a) kolumna dyspersyjna, b) kolumna ze spływającym filmem cieczy, c) kolumna wypełniona przeciwprowodowa, d) kolumna pęcherzykowa, e) kolumna półkowa, f) kolumna pęcherzykowa z mieszaniem mechanicznym, g) kolumna pęcherzykowa z mieszaniem strumienicowym, h) aparat strumienicowy, i) reaktor barbotażowy, j) reaktor barbotażowy z rurą cyrkulacyjną, k) reaktor rurowy przeciwprowodowy, l) reaktor rurowy współprowodowy, m.) reaktor rurowy węzownicowy [9][71][82].


W zależności od specyfiki procesu, fazy mogą występować w bardzo różnej formie, którą nazywa się strukturą przepływu mieszaniny. Może to być w skrajnych przypadkach albo przepływ dyspersyjny kropli cieczy w ciągłej fazie gazowej (a) lub też przepływ pęcherzy gazowych w ciągłej fazie ciekłej (d).

Rysunek 44 przedstawia przykładowo stosunkowo proste aparaty do prowadzenia bardzo różnych procesów w układzie gaz-ciało stałe.



Rysunek 44. Przegląd klasycznych aparatów fluidalnych do kontaktowania cieczy i ciała stałego a) złoże pęcherzykowe, b) złoże pulsacyjne, c) złoże fontannowe [66].

Rysunek 45. zawiera przykłady bardziej złożonych aparatów.



Rysunek 45. Przegląd reaktorów do zgazowania węgla a) pęcherzykowe złoże fluidalne, b) złoże pęcherzykowe z zewnętrzną cyrkulacją ciała stałego, c) szybka fluidyzacja z wewnętrzną i zewnętrzną cyrkulacją ciała stałego [66].

Praca tych urządzeń niezależnie czy odnosi się to do układów gaz-ciecz czy też gaz-ciało stałe, zakłada z góry, występowanie ściśle określonego rodzaju przepływu. Tylko wtedy zaprojektowany aparat działa prawidłowo i wypełnia postawione mu zadania. Odstępstwo od założonej struktury przepływu, zwykle dość gwałtownie pogarsza efektywność pracy urządzenia.

Dla specjalistów zajmujących się przepływami wielofazowymi powszechne jest dzisiaj podejście, że struktura przepływu decyduje w stopniu największym,

o zjawiskach transportu pędu, ciepła i masy. Stanowi zatem podstawowy parametr jaki powinien być określony w pierwszej kolejności.


Taka sytuacja ma miejsce zarówno dla najszerszej przebadanej dotychczas grupy mieszanin gaz-ciecz [10][28], jak również układów fluidalnych [25][32][58], a także dla układów trójskładnikowych (tzw. fluidyzacja trójfazowa [57]).

Do dzisiaj brak jest jednoznacznych metod przewidywania struktury przepływu. Od kilkudziesięciu lat prowadzone są obszerne badania eksperymentalne. W zakresie badań w skali laboratoryjnej dopracowano się już wielu wyrafinowanych metod badawczych, jednak jak dotąd brak jest pewnych metod przewidywania struktury przepływu w warunkach przemysłowych. Co prawda ostatnie lata to bardzo dynamiczny rozwój różnych technik wizualizacyjnych, z metodami tomografii komputerowej włącznie, jednak są one zazwyczaj dość kosztowne i stąd ich zastosowanie jest w dalszym ciągu ograniczone.

7.2. Określenia i definicje

Dla poszczególnych przypadków przepływu mieszanin wielofazowych tworzy się klasyfikacje struktur biorąc pod uwagę przestrzenne i czasowe rozkłady faz w badanej przestrzeni. Bardzo często (tak było do połowy lat 80-tych klasyfikacje struktur tworzone na podstawie obserwacji wizualnej strugi płynącej mieszaniny dwufazowej.


Rysunek 46. przedstawia przykład dość powszechnie przyjętej klasyfikacji struktur przepływu dla wznoszącego przepływu gazu i cieczy w rurze pionowej.



Rysunek 46. Klasyfikacja struktur dla przepływu wznoszącego mieszaniny gaz-ciecz w kanale pionowym; struktura: B – pęcherzykowa, P – korkowa, F – pianowa, A – pierścieniowa, AD – pierścieniowo-dyspersyjna [92].

Dla małej prędkości gazu pojawiają się drobne pęcherze gazowe. Wraz ze wzrostem prędkości gazu, pęcherze łączą się w większe struktury gazowe podłużne korki zajmujące prawie cały przekrój poprzeczny kanału. Dalej następuje na przemian w górę i w dół przepływ porcji cieczy. Przepływ ten zwany jest pianowym. Dla dużych prędkości gazu ciecz płynie już tylko cienką warstewką po ścianie. Jej powierzchnia może być zafalowana i z grzbietów tych fal porywane są drobne krople cieczy. W skrajnym przypadku mamy już tylko przepływ kropli cieczy. Możemy wyróżnić zatem struktury przepływu, które charakteryzują się dużą powierzchnią kontaktu (pęcherzyki, krople) o uspokojonym przepływie, i struktury który przy małej powierzchni kontaktu faz poruszają się z silnymi oscylacjami. Z punktu widzenia procesów transportu ciepła i masy, strumień wymienianego ciepła lub masy to, najogólniej rzecz biorąc, iloczyn powierzchni kontaktu i współczynnika wnikania ciepła lub masy.


Rysunek 47. przedstawia podobną klasyfikację struktur dla układu gaz-ciało stałe stałe.



Rysunek 47. Klasyfikacja struktur dla przepływu mieszaniny gaz- ciało stałe w kanale pionowym: a) złoże zwarte, b) złoże rozluźnione, c) złoże pęcherzykowe, d) złoże pulsujące, e) złoże turbulentne, f) szybka fluidyzacja [84][85].

W początkowym momencie usypane ciało stałe jest w stanie zwartym. Wzrost strumienia gazu może spowodować rozluźnienie złoża aż do wystąpienia przepływu małych pęcherzy gazowych. Dalszy wzrost strumienia gazu to przepływ pulsacyjny złoża a dalej przepływ turbulentny porcji ciała stałego w różnych kierunkach. Dla bardzo dużych prędkości gazu może następować porywanie ciała stałego. Jeżeli następuje zawracanie ciała stałego do aparatu mamy do czynienia z tzw. szybką fluidyzacją. Opis zjawisk transportu ciepła i masy jest analogiczny jak dla mieszaniny gaz-ciecz.

Problem jeszcze bardziej komplikuje się w warunkach rzeczywistych, gdy np. w rurach kotła energetycznego mamy przepływ wody i jej ciągłe odparowanie pod wpływem dostarczonego ciepła. Rysunek 48. przedstawia właśnie taką sytuację.



Rysunek 48. Zmiany struktury mieszaniny woda-para wodna podczas ciągłego odparowania przy przepływie w kanale [92].

Na wlocie do rury znajduje się woda, zaś po drodze rośnie udział pary wodnej, która płynie początkowo w postaci pęcherzy gazowych, potem korków, w formie piany. Na końcu strefy odparowania mamy już tylko przepływ pary nasyconej.


Zarówno dla potrzeb projektowania aparatów w których przepływ mieszaniny wielofazowej jak i ich eksploatacji występuje, problem przewidywania struktury przepływu. Istnieje wiele metod przewidywania struktury przepływu mieszaniny wielofazowej:

- A) rozpoznawanie struktury przepływu poprzez obserwację wizualną i porównanie z wzorcami struktur przepływu; czasem obserwacja wizualna wspomagana jest zdjęciami lub filmowaniem,
- B) korzystanie z map przepływu, gdzie na podstawie parametrów przepływowych i własności fizykochemicznych składników mieszaniny wielofazowej, umieszczanych jako współrzędne układu współrzędnych (zwykle dwuwymiarowego), wyznacza się zakresy występowania poszczególnych struktur przepływu w formie obszarów rozgraniczonych liniami bądź pasami granicznymi. Dla przepływu mieszaniny woda-powietrze w kanale pionowym opracowano już kilkadziesiąt map przepływu, w chwili obecnej najczęściej stosowana jest mapa Taitela. Odpowiednio dla przepływu w rurze poziomej powszechnie stosowana jest mapa wg [3] zmodyfikowana przez [89],
- C) klasyfikację struktur przepływu na podstawie analizy stochastycznej wybranych parametrów np. oscylacji ciśnienia [33], zawartości faz [41][92] – w dalszej części zostanie dokonany przegląd metod badawczych. Ten sposób uwzględnia charakterystyczny dla przepływu mieszanin wielofazowych dynamizm procesu,
- D) tworzenie modeli teoretycznych map przepływu i ich prezentacja dla szczególnych warunków przepływu np. mapa McQuillana i Whalleya [60].

Z powyższej klasyfikacji wynika, że w przypadku A) korzystamy z informacji o przestrzennym rozkładzie faz i porównujemy je z obrazem wzorca przepływu. W przypadku C) ocena struktury przepływu odbywa się głównie na podstawie informacji o dynamice procesu w dziedzinie czasu. Te dwie metody z punktu widzenia poznawczego wydają się być najbardziej interesującymi.

Jednym z najważniejszych parametrów związanych z przepływem mieszanin wielofazowych jest określenie zawartości faz czasem nazywanej udziałem objętościowym.

Z uwagi na różne własności fizykochemiczne składników mieszaniny, różną ich ilość, płyną one z różną prędkością, a zatem udział objętościowy w wybranym obszarze badawczym nie jest równy ilości dozowanych faz. Rysunek 49.a. przedstawia taką sytuację.



Rysunek 49. Różne interpretacje zawartości faz dla przepływu dwufazowego gaz-ciecz w kanale [23].

To stanowi, że pomiar tej wielkości nie jest łatwy. O ile przy ocenie zawartości faz w odniesieniu do objętości kontrolnej nazwa jest jednoznaczna, to w wielu przypadkach rozpatrując obszar lub odcinek kontrolny określenie zawartości faz jest już pewnym nadużyciem. Jednak z uwagi na poważne trudności pomiarowe, przy zapewnieniu reprezentatywności próby, stosuje się taką nazwę nawet w odniesieniu do wartości wyznaczanej w oparciu o pomiar czasu przebywania wybranego punktu w poszczególnych fazach. Rysunek 49.b. zawiera interpretację graficzną takiego działania.

7.3. Przegląd metod badawczych

Prezentowane klasyfikacje struktur przepływu powstały na podstawie obserwacji wizualnej strugi mieszaniny dwufazowej płynącej w przeźroczystym kanale. Faktycznie dostępną dla oka ludzkiego jest zazwyczaj tylko strefa w pobliżu przeźroczystej ściany. Przez wiele dziesiątków lat w oparciu o taką informację sterowano procesami przemysłowymi. Pożądaną strukturę przepływu osiągnano poprzez obserwację wizualną poprzez wzierniki i dokonywano odpowiedniej zmiany nastaw, najczęściej strumieni dozowanych faz. Często jednak z uwagi na bardzo trudne warunki (wysoka temperatura, wysokie ciśnienie, nieprzeźroczyste składniki mieszaniny) bądź też dużą szybkość przepływu mieszaniny (czasem nawet 100 m/s) obserwacja wizualna była niemożliwa.

Dzięki możliwościom bardzo już dzisiaj rozwiniętych metod tomografii komputerowej dokonuje się oceny struktury we wnętrzu aparatu, bez zaburzenia przepływu. Problem przepływu mieszanin ze znacznymi prędkościami wspomaga się metodami szybkiej rejestracji obrazu lub innych wybranych cech mierzalnych.

W ciągu ostatnich 30-40 lat opracowano wiele metod badawczych, które mogą z powodzeniem zastępować a często obiektywizować ocenę struktury przepływu – ocena wizualna jest metodą subiektywną, zależną od obserwatora.

Dla przepływu mieszaniny wielofazowej, nie stwarza wielkiej trudności wybór cechy mierzalnej, która (co wynika z definicji fazy) jest różna dla poszczególnych składników mieszaniny. Np. dla mieszaniny woda-powietrze przewodność elektryczna jest często wielkością mierzalną, która umożliwia odróżnianie składników mieszaniny. Już jednak dla układu olej-powietrze to przenikalność magnetyczna jest właściwym parametrem mierzalnym (olej i powietrze nie przewodzą prądu elektrycznego i pomiar przewodności elektrycznej nie daje szans na rozróżnienie faz).

Tabela 6. przedstawia przykładowy przegląd różnych metod pomiarowych dla układów mieszaniny gaz-ciecz stałe.

Tabela 6.

Przegląd metod pomiarowych dla przepływu mieszaniny gaz-ciecz

Nr	Autor	Rok	Wyznaczany parametr
1	Hubbard, Dukler [33]	1966	Ocena struktury przepływu mieszaniny gaz-ciecz w rurze poziomej na podstawie analizy fluktuacji spadku ciśnienia; funkcja PSD
2	Jones, Zuber [41]	1975	Prześwietlanie kanału wiązką promieni X Funkcje: PDF, PSD
3	Jain, Childerson, Kar, Roy [38]	1981	Prześwietlanie kanału wiązką promieni X Analiza funkcji PDF i PSD
4	El-Ayouty, Stepanek [21]	1983	Analiza tłumienia mikrofal przepływających przez strugę mieszaniny dwufazowej Funkcja PSD
5	Ikeda, Kotani, Maeda, Kohno [35]	1983	Prześwietlanie wiązką promieni X, tomografia komputerowa
6	Sekoguchi, Mori [78]	1997	Wieloelektrodowa sonda przewodnościowa do odwzorowania zafalowanej powierzchni filmu cieczy
7	Dyakowski, Mann, Williams [19]	1998	Przewodnościowa tomografia komputerowa do wyznaczania rozkładu koncentracji faz przy przepływie gaz- ciecz w kanale
8	Schmitz, Petritsch, Mewes [77]	1998	Rezystancyjna tomografia elektryczna drutowa do wyznaczania rozkładu koncentracji faz przy przepływie rzutowym w kanale
9	Shoji [80]	1998	Analiza fraktalna fluktuacji temperatury podczas wrzenia przy przepływie
10	Theofanous, Yuen [88]	1998	Wizualizacja procesu wrzenia poprzez prześwietlanie promieniami X
11	Bennett, Luke, Jia, West, Williams [5]	1999	Ocena struktury przepływu w oparciu o rejestrację video dla struktury pęcherzykowej i pianowej
12	Keska, Smith [43]	1999	Ocena struktury przepływu w kanale pionowym na podstawie analizy stochastycznej dla rejestracji przy pomocy sond: optycznej, rezystancyjnej i pojemnościowej

Nie zawsze celem pomiaru było określenie struktury przepływu; bardzo często badania miały charakter poznawczy albo służyły celom użytkowym (określenie minimum dla powstania przepływu filmowego w reaktorach warstewkowych [93], stanu zawału - zablokowania przepływu w złożu fluidalnym [84], (Tabela 7.). Warto jednak zwrócić uwagę na ogromną różnorodność stosowanych technik pomiarowych.


Tabela 7. przedstawia przykładowy przegląd różnych metod pomiarowych dla układów mieszaniny gaz-ciało stałe.

Tabela 7.

Przegląd metod pomiarowych dla przepływu mieszaniny gaz-ciało stałe


Nr	Autor	Rok	Wielkość mierzona
1	Bader i inni [2]	1988	Ocena struktury złoża fluidalnego na podstawie próbkowania sondą Pitota
2	Hartge i inni	1988	Wyznaczenie rozkładu fazy stałej oraz prędkości dla szybkiej fluidyzacji przy pomocy sondy optycznej
3	Weinstein i inni [94]	1988	Wyznaczanie gęstości złoża poprzez prześwietlanie promieniami X
4	Brereton, Grace [8]	1993	Wykorzystanie sondy pojemnościowej do pomiarów parametrów lokalnych dla szybkiej fluidyzacji
5	Gliskman, Noymer [26]	1996	Ocena ruchu grup cząstek ciała stałego z wykorzystaniem technik termowizyjnych
6	Issangya, Bai, Grace, Lim [36]	1996	Pomiar rozkładu koncentracji faz przy pomocy czujnika światłowodowego odbiciowego
7	Liu, Xu, Reh [59]	1997	Wykorzystanie lokalnych pomiarów technikami laserowymi do określenia zawartości faz i prędkości cząstek
8	Schaaf, Shouten, Johnsson [76]	1998	Analiza fraktalna fluktuacji spadku ciśnienia
9	Szmolke, Ulbrich [84][85]	1999	Ocena struktury szybkiego złoża fluidalnego na podstawie analizy stochastycznej ciśnienia statycznego
10	Dyakowski, Jaworski [18]	2000	Tomograficzne metody wizualizacji przepływu (X, gamma, optyczna)

Rysunek 50. przedstawia obraz zmian zawartości faz dla różnych struktur przepływu w kanale poziomym (rozwarstwionej, falowej i rzutowej).



Rysunek 50. Zmiany zawartości faz dla przepływu mieszaniny gaz-ciecz w kanale poziomym
a) struktura rozwarstwiona, b) struktura zafalowana, c) struktura rzutowa [92].

Widać dość dobre odwzorowanie charakteru zmian zawartości faz w funkcji czasu z rozkładem koncentracji faz. Dokonując analizy przebiegu zmian wybranych cech w funkcji czasu, np. wykorzystując do tego funkcje stochastyczne można, z dobrym skutkiem, dokonać oceny struktury przepływu. Rysunek 51. przedstawia wynik badań zmian zawartości powietrza przy przepływie mieszaniny woda-powietrze w rurze pionowej.



Rysunek 51. Przykład rozróżniania struktur przepływu mieszaniny dwufazowej gaz-ciecz na podstawie oceny kształtu funkcji gęstości prawdopodobieństwa zmian udziału objętościowego gazu [93].

Kształt funkcji gęstości prawdopodobieństwa odmienny dla poszczególnych struktur przepływu jest dobrą cechą odróżniającą struktury przepływu.

W badaniach rozpoznawania struktur przepływu opartych na analizie procesów stochastycznych wybranych parametrów, pojawia się problem reprezentatywności próby.

Tabela 8. przedstawia przykładowe aplikacje metod pomiarowych dla mieszaniny dwufazowej gaz-ciecz które różnią się przede wszystkim wielkością badanego obszaru.

Tabela 8.

Wybór strefy pomiaru w badaniach przepływu mieszaniny gaz-ciecz

Nr	Autor	Rok	Strefa	Parametr
1	Hubbard, Dukler [33]	1966	Punkt	Pomiar fluktuacji ciśnienia
2	Galaup [23]	1976	Odcinek W kierunku osiowym	Sonda oporowa dwuelektrodowa
3	Ulbrich [93]	1982	Odcinek w kierunku poprzecznym	Sonda oporowa
4	Merzkirch, Wagner [62]	1996	Powierzchnia osiowa	Oświetlenie strefowe przy pomocy lasera wewnątrz kolumny wypełnionej cieczą
5	Narabayashi, Tobimatsu, Nagasaka, Kagawa [65]	1983	Powierzchnia poprzeczna	Prześwietlanie promieniami X - tomografia komputerowa
6	Delhaye [17]	1978	Powierzchnia ściany	Zdjęcie rury zabudowanej w prostopadłościenną skrzyni wypełnionej cieczą o współczynniku załamania światła jak materiał rury
7	Merillo, Dechane, Cichowlas [61]	1977	Objętość	Sonda pojemnościowa zabudowana na ścianie kanału

Strefa pomiarowa to: punkt, odcinek, powierzchnia lub objętość, a zatem wnioskowanie o strukturze przepływu na podstawie dynamiki procesu wymaga ogromnej staranności w doborze strefy pomiarowej. To stanowi duże ograniczenie w stosowaniu tej metody.

7.4. Uzasadnienie podjęcia tematu pracy – cel pracy

W wielu aparatach przemysłowych obserwacja wizualna nie jest możliwa i to zarówno z uwagi na konstrukcję tych aparatów jak i parametry w których proces jest prowadzony. Czasem ocena w oparciu o pojedynczy obraz struktury stwarza możliwość wnioskowania, którego skuteczność jest niewielka. Czasem ocena jest prowadzona dla bardzo ograniczonego obszaru. Oba te przypadki prowadzą do jednego –wnioskowanie może być obarczone dużym błędem.

Stąd też celowość wnioskowania o strukturze przepływu równocześnie w oparciu o znaczące dla struktury: przestrzenny i czasowy rozkład faz.

Proponuje się aby łącząc dwie cechy procesu, a więc analizę w dziedzinie czasu lecz w odniesieniu do parametrów opisujących przestrzenny rozkład faz.

W pracy podjęto próbę opracowania metody (algorytmu) rozpoznawania struktur przepływu mieszanin wielofazowych na podstawie oceny charakteru zmian:

- przestrzennego (rejestracja obrazu)
- w dziedzinie czasu (rejestracja video).

Przed metodą stawia się następujące wymagania:


- obiektywizm, dzięki precyzyjnym procedurom obliczeniowym,
- ocena ilościowa na podstawie informacji,
- nieinwazyjność metody – w strefie przepływu nie będą instalowane żadne czujniki,
- heurystyczna metoda klasyfikacji – dzięki zastosowaniu oceny opartej na analizie sekwencji video obrazu badanego procesu.

8. PRAKTYCZNE ZASTOSOWANIE METODY ROZPOZNAWANIA PRZEPŁYWU MIESZANIN DWUFAZOWYCH

W celu praktycznej weryfikacji opracowanej metody w zakresie badania struktur przepływów mieszanin dwufazowych zaprojektowano i wykonano aplikacje realizujące algorytmy przetwarzania danych zgodne z zamieszczonym opisem. W zakresie rozpoznawania śladów dynamicznych został wykonany program znajdujący optymalne zestawienia obrazów reprezentujących ślad dowodowy oraz porównawczy. Rysunek 52. zawiera ogólny schemat przetwarzania danych dla obydwu zagadnień praktycznych.

8.1. Ogólny opis realizacji metody

Na wejściu do systemu znajduje się proces fluidyzacyjny lub inny rodzaj przepływu mieszanin gaz-ciało stałe czy też gaz-ciecz. Akwizycji danych dokonuje kamera wideo. Obraz z kamery jest następnie zapisywany na taśmie wideo. Specjalistyczna karta typu movie grabber dokonuje zamiany sygnału analogowego na postać cyfrową. W efekcie tej operacji zostaje utworzony plik w formacie AVI. Opracowane oprogramowanie zamienia kolejne klatki sekwencji wideo zawartej w pliku AVI na obrazy w postaci map bitowych. W wyniku dalszego przetwarzania utworzona struktura danych zawierająca ciąg liczb stanowiący przebieg zmienności danej cechy. Otrzymany ciąg wartości liczbowych jest następnie normalizowany i zamieniany na ciąg obiektów zdefiniowanych w niniejszym opracowaniu jako impulsy. Kolejne impulsy są klasyfikowane na podstawie zdefiniowanych obszarów decyzyjnych. Na podstawie ilości impulsów zakwalifikowanych do poszczególnych klas, klasyfikowana jest struktura przepływu.




Rysunek 52. Schemat prezentujący ogólną ideę zastosowaną podczas rozpoznawania struktur przepływu mieszanin dwufazowych.

8.2. Praktyczna realizacja metody

Pierwszym i podstawowym działaniem jest przygotowanie toru pomiarowego oraz określenie orientacyjnych parametrów badanego obiektu. Istotne jest, aby na wstępie zostało określone, czy badany jest przepływ gaz-ciecz, czy gaz-ciało stałe, gdyż ma to decydujące znaczenie na wybór sposobu oświetlenia obiektu [51].


Rysunek 53. przedstawia przykładową sekwencję kolejnych klatek dla przepływu gaz-ciecz. Jak widać kontrastowość obrazów nie jest duża, a obiekty znajdujące się na nich są stosunkowo niewielkich rozmiarów. Zachodzą zjawiska wzajemnego przenikania się obiektów, odbicia światła, efekt soczewki oraz inne niekorzystne sytuacje, które utrudniają analizę tego typu obrazów [52].



Rysunek 53. Przykładowa sekwencja kolejnych klatek dla przepływu gaz-ciecz.


W związku z tym, istotne jest aby podczas analizy tego typu przepływów nastąpił właściwy dobór oświetlenia oraz stopień czułości procedur analizy był na wysokim poziomie. Zbyt mocne oświetlenie doprowadza do zmniejszenia kontrastu gdyż, zarówno struktury gazowe znajdujące się w cieczy, jak i sama ciecz są przezroczyste. Różnica polega na stopniu przezroczystości obu stanów, więc dobór oświetlenia ma na celu maksymalnie wykorzystanie te cechy. Z oczywistych powodów istnieją również ograniczenia techniczne dotyczące samego oświetlenia, a związane są z koniecznością zastosowania chłodzenia konwekcyjnego w przypadku silnych źródeł światła. Dodatkowym ograniczeniem jest czułość świetlna kamery, która rejestruje obserwowane zjawisko. Zgranie tych wszystkich elementów wymaga wielu analiz i prób wykonanych bezpośrednio na badanym obiekcie.

Rysunek 54. przedstawia przykładową sekwencję kolejnych klatek dla przepływu gaz-ciało stałe. Kontrastowość obrazu jest zdecydowanie większa, co wynika z możliwości zastosowania oświetlenia o większym natężeniu. Faza stała znajdująca się na obrazie jest nieprzezroczysta, więc zwiększanie oświetlenia nie powoduje zacierania różnic między fazami. W związku z tym rośnie rola prawidłowego chłodzenia źródła światła. Ze względu na parametry kamery nie można zwiększać oświetlenia w sposób niekontrolowany. Zbyt duże oświetlenie spowoduje „oślepienie” kamery w przypadku, gdy na danej scenie ilość fazy stałej będzie stosunkowo niewielka.



Rysunek 54. Przykładowa sekwencja kolejnych klatek dla przepływu mieszaniny gaz-ciało stałe.

Rysunek 55. przedstawia przykładową sekwencję kolejnych klatek dla przepływu rzutowego mającego miejsce w długim kanale o przekroju kołowym.



Rysunek 55. Sekwencja kolejnych klatek dla przepływu rzutowego .

Reasumując cechy charakterystyczne badanych przepływów mieszanin gaz-ciecz oraz gaz-ciało stałe w aspekcie przetwarzania i rozpoznawania obrazów należy zauważyć, iż układu:

- gaz-ciecz
 - niski kontrast wymaga zastosowania większej czułości podczas analizy obrazów,
 - obiekty znajdujące się na scenach stosunkowo rzadko są dużych rozmiarów,
 - zachodzi częste zjawisko rozpadu obiektów na mniejsze lub bardzo wyraźna zmiana kształtu,
- gaz-ciało stałe
 - stosunkowo wysoki kontrast obrazów,
 - obiekty mają tendencje do rozpraszania się oraz czasami następuje ich grupowanie,
 - występuje zjawisko polegające na pojawianiu się dużych grup rozproszonych małych obiektów, które powodują efekt rozmycia przebiegu analizowanej cechy.

8.3. Obszar akwizycji danych

Zakłada się, iż obszar akwizycji danych ma kształt prostokątny. Wyboru obszaru prowadzonych analiz należy dokonywać w dwóch aspektach:


- położenie,
- wymiary (szerokość, wysokość).

Do elementów, które decydują o określeniu powyższych parametrów należy:

- rodzaj przyływu (gaz-ciecz, gaz-ciało stałe),

- parametry fizyczne przepływu (prędkość strumienia wymuszającego przepływ, stosunek ilościowy faz),
- parametry fizyczne użytych faz (np. gęstość, lepkość, napięcie powierzchniowe),
- rodzaj kanału (kształt, długość),
- charakter prowadzonych badań (wyznaczanie parametrów lokalnych lub globalnych).

Zagadnienie jest bardzo złożone i wymaga wielu eksperymentów empirycznych dokonanych na rzeczywistej aparaturze badawczej [53]. Wielokryterialność problemu wymaga znacznego poznania badanych zjawisk oraz konieczność dokonywania szeregu kompromisów [54]. Rysunek 56. przedstawia graficzną reprezentację obszarów akwizycji danych jakie podlegały badaniom.



Rysunek 56. Przyjęte podczas prowadzonych badań obszary akwizycji danych.

Obszar oznaczony jako **C1** jest przydatny podczas badania zjawisk globalnych. Ponieważ obejmuje cały dostępny obszar obserwowanego przepływu. Wyniki są silnie uśrednione, więc i fluktuacje zmian obliczonej cechy są niewielkie. W związku z tym przydatność tego obszaru jest ograniczona do bardzo szczególnych przypadków i jest on stosowany do wstępnej oceny obiektu.

Obszary **PP1** do **PP4** są bardzo interesujące z punktu widzenia przeprowadzonych eksperymentów. Ich cechą charakterystyczną jest obejmowanie swoim zasięgiem całej szerokości kanału, oraz stosunkowo wąski obszar uśredniania wzdłuż kierunku przepływu. Dzięki temu są one nieczułe na niesymetryczność poprzeczną zjawiska, gdyż uśredniają całą szerokość kanału. Mała długość badanego obszaru powoduje zwiększoną czułość na zmiany struktury występujące na różnych wysokościach kanału.

Obszary **PU1** do **PU4** zakładają jednorodność poprzeczną zjawiska, dzięki zmniejszonej powierzchni wykazują większą czułość, co pozwala wykrywanie drobniejszych obiektów typu *pojedyncze cząstki*.

Obszary **PA1** do **PA3** są bardzo specyficzne w swoim zastosowaniu. Dzięki nim możliwe jest wykrywanie np. zjawiska zmiany grubości struktury zwanej „filmem”. Praktyczne zastosowanie tych obszarów jest mocno ograniczone, a ich efektywność ograniczona do badania bardzo szczególnych przypadków przepływów.

Obszary **K1** i **K2** można traktować jako pewne modyfikacje obszaru oznaczonego jako **C1**. Mają one zastosowanie raczej nakierowane do badania zjawisk globalnych, ze względu na zwiększony wymiar wzdłużny. Wraz ze zmniejszaniem powierzchni obszaru następuje przeniesienie ciężaru zainteresowania w kierunku badania lokalnych zmian struktury.

Z punktu widzenia rozpoznawania struktury przepływu realizowanego poprzez analizę lokalnych zmian udziału jednej z faz, najbardziej właściwy okazały się obszary typu **PP2** oraz **PU2**. Są one umieszczone w bliskiej odległości nad złożem w stanie spoczynku, więc wszystkie zjawiska wynikające ze wymuszenia przepływu, nawet dla stosunkowo małych prędkości, są rejestrowane.

Jednocześnie nie zachodzi zjawisko zaburzenia pomiaru związane z zaburzeniem struktury w górnych warstwach kanału. Wielkość obszaru należy dobrać w zależności od warunków fizycznych przepływu. Nieprawidłowy dobór wielkości polegający na wybraniu np. zbyt małego obszaru powoduje wzrost czułości na zjawiska lokalne, ale jednocześnie zawęża zakres pomiarowy [55]. Efekt ten jest analogiczny do zmiany zakresu pomiarowego dowolnego czujnika lub całego urządzenia pomiarowego.

Przed dokonaniem wyboru wielkości i położenia analizowanego obszaru konieczne jest określenie miejsca, w którym zachodzą zjawiska charakterystyczne dla danego rodzaju badania oraz wyznaczyć wielkość obiektów, które występują w przepływie.

8.4. Definicje opracowanych cech

W poprzednich rozdziałach mowa była o sposobie przetwarzania i interpretowania ciągów wartości liczbowych reprezentujących sposób zmienności badanych cech. Ciągi wejściowe oznaczone jako $\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_m\}$ mogą reprezentować różnie definiowane cechy. Sposób ich określenia powinien jednak zapewnić możliwość klasyfikacji obiektów należących do różnych klas. Przedstawione poniżej opisy zawierają zapis formalny oraz charakterystykę właściwości cech opracowanych w celu rozpoznawania struktur przepływów mieszanin dwufazowych.

Wszystkie cechy obliczane są w prostokątnym obszarze. Na potrzeby tego rozdziału dla wszystkich cech przyjmuje się następujące oznaczenia:

(l, t) – współrzędne lewego górnego narożnika badanego obszaru,

(r, b) – współrzędne prawego dolnego narożnika badanego obszaru,

$p_{j,i}^k$ – wartość poziomu jasności piksela o współrzędnych j, i dla sceny o indeksie k ,

k – indeks iteracji sceny w badanej sekwencji obrazów,

j – indeks iteracji, $l \leq j \leq r$,

i – indeks iteracji, $t \leq i \leq b$.

Wartość poziomu jasności obliczana jest w następujący sposób:

$$p_{j,i}^k = \frac{RED(q_{j,i}^k) + GREEN(q_{j,i}^k) + BLUE(q_{j,i}^k)}{3} \quad (96)$$

gdzie:

$q_{j,i}^k$ - 24-bitowy kolor piksela o współrzędnych j, i dla sceny o indeksie k ,

$RED(q_{j,i}^k)$ - wartość składowej koloru czerwonego dla piksela $q_{j,i}^k$,

$GREEN(q_{j,i}^k)$ - wartość składowej koloru zielonego dla piksela $q_{j,i}^k$,

$BLUE(q_{j,i}^k)$ - wartość składowej koloru niebieskiego dla piksela $q_{j,i}^k$.

8.4.1. Średni udział jednej z faz

Cecha ta oznaczona została jako M i stanowi wartość średnią z poziomów jasności pikseli znajdujących się wewnątrz badanego obszaru

$$M_k = \frac{1}{(r-l)(b-t)} \sum_{j=l}^r \sum_{i=t}^b p_{j,i}^k \quad (97)$$

Jest to cecha mająca zastosowanie jako zarówno parametr lokalny, jak i globalny. W przypadku zastosowania lokalnego, tzn. dla stosunkowo małych obszarów, jest ona czuła na zjawiska mające niewielkie rozmiary, jednak bardzo szybko większe obiekty są w stanie wprowadzić ten parametr w stan nasycenia. Dla dużych obszarów występuje zjawisko silnego uśredniania, co powoduje wyraźne „spłaszczenie” wyników obserwacji.

8.4.2. Długość linii brzegowej

Cecha ta oznaczona została jako E i stanowi średni udział punktów brzegowych w stosunku do wszystkich punktów w danym obszarze.

$$E_k = \frac{1}{(r-l-2)(b-t-2)} \sum_{j=l-1}^{r-1} \sum_{i=t-1}^{b-1} edge(p_{j,i}^k) \quad (98)$$

gdzie:

$$edge(p_{j,i}^k) = \begin{cases} 1 & \text{gdy } \exists_{m \in \{-1,0,1\}} \exists_{n \in \{-1,0,1\}} p_{j,i}^k \neq p_{j+m,i+n}^k \\ 0 & \text{gdy } \forall_{m \in \{-1,0,1\}} \forall_{n \in \{-1,0,1\}} p_{j,i}^k = p_{j+m,i+n}^k \end{cases} \quad (99)$$

Jest to parametr o charakterze globalnym określający stopień rozdrobnienia obiektów na danej scenie. Wzrost ilości pikseli należących do brzegów w stosunku do wszystkich pikseli w danym obszarze oznacza zjawisko dyspersji.

8.4.3. Gradient lokalny

Cecha ta oznaczona została jako G i jest oparta na średniej różnicy poziomów jasności obliczanych między tym pikselami, a ich bezpośrednimi sąsiadami

$$G_k = \frac{1}{(r-l-2)(b-t-2)} \sum_{j=l-1}^{r-1} \sum_{i=t-1}^{b-1} \left(\frac{1}{8} \sum_{m=j-1}^{j+1} \sum_{n=i-1}^{i+1} |p_{m,n}^k - p_{j,i}^k| \right). \quad (100)$$

Charakter tej cechy jest lokalny, gdyż dotyczy tylko bezpośredniego sąsiedztwa pikseli. Jest to miara, za pomocą której badany jest stopień jednorodności sceny. Zdecydowany wzrost wartości tego parametru następuje w przypadku zwiększonej ilości bardzo drobnych obiektów, lub gdy duży obiekt rozpada się tworząc w tym czasie duży obszar zawierający wiele miejsc rozjaśnionych w wyniku rozproszenia fazy stałej.

8.4.4. Wariancja

Cecha ta oznaczona została jako V i obliczana jest jako średnia kwadratów różnicy poziomu jasności danego piksela i średniego poziomu jasności całego obszaru

$$V_k = \frac{1}{(r-l)(b-t)} \sum_{j=l}^r \sum_{i=t}^b (p_{j,i}^k - M_k)^2. \quad (101)$$

Jest ona miarą odchylenia poziomów jasności pikseli od wartości średniej badanego obszaru. Charakter tej cechy jest bardziej globalny ale może też być stosowany do oceny lokalnej. Cecha ta jest czuła na sytuację, w której obraz posiada duży kontrast tzn. piksele przyjmują głównie skraje poziomu jasności. Wzrost wartości tej cechy oznacza koalescencję obiektów z postaci rozmytej i rozproszonej fazy stałej do wyraźnych zwartych obiektów o dużym stopniu zaczernienia.

8.4.5. Posumowanie własności cech

W rozdziale tym zebrane zostały podstawowe informacje na temat własności opracowanych cech. Tabela 9. zawiera zestawienie cech wraz ze skróconą charakterystyką ich własności istotnych z punktu widzenia rozpoznawania struktur przepływu.

Tabela 9.

Zestawienie cech oraz ich skrócona charakterystyka

Cecha	Zakres (globalny/lokalny)	Charakterystyka
M	lokalny, globalny	wartość średnia, udział fazy stałej
E	globalny	długość linii brzegowej, dyspersja globalna
G	lokalny	stopień niejednorodności najbliższego otoczenia punktu, dyspersja lokalna
V	lokalny, globalny	odchylenie od wartości średniej, niejednorodność

Analizując poszczególne cechy istotnej jest aby pamiętać, iż amplituda impulsu stanowi względne zmiany danej cechy, natomiast szerokość impulsu odpowiada czasowi trwania zjawiska od minimum poprzez maksimum do kolejnego minimum przebiegu zmienności danej cechy.

Tabela 10. zawiera interpretację parametrów impulsów dla zdefiniowanych cech.

Tabela 10.

Interpretacja parametrów impulsów dla poszczególnych cech

Cecha	Amplituda impulsu		Szerokość impulsu	
	Wysoka	Niska	Duża	Mała
M	większa zmiana stopnia wypełnienia badanego obszaru, większe obiekty	mniejsza zmiana stopnia wypełnienia badanego obszaru, mniejsze obiekty	dłuższy czas zmiany stopnia wypełnienia, bardziej równomierne rozłożenie obiektów	krótszy czas zmiany stopnia wypełnienia, większe obiekty, lub większa prędkość poruszania się
E	pojawienie się dużej ilości drobnych obiektów następujące po jednorodnej scenie	pojawienie się małej ilości obiektów lub dużego i jednorodnego obiektu lub dyspersja	powolna zmiana homogeniczności sceny	nagła dyspersja lub szybki niewielki obiekt
G	pojawienie się dużego niejednorodnego na poziomie pojedynczych pikseli obiektu	mały obiekt lub niewielka zmiana niejednorodności lokalnej	powolny rozpad na poziomie lokalnym, rozproszenie obiektu do skali pojedynczych pikseli	nagły rozpad na poziomie lokalnym, rozproszenie obiektu do skali pojedynczych pikseli lub niewielki szybki obiekt
V	duża zmiana wartości średniej pikseli lub zdecydowana zmiana kontrastu obrazu poprzez zmianę ilości pikseli o skrajnych wartościach	mała zmiana wartości średniej pikseli lub nieznaczna zmiana kontrastu obrazu poprzez zmianę ilości pikseli o skrajnych wartościach	powolna zmiana kontrastu, fluktuacja niejednorodności wynikająca powolnej zmiany rozkładu obiektów na scenie	szybka zmiana kontrastu lub pojawienie się małego szybkiego obiektu

8.5. Sposób przetwarzania informacji oraz wyniki badań

W rozdziale tym zaprezentowane zostaną przykładowe wyniki akwizycji danych oraz ich wstępnego przetwarzania. Przeprowadzona zostanie również dyskusja nad sposobem interpretacji otrzymanych wyników.

8.5.1. Badane obiekty

We wszystkich przypadkach obrazy były rejestrowane kamerą wideo (25 fps). Obserwowane na zarejestrowanym filmie zjawisko jest przepływem dwufazowym mieszaniny gaz-ciało stałe. Analizie poddano ciągi liczb odpowiadające zmianom wartości badanych cech na przestrzeni 24-sekundowych odcinków czasu podzielonych na trzy równe odcinki czasowe. Wejściowym materiałem badawczym było 9 sekwencji wideo zapisanych w formacie AVI. Tabela **11.** zawiera listę sekwencji, którym na podstawie wizualnej oraz stochastycznej analizy eksperta, przypisano nazwy struktur przepływu. W podanych przykładach analizowany obszar znajdował się w prostokącie, którego narożniki mają następujące współrzędne (180, 255) – lewy górny, (281, 286) – prawy dolny. Obszar ten za każdym razem był dzielony na podobszary, w których dokonywano niezależnych analiz, co zwiększało pewność otrzymania rzeczywistych danych, gdyż przy każdej klasyfikacji brała udział większa ilość ciągów liczbowych. W prezentowanych wynikach eksperymentu zastosowano trzy różne wybrane podobszary, których wymiary liczone w pikselach są następujące: 10x10, 10x30, 50x30.

Tabela 11.

Lista sekwencji wideo poddanych badaniom

Nr	Nazwa pliku	Skrócona nazwa	Typ struktury	Podtyp
1	A1xB.AVI	A1	rzutowy	
2	A2xB.AVI	A2	korkowy	regularny
3	A3xB.AVI	A3		duże korki
4	A4xB.AVI	A4		rozpad korków
5	A5xB.AVI	A5		gęsty
6	A6xB.AVI	A6		blokowanie
7	C1.AVI	C1	transport	rzadki
8	C2.AVI	C2		jednorodny
9	C3.AVI	C3		niejednorodny

8.5.2. Wstępne przetwarzanie danych

Wartości zmierzonych cech podlegają wstępnemu przetwarzaniu mającemu na celu filtrację zakłóceń spowodowanych błędami akwizycji oraz odseparowanie informacji zbędnej. W tym celu zastosowano średnią przesuwaną:

$$\begin{aligned} i &= 1 \dots L \\ t &= 1 \dots m - W \\ \alpha_t &= \frac{1}{W} \sum_{k=t}^{t+W} \alpha_k, \end{aligned} \quad (102)$$

gdzie:

- i , – indeksy iteracji uśredniania,
- t – indeksy iteracji ciągu wejściowego,
- k – indeksy iteracji okna uśredniania,
- α_t – element ciągu wejściowego o indeksie t ,
- W – szerokość okna uśredniania,
- L – krotność uśrednienia,
- m – długość ciągu.

Dla wszystkich analizowanych sygnałów dokonano wygładzania metodą średniej przesuwanej przy zastosowaniu parametrów dobranych przez eksperta:


$$W = 3,$$

$$L = 1.$$

Ponadto wszystkie przebiegi zostały znormalizowane w sposób zapewniający, aby wartość cechy reprezentowała daną wielkość w ujęciu procentowym w stosunku do wartości maksymalnej.


W podanych przykładach analizowany obszar znajdował się w prostokącie, które narożniki mają następujące współrzędne: (180, 255) – lewy górny, (281, 286) – prawy dolny.

Rysunek 57. Przedstawia wykres zmian poziomów jasności (cecha M) dla sekwencji A1 (przepływ rzutowy). Kolorem niebieskim oznaczono sygnał wejściowy, natomiast kolor czerwony posiada wykres wygładzonego sygnału.




Rysunek 57. Wykres zmian poziomów jasności dla przepływu mieszaniny reprezentującej strukturę rzutową (sekwencja: A1, cecha: M , podobszary: 10x30).

Zastosowane wygładzanie spowodowało odfiltrowanie składowych o wyższych częstotliwościach, co spowodowało redukcję ilości impulsów przypadkowych wynikających z drobnych zakłóceń pomiaru. Rysunek 58. przedstawia efekt wygładzania dla trzech wybranych impulsów.



Rysunek 58. Wykresy zmian poziomów jasności dla przepływu mieszaniny reprezentującej strukturę rzutową (sekwencja: **A1**, cecha: **M**, podobszary: **10x30**) dla wybranych impulsów.

Rysunek 59. przedstawia mapę impulsów dla przepływu rzutowego, cechy **M**, podobszarów **10x30**. Kolorem niebieskim oznaczono impulsy przed wygładzeniem sygnału, a czerwonym po tej operacji.




Rysunek 59. Wykres mapy impulsów (sekwencja: **A1**, cecha: **M**, podobszary: **10x30**) dla sygnału przed uśrednianiem (niebieski) oraz po uśrednieniu (czerwony).

Wyraźnie widoczny jest efekt zmniejszenia amplitudy impulsów, co jest oczywiste biorąc pod uwagę charakter operacji jakiej dokonano. Równie łatwym do wytłumaczenia jest fakt zwiększenia szerokości impulsów, spowodowany „rozmyciem” wielu impulsów do postaci jednego – o czasie trwania równym sumie szerokości impulsów, z których powstał. Ogólną tendencję zmiany parametrów impulsów wynikającą z zastosowania średniej przesuwanej reprezentuje strzałka umieszczona na wykresie.

Wszystkie kolejne wykresy i rozważania dotyczyć już będą jedynie przebiegów wygładzonych.


Rysunek 60. przedstawia wykresy sygnałów dla 10-ciu różnych podobszarów leżących w obrębie analizowanego obszaru.



Rysunek 60. Wykresy sygnałów (sekwencja: **A1**, cecha: **M**, podobszary: **10x30**) dla 10-ciu różnych podobszarów tej samej wielkości.

Wyraźnie widać, iż zaprezentowane sygnały są zbliżone do siebie zarówno pod względem ekstremów lokalnych jak i kształtów samych przebiegów. Położenie podobszaru nie ma więc większego znaczenia dla analizowanych zjawisk. Widać, iż zmiany wartości cechy następują w podobny sposób. Nieznaczne różnice polegają na tym, iż osiągają one wartości ekstremalne w punktach czasowych przesuniętych względem siebie o niewielkie wartości.

Rysunek 61. przedstawia wykresy sygnałów dla: sekwencji A1 cechy M oraz podobszarów o wielkościach: 10x10, 10x30, 30x50.



Rysunek 61. Wykresy sygnałów (sekwencja: A1, cecha: M , podobszary: 10x10, 10x30, 30x50) dla różnych wielkości podobszarów.

Wykresy wszystkich przebiegów są podobne, a główna różnica polega na stopniu uśrednienia. Większy obszar oznacza większe uśrednienie, a co za tym idzie bardziej gładki przebieg zmienności danej cechy. Można również zauważyć

pewien spadek w zakresie amplitudy. Wartości maksymalne wraz ze wzrostem wielkości podobszarów maleją, a wartości minimalne rosną. Przyczyna jest oczywista, gdyż zjawisko o charakterze lokalnym na większym podobszarze zaznacza się w sposób mniej ostry.

8.5.3. Klasyfikacja impulsów

Rysunek 42. przedstawia graficzną definicję impulsu. Parametry opisujące obiekt tego typu są następujące:

x_i – położenie maksimum impulsu w ciągu wejściowym, impulsu o indeksie i ,

w_i – szerokość zbocza narastającego impulsu o indeksie i ,

v_i – szerokość zbocza opadającego impulsu o indeksie i ,

A_i – amplituda zbocza narastającego impulsu o indeksie i ,

B_i – amplituda zbocza opadającego impulsu o indeksie i .

Cechy A_i oraz B_i zostały sprowadzony do postaci:

$$\forall_{i=1,\dots,\Pi} C_i = \max(A_i, B_i) \quad (103)$$

gdzie:

i – indeks iteracji ciągu impulsów,

Π – długość ciągu impulsów.

Wynika to z faktu, iż przy badanych zjawiskach istotne jest określenie wielkości zmiany danego parametru, a nie kierunku tych zmian. W analogicznym sposobie rozumowania uznano również, że dla badanych przebiegów nie jest istotne rozróżnianie czasu narastania i opadania, lecz sumaryczny czas trwania impulsu


$$u_i = w_i + v_i \quad (104)$$

Ostatecznie brane są pod uwagę dwie cechy:

C – amplituda impulsu,


u – czas trwania impulsu.

Przestrzeń cech w tym przypadku stała się płaszczyzną dwuwymiarową. Rysunek 62. przedstawia graficzną reprezentację przykładowego sposobu segmentacji płaszczyzny decyzyjnej na 4 obszary. Umieszczając impulsy na płaszczyźnie dwuwymiarowej można dokonać ich klasyfikacji.



Rysunek 62. Przykładowy sposób podziału płaszczyzny decyzyjnej C - u na obszary decyzyjne klasyfikacji impulsów.

Kierując się parametrami A oraz u , dokonuje się klasyfikacji polegającej na przypisaniu kolejnym impulsom obszarów, w których się znajdują. Klasyfikacja struktury przepływu odbywa się na zasadzie oceny ilości lub udziału impulsów należących do poszczególnych obszarów dla danego przepływu.




Rysunek 63. Mapa sklasyfikowanych impulsów należących do różnych struktur przepływu.

Rysunek 63. przedstawia przykład klasyfikacji impulsów należących do różnych rodzajów przepływów. Punkty na wykresie oznaczają pojedyncze impulsy, kolory natomiast odpowiadają klasyfikacji do różnych obszarów. Kształty punktów należy interpretować jako przynależność do różnych struktur przepływu.

Sposób definicji obszarów decyzyjnych jest uzależniony od badanej cechy (M , E , G , V), wstępnego przetwarzania (ilość iteracji i szerokość okna uśredniania), wielkości badanych podobszarów (10x10, 10x30, 30x50). Obszary należy dobierać z udziałem eksperta w sposób eksperymentalny.

Rysunek 64. przedstawia przykładowy sygnał oraz odpowiadającą mu mapę impulsów. Sklasyfikowane impulsy zostały wyróżnione kolorami odpowiadającymi kolorom zdefiniowanych obszarów decyzyjnych.




Rysunek 64. Przykład wykresu sygnału oraz odpowiadającej mu mapie impulsów opisującej strukturę A6 dla cechy M w obszarze 10×30 z podziałem na sklasyfikowane impulsy.

W celu prezentacji wyników posłużono się dziewięcioma sekwencjami wideo zawierającymi przepływy dwufazowe mieszaniny gaz-ciało stałe. Sekwencje te zostały oznaczone kolejno A1, A2, A3, A4, A5, A6, C1, C2, C3. (Tabela 11.).

8.5.4. Obiekty badań

Badaniom podlegały przepływy dwufazowe mieszaniny gaz-ciało stałe. Ciało stałe było sypanie i nieprzezroczyste, o ziarnach, których rozrzut średnicy nie przekraczał 30%. Jako gaz zastosowano powietrze. Parametrami regulowanymi była prędkość gazu oraz ilość ciała stałego znajdującego się w kanale. Rysunek 65. przedstawia przykładowe pojedyncze klatki z przepływów, które zostały przebadane, i dla których wyniki zostały zaprezentowane w niniejszej pracy. Zgodnie za główną tezę pracy klasyfikacja powinna być prowadzona na podstawie badania cech sekwencji obrazów reprezentujących dane zjawisko. W związku z tym zaprezentowane obrazy są zamieszczone tylko w celach poglądowych mających, w miarę możliwości, przybliżyć badane obiekty.



A1 - rzutowy




A2 – korki regularne



A3 – korki duże



A4 – korki rozpadające się



A5 – korki gęste



A6 – korki blokowanie



C1 – transport rzadki



C2 – transport jednorodny



C3 – transport niejednorodny

Rysunek 65. Przykładowe pojedyncze sceny z badanych przepływów.

8.5.5. Wyniki prowadzonych badań

Badania prowadzone były na trzech sekwencjach o liczebności 200 scen każda, co odpowiada 8 sekundowym czasom obserwacji. Obiektami było 9 przepływów mieszanin gaz-ciało stałe. Przeprowadzone analizy dotyczyły czterech cech (M , E , G , V). Dla każdej z nich przeanalizowano trzy różne wielkości podobszarów (10x10, 10x30, 30x50). Różne wielkości obszarów oznaczały różne ilości zestawów ciągów wejściowych⁸:

10x10 – 30 ciągów,

10x30 – 10 ciągów,

30x50 – 2 ciągi.

W rezultacie przeprowadzona analiza dotyczyła 324 zestawów ciągów wejściowych, co odpowiada 4536 ciągom wejściowych o długości 200 elementów każdy.


Ze względu na ograniczoną objętość pracy zaprezentowane zostaną zbiorcze wyniki dla wszystkich dziewięciu przepływów, wszystkich czterech cech i dla wybranych wielkości podobszarów. Wyniki zostały oznaczone dwoma parametrami: rodzaj podobszarów: {10x10, 10x30, 30x50} oraz badana cecha: { M , E , G , V }.

Prezentowane wyniki składają się z następujących elementów: oznaczenie wielkości podobszarów i nazwa cechy, mapa impulsów z zaznaczonymi obszarami decyzyjnymi oraz impulsami z wszystkich przepływów, wykresy obrazujące ilości impulsów sklasyfikowanych w ujęciu ilościowym, udziału ilościowego i dla poszczególnych obszarów, mapa impulsów obrazująca charakterystyczne efekty klasyfikacji grup przepływów, tabeli reguł decyzyjnych klasyfikujących obiekty oraz uwagi i wnioski dotyczące badanego przypadku.

⁸ Zestaw ciągów wejściowych odnosi się do grupy ciągów odpowiadających danej sekwencji, dla jednej cechy i grupy podobszarów o określonej wielkości.


8.5.5.1. Analiza wyników dla cechy M i podobszarów 10x30

Cecha M określa udział fazy stałej. Podobszary o wymiarach 10x30 pikseli oznaczają prowadzenie akwizycji danych w obszarze prostokątów zawierających 300 pikseli. Ze względu na wielkość całego badanego obszaru, ilość ciągów wejściowych wynosi 10. Rysunek 66. przedstawia mapę impulsów oraz zaznaczone obszary decyzyjne oznaczone w legendzie wykresu jako: IN(1,3) I-1, IN(1,3) II-1, IN(1,3) III-1, IN(1,3) IV-1. Serie impulsów zostały oznaczone wg następującej konwencji: A1xB (M) 1-200, gdzie A1xB – nazwa pliku zawierającego sekwencję oznaczoną jako A1, (M) – analiza wykonana przy zastosowaniu cechy M , 1-200 – dane dla serii scen od numeru 1 do 200.



Rysunek 66. Mapa impulsów z zaznaczonymi obszarami decyzyjnymi dla cechy M i podobszarów o wielkości 10x30 pikseli.

Rysunek 67. przedstawia wykresy zawierające wynik klasyfikacji impulsów do poszczególnych podobszarów. Wykresy te zostały przedstawione w trzech ujęciach (1) – ilości bezwzględne, (2) – udziały w ujęciu procentowym, (3) - ilości bezwzględne dla poszczególnych obszarów decyzyjnych.



Rysunek 67. Wykresy zawierające wyniki klasyfikacji impulsów do poszczególnych obszarów decyzyjnych reprezentujących specyficzne właściwości przepływów dla cechy M i podobszarów o wielkości 10x30 pikseli.

Tabela 12. zawiera listę reguł decyzyjnych pozwalających klasyfikować obiekty utworzoną na podstawie przedstawionych wyników.


Tabela 12.

Reguły decyzyjne dla cechy M i podobszarów 10x30.

Numer klasy	Obiekty należące do klasy	Reguły							
		I [%]		II [%]		III [%]		IV [%]	
		min	max	min	max	min	max	min	max
1	A1	45	80	30	50	0	2	0	1
2	A2, A3, A4, A5	45	80	20	50	2	8	0	8
3	A6	0	45	30	60	8	20	8	20
4	C1, C2	90	100	0	1	0	1	0	1
5	C3	80	95	2	20	0	1	0	1

gdzie: I, II, III, IV – oznaczają kolejno obszary decyzyjne: IN(1,3) I-1, IN(1,3) II-1, IN(1,3) III-1, IN(1,3) IV-1, min, max – wartości minimalne

i maksymalne w ujęciu procentowym. Reguły tworzone są przy zastosowaniu operatora koniunkcji. Rysunek 68. przedstawia mapę impulsów dla obiektów charakterystycznych oraz odpowiadające im wyniki klasyfikacji.




Rysunek 68. Mapa impulsów dla obiektów charakterystycznych w swojej klasie oraz wykres wyników klasyfikacji impulsów dla tych obiektów (cecha M , podobszary o wielkości 10x30 pikseli).

Za pomocą cechy M dla obszarów 10x30 można rozróżnić 5 klas. Największa nierozróżnialna grupa obiektów są to przepływy korkowe. Z przeprowadzonych obserwacji wynika, iż różnice wizualne między przepływami korkowymi różnych typów są niewielkie. W związku z tym nie należało oczekiwać zbyt wyraźnych efektów klasyfikacji w tej grupie. Możliwe by było rozróżnienie grup obiektów: $\{A2, A3\}$ oraz $\{A4, A5\}$ za pomocą obszaru IV, jednak uznano iż są to zbyt słabe podstawy do konstrukcji takiej reguły klasyfikującej. Bardzo wyraźnie została odróżniona grupa $\{C1, C2, C3\}$ reprezentująca przepływy transportowe od pozostałych obiektów. Równie zdecydowanie został sklasyfikowany obiekt A6, dzięki obszarowi IV. Podsumowując można wyrazić ocenę, iż dla podobszarów o wielkości 10x30 pikseli cecha M dobrze spełniła swoje zadanie i pozwoliła na separację pięciu klas z dziewięciu badanych obiektów.


8.5.5.2. Analiza wyników dla cechy E i podobszarów 50x30

Cecha E określa udział pikseli należących do brzegu. Podobszary o wymiarach 50x30 pikseli oznaczają prowadzenie akwizycji danych w obszarze prostokątów zawierających 1500 pikseli. Ze względu na wielkość całego badanego obszaru, ilość ciągów wejściowych wynosi 2. Rysunek 69. przedstawia mapę impulsów oraz zaznaczone obszary decyzyjne oznaczone w legendzie wykresu jako: IN(1,3) I-1, IN(1,3) II-1, IN(1,3) III-1, IN(1,3) IV-1, IN(1,3) V-1. Serie impulsów zostały oznaczone wg następującej konwencji: A1xB (E) 1-200, gdzie A1xB – nazwa pliku zawierającego sekwencję oznaczoną jako A1, (E) – analiza wykonana przy zastosowaniu cechy E , 1-200 – dane dla serii scen od numeru 1 do 200.



Rysunek 69. Mapa impulsów z zaznaczonymi obszarami decyzyjnymi dla cechy E i podobszarów o wielkości 50x30 pikseli.

Rysunek 70. przedstawia wykresy zawierające wynik klasyfikacji impulsów do poszczególnych podobszarów. Wykresy te zostały przedstawione w trzech ujęciach (1) – ilości bezwzględne, (2) – udziały w ujęciu procentowym, (3) - ilości bezwzględne dla poszczególnych obszarów decyzyjnych.



Rysunek 70. Wykresy zawierające wyniki klasyfikacji impulsów do poszczególnych obszarów decyzyjnych reprezentujących specyficzne właściwości przepływów dla cechy E i podobszarów o wielkości 50x30 pikseli.


Tabela 13. zawiera listę reguł decyzyjnych pozwalających klasyfikować obiekty utworzoną na podstawie przedstawionych wyników.

Tabela 13.

Reguły decyzyjne dla cechy E i podobszarów 50x30.

Numer klasy	Obiekty należące do klasy	Reguły									
		I [%]		II [%]		III [%]		IV [%]		V [%]	
		min	max	min	max	min	max	min	max	min	max
1	A1	3	10	0	2	15	30	15	30	30	60
2	A2, A3, A4, A5	3	20	4	30	2	40	25	70	5	30
3	A6	0	3	0	2	20	50	10	30	40	70
4	C1	95	100	0	1	0	1	0	1	0	1
5	C2	75	95	5	25	0	1	0	1	0	1
6	C3	15	30	60	85	2	10	0	1	0	1

gdzie: I, II, III, IV, V – oznaczają kolejno obszary decyzyjne: IN(1,3) I-1, IN(1,3) II-1, IN(1,3) III-1, IN(1,3) IV-1, IN(1,3) V-1, min, max – wartości minimalne i maksymalne w ujęciu procentowym. Reguły tworzone są przy zastosowaniu operatora koniunkcji. Rysunek 71. przedstawia mapę impulsów dla obiektów charakterystycznych oraz odpowiadające im wyniki klasyfikacji impulsów.




Rysunek 71. Mapa impulsów dla obiektów charakterystycznych w swojej klasie oraz wykres wyników klasyfikacji impulsów dla tych obiektów (cecha E , podobszary o wielkości 50x30 pikseli).

Cecha E dla podobszarów o wielkości 50x30 pikseli dokonuje separacji obiektów na 6 klas. W przeciwieństwie do poprzedniego przypadku możliwe stało się zdecydowane rozpoznanie wszystkich obiektów z grupy $\{C1, C2, C3\}$. Należy zwrócić uwagę, iż badana cecha bardzo wyraźnie separuje obiekt $C1$ od grupy $\{A2, A3, A4, A5\}$ za pomocą obszaru II, co dla cechy M stanowiło pewien problem. Z drugiej strony, obiekty $A1$ i $A6$ nie są już tak wyraźnie rozróżnialne, a w przypadku zastosowania cechy M byłoby to niezwykle proste i jednoznaczne. Pozostałe efekty klasyfikacji są podobne do cechy M dla podobszarów 10x30. Biorąc pod uwagę dużą wielkość podobszarów, co się wiąże ze znacznym uśrednieniem wartości cechy oraz duże właściwości separacyjne, należy podkreślić znaczną skuteczność tej cechy.


8.5.5.3. Analiza wyników dla cechy G i podobszarów 50x30

Cecha G określa stopień niejednorodności najbliższego otoczenia pikseli. Podobszary o wymiarach 50x30 pikseli oznaczają prowadzenie akwizycji danych w obszarze prostokątów zawierających 1500 pikseli. Ze względu na wielkość całego badanego obszaru, ilość ciągów wejściowych wynosi 2. Rysunek 72. przedstawia mapę impulsów oraz zaznaczone obszary decyzyjne oznaczone w legendzie wykresu jako: IN(1,3) I-1, IN(1,3) II-1, IN(1,3) III-1, IN(1,3) IV-1. Serie impulsów zostały oznaczone wg następującej konwencji: A1xB (G) 1-200, gdzie A1xB – nazwa pliku zawierającego sekwencję oznaczoną jako A1, (G) – analiza wykonana przy zastosowaniu cechy G , 1-200 – dane dla serii scen od numeru 1 do 200.



Rysunek 72. Mapa impulsów z zaznaczonymi obszarami decyzyjnymi dla cechy G i podobszarów o wielkości 50x30 pikseli.

Rysunek 73. przedstawia wykresy zawierające wynik klasyfikacji impulsów do poszczególnych podobszarów. Wykresy te zostały przedstawione w trzech ujęciach (1) – ilości bezwzględne, (2) – udziały w ujęciu procentowym, (3) - ilości bezwzględne dla poszczególnych obszarów decyzyjnych.



Rysunek 73. Wykresy zawierające wyniki klasyfikacji impulsów do poszczególnych obszarów decyzyjnych reprezentujących specyficzne właściwości przepływów dla cechy G i podobszarów o wielkości 50x30 pikseli.

Tabela 14. zawiera listę reguł decyzyjnych pozwalających klasyfikować obiekty utworzoną na podstawie przedstawionych wyników.


Tabela 14.

Reguły decyzyjne dla cechy G i podobszarów 50x30.

Numer klasy	Obiekty należące do klasy	Reguły							
		I [%]		II [%]		III [%]		IV [%]	
		min	max	min	max	min	max	min	max
1	A1	8	20	40	80	20	50	0	2
2	A2, A3, A4, A5	15	40	2	15	40	80	2	30
3	A6	0	8	15	40	50	100	0	2
4	C1, C2	70	100	0	2	0	2	0	2
5	C3	60	95	5	20	0	2	0	2

gdzie: I, II, III, IV – oznaczają kolejno obszary decyzyjne: IN(1,3) I-1, IN(1,3) II-1, IN(1,3) III-1, IN(1,3) IV-1, min, max – wartości minimalne

i maksymalne w ujęciu procentowym. Reguły tworzone są przy zastosowaniu operatora koniunkcji. Rysunek 74. przedstawia mapę impulsów dla obiektów charakterystycznych oraz odpowiadające im wyniki klasyfikacji impulsów.




Rysunek 74. Mapa impulsów dla obiektów charakterystycznych w swojej klasie oraz wykres wyników klasyfikacji impulsów dla tych obiektów (cecha G , podobszary o wielkości 50×30 pikseli).

Przy zastosowaniu cechy G dla podobszarów o wielkości 50×30 podzielono badane obiekty na 5 klas. Bardzo wyraźnie został odseparowany obiekt A1, co się stało głównie dzięki obszarowi II. Obiekt A6 zawdzięcza swoją unikalność obszarowi II, który oddzielił go od C1 oraz obszarowi IV pozwalającemu odróżnić go od obiektów z grupy $\{A2, A3, A4, A5\}$ należących do klasy oznaczonej jako 2. Obiekty z grupy $\{C1, C2\}$ pozostały nie rozróżnialne i znalazły się w klasie 4. Rozróżnienie ich byłoby możliwe przy dodaniu jeszcze jednego obszaru decyzyjnego, który podzieliłby obszar I na dwie części. Dosyć dyskusyjna byłaby próba rozpoznawania obiektów z grupy $\{A2, A3, A4, A5\}$ za pomocą obszaru IV. Byłby to wprawdzie możliwe, ale ze zbyt dużym ryzykiem błędnej klasyfikacji. Reasumując cecha ta wykazała dobry poziom separacji obiektów, interesujące właściwości szczególnie w zakresie rozpoznawania przepływów rzutowych, co biorąc pod uwagę definicję cechy jest dosyć naturalne.


8.5.5.4. Analiza wyników dla cechy V i podobszarów 10x10

Cecha V określa stopień odchylenia poziomu jasności pikseli od wartości średniej. Podobszary o wymiarach 10x10 pikseli oznaczają prowadzenie akwizycji danych w obszarze prostokątów zawierających 100 pikseli. Ze względu na wielkość całego badanego obszaru, ilość ciągów wejściowych wynosi 30. Rysunek 75. przedstawia mapę impulsów oraz zaznaczone obszary decyzyjne oznaczone w legendzie wykresu jako: IN(1,3) I-1, IN(1,3) II-1, IN(1,3) III-1, IN(1,3) IV-1, IN(1,3) V-1. Serie impulsów zostały oznaczone wg następującej konwencji: A1xB (V) 1-200, gdzie A1xB – nazwa pliku zawierającego sekwencję oznaczoną jako A1, (V) – analiza wykonana przy zastosowaniu cechy V , 1-200 – dane dla serii scen od numeru 1 do 200.



Rysunek 75. Mapa impulsów z zaznaczonymi obszarami decyzyjnymi dla cechy V i podobszarów o wielkości 10x10 pikseli.

Rysunek 76. przedstawia wykresy zawierające wynik klasyfikacji impulsów do poszczególnych podobszarów. Wykresy te zostały przedstawione w trzech ujęciach (1) – ilości bezwzględne, (2) – udziały w ujęciu procentowym, (3) - ilości bezwzględne dla poszczególnych obszarów decyzyjnych.



Rysunek 76. Wykresy zawierające wyniki klasyfikacji impulsów do poszczególnych obszarów decyzyjnych reprezentujących specyficzne właściwości przepływów dla cechy V i podobszarów o wielkości 10x10 pikseli.

Tabela 15. zawiera listę reguł decyzyjnych pozwalających klasyfikować obiekty utworzoną na podstawie przedstawionych wyników.


Tabela 15.

Reguły decyzyjne dla cechy V i podobszarów 10x10.

Numer klasy	Obiekty należące do klasy	Reguły									
		I [%]		II [%]		III [%]		IV [%]		V [%]	
		min	max	min	max	min	max	min	max	min	max
1	A1, C3	0	5	40	80	15	40	5	20	0	1
2	A2,A3,A4,A5,A6	5	30	10	50	15	40	20	35	0	8
3	C1	0	5	80	100	0	2	0	5	0	2
4	C2	0	5	75	95	2	15	0	5	0	8

gdzie: I, II, III, IV, V – oznaczają kolejno obszary decyzyjne: IN(1,3) I-1, IN(1,3) II-1, IN(1,3) III-1, IN(1,3) IV-1, IN(1,3) V-1, min, max – wartości

minimalne i maksymalne w ujęciu procentowym. Reguły tworzone są przy zastosowaniu operatora koniunkcji. Rysunek 77. przedstawia mapę impulsów dla obiektów charakterystycznych oraz odpowiadające im wyniki klasyfikacji impulsów.



Rysunek 77. Mapa impulsów dla obiektów charakterystycznych w swojej klasie oraz wykres wyników klasyfikacji impulsów dla tych obiektów (cecha V , podobszary o wielkości 10×10 pikseli).

Cecha V dla podobszarów o wielkości 10×10 pozwoliła na rozróżnienie 4 klas. Jest to wynik stosunkowo słaby. Przyczyn tego faktu należy szukać w braku zdolności do rozróżniania obiektów A1 i C3. Biorąc pod uwagę definicję tej cechy oraz zaprezentowane przykładowe obrazy struktury rzutowej oraz transportu niejednorodnego, taka sytuacja przestaje dziwić. Ze względu na fakt, iż w pozostałych przypadkach nie wystąpiły podobne efekty, nie należy upatrywać w tym problemu. Obszar I wyraźnie separuje obiekt A1 od grupy {A2, A3, A4, A5}. Wszystkie obiekty z grupy {C1, C2, C3} są wyraźnie rozróżnialne w obrębie tej grupy. Wszystkie zdefiniowane obszary mają do spełnienia pewne zadania separacyjne, które realizują w sposób właściwy. Ogólnie należy ocenić, iż cecha ta nie odbiega znacznie od pozostałych, poza przypadkiem nie rozróżniania obiektów A1 i C3.

8.6. Wnioski w zakresie rozpoznawania struktur przepływu

Na podstawie otrzymanych wyników możliwe jest dokonanie szeregu ocen oraz wyciągnięcie pewnych wniosków na temat badanego obiektu. Analiza zarówno udziału procentowego, jak i bezwzględnej ilości impulsów poszczególnych typów dostarcza cennych informacji o zachodzących procesach. Informacje te mają postać wysoko przetworzoną, gdyż nie dotyczą prostych parametrów obrazów, lecz jednocześnie nie wymagają bardzo czasochłonnych obliczeń, co jest ich dodatkowym atutem. Informacja wynikowa jest ściśle związana ze specyfiką badanego zjawiska.

W zaprezentowanych analizach wyraźnie widać związek między zmianą struktury przepływu oraz otrzymanymi wynikami. Struktura przepływu jest bardzo złożonym pojęciem, dlatego też jej opis wymaga zagłębienia się w zagadnienia związane z rozkładem tego zjawiska na części składowe. W zaprezentowanej metodzie badano obiekty będące elementami składowymi przepływu. Zgodnie z tezą pracy są to elementy wyznaczone na bazie dynamiki, gdyż tam leży istota struktury przepływu. Na podstawie analizy zamieszczonych przykładów można wyciągnąć następujące wnioski.


Zastosowane cechy wykazują zdolności do klasyfikacji obiektów typu przepływu mieszanin dwufazowych na poziomie bardzo zadowalającym. Różnorodność cech zapewnia możliwość rozpoznawania szerokiej gamy struktur. Tabela 16. przedstawia zestawienie własności separacyjnych dla analizowanych przypadków.

Tabela 16.

Zestawienie klasyfikacji struktur przepływu.

Badany przypadek	Obiekty								
	A1	A2	A3	A4	A5	A6	C1	C2	C3
<i>M</i> 10x30	1	2				3	4		5
<i>E</i> 50x30	1	2				3	4	5	6
<i>G</i> 50x30	1	2				3	4		5
<i>V</i> 10x10	1	2				3		4	1

Rysunek 78. przedstawia wyniki klasyfikacji impulsów w ujęciu udziału procentowego dla przypadków $M 10 \times 30$ i $G 50 \times 30$.



Rysunek 78. Wyniki klasyfikacji impulsów dla przypadków $M 10 \times 30$ oraz $G 50 \times 30$.

Rozróżnialność obiektu C3 od grupy $\{C1, C2\}$ jest wyraźnie wyższa dla $G 50 \times 30$. Podobnie obiekt A1 jest lepiej separowany od obiektów z grupy $\{C2, C3, C4, C5\}$ niż dla $M 10 \times 30$.


Przypadek $E 50 \times 30$ wykazał się największą selektywnością. Rozróżniono w nim aż 6 klas. Pewną wadą cechy E jest stosunkowo duży nakład obliczeniowy, gdyż wymaga ona wyznaczenia brzegów obiektów znajdujących się na scenie. Należy wziąć pod uwagę jeszcze jeden aspekt wykorzystania przedstawionych cech. Nie zawsze możliwe jest uzyskanie obrazów posiadających wysoki stopień kontrastu. W przypadku takich mediów jak woda i powietrze może wystąpić problem wyraźnej zmiany zawartości histogramu poziomów jasności. Wąski zakres zmian poziomu jasności pikseli utrudnia poprawne wyznaczenie niektórych cech, jak np. brzegu obiektów. Z kolei w przypadku zastosowania kamery pozwalającej na akwizycję obrazów z prędkością ponad 1000 fps. oraz z krótkim czasem

otwarcia przesłony, problemy te przestają istnieć, gdyż obrazy są o wysokim kontraście i praktycznie bez efektów rozmycia na granicy faz.

Reasumując należy stwierdzić, iż prezentowane cechy stanowią całkowicie wystarczający element klasyfikujący struktury przepływu. Metoda oparta na badaniu impulsów zbudowanych na bazie przebiegów zmienności tych cech dokonuje poprawnej klasyfikacji i nie wykazuje niekorzystnych efektów w postaci długiego czasu obliczeń, kłopotów interpretacyjnych w zakresie wyników pomiarów, czy innych problemów związanych z operowaniem na danych o wysokim stopniu przetworzenia [91].

8.7. Zastosowane narzędzia


W celu realizacji opisanych zadań opracowano i zastosowano oprogramowanie opisane w tym rozdziale. Rysunek 79. przedstawia zrzut ekranowy programu analizy sygnałów, dzięki któremu prowadzono pierwsze badania z zakresu przetwarzania danych wejściowych dla cechy opisującej udział fazy stałej.



Rysunek 79. Przykładowy zrzut ekranowy z programu realizującego algorytmy rozpoznawania struktur przepływu mieszanin dwufazowych.

Program ten był stosowany w pierwszej fazie opracowywania metody i miał na celu weryfikację poprawności przetwarzania danych zgodnie opracowanymi metodami [4]. Narzędzie to miało na celu przetestowanie algorytmów wstępnego przetwarzania danych oraz stanowiło pierwszy krok w zakresie badania podejścia opierającego się na wyznaczaniu impulsów.

Rysunek 80. zawiera zrzut ekranowy programu do badania metody klasyfikacji impulsów.




Rysunek 80. Przykładowy zrzut ekranowy z programu realizującego algorytmy klasyfikacji impulsów.

Program ten miał na celu testowanie metody w zakresie klasyfikacji impulsów. Badania w tym zakresie pozwoliły na weryfikację poprawności algorytmów rozpoznawania impulsów na bazie różnych zestawów cech. Ostateczna postać wektora cech reprezentująca impuls została wypracowana na bazie wielu analiz i badań wpływu różnych kombinacji cech na zdolności impulsów do właściwego reprezentowania obiektów.

Badano również różne zestawy sekwencji wideo oraz sposoby akwizycji danych. Miało to na celu jak najlepsze dopasowanie sposobu filmowania przepływów do założeń metody i algorytmów. Przeprowadzono również serię testów mających na celu wybór optymalnego obszaru, który będzie poddawany analizie, co miało duże znaczenie dla poprawności prowadzenia eksperymentu mającego na celu potwierdzenie stawianych tez.

Rysunek 81. zawiera zrzut ekranowy programu do rozpoznawania struktur przepływów metodą klasyfikacji impulsów.



Rysunek 81. Przykładowy zrzut ekranowy z programu realizującego algorytmy rozpoznawania struktur przepływu mieszanin dwufazowych metodą klasyfikacji impulsów.

Jest to ostateczny program służący do praktycznej realizacji metody. Zaimplementowano w nim wszystkie opisane oraz pominięte, ze względu na nieistotność dla samej prezentacji, algorytmy przetwarzania obrazów graficznych [96], operowania na strukturach danych [95], analizy sygnałów [39] oraz klasyfikacji impulsów oraz struktur przepływu. Jest to oprogramowanie o znaczącym stopniu złożoności jednak ze względu na to, że jest to tylko narzędzie i nie zawiera elementów nowości, istotnych z punktu widzenia tej pracy, nie zostaną opisane w sposób bardziej szczegółowy.

Wszystkie zaprezentowane w tym rozdziale programy zostały opracowane na potrzeby niniejszej pracy w całości przez autora tego opracowania. Zarówno projekt jak i implementacja została wykonana w modelu obiektowym [14][15][16] przy zastosowaniu narzędzia: Borland C++ Builder 3.0 [6][7][30][64][74].

9. PRAKTYCZNE ZASTOSOWANIE METODY ROZPOZNAWANIA ŚLADÓW DYNAMICZNYCH

Kryminalistyka jest dziedziną nauki zajmującą się metodami ustalania faktu przestępstwa, sposobu jego popełnienia i wykrywania sprawców [31]. Bardzo ważną dziedziną kryminalistyki jest mechanoskopia zajmująca się między innymi badaniem śladów narzędzi. Narzędzia ze względu na mechanizm ich działania można podzielić na trzy grupy: skrawające, tnące (jedno i dwuostrzowe) oraz zgniatające. W przypadku użycia narzędzia tnącego (np. nożyc) powstają ślady dynamiczne, gdyż ostrze przesuwając się po powierzchni rozcięcia pozostawia na niej rysy charakterystyczne dla danego egzemplarza. Ze względu na fakt iż w pewnym procencie przypadków przestępstw narzędzia są używane nie zgodnie z istotą ich działania, podczas klasyfikacji śladów ważny jest faktyczny sposób ich użycia a nie przeznaczenie. Innym zagadnieniem leżącym w zakresie mechanoskopii jest rozpoznawanie śladów powstałych w wyniku przejścia pocisku przez lufę broni palnej.

9.1. Wstęp

Badanie śladów sprowadza się w efekcie do przypisania danemu narzędziu śladu pozostawionemu na miejscu popełnienia przestępstwa. Dotychczasowe metody rozpoznawania dynamicznych śladów narzędzi, polegają na ekspertyzie wizualnej dokonywanej przez eksperta mechanoskopii. Posługuje się on mikroskopem porównawczym, przy pomocy którego można uzyskać obraz jednocześnie dwóch śladów, a następnie przesuwając odpowiednio próbki zestawiać cechy wspólne.

Najistotniejszy powód, dla którego zautomatyzowanie procesu wykonywania ekspertyz jest ważne, polega na trudności wykonywania badań na dużej ilości materiału porównawczego. Nawet wstępna selekcja stanowi bardzo poważną


pomoc, a w niektórych przypadkach wręcz jest jedyną możliwością przeprowadzenia stosownych analiz. Zdarzają się przypadki zaniechania dokonywania ekspertyzy z powodu ogromu materiału porównawczego, gdyż jego przebadanie może zająć wiele miesięcy, a nawet lat. Istnieje bardzo bogaty zasób materiału porównawczego dotyczący śladów powstałych na pociskach, ale ze względu na olbrzymią ilość broni palnej występującej w skali całego kraju, przeszukiwanie całego dostępnego zbioru jest rzeczą nierealną.

Ze względu na duże doświadczenie ekspertów wykonujących te badania, ekspertyzy tego typu stanowią silny materiał dowodowy i niezwykle rzadko są podważane w czasie procesu sądowego. Jednak w razie, gdy ekspertyza zostanie podważona istnieje pewien problem dotyczący weryfikacji oceny ekspertów. Wynika to z faktu, iż konkluzją ekspertyzy jest stwierdzenie czy dokonane porównanie daje podstawy do przypisania danemu narzędziu śladu zabezpieczonego na miejscu popełnienia przestępstwa. Cały protokół zawiera również materiał fotograficzny z oznaczonymi cechami, które pozwoliły na wydanie opinii. Mimo ogromnych starań w kierunku obiektywizmu wydawanych ekspertyz są one z natury rzeczy subiektywne. Dokonywana ocena jest czysto jakościowa, a więc nie podlega porównaniu z innymi ocenami dokonywanymi np. przez innych ekspertów. Skutkiem tego jest problem występujący podczas rozpatrywania przez sąd dwóch sprzecznych ekspertyz. Zadanie sądu polega na wyważeniu, która z ocen jest bliższa prawdy. Bez możliwości ilościowego porównywania wyników zdecydowanie się na przyjęcie którejś z ekspertyz jest zadaniem bardzo trudnym i często prowadzi do zlecenia dokonania ekspertyzy przez trzecie, niezależne laboratorium.

9.2. Obiekty badań


Badanymi obiektami są ślady dynamiczne. Ich reprezentacją są obrazy graficzne odpowiednio oświetlonych próbek. Sposób powstawania śladów dynamicznych może być bardzo różny i zależy od wielu czynników. Rysunek 82.

przedstawia hierarchiczny podział rodzajów odwzorowań stosowany w kryminalistyce.




Rysunek 82. Podział rodzajów odwzorowań.

Ślady dynamiczne stanowią obraz serii wgłębień wywołanych nierównościami ostrza użytego narzędzia. Rysunek 83. przedstawia fragment rzeczywistego obrazu "kodu paskowego" powstałego na śladzie wykonanym nożycami do cięcia drutu.



Rysunek 83. Odpowiednio oświetlony obraz śladu dynamicznego wykonanego nożycami do cięcia drutu.

Rysunek 84. przedstawia mikroskopowe obrazy rzeczywistych śladów dynamicznych zebranych w miejscu popełnienia przestępstwa. Obrazy te powstały w wyniku odpowiedniego oświetlenia powierzchni, która była poddana działaniu ostrej krawędzie narzędzia użytego do rozcinania zabezpieczonego przedmiotu.




Rysunek 84. Przykładowe obrazy rzeczywistych śladów dynamicznych.

9.3. Ogólny opis metody

Istotne dla opisu opracowanej metody jest wyjaśnienie zasady powstawania obrazu graficznego badanego śladu dynamicznego. Z fizycznego punktu widzenia obrazy te powstają w wyniku odbicia światła widzialnego od powierzchni, na której znajduje się ślad. Bardzo ważny jest sposób, w jaki dana próbka zostaje oświetlona. Intensywność światła padającego powinna być możliwie jak najbardziej równomiernie rozłożona na całym badanym obszarze. Ponadto, kąt padania promieni światła powinien być ostry. W przeciwnym wypadku otrzymany obraz nie będzie zawierał uwypuklonych elementów charakterystycznych znajdujących się na jego powierzchni. Rysunek 85. przedstawia mechanizm powstawania mikroskopowego obrazu śladu dynamicznego. Szerokości ciemnych i jasnych prążków zależą od rodzaju wgłębień w śladzie oraz od kąta oświetlenia.

Zapisując wartości poziomów jasności pikseli leżących na prostej prostopadłej do kierunku ruchu narzędzia powstaje ciąg liczb z zakresu 0 do 255

(8-bitowa głębokość poziomów jasności). Operację tą wykonujemy dla dwóch porównywanych obrazów. Aby wyznaczyć ilościowy stopień podobieństwa (odległość między obrazami) należy porównać dwa ciągi liczbowe o różnej długości. Istotnym problemem jest fakt iż dwa ślady wykonane tym samym narzędziem nigdy nie będą "podobne" na całej swojej długości. Dzieje się tak ze względu na niepowtarzalność doświadczenia oraz mechaniczną erozję narzędzia.



Rysunek 85. Mechanizm powstawania „kodu paskowego” w śladach dynamicznych [50].

Opracowany algorytm rozpoznawania śladów dynamicznych składa się z części dotyczącej wstępnego przetwarzania danych oraz wyznaczania stopnia podobieństwa między badanymi śladami.

Rysunek 86. zawiera schemat algorytmu realizacji metody rozpoznawania śladów dynamicznych. Strzałkami szarymi oznaczono przepływ danych, natomiast czarnymi proces przetwarzania danych. Danymi wejściowymi są dwa obrazy graficzne zawierające ślady. W wyniku ich przetwarzania powstają ciągi liczbowe reprezentujące charakter zmian ich powierzchni w zaznaczonych obszarze [47]. Ze względu na konieczność uniknięcia pewnych zakłóceń dokonywane jest uśrednienie przebiegające wzdłuż rys pozostawionych w badanym obszarze.

W rezultacie ciąg liczbowy odpowiadający układowi „kodu paskowego” powstaje w następujący sposób:

$$i = 1 \dots L;$$

$$j = 1 \dots m - W;$$

$$\alpha_j = \frac{1}{W} \sum_{k=j}^{j+W} \alpha_k ;$$

$$j = 1 \dots n - W ;$$

$$\beta_j = \frac{1}{W} \sum_{k=j}^{j+W} \beta_k ;$$

gdzie:


i, j, k – indeksy iteracji,

α, β – ciągi wejściowe,

W – szerokość okna uśredniania,


L – ilość powtórzeń operacji uśredniania.

Ciągi liczbowe zostają następnie zamienione na odpowiadające im ciągi impulsów, które reprezentują chropowatość badanych powierzchni. W wyniku porównania tych ciągów dla różnych przesunięć względem siebie powstaje ciąg liczbowy reprezentujący funkcje podobieństwa śladów. Maksima lokalne tej funkcji odpowiadają przesunięciom, dla których ślady wykazują największe podobieństwo.




Rysunek 86. Algorytm realizacji zadania rozpoznawania śladów dynamicznych.

Po zabezpieczeniu śladu dowodowego zostaje on umieszczony pod mikroskopem i za pomocą kamery wideo oraz karty typu frame grabber wprowadzony do mikrokomputera. Utworzona w ten sposób bitmapa jest wstępnie przetwarzana w celu podwyższenia kontrastu oraz usunięcia z niej elementów zbędnych. Rysunek 87. przedstawia obraz śladu dowodowego oznaczonego jako t10_dow. Na rysunku tym widać charakterystyczne rysy dokonane podczas przecinania ostrym narzędziem.



Rysunek 87. Obraz śladu dowodowego: t10_dow.


Kolejnym etapem jest zaznaczenie badanego obszaru oraz wykonanie operacji polegającej na wyznaczeniu wejściowego ciągu liczbowego. Rysunek 88. przedstawia wykres reprezentujący wyznaczony ciąg wejściowy.



Rysunek 88. Wykres reprezentujący wyznaczony ciąg wejściowy dla obiektu: t10_dow.

Ciąg wejściowy jest wyznaczany na podstawie poziomów jasności pikseli leżących wzdłuż zaznaczonego obszaru.

Kolejnym krokiem jest wyznaczenie na podstawie ciągu wejściowego, ciągu impulsów, które odpowiadają rozkładowi elementów charakterystycznych na powierzchni badanego obiektu. Rysunek 89. przedstawia wykres ciągu impulsów dla obiektu t10_dow.




Rysunek 89. Wykres ciągu impulsów dla obiektu: t10_dow.

Przygotowane w ten sposób dane podlegają następnie porównywaniu z danymi otrzymanymi ze śladów porównawczych. Następnie obliczany jest stopień

podobieństwa między tymi badanymi obiektami dla różnych wzajemnych przesunięć [50]. Obliczenia te realizowane są wg kilku algorytmów. W ten sposób otrzymuje się dla każdego algorytmu ciąg wartości oznaczających wzajemne przesunięcia obiektów, dla których podobieństwo osiągnęło maksimum lokalne.


Przykład pełnej realizacji rozpoznawania śladów dynamicznych zostanie pokazany dla rzeczywistych śladów dynamicznych oznaczonych jako: t13_dow oraz t13_por.

Rysunek 90. przedstawia obraz śladu dowodowego zabezpieczonego na miejscu popełnienia przestępstwa.



Rysunek 90. Obraz śladu dowodowego: t13_dow.


Rysunek 91. przedstawia obraz śladu porównawczego wykonanego za pomocą zabezpieczonego narzędzia, które było użyte podczas dokonania przestępstwa.




Rysunek 91. Obraz śladu porównawczego: t13_por.

Zgodnie z opisaną metodą dla obu śladów wykonuje się procedurę wyznaczania ciągu impulsów, jako podstawowe źródło informacji na temat ukształtowania powierzchni tych śladów.

Rysunek 92. przedstawia wykres ciągu impulsów dla śladu dowodowego t13_por. Rysunek 93. zawiera wykres odpowiadający śladowi porównawczemu.




Rysunek 92. wykres impulsów dla śladu dowodowego: t13_dow.




Rysunek 93. wykres impulsów dla śladu porównawczego: t13_por.

Za pomocą algorytmu rozpoznawania impulsów ślad dowodowy i porównawczy zostają automatycznie zestawione. Rysunek 94. przedstawia zestawienie ciągów impulsów dla badanych śladów.



Rysunek 94. Automatyczne zestawienie impulsów śladu dowodowego i porównawczego.

Powyższe zestawienie impulsów odpowiada konkretnemu zestawieniu śladów. Rysunek 95. przedstawia ślad dowodowy oraz porównawczy zestawiony w ten sposób, aby wykazać, iż oba ślady zostały wykonane tym samym narzędziem. Charakterystyczne elementy tych śladów wizualnie „pasują” do siebie, co stanowi graficzną prezentację poprawności działania metody i algorytmów.



Rysunek 95. Automatyczne zestawienie obrazów śladu dowodowego i porównawczego.

Odległości między śladami są obliczane dla różnych przesunięć wg czterech algorytmów.

Korelacyjny:

Oparty jest on na obliczeniu korelacji wzajemnej dwóch ciągów liczbowych. Nie stosuje się w nim impulsów jako podstawy rozpoznawania.

$$q_{\alpha\beta}(t) = \frac{1}{p_2 - p_1} \sum_{i=p_1}^{p_2} \alpha_i \beta_{i-t} \quad (105)$$

gdzie:

$q_{\alpha\beta}(t)$ – wartość korelacji wzajemnej ciągów α i β dla przesunięcia t ,

i – indeks iteracji,

t – wartość przesunięcia wzajemnego ciągów,

p_1, p_2 – odpowiednio wartości początkowa i końcowa indeksu ciągów α i β ,

Wartości p_1, p_2 są obliczane wg długości ciągów wejściowych α i β .

Algorytm korelacyjny jest algorytmem klasycznym, powszechnie stosowanym w teorii sygnałów jak również i innych obszarach nauki. Z przeprowadzonych badań wynika, iż jest on w pewnej mierze skuteczny dla omawianego zastosowania. Jest on jednak tak skonstruowany, aby wszelkie różnice sygnałów miały swoje odzwierciedlenie w obliczonej wartości końcowej. Dla śladów dynamicznych stanowi to pewien problem, gdyż w przypadku ich badania nie stawia się postulatu maksymalnej zgodności na całym badanym odcinku. Istotne jest raczej, aby znaleźć fragment, na którym zgodność osiąga szczególnie dużą wartość. W związku z tym efektywność tego algorytmu okazała się niewystarczająca.

Impulsowo - korelacyjny:

Algorytm ten jest pewną hybrydą algorytmu korelacyjnego oraz podejścia do sygnałów opartego o wyznaczanie impulsów. Szczegółowy opis tego algorytmu znajduje się na stronie 84 pod postacią opisu miary odległości ciągów impulsów oznaczonej jako M_1 . Ogólnie mówiąc polega on na przesuwaniu się wzdłuż ciągów impulsów z krokiem równym jednemu elementowi ciągu wejściowego, czyli

analogicznie jak w przypadku algorytmu korelacyjnego. Różnica polega na tym, iż wartość dla danego indeksu iteracji nie jest prostym iloczynem wartości ciągów, lecz odległością impulsów, do których należą elementy ciągów o tych indeksach.

Efektywność tego algorytmu okazała się wysoka. Wynika to z faktu, iż uwzględnia i zbliża się on do istoty pojmowania pojęcia podobieństwa śladów dynamicznych.

Impulsowo - dopasowywujący:

Jest to algorytm oparty całkowicie na idei impulsów. Szczegółowy opis tego algorytmu znajduje się na stronie 86 pod postacią opisu miary odległości ciągów impulsów oznaczonej jako M_2 . Iteracja dokonywania jest bezpośrednio po elementach ciągu impulsów. Dla odpowiednich impulsów obliczana jest odległość między nimi wg zadanej miary odległości. Algorytm ten wykazuje dużą sprawność w zestawianiu śladów, a dodatkowo czas potrzeby na dokonanie niezbędnych obliczeń uległ w stosunku do pozostałych algorytmów znacznemu obniżeniu ze względu na operowanie na impulsach, a nie na elementach ciągów liczbowych.

Algorytm łączony:

Polega na prostym iloczynie arytmetycznym wartości obliczonych w algorytmie impulsowo-korelacyjnym oraz impulsowo dopasowywującym. Wartości dla odpowiadających przesunięć są mnożone przez siebie i w ten sposób powstaje ciąg liczb stanowiący algorytm łączony.

$$q_4(t) = q_2(t) q_3(t) \quad (106)$$

gdzie:

$q_4(t)$ – wartość obliczona za pomocą algorytmu łączonego dla przesunięcia t ,

$q_2(t)$ – wartość obliczona za pomocą algorytmu impulsowo-korelacyjnego dla przesunięcia t ,


$q_3(t)$ – wartość obliczona za pomocą algorytmu impulsowo-dopasowującego dla przesunięcia t ,

t – wartość przesunięcia wzajemnego impulsów liczona wg indeksu wejściowego ciągu liczbowego.

Cechą charakterystyczną tego algorytmu jest fakt, iż na wartości obliczone za jego pomocą mają wpływ dwa poprzednie algorytmy. Powoduje to, iż stanowi on detekcję sytuacji, gdy wartości obliczone za pomocą tych algorytmów mają równocześnie dużą wartość.

Ze względu na konieczność porównywania wartości obliczonych za pomocą wszystkich algorytmów, zostały one znormalizowane do postaci, w której wartość maksymalna reprezentowana jest przez liczbę 1, a minimum stanowi 0.

Rysunek 96. przedstawia wykres wartości obliczonych za pomocą wszystkich algorytmów.




Rysunek 96. Wykresy przebiegu wartości funkcji dyskryminacyjnej dla różnych miar odległości.

Wykres ten składa się z czterech przebiegów zależnych o wartości przesunięcia wzajemnego badanych śladów. Wartości maksymalne oznaczają największe podobieństwo dla danego przesunięcia. Wybierając algorytm określa się dla jakiej wartości przesunięcia osiąga ona wartość maksymalną.

Nie zawsze najlepsze zestawienie śladów odpowiada wartości maksymalnej danego algorytmu, dlatego też wyznaczony zostaje ciąg maksimów lokalnych dla każdego algorytmu. Następnie maksima te zostają posortowane wg swojej wartości w kolejności malejącej. W ten sposób możliwe jest zestawianie śladów nie tylko dla różnych algorytmów, ale i dla kolejnych maksimów lokalnych.

Rysunek 97. przedstawia zrzut ekranowy programu, na którym widać możliwość dokonywania zmian algorytmów jak również numeru kolejnego maksimum lokalnego w obrębie danego algorytmu. W prawej części znajdują się obrazy badanych śladów. W lewej dolnej części pokazany jest fragment prezentacji zestawienia śladów.



Rysunek 97. Zestawienie obrazów śladów dla różnych algorytmów oraz maksimów lokalnych.

9.4. Wnioski w zakresie rozpoznawania śladów dynamicznych


Rozpoznawanie śladów dynamicznych za pomocą metody opartej na czterech miarach odległości impulsów oraz czterech algorytmach wyznaczania stopnia podobieństwa ciągów impulsów daje łącznie szesnaście różnych kombinacji wariantów rozpoznawania. Z przeprowadzonych badań testowych oraz praktycznych wynika, że dzięki tej różnorodności możliwe jest pokrycie znacznego obszaru typów zadań. Wyniki świadczą o dużej poprawności rozpoznań. Ponadto konstrukcja metody, algorytmów i poszczególnych miar odległości zapewnia możliwość precyzyjnego i wyczerpującego uzasadnienia otrzymywanych wyników, co dla zastosowań w zakresie kryminalistyki jest szczególnie istotne. Nawet najskuteczniejsza metoda jest prawie bezużyteczna w przypadku, gdy za jej pomocą nie jest możliwe właściwe, wiarygodne i wyczerpujące uzasadnienie oraz udokumentowanie rezultatów jakie są przez nią generowane.

Opracowana metoda nie miała w zamyśle zastąpienia ekspertów z dziedziny mechanoskopii. Jej zadaniem jest dostarczenie metod badania śladów, które umożliwią szybsze i trafniejsze podejmowanie decyzji w zakresie ekspertyz kryminalistycznych z obszaru mechanoskopii. Otrzymane wyniki świadczą że zadanie to zostało spełnione w sposób zgodny z założeniami i zaowocowało praktycznym wprowadzeniem narzędzi opartych na opracowanej metodzie do pracy ekspertów mechanoskopii.

9.5. Zastosowane narzędzia


Biorąc pod uwagę, iż oprogramowanie wykonane w celu weryfikacji opracowanych algorytmów stanowi w niniejszej pracy jedynie tło prezentacyjne, bardzo skrótowo zostanie zaprezentowany końcowa aplikacja, za pomocą której wygenerowano zamieszczone wyniki.

Rysunek 98. zawiera zrzut ekranowy programu realizującego metodę rozpoznawania śladów dynamicznych. Zaznaczony fragment stanowi materiał wejściowy do dalszego przetwarzania.




Rysunek 98. (1) - obraz śladu dowodowego z zaznaczonym fragmentem do badania, (2) - przebieg zmienności poziomu jasności pikseli.

Rysunek 99. przedstawia wykres impulsów wygenerowanych na podstawie ciągu wejściowego oraz wynik automatycznego zestawienia ciągów impulsów.



Rysunek 99. (1) - Wykres impulsów, (2) - zestawienie ciągów impulsów.

Rysunek 100. przedstawia zakładkę programu, w której dokonywany jest wybór algorytmu oraz maksimum lokalnego. Prezentowane są tam również graficzne efekty zestawienia obrazów badanych śladów. Na zrzucie ekranowym znajdującym się po prawej stronie znajduje się zakładka obrazująca przebiegi zmienności wartości wygenerowanych przez stosowane algorytmy dla różnych przesunięć wzajemnych śladów.



Rysunek 100. (1) – Zestawienie śladów dla danego algorytmu oraz wybranego maksimum lokalnego, (2) – wykres wartości odpowiadających podobieństwu ciągów impulsów dla różnych algorytmów.

Podobnie jak w przypadku opracowanych narzędzi dla potrzeb weryfikacji metod i algorytmów stosowanych w zastosowaniach inżynierii procesowej, program ten został napisany całkowicie przez autora tej pracy w modelu obiektowym [83][90] przy zastosowaniu Borland C++ Builder [6][7][30][64][74].

10. PODSUMOWANIE

Główna teza niniejszej pracy opiera się na stwierdzeniu, iż jeżeli specyfika podziału na klasy leży w sposobie zmienności funkcji opisujących obiekty, to w celu określenia podobieństwa obiektów, należy stosować miary odległości przebiegów zmienności cech. W ogólniejszym rozumieniu można wyrazić stwierdzenie, że obiekty należy rozpoznawać wg ich charakterystycznych właściwości pozwalających na dokonanie klasyfikacji. Innymi słowy, określony podział na klasy wytycza kierunek poszukiwania optymalnego wektora cech opisujących obiekty. W przypadku, gdy właściwości charakterystyczne obiektów są stałymi wartościami liczbowymi, istnieje bardzo bogaty zestaw metod, algorytmów i miar odległości pozwalających na rozwiązanie definiowanego problemu. Jeżeli cechy charakterystyczne opisane są w inny sposób, istnieją dwie drogi postępowania.

Jedna z nich polega na sprowadzeniu cechy do postaci stałych wartości liczbowych. W niniejszej pracy cechy opisane są za pomocą ciągów liczbowych. Możliwe więc byłoby sprowadzenie tych ciągów do pojedynczych wartości opisujących możliwie najlepiej te cechy. Takie próby były prowadzone, jednak nie doprowadziły one do zadowalających rezultatów. Wynikało to z faktu, iż niezależnie od stopnia złożoności prowadzonych obliczeń, przejście w jednym kroku z funkcji do pojedynczej liczby prowadzi do zbyt dużego uogólnienia, w którym gubiona jest informacja o unikalności danego obiektu czy klasy.

Dlatego też, na pewnym etapie prac zdecydowano się na wybranie innej drogi. Kluczowym zagadnieniem jest w niej znalezienie miar podobieństwa ciągów liczbowych, w sposób w którym nie zostanie zgubiona informacja o złożoności zawierającej specyfikę obiektu opisanego w ten sposób. W celu osiągnięcia tych założeń przyjęto następujące założenia. Rozpoznawanie będzie następowało w sposób dwuetapowy oraz ciągi liczbowe zostaną poddane segmentacji na obiekty wyrażające cechy morfologiczne. Przyjęcie założenia dot. rozpoznawania dwuetapowego ma na celu uniknięcie zbyt szybkiej redukcji informacji wejściowej, natomiast badanie morfologii ciągu zapewnia możliwość detekcji złożoności danej cechy, jak również umożliwia traktowanie wszystkich obiektów jako aglomeratów


obiektów pierwotnych. Podejście to jest analogiczne do porównywania składu chemicznego danej substancji, a nie np. jej właściwości fizyko-chemicznych. Szukając dalszych analogii do świata materialnego można zauważyć, iż ilość różnych obiektów znajdujących się w naszym otoczeniu jest ogromna, ale wszystkie one składają się ze skończonej liczby pierwiastków chemicznych stanowiących ich budulec.

W zakresie ciągów liczbowych, obiektem takim został określony impuls. W związku z tym ciąg liczb przekształcony został w ciąg impulsów. Wiązało się to oczywiście ze zdefiniowaniem cech opisujących impulsy. Przekształcenie zadania zdefiniowania miary podobieństwa ciągów liczbowych na zadanie opracowania algorytmu obliczania odległości między dwoma ciągami impulsów pociągało za sobą konieczność zdefiniowania miary podobieństwa impulsów oraz miary podobieństwa ciągów impulsów.

Miary takie zostały opracowane w kilku wariantach. Prace te poprzedzało jednak zdefiniowanie metody i algorytmów wyznaczania ciągu liczbowego opisującego badane obiekty. Ponieważ badaniom podlegały obiekty graficzne, zadanie to polegało określeniu sposobu przetwarzania obrazów, lub w przypadku zastosowań w inżynierii procesowej, sekwencji obrazów do postaci ciągów liczbowych.

Opracowana metoda ma charakter otwarty, tzn. możliwa jest jej rozbudowa o takie elementy jak nowe miary podobieństwa impulsów oraz ciągów impulsów. Celowe jest również poszukiwanie dodatkowych cech obrazów graficznych, pozwalających np. na wydobycie nowych właściwości przepływów dwufazowych. Zastosowanie urządzeń technicznych o parametrach umożliwiających akwizycję obrazów z prędkością przekraczającą 1000 fps daje możliwości precyzyjnego wyznaczania cech opartych na parametrach geometrycznych obiektów znajdujących się na scenach. Dzięki analizie przebiegu zmian współczynników kształtu Fereta, cyrkularności, Malinowskiej Blaira-Blissa, Danielssona, Haralicka, oraz innych, możliwe będzie otrzymanie większej ilości informacji.

Rysunek 101. przedstawia ogólny schemat opracowanej metody, na którym zaznaczono fragmenty dotyczące zastosowań inżynierii procesowej na czerwono, a mechanoskopii na niebiesko. Pozostałe elementy stanowią ogólny trzon metody i odnoszą się do całości zastosowań.



Rysunek 101. Ogólny schemat metody.

Reasumując należy podkreślić następujące fakty.

1. Opracowana metoda jest oryginalna w sensie idei oraz realizacji wyrażonej w postaci algorytmów i definicji miar odległości.
2. Niniejsza praca nie stanowi studium przypadku dla konkretnych zastosowań, lecz dotyczy metody i algorytmów pozwalających na jej zastosowanie dla przedstawionych tematów aplikacyjnych.
3. Metoda została gruntownie zweryfikowana dla dwóch grup zastosowań, dla których opracowano, dostosowane do wymagań tych obszarów nauki, miary podobieństwa i algorytmy przetwarzania danych.
4. Zakres prac obejmował wszystkie aspekty rozpoznawania obiektów począwszy od akwizycji danych z obiektów rzeczywistych, skończywszy na klasyfikacji i interpretacji wyników.
5. Podczas prowadzonych prac wykonano szereg narzędzi, dzięki którym zrealizowano niezwykle duży zakres eksperymentów wykonanych na obiektach rzeczywistych. Bardzo niewielka część wyników została udokumentowana w niniejszym opracowaniu.
6. Otrzymane wyniki zostały zweryfikowane przez ekspertów z dziedzin, których dotyczyły i zyskały ich aprobatę zarówno w zakresie poprawności klasyfikacji, jak również zgodności metodologii postępowania z zasadami panującymi w tych dziedzinach.
7. Zagadnienia, których dotyczy niniejsza praca mają charakter teoretyczny, lecz w wyniku zastosowania opracowanej metody zyskały one także liczący się wymiar praktyczny o znacznym stopniu użyteczności.

11. LISTA SYMBOLI

ψ	– algorytm rozpoznawania
M	– zbiór numerów klas
N	– zbiór numerów obiektów
x	– wektor zmierzonych cech
X	– przestrzeń cech
i	– numer klasy
d	– wymiar przestrzeni cech
M	– ilość numerów klas
N	– ilość numerów obiektów
$w^{(k)}$	– wagi
$D_x^{(i)}$	– obszar decyzyjny dla klasy i
g_i	– funkcja dyskryminująca
$x_j^{(k)}$	– wartość k -tej cechy dla i -tego obiektu
$\bar{x}_i^{(k)}$	– reprezentatywna wartość k -tej cechy dla i -tej klasy
m_i	– liczebność klasy o numerze i
$\ x_i - x_j\ $	– odległość między obiektami x_i oraz x_j
ω	– wektor cech
$\omega^{(i)}$	– i -ta cecha
C	– długość ciągu
$a^{(k)}, b^{(k)}$	– wartości k -tej cechy obiektu a i b
p	– wartości przesunięcia wzajemnego ciągów
r	– ilość elementów ciągu biorących udział w obliczeniach
α, β	– wejściowe ciągi liczbowe
m, n	– długości ciągów
ξ	– ciąg znaków różnic między kolejnymi elementami ciągu α
ζ	– ciąg znaków różnic między kolejnymi elementami ciągu β
χ	– ciąg wartości opisujących ekstrema lokalne ciągu α

δ	– ciąg wartości opisujących ekstrema lokalne ciągu β
m_χ	– długość ciągu χ
n_δ	– długość ciągu δ
κ	– ciąg impulsów dla ciągu α
λ	– ciąg impulsów dla ciągu β
$x_i^{(\chi)}$	– położenie (numer indeksu) ekstreum dla ciągu χ_i
$y_i^{(\chi)}$	– wartość ekstreum dla ciągu χ_i
$x_j^{(\delta)}$	– położenie (numer indeksu) ekstreum dla ciągu δ_j
$y_j^{(\delta)}$	– wartość ekstreum dla ciągu δ_j
m_κ	– długość ciągu κ
n_λ	– długości ciągu λ
A	– cecha oznaczająca amplitudę wznoszenia impulsu
B	– cecha oznaczająca amplitudę opadania impulsu
w	– cecha oznaczająca czas narastania impulsu
v	– cecha oznaczająca czas opadania impulsu
Π	– długość ciągu impulsów
C	– maksimum z amplitudy narastania i amplitudy opadania
u	– całkowity czas trwania impulsu
Ω	– ciąg maksimów lokalnych
F	– długość ciągu maksimów lokalnych
μ	– ciągu wartości funkcji dyskryminującej
L	– ilość powtórzeń operacji uśredniania
W	– szerokość okna uśredniania
T	– maksymalne przesunięcie wzajemne ciągów
$D(\kappa_i, \lambda_j)$	– odległość między impulsami κ_i oraz λ_j
$p_{j,i}^k$	– wartość poziomu jasności piksela o współrzędnych j, i dla sceny o indeksie k
$q_{j,i}^k$	– 24-bitowy kolor piksela o współrzędnych j, i dla sceny o indeksie k

- $RED(q_{j,i}^k)$ – wartość składowej koloru czerwonego dla piksela $q_{j,i}^k$
- $GREEN(q_{j,i}^k)$ – wartość składowej koloru zielonego dla piksela $q_{j,i}^k$
- $BLUE(q_{j,i}^k)$ – wartość składowej koloru niebieskiego dla piksela $q_{j,i}^k$
- M_k – wartość miary udziału dla k -tej sceny
- E_k – wartość miary brzegu dla k -tej sceny
- V_k – wartość miary wariancji dla k -tej sceny
- G_k – wartość miary gradientu dla k -tej sceny
- $edge(p_{j,i}^k)$ – funkcja określająca czy piksel $p_{j,i}^k$ należy do brzegu
- $q_{\alpha\beta}(t)$ – wartość korelacji wzajemnej ciągów α i β dla przesunięcia t
- $q_1(t), \dots, q_4(t)$ – wartości wynikowe algorytmów klasyfikacji dla przesunięcia t

12. SPIS RYSUNKÓW

Rysunek 1. Schemat układu akwizycji danych wizyjnych stosowanego podczas prowadzonych badań.....	15
Rysunek 2. Przykład redukcji informacji poprzez odrzucenie obszaru nie biorącego udział w rozpoznawaniu przepływów dwufazowych.	16
Rysunek 3. Przykład korekty błędów akwizycji danych.....	17
Rysunek 4. Figura geometryczna na scenie binarnej.....	18
Rysunek 5. Scena zawierająca figury geometryczne na tle kolorowej mozaiki.	19
Rysunek 6. Przykład sceny zawierającej obraz przepływu mieszaniny dwufazowej gaz-ciecz w przestrzeni międzyrurowej.	19
Rysunek 7. Graficzna reprezentacja zagadnienia zdolności cech do separowania obiektów różnych klas.	21
Rysunek 8. Ogólna idea systemu rozpoznawania obiektów.	28
Rysunek 9. Przykład rozkładu obszarów decyzyjnych na płaszczyźnie 2D.....	29
Rysunek 10. Schemat struktury klasyfikatora opisanego funkcjami dyskryminacyjnymi.....	31
Rysunek 11. Schemat struktury klasyfikatora liniowego.	32
Rysunek 12. Graficzna reprezentacja algorytmu minimalno-odległościowego, dla metody wyboru obiektu „typowego”.	34
Rysunek 13. Graficzna reprezentacja metody wyznaczania nowego obiektu „typowego” wg średniej arytmetycznej.	37
Rysunek 14. Graficzna reprezentacja metody wyznaczania nowego obiektu „typowego” wg mediany.	37
Rysunek 15. Graficzna reprezentacja metody wyznaczania obiektu „typowego” jako najbliższego obiektowi obliczonemu wg średniej arytmetycznej.	38
Rysunek 16. Graficzna reprezentacja metody wyznaczania obiektu „typowego” jako najbliższego obiektowi obliczonemu wg mediany.	38
Rysunek 17. Graficzna reprezentacja algorytmu minimalno-odległościowego, dla metody najbliższego sąsiada.	39
Rysunek 18. Graficzna reprezentacja algorytmu minimalno-odległościowego, dla metody n -najbliższych sąsiadów.	40
Rysunek 19. Interpretacja graficzna różnych miar odległości.	41
Rysunek 20. Ośiem wyróżnionych kierunków na dwuwymiarowej siatce kwadratowej.	49
Rysunek 21. Linie proste łączące dwa punkty.	50
Rysunek 22. Linia o grubości dwóch punktów.	51
Rysunek 23. Najbliższe sąsiedztwo punktu.....	53
Rysunek 24. Kontur obiektu na płaszczyźnie czterokierunkowej.	53
Rysunek 25. Kontur obiektu na płaszczyźnie ośmiokierunkowej.....	54
Rysunek 26. Linia prosta na płaszczyźnie ośmiokierunkowej.	54
Rysunek 27. Linia prosta na płaszczyźnie czterokierunkowej.....	55
Rysunek 28. Obraz zmian struktury pierścieniowo-dyspersyjnej w przekroju poprzecznym [29].	56

Rysunek 29. Przetwarzanie obrazu i detekcja granicy faz.....	57
Rysunek 30. Struktury przepływu gaz-ciecz w rurze pionowej: cienki film, zafalowany film, struktura dyspersyjna.	58
Rysunek 31. Obraz struktury pęcherzykowej (oryginalny).	59
Rysunek 32. Obraz struktury pęcherzykowej (po wyznaczeniu krawędzi).	60
Rysunek 33. Przykład przepływu pulsacyjnego w przestrzeni międzyrurowej (obraz oryginalny).	60
Rysunek 34. Przykład przepływu pulsacyjnego w przestrzeni międzyrurowej (obraz po wyznaczaniu krawędzi).	61
Rysunek 35. Struktura pęcherzykowa (faza 1).	61
Rysunek 36. Struktura pęcherzykowa (faza 2).	62
Rysunek 37. Przepływ dwufazowy (faza 1).	62
Rysunek 38. Przepływ dwufazowy (faza 2).	63
Rysunek 39. Przepływ dwufazowy (faza 3).	63
Rysunek 40. Mapa zagadnień klasyfikacji dla dwóch parametrów: odległości oraz ilości elementów biorących udział w obliczeniach.....	71
Rysunek 41. Przykładowy przebieg zmienności pewnej cechy dla trzech różnych obiektów.....	74
Rysunek 42. Interpretacja graficzna pojęcia <i>impuls</i>	77
Rysunek 43. Przykłady aparatów do kontaktowania gazu i cieczy: a) kolumna dyspersyjna, b) kolumna ze spływającym filmem cieczy, c) kolumna wypełniona przeciwprądowa, d) kolumna pęcherzykowa, e) kolumna półkowa, f) kolumna pęcherzykowa z mieszaniem mechanicznym, g) kolumna pęcherzykowa z mieszaniem strumieniowym, h) aparat strumieniowy, i) reaktor barbotażowy, j) reaktor barbotażowy z rurą cyrkulacyjną, k) reaktor rurowy przeciwprądowy, l) reaktor rurowy współprądowy, m.) reaktor rurowy węzownicowy [9][71][82].	92
Rysunek 44. Przegląd klasycznych aparatów fluidalnych do kontaktowania cieczy i ciała stałego a) złoża pęcherzykowe, b) złoża pulsacyjne, c) złoża fontannowe [66].	93
Rysunek 45. Przegląd reaktorów do zgazowania węgla a) pęcherzykowe złoża fluidalne, b) złoża pęcherzykowe z zewnętrzną cyrkulacją ciała stałego, c) szybka fluidyzacja z wewnętrzną i zewnętrzną cyrkulacją ciała stałego [66]. .	93
Rysunek 46. Klasyfikacja struktur dla przepływu wznoszącego mieszaniny gaz-ciecz w kanale pionowym; struktura: B – pęcherzykowa, P – korkowa, F – pianowa, A – pierścieniowa, AD –pierścieniowo-dyspersyjna [92].	95
Rysunek 47. Klasyfikacja struktur dla przepływu mieszaniny gaz- ciało stałe w kanale pionowym: a) złoża zwarte, b) złoża rozluźnione, c) złoża pęcherzykowe, d) złoża pulsujące, e) złoża turbulentny, f) szybka fluidyzacja [84][85].	96
Rysunek 48. Zmiany struktury mieszaniny woda-para wodna podczas ciągłego odparowania przy przepływie w kanale [92].	96
Rysunek 49. Różne interpretacje zawartości faz dla przepływu dwufazowego gaz-ciecz w kanale [23].	98
Rysunek 50. Zmiany zawartości faz dla przepływu mieszaniny gaz-ciecz w kanale poziomym a) struktura rozwarstwiona, b) struktura zafalowana, c) struktura rzutowa [92].	102

Rysunek 51. Przykład rozróżniania struktur przepływu mieszaniny dwufazowej gaz-ciecz na podstawie oceny kształtu funkcji gęstości prawdopodobieństwa zmian udziału objętościowego gazu [93].	102
Rysunek 52. Schemat prezentujący ogólną ideę zastosowaną podczas rozpoznawania struktur przepływu mieszanin dwufazowych.	106
Rysunek 53. Przykładowa sekwencja kolejnych klatek dla przepływu gaz-ciecz.	107
Rysunek 54. Przykładowa sekwencja kolejnych klatek dla przepływu mieszaniny gaz-ciało stałe.	108
Rysunek 55. Sekwencja kolejnych klatek dla przepływu rzutowego.	109
Rysunek 56. Przyjęte podczas prowadzonych badań obszary akwizycji danych.	111
Rysunek 57. Wykres zmian poziomów jasności dla przepływu mieszaniny reprezentującej strukturę rzutową (sekwencja: A1 , cecha: M , podobszary: 10x30).	120
Rysunek 58. Wykresy zmian poziomów jasności dla przepływu mieszaniny reprezentującej strukturę rzutową (sekwencja: A1 , cecha: M , podobszary: 10x30) dla wybranych impulsów.	121
Rysunek 59. Wykres mapy impulsów (sekwencja: A1 , cecha: M , podobszary: 10x30) dla sygnału przed uśrednianiem (niebieski) oraz po uśrednieniu (czerwony).	121
Rysunek 60. Wykresy sygnałów (sekwencja: A1 , cecha: M , podobszary: 10x30) dla 10-ciu różnych podobszarów tej samej wielkości.	122
Rysunek 61. Wykresy sygnałów (sekwencja: A1 , cecha: M , podobszary: 10x10 , 10x30 , 30x50) dla różnych wielkości podobszarów.	123
Rysunek 62. Przykładowy sposób podziału płaszczyzny decyzyjnej $C-u$ na obszary decyzyjne klasyfikacji impulsów.	125
Rysunek 63. Mapa sklasyfikowanych impulsów należących do różnych struktur przepływu.	126
Rysunek 64. Przykład wykresu sygnału oraz odpowiadającej mu mapie impulsów opisującej strukturę A6 dla cechy M w obszarze 10x30 z podziałem na sklasyfikowane impulsy.	127
Rysunek 65. Przykładowe pojedyncze sceny z badanych przepływów.	128
Rysunek 66. Mapa impulsów z zaznaczonymi obszarami decyzyjnymi dla cechy M i podobszarów o wielkości 10x30 pikseli.	130
Rysunek 67. Wykresy zawierające wyniki klasyfikacji impulsów do poszczególnych obszarów decyzyjnych reprezentujących specyficzne właściwości przepływów dla cechy M i podobszarów o wielkości 10x30 pikseli.	131
Rysunek 68. Mapa impulsów dla obiektów charakterystycznych w swojej klasie oraz wykres wyników klasyfikacji impulsów dla tych obiektów (cecha M , podobszary o wielkości 10x30 pikseli).	132
Rysunek 69. Mapa impulsów z zaznaczonymi obszarami decyzyjnymi dla cechy E i podobszarów o wielkości 50x30 pikseli.	133
Rysunek 70. Wykresy zawierające wyniki klasyfikacji impulsów do poszczególnych obszarów decyzyjnych reprezentujących specyficzne właściwości przepływów dla cechy E i podobszarów o wielkości 50x30 pikseli.	134
Rysunek 71. Mapa impulsów dla obiektów charakterystycznych w swojej klasie oraz wykres wyników klasyfikacji impulsów dla tych obiektów (cecha E , podobszary o wielkości 50x30 pikseli).	135

Rysunek 72. Mapa impulsów z zaznaczonymi obszarami decyzyjnymi dla cechy G i podobszarów o wielkości 50x30 pikseli.	136
Rysunek 73. Wykresy zawierające wyniki klasyfikacji impulsów do poszczególnych obszarów decyzyjnych reprezentujących specyficzne właściwości przepływów dla cechy G i podobszarów o wielkości 50x30 pikseli.....	137
Rysunek 74. Mapa impulsów dla obiektów charakterystycznych w swojej klasie oraz wykres wyników klasyfikacji impulsów dla tych obiektów (cecha G , podobszary o wielkości 50x30 pikseli).....	138
Rysunek 75. Mapa impulsów z zaznaczonymi obszarami decyzyjnymi dla cechy V i podobszarów o wielkości 10x10 pikseli.	139
Rysunek 76. Wykresy zawierające wyniki klasyfikacji impulsów do poszczególnych obszarów decyzyjnych reprezentujących specyficzne właściwości przepływów dla cechy V i podobszarów o wielkości 10x10 pikseli.....	140
Rysunek 77. Mapa impulsów dla obiektów charakterystycznych w swojej klasie oraz wykres wyników klasyfikacji impulsów dla tych obiektów (cecha V , podobszary o wielkości 10x10 pikseli).....	141
Rysunek 78. Wyniki klasyfikacji impulsów dla przypadków M 10x30 oraz G 50x30.	143
Rysunek 79. Przykładowy zrzut ekranowy z programu realizującego algorytm rozpoznawania struktur przepływu mieszanin dwufazowych.	145
Rysunek 80. Przykładowy zrzut ekranowy z programu realizującego algorytm klasyfikacji impulsów.	146
Rysunek 81. Przykładowy zrzut ekranowy z programu realizującego algorytm rozpoznawania struktur przepływu mieszanin dwufazowych metodą klasyfikacji impulsów.	147
Rysunek 82. Podział rodzajów odwzorowań.	150
Rysunek 83. Odpowiednio oświetlony obraz śladu dynamicznego wykonanego nożycami do cięcia drutu.	150
Rysunek 84. Przykładowe obrazy rzeczywistych śladów dynamicznych.	151
Rysunek 85. Mechanizm powstawania „kodu paskowego” w śladach dynamicznych [50]......	152
Rysunek 86. Algorytm realizacji zadania rozpoznawania śladów dynamicznych. .	153
Rysunek 87. Obraz śladu dowodowego: $t10_dow$	154
Rysunek 88. Wykres reprezentujący wyznaczony ciąg wejściowy dla obiektu: $t10_dow$	155
Rysunek 89. Wykres ciągu impulsów dla obiektu: $t10_dow$	155
Rysunek 90. Obraz śladu dowodowego: $t13_dow$	156
Rysunek 91. Obraz śladu porównawczego: $t13_por$	156
Rysunek 92. wykres impulsów dla śladu dowodowego: $t13_dow$	157
Rysunek 93. wykres impulsów dla śladu porównawczego: $t13_por$	158
Rysunek 94. Automatyczne zestawienie impulsów śladu dowodowego i porównawczego.	159
Rysunek 95. Automatyczne zestawienie obrazów śladu dowodowego i porównawczego.	159
Rysunek 96. Wykresy przebiegu wartości funkcji dyskryminacyjnej dla różnych miar odległości.	162

Rysunek 97. Zestawienie obrazów śladów dla różnych algorytmów oraz maksimumów lokalnych.	163
Rysunek 98. (1) - obraz śladu dowodowego z zaznaczonym fragmentem do badania, (2) - przebieg zmienności poziomu jasności pikseli.....	165
Rysunek 99. (1) - Wykres impulsów, (2) – zestawienie ciągu impulsów.	165
Rysunek 100. (1) – Zestawienie śladów dla danego algorytmu oraz wybranego maksimum lokalnego, (2) – wykres wartości odpowiadających podobieństwu ciągów impulsów dla różnych algorytmów.....	166
Rysunek 101. Ogólny schemat metody.....	169

13. BIBLIOGRAFIA

- [1] *ANGEL O.*, **Wprowadzenie do grafiki komputerowej**, PWN Warszawa 1988
- [2] *BADER R. i inni*, **Gas/solid flow patterns in a 30,5 cm diameter circulating fluidized bed, in Circulating Fluidized Bed Technology II**, ed. P. Basu, J. F. Large, Pergamon Press, New York 1988
- [3] *BAKER O.*, **Simultaneous flow of oil and gas**, *Oil and Gas Journal*, 1954, t. 53, s. 185
- [4] *BANACHOWSKI L.*, *KRECZMAR A.*, *RYTTER W.*, **Analiza algorytmów i struktur danych**, WNT Warszawa 1989
- [5] *BENNETT M. A.*, *LUKE S. P.*, *JIA X.*, *WEST R. M.*, *WILLIAMS R. A.L.*, **Analysis and flow regime identification of bubble column dynamics**, 1st World Congress on Industrial Process Tomography, Buxton 1999
- [6] *BIELECKI J.*, **Turbo C++**, PLJ Warszawa 1991
- [7] *BOREK H.*, **Programowanie dla Windows przy użyciu Borland C++**, Lynx-SFT Warszawa 1992
- [8] *BRERETON C. M. H.*, *GRACE J. R.*, **Microstructural aspects of behavior of circulating fluidized beds**, *Chem. Eng. Sci.*, 1993, t. 48, s. 2565
- [9] *CHARPENTIER J. C.*, **A review of the data on mass transfer parameters in most of gas-liquid reactors, in Two-Phase Flow and Heat Transfer**, ed. S. Kakac, F. Mayinger, Hemisphere Publ., Corp., Washington 1976
- [10] *CHISHOLM D.*, **Two-phase flow in pipelines and heat exchangers**, Georg Godwin Ed., London 1983
- [11] *CHROMIEC J.*, *STRZEMIECZNA E.*, **Sztuczna inteligencja**, Akademicka Oficyna Wydawnicza PLJ Warszawa 1994
- [12] *CHWIAŁKOWSKA E.*, **Sztuczna inteligencja w systemach eksperckich**, MIKOM Warszawa 1991
- [13] *CLOSE R.*, *TAMURA S.*, *NAITO H.*, **Estimation of motion from sequential images using integral constraints**, *Pattern Recognition*, 1995
- [14] *COAD P.*, *NICOLA J.*, **Programowanie obiektowe**, READ ME, Warszawa 1994
- [15] *COAD P.*, *YOURDON E.*, **Analiza obiektowa**, READ ME, Warszawa 1994
- [16] *COAD P.*, *YOURDON E.*, **Projektowanie obiektowe**, READ ME, Warszawa 1994
- [17] *DELHAYE J. M.*, **Optical methods in two-phase flow**, *Proc. of the Dynamic Flow Conference*, Paris 1978
- [18] *DYAKOWSKI T.*, *JAWORSKI A. J.*, **Application of tomographic techniques for imaging fluidized beds**, 3rd Israeli Conference for Conveying and Handling of Particulate Solids, Dead Sea 2000

- [19] *DYAKOWSKI T., MANN R., WILLIAMS R. A., Application of electrical tomography for multiphase flow measurements*, 3th Int. Conf. On Multiphase Flow, ICMF'98, Lyon 1998
- [20] *DZIUBNICKI I., ŚWIĄTKOWSKI T., Poradnik matematyczny*, PWN Warszawa 1982
- [21] *EL-AYOUTY E. D., STEPANEK J. B., Use of microwaves in the measurements of frequencies and amplitudes in liquid holdup fluctuations*, Int . J. of Multiphase Flow, 1983, t. 9, nr 1, s. 49
- [22] *FOLEY J.D., VAN DAM A., FEINER S. K. HUGHES J. F. PHILLIPS R. L., Wprowadzenie do grafiki komputerowej*, WNT Warszawa 1995
- [23] *GALAUP J. P., Contribution to the study of methods for measuring two-phase flow, Doctor of Engne Thesis*, National Polytechnic, Institute of Grenoble, Grenoble 1976
- [24] *GARNCAREK Z., KRÓTKIEWICZ M., ULBRICH R., Problem doboru cech w rozpoznawaniu struktur przepływu płynów, III Krajowa Konferencja Naukowa Inżynieria Wiedzy i Systemy Ekspertowe*, Wrocław 1997
- [25] *GELDART D., Gas fluidization technology*, John Willey and Sons, London 1986
- [26] *GLIKSMAN L. R., NOYMER P. D., Measurements of the velocity and acceleration of clusters at the wall of a circulating fluidized bed*, Particle Technology Forum, Chicago 1996
- [27] *GONZALES R., Digital Image Processing*, Addison – Wesley Publishing Company 1987
- [28] *HETSRONI G., Handbook of multiphase systems*, Hemisphere Publ., Corp., Washington 1983
- [29] *HEWITT G.F., ROBERTS D.N., Investigations of interfacial phenomena in annular two-phase flow by means of the axial view technique*, Report AERE-R 6070, Harwell 1969
- [30] *HOLZNER S., Programowanie w Borland C++, INTERSOFTLAND Warszawa 1993*
- [31] *HOŁYST B., Kryminalistyka*, PWN Warszawa 1975
- [32] *HOWARD J. R., Fluidized bed technology: principles and applications*, IOP Publ. Corp., Bristol 1989
- [33] *HUBBARD M. B., DUKLER A. E., The characterization of flow regimes for horizontal two-phase flow*, in Proc. of the 1966 Heat Transfer and Fluid Mechanics Institute, ed. M.A. Saad, J.A. Miller, Stanford Univ. Press Stanford 1966
- [34] *HUZAR Z., KURZYŃSKI M., SAS J., Eksperymentalna analiza porównawcza kombinowanych algorytmów rozpoznawania*, II Krajowa Konferencja Naukowa, Inżynieria wiedzy i systemy ekspertowe, Wrocław 1993
- [35] *IKEDA T., KOTANI K., MAEDA Y., KOHNO H., Preliminary study on application of X-ray CT scanner to measurement of void fractions in steady-state two-phase flows*, J. of Nucl. Sci. And Techn., 1983, t. 20., nr 1, s.1
- [36] *ISSANGYA A. S., BAI D., GRACE J. R., LIM K. S., Flow behavior in the riser of a high-density circulating fluidized bed*, Particle Technology Forum, Chicago 1996

- [37] JÄHNE B, **Digital Image Processing**, Springer Berlin 1977
- [38] JAIN P. K., CHILDERSON M. T., KAR A., ROY R. P., **Experimental investigation of vapour fraction fluctuations in boiling flow**, AIChE Symp. Series, 1981, t.77, nr 208, s.103
- [39] JANKOWSKI M. JANKOWSKA J., **Przegląd metod i algorytmów numerycznych**, WNT Warszawa 1988
- [40] JANKOWSKI M., **Elementy grafiki komputerowej**, WNT Warszawa 1990
- [41] JONES O. C., ZUBER N., **The intercorrelation between fluctuations and flow patterns in two-phase flow**, Int. J. of Multiphase Flow, 1974, t. 2, s. 273
- [42] KACPRZAK T., ŚLOT K., **Sieci neuronowe komórkowe**, PWN Warszawa 1995
- [43] KESKA J. K., SMITH M. D., **Statistical analysis of the flow pattern detection ability of a sensor cluster in two-phase flow**, 3rd ASME/JSME Joint Fluids Engng Conference, San Francisco 1999, Paper FEDSM99-7142
- [44] KIERZENKOWSKI K., **Algorytmy przetwarzania obrazów cyfrowych**, Elektronizacja 1995
- [45] KOLEV N. I., CHEN T., KOLLMANN T., SCHLICHT G., **Visual multi-phase flow analysis**, 3rd Int. Conference on Multiphase Flow, Lyon 1998
- [46] KORBICZ J., OBUCHOWICZ A., UCINŚKI D., **Sztuczne sieci neuronowe**, Akademicka Oficyna Wydawnicza PLJ Warszawa 1994
- [47] KRÓTKIEWICZ M., **Method of pattern recognizing on the basis of examining shapes of edge lines of objects**, Proceedings of the 12th International Conference on Systems Science, Wrocław 1995
- [48] KRÓTKIEWICZ M., **Procedury rozpoznawania elementów obrazów**, praca dyplomowa magisterska, Opole 1993
- [49] KRÓTKIEWICZ M., **Próba klasyfikacji struktur przepływu dwufazowego za pomocą metod rozpoznawania obrazów na przykładzie fotografowania osiowego**, Zeszyty naukowe WSI w Opolu nr 203 z.40, XXVI Międzyuczelniana Konferencja Metrologów MKM'94, Opole 1994
- [50] KRÓTKIEWICZ M., **Rozpoznawanie obrazów śladów dynamicznych w zastosowaniach kryminalistyki**, III Krajowa Konferencja Naukowa nt Inżynieria Wiedzy i Systemy Ekspertowe, Wrocław 1997
- [51] KRÓTKIEWICZ M., SZMOLKE N., ULBRICH R., **Ocena fluktuacji złożeń z wykorzystaniem metody analizy obrazu**. XVI Konferencja Inżynierii Chemicznej i Procesowej, Kraków 1998
- [52] KRÓTKIEWICZ M., ULBRICH R., **Algorytmizacja rozpoznawania struktur przepływu wielofazowego**, Ogólnopolska Konferencja Inżynierii Chemicznej i Procesowej, Gdańsk 1995

- [53] *KRÓTKIEWICZ M., ULBRICH R., Application of dynamic image system for determining of multiphase flow. XIII International Conference on Systems Science, Wrocław 1998*
- [54] *KRÓTKIEWICZ M., ULBRICH R., Zastosowanie metod rozpoznawania obrazów do klasyfikacji dynamicznych procesów przepływu dwufazowego, Komputerowa analiza obrazu w technologii żywności, Olsztyn 1994*
- [55] *KRÓTKIEWICZ M., ULBRICH R., Wykorzystanie metody automatycznej analizy obrazu do oceny struktury przepływu dwufazowego, XV Ogólnopolska Konferencja Inżynierii Chemicznej i Procesowej, Gdańsk 1994*
- [56] *KURZYŃSKI M., Rozpoznawanie obiektów, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 1997.*
- [57] *LIANG W. i inni, Hydrodynamics of a gas-liquid-solid three-phase circulating fluidized bed, Can. J. of Chem. Engng, 1995, t. 73, s. 656*
- [58] *LIM K.S., ZHU J. X., GRACE J. R., Hydrodynamics of gas-solid fluidization, Int. J. of Multiphase Flow, 1995, t. 21, Suppl, s. 141*
- [59] *LIU K., XU Y., REH L., Fluctuation characteristic of solids in a circulating fluidized bed, Int. Symp. On Multiphase Flow, Beijing 1997*
- [60] *McQUILLAN K.W., Whalley P.B., Flow patterns in vertical two-phase flow, Report AERE-R 11032, Harwell 1983*
- [61] *MERILLO M., DECHEME R. L., CICHOWLAS W. M., Void fraction measurement with a rotating electric field conductance gauge, J. of Heat Transfer, 1977, t. 99, nr 52, s. 330*
- [62] *MERZKIRCH W., WAGNER T., PIV with two synchronized video cameras, Int. Sem. on Optical Methods and Data Processing in Heat and Fluid Flow, London 1996*
- [63] *MICHALEWICZ Z., Algorytmy genetyczne + struktury danych = programy ewolucyjne, WNT Warszawa 1996*
- [64] *NABAJYOTI B., Grafika i Animacja w Windows, INTERSOFTLAND, Warszawa 1994*
- [65] *NARABAYASHI T., TOBIMATSU T., NAGASAKA K., KAGAWA T., Measurement of transient flow pattern by high speed scanning X-ray void fraction meter, IUTAM Symp. on Measuring Techniques in Gas-Liquid Two-Phase Flow, Nancy 1983*
- [66] *NAUZE R. D., Combustion in fluidized beds, in Advanced Combustion Methods, ed. F. J. Weinberg, Academic Press, London 1986*
- [67] *ORZECOWSKI Z., Przepływy dwufazowe, PWN, Warszawa 1990*
- [68] *PAULUS D., HORNEGGER J., Applied Pattern Recognition, Vieweg Wiesbaden 1998*
- [69] *PAVLIDIS T., Grafika i przetwarzanie obrazów, PWN Warszawa 1987*
- [70] *PLATANIOTIS K.N., VENETSANOPOULOS A.N., Color Image Processing and Applications, Berlin Springer 2000*

- [71] *POHORECKI R., Effectiveness of mass transfer area in gas-liquid systems*, in Heat and Mass Transfer in Multicomponent Gas-Liquid Systems, Ossolineum, Warszawa 1980
- [72] *PRACA ZBIOROWA POD RED. K. WOJCIECHOWSKIEGO, Laboratorium przetwarzania i rozpoznawania obrazów*, Politechnika Śląska, Gliwice 1992.
- [73] *PRATT K., Digital Image Processing*, Wiley & Sons, New York 1978
- [74] *ROETZHEIN W. H., Nieznane Programowanie w Windows*, Intersoftland, Warszawa 1994
- [75] *ROZIN B.B., Teoria rozpoznawania obrazów w badaniach ekonomicznych*, PWN Warszawa 1979
- [76] *SCHAAF J., SCHOUTEN J. C., JOHNSON F., BLEEK C. M., Decomposition of power spectral density of pressure fluctuations in gas-solids fluidized beds*, 3rd Int. Conf. on Multiphase Flow, Lyon 1998
- [77] *SCHMITZ D., PETRITSCH G., MEWES D., Tomographic imaging of the void distribution in bubble columns during blowdown*, 13th Int. Conf. On Multiphase Flow, ICMF'98, Lyon 1998
- [78] *SEKOGUCHI K., MORI K., New development of experimental study on interfacial structure in gas-liquid two-phase flow*, in *Experimental Heat Transfer, Fluid Mechanics and Thermodynamics*, ed. M. Giot, F. Mayinger, G.P. Celata, Edizioni ETS, Pisa 1997
- [79] *SHIAVI R., Applied Statistical Signal Analysis*, San Diego 1999
- [80] *SHOJI M., Boiling chaos and modeling*, Proc. of the 11th Int. Heat Transfer Conference, Kyongju 1998
- [81] *SKARBK W., Metody reprezentacji obrazów cyfrowych*, Akademicka Oficyna Wydawnicza PLJ Warszawa 1993
- [82] *SOKOLOV V. N., DOMANSKIJ I. V., Gazozydkostnyje reaktory, Masinostrojenije*, Leningrad 1976
- [83] *SYSŁO M., DEO N., KOWALIK J. S., Algorytmy optymalizacji dyskretnej*, PWN Warszawa 1993
- [84] *SZMOLKE N., ULBRICH R., Metoda oceny struktury hydraulicznej cyrkulacyjnego złoża fluidalnego*, Inżynieria Chemiczna i Procesowa, 1999, t. 20, s. 73
- [85] *SZMOLKE N., ULBRICH R., Metoda oceny struktury hydraulicznej klasycznego złoża fluidalnego*, Inżynieria Chemiczna i Procesowa, 1999, t. 20, s. 55
- [86] *TADEUSIEWICZ R., KOROHODA P., Komputerowa analiza i przetwarzanie obrazów*, Kraków 1997
- [87] *TADEUSIEWICZ R., Sieci neuronowe*, Akademicka Oficyna Wydawnicza Warszawa 1993
- [88] *THEOFANOUS T. G., YUEN W. W., Fundamentals of boiling and multiphase flow under extreme conditions*, Proc. of 11th Int. Heat Transfer Conference, Kyongju 1998

- [89] *TRONIEWSKI L., ULBRICH R., The analysis of flow regime maps of gas-liquid flow in pipes*, Chem. Eng. Sci., 1984, t. 39, nr. 7/8, s. 1213
- [90] *TSICHRITZIS D.C., LOCHOVSKY F.H., Modele danych*, PWN Warszawa 1982
- [91] *TYUGU CH., Programowanie z bazą wiedzy*, PWN Warszawa 1989
- [92] *ULBRICH R., Identyfikacja przepływu dwufazowego gaz-ciecz*, ZW WSI w Opolu, Studia i Monografie, z. 32, Opole 1989
- [93] *ULBRICH R., Ocena rodzaju przepływu dwufazowego gaz-ciecz na podstawie analizy procesów stochastycznych*, Krajowa Konferencja Metrologów, Lublin 1982
- [94] *WEINSTEIN H. i inni, Radial variation in solid density in high velocity fluidization, in Circulating Fluidized Bed Technology II*, ed. P. Basu, J. F. Large, Pergamon Press, New York 1988
- [95] *WIRTH N., Algorytmy + struktury danych = programy*, WNT Warszawa 1989
- [96] *WOJNAR L., MAJOREK W., Komputerowa analiza obrazów*, Fotobit Design, Kraków 1994
- [97] *ZHANG Y.Y, WANG P.S.P., Analysis of thinning Algorithms 11th IAPR International Conference on Pattern Recognition*, The Hague, The Netherlands, August 30 - September 3, 1992