



**AGH**

AKADEMIA GÓRNICZO-HUTNICZA  
IM. STANISŁAWA STASZICA W KRAKOWIE

## KATEDRA AUTOMATYKI I INŻYNIERII BIOMEDYCZNEJ

Raport na temat:

### **Weryfikacja i testy algorytmu wykrywania zanieczyszczeń w roztworach opartego na metodzie przestrzeni cech z zastosowaniem PCA do redukcji wymiaru**

*Wykonał zespół badawczy:*      **dr hab. inż. Paweł Rotter**  
   **inż. Wiktor Muroń**

**Kraków, 2015**



Praca wykonana w ramach projektu CYTOROBOT  
finansowanego przez Narodowe Centrum Badań  
i Rozwoju w latach 2012-2015.

Umowa nr PBS1/A9/1/2012 w ramach Programu  
Badań stosowanych w ścieżce A





## Spis treści

1	Wprowadzenie do metody .....	5
1.1	Wstęp .....	5
1.2	Plan ramowy metody .....	6
1.3	Problemy napotykane w trakcie stosowania metody .....	8
1.4	Identyfikowane obiekty .....	11
1.5	Podsumowanie .....	17
2	Otrzymanie wektora współczynników opisującego próbkę .....	18
2.1	Wstęp .....	18
2.2	Nagranie materiału video .....	18
2.3	Ekstrakcja pierwszego planu .....	19
2.4	Otrzymanie przebiegów czasowych głównych cech maski pierwszego planu .....	21
2.4.1	Wstęp .....	21
2.4.2	Środek ciężkości - [CECHA1] .....	22
2.4.3	Ilość cząstek - [CECHA2] .....	24
2.4.4	Moment bezwładności - [CECHA3] .....	25
2.4.5	Przykładowe przebiegi czasowe .....	25
2.5	Analiza i uproszczenie przebiegów czasowych cech .....	27
2.5.1	Wstęp .....	27
2.5.2	Obróbka przebiegu .....	28
2.5.3	Współczynniki opisujące przebiegi czasowe .....	29
2.6	Podsumowanie .....	31
3	Redukcja wymiaru wektorów opisujących próbki metodą analizy głównych składowych (PCA) .....	33
3.1	Wstęp do PCA .....	33
3.2	Redukcja wymiaru .....	35
3.3	Podsumowanie .....	39
4	Uczenie klasyfikatora na podstawie zredukowanych wektorów opisujących .....	40
4.1	Opis metody K-NN .....	40
4.2	Podsumowanie .....	44
5	Testy i kalibracja parametrów metody .....	45

5.1	Wprowadzenie i cel .....	45
5.2	Metodologia.....	45
5.2.1	Metody testowania klasyfikatora .....	45
5.2.2	Oszacowanie błędu dla zbioru parametrów klasyfikatora.....	47
5.3	Przeprowadzone testy .....	48
5.3.1	Etap I – testy i kalibracja parametrów opisu obrazu .....	48
5.3.2	Etap II – testy i kalibracja klasyfikatora.....	52
5.4	Podsumowanie.....	54
6	Klasyfikacja nowych próbek.....	55
7	Wnioski .....	58
8	Bibliografia .....	60

# 1 Wprowadzenie do metody

## 1.1 Wstęp

Głównym problemem w analizie pojedynczego zdjęcia (bądź pojedynczej klatki z materiału video) pojemnika zawierającego roztwór leku z występującym lub nie zanieczyszczeniem jest niemożliwość powtarzalnego i jednoznacznego procesu segmentacji elementów interesujących, takich jak pęcherzyki powietrza i drobiny leku, z kadru zawierającego dodatkowo tło, krawędzie butelki/worka oraz nadrukowane na naczyniu napisy i grafiki. W przypadku błędnej segmentacji możliwa jest sytuacja, gdy np. fragment napisu zostałby błędnie zinterpretowany jako obiekt, który należy w następnym kroku sklasyfikować [3].

Rozwiązaniem zastosowanym w poniższej metodzie jest zastosowanie wysokiej jakości kamery cyfrowej do nagrania zamkniętego naczynia z wprawionym w ruch roztworem leku cytostatycznego. Aby otrzymać nagranie, dla którego możliwe jest przeprowadzenie dalszych kroków, konieczne jest wprawienie w ruch naczynia poprzez powolne obrócenie naczynia dnem „do góry”, a następnie gwałtowne powrócenie do pozycji początkowej. Taki zabieg doprowadza potencjalny osad, zanieczyszczenie lub nierozpuszczony lek do opadania z góry naczynia na dno, a tym samym odróżnia je od nieruchomych części obrazu (nadruki, krawędzie naczynia), których nie dałoby się poprawnie odseparować i sklasyfikować w kontekście tej metody. Dokładniejszy opis wprowadzenia zawartości naczynia w ruch jest opisany w [4].

Jednym z profitów podejścia ilościowego jest możliwość analizy obrazu w skali szarości, gdyż w przypadku rozpatrywania tylko ruchu nie jest potrzebna informacja o kolorze wykrytych ruchomych obiektów. Upraszcza to samą metodę oraz zmniejsza wymagania odnośnie stanowiska robota, ponieważ z reguły kamery czarno-białe są tańsze od porównywalnej jakości kolorowych odpowiedników.

Materiał video z nagranymi ruchomymi obiektami jest następnie poddawany algorytmowi segmentacji pierwszego planu za pomocą metody Mixture of Gaussian [9]. Metoda ta jest algorytmem subtrakcji tła i pozwala na usunięcie z kadru niepotrzebnych informacji, takich jak nieruchome tło, krawędzie butelki, nadruki i napisy na naczyniu. Usunięcie tych elementów z dalszych kroków pozostawia do analizy jedynie czynniki, które niosą odpowiednią w kontekście tej metody informację – obiekty ruchome.

Rezultat metody Mixture of Gaussian dla dwóch klatek jest binarną maską pierwszego planu. W przypadku analizy ciągu następujących po sobie klatek rezultat ten uogólnić można do nowego nagrania zawierającego kolejne binarne maski pierwszego planu. Nagranie maski binarnej zawiera informacje jedynie o ruchu pęcherzyków powietrza i cząstek fizycznych (drobin i zanieczyszczeń) w czasie, a więc jest odpowiednie do dalszej analizy w kolejnych krokach metody.

Wprowadzenie to pozwala zrozumieć istotę podstawowego założenia metody, czyli analizy nagrania wprawionego w ruch roztworu. [2]. Kolejne etapy pozwalające na skondensowanie informacji na temat materiału video oraz docelowo klasyfikację próbek na podstawie

ograniczonej informacji są już konsekwencjami tego wyboru i są dokładniej opisywane już w kolejnych rozdziałach.

## 1.2 Plan ramowy metody

Przydatne w zrozumieniu idei, na bazie których opiera się opisywana metoda, mogą być schematy blokowe opisujące w sposób graficzny przebieg informacji i danych.

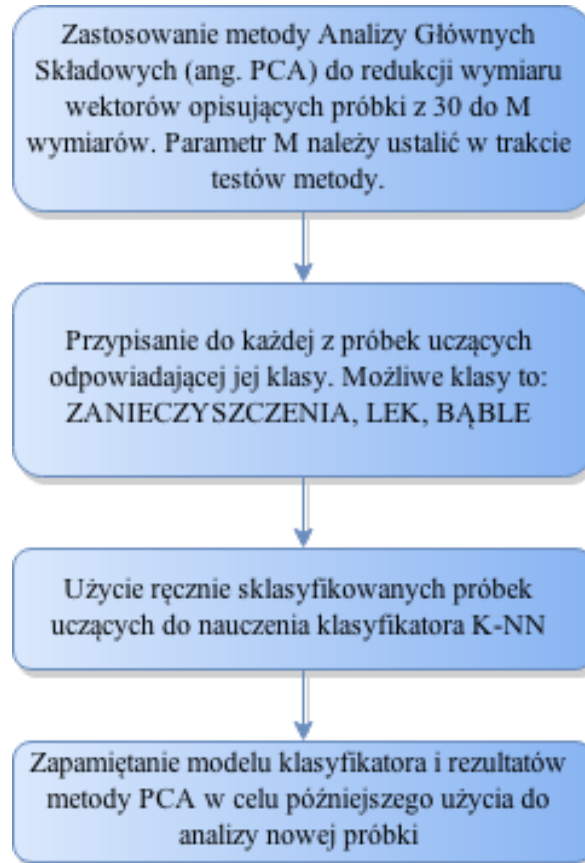
Główne etapy, z których składa się metoda to:

- Otrzymanie wektorów opisujących nagrania dla  $P$  próbek uczących (Rys. 1)



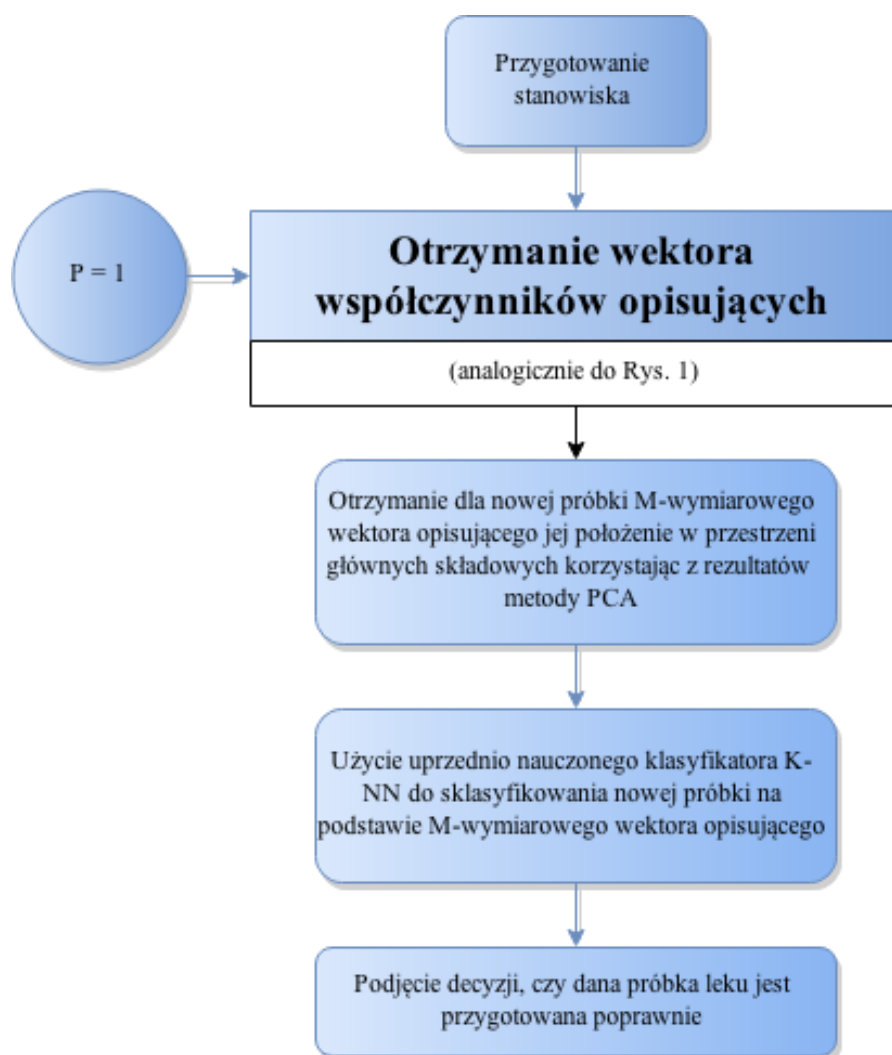
Rys. 1 Schemat pokazujący otrzymywanie wektorów opisujących.

- Zredukowanie wymiaru wektorów opisujących próbki za pomocą metody PCA i zastosowanie otrzymanych zredukowanych M-wymiarowych wektorów do uczenia metody k-najbliższych sąsiadów (Rys. 2)



*Rys. 2 Redukcja wektorów opisujących próbkę i jej klasyfikacja – schemat*

- Użycie nauczonej metody K-NN do klasyfikacji nowej próbki (Rys. 3)



Rys. 3 Schemat pokazujący podejście metody do klasyfikacji nowej próbki leku

Każdy z głównych etapów ze względu na swoją złożoność opisywany jest w dokładnie w kolejnych rozdziałach.

### 1.3 Problemy napotykane w trakcie stosowania metody

Ze względu na doświadczalno-eksperymentalny charakter metody nie jest możliwe sprecyzowanie czy też zamodelowanie problemu i jego rozwiązania w jednoznaczny i dokładny sposób. Wynika to zarówno z ogromnej złożoności ruchu stałych cząstek i pęcherzyków powietrza pod wpływem ruchu naczynia jak i z wielu innych czynników pośrednich, opisywanych w poniższym rozdziale. Problem automatycznej inspekcji optycznej leków cytostatycznych jest na tyle skomplikowany, że metody i podejścia prowadzące do jego rozwiązania lub tylko opisanie w sposób przybliżony mogą być bardzo zróżnicowane. Skuteczność takich metod nie jest łatwa do przewidzenia i dopiero zbadanie podejścia oraz wstępna implementacja metody może pokazać, w jakim stopniu jest ona odpowiednia dla posiadanych nagrań.

Przyjęcie określonego podejścia może doprowadzić do napotkania w kolejnych etapach trudności, które przy alternatywnym zaprojektowaniu metody mogłyby nie być istotne lub w



ogóle nie miałyby miejsca. Ta nieokreśloność problemu i nieprzewidywalność konsekwencji daje z jednej strony swobodę przy zakładaniu w metodzie kolejnych założeń, ale też doprowadza do sytuacji, kiedy nie można w sposób oczywisty zdecydować, czy dane założenie, początkowo wydające się być ułatwieniem, nie uniemożliwi w późniejszym etapie skutecznej klasyfikacji próbek jedynie na podstawie nagranych ruchów cząstek/pęcherzyków.

Oznacza to również, że trzeba przeanalizować wiele czynników utrudniających rozwiązanie problemu i zdecydować, które z nich można zignorować, a które z nich zaproponowana metoda jest w stanie zneutralizować częściowo lub w sposób całkowity.

Poniżej przedstawione są problemy i utrudnienia wzięte pod uwagę w procesie projektowania i implementacji metody.

### **Odwzorowanie 3-wymiarowej przestrzeni na 2-wymiarowym nagraniu**

Ruch zarówno pęcherzyków powietrza jak i stałych obiektów odbywa się trójwymiarowej przestrzeni. Nagranie zarejestrowane standardową kamerą 2D obejmuje tym samym jedynie część informacji, jaką można ekstrahować z analizy ruchu. W szczególności traci się informację o przemieszczeniu oraz o odległości cząstek na kierunku obiektyw – obiekt. Częściowym rozwiązaniem tego problemu jest wprowadzenie zawartości naczynia w ruch, co w pewnym stopniu rekompensuje spłaszczenie obrazu.

### **Gwałtowny przepływ obiektów i pęcherzyków powietrza**

Ruch obiektów po wprowadzeniu w ruch (zwłaszcza pęcherzyków) jest na tyle szybki, że w przypadku nagrywania z przeciętną prędkością (24-30 klatek) nie jest widoczne płynne przemieszczenie obiektów i dochodzi do gwałtownego „przeskoku” pojedynczego obiektu z jednej klatki w drugą. Ze względu na to, że metoda korzysta z ekstrakcji pierwszego planu za pomocą algorytmu tworzącego obraz różnicowy jest to znaczące utrudnienie i konieczne jest stosowanie kamer o możliwości nagrywania obrazu z większą szybkością. Użyta została kamera o możliwości nagrywania około 300 klatek na sekundę [23]. Wadą tego rozwiązania była jednak bardzo niska rozdzielczość kadru – 512x384 px. W docelowym stanowisku zrobotyzowanym planowane jest użycie wolniejszych kamer (ok. 180 klatek na sekundę) o wyższej rozdzielczości, które mogłyby pomóc w uzyskaniu lepszych rezultatów [7].

Prędkość 300 klatek na sekundę oznacza, że w przypadku używanego w metodzie domyślnego parametru ILOŚĆ\_KLATEK = 325 (opisanego w rozdziale 3.1), zarejestrowany materiał video obejmuje ok. 1.08 s ruchu cieczy.

### **Oświetlenie naczynia**

Ze względu na szybkość kamery użytej do nagrywania materiałów video konieczne jest odpowiednie dobranie oświetlenia, które pozwoli na właściwe naświetlenie klatki w stosunkowo krótkim czasie. Zastosowany oświetlacz powinien świecić z odpowiednio wysoką (co najmniej 2 razy wyższą niż szybkość nagrywania kamery) częstotliwością lub świecić światłem ciągłym, aby wyeliminować migotanie oświetlenia. W początkowej fazie nagrywania filmów używano standardowej żarówki 60W, zasilanej z gniazdka elektrycznego 230V i przesłoniętej pleksiglasową płytą działającą jako dyfuzor, jednak uzyskane

niepożądane migotanie obrazu doprowadziło do zmiany oświetlenia na światło słoneczne. W docelowym stanowisku zalecane jest zastosowanie wysokoczęstotliwościowego oświetlacza przemysłowego [7].

### **Nadruk na naczyniach**

Naczynia o zastosowaniach medycznych często są opisywane nadrukiem informującym o zawartości naczynia [4]. W przypadku tej metody, aby zminimalizować wpływ tych napisów na działanie algorytmów konieczne było zastosowanie ekstrakcji pierwszego planu z wykorzystaniem obrazu różnicowego. Powoduje to usunięcie z dalszej analizy wszystkich nieruchomych elementów.

### **Niezamierzone ruchy naczynia**

Sprężystość naczynia może powodować niewielkie drgania jego krawędzi nawet w przypadku zatrzymania się po obrocie, co może prowadzić do błędnego ich zaliczenia do maski pierwszego planu. W przypadku tej metody doprowadzałoby to do zakłamań w ocenie przebiegów czasowych cząstek, dlatego konieczne było ustanowienie dla materiału video każdej próbki odpowiedniego ROI (ang. Region of Interest), pokrywającego jedynie fragment obrazu wewnątrz naczynia, dla którego przeprowadzane będą dalsze analizy.

### **Małe obiekty**

Niewystarczająca rozdzielczość kamery oraz brak odpowiedniego obiektywu typu makro sprawiają, że małe obiekty mogą zostać niewykryte ze względu na niezarejestrowanie je na materiale video. Konieczne jest zatem stosowanie odpowiedniego sprzętu, który pozwala na zneutralizowanie tego problemu.

### **Losowe zachowanie pęcherzyków powietrza i obiektów oraz brak automatyzacji wprawiania naczynia w ruch**

Ze względu na możliwość nagrywania próbek jedynie ręcznie (bez udziału ramienia robota operującego naczyniem) sam sposób wprawiania w ruch jest losowy i niemożliwe jest dwukrotne powtórzenie tego samego działania. Zauważono, że tworzenie się pęcherzyków i ruch dużej grupy cząstek w wytworzonych po obrocie naczynia wirach jest losowy i w związku z tym nie da się zawsze przewidzieć i poprawnie przeanalizować zachowania pojedynczych cząstek. W wyniku przeprowadzonych obserwacji na dużej liczbie materiałów nagraniowych uznano, że dla proponowanej metody dopiero grupa cząstek, traktowana jako całość, jest wystarczająco charakterystyczna i odporna na pojedyncze anomalie.

### **Niewystarczająca liczba próbek oraz potrzeba kalibracji pod docelową aplikację**

Skuteczność działania metody opiera się w dużej mierze na odpowiednio wysokiej liczbie próbek użytych do nauczania klasyfikatora i z tego powodu jej efekty mogą różnić się w sytuacji, gdy do uczenia algorytmu użyto 30 próbek zamiast ilości rzędu setek.

Oznacza to również, że po instalacji stanowiska robota z docelową kamerą i oświetleniem konieczne będzie przeprowadzanie uczenia i kalibracji algorytmu po raz kolejny na podstawie zupełnie nowych próbek, gdyż jedynie ich dopracowanie może pozwolić na zwiększenie skuteczności w nowym środowisku.

## **1.4 Identyfikowane obiekty**

Część z wniosków i obserwacji zawartych w niniejszym rozdziale zostało przedstawionych w opracowaniu [2]. Sposób, w jaki obiekty są podzielone na kategorie odzwierciedla fizyczną naturę zachowania się obiektów i ich ruch po wykonaniu wymuszającego obrotu. Nie kategoryzuje się ich w niniejszym opracowaniu w kategoriach właściwości chemicznych. Ruchome obiekty, które mogą zostać wykryte w trakcie procesu przygotowywania roztworów leków cytostatycznych można podzielić na następujące główne kategorie.

- Obiekty duże
- Obiekty sypkie
- Pęcherzyki powietrza


### **Obiekty duże**

Obiekty duże są kategorią niezanikających obiektów, których rozmiary przekraczają kilka mm i których konsystencja, kształt i kolor nie mogą zostać skutecznie opisane i sprecyzowane przed pojawieniem się takiego obiektu w kadrze.

Obiekty takie mogą zostać wykryte w momencie, gdy w trakcie procesu przygotowywania roztworu dojdzie do następujących niekontrolowanych zdarzeń:

- Ukruszenie fragmentu korka butelki / pojemnika (Rys. 4)
- Ułamanie końcówki igły
- Zlepianie się zanieczyszczeń lub leku w większy obiekt
- Doprowadzenie do dryfowania w roztworze obiektu – „obłoku” o kolorze i ruchu wyróżniającym się na tle czystego roztworu
- Powstanie innych nieprzewidywalnych anomalii

Duże obiekty w docelowej aplikacji projektu są wykrywane przez inny algorytm [2], dlatego grupa ta została pominięta w metodzie opisywanej w poniższym opracowaniu. Pominięcie to jest uzasadnione, ponieważ z samego założenia metoda ta jest przeznaczona dla dużych grup małych obiektów.



*Rys. 4 Fragment korka butelki ułuszonego podczas preparacji leku*

### **Obiekty sypkie**

Obiekty sypkie można opisać następującymi cechami, będącymi zarazem wnioskami z przeprowadzonych testów i podejść w wykrywaniu zanieczyszczeń w roztworach leków.

- Obiekty są podobnego rozmiaru, a ich rozpiętość w najszerszym miejscu nie przekracza limitu kilku milimetrów, powyżej którego pojedynczy obiekt jest skategoryzowany jako obiekt duży,
- Ilość obiektów jest z reguły większa od kilku/kilkunastu,
- Grupa obiektów po wprowadzeniu naczynia w ruch zachowuje się na tyle powtarzalnie i w spójny sposób, aby rozróżnić ruch nierozpuszczonego koncentratu leku od zanieczyszczeń i bąbli.
- Można w sposób empiryczny ocenić na podstawie ruchu i zachowania się cząstek, czy w danym przypadku w roztworze znajdują się obiekty sypkie. Implikuje to możliwość usystematyzowania i opisanie tego ruchu za pomocą sformalizowanych współczynników, na podstawie których będzie możliwa dalsza klasyfikacja,
- Jest to zbiór drobin, które w zależności od parametrów takich jak gęstość, lepkość i stopień rozpuszczenia (jeśli dotyczy) mogą zachowywać się zróżnicowany, ale wciąż rozróżnialny od pęcherzyków powietrza sposób,

Ze względu na konsystencję koncentratu leków cytostatycznych [5,6] dopuszczalne jest zaliczenie ich do kategorii obiektów sypkich. Cechami wyróżniającymi tę podgrupę są:

- Rozpuszczanie się drobin w czasie, a tym samym permanentne zmniejszenie liczby obiektów,
- Po wprowadzeniu w ruch w sposób określony we wstępie, obiekty opadają z pewną prędkością z górnych części naczynia w stronę jego dna,

Inną kategorią sypkich obiektów są zanieczyszczenia, czyli drobiny, które mogły dostać się do roztworu wraz z dawką leków i pozostały w nim po rozpuszczeniu leku. Cechy tej grupy są następujące:

- Drobiny zanieczyszczeń z reguły nie podlegają rozpuszczeniu się, a tym samym ich liczba w czasie jest zdecydowanie bardziej stała niż przypadku koncentratu leków,
- Po wprowadzeniu tej grupy w ruch można zaobserwować nieskoordynowane dryfowanie zanieczyszczeń w roztworze w taki sposób, że pomimo dużego rozproszenia w naczyniu ich środek ciężkości pozostaje na bardziej stałym poziomie, niż w przypadku grupy leków,



*Rys. 5 Nierozpuszczony lek przesypujący się z góry naczynia. Jako zamiennik rozpuszczalnego koncentratu leku użyto sól kuchenną.*



*Rys. 6 Nierozpuszczalne zanieczyszczenia unoszące się w postaci zawiesiny w roztworze rozpuszczonego leku. Zamiennikiem nierozpuszczalnego zanieczyszczenia w danym przypadku był pieprz.*

### **Pęcherzyki powietrza**

Zauważono, że gwałtowny ruch konieczny dla odpowiedniego wzruszenia wszystkich obiektów sypkich często doprowadza do wytworzenia się pewnej ilości pęcherzyków powietrza. Zaobserwowano, że charakteryzują się one znacznym zróżnicowaniem kształtów i wielkości (Rys. 7). Zauważono także, że pęcherzyki charakteryzują się następującymi cechami:

- Nietrwały charakter pęcherzyków powietrza powoduje, że ilość wykrytych obiektów ruchomych bardzo szybko spada i po krótkim czasie osiąga poziom bliski zeru.
- Pęcherzyki powietrza wznoszą się gwałtownie co rzutuje na przemieszczanie się środka ciężkości pierwszego planu do góry.
- Zaniknięcie pęcherzyków powietrza dla danej próbki jest jednorazowe, co oznacza, że ich ilość z reguły nie wzrasta w czasie powyżej dotychczas osiągniętej wartości.



*Rys. 7 Klatka z początkowej fazy nagrania czystego roztworu w chwili po wprowadzeniu w ruch. Zaobserwowane pęcherzyki powietrza charakteryzują się dużym zróżnicowaniem kształtu i wielkości.*

### **Ograniczona klasyfikacja próbek**

Zdecydowano się na zmniejszenie liczby poszukiwanych typów próbek do czterech głównych klas. Z powodów opisanych w poprzednim rozdziale pominięto analizę i klasyfikację próbek z dużymi obiektami. W nawiasach kwadratowych znajduje się uproszczona nazwa klasy, używana w kolejnych rozdziałach do identyfikacji klasy próbki.

- Czysty roztwór – **[CZYSTA]** – nie wykryto żadnych drobin, zanieczyszczeń ani pęcherzyków powietrza – Próbkę sklasyfikowaną do tej kategorii jest akceptowana jako poprawnie przygotowana.
- Próbkę z pęcherzykami powietrza - **[BĄBLE]** – Obiekty w próbce to pęcherzyki, więc zostaje ona zaakceptowana jako poprawnie przygotowana.
- Próbkę z nierozpuszczonym lekiem – **[LEK]** – Po obrocie dochodzi do przesypu drobin z góry na dół. W celach testowych klasa symulowana była za pomocą kryształków soli kuchennej. Próbkę wymaga ponownego wymieszania.
- Próbkę z zanieczyszczeniem – **[ZANIECZYSZCZENIA]** – W roztworze pływa zawiesina nierozpuszczalnych drobin. W celach testowych symulowana za pomocą drobin zmielonego pieprzu. Próbkę jest natychmiastowo odrzucana.

### **Pominięcie klasy [CZYSTA]**

Decyzję odnośnie zaliczenia próbki do klasy [CZYSTA] można podjąć nie przeprowadzając większości analiz koniecznych dla innych klas. Co więcej, wprowadzenie do zbioru uczącego klasyfikator próbek opisujących tę klasę mogłoby doprowadzić do pogorszenia skuteczności metody w rozdzielaniu klas [BĄBLE], [LEK] i [ZANIECZYSZCZENIA] ze względu na zupełnie inny charakter przebiegów podstawowych cech oraz fakt, że klasyfikację tej próbki można określić na podstawie prostego testu sprawdzającego własności przebiegów czasowych, opisanych w kolejnym rozdziale. Mianowicie, w przypadku tej kategorii pierwszy

plan, czyli ruchome części obrazu są całkowicie niewykrywalne (woda jest przezroczysta, a pęcherzyki nie zostały wytworzone). Oznacza to, że jeżeli ilość pikseli uznanych za pierwszy plan utrzymuje się na odpowiednio niskim poziomie (na granicy szumu kamery) to można wnioskować, że ma się do czynienia z próbką klasy [CZYSTA]. Z tego powodu test ten powinien zostać wykonany na początku całej procedury, przed przejściem do etapu otrzymywania współczynników opisujących przebiegi czasowe. W przypadku pozytywnego testu przynależności do tej klasy, dalsze kroki mogą zostać zaniechane.

## **Oświetlenie**

Wymagania dotyczące częstotliwości oświetlaczy zostały sprecyzowane w trakcie nagrywania materiałów, dlatego część z zarejestrowanych próbek jest obciążona nieznacznym wpływem migotania tła. W późniejszym etapie wszystkie próbki nagrano przy świetle słonecznym, choć docelowo planowane jest zastosowanie wysokiej jakości oświetlacza.

W drodze testów zdecydowano się na umieszczenie źródła światła za rozpraszającym panelem z biało-przezroczystego tworzywa pleksiglasowego, działającego jako dyfuzor światła. Światło z tyłu naczynia w dość skuteczny sposób przyciemnia nieprzezroczyste drobiny oraz uwypukla charakterystyczny kształt pęcherzyków powietrza. Takie zróżnicowanie pozwala na bardziej efektywną analizę w dalszych krokach.


## **Naczynie**

W przygotowywaniu leków cytostatycznych, jako naczyń służących do preparowania roztworów używa się butelek szklanych lub plastikowych oraz worków plastikowych. Używane może być szkło/plastik przezroczysty lub kolorowy, jednak barwiony materiał utrudnia analizę zanieczyszczeń ze względu na mniejszą przepuszczalność światła i konieczność używania jaśniejszego oświetlacza.

Do celów raportu zastosowano uproszczone warianty naczynia na roztwór leku:

- Sztywna butelka z przezroczystego plastiku bez nadruku i bez naklejek (Rys. 8)
- Sztywna butelka z przezroczystego plastiku z nadrukiem i z naklejką (Rys. 9)

Taki dobór naczyń pozwalał na wystarczające zbadanie skuteczności usuwania fragmentów stałych i tła przez algorytmy bazujące na tworzeniu maski pierwszego planu przez obraz różnicowy oraz umożliwił sprawdzenie wstępnej postaci metody w uproszczonych warunkach, w których sam materiał wykonania szkła/plastiku nie powoduje utrudnień w analizie cząstek pływających w roztworze.



*Rys. 8 Butelka bez naklejki*



*Rys. 9 Butelka z naklejką po prawej stronie*

### **Podsumowanie**

Odpowiednio dobrany sprzęt w postaci kamery oraz dostosowanego oświetlenia pozwala na zbadanie skuteczności metody w warunkach odpowiednio uproszczonych, w których naczynie zawierające roztwór nie jest pokryte napisami ani utworzone z barwionego materiału.



## 1.5 Podsumowanie

Przedstawiony plan ramowy metody opisuje w sposób uproszczony przepływ informacji w metodzie: począwszy od nagrania zawierającego próbkę roztworu należącego do określonej klasy, skończywszy na zredukowanych wektorach ją opisujących.

Rozdział konfrontuje problemy napotymane przy jej stosowaniu z założonymi uproszczeniami. Jedną z najbardziej znaczących konsekwencji wynikających z początkowych doświadczeń jest obranie do dalszej analizy obrazu różnicowego uzyskanego z nagrania próbki z dużą prędkością. Pozwala to na zachowanie informacji o pierwszym planie, czyli o wszystkich ruchomych obiektach pływających w roztworze.

Ze względu na skomplikowany charakter analizowanego problemu konieczne jest założenie pewnych uproszczeń, które pozwalają zawęzić zakres klasyfikowanych klas próbek do małego zbioru. Klasy należące do tego zbioru muszą umożliwiać ich wzajemne rozróżnienie na podstawie prostych cech opisujących zachowanie ruchu cząstek/pęcherzyków zaliczonych do pierwszego planu po wprawieniu w ruch całego naczynia za pomocą odpowiedniego obrotu.

Klasy próbek roztworu zostały uproszczone do typów zawierających obiekty sypkie oraz pęcherzyki powietrza, natomiast klasa próbki zawierającej jedynie czysty roztwór (z poprawnie rozpuszczonym lekiem i bez pęcherzyków powietrza) ze względu na łatwość wykrywania nie jest brana pod uwagę w dalszych analizach metody. Z tego powodu ogranicza się klasyfikację do klas: ZANIECZYSZCZENIA, LEK i BĄBLE.

## **2 Otrzymanie wektora współczynników opisującego próbkę**

### **2.1 Wstęp**

Nagranie video próbki nie jest wystarczająco skondensowaną informacją, którą można użyć do uczenia klasyfikatora. Ze względu na ilość niepotrzebnych danych oraz duży rozmiar pojedynczej próbki konieczne jest odpowiednie wyłuskanie informacji zawartej w nagraniu pod kątem zastosowania jej do późniejszej klasyfikacji próbek. Sposób ekstrakcji jest kluczowy dla efektywnego działania metody, jednak nie jest łatwe określenie, które cechy obrazu pozwolą na najbardziej szczegółowe odzwierciedlenie zachowania grupy cząstek pod wpływem ruchu. Z tego powodu zastosowano opisanie nagrania za pomocą dużej liczby prostych współczynników, nie wiedząc jednak, które z nich mają najbardziej odpowiednie właściwości pod kątem późniejszej klasyfikacji.

Podjęcie to daje dużą elastyczność algorytmu pod kątem automatyzacji procesu. Wynika to z faktu, że w trakcie implementacji metody nie jest ustalane a priori, które współczynniki mają mniejszą, a które większą wagę. Odgórne założenia co do wag nadałyby metodzie zbyt specyficzne wymagania odnośnie środowiska (oświetlenia i kamery), które mogłyby nie być aktualne w nowej aplikacji metody w innym środowisku. Analogiczne podejście polegające na stworzeniu systemu reguł odnośnie współczynników było wstępnie testowane w poprzednich analizach [2], jednak w takiej metodzie proces ręcznego uczenia algorytmu odpowiednich kryteriów był nieefektywny i zawierał dużą ilość zmiennych, które wymagały ręcznej kalibracji przy każdej zmianie warunków nagrywania próbek. W podejściu zastosowanym w tej metodzie odpowiednikiem kalibracji parametrów klasowych jest uczenie klasyfikatora za pomocą dużej liczby próbek nagranych w nowym środowisku. Nadaje to odpowiednim współczynnikom właściwe wagi, co oznacza, że metoda, przy odpowiedniej ilości próbek uczących, powinna dostosować się do nowych warunków i pozwolić na zautomatyzowaną pracę bez znaczącej ingerencji w działanie algorytmów w trakcie uczenia.

Niniejszy rozdział zawiera opis części metody odpowiedzialnej za pobranie materiału video i jego wstępną obróbkę oraz etap przypisujący każdej z próbek odpowiednie przebiegi czasowe prostych cech opisujących pierwszy plan każdej klatki nagrania. Ostatnim etapem opisywanym w tym rozdziale jest odpowiednie uproszczenie wszystkich otrzymanych przebiegów do wektora 30 współczynników opisujących pojedynczą próbkę.

### **2.2 Nagranie materiału video**

Materiał nagraniowy powinien zostać nagrany zgodnie z wytycznymi opisanymi w rozdziale 2, mając na uwadze opisane utrudnienia i ograniczenia. Ze względu na pracochłonne przygotowywanie materiałów ilość próbek nagraniowych została ustalona a priori na 10 dla danej klasy. Otrzymane w ten sposób 3 klasy po 10 nagrań zostały użyte do stworzenia grupy próbek uczących klasyfikator.

W celu uodpornienia metody na zmienną długość nagrania ustalono, że do dalszej analizy przekazywana jest jedynie określona liczba klatek nagrania. W ten sposób, przy zachowanej

prędkości nagrywania jest zagwarantowane, że prędkość zmian dla głównych cech będzie odzwierciedlała rzeczywiste tempo zmian w domenie czasowej.

Początkową wartość parametru ILOŚĆ\_KLATEK otrzymano metodą prób i błędów i ustalono na  $ILOŚĆ\_KLATEK = 200$ . Parametr ten wymagał kalibracji po zaprojektowaniu pozostałych etapów metody. Ostatecznie, w ramach przeprowadzonych testów opisanych w rozdziale 6, ustalono liczbę klatek wziętych do analizy na 325, co odpowiada nagrywaniu ruchu obiektów w roztworze przez 1.08 s.

Nagrane filmy powinny zostać przekonwertowane z wersji kolorowej do skali szarości, ponieważ informacja o kolorze jest zbędna w późniejszych etapach. Ma to swoje uzasadnienie w empirycznej obserwacji roztworów leków, gdyż zauważono brak możliwości identyfikacji koloru zanieczyszczenia w przypadku ustawienia naczynia pomiędzy obiektywem a oświetlaczem (położenie to jest wymagane w metodzie ze względu na rozróżnienie zanieczyszczeń od tła).

## **2.3 Ekstrakcja pierwszego planu**

### **Wstęp do Mixture Of Gaussian**

Zgodnie z ustaleniami opisanymi w rozdziale 2 oraz zaproponowanymi założeniami metody, aby rozróżnić umieszczony na naczyniu nieruchomy napis lub naklejkę o bliżej nieokreślonym kształcie od zanieczyszczenia lub cząsteczki leku przylepionej do ścianki naczynia, konieczne jest wprowadzenie tych obiektów w ruch. W przypadku, kiedy wszystkie cząsteczki zawieszone w cieczy będą wprowadzone w ruch, a naczynie będzie nieruchome, możliwe jest wyekstrahowanie optyczne materii pływającej w roztworze w celu późniejszej identyfikacji. Obiekty nieporuszające się są nieistotne z punktu widzenia dalszych etapów, dlatego ważne jest, aby sposób wprowadzenia w ruch zawartości naczynia był w stanie „wzruszyć” wszystkie obiekty znajdujące się w naczyniu, tworząc przy tym jak najmniej pęcherzyków. Segmentacja ruchomych elementów obrazu w czasie rzeczywistym jest podstawowym etapem przeprowadzanym przed dalszą analizą obrazu w wielu zastosowaniach wymagających nadzoru i kontroli.

Metodą ekstrakcji pierwszego planu użytą w niniejszym opracowaniu jest bazujący na subtrakcji tła algorytm Mixture of Gaussian (MoG). Subtrakcja tła jest to rodzaj segmentacji obrazu, której celem jest odseparowanie obiektów ruchomych z nagrania (w tym przypadku sypkich obiektów, pęcherzyków itp.) od elementów nieruchomych (naczynia, tła, naklejek) [8]. Najprostsze algorytmy subtrakcji tła bazują na odejmowaniu od siebie aktualnej klatki oraz zapamiętanego modelu tła, zazwyczaj aktualizowanego na bieżąco na podstawie kilku do kilkunastu poprzednich klatek. Istnieją również odmiany algorytmów odporne na ruchy periodyczne tła, dzięki czemu elementy obrazu takie jak drgające ścianki naczynia, falująca woda lub liście poruszane na wietrze mogą zostać w pewnym stopniu zignorowane i zaliczone do fragmentu tła. W ich przypadku stosuje się metody statystyczne [10].

Zastosowany w metodzie algorytm wykorzystujący mieszankę rozkładów Gaussa (ang. Mixture of Gaussian), opisany szerzej w artykułach [9, 12], uwzględnia m.in. zmiany natężenia światła oraz aktualizuje tło na podstawie pewnej liczby poprzednich klatek. Do subtrakcji tła używane jest podejście, w którym przypuszcza się, że każdy z pikseli może zostać zamodelowany za pomocą mieszanki rozkładów Gaussa o określonych parametrach. W kolejnych krokach oblicza się, które piksele z nowej klatki odpowiadają założonemu modelowi i w zależności od wyniku uznaje się je z pewnym prawdopodobieństwem za tło lub w przeciwnym wypadku za pierwszy plan. Grupowanie wykrytych pikseli z pierwszego planu odbywa się za pomocą analizy połączonych komponentów (ang. Connected Component Labeling) [11]. Metoda MoG działa zgodnie z oczekiwaniami przy założeniu, że kamera używana do rejestrowania nagrania nie zmienia położenia w trakcie nagrania.

### Użycie funkcji


W środowisku Matlab zaimplementowana jest klasa ForegroundDetector z pakietu Vision używająca powyżej opisanej metody [12]. Zaimplementowana postać algorytmu oparta jest na postaci metody mieszanek Gaussa opisanych w [9] oraz [11]. Klasa ta pozwala na inicjalizację detektora i ustawienie podstawowych parametrów metody takich jak:

- Liczba początkowych klatek używana do wstępnego uczenia modelu tła (parametr NumTrainingFrames). Ze względu na krótkie nagrania (rzędu kilkuset klatek) zmieniono domyślną wartość 150 klatek uczących na 5, co pozwoliło na szybsze nauczanie modelu tła.
- Liczba rozkładów Gaussa (parametr NumGaussians) w zamodelowanej mieszance rozkładów została ustawiona na 5, co jest typową wartością używaną w tej metodzie.
- Początkowa wariancja w momencie inicjalizacji nowego rozkładu Gaussa. Jej wartością inicjalizowane są wszystkie rozkłady tworzące model Pierwszy plan – Tło. Ze względu na użycie obrazu w skali szarości (typ zmiennej Matlaba: uint8) początkowo stosowano domyślną wartość  $30^2$ , jednak w trakcie ręcznego kalibrowania algorytmu uznano, że wartość  $10^2$  w dokładniejszy sposób ekstrahuje najmniejsze drobiny, nie doprowadzając jednocześnie do nadmiernego wykrywania szumu kamery jako pierwszego planu.

Zaproponowane powyżej wartości domyślne używane w tej konkretnej implementacji metody MoG zostały zaczerpnięte z [12].



Rys. 10 Pojedyncza klatka przekonwertowana do skali szarości. Na podstawie kolejnych klatek algorytm MOG ekstrahuje pierwszy plan w postaci logicznej maski oraz aktualizuje statystyczny model tła.



Rys. 11 Maska logiczna pierwszego planu. Kolory maski zostały odwrócone. Czarne elementy (o wartości logicznej 1) są uznane przez algorytm MOG jako elementy pierwszego planu, czyli ruchome obiekty.

## 2.4 Otrzymanie przebiegów czasowych głównych cech maski pierwszego planu

### 2.4.1 Wstęp

Otrzymana maska pierwszego planu nie definiuje sama w sobie informacji, która w czystej postaci może posłużyć do klasyfikacji próbek. Konieczne jest zdefiniowanie pewnych cech opisujących w zwięzły sposób maskę pierwszego planu pojedynczej klatki. Następujący rozdział opisuje zaproponowane cechy (współczynniki opisujące maskę).

Kolejnym krokiem jest zebranie wartości cech obliczonych dla kolejnych masek pierwszego planu w postaci przebiegów, co pozwoli na późniejszą ich analizę pod kątem trendów, wartości średnich i innych współczynników.

Podobne podejście, opisujące przebiegi ilości cząsteczek w czasie oraz wysokości środka ciężkości, przedstawione zostało w publikacji [2]. Zaproponowane poniżej współczynniki zostały zaprojektowane tak, aby w dokładniejszy sposób oddawać zachowanie przebiegu czasowego pod kątem późniejszej klasyfikacji klasyfikatorem K-NN, w przeciwieństwie do poprzedniego podejścia, w którym współczynniki były dobierane pod kątem systemu regułowego.

Opisany w poprzednim rozdziale detektor pierwszego planu przekształca nową klatkę otrzymaną z nagrania na maskę logiczną  $FG$  (tablicę typu logicznego), którą można matematycznie opisać w następujący sposób:

$$foregroundSubtractor(KLATKA) = FG \quad (1)$$

$$FG = [b_{ij}] \in \text{BOOL}^{m \times n}, \text{ gdzie}$$

$$FG(m, n) = \begin{cases} 1, & \text{KLATKA}(m, n) \text{ uznana za pierwszy plan} \\ 0, & \text{KLATKA}(m, n) \text{ uznana za tło} \end{cases} \quad (2)$$

Przy takiej definicji tablicy  $FG$  można w sposób opisany w poniższych podrozdziałach opisać matematycznie każdą z cech. Cechy te, pomimo znacznego okrojenia pierwotnej informacji, odzwierciedlają te parametry, które są w metodzie istotne. Wartości cech obliczane na bieżąco dla każdej klatki wewnątrz ustanowionego Obszaru Zainteresowania (ang. Region Of Interest) tworzą przebieg czasowy dla następujących wielkości:

- Miejsce skupienia grupy cząsteczek – przybliżone za pomocą środka ciężkości, z reguły dość jednoznacznie pokazuje, czy grupa cząstek przemieszcza się z góry na dół (jak obiekty typu LEK), dryfuje lub oscyluje na stałej wysokości (jak w przypadku klasy ZANIECZYSZCZENIA), czy wznosi się do góry (jak klasa BĄBLE)
- Ilość cząsteczek – przybliżona za pomocą liczby równej ilości pikseli uznanych za pierwszy plan. Odzwierciedla informację o wielkości i liczności obiektów, które w danej klatce poruszały się w Obszarze Zainteresowania. W postaci przebiegu czasowego pozwala na analizę trendów ilości wykrytych obiektów w czasie i umożliwia określenie na tej podstawie niektórych własności nowej próbki (np. szybkiego zanikania cząstek). Informacja ta może pozwolić na klasyfikację konkretnych klas, co jest widoczne w przypadku m.in. klasy BĄBLE, dla której ilość cząstek spada gwałtownie, gdyż pęcherzyki powietrza powstałe przy obrocie naczynia dość szybko zanikają.
- Rozproszenie cząsteczek – przybliżone za pomocą momentu bezwładności obliczonego dla pikseli pierwszego planu. Przebieg ten może być pomocny w rozróżnieniu rozproszonych zanieczyszczeń charakterystycznych dla klasy ZANIECZYSZCZENIA od skupionych grup w próbkach typu LEK.

Cechy takie jak środek ciężkości oraz moment bezwładności mogą być używane w kontekście opisu obrazu [13]. Poniższe podrozdziały opisują w sposób sformalizowany każdą z tych cech. Zaobserwowane empirycznie własności cech podane są jedynie w celu uzasadnienia ich użycia, aczkolwiek nie jest to dowód, że każda z tych cech będzie skutecznie rozróżniała próbki różnych klas. Zasadność użycia takich cech jest możliwa do rozstrzygnięcia w kolejnych etapach poprzez analizę skuteczności klasyfikacji próbek. Wynika to z faktu, że zadaniem używanej do redukcji informacji metody PCA jest automatyczne „wybranie” najbardziej różnicujących współczynników z wszystkich obliczonych na podstawie przebiegów cech.

#### 2.4.2 Środek ciężkości - [CECHA1]

Matematyczny opis:

$$\text{Centroid} = (\text{centroidX}, \text{centroidY}), \text{ gdzie}$$

$$centroidX \in [0, width(ROI)]$$

$$centroidY \in [0, height(ROI)]$$

$$CentroidX = \frac{\sum_{i=0}^{width(ROI)} \sum_{j=0}^{height(ROI)} i * sgn(FG(i, j))}{IlośćCząstek} \quad (3)$$

$$CentroidY = \frac{\sum_{i=0}^{width(ROI)} \sum_{j=0}^{height(ROI)} j * sgn(FG(i, j))}{IlośćCząstek} \quad (4)$$

*ROI* – prostokąt zawierający interesującą część nagrania

Z punktu widzenia metody nie jest konieczne określenie położenia środka ciężkości wzdłuż osi OX, ponieważ interesujące jest tylko położenie grupy cząstek na osi OY (*CentroidY*), które to obserwowane w czasie odzwierciedla opadanie lub wznoszenie się grupy cząstek.

Następujące właściwości składowej *CentroidY* tej cechy zaobserwowano empirycznie:

- Dla klasy CZYSTA powinna być ustalona na połowie wysokości ROI
- Dla klasy ZANIECZYSZCZENIA utrzymuje się na względnie stałym poziomie
- Dla klasy LEK powinna w umiarkowanym tempie opadać z góry na dół naczynia
- Dla klasy BĄBLE szybko podnosi się do góry

#### **Zaobserwowane uwagi:**

- Przy braku odpowiedniej ilości cząstek, cecha ustalana jest na poziomie środka wysokości i szerokości obszaru ROI.
- Przekazywana do dalszych etapów składowa *CentroidY* została znormalizowana do przedziału  $[0,1]$  poprzez podzielenie przez *height(ROI)*.



Rys. 12 Położenie obliczonego środka ciężkości w przypadku dużej ilości zanieczyszczenia nierozpuszczalnego odpowiadającego klasie ZANIECZYSZCZENIA



Rys. 13 Położenie obliczonego środka ciężkości w przypadku klatki z nagrania otrzymanego dla przesypującej się małej ilości soli (symulującej klasę LEK) z góry na dół naczynia

### 2.4.3 Ilość cząstek - [CECHA2]

Matematyczny opis:

$$IlośćCząstek = \sum_{i=0}^{width(ROI)} \sum_{j=0}^{height(ROI)} FG(i,j) \quad (5)$$

Właściwości cechy zaobserwowane empirycznie:

- Dla klasy CZYSTA cecha jest bliska zeru.
- Dla klasy ZANIECZYSZCZENIA utrzymuje się na dość stałym, wysokim poziomie
- Dla klasy LEK w niektórych sytuacjach rośnie do dość dużej wartości a następnie zmniejsza się w podobnym tempie.
- Dla klasy BĄBLE szybko spada od dość dużej wartości

**Zaobserwowane uwagi:**

- Normalizacji cechy (5) dokonano poprzez podzielenie jej przez maksymalną możliwą ilość pikseli wykrytych jako pierwszy plan (6), czyli:

$$MaxIlośćCząstek = width(ROI) * height(ROI) \quad (6)$$



#### 2.4.4 Moment bezwładności - [CECHA3]

Moment bezwładności, czyli moment centralny drugiego rzędu został zdefiniowany w danym zadaniu następująco („masa” jednego piksela wynosi 1):

$$MB = \sum_{i=0}^{width(ROI)} \sum_{j=0}^{height(ROI)} sgn(FG(i,j)) * ((i - CentroidX)^2 + (j - CentroidY)^2) \quad (7)$$

Właściwości cechy zaobserwowane empirycznie:

- Dla klasy CZYSTA cecha jest bliska zeru
- Dla klasy LEK w niektórych sytuacjach rośnie do dość dużej wartości a następnie zmniejsza się
- Dla klasy BĄBLE widoczna jest duża zmienność wartości w czasie

Ze względu na wysokie maksymalne wartości otrzymane w przypadku klatek nagrania zawierających dużą ilość rozproszonych cząstek, zdecydowano się na normalizację wartości do przedziału [0,1]. Normalizację uzyskano przez podzielenie wartości cechy dla każdej klatki przez maksymalną teoretycznie osiągalną wartość momentu bezwładności (8) (osiąganą dla hipotetycznej sytuacji, gdy maska pierwszego planu to całkowicie wypełniony prostokąt o środku ciężkości przesuniętym w jeden z rogów prostokąta).

*MaxMomentBewładności*


$$= \frac{1}{3} width(ROI) * length(ROI) * (width(ROI)^2 + length(ROI)^2) \quad (8)$$

#### 2.4.5 Przykładowe przebiegi czasowe

Wszystkie powyższe cechy zostają obliczane na bieżąco dla każdej nowej klatki dając w wyniku zbiór trzech przebiegów czasowych. Ze względu na rozpiętość przebiegu w czasie niesie on informacje o zmianach i zachowaniu grupy cząstek na różnych etapach danego nagrania, a tym samym uwypukla różnice pomiędzy grupami, gdyż każda z klas jest z reguły reprezentowana za pomocą tych przebiegów w specyficzny dla siebie sposób.

Przykładowe przebiegi obliczone dla 30 próbek uczących należących do 3 głównych klas zostają przedstawione w Tab. 1. Należy zwrócić uwagę na odwróconą skalę OY dla przebiegu Cecha 1, która wynika ze sposobu implementacji układu współrzędnych przez program Matlab (rosnąca wartość odpowiada opadaniu środka ciężkości).

Tab. 1 Poglądowe wykresy przedstawiające przebiegi czasowe cech 1-3 dla podstawowych trzech klas. Wykresy zostały wyskalowane od minimalnej do maksymalnej wartości występującej w danym przebiegu.



Wizualizacja przebiegów na wykresach pokazała, iż niektóre cechy odzwierciedlają różnice między-klasowe w lepszym stopniu niż inne. Oznacza to, że prawdopodobnie konieczne będzie nadanie większych wag współczynnikiem opisującym zdecydowanie bardziej unikatowe przebiegi cechy 1 i jednej z cech 2 i 3 (jak pokazały otrzymane wykresy, cechy te są reprezentowane przez podobne przebiegi).

Kolejnym wnioskiem jest zauważenie, że choć niektóre cechy opisują próbki konkretnych klas w sposób spójny (m.in. w przypadku cechy 2 opisującej próbki klasy LEK), to istnieją kombinacje, dla których taka spójność nie jest zachowana. Jest to widoczne szczególnie w

przypadku klasy BĄBLE i cechy 1, czyli wysokości położenia grupy cząstek. Dopiero uwzględnienie wniosków z poprzedniego akapitu pozwala na poprawne interpretowanie tej cechy, choć nie jest to ogólną zasadą.

## **2.5 Analiza i uproszczenie przebiegów czasowych cech**

### **2.5.1 Wstęp**

Otrzymane w poprzednim etapie surowe dane są podatne na chwilowe wahania powstałe w wyniku występujących w nagraniu anomalii (m.in. nagłych skoków Cechy 2 i Cechy 3 w chwili, gdy naczynie zadrgało w sposób niekontrolowany i w konsekwencji ścianki naczynia oraz powstałe refleksy świetlne zostały błędnie uznane za pierwszy plan) oraz innych czynników zależnych od działania użytych algorytmów. Jednym z najbardziej znaczących czynników, które mogłyby zaburzać rezultaty jest fakt, iż algorytm subtrakcji pierwszego planu generuje swój model tła na podstawie pierwszych kilku klatek i z każdą kolejną klatką aktualizuje ten model [9, 11]. W przypadku, gdy nagranie nie zaczyna się w chwili, w której w Obszarze Zainteresowania nie ma żadnych obiektów, dojdzie do zafałszowanego zamodelowania tła, a tym samym chwilowego zakłamania wykrywania cząstek (tych, które w początkowej fazie uczenia poruszały się zbyt wolno i zostały uznane za tło). Dlatego konieczne jest usunięcie z dalszej analizy pierwszych kilkunastu pozycji z przebiegów czasowych, co odpowiada chwili, w której model tła jest już skorygowany o początkowe błędy.

Z punktu widzenia implementacji, każda z cech obliczana jest dla masek pierwszego planu odpowiadających kolejnym klatkom nagrania i jest umieszczana w tablicy o długości `ILOŚĆ_KLATEK - 1` (ze względu na otrzymywanie maski pierwszego planu w sposób różnicowy). Otrzymane są w ten sposób następujące przebiegi czasowe:

- `PRZEBIEG_Cecha1`
- `PRZEBIEG_Cecha2`
- `PRZEBIEG_Cecha3`

Informacja o zachowaniu grupy cząstek w postaci przebiegów jest na tym etapie metody wystarczająco okrojona, aby pozwalała na analizę i obróbkę przed końcową nauką klasyfikatora.

Wstępna obserwacja przebiegów czasowych cech pokazała, że jest możliwe sprecyzowanie pewnych współczynników (opisanych w kolejnych podrozdziałach) ekstrahujących informacje o trendach i właściwościach przebiegów pod kątem ich późniejszej klasyfikacji.

Dla każdego z przebiegów użyto tego samego zestawu współczynników do jego opisania. W przypadku ilości cząsteczek (`CECHA2`) i momentu bezwładności (`CECHA3`) zachowano dodatkowo informację sprzed normalizacji informującą o skali maksymalnej ilości pikseli pierwszego planu i maksymalnego momentu bezwładności.

## 2.5.2 Obróbka przebiegu

Z powodów opisanych na początku rozdziału konieczny jest etap poprzedzający dalsze opisywanie przebiegów odpowiednią wstępną obróbką.

### Obcinanie krańców przebiegu

Ze względu na często najbardziej zniekształcone informacje na początku przebiegu stosuje się obcinanie (11) początku przebiegu – fragmentu o długości  $USUŃ\_KLATKI\_POCZĄTEK = 25$  klatek.

Operacja na odpowiednim wektorze jest opisana następującym pseudokodem:

$$lewy = USUŃ\_KLATKI\_POCZĄTEK \quad (9)$$

$$prawy = length(przebieg) \quad (10)$$

$$przebieg = przebieg(lewy : prawy) \quad (11)$$

### Wyglądzenie przebiegu

Na całym przebiegu stosuje się filtr uśredniający Savitzky-Golaya o wielomianie uśredniającym rzędu 3 oraz oknie o rozmiarze 49 klatek, aby usunąć wpływ nagłych „skoków” oraz odszumić przebieg. Do tego filtru stosowana jest funkcja programu Matlab: *sgolayfilt()*.


Filtr Savitzky-Golay’a jest rodzajem filtru cyfrowego używanego do wygładzania funkcji oraz zwiększającego stosunek sygnału do szumu bez nadmiernego zniekształcenia samego sygnału. Rezultat ten jest osiągany poprzez aproksymację przylegających kolejno punktów krzywej (w liczbie równej  $ROZMIAR\_FILTRU$ ) za pomocą wielomianu niskiego rzędu metodą najmniejszych kwadratów [14]. Filtr ten został wybrany ze względu na możliwość implementacji średniej kroczącej, używanej powszechnie przy przebiegach czasowych do wygładzania lokalnych fluktuacji przy zachowaniu globalnych trendów [14].

$$ROZMIAR\_FILTRU = 49$$

$$rzadWielomianu = 3$$

$$przebieg = sgolayfilt(przebieg, rzadWielomianu, oknoFiltru) \quad (12)$$

Parametry funkcji dobrano metodą prób i błędów tak, aby osiągnąć zamierzone odfiltrowywanie nie tracąc informacji o globalnych trendach zaobserwowanych dla przebiegu (Rys. 14). Wymagana jest dokładna kalibracja parametru  $ROZMIAR\_FILTRU$  w fazie testów.



Rys. 14 Filtracja przebiegu filtrem uśredniającym Savitzky-Golay'a

### 2.5.3 Współczynniki opisujące przebiegi czasowe

Współczynniki zaproponowane do opisu obrobionego przebiegu miały za zadanie wyłuskać informacje o trendach, skrajnych wartościach oraz uśrednionych wartościach początkowych i końcowych, co po wstępnej analizie wykresów próbek uczących uznano za odpowiednie podejście. Poniższe współczynniki są po części oparte na sposobie opisu krzywej opracowanym przy pierwszych eksperymentach z roztworami leków, przedstawionym w [2]. Zaproponowano 10 współczynników opisujących jeden przebieg. Ze względu na analogiczny charakter informacji wyłuskiwanych z przebiegów, ten sam zestaw 10 współczynników jest użyty do analizy wszystkich 3 przebiegów.

#### Nachylenie dwudzielone

Wyjaśnienie - Opisuje nachylenie oddzielnie pierwszej i drugiej połowy przebiegu czasowego. Nachylenie liczone jest na podstawie pierwszej i ostatniej wartości danego przedziału. W ten sposób obliczone nachylenie pomnożone jest razy 1000 dla odpowiedniego wyskalowania.

Wzory:


*Dług* – długość przebiegu (indeks ostatniego elementu)

*PolowaDług* – połowa przebiegu (indeks środkowego elementu)

$$\text{nachylenie1} = 1000 * \frac{\text{przebieg}(\text{PolowaDług}) - \text{przebieg}(1)}{\text{PolowaDług}} \quad (13)$$

$$\text{nachylenie2} = 1000 * \frac{\text{przebieg}(\text{Dług}) - \text{przebieg}(\text{PolowaDług})}{\text{PolowaDług}} \quad (14)$$

Wizualizacja współczynników *nachylenie1* oraz *nachylenie2* została przedstawiona na Rys. 15. Ich wartości można utożsamiać z tangensem kąta nachylenia aproksymacji odcinkiem do poziomu osi OX dla obydwu przedziałów.



Rys. 15 Wizualizacja współczynnika nachylenie 1 i nachylenie 2. Ich wartości można utożsamiać z tangensem kąta nachylenia aproksymacji odcinkiem każdego z przedziałów do poziomu osi OX.

## Regresja liniowa

Wyjaśnienie – Regresja liniowa opisuje nachylenie w skali całego przebiegu. Krzywa zostaje zaproksymowana za pomocą funkcji liniowej (najlepsze dopasowanie jest określone metodą najmniejszych kwadratów) [15].

Do obliczania stosuje się funkcję programu Matlab: *polyfit()* dla rzędu aproksymacji równemu 2 [16].

Otrzymane współczynniki:

**nachylenie\_aprox** – nachylenie zaproksymowanej krzywej do osi OX

**blad\_aprox** – błąd średniokwadratowy przybliżenia

## Średnia i wariancja

Wyjaśnienie – opisują poziom przebiegu w danym czasie poprzez średnią (współczynnik **średnia**) oraz zmienność przebiegu poprzez kwadrat odchylenia standardowego (**wariancja**). Współczynnik zaprojektowany pod kątem rozróżniania podobnych przebiegów będących na różnych poziomach „zakresu” wartości.

## Uśredniony koniec/początek

Wyjaśnienie – określa uśredniony poziom przebiegu oddzielnie dla fragmentu początku i końca przebiegu. Współczynniki te zostały zaproponowane, ponieważ w wielu przypadkach sama zmiana pomiędzy początkiem, a końcem przebiegu może wskazywać na przynależność do którejś z klas. Widoczne jest to m.in. na przykładzie klasy BĄBLE, w której początkowe

wartości przebiegu CECHA2 są wysokie i szybko się zmniejszają, pod koniec osiągając poziom bliski zeru.

Ilość klatek wzięta do średniej jest określona przez parametr ZAKRES\_ŚREDNIA i w domyślnym przypadku wynosi 50. Do uśredniania wartości użyto funkcji programu Matlab: *mean()*.

Wzory:

$$\textit{sredniaPoczatek} = \textit{mean}(\textit{przebieg}(1:\textit{ZAKRES\_SREDNIA})) \quad (15)$$

$$\textit{sredniaKoniec} = \textit{mean}(\textit{przebieg}(\textit{Dlug} - \textit{ZAKRES\_SREDNIA} : \textit{Dlug})) \quad (16)$$

Konieczna jest kalibracja parametru ZAKRES\_ŚREDNIA w ramach przeprowadzanych testów.

### Wartość minimalna/maksymalna

Wyjaśnienie – opisuje odpowiednio minimalny i maksymalny element przebiegu. Współczynnik został zaproponowany, aby zachować informację nie tylko o trendach występujących w przebiegach, ale również o skrajnych wartościach przebiegu.

Wzory:

$$\textit{przebiegMin} = \textit{min}(\textit{przebieg}) \quad (17)$$

$$\textit{przebiegMax} = \textit{max}(\textit{przebieg}) \quad (18)$$

## 2.6 Podsumowanie

Rezultatem tego etapu metody jest otrzymanie wektora złożonego z 30 współczynników opisujących przebiegi czasowe odpowiednio środka ciężkości, ilości cząstek i momentu bezwładności maski pierwszego planu (Tab. 2). Wektor ten, choć jest już dużym uproszczeniem początkowej postaci opisu próbki, to wciąż nie jest materiałem, który w sposób efektywny można użyć do porównań z nowymi próbkami. Część ze współczynników jest ze sobą w dużym stopniu skorelowana, inne nie mają żadnej korelacji lub nie są wystarczająco różnicujące pod kątem odróżniania próbek akceptowalnych od tych nieakceptowalnych. Istnieje więc potrzeba redukcji zmiennych opisujących każdą z próbek tak, aby proces klasyfikacji odbywał się jedynie za pomocą istotnych statystycznie i jakościowo współczynników. Rozwiązaniem tego problemu jest metoda PCA opisana w kolejnym rozdziale.

Tab. 2 Lista współczynników opisujących pojedynczą próbkę

Przebieg	Wzorec współczynnika	Nazwa skrótowa
Środek ciężkości	nachylenie1	c1
	nachylenie2	c2
	blad_aprox	c3
	średnia	c4
	wariancja	c5
	przebiegMax	c6
	przebiegMin	c7
	sredniaPoczątek	c8
	sredniaKoniec	c9
	nachylenie_aprox	c10
Ilość cząstek	nachylenie1	c11
	nachylenie2	c12
	blad_aprox	c13
	średnia	c14
	wariancja	c15
	przebiegMax	c16
	przebiegMin	c17
	sredniaPoczątek	c18
	sredniaKoniec	c19
	nachylenie_aprox	c20
Moment bezwładności	nachylenie1	c21
	nachylenie2	c22
	blad_aprox	c23
	średnia	c24
	wariancja	c25
	przebiegMax	c26
	przebiegMin	c27
	sredniaPoczątek	c28
	sredniaKoniec	c29
	nachylenie_aprox	c30



## **3 Redukcja wymiaru wektorów opisujących próbki metodą analizy głównych składowych (PCA)**

### **3.1 Wstęp do PCA**

#### **Opis i działanie metody**

Metoda analizy głównych składowych (ang. Principal Component Analysis – PCA) jest jedną z najbardziej popularnych metod analizy czynnikowej. W metodzie tej dany jest zbiór danych składający się z  $P$  obserwacji (próbek), z których każda opisana jest przez  $N$  współczynnika, co może być interpretowane jako chmura  $P$  punktów w przestrzeni  $N$ -wymiarowej. Główną ideą metody jest redukcja wymiaru zbioru danych złożonych z dużej liczby nieskorelowanych zmiennych zachowując jednocześnie jak najwięcej z całkowitej zmienności obecnej w zbiorze danych (interpretacja całkowitej i pojedynczej zmienności opisana jest pod koniec niniejszego rozdziału). Osiąga się to poprzez transformację w nowy zestaw zmiennych, tzw. głównych składowych (ang. principal components), które są nieskorelowane i ułożone w taki sposób, że pierwsza ze z nich zachowuje największą część zmienności zawartej w oryginalnych zmiennych (czyli maksymalizowana jest wariancja pierwszej składowej), druga składowa zachowuje drugą największą część itd. [17]. Powoduje to, że kolejne główne składowe mają coraz mniejszy udział w całkowitej zmienności zbioru danych, a tym samym przy niewielkim poziomie błędów mogą zostać odrzucone nie tracąc dużej części tej zmienności.

Metoda ta pozwala na zidentyfikowanie wzorców i relacji w zbiorze danych, a przede wszystkim na przedstawienie danych w sposób podkreślający różnice i podobieństwa występujące w danych [18]. Jest to szczególnie użyteczne przy analizie wysokowymiarowych zbiorów danych, w przypadku których graficzna reprezentacja i analiza wykresu nie zawsze jest możliwa. To i wcześniej opisywana zdolność do kompresji danych powoduje, że metoda PCA jest wykorzystywana w wielu zastosowaniach, począwszy od kompresji obrazów w grafice komputerowej po analizę dużych zbiorów danych w statystyce.

Z matematycznego punktu widzenia metoda PCA polega na przekształceniu danych za pomocą liniowej transformacji ortogonalnej do nowego układu współrzędnych, w którym największa wariancja projekcji zbioru danych odpowiada pierwszej współrzędnej nowego układu (nazywana pierwszą główną składową), kolejna największa wariancja odpowiada drugiej współrzędnej itd. [17]. W raporcie używana jest wersja metody PCA opartej na macierzy korelacji.

Konieczne jest zwrócenie uwagi na fakt, że metoda PCA jest podatna na skalowanie zmiennych (gdyż ta sama zmienna pomnożona przez dużą stałą nadaje jej dużo większe znaczenie, gdyż stopień jej udziału w wariancji zbioru danych odpowiednio wzrasta). Z tego powodu stosuje się uprzednią standaryzację wszystkich zmiennych (w przypadku macierzy kowariancji stosowałoby się jedynie przesunięcie każdej zmiennej o wartość oczekiwaną), choć nie jest to rozwiązanie, które gwarantuje dobre rezultaty metody. W przypadku tego opracowania uzasadniono konieczność dokonania odpowiedniej standaryzacji tym, że

pomimo wstępnego skalowania współczynników w fazie opisu przebiegów czasowych wyrażają się one w różniących się znacząco zakresach. Tym samym wariancje zmiennych o dużym zakresie wartości (jak np. średnia składowej Y środka ciężkości z całego przebiegu) bez odpowiedniego standaryzowania wyparłaby w dużym stopniu wpływ wariancji pochodzący od zmiennych o małym zakresie (pomimo tego samego początkowego wyskalowania zakresu współczynnika), czyli np. małych wartości momentów bezwładności.

### Algorytm obliczania PCA

Podczas, gdy szczegółowy opis metody PCA wraz z wyprowadzeniami znajduje się w publikacji [17], ramowy schemat algorytmu jest następujący:

- Zgromadź dane w macierzy *SuroweDane* o rozmiarze  $P \times N$ , gdzie każdy wiersz odpowiada innej obserwacji, a każda kolumna innej zmiennej
- Zestandaryzuj każdą ze zmiennych działając na odpowiednich kolumnach. Po tym etapie każda zmienna będzie miała wartość oczekiwaną równą 0 i wariancję równą 1. Przekształcone zmienne zawarte są w macierzy *StdSuroweDane*
- Oblicz estymowaną macierz korelacji  $R$  dla macierzy *StdSuroweDane*. Ponieważ zmienne odpowiadające współczynnikiem są ustandaryzowane, to wzór jest taki sam jak w przypadku macierzy kowariancji:

$$R = \frac{1}{P-1} * StdSuroweDane^T * StdSuroweDane \quad (19)$$

- Oblicz wartości i wektory własne macierzy korelacji  $R$
- Ułóż wektory własne w kolejności nierosnącej odpowiadających im wartości własnych. Przy redukcji wymiaru danych z  $N$  do  $M$  wymiarów zachowaj jedynie pierwsze  $M$  wektorów własnych w macierzy przekształcenia  $T$
- Oblicz położenie danych w nowej przestrzeni za pomocą wzoru:

$$StdNoweDane = T * StdSuroweDane \quad (20)$$

Powyższy algorytm pozwala przekształcić zbiór danych do nowej przestrzeni o zredukowanym wymiarze. Tę samą macierz  $T$  można użyć do przekształcenia nowego, pojedynczego wektora współczynników opisującego klasyfikowaną próbkę do tej samej przestrzeni, jednak konieczne jest uprzednie przekształcenie nowego wektora w taki sam sposób, w jaki ustandaryzowano próbki uczące w kroku 2 powyższego algorytmu.

### Interpretacja zmienności zbioru danych pod kątem metody PCA

Przy interpretacji rezultatów metody PCA używane jest stwierdzenie, że główna składowa może wyjaśniać określoną część (zazwyczaj wyrażaną w procentach) całkowitej zmienności danych. Pojęcia te odpowiadają wartościom liczonym w następujący sposób. W metodzie PCA stopień zachowania zmienności danych (ang. variability) dla danej głównej składowej odpowiada proporcjonalnie odpowiadającej jej wartości własnej. Oznacza to, że wielkość


wartości własnej można utożsamiać z wariancją danej składowej. Z tego powodu stosuje się sortowanie otrzymanych wektorów własnych (czyli głównych składowych) na podstawie nierosnącej kolejności odpowiadających im wartości własnych. W związku z tym całkowita zmienność danych odpowiada sumie wszystkich wartości własnych macierzy kowariancji (lub korelacji), podczas gdy zmienność wyjaśniana przez pojedynczą główną składową wyrażona w procentach odpowiada ilorazowi odpowiadającej wartości własnej i sumy wszystkich wartości własnych.

## 3.2 Redukcja wymiaru

### Wstęp

Dane wejściowe w postaci 30 współczynników opisujących każdą z 30 próbek video zebrano w macierzy *SuroweDane*, w której każda kolumna odpowiada jednemu współczynnikowi natomiast wiersz odpowiada jednej próbce opisanej przez zestaw współczynników. Następnie dokonano standaryzacji każdej ze zmiennych odpowiadającej kolumnie w macierzy *SuroweDane*, co daje nową macierz *StdSuroweDane*. Jednocześnie zapamiętano dla każdej ze zmiennych (kolumn) wartość oczekiwaną oraz odchylenie standardowe, co będzie konieczne do „pseudo-ustandaryzowania” nowej próbki przed późniejszą klasyfikacją.

Ze względu na ilość współczynników opisujących próbki trudne jest samodzielne przeanalizowanie i utworzenie reguł pozwalających na skuteczne sklasyfikowanie próbek na podstawie takich współczynników. Wynika to z faktu, że część zmiennych może być ze sobą w mniejszym bądź większym stopniu skorelowana i mogłaby być zastąpiona nowym współczynnikiem będącym kombinacją liniową tych ze zmiennych, które niosą ze sobą najwięcej rozróżniającej informacji. Opisana tu korelacja zmiennych jest widoczna na Rys. 16. Biorąc pod uwagę np. współczynnik *c4* widać silne skorelowanie dodatnie pomiędzy tym współczynnikiem, a m.in. współczynnikami *c6*, *c7*, *c8* i *c9*. Oznacza to, że w zbiorze próbek uczących dla przebiegu środka ciężkości istnieje zależność pomiędzy wartością średnią przebiegu a wartością minimalną, maksymalną i uśrednionym początkiem i końcem tego przebiegu, co jest rozsądną obserwacją. Podobne zależności można zaobserwować również dla innych zmiennych, m.in. dla grupy współczynników *c11*, *c18*, *c19*, *c20* i *c21*.



Rys. 16 Macierz korelacji macierzy danych współczynników po ustandaryzowaniu współczynników (macierzy StdSuroweDane). Pierwsza kolumna i wiersz tabeli to współrzędne współczynników c1-c30, a kolor na przecięciu współrzędnych odzwierciedla stopień korelacji odpowiednich współczynników. Legenda: Kolor ciemno-niebieski – silna korelacja dodatnia, kolor ciemno-czerwony – silna korelacja ujemna, kolor biały – brak korelacji pomiędzy współczynnikami


Zadaniem metody PCA jest obliczenie nowych współczynników – głównych składowych, które mogą skutecznie zastąpić „surowe” 30-wymiarowe dane uproszczoną, kilkunastowymiarową przestrzenią w sposób opisany we wstępie teoretycznym.

Do obliczenia metody zastosowano zaimplementowaną w programie Matlab funkcję `pca()` [19]. W ramach analizy działania metody przetestowano redukcję wymiaru surowych danych do  $M$  głównych składowych, gdzie  $M \in [1,2,3,4,5,6,7,8,9]$ . Zaniechano analizy wyników dla  $M > 9$ , ponieważ już w przypadku 9-wymiarowej przestrzeni rezultaty redukcji były wystarczające do zobrazowania działania metody. Analiza zbioru danych uczących w zredukowanej przy pomocy PCA przestrzeni opisana jest poniżej, natomiast wyniki testów analizy głównych składowych w kontekście całości metody zostały przedstawione w rozdziale 6.

### Rezultat działania metody PCA

W wyniku działania metody PCA obliczono pierwsze 9 głównych składowych ( $F1-F9$ ). Ze względu na własności metody, aby zastosować redukcję do  $M$  wymiarów wystarczy pozostawić w kolumnach macierzy przekształcenia  $T$  obliczone  $M$  pierwszych głównych składowych. Tym samym, aby przeanalizować wyniki można posłużyć się zbiorczymi tabelami i wykresami dla 9 wymiarów i odpowiednio zinterpretować je dla mniejszych  $M$ .

Zgodnie z oczekiwaniami przekształcenie punktów ze starej ( $N = 30$ ) do nowej przestrzeni  $M$ -wymiarowej pozwoliło na usunięcie korelacji ze zmiennych opisujących próbki. Widać to szczególnie przy porównaniu macierzy korelacji dla danych opisujących próbki w starej (Rys. 16) i nowej (Rys. 17) przestrzeni generowanej przez ortogonalne główne składowe.




Rys. 17 Macierz korelacji dla zbioru danych w przestrzeni pierwszych 9 głównych składowych. Pierwsza kolumna i wiersz to współrzędne głównych składowych F1-F9, a kolor na przecięciu współrzędnych odzwierciedla korelację odpowiednich współczynników. Legenda: Kolor ciemno-niebieski – silna korelacja dodatnia, kolor ciemno-czerwony – silna korelacja ujemna, kolor biały – brak korelacji pomiędzy współczynnikami.

Analiza sumarycznej zmienności dla kolejnych głównych składowych (ang. cumulative variability) pokazuje, że w przypadku redukcji do zaledwie 5 pierwszych głównych składowych zachowane jest ponad 80% całkowitej zmienności zbioru danych, natomiast w przypadku pozostawienia 9 pierwszych głównych składowych wartość ta osiąga ponad 95%. Rezultaty dla pozostałych  $M$ , określone jako przekształcenie danych do przestrzeni generowanej przez główne składowe F1 do FM zostały przedstawione w Tab. 3.

Tab. 3 Wyniki zastosowania metody PCA na 30-wymiarowym zbiorze danych. Wiersz Zmienność - Zmienność zbioru danych wyjaśniana przez daną główną składową (%), Sumaryczna zmienność - Sumaryczna zmienność zbioru danych wyjaśniana przez daną i poprzedzające ją składowe (%)

Główna składowa	F1	F2	F3	F4	F5	F6	F7	F8	F9	...
Wartości własne	9.75	7.40	3.62	2.16	1.49	1.38	1.34	0.97	0.62	...
Zmienność (%)	32.49	24.67	12.06	7.21	4.96	4.59	4.46	3.22	2.08	...
Sumaryczna zmienność (%)	32.49	57.16	69.22	76.43	81.40	85.99	90.45	93.67	95.75	...


W celu zobrazowania wpływu ilości głównych składowych na zachowaną sumaryczną zmienność zbioru danych, informacje z Tab. 3 przedstawiono na Rys. 18.




Rys. 18 Wykres przedstawia udział pierwszych 9 głównych składowych w zachowaniu zmienności pierwotnego zbioru danych przedstawiony jest na wykresie słupkowym. Linia ciągłą narysowany jest wykres przedstawiający sumaryczny procent zmienności wyjaśniany przez daną i poprzedzające główne składowe.

Na przykładzie redukcji danych do  $M = 2$  wymiarów pokazano wpływ doboru głównych składowych użytych do generowania nowej przestrzeni na rozłożenie próbek z różnych klas (Tab. 4). Zaobserwowano, że dla przestrzeni ( $F_1, F_2$ ) klasy są rozmieszczone w łatwych do odseparowania obszarach, natomiast w przypadku składowych ( $F_1, F_3$ ) klasy ZANIECZYSZCZENIA i BABLE w dużym stopniu się nakładają.


Tab. 4 Wykresy przedstawiają zbiór punktów uczących zredukowany do dwuwymiarowej przestrzeni przy zachowaniu rozróżnienia klasowego. Wykres (a) – Redukcja do głównych składowych  $F_1$  i  $F_2$ , (b) –  $F_2$  i  $F_3$ , (c) –  $F_3$  i  $F_1$





(c)

Dodatkowo w celu wizualizacji uzyskanej redukcji wymiarów, dane opisujące próbki w trójwymiarowej przestrzeni głównych składowych  $F1, F2$  oraz  $F3$  zostały zobrazowane na Rys. 19.



Rys. 19 Wykres w 3-wymiarowej przestrzeni  $F1, F2, F3$  obrazuje przynależność do klas dla 30-wymiarowego zbioru uczącego na podstawie położenia punktów w zredukowanej przestrzeni.

### 3.3 Podsumowanie

Użyta metoda PCA pozwala na znaczną redukcję wymiaru danych opisujących próbki przy jednoczesnym zachowaniu dużej części sumarycznej zmienności tego zbioru.

Ponieważ nie można bezpośrednio utożsamiać ilości zachowanej zmienności ze skutecznością działania metody w kolejnych etapach, konieczne jest przeprowadzenie oddzielnych testów pozwalających na dobranie parametru redukcji wymiaru  $M$  w celu zmaksymalizowania skuteczności klasyfikacji za pomocą K-NN. Wyniki testów zostały przedstawione w rozdziale 6.

## 4 Uczenie klasyfikatora na podstawie zredukowanych wektorów opisujących

### 4.1 Opis metody K-NN

Metoda K-NN, lub inaczej metoda K najbliższych sąsiadów należy do grupy metod uczenia nadzorowanego typu *lazy learning*. Oznacza to, że klasyfikacja tą metodą nie polega na zbudowaniu modelu matematycznego upraszczającego i uogólniającego zbiór treningowy, a raczej na zgromadzeniu i zapamiętaniu informacji uczących i późniejszym wykorzystaniu ich w klasyfikacji nowych obserwacji na bieżąco [21].

W stosowanej w poniższym opracowaniu nomenklaturze przez obserwację rozumie się M-wymiarowy wektor, tworzony przez M zmiennych opisujących pojedynczą próbkę (materiał video). Zbiór P obserwacji użytych do uczenia algorytmu nazywamy zbiorem uczącym. Każda z P obserwacji uczących jest opisana dodatkowo etykietą, która definiuje, do jakiej klasy należy dana obserwacja [22].

Metodę K-NN można podzielić na dwa główne etapy:

#### 1. Trening

- a. Dokonaj wstępnej obróbki danych (normalizacja M zmiennych lub pozostawienie bez zmian oryginalnych danych opisujących P obserwacji)
- b. Zapamiętaj cały zbiór uczący (otrzymanie „chmury” P punktów w przestrzeni M-wymiarowej)

#### 2. Klasyfikacja

- a. Pobierz M-wymiarowy wektor testowy (przeznaczony do sklasyfikowania)
- b. Dokonaj obróbki zmiennych adekwatnie do metody obranej w kroku 1.a.
- c. Oblicz odległość obserwacji testowej od każdej obserwacji ze zbioru uczącego zgodnie z ustaloną metryką.
- d. Zbadaj etykiety K najbliższych sąsiadów. Policz ile i jakich etykiet zostało przypisanych do tych sąsiadów.
- e. Nadaj badanej obserwacji etykietę odpowiadającą najczęściej występującej etykiecie wśród K najbliższych sąsiadów. W przypadku, gdy dwie klasy mają taką samą liczbę etykiet, etykietę nowej obserwacji nadaj losując spośród równolicznych sąsiednich etykiet.


Otrzymanie nauczonego modelu klasyfikatora w programie Matlab uzyskano za pomocą klasy *ClassificationKNN* i metody *fit* tej klasy [22]. W przypadku niniejszego opracowania zastosowano wersję metody K-NN bez wstępnej obróbki danych, ponieważ dane zostają odpowiednio przekształcone przez metodę PCA.



## Wizualizacja działania metody

Ilustracja powyższego algorytmu jest przedstawiona na Rys. 20. Klasyfikator o parametrze  $K = 5$  został nauczony grupą  $P = 30$  próbek uczących. Dane opisujące zostały zredukowane w tym przypadku do  $M = 2$  wymiarów w celu umożliwienia wizualizacji. Zastosowano metrykę euklidesową.

Do klasyfikacji przeznaczona została nowa próbka. Po odpowiednim opisaniu i zredukowaniu do dwuwymiarowej przestrzeni położenie nowej próbki zostało zaznaczone na wykresie. Okrąg o środku w nowym punkcie zawiera pierwszych pięciu najbliższych sąsiadów nowej próbki z grupy uczącej. Podliczenie klas zawartych w okręgu wykazuje, że aż 4 najbliższych sąsiadów to próbki klasy ZANIECZYSZCZENIA, podczas gdy ostatni sąsiad jest klasy LEK. Oznacza to, że nowa próbka zostaje sklasyfikowana jako ZANIECZYSZCZENIA.



Rys. 20 Ilustracja działania klasyfikatora  $K$ -NN dla  $K = 5$  na przykładzie danych reprezentowanych w dwóch wymiarach. Nowa próbka przeznaczona do sklasyfikowania zaznaczona jest czarnym krzyżem. Okrąg o środku w nowym punkcie zawiera jego 5 najbliższych sąsiadów.

## Metryka

Ponieważ sposób porównywania obserwacji w tej metodzie bazuje na obliczaniu odległości pomiędzy punktami w przestrzeni  $n$ -wymiarowej, istotne jest obranie i dopasowanie do problemu metryki użytej w tych obliczeniach. Podstawowe metryki używane do obliczania odległości dwóch punktów w przestrzeni  $n$ -wymiarowych są następujące:

Dla  $x, y \in \mathbb{R}^n$ :

- Metryka Euklidesowa

$$d_e(x, y) = \sqrt{(y_1 - x_1)^2 + \dots + (y_n - x_n)^2} \quad (21)$$

- Metryka Manhattan (taksówkarza)

$$d_m(x, y) = \sum_{k=1}^n |x_k - y_k| \quad (22)$$

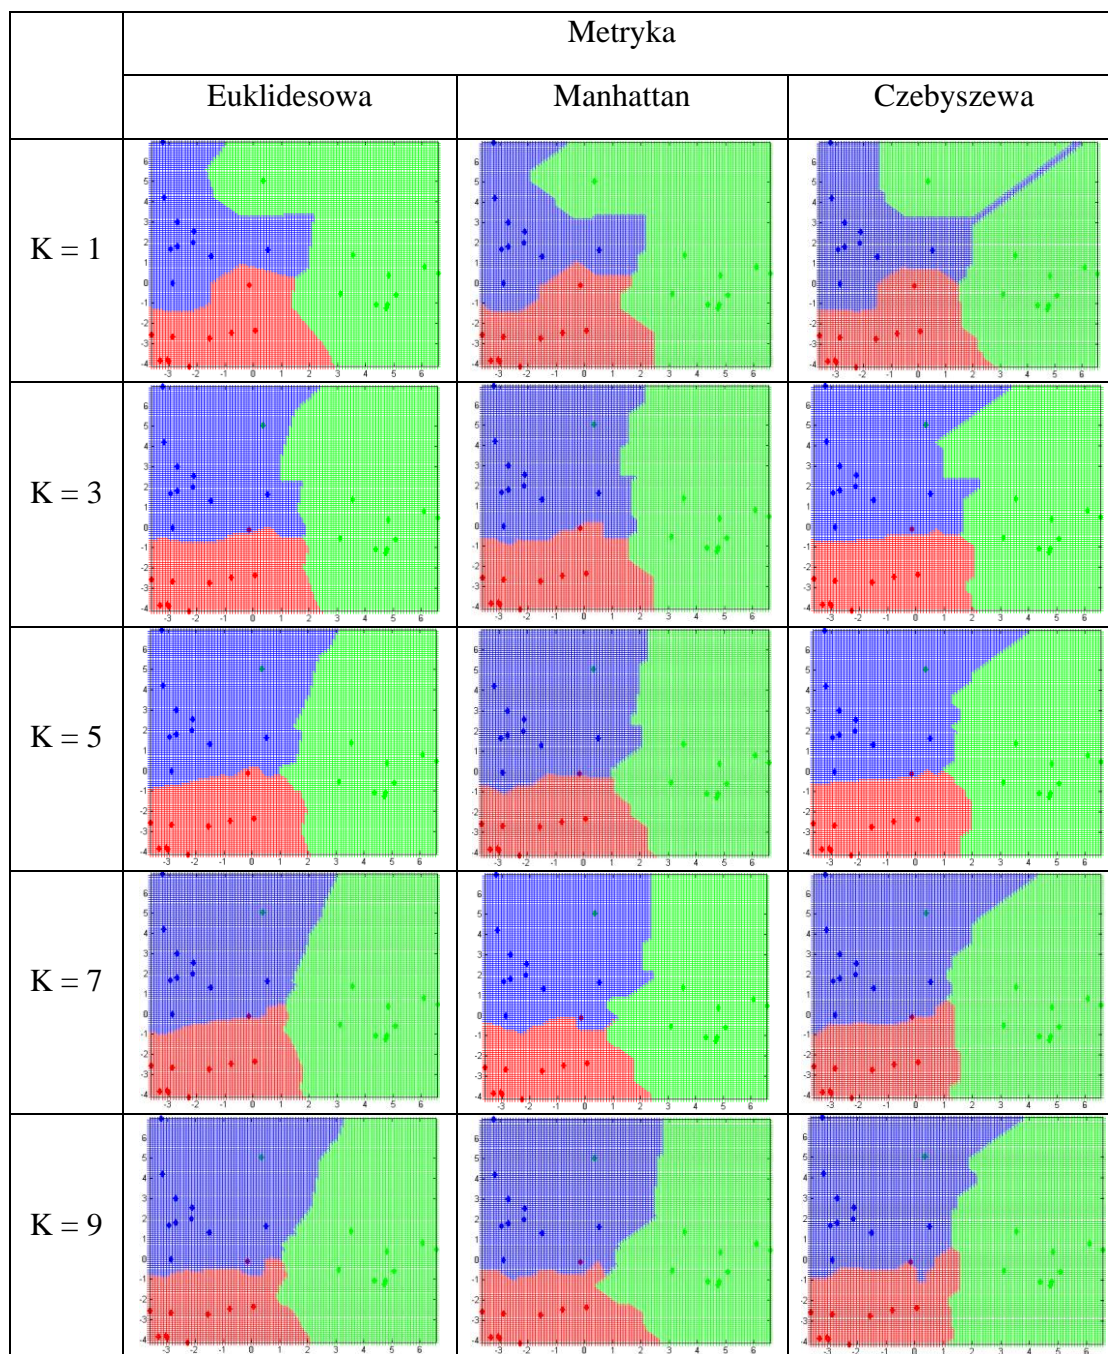
- Metryka Czebyszewa (maksimum)

$$d_{ch}(x, y) = \max_{k=1, \dots, n} |x_k - y_k| \quad (23)$$

Wpływ różnych metryk można przedstawić w intuicyjny sposób dla danych dwuwymiarowych. W ramach przeprowadzonych analiz metody K-NN nauczono klasyfikator K-NN za pomocą tych samych 30 próbek uczących, a następnie zbadano strefy przynależności do klas generowane przez te dane.

Wykresy przedstawione w Tab. 5 pokazują kształty stref przynależności w zależności od liczby najbliższych sąsiadów  $K \in [1, 3, 5, 7, 9]$  oraz trzech różnych metryk. Zawarte w tabeli ilustracje pokazują, że wzrost liczby K dla wszystkich metryk prowadzi do wygładzenia granic pomiędzy strefami i zmniejszenia ich wrażliwości na punkty uczące najbardziej wysunięte w stronę konkurencyjnych stref. Ze względu na niewielkie różnice pomiędzy wpływem rodzaju metryki na kształty stref przynależności dla liczby  $K > 1$ , zaproponowano metrykę Euklidesową jako domyślną dla wszystkich kolejnych etapów metody.

Tab. 5 Kształt stref przynależności klas w przestrzeni (F1,F2) dla klasyfikatora K-NN w zależności od metryki i liczby najbliższych sąsiadów K



### Badanie jakości klasyfikacji

Ze względu na ograniczony zestaw danych uczących, ograniczoną jakość posiadanych nagrań oraz niepewność co do skuteczności podjętych w poprzednich krokach decyzji (dobranie specyficznych współczynników opisujących próbkę, redukcja wymiarowości danych do odpowiednio niskiego wymiaru, ustalenie ilości sąsiadów w metodzie K-NN) może dojść do sytuacji, w której chmura punktów odpowiadających obserwacjom ze zbioru danych uczących nie będzie w wystarczający sposób odzwierciedlała faktycznego kształtu klas.

Istnieje więc potrzeba oceny jakości algorytmu klasyfikacji w taki sposób, aby można było określić, czy obserwacje uczące są rozłożone w przestrzeni w sposób rozróżniający klasy

przy zadanych parametrach metody, takich jak wymiar przestrzeni punktów  $M$  (do której redukujemy początkową 30-wymiarową przestrzeń), liczbę najbliższych sąsiadów  $K$  i rodzaj metryki użytej do obliczania odległości pomiędzy punktami w przestrzeni. Ze względu na kompleksowy charakter przeprowadzonych testów badających wyżej opisane właściwości zamieszczono je w oddzielnym rozdziale.

## 4.2 Podsumowanie

Głównymi parametrami proponowanej metody, które powinny zostać dobrane w trakcie testów są:

- wymiar wektorów, na podstawie których odbywać się będzie klasyfikacja (czyli liczba głównych składowych wyznaczonych metodą PCA)
- liczba najbliższych sąsiadów  $K$

Sposób obliczania odległości, a tym samym najbliższych sąsiadów, w metodzie K-NN bazuje na odpowiedniej metryce, w zależności od której różni się kształt stref przynależności do poszczególnych klas w przestrzeni wektorów opisujących.

Przetestowanie algorytmu K-NN pod kątem klasyfikacji próbek wymaga również zbadania wpływu parametrów opisu przebiegu wideo (np. liczba klatek, rozmiar filtru Savitzkiego-Golaya) na rezultaty i dlatego wszystkie testy są opisane w kolejnym rozdziale.

## 5 Testy i kalibracja parametrów metody

### 5.1 Wprowadzenie i cel

Ze względu na zależność skuteczności metody od dobrania współczynników używanych w różnych etapach konieczne jest przeprowadzenie testów pozwalających na ich kalibrację. Wynika to z faktu, że choć uproszczenia zastosowane przy projektowaniu metody opisywania nagrań pozwalają na wstępne oszacowanie zakresu podstawowych współczynników to wyznaczenie ich dokładnych wartości minimalizujących błąd klasyfikacji dla danych próbek uczących powinno być przeprowadzane indywidualnie dla nowego zbioru danych.

Pierwszym celem jest kalibracja podstawowych parametrów opisu nagrania pod kątem współczynnika odzwierciedlającego uproszczony poziom błędu klasyfikacji. Drugim celem testowania jest dobranie parametrów klasyfikatora K-NN oraz sposobu redukcji wymiarowości danych po uprzednim ustaleniu parametrów opisu obrazu. Otrzymane parametry pozwolą na ustalenie domyślnych parametrów metody.

W przypadku etapu pierwszego poszukiwane są wartości następujących parametrów opisu obrazu:

- ILOŚĆ\_KLATEK
- USUŃ\_KLATKI\_POCZĄTEK
- ZAKRES\_ŚREDNIA
- ROZMIAR\_FILTRU

W przypadku etapu drugiego, osiągniętego po uprzednim przetestowaniu i skalibrowaniu wartości parametrów opisu obrazu, konieczna jest analiza pojedynczej instancji metody (instancji o skalibrowanych parametrach obrazu) i dobranie parametrów klasyfikatora K oraz liczby zredukowanych wymiarów danych M. Wszystkie testy przeprowadzono dla metryki Euklidesowej.

### 5.2 Metodologia

#### 5.2.1 Metody testowania klasyfikatora

Istotne jest, aby testowanie metody odbywało się w warunkach umożliwiających zautomatyzowanie testów i przeprowadzenie ich na odpowiedniej liczbie próbek testujących. Poniższe metody opierają się na poddaniu danych uczących klasyfikacji przez nauczony klasyfikator i określeniu stopnia zgodności sklasyfikowanych próbek z prawdziwymi danymi.

- Metoda 1 – Walidacja krzyżowa (ang. Cross validation)

W metodzie zbiór danych dzielony jest losowo na  $Z$  równych podzbiorów. W  $Z$  krokach ustala się kolejne podzbiory jako zbiór testowy, a pozostałe  $Z - 1$  podzbiorów służy jako zbiór uczący. Zaletą tej metody  $Z$ -krotne powtarzanie fazy

treningu i testowania klasyfikatora. Zwiększa to wiarygodność i stabilność wyników testów klasyfikatora, ponieważ traktowanie na zmianę podzbiorów jako uczących i testujących redukuje ryzyko otrzymania przypadkowego wyniku (na przykład przez specyficzny losowy podział danych na podzbiory).

Ze względu na małą liczbę próbek dostępnych do testowania i uczenia klasyfikatora zbiór 30 obserwacji był dzielony na  $Z = 3$  podzbiory, co daje 3 iteracje, w których klasyfikator K-NN był uczony za pomocą 20 próbek a następnie testowany za pomocą pozostałych 10 próbek. Otrzymany w metodzie błąd jest uśredniany.

Do otrzymania modelu klasyfikatora dla walidacji krzyżowej użyto funkcji *crossval*. Do obliczenia procentu próbek błędnie zinterpretowanych w metodzie walidacji krzyżowej użyto funkcji *kfoldLoss* [22]. Nazwa współczynnika błędu klasyfikacji to *błądKroswalidacja*.

- Metoda 2 – Resubstytucja

Metoda polega na użyciu klasyfikatora K-NN nauczonego za pomocą wszystkich próbek uczących do sklasyfikowania każdej z próbek ze zbioru uczącego i porównaniu zgodności klas z rzeczywistymi.

Metoda obliczana jest za pomocą funkcji programu Matlab: *resubLoss* [22]. Nazwa współczynnika błędu klasyfikacji to *błądResubstytucja*.

Obie metody dają w wyniku wartość liczbową wyrażoną w procentach i informującą o ilości próbek błędnie sklasyfikowanych w toku testowania.

Testy parametrów metody K-NN pod kątem użycia w metodzie pokazały istnienie problemu związanego z zachowaniem metody resubstytucji dla liczby najbliższych sąsiadów  $K = 1$ . Mianowicie przy takiej wartości parametru K jedyną próbką decydującą o klasyfikacji próbki testowej jest ta sama próbka, co prowadzi do wykazania stuprocentowej skuteczności klasyfikacji niezależnie od danych i ustawień. Sytuacja taka jest możliwa jedynie przy testowaniu klasyfikatora zbiorem uczącym, więc uznano, że dopuszczenie takich rezultatów zafałszowałoby wyniki testów.

Zaproponowanym rozwiązaniem jest ocena skuteczności klasyfikacji dla danego ustawienia parametrów poprzez nowy współczynnik opisujący maksymalny z błędów klasyfikacji otrzymanych w obu metodach:

$$\text{błądKlasyfikacji} = \max(\text{błądKroswalidacja}, \text{błądResubstytucja}) \quad (23)$$

Rozwiązanie to uodparnia wyniki testów na „niepewne” wartości błędów klasyfikacji dla  $K = 1$ , ponieważ współczynnik ten odzwierciedla gorszy z wyników częściowych. Oznacza to, że niewielki błąd klasyfikacji w metodzie resubstytucji musi zostać potwierdzony przez metodę walidacji krzyżowej i vice versa.

## 5.2.2 Oszacowanie błędu dla zbioru parametrów klasyfikatora

W pierwszym etapie istotne jest określenie współczynników opisujących uogólniony błąd dla pewnego zbioru kombinacji parametrów  $K$  i  $M$  tak, aby odzwierciedlały błędy otrzymane dla poszczególnych kombinacji.

Zaproponowany został następujący sposób otrzymania współczynników:

1. Ustalenie zbioru kombinacji parametrów  $K$  i  $M$  uwzględnianych do obliczania uogólnionego błędu klasyfikacji.

Zaproponowano następujące wartości parametrów:

$$K \in [1,3,5,7,9] \quad (24)$$

$$M \in [2,3,4,5,6,7,10,15] \quad (25)$$

Im większa wartość  $K$ , tym większa jest odporność klasyfikatora na pojedyncze anomalie w danej klasie [20]. Proponowane wartości  $M$  zostały gęściej zgromadzone w zakresie małych wymiarów, ponieważ docelowo metoda ma polegać na znaczącej redukcji wymiarowości danych opisujących w celu późniejszej klasyfikacji. Wartości  $M = 10$  oraz  $M = 15$  zostały dodane w celu zbadania działania metody przy mniejszej redukcji wymiarów dla dywersyfikacji podejścia.

2. Dla każdego zestawu parametrów  $(K,M)$  nauczanie klasyfikatora  $K$ -NN tą samą grupą próbek uczących (odpowiednio zredukowanych z  $N$  do  $M$  wymiarów)
3. Przetestowanie metody dla każdego zestawu parametrów za pomocą metody resubstytucji i walidacji krzyżowej. Obliczenie na ich podstawie współczynnika *błądKlasyfikacji*.
4. Korzystając z obliczonych wartości błędów obliczenie następujących współczynników opisujących UBK:

a.  $UBK\_MIN = \min_{K,M} \text{błądKlasyfikacji}(K,M)$  - opisuje najmniejszy z obliczonych błędów klasyfikacji po parametrach. Reprezentuje najlepiej dopasowaną kombinację parametrów  $K$  i  $M$ .

b.  $UBK\_SREDNIA = \text{mean}_{K,M}(\text{błądKlasyfikacji}(K,M))$  - reprezentuje uśredniony błąd dla wszystkich kombinacji. Pokazuje trend wielkości błędów klasyfikacji dla całego zbioru instancji metody. Współczynnik zbliżony wartością do  $UBK\_MIN$  sugeruje, że dobrane parametry opisu nagrania dają podobnie dobre rezultaty dla dużej ilości kombinacji, podczas gdy współczynnik zbliżony do  $UBK\_MAX$  sugeruje, że większa ilość kombinacji dała słabe wyniki.

- c.  $UBK\_MAX = \max_{K,M} \text{błędKlasyfikacji}(K,M)$  - opisuje największy z obliczonych błędów klasyfikacji. Reprezentuje najgorzej dopasowaną kombinację parametrów K i M.

Obliczone w powyższy sposób współczynniki UBK opisujące pojedynczą instancję metody (pod kątem wartości parametrów opisu obrazu) pozwoliły następnie na analizę wykresów wartości UBK w funkcji kalibrowanych parametrów, co umożliwiło odpowiednie dobranie parametrów opisu obrazu.

## 5.3 Przeprowadzone testy

### 5.3.1 Etap I – testy i kalibracja parametrów opisu obrazu

#### Warunki początkowe

W trakcie początkowych testów pojedynczych konfiguracji, metodą prób i błędów dobrano następujące wartości parametrów opisu obrazu:

$$ILOŚĆ\_KLATEK = 200$$

$$USUŃ\_KLATKI\_POCZĄTEK = 25$$

$$ZAKRES\_ŚREDNIA = 40$$

$$ROZMIAR\_FILTRU = 29$$


Parametry te pozwalały na uzyskanie błędu klasyfikacji rzędu ok. 13.3% (obliczone za pomocą testów resubstytucji i walidacji krzyżowej). Oznacza to, że na 30 nagrań średnio 4 próbki były niewłaściwie sklasyfikowane. Uznano, że uzyskane w ten sposób parametry mogą służyć za warunki początkowe w fazie testów i kalibracji.

#### Parametr ILOŚĆ\_KLATEK

Test pokazujący wpływ ilości analizowanych klatek nagrania na skuteczność klasyfikacji jest konieczny, ponieważ decyzja, które z klatek i w jakiej ilości zostaną wybrane do analizy rzutuje na każdy kolejny etap metody. Nagranie złożone z pewnej ilości klatek zostaje odzwierciedlone przez metodę w formie przebiegów czasowych, których kształt i zachowanie jest zróżnicowane w zależności od etapu nagrania. Nieodpowiednia długość nagrania może spowodować utratę lub zniekształcenie informacji wyróżniającej przebiegi danej klasy od innych próbek.

Wpływ długości nagrania (wyrażonej w liczbie klatek) na otrzymany w wyniku testów UBK został przedstawiony na Rys. 21.





Rys. 21 Wykres wielkości uogólnionego błędu klasyfikacji w funkcji parametru ILOŚĆ\_KLATEK

Wartości współczynnika UBK\_ŚREDNIA pokazują, że klasyfikator o różnych kombinacjach parametrów K i M ma tendencję do znacznego pogarszania jakości klasyfikacji (błędy większe od 13.3%) poza zakresem [175,375]. Jednocześnie analiza współczynnika UBK\_MIN pokazującego optymistyczny przypadek pokazała, że w przedziale [275,375] błędy klasyfikacji są mniejsze bądź równe 3.3%. Oznacza to, że w przypadku 30 próbek uczących i testujących błędnej klasyfikacji dokonano na jednej bądź na żadnej z próbek. Warto zwrócić uwagę na fakt, że wielkość minimalnego błędu UBK\_MIN może osiągać 0% choć nie oznacza to, że przy tych samych warunkach początkowych funkcja testująca instancję metody otrzyma te same rezultaty. Wynika to z losowego charakteru funkcji walidacji krzyżowej, której jednym z etapów jest podzielenie grupy próbek w sposób losowy na grupę uczącą i testującą.


Ze względu na niepewność wartości minimalnej błędu uznano, że do dobrania parametru konieczne będzie również uwzględnienie tendencji średniego i maksymalnego błędu. W związku z tym, jako dobrany parametr ILOŚĆ\_KLATEK uznano liczbę 325 klatek.

### Parametr USUŃ\_KLATKI\_POCZĄTEK

Kolejnym przeprowadzonym testem była analiza wpływu parametru USUŃ\_KLATKI\_POCZĄTEK na skuteczność klasyfikacji. Kalibracja tego parametru jest wymagana ze względu na niesprecyzowane zachowanie detektora pierwszego planu MOG dla grupy pierwszych kilkunastu klatek. Wynika to z faktu, że po początkowym nauczaniu detektora za pomocą kilku pierwszych klatek model tła często zawiera błędne fragmenty (np. powolne cząstki uznane za tło). Zaproponowanym rozwiązaniem jest odrzucenie z analizy maski pierwszego planu dla pierwszych USUŃ\_KLATKI\_POCZĄTEK klatek.

Wartości pozostałych parametrów opisu obrazu w teście zgodne są z warunkami początkowymi zaktualizowanymi o wartość parametru ILOŚĆ\_KLATEK = 325.

Wpływ liczby początkowych odrzuconych klatek nagrania (wyrażonej w liczbie klatek) na otrzymany w wyniku testów UBK został przedstawiony na Rys. 22.



Rys. 22 Wykres wielkości uogólnionego błędu klasyfikacji w funkcji parametru USUŃ\_KLATKI\_POCZĄTEK


Analizując wykres analogicznie do poprzedniego testu można zauważyć, że wartości współczynnika UBK\_MIN odpowiadają błędnej klasyfikacji jednej lub dwóch próbek w całej testowanej przestrzeni parametru. Pod tym względem, najbardziej stabilne rezultaty otrzymywane są dla zmiany parametru od 4 do 31 klatek, jednak do rozstrzygnięcia, która wartość jest najbardziej odpowiednia uwzględniono również wpływ wartości UBK\_ŚREDNIA. Pozwoliło to na uwzględnienie wpływu innych niż najlepszej instancji metody. Skalibrowany parametr USUŃ\_KLATKI\_POCZĄTEK ustalono na wartość równą 25.

### Parametr ZAKRES\_ŚREDNIA

Parametr ZAKRES\_ŚREDNIA rzutuje na sposób uśredniania początkowych i końcowych fragmentów przebiegów czasowych o takiej długości. Uśrednione wartości przekładają się następnie na 6 współczynników opisujących daną próbkę.

Wartości pozostałych parametrów opisu obrazu w teście zgodne są z warunkami początkowymi zaktualizowanymi o wartości parametrów: ILOŚĆ\_KLATEK = 325 oraz USUŃ\_KLATKI\_POCZĄTEK = 25.

Wpływ liczby początkowych i końcowych klatek użytych do obliczania parametrów c8, c9, c18, c19, c28 i c29 na otrzymany w wyniku testów UBK został przedstawiony na Rys. 23.



Rys. 23 Wykres wielkości uogólnionego błędu klasyfikacji w funkcji parametru ZAKRES\_ŚREDNIA


Analiza parametru UBK\_MIN pokazuje, że nie ma istotnego wpływu parametru ZAKRES\_SREDNIA na najlepszą konfigurację klasyfikatora. Uznano, że wpływ na to ma odpowiednia kalibracja pozostałych parametrów metody, która daje dobre wyniki o minimalnych błędach rzędu 0-3.3%. Zauważono jednocześnie, że uśredniony współczynnik UBK\_ŚREDNIA rośnie wraz ze wzrostem parametru, co oznacza pogarszanie się wyników dla innych niż najlepszej konfiguracji K i M. Ze względu na otrzymanie najlepszej klasyfikacji w zakresie [46,58] ustalono skalibrowany parametr ZAKRES\_SREDNIA na 50.

### Parametr ROZMIAR\_FILTRU

Parametr ten wpływa na wszystkie parametry opisu obrazu, ponieważ początkowe zaszumione przebiegi głównych cech przechodzą przez filtr Savitzky-Golay'a o określonym przez niego rozmiarze okna. Każda grupa klatek o zadanym oknie jest aproksymowana wielomianem 3 stopnia, co oznacza, że im większe wartości rozmiaru filtru, tym bardziej widoczne wygładzenie przebiegu.

Wartości pozostałych parametrów metody ustalono zgodnie z poprzednimi kalibracjami.

Wpływ rozmiaru okna filtru na otrzymany w wyniku testów UBK został przedstawiony na Rys. 24.



Rys. 24 Wykres uogólnionego błędu klasyfikacji w funkcji parametru ROZMIAR\_FILTRU

Analiza wykresu pokazuje, że wyższe rozmiary filtra prowadzą do zmniejszania się średniego błędu UBK. Jednocześnie widać, że w zakresie [45,53] oraz [125,141] znaleziono kombinację parametrów K i M dającą stuprocentową skuteczność klasyfikacji dla 30 próbek. Skalibrowany parametr ROZMIAR\_FILTRU ustalono na 49.

### 5.3.2 Etap II – testy i kalibracja klasyfikatora

#### Wstęp

Po wstępnym ustaleniu parametrów opisu obrazu w poprzednim etapie konieczne jest skalibrowanie dwóch głównych parametrów K i M dla klasyfikatora. Sposób przeprowadzenia testu jest analogiczny do tego używanego w przypadku etapu II. Ocenę jakości klasyfikacji dla konkretnej kombinacji K i M odzwierciedlają następujące współczynniki:  $błądKroswalidacja$ ,  $błądResubstytucja$  oraz obliczony na ich podstawie  $błądKlasyfikacji = \max(błądKroswalidacja, błądResubstytucja)$ .

Etap II został przeprowadzony przy wartościach parametrów opisu obrazu ustalonych na wartości skalibrowane:

$$ILOŚĆ\_KLATEK = 325$$

$$USUŃ\_KLATKI\_POCZĄTEK = 25$$

$$ZAKRES\_ŚREDNIA = 50$$

$$ROZMIAR\_FILTRU = 49$$

#### Wyniki testów

Rezultaty testów resubstytucji zostały zamieszczone w Tab. 6. Zgodnie z przewidywaniami opisanymi w rozdziale o metodologii testów testy te wykazały stuprocentową skuteczność klasyfikacji dla liczby sąsiadów  $K = 1$ . Jest to wynik nieodzwierciedlający prawdziwej skuteczności i dlatego nie jest on miarodajny - konieczne jest porównanie wyników z rezultatami testu walidacji krzyżowej.

Tab. 6 Błędy klasyfikacji obliczone metodą resubstytucji dla poszczególnych instancji metody. Komórka o współrzędnych (K,M) oznacza wartość współczynnika  $\text{bładResubstytucja}$  dla instancji metody opartej na redukcji danych opisujących do M wymiarów oraz liczbie sąsiadów w K-NN równej K. Wartość współczynnika jest wyrażona w procentach. Użyto metryki euklidesowej.

K \ M	2	3	4	5	6	7	10	15
1	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%
3	6.7%	3.3%	3.3%	3.3%	0.0%	0.0%	0.0%	0.0%
5	3.3%	3.3%	3.3%	3.3%	3.3%	3.3%	3.3%	3.3%
7	6.7%	3.3%	3.3%	3.3%	3.3%	6.7%	6.7%	6.7%
9	6.7%	3.3%	3.3%	3.3%	3.3%	3.3%	3.3%	3.3%

Wyniki testów metodą krosvalidacji zostały umieszczone w Tab. 7. Ze względu na losowy charakter podziału na próbki uczące i testujące, wyniki otrzymane za pomocą tej metody można traktować jako dowody lepszego dopasowania niektórych z kombinacji parametrów K i M. Jest to widoczne zwłaszcza dla redukcji wymiarów do  $M = 4$  lub  $M = 5$  oraz liczbie najbliższych sąsiadów K równej 3, 5 lub 7. W przypadku takiej konfiguracji metoda krosvalidacji wykazuje błędy klasyfikacji rzędu 3.3%, co w przypadku 30 próbek uczących można zinterpretować jako jedną próbkę błędnie sklasyfikowaną.

Tab. 7 Błędy klasyfikacji obliczone metodą walidacji krzyżowej dla poszczególnych instancji metody. Komórka o współrzędnych (K,M) oznacza wartość współczynnika  $\text{bładKrosvalidacja}$  dla instancji metody opartej na redukcji danych opisujących do M wymiarów oraz liczbie sąsiadów w K-NN równej K. Wartość współczynnika jest wyrażona w procentach. Użyto metryki euklidesowej.

K \ M	2	3	4	5	6	7	10	15
1	13.3%	6.7%	10.0%	3.3%	10.0%	3.3%	6.7%	6.7%
3	3.3%	3.3%	3.3%	3.3%	6.7%	6.7%	6.7%	3.3%
5	6.7%	10.0%	3.3%	3.3%	10.0%	6.7%	13.3%	3.3%
7	6.7%	6.7%	3.3%	3.3%	3.3%	6.7%	6.7%	3.3%
9	10.0%	6.7%	6.7%	13.3%	6.7%	3.3%	6.7%	3.3%

W celu połączenia wyników obu metod zastosowano obliczenie współczynnika  $\text{bładKlasyfikacji}$  (Tab. 8), którego wartości posłużą do właściwego dopasowania obu parametrów K-NN.

Tab. 8 Błędy klasyfikacji dla poszczególnych instancji metody. Komórka o współrzędnych (K,M) oznacza wartość współczynnika  $\text{bładKlasyfikacji}$  dla instancji metody opartej na redukcji danych opisujących do M wymiarów oraz liczbie sąsiadów w K-NN równej K. Wartość współczynnika jest wyrażona w procentach. Użyto metryki euklidesowej.

K \ M	2	3	4	5	6	7	10	15
1	13.3%	6.7%	10.0%	3.3%	10.0%	3.3%	6.7%	6.7%
3	6.7%	3.3%	3.3%	3.3%	6.7%	6.7%	6.7%	3.3%
5	6.7%	10.0%	3.3%	3.3%	10.0%	6.7%	13.3%	3.3%
7	6.7%	6.7%	3.3%	3.3%	3.3%	6.7%	6.7%	6.7%
9	10.0%	6.7%	6.7%	13.3%	6.7%	3.3%	6.7%	3.3%

Można zauważyć, że w przypadku danych opisujących przebiegi czasowe ustalenie poziomu redukcji wymiarów do wartości  $M = 4$  lub  $M = 5$  oraz liczby najbliższych sąsiadów  $K = 3, 5$

lub 7 prowadzi do zadowalającej poprawności klasyfikacji i błędnego sklasyfikowania tylko jednej próbki na 30. Należy mieć na uwadze, że wyniki te mogą być specyficzne jedynie dla danej grupy uczącej i w przypadku zwiększenia liczby próbek w grupie uczącej do kilkuset, nagranych w bardziej zróżnicowanych warunkach oświetleniowych, konieczne będzie przeprowadzenie analogicznych obliczeń przy doborze parametrów  $K$  i  $M$ . Warto zauważyć, że wartości błędów dla wszystkich kombinacji zawierają się w zakresie od jednej do maksymalnie 4 błędnie sklasyfikowanych próbek.

## 5.4 Podsumowanie

Etap I testów pozwolił na kalibrację parametrów opisu obrazu. Ich skalibrowane wartości są następujące:

$$ILOŚĆ\_KLATEK = 325$$

$$USUŃ\_KLATKI\_POCZĄTEK = 25$$

$$ZAKRES\_ŚREDNIA = 50$$

$$ROZMIAR\_FILTRU = 49$$

Etap II testów został przeprowadzony w celu dobrania parametrów redukcji danych za pomocą metody PCA (parametr  $M$ ) oraz klasyfikatora K-NN (parametr  $K$ ). Ostatecznie, w celu ustalenia uwagi zastosowano następujące parametry domyślne:

$$K = 5$$

$$M = 5$$

Testy metody dla podanych parametrów wykazały skuteczność klasyfikacji na poziomie 96.7% dla 30-próbkowej grupy nagrań. Warto zauważyć, że oznacza to jedną błędnie sklasyfikowaną próbkę.

## 6 Klasyfikacja nowych próbek

### Wstęp

Wszystkie poprzednie etapy zostały przeprowadzone w celu otrzymania dwóch złożonych informacji:

- Sposobu redukcji materiału video do M-wymiarowego wektora opisującego próbkę
- Klasyfikatora nauczonego M-wymiarowymi próbkami ze zbioru uczącego

Ostatnim etapem było wykorzystanie rezultatów tych badań i utworzenie narzędzia w postaci Graficznego Interfejsu Użytkownika (ang. GUI), które pozwalałoby na wczytanie pliku video i odpowiednie jej sklasyfikowanie. Ze względów opisanych w rozdziale 2 zdecydowano się na użycie metody z klasyfikatorem K-NN do rozróżniania od siebie tylko 3 klas (LEK, ZANIECZYSZCZENIA i BĄBLE). Klasa CZYSTA może być wykrywana testem na ilość pikseli pierwszego planu wykrytego przez Ekstraktor Pierwszego Planu MOG.

Całość procesu otrzymania współczynników opisujących nagranie jest analogiczna do tego przeprowadzanego w przypadku 30 próbek uczących. Różnicą jest powtórzenie sekwencji tylko dla jednej testowanej próbki video (zgodnie ze schematem 3 z rozdziału 2).

### Kalkulacja głównych składowych dla nowej próbki

Pierwszym etapem jest przeprowadzanie próbki video dla nowej próbki przez ten sam proces obróbki i opisu, który przechodziły wszystkie próbki uczące. Otrzymany wynik to 30-wymiarowy wektor opisujący próbkę, na podstawie którego należy wyliczyć M (domyślnie 5) głównych składowych, które są współrzędnymi w nowej, zredukowanej przestrzeni. Proces otrzymania nowych współrzędnych jest opisany w rozdziale dotyczącym metody PCA.

### Zastosowanie nauczonego klasyfikatora do klasyfikacji nowej próbki

Kolejnym krokiem po otrzymaniu wektora n-wymiarowego opisującego nową próbkę jest użycie nauczonego klasyfikatora do jej sklasyfikowania. Funkcją użytą do obliczeń jest metoda programu Matlab *predict* użyta na modelu klasyfikatora klasy ClassificationKNN i zredukowanym wektorze opisującym nowe nagranie (uprzednio ustandaryzowanym w opisany w poprzednim rozdziale sposób).


### Narzędzie do klasyfikacji (GUI)

W celu prezentacji efektów działania metody napisano w programie Matlab nakładkę graficzną, która implementowała narzędzie, za pomocą którego można przeprowadzić klasyfikację nowych próbek. Program pozwala na następujące działania:

- Wybranie pliku nagrania z próbką do klasyfikacji poprzez wpisanie nazwy i rozszerzenia ( np. nagranie\_1.mov)
- Sprecyzowanie ROI (ang. Region of Interest), w zakresie którego analizowany jest obraz z nagrania:

- Początkowa współrzędna X
- Początkowa współrzędna Y
- Szerokość ROI
- Wysokość ROI
- Dostosowanie parametrów metody PCA poprzez wybranie stopnia redukcji wymiaru wektorów opisujących. Po ustaleniu wymiaru  $M$  zarówno uczenie klasyfikatora K-NN jak i redukcja wektora opisującego nowe nagranie będzie przeprowadzone w przestrzeni  $M$ -wymiarowej. Możliwy jest dobór  $M$  w zakresie [2,3,4,5,6,7,10,15]
- Dostosowanie parametrów klasyfikatora K-NN:
  - Ustalenie liczby  $K$ - najbliższych sąsiadów. Możliwy jest dobór  $K$  w zakresie [1,3,5,7,9]
  - Ustalenie metryki, za pomocą której będzie liczona odległość pomiędzy poszczególnymi punktami w przestrzeni  $M$ -wymiarowej. Możliwe do wybrania są następujące metryki:
    - Euklidesowa
    - Manhattan
    - Czebyszewa
- Przeprowadzenie klasyfikacji nowej próbki z ustalonymi parametrami poprzez naciśnięcie przycisku Sklasyfikuj oraz przekazanie rezultatu użytkownikowi za pomocą pola tekstowego „Sklasyfikowano jako: *KLASA*”
- Wizualizację zbioru uczącego oraz położenia nowej próbki w zredukowanej przestrzeni 3-wymiarowej, jeżeli ustalono redukcję wymiaru problemu do  $M \geq 3$ . Jeżeli klasyfikacja przebiega w przestrzeni większej niż trójwymiarowej to do wizualizacji brane są jedynie pierwsze 3 główne składowe (wymiarzy nowej przestrzeni). Położenie nowej próbki w przestrzeni jest oznaczone okręgiem natomiast dla próbek uczących zastosowano kolorowanie w postaci markera typu diament o następujących kolorach:
  - Czerwony – klasa ZANIECZYSZCZENIA
  - Niebieski – klasa LEK
  - Zielony – klasa BAŁBLE





Rys. 25 Graficzny Interfejs Użytkownika pozwalający na sklasyfikowanie nowej próbki za pomocą nagrania.

## Podsumowanie

Graficzny Interfejs Użytkownika pozwolił na pojedyncze testy metody dla nowych próbek w różnych konfiguracjach parametrów zarówno metody PCA jak i klasyfikacji metodą K-NN. Ze względu na dość złożony sposób przygotowywania nowych próbek zrezygnowano z przeprowadzania oddzielnych testów poprzez GUI. Oznacza to, że sposobem oceny działania metody są funkcje testujące klasyfikator opisane w rozdziale 6.

## 7 Wnioski

### Działanie metody

Podjęcie polegające na klasyfikacji próbek roztworów leków cytostatycznych poprzez wprowadzenie w ruch zawartości naczynia i analizę stałej ilości klatek nagrania tego ruchu pozwoliło na zadowalającą jakość klasyfikacji przy danych próbkach uczących. Testy klasyfikacji przeprowadzone przy skalibrowanych parametrach opisu obrazu, metody PCA i klasyfikatora K-NN pozwoliły na wykazanie skuteczności klasyfikacji rzędu 96.7%, co odpowiada jednej błędnie sklasyfikowanej próbce na 30 testujących. Otwartą kwestią pozostaje dobór etapów i metod tworzących algorytm opisu nagranych próbek, który mógł być zaprojektowany na wiele innych sposobów i niemożliwe jest wykazanie optymalności użytej w opracowaniu sekwencji kroków.

Charakterystyczną cechą proponowanej metody jest użycie dużej liczby prostych współczynników opisujących próbki (z których duża część pozornie nie jest w żaden sposób skorelowana i może nawet nie wnosić znaczącej informacji do procesu klasyfikacji) i użycie metod statystycznych - w tym przypadku metody PCA - do redukcji wymiaru wektorów opisujących próbki w taki sposób, aby wyłuskać informacje rozróżniające klasy pod kątem późniejszej klasyfikacji. Pozwoliło to na ograniczenie wpływu danych o dublującym się charakterze i nadanie większego znaczenia współczynnikom, które najlepiej odzwierciedlały wariancję współrzędnych opisujących położenie grupy uczącej. Takie podejście niewątpliwie ułatwiło pracę przy projektowaniu metody i umożliwiło nadanie jej pewnego stopnia automatyczności, gdyż autonomiczne decydowanie metody o preferencji pewnych zmiennych opisujących w stosunku do innych ogranicza konieczność samodzielnej analizy współczynników i ich korelacji pod kątem przynależności do klas próbek z nowego zbioru uczącego. Niestety zmniejsza to możliwości ingerencji w wyniki metody i praktycznie pozostawia decyzję algorytmowi bazującemu na zachowaniu jak największej zmienności współczynników.

Zależność od danych uczących pozostaje dużym problemem metody i konieczne jest przeprowadzenie testów na bardzo dużej liczbie próbek nagranych w jednolitych warunkach przy pomocy wysokiej jakości kamery. Dopiero zwiększenie ilości próbek uczących do co najmniej kilkudziesięciu nagrań przypadających na klasę pozwoli na zbudowanie odpowiednio złożonego modelu klasyfikatora, który uwzględni różnorodne możliwości położenia przedstawicieli klas w przestrzeni głównych składowych.

Przeprowadzanie takich testów będzie możliwe dopiero na docelowym stanowisku, wyposażonym w odpowiednie ramię robota zdolne do manipulacji naczyniem. W ograniczonych warunkach nie jest możliwe przeprowadzenie w sposób powtarzalny tego samego wprowadzenia w ruch naczynia, co prowadzi do dużej zmienności w zachowaniu cząstek w zakresie jednej klasy. Utrudnione było również uchwycenie nagrania próbki w chwilę po wprowadzeniu w ruch, gdyż z reguły naczynie ze względu na swoją bezwładność i sprężystość nadal wykazuje drobne drgania. W związku z powyższymi ograniczeniami

nagrywanie dużej ilości słabo wykonanych nagrań nie doprowadzi do znaczącej poprawy rezultatów metody i konieczne będzie przeprowadzenie nagrań już w docelowych warunkach.

Równie ważne jest podjęcie decyzji o wykluczeniu klasyfikacji próbki czystej (klasa CZYSTA) z głównego algorytmu metody. Po wstępnym przeprowadzeniu testów dla wszystkich klas zauważono, że czysta próbka odznacza się najbardziej odbiegającymi od innych przebiegami wszystkich trzech cech, które znajdują się na stałym poziomie przez cały czas trwania nagrania. Oznacza to, że do wykrywania jej wystarczył test badający czy maksymalna liczba wykrytych pikseli pierwszego planu nie przekracza ustalonego a priori niskiego progu, który odzwierciedla maksymalną liczbę pikseli powstałych w wyniku zaszumienia obrazu otrzymanego z kamery.

### **Możliwe poprawki w docelowej aplikacji metody**

Ze względu na dużą złożoność metody konieczna będzie weryfikacja jej skuteczności w docelowym stanowisku robota. Dzięki segmentowej budowie algorytmu możliwe będzie dostosowanie nie tylko współczynników (ich całkowite usunięcie lub zamianę na inne, lepiej opisujące przebiegi czasowe w nowych warunkach), ale także algorytmów używanych do przeprowadzania trzech złożonych operacji – subtrakcji tła (aktualnie algorytmem Mixture of Gaussian), analizy statystycznej danych (aktualnie metodą PCA) i klasyfikacji próbek na podstawie zredukowanych wektorów opisujących (aktualnie klasyfikatora K-NN).

Ze względu na zależność metody od zbioru uczącego wymagane będą testy dla dużej ilości próbek uwzględniające zmienne proporcje przedstawicieli jednej klasy o różnych postaciach i charakterze zachowania obiektów po wprowadzeniu w ruch. Problem ten może zostać w dużym stopniu uproszczony poprzez zastosowanie do wprowadzenia w ruch ramienia robota, które ze względu na swoją powtarzalność pozwoliłoby na zdecydowane ujednolicenie przebiegów opisujących próbki.

## 8 Bibliografia

- [1] Gać P., Pawlas K., *Ryzyko związane z zawodową ekspozycją na preparaty cytostatyczne*, <http://archiwum.ciop.pl/41990>
- [2] Rotter P., Muroń W., *Wykrywanie obecności proszku w cieczach poprzez analizę zmienności szumu na obrazie*, 2014
- [3] Rotter P., Muroń W., Lizończyk P., *Wykrywanie zanieczyszczeń w roztworach leków cytostatycznych na podstawie obrazu. Projektowanie mechatroniczne. Zagadnienia wybrane. Praca zbiorowa pod red. T. Uhla. (s. 47-54)*, Wydawnictwo Naukowe Instytutu Technologii Eksploatacji, Państwowy Instytut Badawczy, Radom, 2014
- [4] Rotter P., & Muroń W., *Algorytmy optycznego wykrywania zanieczyszczeń w roztworach: metody analizy przebiegów szumów na obrazach różnicowych*, AGH University of Science and Technology, Kraków, 2014
- [5] Rotter P., Muroń W., Lizończyk P., *Identyfikacja zanieczyszczeń w roztworach leków cytostatycznych na podstawie obrazu*, Warsztaty projektowania mechatronicznego, Kraków, 10-11.06.2013
- [6] Rotter P., Byrski W., Muroń W., *Analiza możliwości optycznej identyfikacji zanieczyszczeń w roztworach leków cytostatycznych pod kątem określenia wymagań dla stanowiska zrobotyzowanego*, Raport techniczny, AGH, 2013
- [7] Rotter P., Nowak M., Byrski W., Lizończyk P., *Opracowanie wymagań sprzętowych dla systemu inspekcji optycznej leków cytostatycznych i analiza rozwiązań aktualnie dostępnych na rynku*. Raport techniczny, AGH, Kraków, 2013.
- [8] Cyganek B., *Object Detection and Recognition in Digital Images. Theory and practice*, John Wiley & Sons, Ltd, Chichester, UK, 2013
- [9] P. Kaewtrakulpong., R. Bowden, *An Improved Adaptive Background Mixture Model for Realtime Tracking with Shadow Detection*, In Proc. 2nd European Workshop on Advanced Video Based Surveillance Systems, 2001
- [10] Zivkovic Z., & Heijden F., *Efficient Adaptive Density Estimation per Image Pixel for the Task of Background Subtraction*. Pattern Recognition Letters, 27(7), 773-780, 2006
- [11] Stauffer C., Grimson W.E.L., *Adaptive Background Mixture Models for Real-Time Tracking*, Computer Vision and Pattern Recognition, IEEE Computer Society Conference, Vol. 2 (06 August 1999), pp. 2246-252 Vol. 2.
- [12] Matlab documentation, *Foreground detection using Gaussian mixture models*, <http://www.mathworks.com/help/vision/ref/vision.foregrounddetector-class.html>
- [13] Strach M., *Wyszukiwanie obrazów na podstawie zawartości*. Praca magisterska, AGH, Kraków, 2010, <http://www.focus.agh.edu.pl/theses/MGR03.pdf>
- [14] Savitzky A., Golay M.J.E., *Smoothing and Differentiation of Data by Simplified Least Squares Procedures*. Analytical Chemistry 36 (8): 1627–39, 1964
- [15] Cohen J., Cohen P., West S.G., Aiken L.S., *Applied multiple regression/correlation analysis for the behavioral sciences*. (2nd ed.) Hillsdale, NJ: Lawrence Erlbaum Associates, 2003

- [16] Matlab documentation, *Polynomial curve fitting*,  
<http://www.mathworks.com/help/matlab/ref/polyfit.html>
- [17] Jolliffe I. T., *Principal Component Analysis*, Springer, 2002
- [18] Smith. I.L., *A tutorial on Principal Components Analysis*,  
[http://www.cs.otago.ac.nz/cosc453/student\\_tutorials/principal\\_components.pdf](http://www.cs.otago.ac.nz/cosc453/student_tutorials/principal_components.pdf), 2002
- [19] Matlab documentation, *Function pca()*, <http://www.mathworks.com/help/stats/pca.html>
- [20] Everitt B. S., Landau S., Leese M., Stahl D., *Miscellaneous Clustering Methods in Cluster Analysis*, 5th Edition, John Wiley & Sons, Ltd, Chichester, UK, 2011
- [21] *K- najbliższych sąsiadów*, StatSoft, <http://www.statsoft.com/Textbook/k-Nearest-Neighbors>
- [22] Matlab Documentation, *Classification Using Nearest Neighbors*,  
<http://www.mathworks.com/help/stats/classification-using-nearest-neighbors.html>,  
<http://www.mathworks.com/help/stats/regressionpartitionedmodel.kfoldloss.html>,  
<http://www.mathworks.com/help/stats/classificationensemble.resubloss.html>
- [23] Casio Digital Camera EX-F1 User's Guide,  
[http://support.casio.com/storage/en/manual/pdf/EN/001/EXF1\\_M29\\_FD\\_eu\\_EN.pdf](http://support.casio.com/storage/en/manual/pdf/EN/001/EXF1_M29_FD_eu_EN.pdf)