

ZBIGNIEW RUDNICKI

**Metody  
komputerowej analizy obrazów  
w badaniach tribologicznych**

 WYDAWNICTWA AGH

KRAKÓW 2010

KU 0370 pozycja wydawnictw naukowych  
Akademii Górniczo-Hutniczej im. Stanisława Staszica w Krakowie

© Wydawnictwa AGH, Kraków 2010  
ISBN 978-83-7464-311-5

Redaktor Naczelny Wydawnictw AGH: *Jan Sas*

Komitety Naukowe Wydawnictw AGH:

*Tomasz Szumc* (przewodniczący),

*Marek Capiński,*

*Jerzy Klich,*

*Witold K. Krajewski,*

*Tadeusz Sawik,*

*Mariusz Ziółko*

Recenzenci: *prof. dr hab. inż. Stanisław Pytko,*  
*prof. UŚ dr hab. inż. Zygmunt Wróbel*

**Druk publikacji wykonano z materiałów  
i składu dostarczonych przez Autora**

PROJEKT OKŁADKI I STRONY TYTUŁOWEJ: AUTOR

WYDANIE PIERWSZE

---

Redakcja Wydawnictw AGH  
al. Mickiewicza 30, 30-059 Kraków  
tel. 12 617 32 28, tel./faks 12 638 40 38  
<http://www.wydawnictwa.agh.edu.pl>  
e-mail: [redakcja@wydawnictwoagh.pl](mailto:redakcja@wydawnictwoagh.pl)

---

# Spis treści

<b>STRESZCZENIE</b> .....	<b>7</b>
<b>SUMMARY</b> .....	<b>8</b>
<b>SPIS OZNACZEŃ W KOLEJNOŚCI WYSTĘPOWANIA</b> .....	<b>9</b>
<b>1. WPROWADZENIE</b> .....	<b>13</b>
1.1 WSTĘP .....	13
1.2 PODSTAWOWE POJĘCIA .....	15
1.2.1 <i>Obrazy obiektów oraz tekstur</i> .....	18
1.2.2 <i>Cyfrowy zapis obrazów rastrowych szarych</i> .....	18
1.2.3 <i>Cyfrowy zapis sekwencji obrazów</i> .....	19
1.2.4 <i>Akwizycja obrazów i sekwencji obrazów</i> .....	19
1.2.5 <i>Przetwarzanie obrazów</i> .....	20
1.2.6 <i>Binaryzacja i segmentacja</i> .....	21
1.2.7 <i>Rozpoznawanie i klasyfikacja. Cechy dyskryminacyjne</i> .....	22
1.2.8 <i>Ocena zdolności dyskryminacyjnej cech obrazów</i> .....	23
1.3 ANALIZA OBRAZÓW W TRIBOLOGII – STAN OBECNY .....	24
<b>2. GENEZA I CEL PRACY</b> .....	<b>26</b>
<b>3. OBSZAR I ORGANIZACJA BADAŃ</b> .....	<b>28</b>
3.1 MATERIAŁ BADAWCZY .....	28
3.2 APRIORYCZNA SELEKCJA REPREZENTANTÓW KLAS OBRAZÓW TRIBOLOGICZNYCH ..	29
3.3 CHARAKTERYSTYKI, CECHY I META-CECHY OBRAZÓW.....	30
3.4 TESTOWANE METODY SELEKCJI CECH DISKRYMINACYJNYCH.....	31
3.5 STATYCZNA I DYNAMICZNA ANALIZA OBRAZÓW .....	32
3.6 ZASTOSOWANE NARZĘDZIA .....	33
3.6.1 <i>Narzędzia do akwizycji obrazów</i> .....	33
3.6.2 <i>Zastosowane programy komputerowe</i> .....	33
<b>4. WYBRANE ZAGADNIENIA AKWIZYCJI I KOREKTY OBRAZÓW</b> .....	<b>35</b>
4.1 ZAGADNIENIA AKWIZYCJI.....	35
4.1.1 <i>Zalecenia odnośnie oświetlenia i kąta obserwacji</i> .....	36
4.1.2 <i>Dobór powiększenia i kadru obrazu</i> .....	36
4.1.3 <i>Podział obrazu na podobrazy</i> .....	37
4.2 RODZAJE BŁĘDÓW .....	37
4.3 OCENA I FILTRACJA SZUMU.....	38
4.3.1 <i>Badanie poziomu szumu</i> .....	38
4.3.2 <i>Poziom szumu a jasność obrazu. Filtracja szumu</i> .....	39
4.4 PRZESTRZENNA NIERÓWNOMIERNOŚĆ JASNOŚCI OBRAZU I JEJ KOREKTA.....	41

4.5	KOREKTA UKIERUNKOWANIA OBRAZÓW.....	45
<b>5.</b>	<b>CHARAKTERYSTYKI TEKSTUR SZARYCH ORAZ ICH ROLA W ANALIZIE OBRAZÓW TRIBOLOGICZNYCH.....</b>	<b>47</b>
5.1	CHARAKTERYSTYKI JASNOŚCI PIKSELI OBRAZU .....	47
5.1.1	<i>Histogramy</i> .....	47
5.1.2	<i>Krzywe percentylowe</i> .....	50
5.2	CHARAKTERYSTYKI WYZNACZANE Z OTOCZEŃ PIKSELI .....	51
5.2.1	<i>Macierz gradientu</i> .....	51
5.2.2	<i>Cechy wyznaczone z modelu autoregresji</i> .....	52
5.3	CHARAKTERYSTYKI KOLUMN I WIERSZY MACIERZY OBRAZU.....	53
5.3.1	<i>Średnie jasności kolumn i wierszy obrazu</i> .....	53
5.3.2	<i>Udział czerni w kolumnach i wierszach</i> .....	54
5.4	CHARAKTERYSTYKI ZBIORÓW PAR PIKSELI .....	54
5.4.1	<i>Macierz przejść tonalnych C</i> .....	54
5.4.2	<i>Deskrytory zmienności wierszy i kolumn</i> .....	58
5.5	CHARAKTERYSTYKI PASM - MACIERZ R I JEJ CECHY .....	58
<b>6.</b>	<b>BINARYZACJA ORAZ ANALIZA OBRAZÓW BINARNYCH.....</b>	<b>60</b>
6.1	WYZNACZANIE PROGU BINARYZACJI.....	60
6.2	PROPONOWANE DESKRYTORY CECH TEKSTURY BINARNEJ .....	63
6.2.1	<i>Względne pokrycie powierzchni obrazu</i> .....	63
6.2.2	<i>Ziarnistość i średnia długość pasm białych</i> .....	63
6.2.3	<i>Rozkłady i udziały pasm o różnych długościach</i> .....	64
6.3	SEGMENTACJA I INDEKSACJA .....	65
6.4	WYZNACZANIE CECH WYODRĘBNIONYCH OBIEKTÓW .....	66
6.4.1	<i>Dominująca orientacja obiektów binarnych</i> .....	67
6.4.2	<i>Rozkłady pól obiektów binarnych</i> .....	68
<b>7.</b>	<b>EKSTENSYWNA, AUTOMATYCZNA SELEKCJA CECH DYSKRYMINACYJNYCH.....</b>	<b>70</b>
7.1	TESTOWANIE WSTĘPNE METOD SELEKCJI EKSTENSYWNEJ.....	70
7.1.1	<i>Porównanie selekcji ekstensywnej z ukierunkowaną</i> .....	74
7.1.2	<i>Wnioski z testowania wstępnego metod selekcji ekstensywnej</i> .....	75
7.2	SELEKCJA EKSTENSYWNA W STATYCZNEJ ANALIZIE TRANSFERU MATERIAŁU.....	75
7.3	PRÓBA OCENY ZUŻYCIA MATERIAŁU OCZEK CIĄGADEŁ DRUTU.....	78
7.4	OGÓLNA OCENA SELEKCJI EKSTENSYWNEJ.....	80
<b>8.</b>	<b>LICZBOWA EKSPRESJA WYBRANYCH CECH JAKOŚCIOWYCH OBRAZÓW TRIBOLOGICZNYCH .....</b>	<b>81</b>
8.1	WRAŻLIWOŚĆ CECH NA ZMIANY JASNOŚCI, KONTRASTU, OSTROŚCI ORAZ UPORZĄDKOWANIA MORFOLOGII OBRAZU.....	81
8.1.1	<i>Wrażliwość cech na zmiany jasności, kontrastu i ostrości</i> .....	81
8.1.2	<i>Wrażliwość cech na zmianę uporządkowania struktury obrazu</i> .....	84
8.1.3	<i>Detektory zmian jasności, kontrastu, ostrości i uporządkowania</i> .....	85
8.2	NIJEDNORODNOŚĆ PRZESTRZENNA.....	86
8.2.1	<i>Aspekty niejednorodności przestrzennej obrazu</i> .....	86
8.2.2	<i>Niejednorodność przestrzenna a transformata Fouriera</i> .....	86

8.2.3	Liczbowe miary niejednorodności .....	88
8.2.4	Jednorodność obrazów a filtracja medianowa .....	90
8.3	ANIZOTROPIA I UKIERUNKOWANIE ELEMENTÓW OBRAZÓW .....	91
8.3.1	Wprowadzenie podstawowych pojęć .....	91
8.3.2	Proponowane miary anizotropii i ortotropii .....	92
8.3.3	Generowanie zbioru obrazów obróconych .....	93
8.3.4	Ocena anizotropii na podstawie zmienności wierszy i kolumn .....	94
8.3.4.1	Anizotropia unormowanej różnicy zmienności kolumn i wierszy .....	94
8.3.4.2	Ortotropia względna zmienności wierszy i kolumn .....	96
8.3.4.3	Ilorazowa ortotropia względna tekstury binarnej .....	98
8.3.5	Zastosowanie cech wyznaczanych z macierzy R .....	98
8.3.5.1	Badania w oparciu o obrazy sztuczne .....	99
8.3.5.2	Pomiar anizotropii rzeczywistych obrazów powierzchni trących .....	102
8.3.6	Cechy wierszy obrazu - UDSW, UDMedW, UMxDW .....	104
8.3.7	Porównanie czasów wyznaczania anizotropii cech .....	107
8.4	ANALIZA PÓL WYODRĘBNIONYCH OBIEKTÓW .....	108
8.4.1	Rozkłady pól obiektów .....	108
8.4.2	Metoda MRHS analizy różnic histogramów skumulowanych .....	109
8.5	PRZYKŁAD KLASYFIKACJI OBRAZÓW TESTOWYCH .....	110
<b>9.</b>	<b>PRZETWARZANIE I ANALIZA SEKWENCJI OBRAZÓW</b>	
	<b>TRIBOLOGICZNYCH .....</b>	<b>112</b>
9.1	CEL I PRZEDMIOT BADAŃ .....	113
9.2	STANOWISKO BADAWCZE .....	113
9.3	MATERIAŁ BADAWCZY Z ZAKRESU ANALIZY OBRAZÓW .....	116
9.4	AUTOMATYZACJA PRZETWARZANIA I ANALIZY .....	116
9.4.1	Typy plików .....	116
9.4.2	Nazewnictwo plików z obrazami .....	117
9.4.3	Automatyczne sporządzanie spisów .....	117
9.4.4	Generowanie animacji (plików filmowych *.avi) .....	118
9.4.5	Kontrola czasu obliczeń i przetwarzania obrazów .....	118
9.5	DODATKOWE KOREKTY STOSOWANE DLA SEKWENCJI OBRAZÓW .....	118
9.5.1	Ocena i korekta zakresu jasności sekwencji obrazów .....	119
9.5.2	Ocena i korekta fluktuacji jasności w sekwencjach obrazów .....	122
9.5.3	Pomiar i korekta przemieszczeń obrazów w ramach sekwencji .....	125
9.6	PRZYKŁAD ANALIZY SEKWENCJI OBRAZÓW PODDANYCH BINARYZACJI PROGOWEJ .....	128
9.6.1	Operacje wstępne .....	128
9.6.2	Wyznaczanie progu binaryzacji dla sekwencji obrazów .....	128
9.6.3	Program do analizy binarnych sekwencji obrazów .....	133
9.6.4	Funkcja aproksymująca przebieg zmian pokrycia powierzchni stali materiałem kompozytowym .....	134
9.6.5	Wyniki analizy .....	135
9.6.5.1	Materiał SM-K22G3 .....	135
9.6.5.2	Materiał SM-2 .....	142
9.6.5.3	Materiał SM-B40G2 – analiza pasm jasnych w polu ciemnym .....	145
9.6.5.4	Materiał SM-S25 – analiza pasm jasnych w polu ciemnym .....	150
9.6.6	Podsumowanie wyników i wnioski .....	155
9.7	ZMIANY KURTOZY I NIEJEDNORODNOŚCI W SEKWENCJACH OBRAZÓW .....	156
9.8	PRZYKŁAD ANALIZY RÓŻNIC BINARNYCH SEKWENCJI OBRAZÓW .....	158

9.8.1	<i>Binaryzacja różnicowa bez korekty zakłóceń</i> .....	158
9.8.2	<i>Binaryzacja różnicowa z zastosowaniem korekt</i> .....	159
9.9	PRZYKŁAD ANALIZY RÓŻNIC HISTOGRAMÓW SKUMULOWANYCH .....	162
9.10	PRZYKŁAD ANALIZY MIGRACJI SKUPISK NANOSZONEGO MATERIAŁU METODĄ UC. ....	164
9.11	PODSUMOWANIE METOD ANALIZY SEKWENCJI OBRAZÓW .....	167
<b>10.</b>	<b>PODSUMOWANIE I WNIOSKI</b> .....	<b>169</b>
<b>11.</b>	<b>LITERATURA</b> .....	<b>171</b>
	PUBLIKACJE WŁASNE (W KOLEJNOŚCI CHRONOLOGICZNEJ) .....	171
	PUBLIKACJE OBCE (ALFABETYCZNIE).....	172
	ODSYŁACZE DO STRON INTERNETOWYCH .....	175
	PROGRAMY I FILMY UDOSTĘPNIONE NA STRONIE INTERNETOWEJ [S1] .....	176

ZBIGNIEW RUDNICKI  
**Metody komputerowej analizy obrazów  
w badaniach tribologicznych**

## **Streszczenie**

W niniejszej monografii przedstawiono istotne zagadnienia dotyczące komputerowej analizy obrazów odwzorowujących różne stany powierzchni występujące w procesach tarcia. Uwzględniono zarówno zmiany powierzchni wynikające z obróbki ubytkowej jak i niektóre zmiany wynikające z procesów zużycia tarciowego.

Po wprowadzeniu, we wstępie, podstawowych pojęć i omówieniu aktualnego stanu wiedzy, wyodrębniono pięć podstawowych kategorii tego rodzaju obrazów nazywanych ogólnie tribologicznymi. Dokonano przeglądu wielu istniejących metod analizy obrazów szarych oraz czarno-białych oceniając ich przydatność dla rozróżniania obrazów tribologicznych, a także zdefiniowano w tym celu szereg nowych deskryptorów w szczególności dla rozróżnianych wizualnie cech i meta-cech obrazów - reprezentujących niejednorodność, anizotropię oraz ukierunkowanie morfologii obrazu.

Przedstawiono dwa podejścia stosowane przy selekcji najlepszych liczbowych cech dyskryminacyjnych – pozwalających rozróżniać klasy obrazów - automatyczną selekcję ekstensywną (przez testowanie wielu różnorodnych cech) oraz podejście analityczne, ukierunkowane oparte na cechach jakościowych mających związek z badanymi procesami.

Rozpatrzono zarówno analizę statyczną – klas obrazów pozyskiwanych podczas przerw w procesach – jak i analizę dynamiczną - polegającą na analizie sekwencji obrazów rejestrowanych na bieżąco w trakcie procesów.

Za istotne uznano zagadnienia binaryzacji i analizy cech obrazów binarnych – omawiane oddzielnie dla obrazów statycznych oraz sekwencji obrazów.

Osobny rozdział poświęcono sposobom liczbowej ekspresji istotnych cech jakościowych obrazów tribologicznych, za które uznano m.in. niejednorodność przestrzenną oraz anizotropię i ukierunkowanie tekstury a także rozkłady wielkości elementów obrazów.

Końcowe rozdziały prezentują rezultaty prac autora dotyczących analizy sekwencji obrazów tribologicznych rejestrowanych podczas tarcia ślizgowego próbek kompozytów PTFE o powierzchnię tarczy stalowej w tribotesterze typu trzpień-tarcza. W szczególności przedmiotem zainteresowań było zjawisko transferu PTFE i warunki w jakich powoduje ono tworzenie się tzw. filmu transferowego czyli cienkiej warstwy polimeru na powierzchni stali korzystnej dla zmniejszania współczynnika tarcia oraz wzrostu trwałości par kinematycznych. Pokazano sposób automatyzacji komputerowego przetwarzania i analizy sekwencji obrazów. Opisano sposoby detekcji i korekcji szumów oraz innych zakłóceń procesu akwizycji sekwencji obrazów. Zaprezentowano konkluzje z dziedziny tribologii uzyskane w wyniku tej analizy.

## **Summary**

An important problems of computer analysis of images visualizing many states of surfaces during friction processes are presented and discussed in this monograph. Some changes of surfaces implied from machining or friction wear are taken into consideration.

After introducing the basic terms and overview of some current known research, five main categories of such tribological images are defined. Many known methods of analysis of gray level and binary images are presented and their ability for tribological image classification are discussed. Several new image features and meta-features descriptors are defined, especially those which represent nonhomogeneity, anisotropy and directionality of an image morphology.

The two approaches in selection of the best numerical discrimination features for image classification are presented: an automatic extensive selection (by testing of many features) and analytic driven selection – based on quality features correlated with investigated processes.

Static analysis - of images registered in process pauses are considered as well as dynamic analysis - of image sequences registered on line, during friction.

An important problems of binarization and binary images analysis were considered separately for static images and image sequences.

One of chapters deliberate methods of numerical expression of important quality features, which include nonhomogeneity, anisotropy and directionality of image texture and also distributions of image element areas.

The last part of the monograph describe the results of tribology image sequences investigation. These sequences were registered during sliding friction of PTFE composite samples on the steel disk of pin-on-disk tribotester. Especially PTFE transfer and creation of thin film of PTFE on steel surface was at the center of interest because of its relation to friction coefficient and wear rate of friction pairs. The method of automatic processing and analysis of image sequences was shown.

Methods of detection and correction of noise and other disturbances of image sequence acquisition were described. Conclusions from tribology area were presented.



## Spis oznaczeń w kolejności występowania

Symbol:	Objasnienie:
$X$	– cyfrowy obraz rastrowy szary
$Y$	– znormalizowana macierz obrazu
$k$	– numer kolumny macierzy obrazu
$Lk$	– liczba kolumn macierzy obrazu
$w$	– numer wiersza macierzy obrazu
$Lw$	– liczba wierszy macierzy obrazu
$Lx$	– liczba wszystkich pikseli obrazu
$Lg$	– nominalna liczba poziomów szarości
$g$	– numer odcienia szarości
$GR$	– wektor nominalnych poziomów szarości
$x_{w,k}$	– jasność piksela obrazu szarego (piksel obrazu szarego)
$\mathbf{X}=[X_i]$	– sekwencja obrazów cyfrowych szarych
$x_{w,k,i}$	– voksel (piksel trójwymiarowy) $i$ -tego obrazu sekwencji
$Li$	– liczba obrazów w sekwencji
$B$	– macierz obrazu binarnego (czarno-białego)
$\sim B$ lub $\tilde{B}$	– negacja logiczna macierzy binarnej
$BN$	– obraz binarny uzyskany w wyniku binaryzacji negatywowej
$\mathbf{B}=[B_i]$	– sekwencja obrazów binarnych
$b_{w,k,i}$	– voksel $i$ -tego obrazu sekwencji obrazów binarnych
$p$	– próg binaryzacji
$Ra$	– chropowatość powierzchni
$Fc$	– współczynnik Fisher'a – miernik zdolności dyskryminacyjnej
$D$	– wariancja międzyklasowa
$V$	– wariancja wewnątrzklasowa
$\mu$	– średnia
$Fc12$	– współczynnik Fischer'a dla dwu równolicznych klas
KAO	– komputerowa analiza obrazów
TA .. TE	– wyróżnione typy obrazów powierzchni trących
$SZUM_i=(X_i-X_s)$	– szum zawarty w obrazie $X_i$ uzyskany po odjęciu obrazu uśrednionego $X_s$
$xmin, xmax$	– granice rzeczywistego zakresu jasności pikseli obrazu
$percentyl_n\%$	– $n$ -ty percentyl jasności pikseli obrazu (w notacji ogólnej a nie Matlab'a)
$\mathbf{H}=[H_g]$	– histogram obrazu
$\mathbf{Hn}=[Hn_g]$	– znormalizowany histogram obrazu
$\mathbf{Hns}=[Hns_g]$	– histogram obrazu znormalizowany, skumulowany
$\mu_H$	– średnia histogramu obrazu

$(\sigma_H)^2$	–	wariancja histogramu obrazu
$\mu_H^3$	–	skośność histogramu obrazu
$\mu_H^4$	–	kurtoza histogramu obrazu
$VX$	–	wektor wszystkich pikseli obrazu
$SVX$	–	uporządkowany rosnąco wektor wszystkich pikseli obrazu
$G=[G_{w,k}]$	–	macierz gradientu obrazu szarego
$\mu_G$	–	średni gradient ( <i>GrMean</i> )
$(\sigma_G)^2$	–	wariancja gradientu ( <i>GrVariance</i> )
$\mu_G^3$	–	skośność gradientu ( <i>GrSkewness</i> )
$\mu_G^4$	–	kurtoza gradientu ( <i>GrKurtosis</i> )
$SJK$	–	wektor średnich jasności poszczególnych kolumn
$SJW$	–	wektor średnich jasności wierszy
$UCW$	–	procentowy udział czarnych pikseli w wierszach obrazów
$UCK$	–	procentowy udział czarnych pikseli w kolumnach obrazów
$C$	–	macierz przejść tonalnych ( <i>GLCM- gray level cooccurrence matrix</i> )
$\psi$	–	kąt skanowania macierzy obrazu
$\phi$	–	kąt obrotu obrazu
$dw, dk$	–	składowe wektora skanowania macierzy obrazu
$C(dw, dk)$	–	element macierzy przejść tonalnych $C$
$AngScMom$	–	drugi moment kątowy – energia (cecha macierzy $C$ )
$Contrast$	–	kontrast (cecha macierzy $C$ )
$Correlat$	–	korelacja (cecha macierzy $C$ )
$SumOfSqs$	–	suma kwadratów (cecha macierzy $C$ )
$InvDfMom$	–	odwrotny moment różnicowy (cecha macierzy $C$ )
$SumAverg$	–	sumaryczna średnia (cecha macierzy $C$ )
$SumVar$	–	sumaryczna wariancja (cecha macierzy $C$ )
$SumEntrp$	–	sumaryczna entropia (cecha macierzy $C$ )
$Entropy$	–	entropia (cecha macierzy $C$ )
$DifVarnc$	–	wariancja różnicowa (cecha macierzy $C$ )
$DifEntrp$	–	entropia różnicowa (cecha macierzy $C$ )
$ZK$	–	zmiennosc kolumn
$ZW$	–	zmiennosc wierszy
$PZK$	–	progowa zmiennosc kolumn
$PZW$	–	progowa zmiennosc wierszy
$R$	–	macierz rozkładu długości pasm ( <i>RLM - Run Length Matrix</i> )
$Lr$	–	maksymalna długość pasma
$SRE$	–	odwrotny moment uwydatnienia krótkich pasm ( <i>Short Run Emphasis inverse moment</i> )
$LngREmph$	–	moment uwydatnienia dł. pasm ( <i>Long Run Emphasis moment</i> )
$LRE$	–	moment uwydatnienia dł. pasm znormalizowany do zakr. <0; 1>
$RLNonUni$	–	niejednorodność pasm ( <i>Run Length Nonuniformity</i> )
$RLN$	–	niejednorodność pasm znormalizowana do zakr. <0; 1>
$FIR$	–	część obrazu w pasmach ( <i>Fraction of Image in Runs</i> )
$GLevNonU$	–	niejednorodność szarości ( <i>Gray Level NonUniformity</i> )
$AR$	–	model autoregresji
$\theta_1, \theta_2, \theta_3, \theta_4$	–	parametry modelu autoregresji
$BN99$	–	metoda binaryzacji (normalizacja <i>Norm99</i> i stały próg $p=128$ )
$OD$	–	orientacja dominująca obiektów binarnych

<i>Pokr</i>	–	względne pokrycie białymi zmianami czarnego tła obrazu
<i>Lc</i>	–	liczba czarnych pikseli obrazu binarnego
<i>Lb</i>	–	liczba białych pikseli obrazu binarnego
<i>Nx, Ny</i>	–	liczba pasm poziomych ( <i>Nx</i> ) oraz pionowych ( <i>Ny</i> )
<i>Dx, Dy</i>	–	średnie długości pasm poziomych ( <i>Dx</i> ) oraz pionowych ( <i>Dy</i> )
<i>Zx, Zy</i>	–	ziarnistość pozioma ( <i>Zx</i> ) oraz pionowa ( <i>Zy</i> ) obrazu
<i>Rc, Rb</i>	–	rozkład długości pasm czarnych ( <i>Rc</i> ) oraz białych ( <i>Rb</i> )
<i>Rbx</i>	–	znormalizowany rozkład ważonych długości pasm białych w wierszach obrazu
<i>W3bx</i>	–	Rozkład <i>Rbx</i> zredukowany do trzech składowych i znormalizowany do zakresu 0÷1
<i>Kr=W3bx<sub>1</sub></i>	–	udział pasm krótkich w pokryciu obrazu bielą
<i>Sr=W3bx<sub>2</sub></i>	–	udział pasm średnich w pokryciu obrazu bielą
<i>Dl=W3bx<sub>3</sub></i>	–	udział pasm długich w pokryciu obrazu bielą
<i>LAB</i>	–	macierz indeksów wyodrębnionych funkcją <i>bwlabel</i> obiektów
<i>no</i>	–	liczba wyodrębnionych podczas indeksacji obiektów
<i>cechy</i>	–	tablica strukturalna z wartościami cech obiektów
<i>OD</i>	–	orientacja dominująca wyodrębnionych obiektów
<i>L(wyrażenie)</i>	–	wartość logiczna <i>wyrażenia</i> (1=prawda, 0=falsz)
<i>HA</i>	–	rozkład pól obiektów
<i>HWA</i>	–	ważony znormalizowany rozkład pól
<i>SHWA</i>	–	skumulowany ważony rozkład pól (dystrybuanta)
<i>fft2(X)</i>	–	dwuwymiarowa szybka transformata Fourier'a obrazu <i>X</i>
<i>F(X)</i>	–	macierz $F(X) = \text{Log}(\text{Abs}(\text{fft2}(X)))$
<i>Njn(Cx,X)</i>	–	niejednorodność obrazu <i>X</i> względem cechy <i>Cx</i> przy <i>n</i> podobrazach
<i>Nj4(Cx,X)</i>	–	niejednorodność ćwiartkowa obrazu <i>X</i> wzgl. odchyl. stand. cechy <i>Cx</i>
<i>Nj13med</i>	–	niejednorodność mediany w zbiorze 4+9 podobrazów: <i>Nj13(median,X)</i>
<i>Nj4mean</i>	–	niejednorodność ćwiartkowa śr. jasności: <i>Nj4(mean,X)</i>
<i>Cx</i>	–	cecha obrazu
<i>Cx(X, ψ)</i>	–	rozkład kierunkowy cechy <i>Cx</i> obrazu <i>X</i> w funkcji kąta skanowania <i>ψ</i>
<i>Dir1</i>	–	pierwszy kierunek dominujący (inaczej główny)
<i>Dir2</i>	–	drugi kierunek dominujący
<i>Anizo_r(X,Cx)</i>	–	różnicowa miara anizotropii
<i>Anizo_d(X,Cx)</i>	–	różnicowa dodatnia miara anizotropii
<i>Anizo_h(X,Cx)</i>	–	hiperboliczna unormowana miara anizotropii
<i>Orto_r(X,Cx)</i>	–	ortotropia bezwzględna różnicowa
<i>Orto_d(X,Cx)</i>	–	ortotropia bezwzględna różnicowa dodatnia
<i>Orto_h(X,Cx)</i>	–	unormowana bezwzględna ortotropia hiperboliczna
<i>OrtW_r(X,Cx)</i>	–	ortotropia względna różnicowa
<i>OrtW_d(X,Cx)</i>	–	ortotropia względna różnicowa dodatnia
<i>OrtW_h(X,Cx)</i>	–	unormowana względna ortotropia hiperboliczna
<i>URZKW</i>	–	unormowana różnica zmienności kolumn i wierszy
<i>Nxy</i>	–	ilorazowa ortotropia względna tekstury binarnej $Nxy=Nx/Ny$
<i>UDSW</i>	–	unormowana dewiacja średnich z wierszy
<i>UDMedW</i>	–	unormowana dewiacja median wierszy
<i>UMxDW</i>	–	unormowana maksymalna dewiacja wierszy
<i>MRHS</i>	–	metoda różnic histogramów skumulowanych
<i>PR<sub>mSP</sub></i>	–	próg wyznaczany dla sekwencji obrazów w/g wzoru (8.5)

<i>Ls</i>	–	liczba ślizgów (przejsć próbki trącej przez badany wycinek tarczy)
<i>S</i>	–	droga tarcia
<i>v</i>	–	predkość liniowa próbki względem tarczy tribotestera
<i>Obw</i>	–	średni obwód śladu tarcia na tarczy tribotestera
<i>Pk(Ls)</i>	–	funkcja aproksymująca przebieg zmian pokrycia względnego
<i>Pk0</i>	–	początkowy poziom pokrycia - dla czystej tarczy powinien wynosić zero
<i>Ls1</i>	–	liczba ślizgów po której rozpoczyna się wzrost pokrycia
<i>Pk1</i>	–	poziom ustalony pierwszego członu wykładniczego
<i>T1</i>	–	stała czasowa pierwszego członu wykładniczego
<i>Ls2</i>	–	liczba ślizgów po której rozpoczyna się działanie drugiego członu wykładniczego funkcji
<i>Pk2</i>	–	poziom ustalony drugiego członu wykładniczego
<i>T2</i>	–	stała czasowa drugiego członu wykładniczego
<i>kp</i>	–	współczynnik korekty binaryzacji różnicowej
<i>KORMIN</i>	–	metoda binaryzacji różnicowej sekwencji obrazów z korektą przemieszczeń kadu obrazów oraz fluktuacji jasności oświetlenia
<i>BINp</i>	–	binaryzacja sekwencji obrazów ze stałym progamiem p

# 1. Wprowadzenie

## 1.1 Wstęp

Wizualna obserwacja należy do najprostszych i podstawowych sposobów oceny stanów powierzchni poddawanych tarcia. Dążenie do zautomatyzowania i skomputeryzowania tej czynności jest naturalną konsekwencją rozwoju techniki. Jednakże rozpoznawanie różnorodnych klas obrazów - dla człowieka proste i naturalne - dla robotów lub urządzeń automatycznego monitorowania stanowi na ogół zadanie trudne, nie poddające się uniwersalnym regułom, wymagające uwzględnienia wielu czynników oraz zawężenia obszaru zainteresowań do określonych kategorii obrazów.

Komputerowe przetwarzanie, analizowanie i rozpoznawanie obrazów jest jednak z powodzeniem stosowane w bardzo wielu dziedzinach nauki i techniki jak: geologia, petrografia, krystalografia, inżynieria materiałowa, metalografia, robotyka, meteorologia, medycyna, kryminalistyka i inne.

Skomputeryzowane systemy wizyjne (*machine vision systems*) już zastępują i wyręczają ludzi w wielu procesach analizy i rozpoznawania określonych klas obrazów, jak choćby linii papilarnych w systemach zabezpieczających dostęp, czy banknotów w automatach sprzedających produkty. W innych dziedzinach – a szczególnie w przypadku złożonych obrazów i zmieniających się obiektów trójwymiarowych - systemy te są wciąż doskonałe, pozwalając raczej na wstępną hipotetyczną klasyfikację. Tak czy owak, systemy wizyjne po pierwsze - rozszerzają zakres percepcji naszego zmysłu wzroku - na przykład na zakres podczerwieni czy ultrafioletu albo dostrzegania różnic niewykrywalnych przy bezpośredniej obserwacji, po drugie umożliwiają automatyczną, masową analizę i klasyfikację milionów obrazów, w oparciu o liczbowe kryteria, przy pomocy urządzeń nie podlegających emocjom ani zmęczeniu, także tam gdzie człowiek dotrzeć nie może.

W dziedzinie tribologii stosunkowo niewiele publikacji świadczy o wykorzystywaniu tego rodzaju narzędzi. Jednakże, zarówno stale postępująca automatyzacja i robotyzacja procesów obróbki i monitorowania stanu eksploatowanych maszyn, jak również ciągły rozwój badań tribologicznych, stwarzają – zdaniem autora – zapotrzebowanie na rozwijanie metod automatycznej komputerowej analizy obrazów powierzchni, uczestniczących w procesach tarcia. Niniejsza monografia ma odpowiedzieć temu zapotrzebowaniu przedstawiając **metody i możliwości zastosowań przetwarzania i analizy obrazów w tribologii**, oraz ilustrując je wynikami szeregu eksperymentów. Przeznaczona jest dla osób zainteresowanych stosowaniem metod analizy obrazów w badaniach tribologicznych.

Rozdział pierwszy wprowadza w **terminologię** dziedziny przetwarzania i analizy obrazów i ich sekwencji (p.1.2) oraz zarysowuje **aktualny zakres** zastosowań metod analizy obrazów w tribologii (p.1.3).

W rozdziale drugim zdefiniowano **cele badań** przedstawianych w monografii. Głównym celem był dobór metod z dziedziny komputerowej analizy obrazów, które pozwolą na automatyczną identyfikację oraz klasyfikację obrazów przedstawiających wybrane charakterystyczne stany powierzchni metali spotykane w procesach tarcia i zużycia, oraz metod pozwalających monitorować przebieg zmian morfologii powierzchni trących. Dodatkowe cele odnośnie badania sekwencji obrazów tribologicznych zdefiniowano w rozdziale 9.

Rozdział 3 „Obszar i organizacja badań” m.in. wyjaśnia wielowątkowość i wielotorowość badań skutkujących nieco skomplikowaną strukturą niniejszej monografii.

Najpierw (p.3.1) przedstawiono cztery **kategorie badanych obrazów** - zarówno rzeczywistych powierzchni jak sztucznie wygenerowanych, następnie rozróżniono ilościowe i jakościowe cechy obrazów tribologicznych (p.3.2) i wyróżniono (w pierwszej kategorii) **pięć klas obrazów tribologicznych** odpowiadających jakościowo różnym typom morfologii powierzchni, od *zmian punktowych*, poprzez *plamy i wżery* aż do różnego typu *zarysowań*. Pokazano obrazy reprezentujące te klasy i stanowiące obiekty pierwszej części badań.

Podrozdział 3.3 wprowadza zaproponowaną przez autora **klasyfikację cech** obrazów, rozpatrywanych jako populacje określonych grup pikseli, definiowanych a priori (np. par, kolumn, wierszy) lub reprezentujących wydzielone obiekty. Wprowadza także pojęcie **meta-cech**, takich jak: niejednorodność przestrzenna oraz anizotropia obrazu względem danej cechy. W podrozdziale 3.4 rozróżniono dwie testowane kategorie metod poszukiwania cech pozwalających rozróżnić klasy obrazów tribologicznych – selekcję ekstensywną oraz podejście analityczne. Następnie (p.3.5) scharakteryzowano analizę statyczną (klas obrazów) oraz dynamiczną (sekwencji obrazów) oraz opisano krótko użyty sprzęt i oprogramowanie.

Rozdział 4 omawia wybrane istotne zagadnienia akwizycji obrazów oraz analizy i korekty błędów i zakłóceń, takich jak przestrzenna nierównomierność jasności oraz szum.

Rozdział 5 opisuje charakterystyki i **cechy obrazów cyfrowych szarych**, zarówno znane z literatury jak i niektóre zdefiniowane przez autora. Przedstawia i omawia zróżnicowanie tych charakterystyk wyznaczonych dla reprezentantów wybranych klas obrazów tribologicznych i ocenia ich przydatność dla badań tribologicznych.

Rozdział 6 omawia najpierw zagadnienie **binaryzacji** czyli przetwarzania obrazów na czarno-białe a następnie omawia **cechy wyznaczane z obrazów czarno-białych**, w tym również cechy zdefiniowane przez autora, przydatne w analizie obrazów tribologicznych.

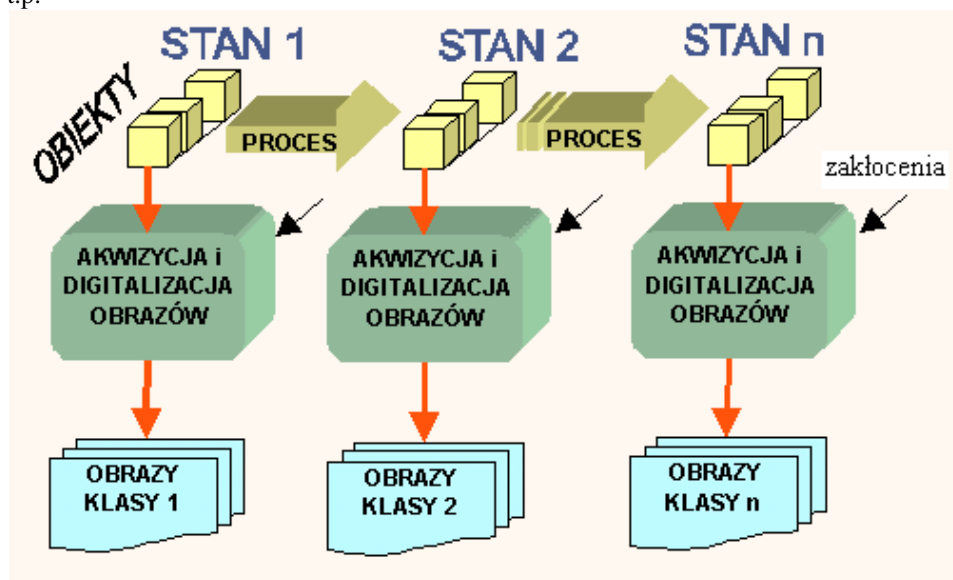
Rozdział 7 przedstawia wyniki kilku prób zastosowań **ekstensywnej**, „ślepej” **selekcji cech dyskryminacyjnych**, realizowanej przy pomocy programów MaZda i Convert oraz dokonuje podsumowania zalet i wad takiego podejścia dla obrazów tribologicznych.

Rozdział 8 zajmuje się **relacjami między cechami jakościowymi** – dostrzeganymi przez człowieka **a ilościowymi** – statystykami obrazu. Przedstawiono wyniki badań wrażliwości znanych cech ilościowych na zmiany jasności, kontrastu, ostrości oraz uporządkowania tekstury, traktując uporządkowanie jako istotne dla obrazów tribologicznych. Następnie przedstawiono rozwinięcie idei meta-cech obrazów oraz bardzo istotne wyniki uzyskane przez autora w poszukiwaniu ilościowych cech obrazów najlepiej odzwierciedlających wizualnie dostrzegane cechy jakościowe obrazów tribologicznych, takie jak niejednorodność, anizotropię i ukierunkowanie tekstury.

Obszerny rozdział 9 omawia problematykę analizy **sekwencji obrazów** tribologicznych na przykładach badania transferu materiału kompozytowego w trakcie tarcia. Przedstawiono m.in. badania **zakłóceń** i błędów oraz metody ich kompensacji. Zaprezentowano **przebiegi zmian** „filmu transferowego” dla kilku badanych materiałów kompozytowych.

## 1.2 Podstawowe pojęcia

Potrzeba zastosowania komputerowego przetwarzania i analizy obrazów w dziedzinie tribologii, może wynikać z konieczności automatyzacji uzyskiwania odpowiedzi na takie proste pytania jak: „czy stan obrabianej powierzchni jest zadowalający?”, „czy powierzchnia elementu maszyny wykazuje zużycie wymagające interwencji?”, „czy wytworzyła się warstewka tzw. filmu smarnego, zmniejszającego tarcie?”, „czy narzędzie wymaga wymiany?”, „jakie zmiany zachodzą na powierzchni przy zmianie parametrów procesu tarcia?” i t.p.



Rys. 1.1. Stany obiektów i odpowiadające im klasy obrazów

Odpowiedzi na takie pytania zawierają wprawdzie niewielkie porcje informacji – czasem równoważne pojedynczym bitom - ale za to istotnych, zarówno w procesach obróbki jak i eksploatacji maszyn. Przejście od milionów bitów wyrażających obrazy do pojedynczych bitów stanowiących szukane odpowiedzi – jest wieloetapowym procesem redukcji i selekcji informacji stanowiącym przetwarzanie, analizę i rozpoznawanie obrazów.

U podstaw analizy i rozpoznawania obrazów leży założenie, że poszczególnym odpowiedziom na tego rodzaju pytania odpowiadają różniące się **stany** badanych powierzchni, (Rys. 1.1) odwzorowywane przez oddzielne **klasy obrazów**, dające się rozróżnić komputerowo.

Stan powierzchni może być określany różnymi charakterystykami i parametrami opisującymi m.in. chropowatość oraz skład i rozkład przestrzenny produktów chemicznych

powstających w wyniku różnych procesów. Obrazy powierzchni tylko w pewnym stopniu odwzorowują jej stan, dostarczając jednak informacji przydatnych do oceny tego stanu. Komputerowa analiza obrazów może więc posłużyć do automatyzacji diagnostyki wybranych parametrów stanu powierzchni, dając przesłanki do podejmowania decyzji eksploatacyjnych. Przykładowo – zmiany na obrazach obrabianej powierzchni mogą być sygnałem do wymiany zużytego narzędzia obrabiającego.

Warunkiem koniecznym dla możliwości zastosowania komputerowej analizy obrazów jest znalezienie takich cech, które umożliwią rozróżnianie obrazów odwzorowujących poszczególne stany powierzchni interesujące z punktu widzenia tribologii.

Pojęcia: „przetwarzanie”, „analiza” oraz „rozpoznawanie”, bywają zamiennie stosowane w odniesieniu do obrazów, jednak oznaczają różne operacje, a mianowicie - do **przetwarzania** obrazów należą operacje dające w wyniku również obrazy, operacje **analizy** – dają w wyniku liczbowe charakterystyki i **cechy** obrazów, natomiast **rozpoznawanie** pozwala - na podstawie wartości **wektora** wyróżnionych **cech** – klasyfikować, zaliczając badane obrazy do znanych **klas**.

obraz 1 → PRZETWARZANIE → obraz 2
obraz → ANALIZA → wektor deskryptorów liczbowych wybranych cech obrazu
wektor cech obrazu → ROZPOZNAWANIE → zaklasyfikowanie obrazu

Rozpoznawanie obrazów poprzedzane jest zawsze operacjami przetwarzania oraz analizy. Łącznie operacje te realizują **redukcję** informacji – od milionów bitów wyrażających odcienie i rozmieszczenie poszczególnych punktów obrazu (często zniekształconego oraz zakłóconego) do kilku bitów stanowiących poszukiwaną odpowiedź.

Kolejność etapów badań obrazów może być następująca:

1. określenie **celu** analizy i parametrów procesu akwizycji,
2. **akwizycja** obrazów – pobieranie, przetwarzanie na postać cyfrową i zapisywanie w pamięci komputera,
3. **selekcja** obrazów do „**zbiorów uczących**”, reprezentujących poszczególne klasy,
4. **obserwacja** obrazów i **wybór cech** do analizy,
5. **przetwarzanie** obrazów (filtracja zakłóceń, korekta zniekształceń, uwydatnianie wybranych cech),
6. **segmentacja** (dla obrazów teksturowych bywa pomijana) – wydzielenie obiektów lub obszarów zainteresowań (*ROI – region of interest*), jeśli wyodrębnione będą obiekty do analizy to dodatkowo są one numerowane przy pomocy operacji zwanej **indeksacją**,
7. **analiza** obrazów - wyznaczanie charakterystyk wektorowych lub macierzowych oraz liczbowych deskryptorów dla wybranych cech obrazów lub wydzielonych obiektów,
8. **ocena zdolności dyskryminacyjnej** wybranych cech na wzorcowych klasach obrazów zwanych „zbiorami uczącymi”,
9. ostateczny **wybór wektora cech** dyskryminacyjnych lub powrót do punktu 3,
10. zastosowanie analizy wybranych cech do **rozpoznawania** innych nieznanych obrazów.

Powodzenie procesu rozpoznawania zależy m.in. od znalezienia (selekcji) i wykorzystania takich **cech** obrazów (spośród bardzo wielu możliwych), które będą **najlepszymi**

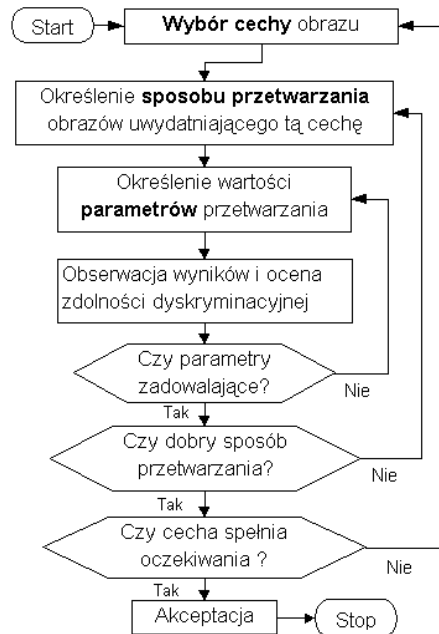


**dyskryminatorami** klas obrazów. Inaczej mówiąc - pozwolą wyraźnie rozróżniać (*discriminate*) badane klasy obrazów. Sprawdzanie **zdolności dyskryminacyjnej** różnych cech dokonywane jest na wzorcowych reprezentantach klas obrazów czyli tzw. zbiorach uczących.

Selekcja cech dyskryminacyjnych może być realizowana:

- automatycznie – przez komputerowe wyznaczanie i porównywanie zdolności dyskryminacyjnej możliwie jak największej liczby różnych cech – co można określić jako *selekcję ekstensywną*,
- samodzielnie przez badacza – na podstawie analizy problemu i badania hipotez – ten rodzaj selekcji można nazwać *selekcją dedukcyjną*.

W tym drugim przypadku, kolejne próby mogą przebiegać według schematu:



Rys. 1.2. Empiryczny dobór cech dyskryminacyjnych

Wyodrębnionym cechom przypisywane są – w wyniku określonych procedur – liczbowe **deskryptory**. Proces wyznaczania deskryptorów cech nazywany jest czasem **ekstrakcją cech**. W przypadku pojedynczej cechy – rozróżnianym klasom obrazów powinny odpowiadać rozłączne przedziały wartości deskryptora tej cechy. Najczęściej jednak, dla każdego obrazu wyznaczany jest **wektor** kilku **cech** i wtedy poszczególnym klasom obrazów odpowiadają różne obszary n-wymiarowej **przestrzeni cech**, przy czym istotnym zagadnieniem jest oszacowanie (probabilistyczne) granic tych obszarów (na podstawie zbiorów uczących). Rozpoznanie nieznanego obrazu wymaga zaklasyfikowania jego wektora cech do obszaru przestrzeni cech odpowiadającego jednej z klas.

Obrazy powierzchni biorących udział w procesach tarcia nazywane będą **obrazami tribologicznymi**. W analizie obrazów tribologicznych jako pierwszy etap redukcji informa-

cji przyjęto rezygnację z koloru. Dlatego w niniejszej pracy rozważane będą jedynie obrazy i sekwencje **obrazów szarych** oraz **czarno-białych** zwanych **binarnymi**.

### 1.2.1 Obrazy obiektów oraz tekstur

Obrazy cyfrowe (zarówno szare jak i barwne) można klasyfikować m.in. pod względem przedstawianych treści na:

- obrazy **obiektów** (wyróżniających się z tła) - inaczej "**obrazy obiektowe**"
- obrazy **tekstur** - przedstawiające fragment jednej powierzchni, a w szczególności jej fakturę (ang.: *texture*) i dlatego nazywane - zgodnie z anglo-języcznym terminem - "obrazami **teksturowymi**" (*texture image*).

Podział ten jest w znacznej mierze umowny i zależy od skali, liczby obiektów oraz równomierności ich rozkładu na obrazie. Obraz przedstawiający wielką liczbę obiektów (np.: cegieł czy drzew) rozłożonych równomiernie (lub w przybliżeniu równomiernie) jest zazwyczaj zaliczany do kategorii tekstur, podczas gdy wycinek tego obrazu przedstawiający jeden lub kilka wybranych obiektów - może być analizowany raczej jako obraz obiektowy.

Klasyfikacja ta jest istotna ze względu na różne metody analizy. Obrazy tekstur są analizowane jako populacje ustalonych a priori grup pikseli, podczas gdy obiekty muszą być najpierw wyodrębnione (w procesie segmentacji) i ponumerowane (w procesie indeksacji), a potem wyznaczane są parametry dla każdego obiektu z osobna. Dla niektórych typów obrazów - na przykład gdy występują obiekty różniące się teksturą - bywają stosowane oba podejścia.

Obrazy teksturowe występują i mają duże znaczenie w bardzo wielu dziedzinach nauki i techniki jak choćby: metalografia i krystalografia, tribologia (obrazy powierzchni trących i cząstek zużyciowych), geologia (powierzchnie skał), medycyna (fragmenty tomogramów, rentgenogramów, itd.).

W grafice komputerowej [42] rozróżnianych jest kilka kategorii tekstur, począwszy od regularnych poprzez prawie regularne i nieregularne aż do stochastycznych. W teksturach regularnych powtarzają się identyczne elementy rozmieszczone w regularnej siatce przestrzennej. W teksturach stochastycznych zarówno kształt i wymiary motywów obrazu jak ich rozmieszczenie jest losowe.

Obrazy tribologiczne najczęściej mogą być zaliczane do kategorii **tekstur** stochastycznych. Dla niektórych typów obrazów - gdy pojawiają się plamy czy wżery - mogą być także stosowane metody analizy **obiektów**.

### 1.2.2 Cyfrowy zapis obrazów rastrowych szarych

Jak wspomniano, jednym z pierwszych etapów redukcji informacji - będącej podstawowym celem analizy - jest zazwyczaj rezygnacja z kolorów i ograniczenie analizy do klasy obrazów monochromatycznych o wielu odcieniach szarości, reprezentowanych w komputerze jako **obrazy rastrowe szare** (*raster grayscale image*).

Każdy tego typu obraz  $X$  jest zbiorem elementarnych punktów - **pikseli** - rozmieszczonych w prostokątnej siatce czyli rastrze o określonej liczbie  $L_w$  wierszy i  $L_k$  kolumn.

Zapis rastrowego obrazu szarego w pamięci komputera, czyli inaczej mówiąc - obraz cyfrowy szary - jest macierzą:

$$X = [x_{w,k} \in GR] \quad (1.1)$$

gdzie:  $k = 1, 2, \dots, Lk$  - numery kolumn,  
 $w = 1, 2, \dots, Lw$  - numery wierszy,  
 $GR = [GR_g]$ ,  $g=1, 2, \dots, Lg$  - wektor nominalnych poziomów szarości  
 $Lg$  = liczba poziomów szarości

Jasność  $x_{w,k}$  każdego piksela obrazu szarego może przyjmować wartości należące do wektora nominalnych poziomów szarości  $GR$ . Wektor  $GR$  jest nazywany „mapą kolorów” (*color map*), a liczba jego składowych  $Lg$  zależy od zastosowanej rozdzielczości chromatycznej. Najczęściej maksymalną stosowaną liczbą poziomów szarości jest  $Lg=256$ .

W programach komputerowych, tworzonych w systemie Matlab, posługiwano się zarówno macierzami obrazów typu *uint8* (liczby całkowite bez znaku) w których  $Lg=256$ ,  $GR \in \langle 0; Lg-1 \rangle$ , a dokładniej  $GR_g = g-1$ , jak również macierzami typu *double* (liczby rzeczywiste podwójnej precyzji z zakresu  $GR \in \langle 0; 1 \rangle$ ) obowiązującego przy realizowaniu operacji arytmetycznych na obrazach.

Konwersja obrazów na typ *double* powinna być dokonywana przy pomocy funkcji *im2double(...)* przeskalowującej zakres wartości elementów macierzy obrazu do przedziału  $\langle 0; 1 \rangle$ .

### 1.2.3 Cyfrowy zapis sekwencji obrazów

Analizowano również sekwencje cyfrowych obrazów szarych reprezentowane przez macierze trójwymiarowe:

$$\mathbf{X} = [X_i] = [x_{w,k,i} \in GR, i=1,2..Li, k=1,2..Lk, w=1,2..Lw] \quad (1.2)$$

gdzie:

$i$  - numer obrazu,  $Li$  - liczba obrazów,  
 $x_{w,k,i}$  - piksel  $i$ -tego obrazu sekwencji czyli voksel (piksel trójwymiarowy),  
pozostałe oznaczenia jak poprzednio.

Przy rozpatrywaniu pojedynczego obrazu pomijany będzie jego numer  $i$ .

### 1.2.4 Akwizycja obrazów i sekwencji obrazów

Gromadzenie, przetwarzanie i analizowanie wszelkiego typu informacji przy pomocy komputerów wymaga ich digitalizacji czyli wyrażenia w postaci cyfrowej i dotyczy to oczywiście także obrazów. Wprowadzanie informacji graficznych do komputera, przy pomocy takich urządzeń jak skanery oraz foto-aparaty i kamery cyfrowe, nazywane jest ogólnie **akwizycją obrazów**.

Organizacja procesu akwizycji obrazów wymaga przede wszystkim określenia:

- **lokalizacji** badanych obszarów oraz **wymiarów kadru obrazu** (wyrażanych w jednostkach długości), zależnych od zastosowanego **powiększenia**,
- **rozdzielczości przestrzennej** obrazu (wyrażanej w pikselach na jednostkę długości),
- **rozdzielczości chromatycznej** określającej liczbę rozróżnianych kolorów lub odcieni szarości,
- **czasu ekspozycji** - szczególnie istotnego przy obiektach poruszających się i dobrania wymaganej w związku z tym **czułości przetwornika obrazu**,
- ustawień **parametrów oświetlenia** (skupione, rozproszone, liczba źródeł, kąt padania, jasność, barwa),

- dostrojenia układu optycznego, a w szczególności ustawienia **ostrości**.

W procesie akwizycji informacja graficzna jest zniekształcana i zakłócana m.in. przez takie czynniki jak:

- aberacje geometryczne i chromatyczne układu optycznego,
- wady oświetlenia (poziom, nierównomierność, odbłaski)
- szумы przetwornika wizyjnego i układów elektronicznych,
- przypadkowe artefakty (np. zabrudzenia układu optycznego lub oświetlacza),

Wynikające stąd **wady obrazów** mogą w znacznym stopniu być **korygowane** przy pomocy **przetwarzania obrazów**. Jednak należy zaznaczyć, że niektóre błędy akwizycji, jak nadmierny kontrast lub zbyt jasne oświetlenie, mogą powodować nieodwracalną utratę części informacji, zawartych często w większym stopniu w ciemnych czy mało kontrastowych obrazach.

Niezależnie od wymagań odnośnie parametrów procesu akwizycji, konieczne jest utrzymywanie stałości tych parametrów przy akwizycji obrazów, których cechy mają być wzajemnie porównywane.

### 1.2.5 Przetwarzanie obrazów

Jak już wspomniano - do przetwarzania obrazów należą wszelkie operacje dokonywane na obrazie źródłowym, których **wynikiem jest również obraz** lub jego fragment.

Niektóre cele stosowania różnorodnych operacji przetwarzania to:

- redukcja zakłóceń (np. szumów) i korygowanie błędów,
- poprawa jakości obrazu,
- redukcja liczby informacji,
- uwydatnienie określonych cech,
- podział obrazu na podobrazy
- wyodrębnianie obiektów (segmentacja).

Oprócz korygowania błędów i filtrowania zakłóceń, przetwarzanie obrazów może spełniać szereg innych funkcji jak choćby normalizacja zakresu jasności obrazów czy wyodrębnianie obiektów lub "regionów zainteresowania" (*ROI - region of interest*) bądź uwydatnianie określonych cech.

W niniejszych badaniach stosowano m.in. takie operacje przetwarzania jak:

1. wycinanie fragmentu obrazu lub podział na podobrazy,
2. obracanie i skalowanie,
3. wyrównywanie jasności tła zwane też "wyrównywaniem cienia",
4. normalizacja obrazu – czyli rozszerzenie zakresu odcieni do maksymalnego dopuszczalnego,
5. wyrównywanie (*equalizacja*) histogramu obrazu - skutkujące zazwyczaj maksymalnym zwiększeniem kontrastu i utratą niektórych odcieni,
6. rozjaśnianie lub przyciemnianie obrazów,

7. filtracja medianowa - w której wartość każdego piksela zostaje zastąpiona wartością mediany jego otoczenia – pozwalającą m.in. usuwać jasne i ciemne punkty lub drobne plamy będące wynikiem szumu,
8. odejmowanie i dodawanie obrazów lub ich składowych uzyskiwanych w rezultacie filtacji i innych operacji,
9. binaryzacja progowa,
10. binaryzacja różnicowa oraz gradientowa
11. indeksacja (numerowanie) quasi-objektów,
12. czyszczenie brzegu czyli usuwanie obiektów przecinanych przez granice obrazu.
13. operacje morfologiczne na obrazach binarnych

Niektóre z tych operacji omówiono dokładniej w dalszej części tej monografii.

Należy pamiętać, że **przetwarzanie** zmieniając obraz **może zmienić** także **wyniki** analizy. Dlatego trzeba być świadomym tego wpływu i stosować przetwarzanie tylko wtedy gdy to konieczne. Obrazy dobrej jakości, uzyskane z poprawnie przeprowadzonego procesu akwizycji mogą nie wymagać przetwarzania

Jeśli jednak konieczne jest przetwarzanie to aby uniknąć zafałszowania wyników najlepiej stosować identyczną - także co do parametrów - operację dla wszystkich badanych obrazów. Odnosi się to w szczególności do operacji zmieniających jasność pikseli oraz binaryzacji.

## 1.2.6 BINARYZACJA I SEGMENTACJA

W ramach redukcji informacji bardzo często stosowaną operacją jest **binaryzacja**. Polega ona na przetworzeniu obrazów szarych na czarno-białe zwane binarnymi gdyż do zapisu każdego piksela wystarcza w nich jeden bit informacji. Wartość zerowa tego bitu oznacza piksel czarny, a wartość równa jeden – piksel biały.

Celem binaryzacji jest najczęściej wyodrębnienie obiektów zainteresowań od reszty obrazu traktowanej jako tło. Ogólnie wyodrębnianie obiektów od tła nazywa się segmentacją, a więc binaryzacja może być jednym ze sposobów segmentacji.

Najczęściej stosowana jest **binaryzacja progowa**. W tej operacji wartości wszystkich pikseli obrazu szarego  $X$  są porównywane z ustalonym **progiem**  $p$ . Piksele jaśniejsze od  $p$  są przetworzone w wynikowym obrazie  $B$  na białe, a piksele ciemniejsze od  $p$  stają się czarnymi. Taka binaryzacja nazywana jest „binaryzacją z dolnym progiem” [38].

W Matlabie może ona być zrealizowana następującą operacją logiczną:

$$B = X > p;$$

Sekwencję obrazów binarnych można zapisać jako macierz trójwymiarową:

$$\mathbf{B} = [B_i] = [b_{w,k,i} \in [0, Lg-1]]; \quad Lg=2; \quad i=1,2..Li; \quad k=1,2..Lk; \quad w=1,2..Lw] \quad (1.3)$$

gdzie:

$B_i$  – obraz binarny (czarno-biały)

$b_{w,k,i}$  – piksel  $i$ -tego obrazu sekwencji czyli voksel macierzy trójwymiarowej:

$$b_{w,k,i} = \begin{cases} 1 & \text{dla } x_{w,k,i} > p \\ 0 & \text{dla } x_{w,k,i} \leq p \end{cases} \quad (1.4)$$

Podwyższanie progu zwiększa liczbę czarnych pikseli w wynikowym obrazie, a obniżanie zmniejsza. Towarzyszą temu zmiany pola, a często i kształtu obiektów. Właściwy dla danych celów **dobór** jednego stałego - **globalnego dla badanych klas progu binaryzacji  $p$**  i utrzymanie jego stałości dla porównywanych klas obrazów jest więc kluczowym zagadnieniem od którego zależy wynik binaryzacji, a pośrednio wyniki pomiarów własności wyodrębnionych obszarów, stanowiące rezultat analizy.

W uzasadnionych przypadkach wartość progu może jednak być ustalana **lokalnie w sekwencji** - uzależniona od parametrów każdego obrazu, na przykład percentyli 1% i 99% - albo **lokalnie w obrazie** - dla każdego piksela uzależniana od jego otoczenia, co jest równoważne wprowadzeniu filtracji kontekstowej przed binaryzacją. Zastrzeżenia dotyczące takiego **adaptacyjnego** progu są analogiczne jak dla innych przekształceń, wnoszących ryzyko zafałszowania wyników analizy.

W przypadku obrazów z jasnym tłem i ciemnymi obiektami stosuje się binaryzację negatywową zwaną też „z górnym progim” :

$$\mathbf{BN}=[BN_i]=bn_{w,k,i}; \quad bn_{w,k,i} = \begin{cases} 0 & \text{dla } x_{w,k,i} \geq p \\ 1 & \text{dla } x_{w,k,i} < p \end{cases} \quad (1.5)$$

Binaryzacja z zastosowaniem **kilku progów** i odpowiednich zależności logicznych jest stosowana znacznie rzadziej, m.in. w przypadkach gdy chodzi o wyodrębnienie obszarów o znanym zakresie odcieni.

Niektóre sposoby określania progu binaryzacji opisano w p.6.1, a w rozdziale 9 omówiono zagadnienia związane z binaryzacją sekwencji obrazów (p.9.6.2), w tym także **binaryzacji różnicowej** (p.9.8) polegającej na porównywaniu dwu obrazów zamiast porównywania obrazu z progim.

### 1.2.7 Rozpoznawanie i klasyfikacja. Cechy dyskryminacyjne

Przyjęcie a priori liczby i przybliżonych definicji klas – jak to zaproponowano dla obrazów tribologicznych w rozdziale 3.2 - odpowiada najczęściej spotykanemu wariantowi **rozpoznawania obrazów** utożsamianemu z **klasyfikacją**. Taka klasyfikacja nazywana jest także rozpoznawaniem wzorców (*pattern recognition*), a czasem z angielska dyskryminacją (*discriminate* – rozróżniać). Analogiczny proces występuje w sieciach neuronowych z tak zwanym „nadzorowanym uczeniem” zwanym też "uczeniem z nauczycielem".

Klasy mogą być wstępnie określone charakterystycznymi cechami (jakościowymi) ale najczęściej są w przybliżeniu definiowane przez **wzorcowe zbiory reprezentantów obrazów z poszczególnych klas** określane też mianem "zbiorów uczących". Te wzorcowe zbiory obrazów służą do doboru **ilościowych cech** obrazów, które pozwolą rozróżniać komputerowo przedstawicieli poszczególnych klas. Inaczej mówiąc z bardzo wielu możliwych cech należy dokonać **selekcji cech dyskryminacyjnych** pozwalających automatycznie klasyfikować obrazy. Można to zrobić albo na podstawie arbitralnej decyzji badacza - opartej na doświadczeniu i intuicji – albo automatycznie testując zdolność dyskryminacyjną poszczególnych cech dla wzorcowych klas obrazów .

Wyznaczanie liczbowych wartości czyli **deskryptorów** czyli **ekstrakcja cech** omawiana jest m.in. w rozdziałach 4, 6 oraz 8.

Inny wariant rozpoznawania zachodzi gdy **klasy nie są z góry znane** lecz powstają na podstawie grupowania podobnych danych, czyli **klasteryzacji** występującej m.in. w uczeniu nienadzorowanym sieci neuronowych (tzw. uczeniu "bez nauczyciela"). W tym przypadku a

**priori muszą być wybrane cechy** względem których oceniane będzie podobieństwo obrazów.

### 1.2.8 Ocena zdolności dyskryminacyjnej cech obrazów

Zdolność rozróżniania obrazów należących do osobnych klas, dzięki istotnie różnym wartościom pewnej cechy – nazywa się zdolnością dyskryminacyjną tej cechy. Istnieje wiele zaawansowanych metod statystycznych zajmujących się selekcją cech dyskryminacyjnych i ich oceną. Metody te zalicza się do dziedziny analizy dyskryminacyjnej.

Dość często stosowanym miernikiem zdolności dyskryminacyjnej cech jest współczynnik Fisher'a  $F_c$ . Jest on proporcjonalny do wariancji  $D$  - między klasowej a odwrotnie proporcjonalny do wariancji  $V$  - cech wewnątrz klas. Inaczej mówiąc – współczynnik Fishera jest tym większy im oceniana przez niego cecha wykazuje większe liczbowe różnice dla obrazów pochodzących z różnych klas a im mniejsze te różnice są dla obrazów należących do tej samej klasy.

$$F_c = \frac{D}{V} \quad (1.6)$$

gdzie:

$$D = \frac{1}{1 - \sum_{i=1}^k P_i^2} \cdot \sum \sum P_i \cdot P_j \cdot (\mu_i - \mu_j)^2 \quad (1.7)$$

$$V = \sum_{i=1}^k P_i \cdot V_i \quad (1.8)$$

gdzie:  $\mu_i$  – średnia wartość cechy dla klasy  $i$   
 $k$  – liczba klas  
 $V_i$  – wariancja cechy w klasie  $i$ ,  
 $P_i$  – prawdopodobieństwo klasy  $i$   
(stosunek liczby obrazów z tej klasy do wszystkich obrazów)

a więc dla dwu równolicznych klas  $k=2$ ,  $P_1=0,5$ ,  $P_2=0,5$  oraz:

$$F_{c12} = \frac{2(\mu_2 - \mu_1)^2}{V_1 + V_2} \quad (1.9)$$

Współczynnik  $F_c$  jest prostą i dość uniwersalną miarą dyskryminacji dla pojedynczej cechy - dlatego głównie z niego korzystano w niniejszej pracy - aczkolwiek może on dawać błędne wyniki w przypadku gdy rozkłady prawdopodobieństwa występowania poszczególnych wartości badanej cechy dla danych zbiorów obrazów znacznie odbiegają od rozkładu normalnego.

Inne miary zdolności dyskryminacyjnej, uwzględniające także zależności między poszczególnymi cechami, zostały zaproponowane i zaimplementowane m.in. w programie Convert [S3]. Są to:

- miara dyskryminacji oznaczona jako POE+ACC - oparta o kryterium łączące dwa warunki: minimalnego prawdopodobieństwa błędu klasyfikacji oraz minimalnych średnich współczynników korelacji między badanymi cechami,
- miara dyskryminacji wielowymiarowej MDM wyznaczana z macierzy rozrzutu międzyklasowego oraz wewnątrzklasowego.

Obie z tych miar mogą zawodzić w przypadku gdy badane cechy są liniowo zależne, co jest znacznym utrudnieniem przy badaniu setek cech, dlatego rzadko z nich korzystano.

### 1.3 Analiza obrazów w tribologii – stan obecny

Badania stosujące komputerową analizę obrazów (KAO) w tribologii są raczej nieliczne. Ze względu na typ badanych obiektów można rozróżnić:

- analizę obrazów powierzchni,
- analizę obrazów cząstek powstających w procesie zużycia (*wear debris*).

Procesy tribologiczne w badaniu których zastosowanie KAO jest możliwe i bywa stosowane to:

- **obróbka** ubytkowa,
- **zużycie** powierzchni par ciernych w trakcie eksploatacji,
- **transfer materiału** przy tarcii ślizgowym.

Przykładem zastosowania analizy obrazów do oceny stanu powierzchni w procesie obróbki ubytkowej może być praca [1]. Zaproponowano w niej metodę oceny gładkości powierzchni w trakcie procesu polerowania, przy pomocy analizy anizotropii obrazów. W wieloetapowym procesie polerowania kierunek obróbki ściernej zmieniany jest w każdym etapie na prostopadły do kierunku w poprzednim etapie, a etap powinien trwać aż do zaniku śladów obróbki z poprzedniego etapu. W analizowanych obrazach - po wstępnym przetwarzaniu i binaryzacji - wyodrębniono obiekty odpowiadające mikrorysom, a następnie wyznaczono kąt ukierunkowania każdego obiektu. Następnie zdefiniowano parametr P określający stan obróbki na danym etapie polerowania:

$$P = (c1 - cn) / c1 \quad \text{gdzie:}$$

c1 = liczba mikrorys o ukierunkowaniu początkowym,

cn = liczba nowych mikrorys o zmienionym ukierunkowaniu

Analiza obrazów jest też wykorzystywana do oceny zużycia narzędzi, a szczególnie noży tokarskich. W tej dziedzinie najczęściej analizowane są obrazy obrabianej powierzchni [7], [8], [46], [47]. Przykładowo A. Zawada-Tomkiewicz i B. Storch [46] testują dwie metody klasyfikacji obrazów obrabianej powierzchni przy użyciu sieci neuronowych. W pierwszej, do sieci wprowadzano 150 punktów profilu obrazu powierzchni, a w drugiej znormalizowany obraz szary tej powierzchni o wymiarach 24 x 120 pikseli. Wadą bezpośredniego wprowadzania obrazu do sieci neuronowej jest rosnąca wymagana liczba wzorców uczących, proporcjonalna do liczby wejść sieci neuronowej. Dla zmniejszenia tej liczby, sieci neuronowe stosuje się raczej łącznie z analizą obrazu, wyznaczającą z każdego obrazu niewielką liczbę cech. Taką kompleksową metodę prezentują m.in. prace [10][16][40].



Kolejne zastosowanie znajduje analiza obrazów w ocenie zużycia powierzchni elementów maszyn w trakcie eksploatacji. W tej dziedzinie większość prac [19]-[25], [32], [40], dotyczy analizy obrazów cząstek zużyciowych. Przykładowo Stachowiak [32] oraz Podsiadlo i Stachowiak [19] opisują zastosowania analizy fraktalnej do charakteryzowania powierzchni trących i cząstek zużyciowych. Inna ich praca [24] dotyczy opisywania anizotropii powierzchni przy zastosowaniu transformacji Hurst'a, natomiast Umeda, Sugimura i Yamamoto [40] opisują próby określania zużycia powierzchni przy pomocy deskryptorów tekstur, wyznaczanych z tzw. macierzy współwystąpień.

Istnieją też publikacje dotyczące analizy obrazów powierzchni z wykorzystaniem innych metod analizy jak: transformacja Fourier'a [45], falki [48], [49] i fraktale [47].

Analiza obrazów może odgrywać także istotną rolę w badaniach mediów zmniejszających tarcie oraz par kinematycznych metal – polimer. Przykładami takich par mogą być polimerowe łożyska ślizgowe współpracujące ze stalowymi wałami czy też polimerowe pierścienie uszczelniające tłoki sprężarek.

Ważną cechą współpracy cierno-ślizgowej metalu z polimerem jest przeniesienie (transfer) cząstek polimeru na powierzchnię metalu [26], [31]. Przeniesione cząstki mogą tworzyć różnego rodzaju skupiska zależnie od składu materiałów, warunków pracy i parametrów otoczenia. Szczególne własności posiadają materiały zawierające PTFE (poli-tetrafluoro-etylen o fabrycznych nazwach "teflon" lub "tarflen"), które w pewnych warunkach mogą tworzyć na powierzchni stali dość równomierną warstwę nazywaną w literaturze filmem transferowym (*transfer film*). Warstwa ta jest czynnikiem korzystnym – zmniejszającym tarcie i zwiększającym odporność łożysk na zużycie. W niniejszej pracy filmem transferowym nazywane są wszelkie ślady pozostawiane na powierzchni stali przez trący o nią polimerowy materiał kompozytowy.

W tej dziedzinie ciekawe obserwacje – aczkolwiek bez zastosowania komputerowej analizy obrazu - poczynili Franklin i de Kraker [4] badając wpływ chropowatości powierzchni stali na zużycie polimeru przy dwu różnych obciążeniach. Zwrócili oni uwagę na zmiany obrazu filmu transferowego towarzyszące zmianom szybkości zużycia. Stwierdzono mianowicie spadek współczynnika tarcia oraz zużycia przy początkowym zwiększaniu chropowatości powierzchni z  $Ra=0,08 \mu\text{m}$  do  $Ra=0,4 \mu\text{m}$  oraz towarzyszącą temu zmianę obrazu filmu transferowego z małych pojedynczych skupisk ( $<20 \mu\text{m}$ ) w równomiernie rozłożone pasma pokrywające całą strefę tarcia. Przy dalszym zwiększaniu chropowatości ( $Ra>0,45$ ), następował znacznie szybszy wzrost zużycia, a na obrazach filmu transferowego powstawały duże plamy ( $>100 \mu\text{m}$ ).

Na zakończenie tego krótkiego przeglądu pragnę podkreślić bardzo ważną możliwość wykorzystywania wielu wartościowych publikacji z zakresu zastosowań analizy obrazów w innych dziedzinach - jak choćby medycyna [11], [12], [13], [14] – gdzie badania są od dawna intensywnie prowadzone, a morfologia obrazów miewa zbliżony charakter.

Podsumowując należy stwierdzić, że wielu badaczy od dawna próbuje sporadycznie wykorzystywać nawet dość wyrafinowane metody analizy obrazów w badaniach tribologicznych. Często brak jednak uzasadnienia wyboru takich czy innych cech analizowanych obrazów i ich związku z obserwowanymi przez badacza charakterystycznymi cechami jakościowymi obrazów tribologicznych. Niniejsza monografia ma między innymi, przynajmniej częściowo wypełnić tę lukę.

## 2. Geneza i cel pracy

Monitorowanie zmian powierzchni powstających w procesach tarcia jest dotychczas najczęściej realizowane przy pomocy najdoskonalszego analizatora jakim jest ludzki zmysł wzroku. Jednak postępująca robotyzacja oraz komputeryzacja badań laboratoryjnych wymusza potrzebę automatyzowania tych operacji.

Badania opisane w monografii można podzielić na dwie części:

- część 1 (rozdziały 4-8) – dotyczy statycznej analizy klas obrazów tribologicznych,
- część 2 (rozdział 9) - opisuje dynamiczną analizę sekwencji obrazów.

Celem pierwszej części pracy był **dobór metod z dziedziny komputerowej analizy obrazów, które pozwolą na automatyczną identyfikację oraz klasyfikację obrazów przedstawiających charakterystyczne stany powierzchni spotykane w procesach tarcia i zużycia**. W tej części pracy badano dwie kategorie metod analizy.

Pierwsza dotyczyła klas obrazów nie wykazujących łatwo definiowalnych różnic wizualnych, lecz zarejestrowanych w określonych stadiach procesu tarcia, zużycia lub obróbki ubytkowej. Dla takich klas obrazów celem było - **przetestowanie możliwości automatycznego doboru cech dyskryminacyjnych** pozwalających rozróżnić przynależność obrazów do poszczególnych klas przypisanych poszczególnym etapom procesów tarcia.

Druga kategoria metod analizy dotyczyła klas obrazów różniących się wyraźnymi jakościowymi cechami wizualnymi, charakterystycznymi dla danego procesu tribologicznego, jak na przykład rysy lub zużycie punktowe (wżery). Cechy te pozwoliły zdefiniować kilka typowych klas obrazów tribologicznych. W tym przypadku celem było **znalezienie najlepszych cech ilościowych, odzwierciedlających charakterystyczne cechy jakościowe obrazów tribologicznych** i pozwalające rozróżniać stany powierzchni trących.

Cele cząstkowe dotyczące statycznej analizy klas obrazów obejmowały:

1. wybór **reprezentantów klas obrazów** przedstawiających typy powierzchni często spotykane w badaniach tribologicznych,
2. analizę przydatności wielu znanych **charakterystyk i cech ilościowych** w badaniach obrazów tribologicznych a także opracowanie koncepcji **nowych cech ilościowych**,
3. **selekcję jakościowych cech obrazów** – istotnych z punktu widzenia tribologii i pozwalających wnioskować o właściwościach badanych powierzchni, oraz opracowanie **metod wyznaczania liczbowych deskryptorów** tych cech,
4. opracowanie algorytmów i programów komputerowych zapewniających efektywne **wyznaczenie** wyselekcjonowanych **cech** obrazów oraz ich prezentację w czytelnej postaci – oddzielnie dla analizy statycznej i dynamicznej obrazów,

5. sprawdzenie **zdolności dyskryminacyjnej** tych deskryptorów dla testowych obrazów,
6. omówienie przykładów rozpoznawania i klasyfikowania obrazów tribologicznych.

Celem drugiej części tej monografii było przedstawienie możliwości zastosowania dynamicznej analizy **sekwencji** obrazów do **badania na bieżąco** przebiegu zmian zachodzących na wybranym wycinku powierzchni poddawanej procesowi tarcia.

W szczególności, celami cząstkowymi tej części pracy były:

7. **automatyzacja** przetwarzania i analizy **sekwencji** obrazów,
8. **ocena i korekta błędów i zakłóceń** powstających przy akwizycji sekwencji obrazów,
9. metody uwydatniania i **detekcji subtelnych zmian** stanu badanej powierzchni,
10. analityczne **określenie przebiegu** lokalnych zmian **transferu materiału PTFE** na powierzchnię stali, podczas tarcia ślizgowego pary kinematycznej trzpień polimerowy-tarcza stalowa.

## 3. Obszar i organizacja badań

### 3.1 Materiał badawczy

Niniejsza monografia obejmuje zarówno badanie **wybranych klas obrazów tribologicznych** jak i badanie **sekwencji** tego rodzaju obrazów.

Materiał badawczy stanowią obrazy które można podzielić na cztery kategorie.

Do kategorii pierwszej należą obrazy **wybrane arbitralnie w roli reprezentantów podstawowych** i istotnie różniących się **klas** – przedstawiających powierzchnie z różnego rodzaju śladami tarcia. Obrazy te, tworzą tak zwane „zbiory uczące”, służące **do testowania zdolności dyskryminacyjnej cech** obliczeniowych i selekcji najlepszych dyskryminatorów. Uwzględniono obrazy uznane za charakterystyczne dla niektórych typów powierzchni spotykanych przy **obróbce użytkowej** oraz powierzchni elementów maszyn wykazujących **zużycie eksploatacyjne** – w szczególności par kinematycznych współpracujących tocznie lub ślizgowo.

Do drugiej kategorii można zaliczyć obrazy stanowiące **rzeczywisty materiał do analizy** i klasyfikowania celem rozstrzygnięcia pewnych zagadnień z dziedziny tribologii. Obrazy te występują w szeregu przykładów. Jednym z nich jest analiza zmian anizotropii i ukierunkowania morfologii powierzchni cylindrów silnika spalinowego wynikających z procesu eksploatacji. Inny, nieco nietypowy przykład, stanowi analiza obrazów zglądów metalograficznych warstw przypowierzchniowych oczek ciągnących używanych przy produkcji drutu i wnioskowanie o stopniu ich zużycia.

Trzecią kategorię stanowią obrazy **sztucznie generowane**, celem badania własności poszczególnych cech obliczeniowych.

Czwarta kategoria to **sekwencje obrazów rejestrowane na bieżąco w trakcie procesu tarcia** i przedstawiające dynamiczny przebieg zmian wybranego fragmenty powierzchni poddawanych tarcia. Analizowane sekwencje nie tylko są materiałem dla ciekawych badań tribologicznych – dotyczących **zmian filmu transferowego** na powierzchniach metali współpracujących z tworzywami sztucznymi – ale także w dziedzinie analizy obrazów stanowią trudny i bogaty dla badań materiał m.in. ze względu na słabą jakość obrazów i występujące zakłócenia, wymagające wyrafinowanych korekt.

## 3.2 Aprioryczna selekcja reprezentantów klas obrazów tribologicznych


Analiza oraz klasyfikacja obrazów tribologicznych wymaga określenia cech, które mogą być podstawą tej klasyfikacji. Rozróznilo:

- cechy jakościowe – związane z przebiegiem i charakterystyką procesu tarcia oraz właściwościami ciał biorących w nim udział,
- cechy ilościowe – jako liczbowe deskrytory obliczane z różnorodnych charakterystyk obrazów cyfrowych.

**Cechy jakościowe** mogą być podstawą apriorycznej selekcji materiału badawczego, natomiast cechy ilościowe mają być podstawą komputerowej klasyfikacji obrazów i wynikającego z niej rozpoznawania stanów powierzchni. Wyznaczenie cech ilościowych, które byłyby najlepszymi **dyskryminatorami** poszczególnych klas obrazów tribologicznych jest jednym z głównych celów pracy.

Na potrzeby oceny przydatności poszczególnych charakterystyk i cech ilościowych dla klasyfikacji obrazów tribologicznych rozróznilo **5 klas** obrazów powierzchni uczestniczących w tarcu (Rys. 3.1), różniących się posiadaniem następujących cech jakościowych:

- TA** - zmian o charakterze punktowym, występujących m.in. przy zużyciu typu "pitting",
- TB** - zmian o znacznym polu powierzchni określanych jako „plamy” lub „wżery”,
- TC** - rys i innych zmian o wyraźnie wyróżnionym ukierunkowaniu, zgodnym z kierunkiem tarcia lub obróbki ubytkowej,
- TD** - układów rys wykazujących co najmniej dwa wyraźne kierunki,
- TE** - rys o różnych kierunkach, także krzywoliniowych.



Rys. 3.1. Reprezentanci wybranych typowych klas obrazów tribologicznych

Rzeczywiste obrazy powierzchni (np.: TB1) mogą wykazywać istnienie równocześnie kilku z wymienionych cech, w różnym natężeniu, na całym obszarze obrazu lub w poszczególnych jego fragmentach i wówczas analiza musi być poprzedzona dodatkowymi

operacjami - pozwalającymi dokonać dekompozycji obrazu - jak filtracja, segmentacja, a także odejmowanie - stosowane w niniejszych badaniach w analizie sekwencji obrazów.

Wyróżnione powyżej cechy jakościowe korespondują też z podziałem obrazów na teksturowe i obiektowe, a mianowicie występujące na obrazach plamy, wżery i t.p. mogą być badane jako obiekty, natomiast obrazy wypełnione motywami rys - będą uznawane za obrazy teksturowe.

Wyróżnienie plam lub rys jako podstawowych obiektów zainteresowań, prowadzi w naturalny sposób do omawianego w dalszych rozdziałach badania rozkładów i parametrów statystycznych takich cech jak:

- niejednorodność przestrzenna obrazu
- pole i kształt obiektów oraz ich sumaryczna powierzchnia jako procent obrazu,
- anizotropia tekstur i kierunki główne.

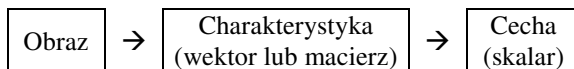
### 3.3 Charakterystyki, cechy i meta-cechy obrazów

Obrazy tribologiczne mogą być charakteryzowane przez omawiane w rozdziale 4 **cechy ilościowe** wyznaczone jako parametry statystyczne różnych **charakterystyk obrazu** wynikających z rozpatrywania obrazu jako **populacji** pojedynczych pikseli lub **grup pikseli**, jak to pokazuje **Tabela 3.1**.

**Tabela 3.1.** Analizowane populacje pikseli obrazów i wyznaczone z nich charakterystyki oraz cechy


Elementy badanej populacji:	Charakterystyki	Cechy dotyczą
Pojedyncze piksele	histogram, histogram skumulowany, krzywa percentylowa	zakresu i rozkładu jasności pikseli
Otoczenia pikseli	macierz gradientu G i in.	kontrastu i ostrości
Segmenty obrazu wynikające z jego podziału na równe części	rozkład przestrzenny cechy	niejednorodność cechy w zbiorze segmentów obrazu
Pary pikseli odległych o dx w kierunku poziomym	macierz sąsiedztwa C	własności tekstury
Pasma o jednakowej jasności	macierz długości pasm R	rozkładu długości pasm
Kolumny macierzy obrazu	wektory statystyk kolumn	różnic między kolumnami
Wydzielone obiekty	rozkłady miar obiektów	parametrów obiektów

Wyznaczanie cech odbywa się więc zazwyczaj według schematu:



Rozpatrywanie obrazu jako populacji pojedynczych pikseli pozwala oceniać jedynie jego cechy chromatyczne, jeśli natomiast istotne są informacje morfologiczne wynikające z uporządkowania pikseli – konieczne jest badanie populacji grup pikseli.

Jak wspomniano, badane obrazy mogą być niejednorodne. Podstawą badania **niejednorodności obrazu względem danej cechy** – omawianego w 8.2 - jest określenie **przestrzennego rozkładu cechy** w zbiorze podobrazów, utworzonych przez podział badanego obrazu na N części:




Komputerowa analiza wymienionych populacji pikseli dokonywana jest sekwencyjnie, według określonego porządku zwanego **kierunkiem skanowania** macierzy obrazu. Kierunek ten może być zgodny z poziomą lub pionową krawędzią obrazu a także może być zmieniany przez obracanie obrazu.

Niektóre z charakterystyk (np. pojedynczych pikseli lub otoczeń pikseli) dają wyniki niezależne od kierunku, dla innych kierunek ma istotne znaczenie. W związku z tym można charakterystyki i cechy obrazów podzielić na:

- **bezkierunkowe** – niezależne od kierunku skanowania
- **kierunkowe** – wrażliwe na kierunek skanowania

W rozdziale 4 będą omawiane najpierw charakterystyki i cechy bezkierunkowe (5.1, 5.2), a następnie kierunkowe, pozwalające badać **anizotropię** obrazu – zdefiniowaną w podrozdziale 8.3, szczególnie istotną dla obrazów tribologicznych gdyż mającą związek z kierunkiem tarcia i jego skutkami dla powierzchni. Miary anizotropii - konstruowane na podstawie różnych cech kierunkowych – zostały omówione w dalszej części tego podrozdziału. Badanie zależności cech od kierunku skanowania czyli wyznaczanie **kierunkowego rozkładu danej cechy** będzie realizowane w zbiorze obrazów otrzymanym przez obracanie obrazu pierwotnego t.zw. „zbiorze obrazów obróconych”:



Niejednorodność przestrzenna oraz anizotropia dotyczą konkretnej cechy obrazu są więc charakterystyczne zarówno dla danego obrazu jak i dla danej jego cechy dlatego można nazwać je **meta-cechami**, podobnie jak „periodyczność” oraz „losowość” [9].

### 3.4 Testowane metody selekcji cech dyskryminacyjnych

Zdefiniowane ogólnie w 1.2.7 cechy dyskryminacyjne pozwalają rozróżnić i identyfikować klasy obrazów odpowiadające różnym stanom powierzchni poddawanych tarcia. Dla każdego obrazu możliwe jest badanie bardzo wielu cech, związanych na przykład z liczbą i rozłożeniem odcieni, kontrastem, ostrością, wielkością i kształtem motywów tekstury. Metody analizy obrazów pozwalają wyznaczać różnorodne liczbowe deskryptory cech, jednak tylko niewiele z nich może okazać się **dobrymi dyskryminatorami** pozwalającymi **rozróżnić** badane klasy obrazów.

Przy poszukiwaniu deskryptorów najczęściej spotykanych klas obrazów tribologicznych testowano zarówno cechy dość powszechnie stosowane do analizy obrazów w różnych dziedzinach jak również cechy, które - według koncepcji autora – powinny w większym stopniu odzwierciedlać specyfikę tych klas obrazów.

Tak więc rozróżnione zostały dwie sytuacje:

- a) brak hipotez dotyczących prawdopodobnych cech dyskryminacyjnych,
- b) istnieją hipotezy dotyczące różnic między klasami, na przykład wynikające z obserwacji wizualnej lub znajomości parametrów procesu tarcia (rodzaj, kierunek,

nacisk, prędkość, współczynnik tarcia, medium pośredniczące i t.d)

W związku z tym można określić **dwa zasadnicze sposoby selekcji** najlepszych dyskryminatorów dla danych reprezentantów klas obrazów:

1. **Selekcja ekstensywna**, którą można też nazwać **ślepa** – odpowiadająca sytuacji (a) - czyli sprawdzenie w sposób automatyczny zdolności dyskryminacyjnej możliwie jak największej liczby cech bez stawiania hipotez wstępnych. Taka selekcję - z wielu cech, m.in. opisanych w rozdziale 4 – realizowano przy wykorzystaniu programów komputerowych MaZda i Convert, a opisano w rozdziale 7. Podobne, choć mniej uniwersalne podejście polega na wykorzystaniu deskryptorów stosowanych przez innych badaczy w analogicznych przypadkach. Tak być może postąpili m.in. A. Umeda i in. [40] stosując dwa parametry Haralick'a (kontrast i drugi moment kątowy) do analizy powierzchni po tarcia .
2. **Podejście analityczne, ukierunkowane** – wymaga zaobserwowania cech jakościowych, którymi różnią się klasy obrazów i które mają związek z badanymi procesami. Konsekwencją tych obserwacji jest sformułowanie i weryfikacja hipotez co do przypuszczalnych najlepszych ilościowych cech dyskryminacyjnych. Zazwyczaj niezbędna jest przy tym znajomość danej dziedziny i genezy powstawania obrazów oraz metod analizy obrazów cyfrowych. Najlepiej więc działać w zespole złożonym z informatyka oraz specjalisty z tej dziedziny, której dotyczą obrazy [37]. Podejście to zaprezentowano m.in. w rozdziale 8, w którym dla wytypowanych jakościowych cech wizualnych – różniących obrazy tribologiczne – konstruowane są liczbowe deskryptory wraz z algorytmami i programami ich wyznaczania.

W niniejszej pracy i cytowanych publikacjach własnych wypróbowano oba podejścia - uzyskując najlepsze rezultaty przy podejściu drugim.

### 3.5 Statyczna i dynamiczna analiza obrazów

W dziedzinie analizy obrazów a także w niniejszej monografii istotne jest rozróżnienie:

- a) analizy **statycznej** – klas obrazów,
- b) analizy **dynamicznej** - sekwencji obrazów.

W analizie **statycznej** - liczba klas obrazów musi być równa liczbie stanów powierzchni jakie mają być rozróżniane. Każda klasa obrazów ma odpowiadać **stanowi powierzchni w określonym momencie czasu** i ma być reprezentowana wieloma obrazami. Wynika z tego kilka możliwych sposobów akwizycji obrazów, a mianowicie:

- 1) akwizycja może być dokonywana jednym aparatem po zatrzymaniu procesu tarcia,
- 2) akwizycja może być dokonywana w jednym momencie przy pomocy wielu aparatów,
- 3) wykonywane jest pojedyncze zdjęcie o dużej rozdzielczości, a następnie dzielone na kilka fragmentów traktowanych jako oddzielne obrazy.

Zbiór obrazów reprezentujący każdą z klas poddawanych analizie powinien stanowić reprezentatywną próbę statystyczną zarówno co do liczebności jak i losowo wybieranej lokalizacji rejestrowanych obrazów śladów tarcia. Jeśli to niemożliwe to zamiastką próby losowej może być wyodrębnienie w pojedynczym obrazie kilku podobrazów, co z kolei jest korzystne dla zapewnienia stałych warunków akwizycji.



W wielu badaniach zatrzymywanie procesu tarcia celem wykonania zdjęć jest niedopuszczalne ze względu na konieczność utrzymywania ciągłości procesu. Przykładowo w badaniach nanoszenia warstewki filmu PTFE na powierzchnię tarczy stalowej zatrzymanie tarcia zmieniałoby przebieg zmian temperatury tarczy niesłychanie istotny dla procesu tarcia i transferu materiału. W tego rodzaju badaniach konieczne było rejestrowanie **sekwencji obrazów** w trakcie procesu (*on-line*), a następnie analizowanie tych sekwencji – nazwane analizą dynamiczną. Efektywna analiza wielu sekwencji składających się z tysięcy obrazów wymagała opracowania programów automatyzujących procesy przetwarzania i analizy. W efekcie uzyskiwano przebiegi zmian wybranych cech w funkcji czasu lub drogi tarcia.

## 3.6 Zastosowane narzędzia

### 3.6.1 Narzędzia do akwizycji obrazów

Niniejsza monografia jest podsumowaniem wielu różnych badań w których stosowano różne narzędzia do akwizycji obrazów, a mianowicie:

- akwizycję sekwencji obrazów realizowano urządzeniami stanowiska opisanego w rozdziale 9.2, złożonego z tribotestera wyposażonego w mikroskop stereoskopowy Olympus SZ-51 oraz kamerę i układy elektroniczne Video-Stroboskopu MOCON-RT sprzężonego z komputerem;
- w analizie statycznej częściowo wykorzystano również obrazy z zarejestrowanych na tym stanowisku sekwencji ale także obrazy uzyskiwane z mikroskopu metalograficznego (wchodzącego w skład mikrotwardościomierza Hanemann'a) sprzężonego z cyfrowym aparatem fotograficznym Canon A630 oraz obrazy zglądów metalograficznych przekrojów cieków ciągadeł uzyskane z mikroskopu elektronowego IXA-50 A firmy JEOL.

### 3.6.2 Zastosowane programy komputerowe

Testowanie dwu różnych metod selekcji cech dyskryminacyjnych – przedstawionych w p.3.4 – wiązało się z zastosowaniem różnych narzędzi komputerowych.

Znakomitą większość badań prezentowanych w monografii, a w szczególności ukierunkowaną selekcję cech dyskryminacyjnych, opartą o cechy jakościowe obrazów tribologicznych, prowadzono przy pomocy własnych programów napisanych w Matlabie z wykorzystaniem funkcji pakietu "Image Analysis Toolbox" [6], [44]. Część tych programów, realizujących w praktyce opracowywane metody przetwarzania i analizy obrazów, udostępniono na stronie internetowej [S1]. Matlab to uniwersalny język i narzędzie programistyczne, rozpowszechnione na uczelniach i z powodzeniem wykorzystywane w wielu dziedzinach.

Dla testowania metod selekcji ekstensywnej cech dyskryminacyjnych wykorzystano natomiast programy MaZda i Convert opracowane w Instytucie Elektroniki Politechniki Łódzkiej w ramach międzynarodowego projektu badawczego "COST-B11 Ilościowa analiza tekstury obrazów tomograficznych rezonansu magnetycznego" [11], [12], [13] i udostępni-

ne bezpłatnie do celów naukowych na stronie internetowej [www.eletel.p.lodz.pl/cost/cost\\_b11.html](http://www.eletel.p.lodz.pl/cost/cost_b11.html).

Program MaZda (nazwa od "macierz zdarzeń") pozwala analizować obrazy teksturowe szare i wyznaczać obszerny zbiór 259 deskryptorów cech (**Tabela 3.2**), na podstawie:

- a) wektora histogramu obrazu ***Hn***: 9 cech,
- b) macierzy gradientu obrazu ***G***: 5 cech
- c) macierzy rozkładu długości pasm ***R***: 5 cech  $\times$  4 kierunki
- d) macierzy przejść tonalnych ***C***: 11 cech  $\times$  4 kierunki  $\times$  5 odległości = 220
- e) modelu autoregresji ***AR***: 5 cech

**Tabela 3.2.** Cechy obrazów wyznaczane w programie MaZda

Cechy histogramu	Cechy macierzy <i>G</i>	Cechy macierzy długości pasm <i>R</i>	Cechy macierzy przejść tonalnych <i>C</i>	C. <i>AR</i>
Średnia	Średnia	Nierównomierność pasm	Drugi moment kątowy	$\theta_1$
Wariancja	Wariancja	Nierównomierność szarości	Kontrast	$\theta_2$
Skośność	Wariancja		Korelacja	$\theta_3$
Kurtoza	Skośność	Uwydatnienie krótkich pasm	Suma kwadratów	$\theta_4$
Percentyl 1%	Kurtoza	Uwydatnienie długich pasm	Odwr. moment różnicowy	$\sigma$
Percentyl 10%			Sumaryczna średnia	
Percentyl 50%	Procent pikseli z niezerowym gradientem	Część obrazu w pasmach	Sumaryczna wariancja	
Percentyl 90%			Sumaryczna entropia	
Percentyl 99%			Entropia	
			Wariancja różnicowa	
			Entropia różnicowa	

Możliwości przetwarzania wstępnego w programie MaZda ograniczają się do:

1. zaznaczenia (ręcznego) maksimum 6-ciu fragmentów obrazu jako **regionów zainteresowania** (ang.: *ROI – region of interest*),
2. **normalizacji** obrazu (poszerzenia zakresu odcieni do maksymalnego dopuszczalnego),
3. **rekwantyzacji** czyli zmiany liczby poziomów szarości. Do dyspozycji są liczby 4-8 bitów na piksel czyli: 16, 32, 64, 128, 256 poziomów szarości.

Program Convert określa zdolność dyskryminacyjną cech wyznaczonych programem MaZda dla dwu lub więcej klas obrazów, dokonując selekcji dziesięciu najlepszych dyskryminatorów tych klas.

Odsyłacze do stron internetowych wielu innych programów do analizy obrazów - w tym także darmowych – autor zamieścił na stronie internetowej Katedry Konstrukcji i Eksploatacji maszyn AGH poświęconej analizie obrazów [S1].

## **4. Wybrane zagadnienia akwizycji i korekty obrazów**

Powodzenie analizy obrazów uzależnione jest w bardzo dużym stopniu od jakości obrazów cyfrowych uzyskiwanych w procesie akwizycji. Wprawdzie wiele wad obrazów może być korygowanych operacjami przetwarzania, jednak niektóre błędy akwizycji powodują nieodwracalną utratę części informacji, dlatego znacznie korzystniejsze jest uzyskiwanie od razu dobrej jakości obrazów niż poddawanie ich następnie wielu przekształceniom. Należy się bowiem liczyć także z tym, że przekształcenia, korygując jedne cechy obrazów mogą zmieniać inne - być może istotne - cechy. Niemniej, prawie zawsze obrazy uzyskiwane w procesie akwizycji wymagają zastosowania różnorodnych operacji filtrowania zakłóceń i korygowania błędów.

Ważniejsze zagadnienia akwizycji obrazów scharakteryzowano ogólnie w p.1.2.4, natomiast w tym rozdziale sformułowano praktyczne zalecenia dotyczące akwizycji obrazów śladów tarcia powstających na powierzchniach obiektów metalowych, oraz opisano zastosowane przez autora metody korekty wad i zakłóceń istotnych w analizie obrazów triobologicznych.

Szersze zapoznanie się z szeregiem trudnych zagadnień procesu akwizycji obrazów autor zawdzięcza m.in. pracy nad korygowaniem wielu różnorodnych wad obrazów uzyskiwanych na stanowisku badawczym OSA-2, opisanym w rozdziale 9. W rozdziale tym (p.9.5) omówiono inne korekty, mające zastosowanie jedynie dla sekwencji obrazów, w tym przypadku przedstawiających zmiany w konkretnym obszarze powierzchni poddawanej tarcia.

### **4.1 Zagadnienia akwizycji**

Badane obrazy tribologiczne były obrazami śladów tarcia na powierzchniach metalowych, takie jak ubytki materiału, zmiany topografii powierzchni (rysy, wżery), odbarwienia wynikające ze zjawisk termicznych i reakcji chemicznych a także ślady materiału nanoszonego w trakcie tarcia, w tym także materiału półprzezroczystego.

Zależnie od charakteru zmian stosowano jeden z dwu typów obserwacji stosowanych w mikroskopii optycznej: obserwację w polu jasnym (OPJ) lub obserwację w polu ciemnym (OPC).

### 4.1.1 Zalecenia odnośnie oświetlenia i kąta obserwacji

Na jasność i kontrast poszczególnych fragmentów rejestrowanych obrazów mają wpływ takie czynniki jak:

- parametry odbiornika obrazu (złożonego z układu optycznego, przetwornika obrazu na sygnały elektryczne oraz układów elektronicznych rejestrujących obrazy),
- charakterystyki i parametry źródeł światła (liczba, rozmieszczenie, jasność, powierzchnia, charakterystyka widmowa barw składowych, kierunkowość, ...),
- usytuowanie badanej powierzchni względem źródeł światła i odbiornika obrazu.
- właściwości optyczne i chromatyczne badanej powierzchni oraz obserwowanych na niej zmian (połysk powierzchni, barwa zmian)

Można z dużym prawdopodobieństwem przyjąć, że współczesne profesjonalne odbiorniki obrazu (cyfrowe aparaty i kamery) są w stanie zapewnić wystarczającą jakość obrazów dla większości zastosowań. Dotyczy to również układów optycznych mikroskopów.

Znacznie większym problemem jest jednak zapewnienie odpowiedniego oświetlenia. Oświetlacze stosowane w mikroskopach mają bowiem na ogół zapewniać maksymalny kontrast bez względu na ewentualne występowanie odbłasków i rozszczepień barw, podczas gdy dla celów analizy komputerowej istotne jest uwzględnienie następujących uwag:

- pole obrazu powinno być oświetlone równomiernie (co warto sprawdzić na obrazie kontrolnym przedstawiającym np. powierzchnię białego kartonu),
- nadmierny kontrast lub jasność powodują utratę części informacji, podczas gdy obraz nieco za ciemny lub niekontrastowy może być łatwo skorygowany komputerowo.
- oś główna układu optycznego powinna być ustawiona prostopadle do badanej powierzchni,
- dla uniknięcia odbłasków (np. dla powierzchni metalowych) wskazane jest oświetlenie rozproszone lub ukierunkowane tak aby odbłask nie był widoczny.

Przy ocenie cech oświetlenia pomocne jest badanie takich charakterystyk jak profile, histogramy oraz krzywe percentylowe.

### 4.1.2 Dobór powiększenia i kadru obrazu

Jedną z pierwszych i zasadniczych spraw jest właściwy wybór powiększenia i kadru obrazu. Jeśli obraz zawiera interesujące nas „obiekty” jak „plamy” czy „wzery” to w sposób oczywisty dążymy aby na obrazie – jeśli to możliwe - znalazło się przynajmniej kilka czy kilkanaście takich obiektów w całości, tak aby badane obrazy były możliwie reprezentatywną próbą statystyczną badanego obszaru powierzchni. Dobór kadru obrazu najczęściej musi być dokonywany przez badacza aczkolwiek możliwa jest wstępna selekcja komputerowa na przykład oparta o analizę wariancji poszczególnych obrazów.

Obiekty widoczne tylko częściowo i stykające się z brzegami obrazu mogą być komputerowo usunięte (np. przy pomocy funkcji *ClBorder* [P1]), aczkolwiek nie jest to sensowne dla obrazów na których występują rysy lub długie pasma albo na których - w trakcie monitorowania - następuje znaczny rozrost powierzchni plam.

Zbyt duże powiększenie może być sygnalizowane wzrostem stopnia niejednorodności wybranej cechy. Zagadnienia dotyczące oceny niejednorodności omówiono rozdziale 7.2 oraz publikacji [W6].

### 4.1.3 Podział obrazu na podobrazy

Podział obrazu na podobrazy może być potrzebny w szczególności gdy:

- a) potrzebne jest zwiększenie liczby analizowanych obrazów – na przykład gdy jest ich zbyt mało w badanej próbie statystycznej,
- b) potrzebna jest ocena jednorodności obrazu względem wyznaczonej cechy.

Do dzielenia obrazu na podobrazy o jednakowych rozmiarach opracowano funkcję  $B = wycinki(A, Nox, Noy)$  – załączoną w [S1] jako program [P16], której parametrami są:

$A$  – obraz o rozmiarach  $[Lw, Lk]$  dzielony na części,

$Nox$  – liczba podziałów w poziomie,

$Noy$  – liczba podziałów w pionie

W wyniku uzyskuje się macierz trójwymiarową  $B(1:Lw/Noy, 1:Lk/Nox, i)$ , gdzie  $i$  jest numerem podobrazu.

## 4.2 Rodzaje błędów

Cechy rejestrowanych obrazów oraz ich zmiany, zarówno na przestrzeni obrazu jak w funkcji czasu, powodowane są zarówno zmianami badanych obiektów jak i błędami oraz zakłóceniami procesu akwizycji. Jednym z pierwszych zadań skomputeryzowanego systemu analizy obrazów jest więc kompensowanie tych błędów.

Błędy i zakłócenia można podzielić na kilka kategorii, a mianowicie:

- a) zakłócenia treści obrazu (artefakty i szumy),
- b) błędy jasności pikseli na przestrzeni obrazu – wywołane na przykład zbyt słabym albo nierównomiernym oświetleniem lub odbłaskami powierzchni,
- c) błędy geometrii obrazu, takie jak przemieszczenia czy obroty kadru oraz dystorsja (beczkowa lub poduszkowa),
- d) błędy ostrości (rozmycie, nierównomierna ostrość).

Dodatkowo, poszczególne typy błędów mogą być stałe lub zmienne w czasie.

Na ogół nie jest jednak uzasadnione automatyczne wykrywanie wszelkich usterek, gdyż wpływ wielu z nich może być albo pomijalnie mały albo jest tylko jednym z mniej istotnych składników wpływających na losowy charakter obrazów. Istotność poszczególnych błędów zależy zarówno od parametrów konkretnego systemu akwizycji obrazów jak i od rodzaju badanych cech obrazów.

Przed przyjęciem decyzji dotyczących korekt niezbędnych w danym systemie, konieczne jest więc przeprowadzenie obserwacji i oceny wzrokowej obrazów, a także wyznaczenie i przeanalizowanie podstawowych charakterystyk i parametrów obrazów jak: zakres jasności, ostrość, równomierność oświetlenia, poziom szumów i in.

## 4.3 Ocena i filtracja szumu

### 4.3.1 Badanie poziomu szumu

Jednym z typów zakłóceń występujących w obrazach jest szum generowany w przetwornikach obrazowych - najczęściej typu **CCD** (*Charge Coupled Device*) – oraz układach elektronicznych kamer cyfrowych. Szum ten jest widoczny szczególnie przy oglądaniu ciemniejszych sekwencji obrazów.


W celu ilościowej oceny poziomu szumów przeprowadzono analizę kilku krótkich sekwencji obrazów wycinka nieruchomej tarczy tribotestera [W16] [W18]. Każda sekwencja składała się z pięciu fotografii tego samego miejsca tarczy. Poszczególne sekwencje rejestrowano przy różnych wartościach kąta oświetlenia. Oświetlenie realizowano poprzez jeden z dwu okularów mikroskopu, podczas gdy przez drugi okular obraz przekazywany był do kamery. Nazwy serii i odpowiadających im kątów oświetlenia podaje **Tabela 4.1**.

**Tabela 4.1.** Serie obrazów w których badano wpływ kąta oświetlenia oraz szum


Nazwa serii:	85GR	90C	90GR-a	boczne	90GR	89GR	90gr-b
Kąt oświetlenia [°]	85	90	90	60	90	89	90

Dla wyodrębnienia szumu w danej serii  $X_i$  najpierw wyznaczono obraz uśredniony  $XS$  czyli macierz będącą średnią arytmetyczną macierzy obrazów tej serii, a następnie odejmowano go od poszczególnych obrazów:

$$SZUM_i = (X_i - XS) \quad (4.1)$$




Rys. 4.1. Przykładowy obraz z serii "BOCZNE" i obraz binarny jego szumu



Rys. 4.2. Wizualizacja profili szumu obrazu z serii BOCZNE

Przykładowy obraz serii "Boczne" i binarny obraz szumu uzyskany przez odjęcie od niego obrazu uśrednionego pokazuje Rys. 4.1, a profile obrazu szumu pokazuje Rys. 4.2.

Obrazy szumu uzyskano programem [P2], który wyznacza także wartości parametrów statystycznych obrazu i szumu.



Rys. 4.3. Histogram szumu dla obrazu "BOCZNE\_001.BMP"

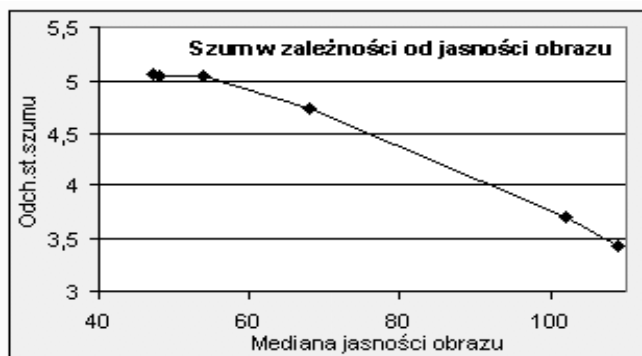
Wyznaczano także histogramy szumu. Jeden z nich pokazano na Rys. 4.3. Kształt histogramów jest zbliżony do krzywej Gauss'a co pozwala przyjąć założenie o zgodności rozkładu amplitud szumu z rozkładem normalnym.

### 4.3.2 Poziom szumu a jasność obrazu. Filtracja szumu

Dla ostatniego obrazu każdej z badanych sekwencji wyodrębniono szum przez odjęcie obrazu uśrednionego według wzoru 8.1. Dokonano oceny zależności poziomu szumu od mediany jasności obrazu a także od zastosowanego czasu ekspozycji. Wyniki pokazuje **Tabela 4.2** oraz wykres na Rys. 4.4.

**Tabela 4.2.** Zależność odchylenia standardowego szumu od jasności obrazów

Obraz z serii:	85GR	90C	90GR-a	boczne	90GR	89GR	90gr-b
Mediana jasności	47	48	54	54	68	102	109
Szum (bez filtracji)	5,06	5,05	5,05	4,95	4,74	3,69	3,42
Nr migawki	11	15	15	10	17	12	11
Czas ekspoz. [ $\mu$ s]	20	4	4	40	1,1	14,3	20

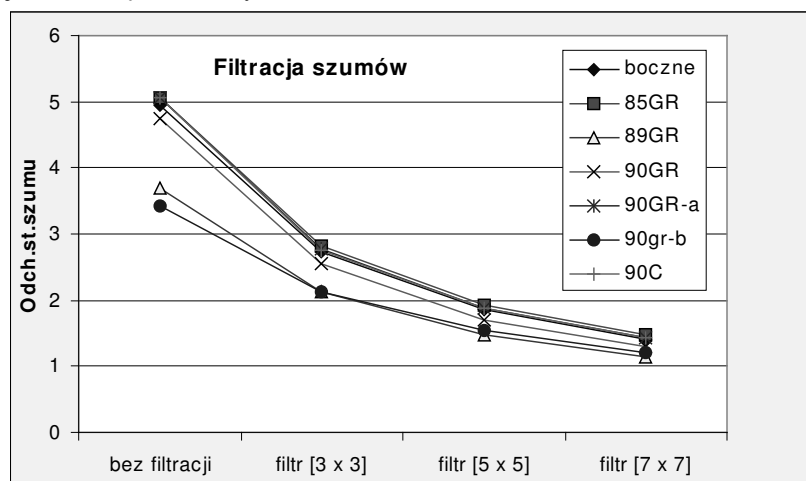


Rys. 4.4. Zależność poziomu szumu od jasności obrazu

Jak widać szum maleje przy wzroście mediany jasności obrazów, a więc i jasności oświetlenia zastosowanego przy akwizycji, natomiast praktycznie nie zależy od czasu ekspozycji.

Następnie zbadano wpływ zmian rozmiarów okna medianizacji stosowanego przy filtracji medianowej szumu na zmniejszanie poziomu szumu. Filtracja medianowa polega bowiem na zastępowaniu wartości każdego analizowanego piksela obrazu medianą wartości zbioru pikseli stanowiących jego otoczenie, nazywane tu właśnie oknem medianizacji. Uwzględniono trzy rozmiary okna medianizacji (w pikselach): 3x3, 5x5, 7x7.

Wyniki (Rys. 4.5) pokazują, że nasilenie filtracji medianowej przez powiększanie okna medianizacji przynosi coraz słabszy efekt, a równocześnie wydłuża czas przetwarzania i powoduje coraz większe rozmycie obrazu.



Rys. 4.5. Wpływ filtracji na odchylenie standardowe szumu

Dla sprawdzenia jaki jest względny spadek odchylenia standardowego szumu przy poszczególnych wariantach filtracji medianowej, podzielono wyniki pokazane na Rys. 4.5 przez wartość odchylenia standardowego szumu bez filtracji. Jak pokazuje **Tabela 4.3** już zastosowanie najsłabszej filtracji medianowej (stosującej okno medianizacji 3x3) zmniejsza szum do 50% - 60% wartości początkowej, a zarazem praktycznie nie wprowadza istotnego rozmycia ostrości obrazu. W związku z czym przyjęto taką filtrację jako zalecaną.

**Tabela 4.3.** Względny spadek szumu przy filtracji

Obraz z serii:	boczne	85GR	89GR	90GR	90GR-a	90gr-b	90C
Filtracja:							
bez filtracji	1	1	1	1	1	1	1
filtr [3 x 3]	0,6	0,6	0,6	0,5	0,5	0,6	0,5
filtr [5 x 5]	0,4	0,4	0,4	0,4	0,4	0,5	0,4
filtr [7 x 7]	0,3	0,3	0,3	0,3	0,3	0,4	0,3

Inną z przetestowanych szybkich (choć mniej dokładnych) jakościowych metod oceny poziomu szumów była obserwacja profili obrazów.



## 4.4 Przestrzenna nierównomierność jasności obrazu i jej korekta

Przestrzenna nierównomierność jasności obszaru obrazu - wynikająca z błędów akwizycji, a nie z istoty oglądanych szczegółów badanej powierzchni - może wynikać:

- z nierównomierności oświetlenia badanej powierzchni,
- z odbłasków – występujących szczególnie na powierzchniach metalowych.

Korygowanie tego rodzaju błędów akwizycji – zwane korektą cienia - jest w przypadku obrazów obiektowych jednym z typowych zagadnień opisanych m.in. w pracy [6]. Korekta opiera się na założeniu, że rzeczywiste tło ma równomierną jasność, a nierównomierność jasności tego tła na obrazie wynika ze wspomnianych błędów oświetlenia. Skoro tak to jasność pikseli obrazu ma być skorygowana w taki sposób aby piksele należące do tła miały jednakową (lub w przybliżeniu jednakową) jasność. Korekta polega na wyznaczeniu macierzy reprezentującej powierzchnię nierównomiernie oświetlonego tła - zwanej też „powierzchnią cienia” - i odjęcie jej od macierzy obrazu, a następnie dodanie zamiast niej wartości reprezentującej stałą poziom szarości. Wyznaczanie „powierzchni cienia” bazuje na parametrach wyznaczających jasność tła podobrazów na jakie zostaje podzielony obraz. Powinny być przy tym pominięte obiekty wyróżniające się z tła różnym zakresem jasności. W przypadku niewielkich obiektów, których sumaryczne pole w każdym z podobrazów nie przekracza 50% powierzchni - do określania jasności tła każdego podobrazu może być zastosowana mediana.

Jednym ze sposobów badania przestrzennej nierównomierności jasności obrazu może być obserwacja profili obrazów cyfrowych. Przykładowe rezultaty uzyskane opracowanym w Matlabie programem *Profi\_Cien1* [P5] pokazuje Rys. 4.6

Program ten wyświetla rezultaty w czterech oknach. W pierwszym z nich pojawi się podgląd wybranego do analizy obrazu. Przy pomocy suwaków można ustalić lokalizację profilu poziomego i pionowego. Profile te ukazują się w oknach 2 i 3, przy czym są one aktualizowane automatycznie przy każdej zmianie położenia suwaków. Obraz dzielony jest na 25 podobrazów dla których wyznaczane są mediany, a na ich podstawie aproksymowana jest powierzchnia tła, której wykres warstwiczny można oglądać w oknie czwartym. Profile powierzchni tła wyświetlane są łącznie z profilami obrazu i wyznaczane są dla tych samych lokalizacji. Program wyznacza także i wyświetla pod wykresem warstwicowym wartości minimum i maksimum jasności powierzchni tła.

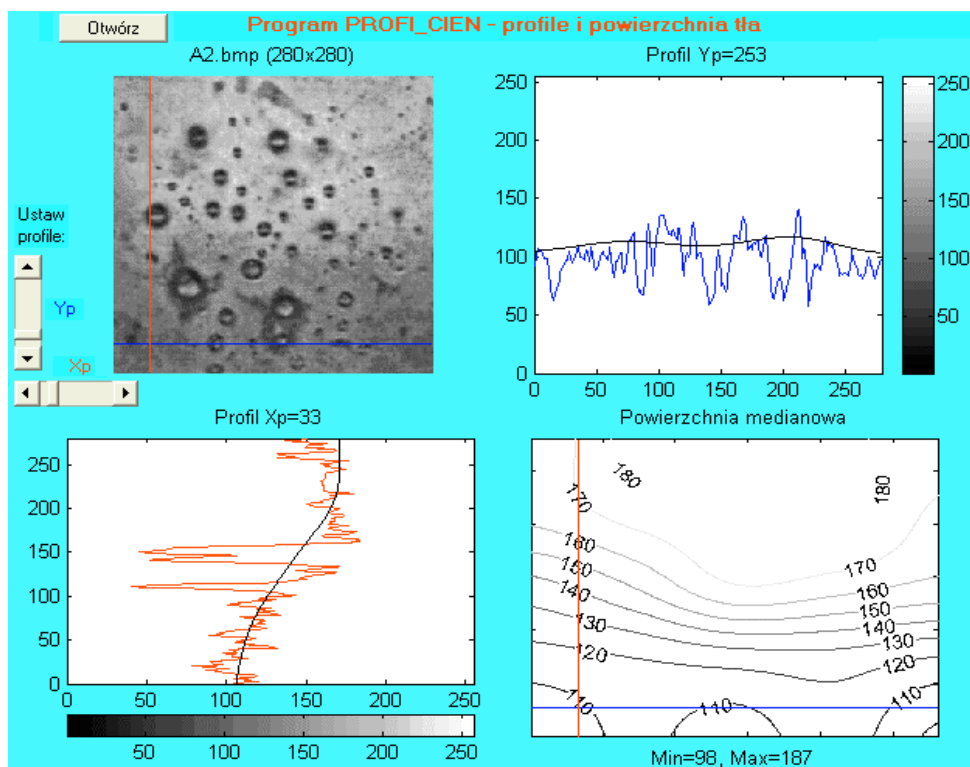
W skład programu *PROFI\_CIEN1* wchodzi także procedury: *Profi\_otw* i *Profi2* zapisane w osobnych plikach.

Zastosowanie mediany dla obrazu pokazanego na Rys. 4.6 jest uzasadnione ponieważ można przyjąć, że w poszczególnych podobrazach tło zajmuje więcej niż 50% obszaru.

Przy określaniu liczby podobrazów istotne są dwa przeciwstawne czynniki. Z jednej strony – większa liczba podobrazów to dokładniejsze wyznaczenie nierównomierności oświetlenia, z drugiej – rozmiary każdego podobrazu powinny być na tyle duże aby, przy zastosowaniu median, sumaryczne pole obiektów zajmowało w nim mniej niż 50%. Dla obrazów pokazanych na rysunkach przyjęto podział na 25 podobrazów.

Dla obrazów tribologicznych teksturowych zagadnienie było nieco trudniejsze. Obrazy te z definicji nie posiadają wyróżnionego tła ani obiektów. Występuje więc problem co w tym przypadku umownie uznać za tło. Po analizie potwierdzonej eksperymentami stwier-

dzono przydatność percentyli jako statystyk użytecznych do wyznaczania umownej powierzchni tła.



Rys. 4.6. Ekran programu PROFIL\_CIENI

Przyjęto, że jeśli tło zajmuje więcej niż połowę powierzchni nie tylko obrazu ale i poszczególnych podobrazów to:

- jako umowne tło ciemne może być przyjęty percentyl obrazu nie wyższy od mediany,
- jako umowne tło jasne może być przyjęty percentyl nie niższy od mediany.

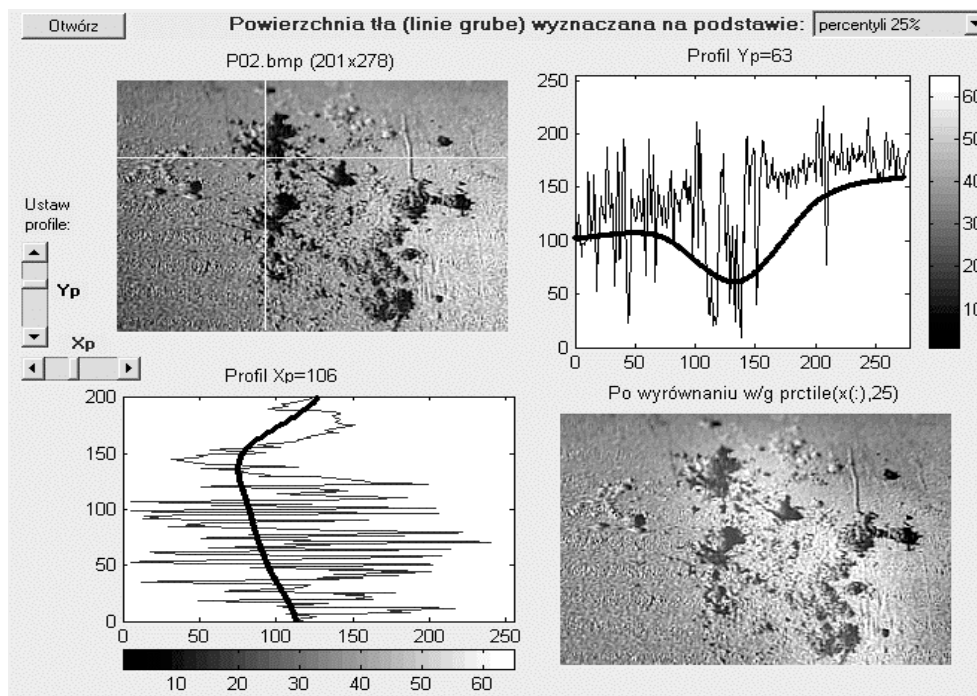
Mediana nie jest więc bezpiecznym parametrem dla określania „powierzchni cienia” szczególnie w przypadkach gdy obszar zmian traktowanych jako „obiekty” mógłby zbliżyć się lub przekraczać granicę 50% powierzchni obrazu. Wygodnymi parametrami statystycznymi mogą być natomiast percentyle jasności pikseli obrazu, a mianowicie:

- pierwszy kwartył lub percentyl 10%-30% dla umownego tła ciemnego, oraz
- trzeci kwartył lub percentyl z zakresu 70%-90% dla określania umownego tła jasnego.

Przy takich ustaleniach korygowanie nierównomierności realizowane jest następująco:

- obraz dzielony jest na podobrazy czyli jednakowych rozmiarów prostokąty (a wcześniej przycinany tak aby był wielokrotnością tych prostokątów)
- dla każdego podobrazu wyznaczany jest przyjęty, odpowiedni dla jasnego lub ciemnego tła, percentyl;

- w oparciu o zbiór wartości percentyla wyznaczonego dla każdego podobrazu wyznaczana jest aproksymacyjnie „powierzchnia cienia”;
- „powierzchnia cienia” odejmowana jest od obrazu, a zamiast niej dodawana macierz stałych wartości odpowiadających średniej szarości.



Rys. 4.7. Niewłaściwe zastosowanie pierwszego kwartyla do wyrównywania jasnego tła

Zastosowanie percentyli umożliwia kolejny program *Profi\_Cien2* [P6] pozwalający wybierać różne percentyle jako bazę dla wyznaczania „powierzchni cienia”. Rys. 4.7 pokazuje zły efekt wybrania percentyla 25% dla wyrównywania tła jasnego, natomiast Rys. 4.8 pokazuje prawidłowe wyrównanie jasności tła jasnego przy użyciu trzeciego kwartyla.

Wysokie percentyle są odpowiedniejsze szczególnie gdy badane ciemne obiekty mają znaczne rozmiary i w badanych podobrazie jest znacznie mniej pikseli jasnego tła niż ciemnego obiektu.

Ostatecznie, powyższe spostrzeżenia uwzględniono opracowując funkcję do wyrównywania jasności tła, o nazwie *Wyr\_tlo(obraz, tlo, N)* [P12]. Parametrami tej funkcji są:

*obraz* - macierz obrazu źródłowego;

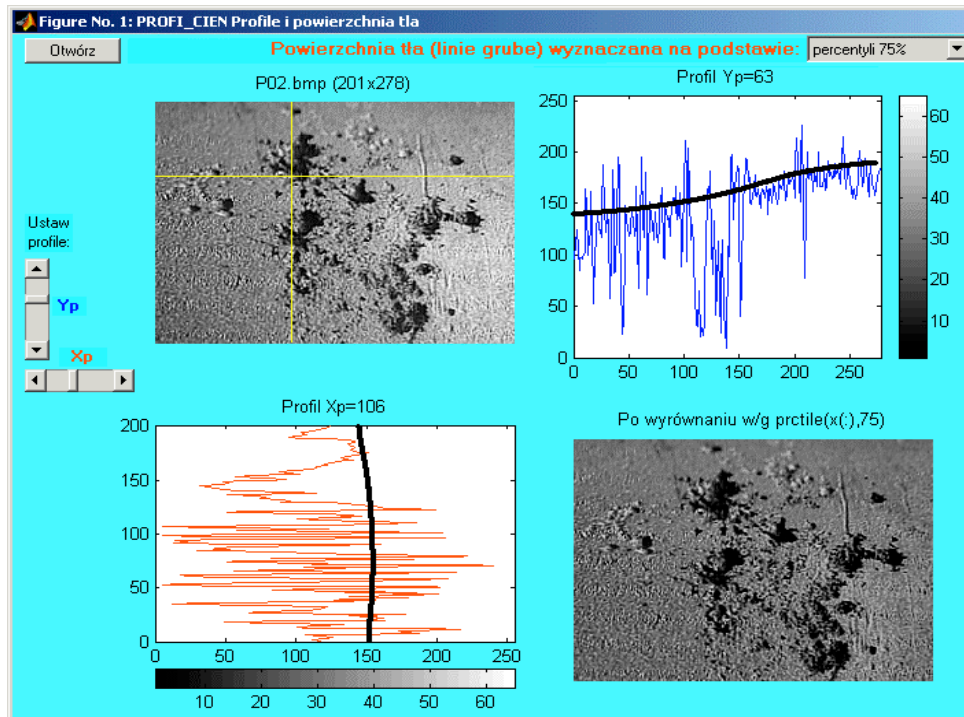
*tlo* - parametr równy zero dla tła ciemnego, 1 dla jasnego oraz 0.5 jeśli  $tlo = \text{mediana}$

*N* - liczba podobrazów w pionie oraz poziomie - razem  $N*N$  podobrazów

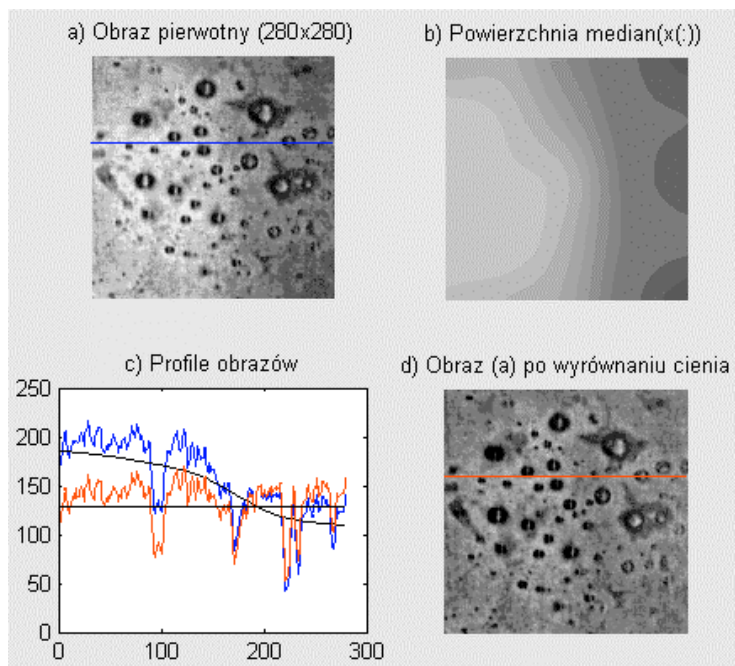
Dla korygowania nierównomierności jasności tła i prezentowania rezultatów tej operacji (jak na Rys. 4.9) opracowano kolejny program o nazwie *Wyr\_T2* [P13].

W programie tym można dobrać różne parametry statystyczne, na których ma opierać się aproksymacja powierzchni tła.

Poruszane w tym podrozdziale zagadnienia zostały omówione także w publikacji [W13].



Rys. 4.8. Prawidłowe wyrównanie jasnego tła z zastosowaniem trzeciego kwartyla



Rys. 4.9. Wyrównywanie jasności tła

## 4.5 Korekta ukierunkowania obrazów

W przypadku wyraźnego ukierunkowania tekstury obrazów – wynikającego dla obrazów tribologicznych z kierunku tarcia – pozioma krawędź kadru obrazu powinna być równoległa do kierunku dominującego  $Dir1$ . Obrazy spełniające ten warunek nazwano w 8.3.1 horyzontalnymi. W procesie akwizycji obrazów należy więc dążyć do uzyskiwania obrazów horyzontalnych, najlepiej przez takie ustawienie kamery aby kierunek tarcia był równoległy do krawędzi obrazu.

Dla obrazów nie spełniających tego warunku dokonywano:


- detekcji anizotropii i pomiaru dominującego kierunku elementów obrazu, oraz
- korygowano ukierunkowanie przez obracanie i przycinanie obrazu.

Do pomiaru kąta ukierunkowania obrazu mogą być użyte różne cechy kierunkowe opisane w 8.3. Między innymi dla potrzeb opisywanych tu badań opracowano funkcję o nazwie *det\_kier* [P14]. Jej koncepcja – analogiczna do opisywanych w 8.3 - polega na binaryzacji obrazu, a następnie cyklicznym obracaniu obrazu i wyznaczaniu (w znormalizowanym co do wymiarów wycinku obrazu) dla każdego kąta obrotu, współczynnika ortotropii względnej  $Nyx = Ny/Nx$  gdzie:

$Ny$  - liczba pionowych pasm czarnych (spadków jasności w kolumnach obrazu),

$Nx$  - liczba poziomych pasm czarnych (spadków jasności w wierszach obrazu).

Kąt dla którego wystąpi maksimum  $Nyx$  zostaje uznany za kierunek dominujący  $Dir1$ . Dla zmniejszenia ryzyka błędów operacja może być wykonywana przy pomocy programu *det\_kier6* [P15] (wykorzystującego funkcję [P16]) oddzielnie dla sześciu części badanego obrazu i wówczas z 6-ciu wyników wybierany jest kąt dla którego  $Nyx$  osiągnął maksimum.



Rys. 4.10. Korekta ukierunkowania obrazu dla niewielkich kątów

a) obraz oryginalny

b) obraz obrócony ( $-5^\circ$ )


c) obraz wynikowy

Dla korygowania ukierunkowania obrazu w zakresie niewielkich kątów  $Dir1$ , opracowano w Matlabie funkcję *obrot(Obraz,alfa)* [P17], która obraca *Obraz* o zadany kat *alfa* podany w stopniach (wyznaczony programem *det\_kier*), a także obcina marginesy wynikające z powstania przy obracaniu czarnych trójkątów na obrzeżach, widocznych na rysunku (Rys. 4.10) gdzie pokazano obraz oryginalny (a), a następnie obraz po obrocie z zaznaczonymi obszarami do obcięcia (b) i ostatecznie obraz po przycięciu (c).


Metoda polegająca na obcinaniu marginesów jest skuteczna dla niewielkich kątów  $Dir1$ , gdyż dla obrazu o długości  $DX$  i szerokości  $DY$  (gdzie  $DX > DY$ ) musi być spełniony warunek:  $DX > 2*(DY/2)*tg(Dir1)$ .

Dla większych wartości kątów w zakresie  $0-90^\circ$  zastosowano inny sposób - przedstawiony na Rys. 4.11 – polegający na pobieraniu prostokątnego wycinka wyznaczonego przez punkty przecięcia przekątnej obrazu wynikowego z dłuższym bokiem obróconego

go obrazu pierwotnego i realizowany funkcją OBROT2 [P18]. Przykład zastosowania pokazuje Rys. 4.12.



Rys. 4.11. Korekta ukierunkowania dla kątów 0-90°



Rys. 4.12. Przykłady korekty ukierunkowania

## 5. Charakterystyki tekstur szarych oraz ich rola w analizie obrazów tribologicznych

Rozdział ten przedstawia wybrane ilościowe charakterystyki i cechy obrazów szarych, traktowanych jako tekstury, czyli bez określania tła oraz wyodrębnianych z niego obiektów. Uwzględniono zarówno charakterystyki znane z literatury jak i oparte na pomysłach autora (pp.: 5.1.2, 5.3, 5.4.2). Przedstawiono graficzne postacie tych charakterystyk, wyznaczonych dla testowych obrazów tribologicznych, oraz skomentowano przydatność poszczególnych charakterystyk i cech dla tego typu obrazów.

Jako pierwsze omówiono charakterystyki obrazów traktowanych jako populacje pojedynczych pikseli, a kolejne podrozdziały dotyczą obrazów traktowanych jako populacje różnego rodzaju grup pikseli wymienionych w 3.3.

### 5.1 Charakterystyki jasności pikseli obrazu

Rozpatrywanie obrazu jako populacji pojedynczych pikseli pozwala wyznaczać takie charakterystyki jak histogram obrazu, histogram skumulowany oraz krzywa percentylowa. Charakterystyki te nie zawierają żadnych informacji o strukturze przestrzennej obrazu, natomiast pozwalają oceniać **zakres i rozkład jasności** populacji pikseli, co może być podstawą do korekty jasności i kontrastu oraz doboru progu binaryzacji.

Zmiany histogramów wyznaczanych dla sekwencji obrazów, mogą dostarczyć informacji o pojawianiu się lub zanikaniu obiektów różniących się jasnością od tła lub o fluktuacjach jasności tła wynikających ze zmian oświetlenia lub zmian odbłasku powierzchni.

#### 5.1.1 Histogramy

**Histogram** obrazu szarego określa ilościowy udział w obrazie pikseli o poszczególnych odcieniach. Matematycznie to wektor  $\mathbf{H}$  o  $Lh$  składowych odpowiadających poszczególnym jednakowym przedziałom o długości  $dG$  na jakie podzielono nominalny zakres poziomów szarości. Każda składowa  $H_j$  podaje liczbę pikseli obrazu posiadających odcień zawarty w odpowiadającym tej składowej przedziale:

$$\mathbf{H}=[H_j], j=1, 2, \dots, Lh, \quad H_j = \sum_{w=1}^{Lw} \sum_{k=1}^{Lk} L((j-1) \cdot dG < x_{w,k} \leq j \cdot dG) \quad (5.1)$$

gdzie:  $dG = GR/Lh$ ; – długość przedziału,  
 $L(\text{wyrażenie})$  – funkcja wyznaczająca wartość logiczną wyrażenia  
(1=prawda, 0=falsz).

Histogram **znormalizowany** to wektor  $Hn$ , którego składowe  $Hn_j$  otrzymuje się przez podzielenie składowych  $H_j$  przez liczbę wszystkich pikseli obrazu  $Lx$ .

$$Hn_j = H_j / Lx \quad (5.2)$$

Nadaje to histogramowi postać rozkładu prawdopodobieństwa występowania w obrazie poszczególnych odcieni.

Parametry statystyczne histogramu obrazu można traktować jako deskryptory cech obrazu. Wyznaczano m.in. percentyle – omówione w podpunkcie następnym - oraz:


$$\text{średnią histogramu obrazu: } \mu_H = \sum_{j=1}^{Lh} j \cdot dG \cdot Hn_j \quad (5.3)$$

$$\text{wariancję histogramu obrazu: } (\sigma_H)^2 = \sum_{j=1}^{Lh} (j \cdot dG - \mu_H)^2 \cdot Hn_j \quad (5.4)$$

$$\text{skośność histogramu obrazu: } \mu_H^3 = \sigma^{-3} \cdot \sum_{j=1}^{Lh} (j \cdot dG - \mu_H)^3 \cdot Hn_j \quad (5.5)$$

$$\text{kurtozę histogramu obrazu: } \mu_H^4 = \sigma^{-4} \cdot \sum_{j=1}^{Lh} (j \cdot dG - \mu_H)^4 \cdot Hn_j - 3 \quad (5.6)$$

Wygenerowane programem HIST3 [P19] histogramy obrazów reprezentujących grupy A-E przedstawiono na Rys. 5.1 i Rys. 5.3.




Rys. 5.1. Histogramy znormalizowane obrazów TA-TB

Warto zauważyć (Rys. 5.1), że na histogramach obrazów powierzchni błyszczących, posiadających rysy wynikające z obróbki lub zużycia ciernego – występuje zazwyczaj wiele maksimów w postaci „szpilek”.




Występowanie dwu maksimów o bardziej łagodnym kształcie może świadczyć o występowaniu ciemniejszych obiektów na jaśniejszym tle (jak na Rys. 5.1) lub odwrotnie – jasnych obiektów na ciemnym tle. Podobnie, większa liczba maksimów może świadczyć o występowaniu większej liczby obiektów, różniących się odcieniami szarości.

Powyższe uwagi nie zawsze są słuszne o czym świadczy histogram obrazu TA2, wykazujący na Rys. 5.1 dwa maksima. Okazuje się, że jedno z nich jest wywołane przez odbłask tła i znika po wyrównaniu jasności tła (Rys. 5.2).



Rys. 5.2. Histogram obrazu TA2: a) po wyrównaniu jasności tła, b) po usunięciu ciemnych plam



Rys. 5.3. Histogramy znormalizowane obrazów TC-TE

Jak widać na Rys. 5.2, ciemnych plam jest za mało aby powstało drugie maksimum, natomiast powodują one asymetrię histogramu, wykrywalną przy pomocy cechy  $\mu_H^3$  (w Matlabie funkcja: *skewness*). Tak więc przy jednorodnym tle obrazu cecha **skośność**

**histogramu  $\mu_H^3$**  może służyć do detekcji przyrostu liczby zmian powierzchni, stanowiących być może symptomy zużycia albo zwiększenia pola powierzchni tzw. filmu smarowego.

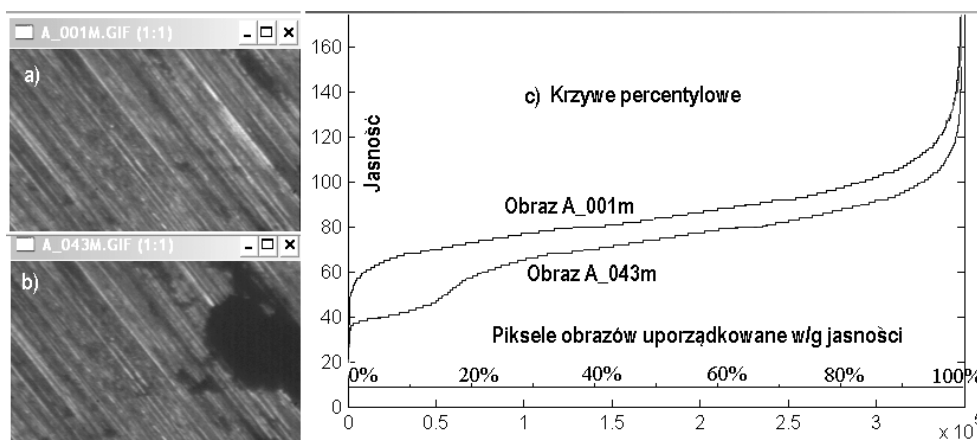
**Histogram skumulowany  $Hns$**  czyli dystrybuanta rozkładu odcieni szarości ma znacznie bardziej stabilny przebieg. Formalnie można określić go wzorami:

$$Hns=[Hns_j; j=1, 2, ..Lh]; \quad Hns_j = \sum_{i=1}^j Hn_i \quad (5.7)$$

Odejmowanie skumulowanych histogramów obrazów autor zastosował w metodzie nazwanej MRHS, użytej następnie do wykrywania zmian jakie zachodzą w sekwencjach obrazów śladów tarcia. Metodę tą opisano w podrozdziale 8.4.2

### 5.1.2 Krzywe percentylowe

Histogramy skumulowane przedstawione w innym układzie współrzędnych nazywane są w tej pracy krzywymi percentylowymi. Można je wyznaczać znacznie prościej niż histogramy. Jeśli ze zbioru wszystkich pikseli obrazu  $X$  utworzymy wektor  $VX$  i uporządkujemy te piksele według rosnącej jasności:  $SVX = sort(VX)$ , to **n-ty percentyl** obrazu  $X$ , oznaczany jako  $prctile(X, n)$  jest jasnością piksela znajdującego się na takiej pozycji, że jej odległość od początku wektora, wyrażona w procentach długości całego wektora, wynosi  $n\%$ .



Rys. 5.4. Zmiany w sekwencji obrazów odwzorowane krzywymi percentylowymi

Wektor  $SVX$  - nazwany w profilometrii krzywą Abbota-Firestone'a (AF) [2], [W15] można w Matlabie otrzymać przy pomocy wyrażenia:

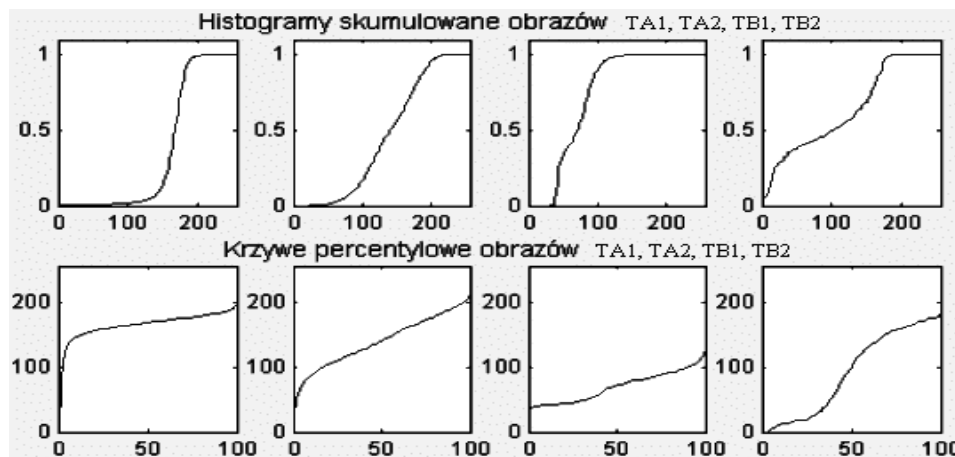
$$SVX=sort(X(:)) \quad (5.8)$$

Przedstawmy na wykresie zależność jasności od położenia piksela w tym uporządkowanym ciągu. Jeśli oś poziomą wyskalujemy w procentach całkowitej liczby pikseli obrazu, to otrzymamy **krzywą percentylową**, której rzędne są percentylami obrazu.

Krzywe percentylowe dobrze pokazują zmiany zachodzące w sekwencjach obrazów. Przykładowo, zmiany zachodzące w omawianej dalej sekwencji obrazów „A”, polegające na rozrastaniu się ciemnej plamy (Rys. 5.4a,b), pokazują wykresy krzywych percentylowych (Rys. 5.4c) odpowiadających kolejnym obrazom w tej sekwencji. Jak widać pojawienie się na obrazie A\_043 ciemnej plamy naniesionego w trakcie tarcia materiału kompozytowego skutkuje powstaniem załamania na wykresie krzywej percentylowej tego obrazu.

Równocześnie pionowy odstęp między częściami krzywych mającymi równoległy charakter pokazuje różnice jasności tła tych obrazów. Kompensacja tych różnic jasności omówiona jest w p.9.5.2 oraz p.9.8.2.

Histogramy znormalizowane skumulowane oraz krzywe percentylowe obrazów testowych TA1-TB2 wygenerowane programem HS\_PERC [P20] pokazuje Rys. 5.5.



Rys. 5.5. Histogramy skumulowane i krzywe percentylowe przykładowych obrazów

## 5.2 Charakterystyki wyznaczone z otoczeń pikseli

### 5.2.1 Macierz gradientu

Macierz gradientu obrazu charakteryzuje różnice odcieni par pikseli sąsiadujących z badanym pikselem lub położonych od niego w odległości  $d$  (zazwyczaj:  $d=1$  lub  $d=2$ ).

$$G_{w,k} = \sqrt{((x_{w+d,k} - x_{w-d,k})^2 + (x_{w,k+d} - x_{w,k-d})^2)} \quad (5.9)$$

Dla macierzy gradientu – podobnie jak w przypadku innych charakterystyk - można obliczać różnego rodzaju parametry statystyczne. W nawiasach podano nazwy tych parametrów stosowane w programie MaZda:

- średni gradient (GrMean):

$$\mu_G = \frac{1}{m} \sum_{w,k} G_{w,k} \quad (5.10)$$

- wariancję gradientu (GrVariance):

$$(\sigma_G)^2 = \frac{1}{m} \sum_{w,k} (G_{w,k} - \mu_G)^2 \quad (5.11)$$

- skośność gradientu (GrSkewness):

$$\mu_G^3 = \frac{1}{m \cdot (\sigma_G)^3} \cdot \sum_{w,k} (G_{w,k} - \mu_G)^3 \quad (5.12)$$


- kurtozę gradientu (GrKurtosis):

$$\mu_G^4 = \frac{1}{m \cdot (\sigma_G)^4} \cdot \sum_{w,k} (G_{w,k} - \mu_G)^4 - 3 \quad (5.13)$$

przy czym:  $m$  = liczba elementów macierzy  $G$

Gradient obrazu może być podstawą do oceny lokalnego kontrastu a więc także ostrości obrazu.

Wizualizację macierzy gradientu dla obrazu TB2 pokazuje Rys. 5.6. Jak widać nastąpiło wyodrębnienie konturów co sugeruje, że macierz  $G$  może służyć do szacowania długości obwodu obiektów. Funkcję Mgrad(A,d) – wyznaczającą macierz  $G$  - załączono w [S1] jako program [P40].



Rys. 5.6. Obraz TB2 i jego macierz gradientu

Ze względu na niezależność gradientu od ukierunkowania elementów obrazu, cechy wyznaczane z macierzy  $G$  były niezbyt przydatne do analizy obrazów tribologicznych.

### 5.2.2 Cechy wyznaczane z modelu autoregresji

Model autoregresji zakłada, że jasność badanego piksela jest uzależniona od jasności pikseli z jego otoczenia. Dla otoczenia obejmującego tylko najbliższe piksele wyraża to zależność:

$$x_{w,k} = \theta_1 \cdot x_{w,k-1} + \theta_2 \cdot x_{w-1,k-1} + \theta_3 \cdot x_{w-1,k} + \theta_4 \cdot x_{w-1,k+1} + Er \quad (5.14)$$


gdzie  $Er$  to odchyłka będąca zmienną losową o średniej zero i odchyleniu standardowym.

Parametry  $\theta_1, \theta_2, \theta_3, \theta_4$  - traktowane jako cechy obrazu - są wyznaczone tak aby zminimalizować odchyłkę  $Er$  [51], [S3].

### 5.3 Charakterystyki kolumn i wierszy macierzy obrazu

W rozdziale 4.3 przedstawiono profile obrazu, którymi są pojedyncze kolumny lub wiersze macierzy obrazu. Są one wygodne do wrywkowych obserwacji. Aby móc wnioskować o całym obrazie wyznaczano statystyki dotyczące wszystkich kolumn lub wierszy.

#### 5.3.1 Średnie jasności kolumn i wierszy obrazu



Rys. 5.7. Średnie jasności kolumn i wierszy dla obrazu rys pionowych C2

Najprostszą charakterystyką statystyczną wszystkich kolumn macierzy obrazu jest wektor **średnich jasności kolumn** SJK (Rys. 5.7).:

$$SJK_k = \frac{1}{LW} \sum_{w=1}^{Lw} x_{w,k} \quad (5.15)$$

Analogicznie „średnie jasności wierszy” (SJW) można wyznaczyć w ten sam sposób, po transponowaniu macierzy obrazu:

$$SJW_w = \frac{1}{Lk} \sum_{k=1}^{Lk} x_{k,w} \quad (5.16)$$

W Matlabie wystarczy do tego celu zastosować funkcję standardową „mean”:

$$SJK = \text{mean}(X); \quad SJW = \text{mean}(X');$$

Charakterystyki te mogą być użyteczne w przypadku wykrywania obecności podłużnych elementów o kierunku równoległym do krawędzi obrazu. Zachodzi bowiem wówczas znaczna rozbieżność między rozrzutem wartości wektora SJK i rozrzutem wartości wektora SJW. Na podstawie tych obserwacji, w rozdziale 8.3.6. zdefiniowano cechę UDSW, która okazała się najlepsza do wykrywania anizotropii i ukierunkowania elementów tekstury obrazu.

### 5.3.2 Udział czerni w kolumnach i wierszach

Sumowanie kolumn i wierszy wykorzystano także w analizie sekwencji obrazów tribologicznych czarno-białych o czym obszerniej napisano w publikacji [W13] oraz rozdziale 9.10. Dla negatywu każdego  $i$ -tego binarnego obrazu  $B_i$  w danej sekwencji wyznaczano mianowicie wektor  $UCK_k$  procentowego „udziału czerni w kolumnach” obrazu oraz analogiczny wektor  $UCW_w$  procentowego „udziału czerni w wierszach”, co dla całej sekwencji skutkowało powstaniem następujących dwu macierzy:

$$UCK_{k,i} = \frac{100}{Lw} \cdot \sum_w^{Lw} \tilde{B}_{w,k,i} \quad (5.17)$$

$$UCW_{w,i} = \frac{100}{Lk} \cdot \sum_k^{Lk} \tilde{B}_{w,k,i} \quad (5.18)$$

Operacje sumowania kolumn i wierszy zwane też „wyznaczaniem rzutów obrazu na osie X oraz Y” wchodzą także w skład tzw. transformacji Radona, wykorzystywanej wraz z transformacją odwrotną w tomografii komputerowej. W analizie obrazów tribologicznych szarych wykorzystano te operacje przy wyznaczaniu lokalnych progów binaryzacji [W14] pozwalających uwydatnić subtelne zmiany na obrazach powierzchni.

## 5.4 Charakterystyki zbiorów par pikseli

### 5.4.1 Macierz przejść tonalnych C

**Macierz przejść tonalnych C** zwana też macierzą sąsiedztwa [18], macierzą zdarzeń [W1] [11], [51] lub macierzą współwystąpień ( $COM = Co-Occurrence Matrix$ ,  $GLCM - Gray Level Co-Occurrence Matrix$ ) [5], [10] albo histogramem drugiego rzędu wyraża relacje między odcieniami określonych par pikseli. Macierz  $C$  jest macierzą kwadratową o rozmiarach  $Lg \cdot Lg$  wyznaczaną dla określonego kierunku  $\psi$  oraz odległości między parami pikseli. Element  $C_{a,b}$  powstaje przez zliczenie wszystkich takich par pikseli, które posiadają odpowiednio odcienie  $a$  i  $b$ . Kierunkami  $\psi$  dla których może być wyznaczana macierz  $C$  są  $0^\circ$  i  $90^\circ$ , a rzadziej  $45^\circ$  i  $135^\circ$  co odpowiada wektorom skanowania macierzy [dw,dk]: [0,d], [d,0], [d,d], [-d,d] - dla numeracji macierzowej wierszy i kolumn (pocz. w lewym górnym rogu) lub po przejściu na współrzędne x,y (początek w lewym dolnym rogu obrazu): [d,0], [d,d], [0,d], [d,-d] (tak oznaczane są kierunki w programie MaZda, w którym macierze  $C$  można wyznaczać dla odległości:  $d = 1, 2, \dots, 5$ ).

Jeśli kierunek i odległość zdefiniujemy przy pomocy wektora przyrostu [dw, dk] to element znormalizowanej macierzy  $C(dw,dk)$  odpowiadający odcieniom  $a$  i  $b$  można określić wzorami:

$$C(dw, dk)_{a,b} = \frac{1}{m} \sum_w \sum_k pt(a, b, x_{w,k}, x_{w+dw, k+dk}) \quad (5.19)$$

gdzie:  $a = 0, 1, 2, \dots, Lg$ ;  $b = 0, 1, 2, \dots, Lg$

$$pt(a, b, x_{w,k}, x_{w+dw,k+dk}) = \begin{cases} 1 & \text{gdy: } (x_{w,k} = a) \wedge (x_{w+dw,k+dk} = b) \\ 0 & \text{w przeciwnym przypadku} \end{cases}$$

Macierz ta może być normalizowana przez podzielenie wartości jej elementów przez liczbę wszystkich badanych par pikseli  $m$ . Nadaje to macierzy C znaczenie rozkładu prawdopodobieństwa.


a)		b)		c)																																																								
	<table border="1"> <tr><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr> <tr><td>1</td><td>1</td><td>0</td><td>1</td><td>1</td><td>0</td></tr> <tr><td>0</td><td>2</td><td>2</td><td>0</td><td>2</td><td>2</td></tr> <tr><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr> </table>	0	0	0	0	0	0	1	1	0	1	1	0	0	2	2	0	2	2	0	0	0	0	0	0		<table border="1"> <tr><td></td><td>0</td><td>1</td><td>2</td></tr> <tr><td>0</td><td>10</td><td>1</td><td>2</td></tr> <tr><td>1</td><td>2</td><td>2</td><td>0</td></tr> <tr><td>2</td><td>1</td><td>0</td><td>2</td></tr> </table>		0	1	2	0	10	1	2	1	2	2	0	2	1	0	2	<table border="1"> <tr><td></td><td>0</td><td>1</td><td>2</td></tr> <tr><td>0</td><td>0.5</td><td>0.05</td><td>0.1</td></tr> <tr><td>1</td><td>0.1</td><td>0.1</td><td>0</td></tr> <tr><td>2</td><td>0.05</td><td>0</td><td>0.1</td></tr> </table>		0	1	2	0	0.5	0.05	0.1	1	0.1	0.1	0	2	0.05	0	0.1
0	0	0	0	0	0																																																							
1	1	0	1	1	0																																																							
0	2	2	0	2	2																																																							
0	0	0	0	0	0																																																							
	0	1	2																																																									
0	10	1	2																																																									
1	2	2	0																																																									
2	1	0	2																																																									
	0	1	2																																																									
0	0.5	0.05	0.1																																																									
1	0.1	0.1	0																																																									
2	0.05	0	0.1																																																									
d)		e)		f)																																																								
	<table border="1"> <tr><td></td><td>0</td><td>1</td><td>2</td></tr> <tr><td>0</td><td>10</td><td>2</td><td>1</td></tr> <tr><td>1</td><td>1</td><td>2</td><td>0</td></tr> <tr><td>2</td><td>2</td><td>0</td><td>2</td></tr> </table>		0	1	2	0	10	2	1	1	1	2	0	2	2	0	2		<table border="1"> <tr><td></td><td>0</td><td>1</td><td>2</td></tr> <tr><td>0</td><td>20</td><td>3</td><td>3</td></tr> <tr><td>1</td><td>3</td><td>4</td><td>0</td></tr> <tr><td>2</td><td>3</td><td>0</td><td>4</td></tr> </table>		0	1	2	0	20	3	3	1	3	4	0	2	3	0	4	<table border="1"> <tr><td></td><td>0</td><td>1</td><td>2</td></tr> <tr><td>0</td><td>0.5</td><td>0.075</td><td>0.075</td></tr> <tr><td>1</td><td>0.075</td><td>0.1</td><td>0</td></tr> <tr><td>2</td><td>0.075</td><td>0</td><td>0.1</td></tr> </table>		0	1	2	0	0.5	0.075	0.075	1	0.075	0.1	0	2	0.075	0	0.1								
	0	1	2																																																									
0	10	2	1																																																									
1	1	2	0																																																									
2	2	0	2																																																									
	0	1	2																																																									
0	20	3	3																																																									
1	3	4	0																																																									
2	3	0	4																																																									
	0	1	2																																																									
0	0.5	0.075	0.075																																																									
1	0.075	0.1	0																																																									
2	0.075	0	0.1																																																									

Rys. 5.8. Przykłady macierzy zdarzeń: a) wartości pikseli obrazu; b) macierz dla  $dw=0, dk=1$ ; c) po normalizacji; d) transponowana macierz (b); e) suma macierzy (b) i (d); f) po normalizacji

Ideę budowania macierzy zdarzeń pokazuje rysunek (Rys. 5.8) na przykładzie bardzo prostego obrazu (Rys. 5.8a) o trzech odcieniach szarości 0, 1, 2 i wymiarach  $6 \times 4$ .

Analizowane są sąsiadujące piksele ( $d=1$ ) w kierunku poziomym ( $0^\circ$ ). Macierz (Rys. 5.8b) pokazuje liczbę przejść z odcieni 0,1,2 opisanych z lewej strony macierzy do odcieni opisanych nad macierzą. Jak widać jest to macierz asymetryczna.


Aby jednakowo traktować kierunki skanowania i kierunki do nich przeciwne, dokonuje się symetryzacji macierzy (Rys. 5.8e) przez zsumowanie macierzy pierwotnej (Rys. 5.8b) i jej transpozycji (Rys. 5.8d). Macierze (b) i (e) znormalizowane przez podzielenie wartości wszystkich elementów przez liczbę wszystkich skanowanych par widać na rysunkach Rys. 5.8c i Rys. 5.8f.



Rys. 5.9. Wizualizacje macierzy przejść tonalnych dla obrazów typu A i B

Macierze  $C$  dla przykładowych obrazów tribologicznych, pokazane na Rys. 5.9 oraz Rys. 5.10, wyznaczono programem *test\_GLCM* [P22] wykorzystującym funkcję *coocmx* [P25]. Jak widać największe elementy tych macierzy skupiają się w pobliżu przekątnej głównej, a wykres wartości tej przekątnej ma kształt podobny do histogramu.

Z macierzy  $C$  wyznaczane są deskryptory zwane parametrami lub deskryptorami Haralick'a zaproponowane przez niego po raz pierwszy w pracy [5].



Rys. 5.10. Wizualizacje macierzy przejść tonalnych dla obrazów typu C, D, E

Deskryptory Haralick'a wyznaczane z symetrycznej znormalizowanej macierzy przejść tonalnych przedstawiono poniżej:

Energia (Drugi moment kątowy) - *Angular second moment*:

$$AngScMom = \sum_{a,b} (C_{a,b})^2 \quad (5.20)$$

Kontrast - *Contrast (Inertia)*:

$$Contrast = \sum_{a,b} ((a-b)^2 \cdot C_{a,b}) \quad (5.21)$$

Korelacja - *Correlation*

$$Correlat = -\sum_{a,b} \frac{(a-\mu) \cdot (b-\mu)}{\sigma^2} \cdot C_{a,b} \quad (5.22)$$

Wariancja (Suma kwadratów) - *Sum of squares; Variance*

$$SumOfSqs = \sum_{a,b} (a-\mu)^2 \cdot C_{a,b} \quad (5.23)$$

Odwrotny moment różnicowy; Jednorodność - *Inverse difference moment; Homogeneity*:

$$InvDfMom = \sum_{a,b} \frac{C_{a,b}}{1+(a-b)^2} \quad (5.24)$$



Sumaryczna srednia - *Sum average*:

$$SumAverg = \sum_{k=2}^{2 \cdot Lg} k \cdot P_{x+y}(k) \quad (5.25)$$

Sumaryczna wariancja - *Sum variance*:

$$SumVar = \sum_{k=2}^{2 \cdot Lg} (k - SumAverg)^2 \cdot P_{x+y}(k) \quad (5.26)$$

Sumaryczna entropia - *Sum entropy*:

$$SumEntrp = - \sum_{k=2}^{2 \cdot Lg} P_{x+y}(k) \cdot \log(P_{x+y}(k)) \quad (5.27)$$

Entropia - *Entropy*:

$$Entropy = - \sum_{a,b} C_{a,b} \cdot \log(C_{a,b}) \quad (5.28)$$

Wariancja różnicowa - *Difference variance*:

$$DifVarnc = \sum_{k=0}^{Lg-1} k^2 \cdot P_{x-y}(k) \quad (5.29)$$

Entropia różnicowa - *Difference entropy*:

$$DifEntrp = - \sum_{k=0}^{Lg-1} P_{x-y}(k) \cdot \log(P_{x-y}(k)) \quad (5.30)$$

gdzie (dla macierzy symetrycznej):

$$\mu = \mu_x = \mu_y = \sum_a a \sum_b C_{a,b} = \sum_b b \sum_a C_{a,b} = \text{średnia z sumy wierszy lub kolumn},$$

$$\sigma = \sigma_x = \sigma_y = \sum_a (a - \mu)^2 \cdot \sum_b C_{a,b} = \text{odchyl. standardowe sum wierszy lub kolumn},$$

$$P_{x+y}(k) = \sum_{a,b | a+b=k} C_{a,b} ; \quad P_{x-y}(k) = \sum_{a,b | a-b=k} C_{a,b}$$

Przydatność opisanych wyżej deskryptorów tekstur dla obrazów tribologicznych testowano w badaniach opisanych w [W1] [W2] [W3] i zrelacjonowanych w rozdziale 2.

Kolejną próbę zastosowania tych deskryptorów – tym razem do oceny stopnia zużycia oczek ciągadeł i związanej z tym oceny skuteczności działania kilku badanych mediów chłodząco-smarujących – opisano w publikacji [W7] .

Dla analizy obrazów tribologicznych zdefiniowano w rozdziale 4.3.4 nieco inne deskryptory, także oparte o badanie relacji między parami pikseli, a znacznie bardziej przydatne w ocenie anizotropii i wykrywaniu ukierunkowania motywów obrazów.

## 5.4.2 Deskrytory zmienności wierszy i kolumn

W ramach poszukiwania cech przydatnych w ocenie anizotropii i ukierunkowania obrazów zdefiniowano deskrytory zmienności kolumn i wierszy przedstawione poniżej.

**Zmienność kolumn  $ZK$  i zmienność wierszy  $ZW$**  oparte są – tak jak i macierz  $C$  – o analizę par sąsiadujących pikseli ale przyjęto znacznie prostsze kryterium niż poszczególne odcienie szarości, a mianowicie dla  $ZK$  w każdej kolumnie, a dla  $ZW$  w każdym wierszu, **zliczane są wszystkie pary pikseli odległych o  $d$  i różnych co do wartości:**

$$ZW = \frac{d}{LW \cdot (Lk - d)} \sum_{w=1}^{Lw} \sum_{k=1+d}^{Lk} L(x_{w,k-d} \neq x_{w,k}); \text{ dla } k = 1 + d, 1 + 2d, \dots \quad (5.31)$$

$$ZK = \frac{d}{Lk \cdot (Lw - d)} \sum_{k=1}^{Lk} \sum_{w=1+d}^{Lw} L(x_{w-d,k} \neq x_{w,k}); \text{ dla } w = 1 + d, 1 + 2d, \dots \quad (5.32)$$

Zastosowana we wzorach funkcja  $L$  (wyrażenie logiczne) zwraca 1 dla wyrażeń o wartości „prawda” oraz zero dla wyrażeń o wartości „fałsz”

Dla wykrywania istotniejszych zmian jasności - jakie powinny występować między średnim odcieniem tła i średnim odcieniem badanych zmian powierzchni – zdefiniowano deskrytory **progowej zmienności wierszy i kolumn:**

$$PZW = \frac{d}{Lw \cdot (Lk - d)} \sum_{w=1}^{Lw} \sum_{k=1+d}^{Lk} L(|x_{w,k-d} - x_{w,k}| > p); \text{ dla } k = 1 + d, 1 + 2d, \dots \quad (5.33)$$

$$PKZ = \frac{d}{Lk \cdot (Lw - d)} \sum_{k=1}^{Lk} \sum_{w=1+d}^{Lw} L(|x_{w-d,k} - x_{w,k}| > p); \text{ dla } w = 1 + d, 1 + 2d, \dots \quad (5.34)$$

gdzie  $p$  to wartość progu.

Program opracowany dla wyznaczania tych deskryptorów udostępniono w [S1] jako funkcję [P26]. Deskrytory zmienności wierszy i kolumn wykorzystano przy badaniu anizotropii obrazów – opisanym w 4.3.4.

Podobne deskrytory zdefiniowane (w trakcie wcześniejszych badań) dla obrazów tekstur binarnych przedstawiono natomiast w rozdziale 2.2 dotyczącym analizy tego typu obrazów.

## 5.5 Charakterystyki pasm - macierz $R$ i jej cechy

Kolejnymi analizowanymi elementami macierzy obrazów cyfrowych mogą być pasma pikseli o jednakowym odcieniu. Charakterystyką zawierającą informacje o częstotliwości występowania pasm o poszczególnych odcieniach oraz długościach (mierzonych liczbą pikseli) jest macierz długości pasm, określana w literaturze akronimem **RLM** (*Run Length Matrix*), a w niniejszej pracy literą **R**.

Macierz **R** jest wyznaczana dla określonego kierunku skanowania  $\psi$ , a każdy jej element  $R_{g,j}$  zawiera informację ile razy wystąpiło pasmo pikseli o odcieniu  $g$  oraz długości  $j$ . Osobne macierze mogą być wyznaczane są dla kierunków  $\psi$ :  $0^\circ$  i  $90^\circ$ , a także  $45^\circ$  i  $135^\circ$ .

Macierz  $R$  ma wymiary  $(Lg \cdot Lr)$  gdzie  $Lr$  to maksymalna długość pasma (w pikselach), a  $Lg$  – liczba odcieni szarości.

W niniejszych badaniach macierz  $R$  wyznaczano dla kąta skanowania  $\psi = 0^\circ$  przy pomocy funkcji [P27], natomiast funkcja [P28] służyła do wyznaczania cech z macierzy  $R$ .

Badano następujące cechy [51][W1] obrazów wyznaczane z macierzy  $R$ :

- 1) Odwrotny moment uwydatnienia krótkich pasm - *Short Run Emphasis inverse moment*:

$$SRE = \left( \sum_{g=1}^{Lg} \sum_{j=1}^{Lr} \frac{R_{g,j}}{j^2} \right) / c \quad (5.35)$$

- 2) Moment uwydatnienia długich pasm - *Long Run Emphasis moment*:

$$LngREmph = \left( \sum_{g=1}^{Lg} \sum_{j=1}^{Lr} j^2 \cdot R_{g,j} \right) / c \quad (5.36)$$

- 3) Niejednorodność pasm - *Run Length Nonuniformity*:

$$RLNonUni = \left( \sum_{j=1}^{Lr} \left( \sum_{g=1}^{Lg} R_{g,j} \right)^2 \right) / c \quad (5.37)$$

- 4) Część obrazu w pasmach - *Fraction of image in runs*:

$$FIR = c / \left( \sum_{g=1}^{Lg} \sum_{j=1}^{Lr} j \cdot R_{g,j} \right) \quad (5.38)$$

- 5) Niejednorodność szarości - *Gray Level Nonuniformity*:

$$GLevNonU = \left( \sum_{g=1}^{Lg} \left( \sum_{j=1}^{Lr} R_{g,j} \right)^2 \right) / c \quad (5.39)$$

przy czym współczynnik  $c$  jest zdefiniowany następująco:  $c = \sum_{g=1}^{Lg} \sum_{j=1}^{Lr} R_{g,j}$

Zastosowanie pierwszych czterech z tych cech do oceny anizotropii obrazu opisano w publikacji [W19] oraz w rozdziale 4.3.4.

Rozkłady długości pasm tekstur binarnych omówiono w p.2.2.3.

## 6. Binarystacja oraz analiza obrazów binarnych

W ramach redukcji informacji prawie zawsze stosowana jest **binarystacja** - opisana w podrozdziale 1.2.6. - przetwarzająca obrazy na czarno-białe. Binarystacja jest jedną z metod segmentacji obrazów mających na celu wyodrębnienie badanych **obektów** z tła obrazu, jednak może być stosowana również dla obrazów **teksturowych**, pomagając rozróżnić klasy obrazów lub wykrywać zachodzące zmiany. Przykładowo w podrozdziale 4.3.6 cecha UDSW użyta do detekcji anizotropii i określania kierunków głównych tekstury, została użyta także do obrazów binarnych, a analiza sekwencji obrazów opisana w rozdziale 5.6 i następnych także bazuje na wyznaczaniu cech obrazów binarnych.

Jak wykazały badania wstępne – binarystacja pozwala często uwydatnić zmiany zachodzące na obrazach powierzchni i wyznaczać cechy o lepszej zdolności dyskryminacyjnej niż dla obrazów szarych.

Poniżej omówiono wybrane problemy binarystacji oraz opisano niektóre metody analizy obrazów binarnych – m.in. wykorzystane następnie w analizie sekwencji obrazów zmian warstewki tzw. „filmu transferowego” zachodzących na powierzchni stali współpracującej ślizgowo z kompozytami polimerowymi zawierającymi PTFE.

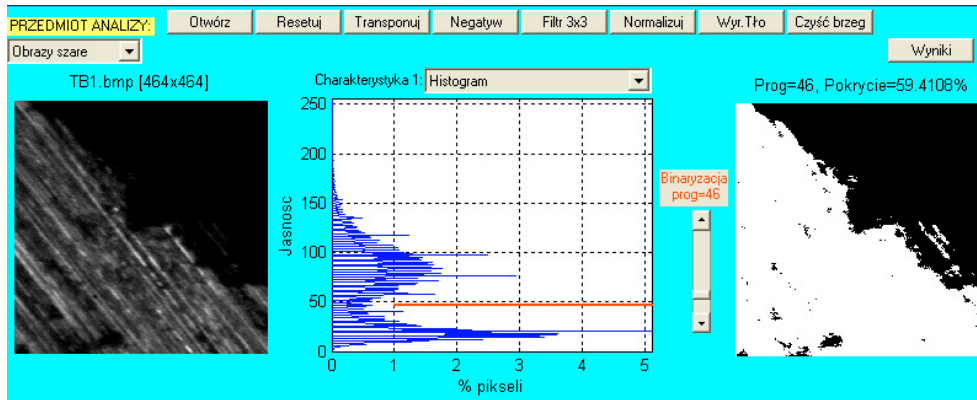
### 6.1 Wyznaczanie progu binarystacji

W najprostszym przypadku piksele wyodrębnianych obiektów mają inny zakres jasności niż piksele tła, w rezultacie czego histogram jest bimodalny – posiadający dwa maksima oddzielone „doliną”. Wartość progu binarystacji (w/g wzoru 1.4) powinna wówczas być równa jasności odpowiadającej „dnie doliny” [38]. Niestety histogram ma zazwyczaj znaczną składową losową utrudniającą ustalenie tego położenia.

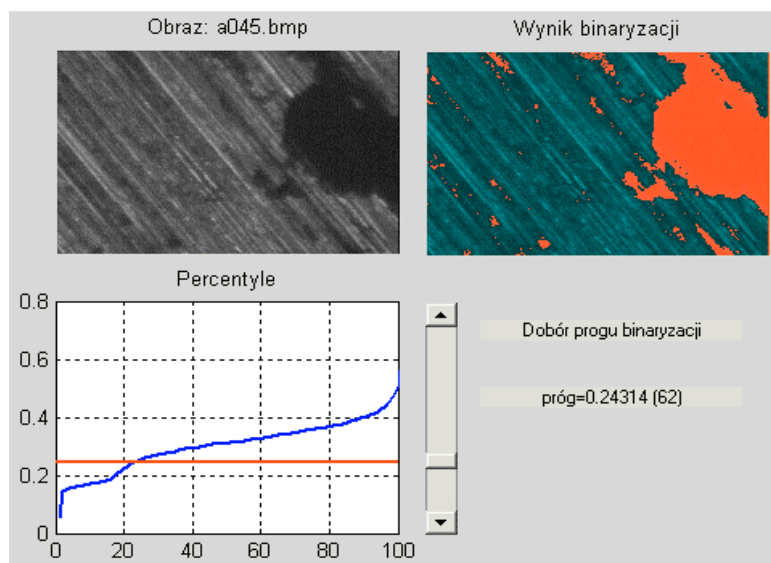
Jednym z możliwych sposobów jest skorzystanie z interaktywnego narzędzia, takiego jak opracowywany w Matlabie program ANALIZA\_01, który nie tylko umożliwia oglądanie badanego obrazu i jego charakterystyk ale pozwala także dobierać wartość progu binarystacji, równocześnie obserwując jego położenie na wykresie histogramu oraz rezultat binarystacji (Rys. 2.1). Podobnie, lecz w oparciu o krzywą percentylową (Rys. 2.2), ustalany jest próg binarystacji w programie BinKolor [P56].

Testowano również metody obliczeniowego wyznaczania progu na podstawie statystyk obrazu. W szczególności opracowano funkcję  $prog = dolina(OBRAZ)$  [P8], która wyznacza próg - po wygładzeniu histogramu - jako położenie minimum w przedziale między dwoma największymi maksimami lokalnymi. Wygładzenie histogramu uzyskano przez zmniejszenie liczby przedziałów do 16 lub 32 co pokazano linią grubą na Rys. 2.3b, natomiast wynik


binaryzacji z tak wyznaczonym progiem pokazano na Rys. 2.3c.



Rys. 2.1. Interaktywny dobór progu binaryzacji w programie ANALIZA\_01



Rys. 2.2. Interaktywny dobór progu binaryzacji programem BinKolor




Rys. 2.3. Porównanie wyników dwu metod binaryzacji


Obraz z Rys. 2.3a został wcześniej znormalizowany funkcją Norm99 [P7].

Metody binaryzacji zakładające bimodalność histogramu nie nadają się dla większości obrazów teksturowych, nie mających takich histogramów. Dlatego testowano inne metody.

Bardzo dobrą metodą okazało się zastosowanie stałego progu binaryzacji ustalonego w połowie pełnego zakresu jasności obrazów, które wcześniej poddano normalizacji przy pomocy funkcji Norm99. Metoda ta pozwoliła otrzymać obrazy binarne bardzo podobne do oryginałów co pokazano na Rys. 2.3d oraz Rys. 2.4 i Rys. 2.5. Metodę nazwano **BN99**.



Rys. 2.4. Wyniki binaryzacji metodą BN99 dla obrazów TA1, TA2, TB1, TB2



Rys. 2.5. Wyniki binaryzacji metodą BN99 dla obrazów TC1, TC2, TD1, TE1

Metoda ta daje wyniki podobne jak algorytm „symetrii rozkładu tła” oraz algorytm „trójkąta” Zack’a [S12] i jest lepsza od metody Brensena wyznaczającej próg jako średnią z wartości pikseli o maksymalnej i minimalnej jasności.

Testowane inne metody działały poprawnie tylko dla niektórych z pokazanych na rysunkach obrazów, dla innych dając wyniki zafałszowane.

Nieco innym zagadnieniem było ustalanie progu w przypadku binaryzacji sekwencji obrazów, analizowanych w rozdziale 5. Istotne było wówczas dobranie progu optymalnego dla całej sekwencji, na przykład przy uwzględnieniu postulatu maksymalnego uwydatnienia zmian obrazów będących skutkiem przebiegu procesu tarcia i przenoszenia materiału.

## 6.2 Proponowane deskryptory cech tekstury binarnej

Większość metod analizy obrazów teksturowych szarych - opisanych w rozdziale 4 - nie nadaje się do analizy tekstur binarnych dlatego zaszała potrzeba zdefiniowania i przetestowania opisanych poniżej deskryptorów.

### 6.2.1 Względne pokrycie powierzchni obrazu

Cecha reprezentująca względne pokrycie powierzchni obrazu plamami naniesionego materiału miała istotne znaczenie szczególnie przy analizie transferu materiału polimerowego na powierzchnię stali w procesie tarcia ślizgowego – opisanej w drugiej części niniejszej monografii.

Domyślnie przyjęto, że cecha ta dotyczy obrazów binarnych oraz – podobnie jak przy analizie obiektów – że chodzi o „względne pokrycie bielą”:

$$Pokr = Lb / Lx \quad (2.1)$$

przy czym (przy zastosowaniu notacji Matlab'a):

$Lb = \text{sum}(B(:))$  – liczba białych pikseli obrazu binarnego B

$Lx = Lw * Lk$  – liczba wszystkich pikseli obrazu

W przypadkach gdy nanoszony materiał jest ciemny, wówczas musi być zastosowana binaryzacja negatywowa, tak aby badanym obszarem były zawsze białe plamy na czarnym tle a nie odwrotnie.

### 6.2.2 Ziarnistość i średnia długość pasm białych

Deskryptory analogiczne do zmienności wierszy i kolumn (zdefiniowanych w 1.1.2) nazwano:

$Nx$  – liczba poziomych pasm białych oraz  $Ny$  – liczba pionowych pasm białych:

$$Nx = \sum_{w=1}^{Lw} \sum_{k=2}^{Lk} \text{Step0}(xb_{w,k}, xb_{w,k-1}) \quad (2.2)$$

$$Ny = \sum_{k=1}^{Lk} \sum_{w=2}^{Lw} \text{Step0}(xb_{w,k}, xb_{w-1,k}) \quad (2.3)$$

$$\text{gdzie: } Step0(r, s) = \begin{cases} 1 & \text{dla } r > s \\ 0 & \text{dla } r \leq s \end{cases} \quad (2.4)$$

Są to więc liczby przejść z czerni do bieli, odpowiednio w wierszach oraz kolumnach. Wartości deskryptorów  $N_x, N_y$  – wyznaczanych programem [P9] – zależą jednak nie tylko od liczby, kształtu i ukierunkowania białych motywów obrazu, ale również od jego rozmiarów, dlatego zdefiniowano też deskryptory inwariantne względem rozmiarów obrazu i unormowane do zakresu (0; 1) - **ziarnistość poziomą  $Z_x$  i ziarnistość pionową  $Z_y$** .

$$Z_x = 2 * N_x / L_x; \quad Z_y = 2 * N_y / L_x \quad (2.5)$$

Kolejne deskryptory to: **średnie długości pasm białych  $D_x, D_y$**  – także inwariantne względem rozmiarów obrazów. Wyznaczono je jako stosunek liczby białych pikseli  $N_b$  (sumy wartości pikseli obrazu binarnego) do liczby pasm  $N_x$  oraz  $N_y$ :

$$D_x = N_b / N_x; \quad D_y = N_b / N_y \quad (2.6)$$

Analogiczne deskryptory można zdefiniować dla pasm czarnych, dlatego w dalszym tekście każdorazowo zaznaczono o jakie pasma chodzi.

Iloraz średnich długości pasm  $D_y/D_x$  był traktowany we wczesnej fazie badań jako miara ortotropii względnej (patrz 4.3.4.3), a ich iloczyn  $D_x * D_y$  – jako deskryptor w przybliżeniu proporcjonalny do średniego pola obiektów występujących na obrazie.

### 6.2.3 Rozkłady i udziały pasm o różnych długościach

Dla obrazów binarnych macierz  $R$  długości pasm (patrz 1.2) zawiera jedynie dwa wiersze. Składowe pierwszego wiersza reprezentują rozkład długości pasm czarnych (liczność pasm o poszczególnych długościach)  $R_c$ , a rozkład pasm białych  $R_b$  zawarty jest w wierszu drugim.

$$R_c = [R_{1,j}]; \quad R_b = [R_{2,j}]; \quad j=1,2, .. L_r \quad (2.7)$$

gdzie:  $L_r \leq L_k$  – maksymalna długość pasma.

Rozkłady podające jedynie licznosc pasm są niezbyt adekwatne do ważności obserwowanych obiektów, gdyż jeden duży obiekt jest znacznie istotniejszy niż wiele drobnych, dlatego wprowadzono pojęcie „ważonych znormalizowanych rozkładów długości pasm”  $R_{bx}, R_{cx}$ , w których każda składowa podaje nie liczbę pasm lecz względną liczbę pikseli przypadających na pasmo o określonej długości.

Dla zdefiniowania kolejnych deskryptorów obrazów binarnych zdefiniowano i wykorzystano znormalizowany rozkład ważonych długości pasm białych w wierszach obrazu:

$$R_{bx} = [R_{bx,j}, j=1..L_r] = [j \cdot R_{b,j}] \quad (2.8)$$

Rozkład  $R_{bx}$  jest wektorem którego poszczególne składowe odpowiadają długościom pasm od jednego do  $L_r$  pikseli. Wartość składowej  $R_{bx,j}$  jest równa iloczynowi liczby  $R_{b,j}$  ciągłych sekwencji białych pikseli o długości  $j$  wykrytych przy skanowaniu macierzy obrazu wierszami, pomnożonej przez długość  $j$  tych sekwencji i podzielonej przez liczbę wszystkich białych pikseli obrazu  $L_b$ . Mnożenie przez długość pasma nadaje więc składowym odpowiednią wagę.

Ponieważ cały rozkład jest charakterystyką bardzo zmienną i przynoszącą nadmiar informacji, więc dla zredukowania liczby informacji zdefiniowano tylko trzy klasy długości pasm i odpowiadające im deskryptory, a mianowicie: **względne udziały pikseli białych w pasmach podłużnych „krótkich”, „średnich” oraz „długich”** (zgodnych z kierunkiem



tarcia) wyznaczane z rozkładu długości pasm  $Rbx$ :

- *krótkie* - o długości mniejszej niż 20% długości obrazu ( $j < gr1$ )
  - *średnie* - o długości 20% do 50% długości obrazu ( $gr1 < j < gr2$ )
  - *długie* - czyli dłuższe niż 50% długości obrazu ( $j > gr2$ )
- gdzie:  $gr1 = \text{round}(0.2 * Lk)$ ;  $gr2 = \text{round}(0.5 * Lk)$ ;  $Lk = \text{liczba kolumn}$ .

Inaczej mówiąc zredukowano liczbę składowych histogramu ważonej długości poziomych pasm białych  $Rbx$  do trzech, a zarazem znormalizowano ich wartości tak aby ich suma wynosiła jeden. Nowy rozkład oznaczany będzie jako  $W3bx$ . Jego składowe przyjmują jako trzy nowe deskryptory obrazu:

$$\text{udział pasm „krótkich”}: Kr = W3bx_1 = \frac{1}{Lb} \sum_{j=1}^{gr1-1} Rbx_j \quad (2.9)$$

$$\text{udział pasm „średnich”}: Sr = W3bx_2 = \frac{1}{Lb} \sum_{j=gr1}^{gr2} Rbx_j \quad (2.10)$$

$$\text{udział pasm „długich”}: Dl = W3bx_3 = (1 - W3bx_1 - W3bx_2) \quad (2.11)$$

Suma wartości tych trzech deskryptorów dla każdego obrazu wynosi z definicji 1, a więc trzeci deskryptor nie wnosi nowych informacji jako zależny od dwu pozostałych.

### 6.3 Segmentacja i indeksacja

W odróżnieniu od analizy tekstury całości obrazu, podejście obiektowe dotyczy **spójnych obszarów** wyodrębnionych w procesie **segmentacji** i automatycznie ponumerowanych przy zastosowaniu procedury **indeksacji**. Wydzielone obszary uważane są za **obiekty** obrazu odpowiadające rzeczywistym obiektom. Dla obrazów tribologicznych obiekty mogą odpowiadać na przykład uszkodzeniom powierzchni, takim jak „wżery” czy wykruszenia albo plamom wynikającym ze zmian fizyko-chemicznych lub tworzenia się warstewki tzw. „filmu transferowego” wynikającego z nakładania się materiału polimerowego w trakcie tarcia. Mogą one także przedstawiać cząstki zużyciowe (*wear particles*, *wear debris*) odrywające się w trakcie tarcia od powierzchni trących.

Spójne obszary obrazu wyodrębniane w procesie segmentacji [38] spełniają pewne kryteria jednorodności, którymi mogą być np. zakres poziomów jasności lub tekstura (faktura).

W przypadku gdy zakres jasności pikseli należących do obiektów jest rozłączny z zakresem jasności pikseli tła, wówczas - jako najprostszy sposób segmentacji - może być zastosowana **binaryzacja progowa** (2.1). Ważne jest aby w wyniku binaryzacji uzyskać **białe obiekty i czarne tło** a nie odwrotnie.

W bardziej złożonych przypadkach binaryzacja musi być uzupełniona szeregiem przekształceń w wyniku których powstaną **maski binarne** umożliwiające wydzielenie obiektów oraz **badanie ich kształtów**.

Kolejny etap to **indeksacja** czyli automatyczne ponumerowanie obiektów i należących do nich pikseli. W Matlabie można wykonać indeksację obiektów obrazu binarnego  $B$  przy pomocy funkcji  $[LAB, no] = \text{bwlabel}(B, s)$ . Wynikiem jest macierz  $LAB$  (klasy *double*),

o rozmiarach takich samych jak  $B$ , w której liczby wyrażające jasność pikseli zostały zastąpione numerami kolejnych obiektów do których te piksele należą. Tło jest obiektem o numerze zerowym, a pozostałe obiekty numerowane są kolejnymi liczbami naturalnymi od 1 do  $no$ .

Przynależność piksela do obiektu zależy od jego otoczenia i od przyjętego za obowiązujący typu sąsiedztwa  $s$ . Możliwe są dwa typy sąsiedztwa:

- a) **sąsiedztwo cztero pikselowe:  $s=4$**  polega na rozpatrywaniu połączeń pikseli tylko w czterech kierunkach (górze, dół, lewo, prawo)
- b) **sąsiedztwo ośmio pikselowe:  $s=8$**  polega na rozpatrywaniu połączeń pikseli w ośmiu kierunkach –uwzględniając także połączenia pikseli narożnikami czyli w kierunkach 45 i 135 stopni.

W pierwszym przypadku obiekty stykające się narożnikami nie są uważane za połączone a w drugim zaś tak.

## 6.4 Wyznaczanie cech wyodrębnionych obiektów

Praktycznie, jedynie z obrazów binarnych można uzyskać informacje o **rozmiarach** i **kształcie** poszczególnych obiektów [38], a także równomierności ich rozmieszczenia oraz wypełnieniu obrazu obszarami obiektów. Przy badaniu obiektów wyodrębnionych na obrazach binarnych przyjmuje się najczęściej, że **tło** jest **czarne** a **obiekty białe**. Jeśli jest inaczej to obraz może być przetworzony na negatyw.

Po zastosowaniu segmentacji i indeksacji można dokonać pomiaru cech poszczególnych wyodrębnionych i ponumerowanych obiektów macierzy  $LAB$ . W Matlabie 6 służy do tego funkcja *imfeature* o postaci:

$$cechy = imfeature(LAB, rodzaje\_cech)$$

W nowszych wersjach Matlab'a funkcja ta nosi nazwę *regionprops(L, rodzaje\_ cech)*.

Najważniejsze rodzaje wyznaczanych cech mogą być następujące:


- 'Area' – pole obiektu  $A$ ,
- 'Centroid' – współrzędne  $X_s$  oraz  $Y_s$  środka masy regionu,
- 'BoundingBox' – gabaryty obiektu [ $x_p, y_p, dx, dy$ ] gdzie ( $x_p, y_p$ ) - lewy górny róg,
- 'MajorAxisLength' – dłuższa oś  $MaA$  opisanej na obiekcie elipsy, której momenty bezwładności są takie same jak obiektu,
- 'MinorAxisLength' – krótsza oś  $MiA$  opisanej na obiekcie elipsy,
- 'Eccentricity' – ekscentryczność  $E$  opisanej na obiekcie elipsy: stosunek odległości między ogniskami do długości osi głównej,
- 'Orientation' – kąt (w stopniach)  $O$  nachylenia osi głównej elipsy opisanej na obiekcie względem osi  $x$ .

Wynikowa tablica strukturalna *cechy* ma długość równą liczbie obiektów, a szerokość równą liczbie wyznaczanych cech. Inaczej mówiąc każdemu obiektowi odpowiada wiersz tablicy zawierający pola (różnego typu) charakteryzujące poszczególne cechy tego obiektu.

Parametr "*rodzaje\_ cech*" ma być listą nazw cech, które mają być wyznaczane. Zamiast tej listy może być użyte słowo '**all**' – jako rozkaz wyznaczenia wszystkich cech lub '**basic**'

co spowoduje wyznaczenie cech: 'Area', 'Centroid', oraz 'BoundingBox'.

Przykład analizy cech obiektów pokazuje Rys. 2.6 oraz **Tabela 2.1**. Na Rys. 2.6a widać obraz oryginalny przedstawiający cząstki PTFE osadzone na powierzchni stalowej tarczy tribotestera typu trzpień-tarcza. Obraz binarny na Rys. 2.6b otrzymano wyznaczając próg binaryzacji funkcją  $dolina(X)$  [P8] (metodą znajdowania „doliny” histogramu). Następnie obraz ten poddano operacji czyszczenia brzegów, przy pomocy funkcji  $clborder(X)$  oraz filtracji medianowej (oknem  $7 \times 7$ ), która zmniejszyła liczbę wykrywanych obiektów z kilkudziesięciu do trzech, dzięki usunięciu zakłóceń wynikających z szumów przetwornika CCD kamery (widocznych przy słabym oświetleniu lub bardzo krótkich czasach ekspozycji).



Rys. 2.6. Segmentacja obiektów do analizy

Operacja czyszczenia brzegów – konieczna przy badaniu kształtu obiektów – niestety często musi być pominięta przy badaniu obrazu podłużnych śladów tarcia gdyż doprowadziłaby do usunięcia większości elementów obrazu.

Wyniki pomiaru własności trzech obiektów z Rys. 2.6, wygenerowane programem *Obiekt* [P10] zamieszcza **Tabela 2.1**

**Tabela 2.1.** Wybrane cechy trzech obiektów z Rys. 2.6

Cecha	Obiekt1	Obiekt2	Obiekt3
Area - $A_i$	550	5377	50157
Centroid [ $X_s$ , $Y_s$ ]	146.7 20.9	208.6 147.9	379.6 271.3
BoundingBox	135.5 5.5 24 31	178.5 86.5 66 124	202.5 109.5 335 293
MajorAxisLength $MaA$	29.8	112.3	393.8
MinorAxisLength $MiA$	24.1	64.2	179.3
Eccentricity - $E_i$	0.59	0.82	0.89
Orientation - $O_i$	85.6	93.7	37.5

Wyniki podawane przez funkcję *imfeature* mogą dotyczyć tysięcy obiektów obrazu, a więc, w celu formułowania wniosków, należy przeprowadzić analizę statystyczną.

#### 6.4.1 Dominująca orientacja obiektów binarnych

Dla obrazów tribologicznych proponuję wprowadzenie parametru „orientacja dominująca” - OD – zależnego od udziału obiektów najbardziej wydłużonych i największych.

$$OD = \frac{\sum A_i \cdot E_i \cdot MaA_i}{\sum E_i \cdot MaA_i} \quad (2.12)$$

Dla obiektów przedstawionych na Rys. 2.6c parametr  $OD$  wynosi:  $OD=50,58^\circ$

## 6.4.2 Rozkłady pól obiektów binarnych

Przedstawiona wyżej możliwość pomiaru pól obiektów, wyodrębnionych w procesach segmentacji i indeksacji, pozwala otrzymać histogram (rozkład eksperymentalny) częstości występowania „plam” o różnych polach.

$$HA=[HA_j]; j=1,2, \dots, LA; HA_j = \sum_{i=1}^{no} L((j-1) \cdot dA < A_i \leq j \cdot dA) \quad (2.13)$$

gdzie:  $LA$  – zadana liczba podprzedziałów zakresu pól  
 $dA = \max(A_i)/LA$ ; – podprzedział zakresu pól,  
 $L(\text{wyrażenie})$  – wartość logiczna wyrażenia (1=prawda, 0=falsz).  
 $no$  – liczba wyodrębnionych obiektów

Bardziej miarodajne (i zgodne z obserwacją) są opisane niżej charakterystyki uwzględniające nie tylko liczbę obiektów ale i zajmowane przez nie sumaryczne pole (jako udział w całości obrazu).


Pierwsza z nich to **ważony znormalizowany rozkład pól** (Rys. 2.7):

$$HWA_j = j \cdot dA \cdot HA_j / Lx \quad (2.14)$$

Kolejny to skumulowany ważony rozkład pól (dystrybuanta rozkładu ważonego znormalizowanego):


$$SHWA_j = \frac{1}{Lx} \sum_{i=1}^j i \cdot dA \cdot HA_i \quad (2.15)$$

Przykłady rozkładów – wygenerowane programem *Rozkl\_Skum* [P11] – pokazuje Rys. 2.7 i następne.




Rys. 2.7. Ważony znormalizowany rozkład pól obiektów białych


Jak widać z wykresu dystrybuanty można łatwo odczytać zarówno pole maksymalnej plamy (0,15%) jak i procentowe pokrycie obrazu bielą (33%) a także – z kształtu krzywej – udziały pól plam o poszczególnych wielkościach w sumarycznym pokryciu obrazu, co można prześledzić na Rys. 2.8, Rys. 2.9, oraz Rys. 2.10.



Rys. 2.8. Dystrybuanta ważona znormalizowanego rozkładu pól obiektów białych



Rys. 2.9. Przykład dystrybuanty pól obiektów – „plamy średnie”



Rys. 2.10. Przykład dystrybuanty pól obiektów – „plama duża”

## 7. Ekstensywna, automatyczna selekcja cech dyskryminacyjnych

Poszukując cech dyskryminacyjnych, które pozwolą najlepiej rozróżniać dane klasy obrazów możemy zastosować jeden z dwu wymienionych w podrozdziale 3.3 sposobów selekcji cech. Niniejszy rozdział przedstawia przykłady pierwszego z tych sposobów, a mianowicie, **ekstensywnej, automatycznej selekcji** najlepszych dyskryminatorów, zwanej też selekcją „ślepą”, gdyż stosowana jest m.in. gdy brak hipotez ułatwiających wybór.

Badacz zakłada jedynie, że każda klasa obrazów przedstawia inny stan powierzchni, na przykład dlatego, że odpowiada innym wartościom zmiennych decydujących o przebiegu procesu tarcia, jak: czas i droga tarcia, nacisk, temperatura, wilgotność, rodzaj materiału i czynnika smarnego.

Selekcja ekstensywna polega na wyznaczeniu możliwie jak najobszerniejszego zbioru różnorodnych cech obrazów – w większości opisanych w rozdziale poprzednim - a następnie, automatycznym testowaniu ich zdolności dyskryminacyjnej dla danych klas obrazów i wybraniu najlepszych cech dyskryminacyjnych.

Automatyczna selekcja może być także stosowana gdy istnieje potrzeba sprawdzenia, która z kilku wybranych cech jest lepszym dyskryminatorem.

Testowanie zalet i wad tego podejścia oraz możliwości zastosowań w tribologii uniwersalnych programów - stosowanych do analizy obrazów w innych dziedzinach – było jednym z pierwszych chronologicznie etapów moich badań.

Do selekcji ekstensywnej zastosowano programy **MaZda** i **Convert** (wspomniane w rozdziale 3.6.2). Programy te opracowane w ramach europejskiego projektu badawczego w Instytucie Elektroniki Politechniki Łódzkiej dla analizy obrazów medycznych (tomograficznych) zostały udostępnione w Internecie bezpłatnie do celów naukowych.

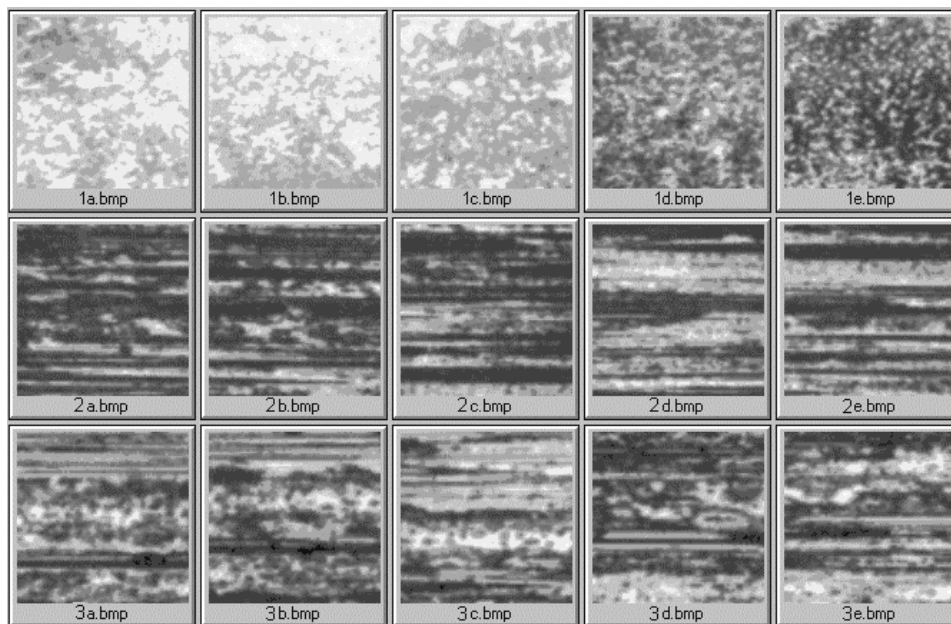
### 7.1 Testowanie wstępne metod selekcji ekstensywnej

Badania wstępne przeprowadzono na niewielkim zbiorze obrazów, a mianowicie z serii fotografii powierzchni wybrano trzy – zakładając, że odpowiadają trzem klasom obrazów oraz stanom badanych powierzchni. Dwie z nich wykazywały wizualnie wyraźne różnice, a trzecia zawierała elementy obu poprzednich. Tak więc decydując na podstawie obserwacji należałoby uznać, że istnieją tylko dwie klasy obrazów – wizualnie różne.

Początkowo przetestowano jednakże wariant zakładający istnienie trzech klas obrazów odpowiadających trzem fotografiami. Z każdej z tych fotografii wycięto po 5 fragmentów

o rozmiarach 200x200 pikseli uzyskując w ten sposób reprezentantów trzech klas obrazów C1, C2, C3 przedstawionych na Rys. 3.1.

Celem było znalezienie cech **dyskryminacyjnych** pozwalających najlepiej rozróżniać obrazy przynależące do poszczególnych klas.



Rys. 3.1. Badane obrazy (1a-1e) – klasa C1, (2a-2e) – klasa C2, (3a-3e) – klasa C3. Wymiary 200x200 pikseli, 256 odcieni szarości


Wartości 259 cech wyznaczano programem MaZda osobno dla obrazów oryginalnych oraz tych samych obrazów po normalizacji. Z tego obszernego zestawu cech, program Convert wytypował (**Tabela 3.1**) jako najlepsze dyskryminatory 10 cech o maksymalnym (dla trzech klas) współczynniku Fisher'a. Liczby w nawiasach okrągłych (dx,dy) oznaczają składowe wektora kierunku skanowania macierzy obrazu.

**Tabela 3.1.** Cechy o najwyższych współczynnikach Fisher'a **Fc**, wybrane przez program Convert

a) Bez normalizacji, 256 odcieni		b) Po normalizacji ( $3\sigma$ ), 16 odcieni	
Cecha	Fc	Cecha	Fc
Uwydatnienie krótkich pasm (0,1)	22.27	Odwrotny moment różnicowy (5, 0)	38.28
Skośność gradientu	20.80	Odwrotny moment różnicowy (4,0)	36.07
Teta 1	15.90	Niejednorodność szarości (0,1)	32.96
Korelacja (1, 0)	12.39	Entropia(5, 0)	32.23
Korelacja (2, 0)	11.67	Entropia (4, 0)	31.01
Korelacja (5, 0)	11.32	Odwrotny moment różnicowy(3, 0)	30.40
Korelacja (3, 0)	11.26	Entropia(3, 0)	28.48
Korelacja (4, 0)	11.21	Sum. Entropia (1, 0)	27.89
Sigma	10.85	Entropia (2, 0)	26.84
Kurtoza gradientu (1,0)	9.98	Odwrotny moment różnicowy (2, 0)	26.34

**Tabela 3.1** pokazuje m.in., że normalizacja znacznie poprawiła możliwość rozróżniania obrazów. Wykresy wartości dwu najlepszych cech z tej tabeli pokazuje Rys. 3.2 – dla

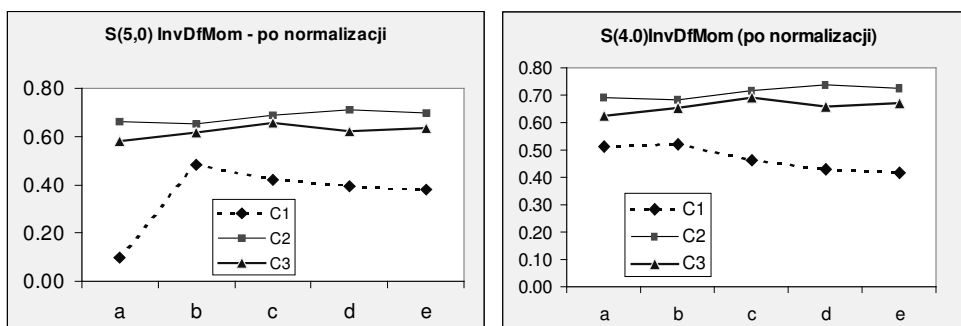
obrazów nie normalizowanych oraz Rys. 3.3 – dla obrazów normalizowanych.



a) Uwydatn. krótkich pasm  $F_c=22.27$

b) Skośność gradientu  $F_c=20.8$

Rys. 3.2. Dwie cechy o najwyższych wsp. Fisher'a dla obrazów z klas C1, C2, C3 bez normalizacji



Rys. 3.3. Dwie cechy o najwyższych wsp. Fisher'a dla obrazów z klas C1, C2, C3 po normalizacji

Jak widać cecha najlepsza w/g współczynnika Fisher'a – "uwydatnienie krótkich pasm" - nie rozróżnia klas C2 i C3 natomiast "skośność gradientu" daje wyniki w dużym stopniu zgodne z wynikami obserwacji obrazów (wykazuje podobieństwo obrazów 2d, 2e, 3d, 3e ale i 1d, 1e). Wybrane jako najlepsze cechy w/g wsp. Fisher'a dla obrazów po normalizacji są również zgodne z zaobserwowanymi wizualnymi różnicami.

**Tabela 3.2** zestawia wybrane cztery najlepsze dyskryminatory dla trójki oraz pary klas.

Jak widać największe wartości współczynnika Fisher'a uzyskano dla pary klas najbardziej wizualnie różniących się.

**Tabela 3.2.** Najlepsze dyskryminatory dla dwu i trzech klas

Cecha	Fc12	Fc123
S(1,0) Sumaryczna entropia	68.16	27.89
S(5,0) Entropia	67.07	32.23
S(5,0) Odwr. moment różnicowy	59.45	38.28
Niejednorodność szarości w pionie	42.32	32.96

Kolejna próba polegała na zastosowaniu selekcji cech według innych miar zdolności dyskryminacyjnej niż współczynnik Fisher'a

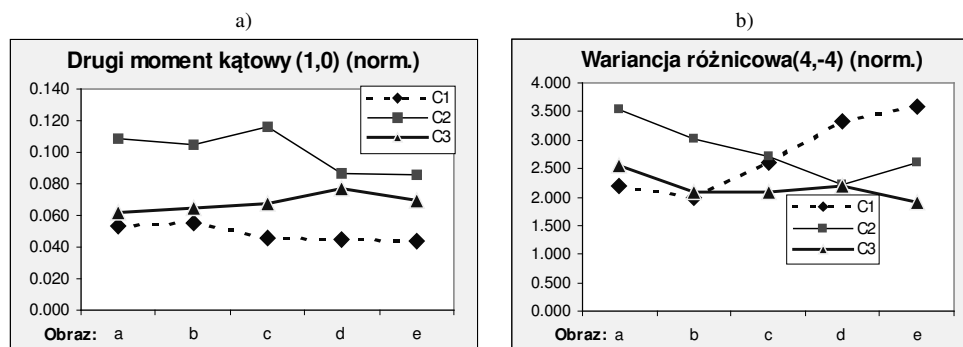
**Tabela 3.3** przedstawia wyniki selekcji cech dyskryminacyjnych według miary zdolności dyskryminacyjnej oznaczonej w programie Convert akronimem POE+ACC (w tym



przypadku im mniejsza miara tym lepsza cecha). Również w tym przypadku po normalizacji uzyskano lepsze wyniki chociaż interesujące jest to, że jako najlepsze cechy różniące klasy obrazów tym razem program Convert wytypował całkiem inne cechy.

**Tabela 3.3.** Cechy wybrane przez program Convert w/g minimum miary dyskryminacji POE+ACC

a) Bez normalizacji, 8 bitów odcieni		b) Po normalizacji (3 $\sigma$ ), 4 bity odcieni	
Cecha	Miara	Cecha	Miara
Wariancja różnicowa (0, 2)	0.00	Drugi moment kątowy (1, 0)	0.00
Kurtoza	0.07	Wariancja różnicowa (4,-4)	0.04
Drugi moment kątowy (0, 2)	0.22	Sumaryczna średnia (0, 1)	0.12
Sigma	0.22	Teta 4	0.11
Kurtoza gradientu	0.24	Sum. Entropia (3, 0)	0.15
Teta 4	0.23	Wariancja gradientu	0.16
Wariancja gradientu	0.25	Kurtoza gradientu	0.16
Niejednorodność szarości (1,1)	0.26	Drugi moment kątowy (5, 0)	0.17
Percentyl 99%	0.26	Percentyl 99%	0.19
Niejednorodność szarości (-1,1)	0.26	Drugi moment kątowy (3, 0)	0.20



Rys. 3.4. Cechy o minimalnym współczynniku POE+ACC dla obrazów po normalizacji


**Tabela 3.4.** Cechy wybrane przez program Convert w/g maksimum miary MDM

a) Bez normalizacji, 8 bitów odcieni		b) Po normalizacji (3 $\sigma$ ), 4 bity odcieni	
Cecha	MDM	Cecha	MDM
Drugi moment kątowy (5, 0)	1.49E15	Teta4	1.29E15
Drugi moment kątowy (2, 0)	4.68E14	Entropia różnicowa (5,-5)	4.32E14
Korelacja (1, 0)	1.58E14	Wariancja różnicowa (0, 4)	4.02E14
Sigma	1.03E14	Kontrast (3, 0)	3.59E14
Drugi moment kątowy (2,-2)	5.62E13	Korelacja (4, 0)	2.58E14
Drugi moment kątowy (0, 5)	4.42E13	Entropia (5, 5)	1.54E14
Odwrotny moment różnicowy (5, 5)	3.71E13	Wariancja różnicowa (3,-3)	1.52E14
Odwrotny moment różnicowy (5,-5)	2.58E13	Odwrotny moment różnicowy (4, 4)	1.47E14
Odwrotny moment różnicowy (4, 4)	2.53E13	Entropia różnicowa (3, 0)	1.44E14
Drugi moment kątowy (5, 5)	2.07E13	Wariancja różnicowa (5,-5)	1.41E14

Niestety wykres (Rys. 3.4b) wykazał że metoda druga (POE+ACC) wybiera dla obrazów znormalizowanych cechy, które nie różnią prawidłowo klas C1, C2, C3.

Nieprawidłowe wyniki (Rys. 3.5b) dają także trzecia metoda (**Tabela 3.4**) selekcji cech w programie Convert (metoda dyskryminacji wielowymiarowej) określona akronimem MDM, przy czym program lojalnie ostrzega użytkownika wyświetlając komunikat o "moż-

liwości bardzo niedokładnych wyników" ze względu na "prawie osobliwą" macierz w równaniach. Dodatkowo widać, że dla metody MDM normalizacja pogorszyła wartości miary.

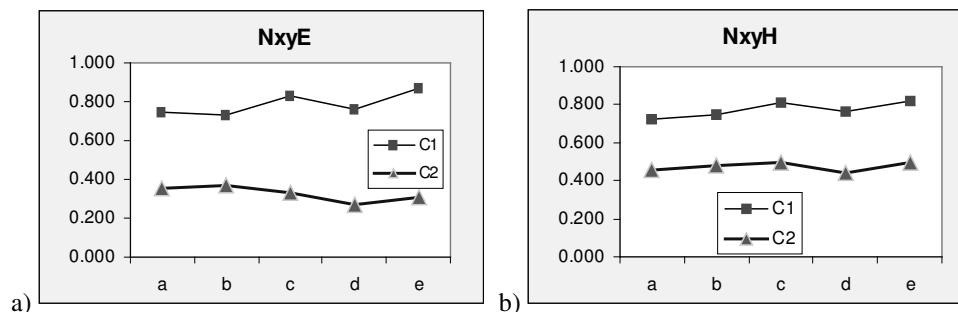


Rys. 3.5. Cechy w/g maksimum miary dyskryminacji wielowymiarowej (MDM) - po normalizacji

W związku ze stwierdzeniem możliwości uzyskiwania fałszywych wyników przy zastosowaniu w programach MaZda i Convert metod innych niż metoda Fisher'a – w dalszych badaniach wykorzystywano jedynie selekcję dyskryminatorów według maksymalnych wartości współczynnika Fisher'a.

### 7.1.1 Porównanie selekcji ekstensywnej z ukierunkowaną

Wzrokowa ocena jakościowa wykazuje, że klasy obrazów różni głównie anizotropia. Wykorzystano to dla porównania selekcji ekstensywnej z ukierunkowaną, stosując binaryzację oraz wyznaczając [W1] cechę zdefiniowaną w p.4.3.4.3 nazwaną „ilorazową ortotropią względną”  $N_{xy}$ . Dla klas C1 i C2 uzyskano dla tej cechy znacznie lepszą zdolność dyskryminacyjną  $F_c \approx 82$  (Rys. 3.6a), a po dodatkowym zastosowaniu, przed binaryzacją, filtracji medianowej górnoprzepustowej, dla poprawy jednorodności, współczynnik  $F_c$  przekroczył wartość 90 (Rys. 3.6b), podczas gdy w selekcji ekstensywnej najlepsza cecha osiągnęła wartość współczynnika Fisher'a 68.



Rys. 3.6. Cecha  $N_{xy}$  po binaryzacji (a) oraz filtracji medianowej górnoprzepustowej (b)

### 7.1.2 Wnioski z testowania wstępnego metod selekcji ekstensywnej

Wstępne testowanie metod automatycznej selekcji ekstensywnej pozwoliło m.in. na sformułowanie następujących wniosków:

- rozróżnianie klas obrazów po zastosowaniu binaryzacji i na podstawie cech odpowiadających obserwowanym różnicom wizualnym dało lepsze rezultaty niż selekcja ekstensywna;
- cechy dyskryminacyjne najlepiej określać dla klas obrazów najbardziej różniących się wizualnie, nawet jeśli mają być stosowane także dla klas pośrednich,
- normalizacja obrazów pozwoliła na uzyskanie lepszych wyników niż bez normalizacji,
- współczynnik Fisher'a okazał się być najbardziej uniwersalną miarą zdolności dyskryminacyjnej,
- dla rozróżniania morfologii obrazów niezbędne są cechy wyznaczane z charakterystyk par lub grup pikseli a nie pojedynczych pikseli (jak histogram),

## 7.2 Selekcja ekstensywna w statycznej analizie transferu materiału

Kolejna próba zastosowania automatycznej selekcji ekstensywnej dotyczyła obrazów śladów tarcia ślizgowego pozostawianych na stalowej tarczy przeciwpróbkowej tribotestera typu pin-on-disk przez trące o nią próbki materiałów kompozytowych zawierających tarflen (PTFE). Użyta w tym celu aparaturę oraz przebieg eksperymentów opisano w rozdziale 5.

W omawianych tutaj badaniach wykorzystano próbki dwu materiałów o oznaczeniach:

- SM-2 - czysty tarflen, oraz
- SM-K22G3 – tarflen z domieszkami koksu i grafitu

Każdy z materiałów brał udział trzykrotnie w tarcu ślizgowym o stalową tarczę przy zastosowaniu różnych warunków pracy ślizgowej określonych dociskiem **F** i prędkością poślizgu **v**:

**L** – warunki lekkie:  $F = 30 \text{ N}$ , ( $p=0,313 \text{ MPa}$ ),  $v = 0,84 \text{ m/s}$

**S** - warunki średnie:  $F = 30 \text{ N}$ , ( $p=0,313 \text{ MPa}$ ),  $v = 2,51 \text{ m/s}$

**C**- warunki ciężkie:  $F = 100 \text{ N}$ , ( $p=1,04 \text{ MPa}$ ),  $v = 2,51 \text{ m/s}$


Każda z sześciu sekwencji obrazów przedstawia to samo miejsce tarczy, gdyż obrazy rejestrowano synchronicznie z obrotami tarczy. Jak z tego wynika - stanowisko badawcze zostało przystosowane do akwizycji **sekwencji** obrazów w trakcie procesu tarcia, czyli dla dynamicznej analizy zmian wybranego wycinka powierzchni tarczy tribotestera.

Zastosowanie **stacyjnej** analizy obrazów było więc możliwe jedynie w ograniczonym zakresie, przy założeniu, że wybrane do analizy grupy obrazów reprezentują poszczególne stany powierzchni, a zmiany powierzchni jakie zachodzą w trakcie rejestracji kilku obrazów reprezentujących daną klasę są pomijalnie małe.

W statycznej analizie obrazów lokalizacja pobieranych obrazów śladów tarcia - jako reprezentatywnych próbek z populacji - powinna być wybierana losowo. W tym przypadku było to niemożliwe do spełnienia ze względu na sposób rejestrowania, jednak zamiastką

próby losowej było wyodrębnienie w pojedynczym obrazie kilku **podobrazów** (co z kolei zapewniało powtarzalność warunków akwizycji).

Zarejestrowane sekwencje zawierały po 150 obrazów, jednak do statycznej analizy wybrano jedynie po 4 końcowe obrazy z każdej sekwencji, dodatkowo dzieląc każdy obraz na 4 części. W ten sposób uzyskano po 16 obrazów reprezentujących każdą z sześciu analizowanych klas. Przykładowe obrazy z poszczególnych klas pokazuje Rys. 3.7



Rys. 3.7. Przykładowe obrazy badanych klas odpowiadających materiałom SM-2 i SM-K22G3 oraz warunkom pracy L, S, C.

Automatycznej selekcji cech dyskryminacyjnych dla każdej pary klas dokonano przy zastosowaniu programów MaZda oraz Convert, przy czym chodziło o cechy pozwalające rozróżniać ślady tarcia pozostawiane przez różne materiały kompozytowe.

Programem MaZda wyznaczano dla każdego z badanych obrazów 259 wartości cech (opisanych w rozdziale 4), a wyznaczanych na podstawie:

- f) wektora histogramu obrazu ***Hn***: 9 cech,
- g) macierzy gradientu obrazu ***G***: 5 cech
- h) macierzy rozkładu długości pasm ***R***: 5 cech  $\times$  4 kierunki
- i) macierzy zdarzeń ***C***: 11 cech  $\times$  4 kierunki  $\times$  5 odległości = 220
- j) modelu autoregresji ***AR***: 5 cech

Dla każdej z trzech kategorii pracy ślizgowej program Convert wyselekcjonował inne cechy dyskryminacyjne – pokazuje je **Tabela 3.5** - jednak cechy z grupy “Korelacja” powtarzały się we wszystkich trzech przypadkach, a cecha “Teta1” w dwóch.


Rozmieszczenie cech badanych obrazów w przestrzeni cech Korelacja(5,-5) i Teta1 przedstawiono na wykresie pokazanym na Rys. 3.8, przy czym K22 i SM2 to skrótowe oznaczenia wymienionych już materiałów, a litery L, S, C to warunki pracy.

Uzyskane wyniki pokazują, że dla materiału SM-K22G3 “korelacja” (a więc i regularność struktury obrazu) wzrosła przy przejściu z pracy L do S, a następnie, przy przejściu z S do C, wzrosła jedynie cecha “teta 1”. Natomiast dla materiału SM-2 zaobserwowano jedynie spadek cechy “Teta 1” przy przejściu z L do S.

Niestety czasem wytypowane automatycznie cechy dyskryminacyjne są trudne do interpretacji i użytkownik nie mając potwierdzenia wizualnego nie może być pewien czy zmiany cech nie wyniknęły z przypadkowych zmian w procesie akwizycji.

**Tabela 3.5.** Cechy rozróżniające ślady tarcia dwu materiałów kompozytowych

L – warunki lekkie		S – warunki średnie		C – warunki ciężkie	
Cecha	Fc	Cecha	Fc	Cecha	Fc
Teta1	282,32	S(0, 2)Correlat	135,19	S(1,0)Correlat	319,96
S(0, 2)DifVarnc	71,5	S(0, 3)Correlat	109,91	S(1,1)Correlat	307,44
S(0, 1)DifVarnc	63,04	S(0, 4)Correlat	94,05	S(1,-1)Correlat	294,29
S(0, 5)SumAverg	55,57	S(0, 1)Correlat	89,45	S(2,2)Correlat	277,95
S(0, 4)SumAverg	55,54	S(0, 5)Correlat	83,44	S(2,-2)Correlat	207,62
S(0, 3)SumAverg	55,53	Teta1	62,82	S(3,0)Correlat	205,41
S(0, 2)SumAverg	55,51	S(5,-5)SumVarnc	62,48	S(3,3)Correlat	204,19
S(0, 1)SumAverg	55,47	Sigma	62,11	S(4,0)Correlat	196,74
Mean	55,39	S(4,-4)SumVarnc	62,02	S(5,0)Correlat	188,65
S(5,-5)Correlat	54,49	S(3,-3)SumVarnc	60,84	S(5,-5)Correlat	179,09




Rys. 3.8. Charakterystyka obrazów śladów tarcia ślizgowego cechami „Korelacja i „Teta 1”

Dlatego z jednej strony przeprowadzono analizę zakłóceń i błędów procesu akwizycji – opisaną w rozdziale 4 oraz 5.5, a z drugiej – przeprowadzono badania wrażliwości cech tekstury na zmiany jasności, kontrastu i ostrości obrazu oraz uporządkowania i anizotropii, których wyniki zaprezentowano w rozdziale 4.

### 7.3 Próba oceny zużycia materiału oczek ciągadeł drutu

Trzeci przykład stanowiła próba zastosowania analizy obrazów do oceny stopnia zużycia materiału. Analizowano obrazy metalograficzne warstw przypowierzchniowych oczek ciągadeł otrzymane z mikroskopu elektronowego Rys. 3.9.



Rys. 3.9. Przykładowe obrazy zglądów oczek ciągadeł: a) materiał nowy, b) zużyty

Pierwsze etapy pracy polegały na wyselekcjonowaniu z posiadanych obrazów dwu zbiorów “uczących” C1, C2, reprezentujących osobno klasę obrazów oczek nowych oraz klasę obrazów oczek zużytych, a następnie dokonaniu na ich podstawie selekcji deskryptorów będących najlepszymi dyskryminatorami tych klas. Wykorzystano w tym celu wspomniany wcześniej program *Mazda* – pozwalający wyznaczać dla każdego obrazu ponad 250 cech oraz program *Convert* - dokonujący selekcji dziesięciu cech stanowiących najlepsze dyskryminatory badanych klas obrazów.

Pięć najlepszych cech dyskryminacyjnych wybranych przez program *Convert* oraz ich zdolność dyskryminacyjną  $F_c$  w/g współczynnika Fisher’a pokazuje **Tabela 3.6**.

**Tabela 3.6.** Najlepsze cechy dyskryminacyjne dla klas obrazów C1, C2 (po normalizacji).

Cecha	Korelacja	Korelacja	Kontrast	Kontrast	Korelacja
<b>Kierunek</b>	<b>(2,-2)</b>	(3,-3)	<b>(2,-2)</b>	(1,-1)	(1,-1)
<b>Fc</b>	<b>13.95</b>	13.36	<b>12.96</b>	12.66	11.50

Dwoma najlepszymi niezależnymi cechami są więc  $Kr(2,-2)$  - korelacja i  $Kt(2,-2)$  - kontrast, a ich wartości dla wzorcowych klas obrazów pokazuje wykres na Rys. 3.10.


Jak widać w **miarę zużycia rosną wartości cechy „kontrast”, a maleją wartości cechy „korelacja”**.

Związek tych cech z cechami jakościowymi jest tym razem dość oczywisty i potwierdzony badaniami w rozdziale 4. Wzrost kontrastu wynika z powstawania ciemnych szczelin w materiale zużytym, a równocześnie spadek korelacji jest powodowany zakłócaniem jednorodności i równomierności struktury obrazu.


Kolejnym etapem była ocena stanu warstw wierzchnich przypisanych poszczególnym mediom chłodzącym - oznaczonym [A], [H], [W], [U] - przy pomocy znalezionych deskryptorów obrazów. Dla przeprowadzenia liczbowej oceny stanu warstwy wierzchniej przy

wykorzystaniu 15-tu fotografii, odpowiadających trzem obszarom oczka i 5-ciu warunkom pracy, analizowano na każdej z nich po 2 w przybliżeniu kwadratowe obszary (Rys. 3.11) w pobliżu powierzchni oczka co łącznie dało 30 analizowanych obrazów.

Dla obrazów tych wyznaczono wartości cech (1-Kr(2,-2)) i Kt(2,-2) traktując je jako wskaźniki zużycia warstwy wierzchniej.



Rys. 3.10. Rozróżnianie wzorcowych obrazów materiału nowego i zużytego w przestrzeni cech „kontrast” i „korelacja” wyznaczanych z macierzy przejść tonalnych.




Rys. 3.11. Badane obszary

W dyskusji wyników stwierdzono m.in., że błędy analizy może powodować fakt iż obrazy uzyskiwane z mikroskopów metalograficznych cechują się zazwyczaj nadmiernym kontrastem i odbłaskiem na brzegach ziaren materiału – w tym przypadku ziaren węgla kobaltu.

Wartości tych cech dla poszczególnych kategorii oczek pokazuje Rys. 3.12. Jak widać obie cechy wykazują zgodnie, że najmniejsze zużycie, a więc stan zbliżony do stanu nowego oczka ciągnadła [N] następuje dla chłodziwa [A] czyli Alumol, a kolejne miejsca zajmują: [H] - Hydropol, [W] - W-35 i ostatnie, a więc najgorsze zdolności zapobiegania zużyciu, ma chłodziwo [U] – Unopol.

Przedstawione wyniki są w większości zgodne z uzyskanymi innymi metodami [W12] z jednym wyjątkiem, a mianowicie poprzednio typowano na pierwsze miejsce chłodziwo Hydropol, a na drugie Alumol, podczas gdy przy obecnej ocenie zamieniły się one miejscami.



Rys. 3.12. Wartości wybranych cech obrazów dla oczek nowych (N) oraz zużytych, pracujących z chłodziwami: Alumol [A], Hydropol [H], W-35 [W], Unopol [U].

## 7.4 Ogólna ocena selekcji ekstensywnej

**Zaletą** podejścia ekstensywnego są szybkość i prostota analizy z użyciem programów takich jak MaZda i Convert, co czyni metodę dostępną nawet osobom niezaawansowanym w analizie obrazów.

**Wadą** stosowanego testowania wielkiej liczby cech jest trudność interpretacji związku znalezionych dyskryminatorów z wizualnie dostrzeganymi cechami jakościowymi oraz związane z tym ryzyko selekcji cech nieistotnych dla celu badań, a charakteryzujących przypadkowe różnice warunków akwizycji klas obrazów.

Powyższa wada będzie niwelowana w tym większym stopniu im bardziej znane będą relacje między poszczególnymi cechami ilościowymi a charakterystycznymi cechami jakościowymi badanych obrazów. Celowi temu służyły badania opisane w rozdziale 4.

W przypadkach gdy selekcja ekstensywna dotyczy więcej niż dwu klas lub gdy obserwacje nie pozwalają stwierdzić istotnych różnic między klasami obrazów – można spodziewać się niejednoznacznych wyników takiej selekcji.

Znalezienie dobrych dyskryminatorów może być ułatwione m.in. przez zastosowanie odpowiednich sposobów przetwarzania obrazów, celem poprawy jakości obrazów i uwydatnienia istotnych cech. Należy jednak być świadomym, że pierwotne informacje są wówczas zmieniane i jeśli przetwarzanie jest naprawdę potrzebne to wszystkie obrazy powinny być przetwarzane w ten sam sposób.

Jeśli badane klasy obrazów wykazują dostrzegane wizualnie różnice to zazwyczaj lepsze rezultaty - niż w selekcji ekstensywnej - można uzyskać wiedząc jakie cechy odzwierciedlają te różnice i dokonując ekstrakcji tych cech. Dlatego kolejny rozdział poświęcony jest właśnie tej problematyce.



## 8. Liczbowa ekspresja wybranych cech jakościowych obrazów tribologicznych

W tym rozdziale przedstawiam wyniki poszukiwań liczbowych deskryptorów wyrażających dostrzegane przez człowieka jakościowe cechy obrazów tribologicznych oraz wrażliwych na zmiany tych cech. Ludzki wzrok i umysł zazwyczaj szybko i bezbłędnie pozwala stwierdzić wizualne różnice ale nie zawsze łatwo opisać je słownie a tym bardziej matematycznie.

Przeprowadzone badania pozwoliły wyselekcjonować cechy ilościowe najbardziej wrażliwe na zmiany jasności, kontrastu, ostrości oraz uporządkowania struktury obrazu.

Zaproponowano także i przetestowano ilościowe deskryptory dla takich cech jakościowych jak niejednorodność, anizotropia czy ukierunkowanie elementów obrazu. Deskryptory te wyznaczano w oparciu o różne ilościowe cechy statystyczne obrazów, a więc mogą być one uważane za **meta-cechy** stanowiące zarówno właściwość obrazu jak i wykorzystanej cechy.

### 8.1 Wrażliwość cech na zmiany jasności, kontrastu, ostrości oraz uporządkowania morfologii obrazu


W wielu przypadkach zmiany jasności, kontrastu i ostrości obrazów mogą wynikać z błędów procesu akwizycji, stąd wyniknęła potrzeba znalezienia po pierwsze cech pozwalających wykrywać takie zmiany, a po drugie cech odpornych na tego rodzaju zmiany, natomiast reagujących na zmiany uporządkowania morfologii obrazu.

#### 8.1.1 Wrażliwość cech na zmiany jasności, kontrastu i ostrości

Do badań wrażliwości cech na zmiany jasności, kontrastu i ostrości obrazów [W20] sporządzono serię czterech obrazów (Rys. 4.1), w skład której wchodził wybrany obraz oryginalny (1a) oraz trzy obrazy wtórne otrzymane przez przetworzenie obrazu oryginalnego „1a” w programie Paintshop-Pro, a mianowicie:

- rozjaśnienie – zwiększenie średniej jasności o 40% - obraz „1aj”
- zwiększenie kontrastu – wariancja histogramu zwiększona ok. 6 razy - obraz „1ak”
- rozmycie (operacja "more soft" w programie Paint Shop Pro) - obraz „1as”


Następnie, dla każdego z tych obrazów wyznaczono przy pomocy programu MaZda 259 cech (opisanych już uprzednio). Wyniki przeniesiono do arkusza kalkulacyjnego Excel, w którym wyznaczono procentowe zmiany cech spowodowane poszczególnymi operacjami przetwarzania.



Rys. 4.1. Obrazy użyte do analizy wrażliwości cech na zmiany jasności, kontrastu i ostrości

Wyniki przedstawiono na wykresach, przy czym dla cech wyznaczanych w różnych kierunkach i przy różnych odległościach pikseli brano do wykresu wartość największą.

Na **zmiany jasności wrażliwe** są jedynie – pokazane na Rys. 4.2 - cechy wyznaczane z histogramu oraz cecha „sumaryczna średnia” (*SumAverg*) wyznaczana z macierzy przejść tonalnych C (patrz rozdział 5.4).




Rys. 4.2. Cechy wrażliwe na zmiany jasności obrazu

**Wrażliwość na zmiany kontrastu** wykazuje wiele cech. Część z nich - dla których zmiana była większa niż 5% - przedstawia wykres na Rys. 4.3. Jak widać na pierwszym miejscu jest cecha „**kontrast**” (zgodnie ze swą nazwą) oraz 5 **wariancji** różnych cech, które zmieniły się aż o blisko 500%.

Na dalszych miejscach są dwie cechy wyznaczane z macierzy gradientu – „średni gradient” (*GrMean*) 146% i „skośność gradientu” (*GrSkewness*) 13% oraz niektóre cechy wyznaczane z histogramu i macierzy przejść tonalnych, natomiast tylko jedna cecha wyznaczana z macierzy długości pasm R – „uwydatnienie długich pasm pionowych” (*Verti Ln-gREmp*).

Do cech całkowicie **niewrażliwych na zmiany kontrastu** należą pozostałe cechy wyznaczane z **macierzy długości pasm R** oraz trzy cechy wyznaczane z macierzy C: „drugi moment kątowy” lub inaczej „**energia**” (*AngScMom*) oraz „**korelacja**” i „**entropia**”.

Cechy najbardziej **wrażliwe na zmiany ostrości** obrazu przedstawiono na Rys. 4.4, przy czym jaśniejszy kolor przypisano tym cechom, które są równocześnie wrażliwe na zmiany kontrastu. Jak widać, na zmiany ostrości najsilniej reagują cechy Teta2 i Teta3 wyznaczone z modelu autoregresji, ale i pozostałe cechy wyznaczone z tej charakterystyki dość silnie reagują na zmiany ostrości, a znacznie słabiej na zmiany kontrastu. Podobnie zachowuje się cecha „energia” (*AngScMom*) – wrażliwa na zmianę ostrości a niewrażliwa na zmianę kontrastu. Inne cechy wrażliwe na zmiany ostrości wyznaczone są z macierzy gradientu, długości pasm i przejść tonalnych.




Rys. 4.3. Cechy wrażliwe na zmiany kontrastu

Rozpatrując grupy cech można stwierdzić:

- cechy histogramu są wrażliwe zarówno na zmianę jasności jak i kontrastu, z wyjątkiem wariacji (*Variance*) i skośności (*Skewness*) niezależnych od jasności oraz kurtozy (*Kurtosis*) prawie niezależnej;
- prawie wszystkie cechy wyższych rzędów (par lub grup pikseli) są odporne na zmiany jasności z wyjątkiem cechy SumAverg, natomiast wrażliwe są na zmiany ostrości z wyjątkiem cech SumEntrp i SumAverg;

- wszystkie cechy wyznaczone z macierzy  $R$  - wyjątkiem *Vertl\_LngREmp* - są odporne na zmiany kontrastu;
- z cech wyznaczanych z macierzy  $C$  najbardziej odporna na zmiany kontrastu jest korelacja (*Corelat*). Cecha *SumAverg* jest odporna na rozmycie ostrości.




Rys. 4.4. Cechy wrażliwe na zmiany ostrości obrazu

### 8.1.2 Wrażliwość cech na zmianę uporządkowania struktury obrazu

Dla badań wrażliwości cech na zmianę uporządkowania struktury obrazu wygenerowano – przy pomocy programu napisanego w Matlabie – serie obrazów tworzących dwie klasy testowe. Wszystkie obrazy miały te same rozmiary 128x128 pikseli.

Klasa pierwsza zawierała obrazy jasnych krat na czarnym tle, przy czym jasność pikseli tworzących kratę zmieniano losowo (według rozkładu równomiernego w zakresie 56-255), a krata na każdym obrazie była obrócona o inny kąt zmieniający się od zera co 5 stopni aż do 60 stopni (Rys. 4.5a,b)



Rys. 4.5. Przykładowe obrazy testowe

Klasa druga zawierała obrazy o takiej samej liczbie jasnych pikseli jak w klasie pierwszej, o losowo zmienianej jasności, lecz rozmieszczenie pikseli było losowe (według rozkładu równomiernego), jak to pokazuje Rys. 4.5c.

Mając dwie równoliczne klasy, dla każdego obrazu tych klas wyznaczono programem MaZda zbiór cech, a następnie wyselekcjonowano programem Convert najlepsze dyskryminatory. Okazało się, że uporządkowanie struktury obrazu najlepiej wykrywają cechy:

- „nierównomierność szarości” (*GLevNonU*) - wyznaczana z macierzy  $R$  (Fc=37),
- „korelacja” (*Correlat*) - wyznaczana z macierzy  $C$  (Fc=33),
- „sumaryczna wariancja” (*SumVarnc*) - wyznaczana z macierzy  $C$  (Fc=30).

Jednakże ta ostatnia cecha jest także mocno zależna od zmian kontrastu, a pozostałe jedynie reagują w niewielkim stopniu na zmiany ostrości (Rys. 4.4).

### 8.1.3 Detektory zmian jasności, kontrastu, ostrości i uporządkowania

Zestawienie cech najbardziej wrażliwych na zmiany jasności, kontrastu, ostrości i uporządkowania podaje **Tabela 4.1**. W szczególności dla detekcji uporządkowania morfologii obrazu najbardziej odpowiednie okazały się cechy: *GLevNoNU* – „niejednorodność szarości” wyznaczana z macierzy  $R$  oraz *Correlat* – korelacja wyznaczana z macierzy  $C$ .

**Tabela 4.1.** Detektory zmian jasności, kontrastu, ostrości i uporządkowania

Ch-ka	Cecha -detektor zmian	Zmiana obrazu			
		Rozjaśn.	Zw.kontrast.	Rozmycie	Uporządk.
Histogram	<i>Perc. 1%</i>	<b>+111%</b>	13%	0%	0%
	<i>Perc. 10%</i>	<b>+96%</b>	8%	0%	0%
	<i>Variance</i>	0%	<b>+494%</b>	9%	1%
Macierz R	<i>GLevNonU</i>	0%	0%	13%	<b>-106%</b>
Macierz C	<i>SumOfSqs</i>	0%	<b>+497%</b>	10%	1%
	<i>AngScMom</i>	0%	0%	<b>+76%</b>	15%
	<i>Correlat</i>	0%	0%	+12%	<b>+102%</b>
Model AR	<i>Teta2</i>	0%	9%	<b>+243%</b>	+99%
	<i>Teta3</i>	0%	5%	<b>+213%</b>	+100%

Cechy te są zarazem mało wrażliwe na zmiany jasności kontrastu i ostrości obrazów.

## 8.2 Niejednorodność przestrzenna

### 8.2.1 Aspekty niejednorodności przestrzennej obrazu

Niejednorodność przestrzenna, rozumiana jako różnice cech w poszczególnych obszarach obrazu, jest istotą zawartości informacyjnej, w której skład wchodzi jednak także zakłócenia i błędy. Idealnie jednorodny jest obraz całkowicie pusty lub całkowicie wypełniony jednym kolorem, a niejednorodność może świadczyć zarówno o nierównomiernym oświetleniu, jak i o istnieniu interesujących obiektów, których dotyczyć ma analiza. Różne czynniki powodujące niejednorodność występują równocześnie co komplikuje proces analizy obrazu. Oprócz tego, zależnie od celów analizy i postawionych hipotez, ta sama niejednorodność może być uznana za sygnał użyteczny lub za zakłócenie.


Ze względu na **źródło** powstania niejednorodności można więc rozróżnić:

- **niejednorodność rzeczywistą**, która sygnalizuje obecność obiektów lub obszarów obrazu istotnych z punktu widzenia celów analizy i wynikających z własności przedmiotu wizualizowanego, oraz
- **niejednorodność akwizycyjną** wynikającą z takich błędów akwizycji jak:
  - nieodpowiednie powiększenie
  - nierównomierne oświetlenie pola obrazu
  - nierównomierna ostrość w polu obrazu
  - artefakty (na przykład drobiny kurzu w układzie optycznym)

Określenie przyczyny niejednorodności należy zazwyczaj do badacza, jednak metodami komputerowymi można dokonać oceny stopnia niejednorodności obrazu. Stwierdzenie zmian niejednorodności lub jej znacznego poziomu może być ważnym sygnałem stymulującym konieczność sprawdzenia przyczyny tej niejednorodności.


### 8.2.2 Niejednorodność przestrzenna a transformata Fouriera

Zakładając, że obrazy niejednorodne przestrzennie zawierają przeważnie duże quasi-objekty typu „plama”, można przypuścić, że w dziedzinie częstotliwościowej powinny charakteryzować się przewagą niskich częstotliwości. Stąd wyniknęła próba przetestowania przydatności transformaty Fouriera do oceny niejednorodności przestrzennej obrazów.




Rys. 4.6. Macierz logarytmów amplitud transformaty Fouriera obrazu TB2 i jej przekątna

Rys. 4.6 przedstawia macierz  $F$  logarytmów amplitud transformaty Fouriera obrazu TB2 oraz wykres wartości jej przekątnej – uzyskane programem [P55]. Porównanie wykresów dla obrazów jednorodnych i niejednorodnych - zarówno szarych jak binarnych - nie wykazało jednak oczekiwanych istotnych różnic co pokazuje Rys. 4.7 i Rys. 4.8.



Rys. 4.7. Wykres przekątnej macierzy  $F$  dla obrazu niejednorodnego



Rys. 4.8. Wykres przekątnej macierzy  $F$  dla obrazu jednorodnego

Jak widać – dla obrazów jednorodnych wykres przekątnej macierzy  $F$  jest nieco bardziej spłaszczony jednak – jak stwierdzono po obserwacji wykresów dla wielu innych obrazów - różnice nie są na tyle duże aby rokowały możliwość adekwatnej oceny niejednorodności przestrzennej. Jest to też zgodne z ogólną oceną małej przydatności transformat Fouriera w analizie obrazów zamieszczonej w książce [38].

W związku z powyższym – w kolejnych podrozdziałach – zdefiniowano własne miary niejednorodności.

### 8.2.3 Liczbowe miary niejednorodności


Przyjęto, że **miary niejednorodności** obrazu  $X$  muszą być definiowane przy uwzględnieniu;

- określonego podziału obrazu na  $n$  podobrazów (okien) o jednakowych wymiarach,
- określonej cechy  $Cx$  obrazu ,
- określonej statystycznej miary  $R$  rozrzutu wartości deskryptora danej cechy w zbiorze  $n$  podobrazów – za domyślną miarę rozrzutu przyjęto odchylenie standardowe.

Tak więc niejednorodność charakteryzując obraz jest zarazem własnością pewnej cechy tego obrazu czyli **meta-cechą**.

W pracy [W6] zaproponowano miarę niejednorodności opartą na odchyleniu standardowym zbioru wartości cechy wyznaczanych dla ćwiartek obrazu (Rys. 4.9). Uogólniając nieco przedstawione tam propozycje można zdefiniować kilka różnych miar niejednorodności  $NjnR(Cx, X)$ , różniących się liczbą  $n$  uwzględnianych podobrazów obrazu  $X$ .

Dla umożliwienia porównywania zarówno natężenia poszczególnych cech jak i ich niejednorodności w polu obrazu korzystne jest **unormowanie** zarówno cech jak i miar niejednorodności do zakresu  $\langle 0; 1 \rangle$ .



Rys. 4.9. Badanie niejednorodności na podstawie ćwiartek obrazu

Dla spełnienia warunku unormowania cech dotyczących jasności pikseli – jak średnia czy mediana - obraz musi być przeskalowany z zakresu  $\langle 0; 255 \rangle$  do zakresu  $\langle 0; 1 \rangle$ . W Matlabie służy do tego funkcja  $im2double()$ .

Dla przykładu konstruję poniżej miary niejednorodności obrazu  $X$  względem cech: średnia jasność (*mean*) oraz mediana jasności (*median*).

W przypadku analizowania jasności ćwiartek obrazu, maksymalna niejednorodność wystąpi jeśli dwie ćwiartki będą białe (jasność 1), a dwie czarne (jasność 0). Wektor cechy  $Cx$  zarówno dla mediany jak średniej jasności jest wówczas równy:

$$Cx = [1, 0, 1, 0];$$

Wariancja i odchylenie standardowe tego wektora cech wynoszą:

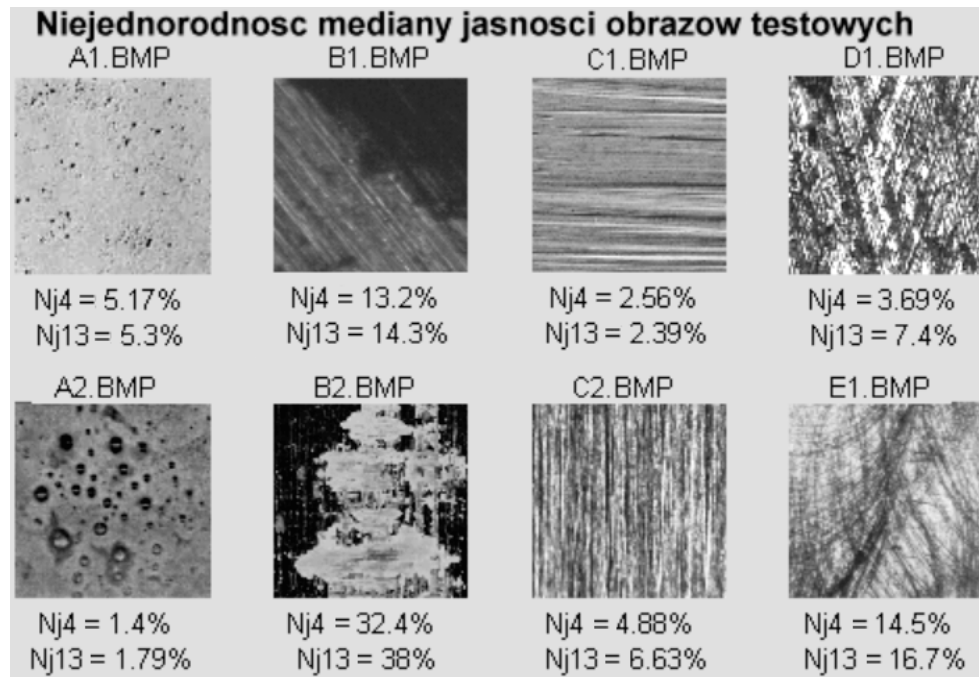
$$\text{var}(Cx) = (0.5)^2 = 0.25; \quad \text{std}(Cx) = 0.5$$

Dla takiego obrazu o maksymalnej niejednorodności, jej miary mają być równe 1 stąd, przy zastosowaniu odchylenia standardowego, ćwiartkowa miara niejednorodności obrazu  $X$  względem cechy „średnia jasność” lub cechy „mediana jasności” jest zdefiniowana wzorem:

$$Nj4(Cx, X) = 2 * \text{std}(Cx) \tag{4.1}$$




Przykładowo niejednorodność mediany jasności pikseli w zbiorze ćwiartek obrazu  $X$  czyli „niejednorodność ćwiartkową mediany”  $Nj4(\text{median}, X)$  - wyznaczono dla obrazów testowych i przedstawiono na Rys. 4.10.



Rys. 4.10. Ocena niejednorodności cechy „mediana jasności” obrazów testowych

Na tym samym rysunku zamieszczono też – dla porównania – wartości innej, nieco precyzyjniejszej miary niejednorodności – nazwanej  $Nj13R$  - wyznaczanej dla zbioru trzynastu podobrazów wynikającego z dwu niezależnych podziałów, a mianowicie do zbioru ćwiartek dołączany jest zbiór otrzymany przez podział obrazu na 9 równych części.

Dzięki temu że obraz jest dzielony raz na parzystą liczbę części, a drugi raz na liczbę nieparzystą – uniknięto ryzyka fałszywych ocen wynikających z cyklicznej powtarzalności motywów obrazu. Cechę  $Nj13(\text{median}, X)$  - niejednorodność median dla zbioru 4+9 podobrazów wyznacza funkcja o tej samej nazwie, załączona w [S1] jako program [P23].



Rys. 4.11. Porównanie miar niejednorodności mediany dla obrazów o maksymalnej niejednorodności

Porównanie miar niejednorodności  $Nj4$  i  $Nj13$  dla cechy „mediana jasności pikseli” pokazuje Rys. 4.11. Na wszystkich trzech obrazach połowa obszaru jest biała i połowa czarna. Jak widać, miara trzynastkowa jest znacznie bardziej stabilna, podczas gdy miara ćwiartkowa wykazuje znacznie większe wahania.

Podobne rezultaty uzyskano dla miar niejednorodności średniej jasności dla tych samych trzech obrazów, a mianowicie wartości miary ćwiartkowej  $Nj4(mean,X)$  wynoszą: 0,94; 0,67; 0,61, a wartości miary trzynastkowej  $Nj13(mean,X)$  wynoszą: 0,84; 0,78; 0,82.

Zmniejszyć niejednorodność można stosując:

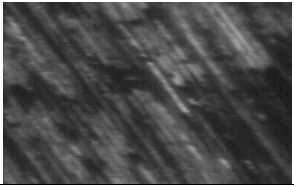
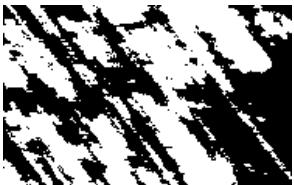

- a) odpowiednie dobranie powiększenia i kadru obrazu
- b) filtrację usuwającą składowe o niskiej częstotliwości przestrzennej

W seriach obrazów w których obserwowano znaczne zmiany wielkości jednego czy kilku obiektów typu "plama" i związane z tym zmiany niejednorodności - zaproponowano w publikacji [W6] **wykorzystanie niejednorodności obrazu** jako cechy użytecznej dla scharakteryzowania danej sekwencji.

W przypadku uznania niejednorodności za cechę niepożądaną, zaproponowano zastosowanie pewnego rodzaju **filtracji przestrzenno-częstotliwościowej** - opisanej niżej - jako jednej z możliwych metod ograniczania tej niejednorodności [W6].

## 8.2.4 Jednorodność obrazów a filtracja medianowa

Przy analizie zmian powierzchni powodowanych tarciami trzeba decydować o istotności różnych elementów obrazu, na przykład - czy istotniejsze są cechy dużych plam czy drobnych motywów obrazu. Po podjęciu tego rodzaju decyzji korzystne jest zastosowanie filtracji w zakresie częstotliwości przestrzennych obrazu.

Obraz oryginalny $X=E\_020.BMP$ :		Niejednorodność obrazu względem cech $Dx, Dy$ dla zbioru ćwiartek obrazu:
Obraz po wyrównaniu histogramu i binaryzacji z progiem 127		$Nj4(Dx,X)= 17,5\%$ $Nj4(Dy,X)= 17,4\%$
Obraz po pasmowej filtracji medianowej (5, 50) i binaryzacji z progiem 127		$Nj4(Dx,X)= 7,2\%$ $Nj4(Dy,X)= 6,3\%$

Rys. 4.12. Przetwarzanie wstępne obrazów i jego wpływ na jednorodność obrazów

Przy pomocy pasmowej filtracji medianowej można z jednej strony uzyskać zmniejszenie poziomu szumów – filtrując częstotliwości najwyższe, a z drugiej - wyeliminować

największe obiekty typu "plama" – zmniejszając niejednorodność obrazu. Jak przy każdej filtracji, należy przy tym rozważyć możliwość utraty istotnych informacji.

Na Rys. 4.12 pokazano omawiane w pracy [W6] porównanie dwu metod przetwarzania wstępnego obrazów mającego na celu uwydatnienie ciemnych plam, a mianowicie:

- poprawę kontrastu przez wyrównywanie histogramu oraz binaryzacja z progiem 127;
- filtrację medianową pasmową z zastosowaniem okien medianizacji o rozmiarach 5x5 i 50x50 pikseli, a po niej zastosowanie przekształceń jak w (a)

Zastosowana pasmowa filtracja medianowa wyeliminowała na obrazie składowe o niskiej częstotliwości przestrzennej (duże plamy) a także składowe o najwyższych częstotliwościach uznane za szum. Przykładowa realizacja tej filtracji w Matlabie jest następująca:

```
A1 = medfilt2(A,[5 5]); AL = medfilt2(A,[50 50]);  
B = uint8(double(A1) + 127 - double(AL));
```

gdzie:

- $A$  – obraz pierwotny;
- $A1$  – obraz po filtracji medianowej szumu;
- $AL$  – niskoczęstotliwościowa składowa obrazu;
- $B$  – binarny obraz wynikowy;
- $medfilt2(obraz, [D D])$  – funkcja medianizacji otoczeń pikseli o rozmiarach  $D*D$
- $uint8$  oraz  $double$  – funkcje konwersji typów zmiennych

Zastosowana filtracja zmniejszyła radykalnie niejednorodność obrazu względem cech:  $D_x$  = "średnia długość poziomych pasm czarnych" oraz  $D_y$  = "średnia długość pionowych pasm czarnych" z wartości ok.17% na ok. 6-7%.

Tego rodzaju filtracja może być dopuszczalna przy badaniu anizotropii obrazu natomiast nie może być stosowana przed wyznaczeniem pola lub rozmiarów plam.

## 8.3 Anizotropia i ukierunkowanie elementów obrazów

### 8.3.1 Wprowadzenie podstawowych pojęć

Ślady tarcia lub obróbki ubytkowej widoczne na obrazach tribologicznych mają często charakter ukierunkowany, inaczej mówiąc: morfologia tych obrazów wykazuje anizotropię.

Anizotropia obrazu jest odzwierciedlana przez cechy ilościowe w różnym stopniu i to jedynie przez cechy kierunkowe określone w podrozdziale 3.3. Przykładowo cechy wyznaczane z histogramu obrazu - jako bezkierunkowe - nie wykazują anizotropii.

Anizotropię można więc analizować tylko **względem danej cechy** i jako własność poszczególnych cech anizotropia jest **meta-cechą**.

Cechy kierunkowe obrazu wyznaczone są według **kierunku skanowania** macierzy obrazu. Określa go **kąt skanowania**  $\psi$  mierzony od poziomej krawędzi obrazu. Analizowaniu obrazu wzdłuż wierszy odpowiada więc kąt  $\psi=0^\circ$ , a analizie wzdłuż kolumn  $\psi=90^\circ$ .

Efekt równoznaczny ze zmianą kąta  $\psi$  można osiągnąć przez obracanie obrazu w przeciwnym kierunku o kąt  $\phi = -\psi$ , aczkolwiek obraz musi być wówczas zmniejszony przez okrojenie do horyzontalnie ustawionego prostokąta.

W celu zbadania anizotropii danej cechy  $Cx$  obrazu  $X$  wyznaczano **rozkład kierunkowy**  $Cx(X, \psi)$  tej cechy w funkcji kąta  $\psi$ .

Anizotropia obrazu  $X$  względem cechy  $Cx$  jest miarą zakresu zmienności rozkładu kierunkowego tej cechy  $Cx(X, \psi)$ .

Badana cecha może wykazywać zwiększone wartości (maksima lokalne) dla jednego lub wielu kierunków. **Dominującym kierunkiem**  $Dir1$  obrazu  $X$  względem danej cechy  $Cx(X, \psi)$  - nazywany będzie kątem skanowania  $\psi$  przy którym cecha wykazuje maksimum globalne:

$$Dir1 = \psi1: Cx(X, \psi1) = \max(Cx(X, \psi)) \quad (4.2)$$

Obraz dla którego dana cecha posiada kierunek dominujący  $Dir1=0^\circ$  nazywany będzie **horyzontalnym** względem tej cechy lub **wertykalnym** jeśli  $Dir1=90^\circ$ .

Zazwyczaj – jeśli wykryto jeden kierunek dominujący – wskazana jest **korekta kadru przez obrócenie obrazu** w taki sposób aby kierunek dominujący był równoległy do krawędzi obrazu, dzięki czemu otrzymujemy obraz horyzontalny lub wertykalny.

W przypadku uznania za istotne dwu kierunków – kierunek  $Dir1$  odpowiadający maksimum globalnemu nazywano „pierwszym dominującym”, a następny  $Dir2$  – odpowiadający największemu z kolejnych maksimów lokalnych ale niemniejszym niż  $Cx(X, Dir1)/5$  – „drugim dominującym”.

Aby uniknąć wykrywania „mikromaksimów” lokalnych przyjęto, że uwzględniane będą maksima lokalne definiowane względem pewnego otoczenia  $d$  badanego punktu rozkładu kierunkowego  $Cx(X, \psi)$ . W prezentowanych dalej przykładach przyjęto  $d=4$ .

### 8.3.2 Proponowane miary anizotropii i ortotropii

Poniżej zaproponowano **miary anizotropii** obrazu  $X$  względem cechy  $Cx$  znormalizowanej do zakresu  $\langle 0;1 \rangle$ , skonstruowane w oparciu o różnicę lub iloraz wartości minimum oraz maksimum rozkładu kierunkowego  $Cx(X, \psi)$  tej cechy. Przyjęto, że zakres wartości proponowanych miar powinien mieścić się w przedziale  $\langle 0, 1 \rangle$  lub  $\langle -1, 1 \rangle$ .

Najprostsza **różnicowa miara anizotropii** – znormalizowana do zakresu  $\langle -1;1 \rangle$  - to:

$$Anizo\_r(X, Cx) = \max(Cx(X, \psi)) - \min(Cx(X, \psi)) \quad (4.3)$$

Po normalizacji do zakresu  $\langle 0;1 \rangle$  uzyskuję **różnicową dodatnią miarę anizotropii**:

$$Anizo\_d(X, Cx) = (1 + \max(Cx(X, \psi)) - \min(Cx(X, \psi))) / 2 \quad (4.4)$$

Kolejną, zdefiniowaną niżej miarę ilorazową, nazwano **hiperboliczną miarę anizotropii** obrazu  $X$  względem cechy  $C$ :

$$Anizo\_h(X, Cx) = 1 - \min(Cx(X, \psi)) / \max(Cx(X, \psi)), \text{ dla: } \psi \in [0^\circ; 180^\circ] \quad (4.5)$$

Wyznaczanie anizotropii na podstawie charakterystyk kierunkowych poszczególnych cech jest nieco czasochłonne, więc dla obrazów horyzontalnych względem danej cechy, dla których  $\max(Cx(X, \psi)) = Cx(X, 0^\circ)$ , oraz przy założeniu, że  $\min(Cx(X, \psi)) \approx Cx(X, 90^\circ)$  zdefiniowano prostsze obliczeniowo **miary ortotropii**:

$$Orto\_r(X, Cx) = Cx(X, 0^\circ) - Cx(X, 90^\circ) \quad (4.6)$$

$$Orto\_d(X, Cx) = (1 + Cx(X, 0^\circ) - Cx(X, 90^\circ))/2 \quad (4.7)$$


$$Orto\_h(X, Cx) = 1 - Cx(X, 90^\circ) / Cx(X, 0^\circ) \quad (4.8)$$

Wyznaczanie miar ortotropii może wymagać obrócenia obrazu tak, aby stał się obrazem horyzontalnym. Dla obrazów wertykalnych, we wzorach powyższych należy zamienić miejscami wartości  $0^\circ$  i  $90^\circ$ .

### 8.3.3 Generowanie zbioru obrazów obróconych

Jak wspomniano - ocena anizotropii obrazu  $X$  a także zdolności danej cechy  $Cx(X)$  wyrażenia tej anizotropii jest dokonywana na podstawie kierunkowego rozkładu badanej cechy  $Cx(X, \psi)$  dla kąta skanowania  $\psi$  zmienianego w zakresie od  $0^\circ$  do  $180^\circ$ , lub – co jest znacznie prostsze – dla „zbioru obrazów obróconych”, otrzymywanych przez obracanie wycinka pierwotnego obrazu o kąt obrotu  $\phi \in \langle 0^\circ, -180^\circ \rangle$  i stałej wartości kąta skanowania  $\psi = 0^\circ$ .

Matlab oferuje dwie metody obracania obrazu. W pierwszej z metod nie są przycinane narożniki po obrocie obrazu wskutek czego obraz zwiększa rozmiary gdyż nowe krawędzie prowadzone są przez narożniki obróconego obrazu. Druga metoda utrzymuje stałe rozmiary obrazu wynikowego gdyż narożniki są obcinane po obróceniu, jak na Rys. 4.13a.



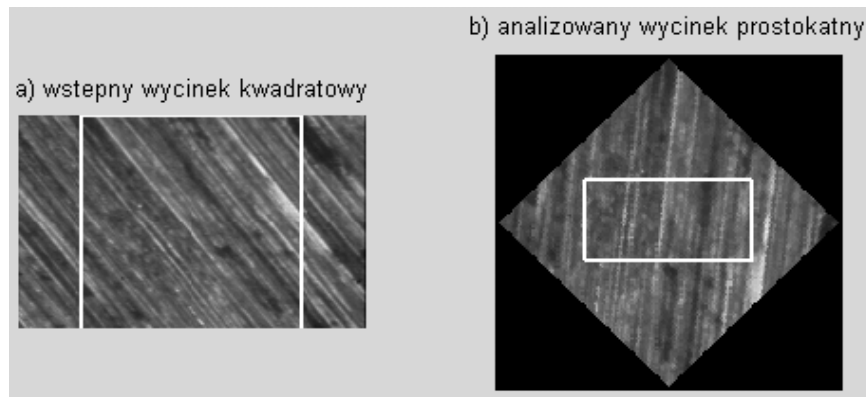
Rys. 4.13. Pobieranie wycinka kołowego

W obu przypadkach po obróceniu obrazu prostokątnego lub kwadratowego (Rys. 4.13a) w narożnikach powstają czarne trójkątne obszary (Rys. 4.13b), które przeszkadzałyby w analizie dlatego badania ograniczono do pobieranego z obrazu wycinka.

Przy badaniu anizotropii stosowano dwie metody pobierania wycinka obrazu do analizy. Jedną z nich – realizowaną programem **Anizo\_kolo** - ilustruje Rys. 4.13. W metodzie tej kwadratowy wycinek pobierany z centrum (a) mnożono przez maskę binarną co w efekcie dawało kołowy kształt analizowanego wycinka (c), o stałej zawartości nie zmieniającej się przy obracaniu.

Drugą metodą - realizowaną programem **Anizo** - było pobieranie z centrum obrazu wycinka prostokątnego o stałych rozmiarach (Rys. 4.14), przy czym - obracanie obrazu powodowało zmiany zawartości tego wycinka.

Wyznaczanie anizotropii obrazów względem różnorodnych cech z zastosowaniem obu tych metod pozwalało stwierdzić, że dla niektórych cech była lepsza metoda pierwsza, a dla innych druga metoda pobierania wycinka obrazu.



Rys. 4.14. Pobieranie wycinka prostokątnego

W kolejnych podrozdziałach przedstawiono wyniki testowania przydatności wybranych cech dla oceny anizotropii i wyznaczania kierunków dominujących tekstury obrazu. Kolejno przetestowano cechy wyznaczone z analizy par pikseli, analizy macierzy pasm oraz statystyk wierszy lub kolumn macierzy obrazu.

### 8.3.4 Ocena anizotropii na podstawie zmienności wierszy i kolumn


Zdefiniowane w 1.1.2 deskryptory zmienności wierszy i kolumn - wyznaczone na podstawie analizy par pikseli - były podstawą do ocen anizotropii i ukierunkowania motywów obrazów opisanych poniżej.

#### 8.3.4.1 Anizotropia unormowanej różnicy zmienności kolumn i wierszy

Na podstawie opisanych w 1.1.2 deskryptorów ZW oraz ZK, zdefiniowano cechę o nazwie „unormowana różnica zmienności kolumn i wierszy”:

$$URZKW = Anizo\_d(X, ZWK) = (1 + ZK - ZW) / 2 \quad (4.9)$$

gdzie ZW i ZK wyznaczano funkcją [P26]:  $[ZW, ZK] = ZWK(\text{Obraz}, 3, 10)$




Rys. 4.15. Anizotropia i kierunki główne względem cechy URZKW bez filtracji


Cecha ta należy do cech kierunkowych więc może być podstawą do oceny anizotropii i ukierunkowania tekstury obrazu. Rozkład kierunkowy tej cechy pokazuje Rys. 4.15. War-

tość anizotropii wynosi ok. 0,55, a kierunek główny to  $Dir1=129^\circ$ .

Po filtracji szumu i zmianie wartości argumentów funkcji ZWK ( $d=1$ ,  $prog=5$ ) uzyskano gładzy przebieg rozkładu kierunkowego (Rys. 4.16), natomiast w przypadku maksymalnego wzmocnienia kontrastu (operacją wyrównywania histogramu) wartość anizotropii spadła do 0,383.




Rys. 4.16. Anizotropia i kierunki główne względem cechy URZKW po filtracji



Rys. 4.17. Próba detekcji dwu kierunków tekstury przy pomocy cechy URZKW ( $d=1$ ,  $prog=5$ )

Kolejne rysunki pokazują wyniki testowania cechy dla wykrywania dwu kierunków tekstury obrazu.



Rys. 4.18. Iloraz  $Zk/Zw$  nie pozwala wykryć dwu kierunków rys na obrazie.

Okazało się, że testowana cecha nie ma wystarczającej rozdzielczości kątowej dla prawidłowego wykrycia dwu kierunków nawet na sztucznie wygenerowanych obrazach (Rys. 4.17). Jeszcze gorzej jest dla obrazów rzeczywistych powierzchni co widać na Rys. 4.18. pokazującym rozkład kierunkowy nieco innej cechy, bazującej na  $Z_w$  i  $Z_k$ .

### 8.3.4.2 Ortotropia względna zmienności wierszy i kolumn

Kolejną badaną cechą była różnica zmienności wierszy i kolumn przyjęta za miarę ortotropii względnej ( $O_w$ ) obrazu wyznaczanej bez jego obracania, dla aktualnego kadru obrazu.

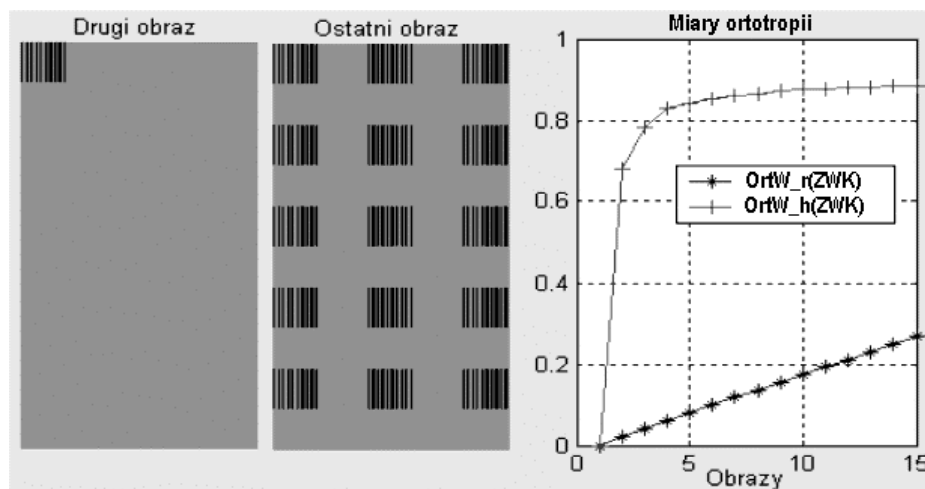
$$OrtW_r(X, ZWK) = ZW - ZK \quad (4.10)$$

Wartości tak zdefiniowanej miary są **unormowane** do przedziału  $[-1; 1]$  i **nie zależą od rozmiarów** obrazu, co pokazano na Rys. 4.19. Wartości ujemne odpowiadają obrazom horyzontalnym a dodatnie – wertykalnym.

Dodatkowo **miara ta jest liniowa** to znaczy zmienia się proporcjonalnie do obszaru obrazu wykazującego ortotropię jeśli tło całego obrazu jest jednobarwne. Właściwość tą pokazano na Rys.7.20, na przykładzie badania sekwencji piętnastu obrazów na których stopniowo wzrasta liczba pionowych motywów ortotropowych.



Rys. 4.19. Miara ortotropii:  $OrtW_r(X, ZWK)$



Rys. 4.20. Testowanie miar ortotropii na wygenerowanych obrazach z tłem szarym

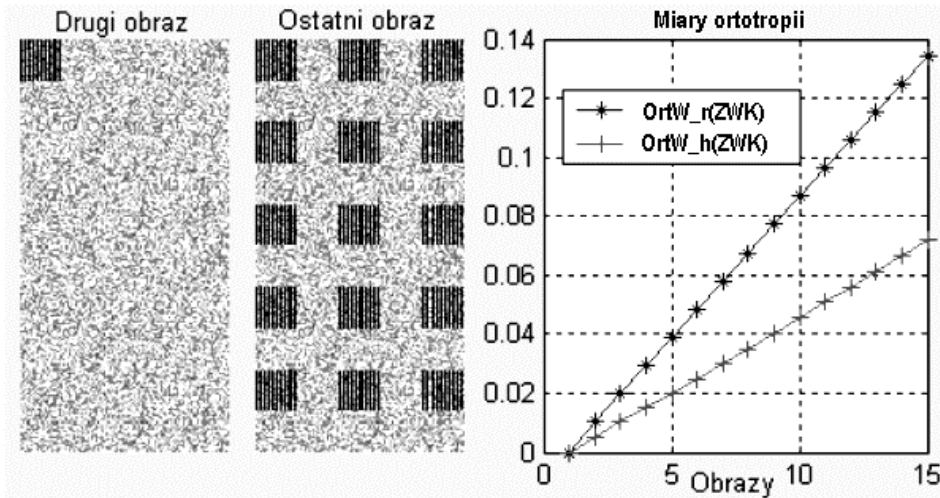


Maksymalna ortotropia względna – osiągnięta na ostatnim obrazie tej sekwencji – jest w przybliżeniu równa 0,3 czyli stosunkowi pola wszystkich motywów ortotropowych do pola obrazu ( $0,5 \cdot 3/5$ ).

Dla wykrywania niewielkich ortotropii korzystniejsza jest inna miara, której czułość wykazuje przebieg hiperboliczny:

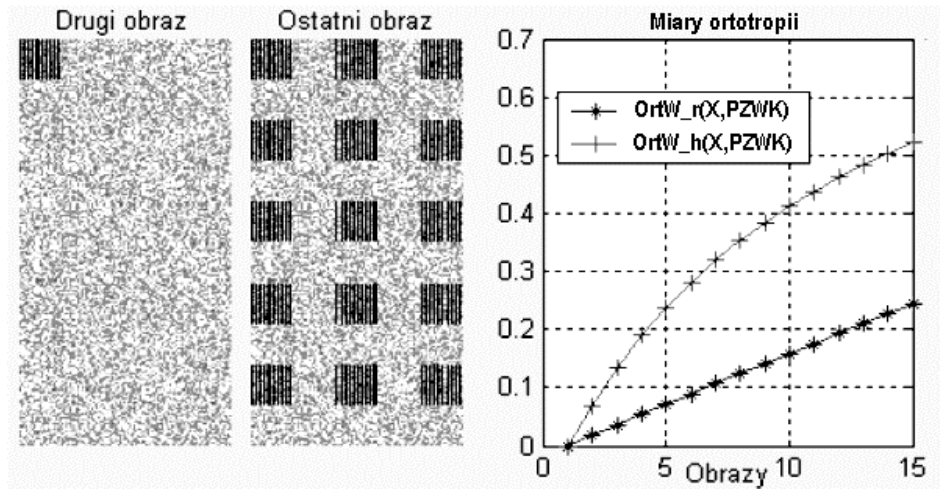
$$OrtW_h(X, ZWK) = Lw * Lk * (ZW - ZK) / (ZW + ZK) \quad (4.11)$$

Miara ta początkowo wzrasta szybko już przy nieznacznym przyroście ortotropii, a następnie rośnie coraz wolniej. Jest ona również unormowana do zakresu [-1; 1], przy czym wartości ujemne występują przy przewodze elementów poziomych obrazu, a dodatnie przy przewodze pionowych.



Rys. 4.21. Testowanie miar ortotropii względnej na wygenerowanych obrazach z tłem losowym

W przypadku gdy tłem jest szum losowy – jak na Rys. 4.21 - ortotropia względna znacznie spada gdyż rośnie ogólna zmienność zarówno wierszy jak i kolumn.



Rys. 4.22. Miary ortotropii względnej oparte na progowej zmienności wierszy i kolumn

Co ciekawe – czułość miary hiperbolicznej spada w tym przypadku tak radykalnie, że praktycznie jej przebieg w przedstawionym przedziale można uznać za w przybliżeniu liniowy.

Dla tego typu obrazów – bardziej podobnych do obrazów tribologicznych – korzystniejsze są miary oparte na progowej zmienności wierszy i kolumn ( $p$ =próg):

$$OrtW_r(X,PZWK) = (PZW-PZK)/(Lw*Lk) \quad (4.12)$$

$$OrtW_h(X,PZWK) = (PZW-PZK)/(PZW+PZK) \quad (4.13)$$

Jak pokazuje Rys. 4.22, przy zastosowanym w tym przypadku progu  $p=100$ , wartości miary  $OrtW_r(X,PZWK)$  zbliżyły się do wartości uzyskiwanych przy tle szarym, a miara hiperboliczna  $OrtW_h(X,PZWK)$ , mimo znacznego wzrostu nie osiągnęła analogicznych wartości. Rysunki i wykresy wygenerowano programem [P35], wykorzystującym funkcje: [P36] i [P37], których parametrami są: obraz  $X$  i próg  $p$ .

### 8.3.4.3 Ilorazowa ortotropia względna tekstury binarnej

Wykorzystując zdefiniowane w 2.2.2 deskryptory średniej długości pasm  $D_x$ ,  $D_y$  lub liczby pasm poziomych  $N_x$  i pionowych  $N_y$  zdefiniowano z kolei współczynnik  $N_{xy}$ , który po uwzględnieniu definicji zamieszczonych w 4.3, a wprowadzonych chronologicznie później, można nazwać **ilorazową ortotropią względną tekstury binarnej**:

$$N_{xy} = D_y/D_x = N_x/N_y \quad (4.14)$$

Współczynniki  $N_x$ ,  $N_y$  są dla obrazów binarnych odpowiednikami cech  $Z_w$ ,  $Z_k$ .

Cechę  $N_{xy}$  nazwano ortotropią względną ponieważ jest wyznaczana względem kierunków krawędzi kadru obrazu niezależnie od ukierunkowania motywów widocznych na obrazie. W przypadku gdy kierunek główny motywów obrazu jest zgodny z poziomą krawędzią kadru obrazu wówczas  $N_{xy}$  jest pewną (nieunormowaną) miarą ortotropii bezwzględnej. W związku z tym na ogół stosowano takie kadrowanie lub obracanie obrazów aby pasma wynikające z kierunku tarcia były równoległe do krawędzi obrazu.

### 8.3.5 Zastosowanie cech wyznaczanych z macierzy $R$

Intuicyjnie wydaje się, że cechy wyznaczane na podstawie analizy pasm pikseli o jednakowych odcieniach – zamiast analizy par pikseli - będą skuteczniejsze dla wykrywania anizotropii obrazów wynikającej z ukierunkowanego tarcia badanych powierzchni. W związku z tym przetestowano przydatność opisanych w podrozdziale 1.1.2. cech wyznaczanych z macierzy długości pasm  $R$  (*Run Length Matrix*) do oceny anizotropii obrazów tribologicznych oraz pomiaru kierunków głównych tekstur tych obrazów.

W pracy [W19] przedstawiono wyniki badań nad wykorzystaniem opisanych w rozdziale 1.1.2. cech o nazwach:

- 1) **SRE** – *Short Run Emphasis inverse moment* - odwrotny moment uwydatnienia krótkich pasm
- 2) **LngREmph** - *Long Run Emphasis moment* - moment uwydatnienia długich pasm
- 3) **RLNonUni** - *Run Length Nonuniformity* - niejednorodność pasm
- 4) **FIR** - *Fraction of image in runs* - część obrazu w pasmach

Macierz  $R$  wyznaczano funkcją [P27] wyłącznie dla kąta skanowania  $\psi = 0^\circ$ , a zależność wartości cech od kierunku pasm pikseli uzyskano przez obracanie badanych obrazów

w zakresie  $\varphi = 0^\circ, \dots, -180^\circ$ . Rezultat tych operacji był więc identyczny jak dla zmian kąta skanowania:  $\psi = 0^\circ, \dots, 180^\circ$

Istotnym zagadnieniem było znormalizowanie zakresu wartości cech do przedziału  $\langle 0; 1 \rangle$ . Cechy **SRE** oraz **FIR** nie wymagały normalizacji, natomiast pozostałe cechy (2) i (3) znormalizowano jak niżej:

$$LRE = \left( \sum_{g=0}^{Ng-1} \sum_{j=1}^{Nr} j^2 \cdot R_{g,j} \right) / c / Lk^2 \quad (4.15)$$

$$RLN = \left( \sum_{j=1}^{Nr} \left( \sum_{g=0}^{Ng} R_{g,j} \right)^2 \right) / c / N \quad (4.16)$$

Wstępne badania wykazały, że jedynie cecha **LRE** osiąga maksimum przy kącie  $\psi$  zgodnym z dominującym kierunkiem pasm tekstury obrazu, a pozostałe cechy osiągają wówczas minima więc postanowiono wyznaczać ich dopełnienia do 1. Ostatecznie wyznaczano więc (programem [P28]) następujące cztery cechy:

$$C1 = 1 - SRE; \quad C2 = LRE; \quad C3 = 1 - RLN; \quad C4 = 1 - FIR \quad (4.17)$$

### 8.3.5.1 Badania w oparciu o obrazy sztuczne


Badania wrażliwości deskryptorów na anizotropię i ukierunkowanie tekstury obrazu przeprowadzono początkowo na kilku typach sztucznych obrazów wygenerowanych przy pomocy programów napisanych w Matlabie. Przykłady obrazów każdego z tych typów przedstawiono na Rys. 4.23, a mianowicie:

- Rys. 4.23.(a) „pasy a” - poziome, generowane programem [P29] z wykorzystaniem pełnego zakresu odcieni szarości
- Rys. 4.23.(b) „pasy b” - poziome o trzech odcieniach szarości (0, 120, 240)
- Rys. 4.23.(c) „pasy c” – poziome oraz pod kątem  $30^\circ$ , na tle czarnym, o losowo dobranej położeniach, długościach, szerokościach i odcieniach szarości [P30], [P31].


Badania przeprowadzono dla różnych wariantów generowanych obrazów a także dla wersji obróconych o określony kąt. Sposób badania zależności cech od ukierunkowania obrazu był następujący:

- przy zastosowaniu serii operacji obracania (w zakresie 0 do 180 stopni) oraz wycinania centralnego prostokątnego fragmentu (rys.1d) uzyskiwano serię obrazów o różnym ukierunkowaniu podłużnych pasów,
- dla każdego z tych obrazów wyznaczano macierz **RLM** oraz wartości wybranej cechy w funkcji kąta  $\psi$  oraz generowano wykresy tej funkcji,
- na podstawie wartości rozkładu kierunkowego danej cechy wyznaczano miarę anizotropii **An** oraz kąt ukierunkowania tekstury **Dir1**.

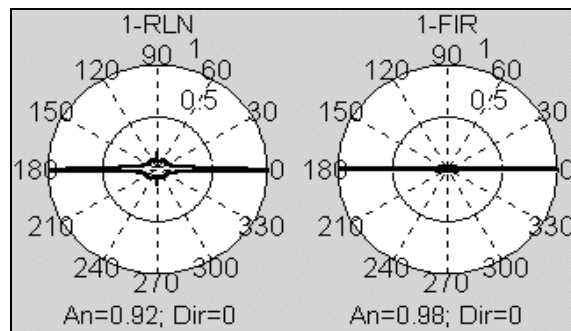
Wyniki badań dla obrazu „pasy a” z Rys. 4.23.a pokazano na Rys. 4.24 oraz Rys. 4.25. Są to wykresy biegunowe zmian badanych cech w funkcji kąta  $\psi$ . Wszystkie cechy wykazują wyraźną anizotropię osiągając ostre maksimum dla kątów  $0^\circ$  oraz  $180^\circ$  i prawidłowo wykazując ukierunkowanie tekstury obrazu.



Rys. 4.23. a), b), c) wygenerowane obrazy testowe. d) przetwarzanie




Rys. 4.24. Wykresy biegunowe zmian cech C1 i C2 obrazu „pasy a” w funkcji kąta skanowania  $\psi$ .




Rys. 4.25. Wykresy biegunowe zmian cech C2 i C3 obrazu „pasy a” w funkcji kąta skanowania  $\psi$ .

Pozostałe cechy również dają zadowalające wyniki dla tego typu obrazu.

Jednakże analiza obrazu „pasy b” - posiadającego tylko trzy odcienie szarości - dała wyraźnie różne wyniki. Rys. 4.26 oraz Rys. 4.27 przedstawiają zmienione kształty wykresów uzyskane dla trzech cech tego obrazu, podczas gdy **cecha C2 czyli LRE** ponownie okazuje się najlepszą cechą wykrywającą anizotropię obrazów.




Rys. 4.26. Wykresy biegunowe zmian cech C2 i C3 obrazu „pasy b” w funkcji kąta skanowania  $\psi$ .



Rys. 4.27. Cechy C3 i C4 obrazu „pasy b” w funkcji kąta skanowania  $\psi$


W związku z tym uznano cechę **LRE** za jedyną cechę - wyznaczaną z macierzy **R** - wartą dalszego badania pod względem przydatności do oceny anizotropii i ukierunkowania tekstury obrazów.



Rys. 4.28. Fałszywe maksimum dla kąta 90° oraz niedoszacowanie pasm o kierunku 30°

Rozkład kierunkowy cechy LRE dla obrazu „pasy c” zawierającego pasma o kierunkach 0 i 30 stopni wykazał jednak powstawanie fałszywego maksimum dla kierunku 90° i nadmierną reakcję cechy na kierunek poziomy przy zmniejszonej reakcji na pozostałe kierunki. Widać to wyraźnie na Rys. 4.28 gdzie maksimum dla pasm o kierunku 30° jest wielokrotnie mniejsze niż maksimum dla 0°.

Aby skorygować tę wadę postanowiono ominąć wyznaczanie fałszywych maksimum cechy LRE dla kierunku pionowego i poziomego - zmieniając ciąg wartości kąta skanowania na:  $\psi = -1^\circ, 1^\circ, 3^\circ, \dots, 179^\circ$ . Pozwoliło to znacznie poprawić wykrywalność drugiego kierunku anizotropii dla cechy LRE jak to pokazano na Rys. 4.29.



Rys. 4.29. Wykrywanie dwu kierunków anizotropii po korekcie zakresu kąta skanowania


Zarówno przedstawione wyżej wykresy jak wszystkie operacje przetwarzania i analizy przeprowadzono za pomocą własnych programów napisanych w Matlabie z wykorzystaniem podprogramów Image Processing Toolbox. Opracowano m.in programy do:

- generowania obrazów testowych [P29], [P30], [P31]
- wyznaczania macierzy RLM [P27]
- wyznaczania cech z macierzy RLM [P28]
- wyznaczania przebiegu danej cechy w funkcji kąta obrotu obrazu (i kąta skanowania obrazu) i prezentacji w postaci wykresu biegunowego oraz typu X-Y [P32]
- wyznaczania maksimum lokalnych danej cechy i kątów przy których występują [P33]
- wyznaczania zbiorczego wykresu anizotropii czterech cech obrazu [P34]


### 8.3.5.2 Pomiar anizotropii rzeczywistych obrazów powierzchni trących

W kolejnym etapie realizowanym w ramach pracy dyplomowej [6] zastosowano opracowaną metodę oraz programy komputerowe do oceny zmian anizotropii rzeczywistych powierzchni.

Analizowane dwie klasy obrazów. Pierwsza to cztery obrazy powierzchni umownie określonej jako "nowa" (Rys. 4.30a), a druga to cztery obrazy powierzchni "zużytej" (Rys. 4.30b). Fotografowanym obiektem była prostokątna próbka stalowa (o wymiarach 30mm x 30 mm x 5 mm) o szlifowanych powierzchniach. Zdjęcia wykonano mikroskopem optycznym (Mikro-Combi-Tester firmy CSM) w powiększeniu 50x. Powierzchnię "zużytą" (Rys. 4.30b) stanowiła ta sama próbka z dodatkowo naniesionymi zarysowaniami wykonanymi papierem ściernym o ziarnistości 600.




Rys. 4.30. Przykładowe obrazy: a) powierzchni "nowej", b) powierzchni „zużytej” (pow. 50x)



Rys. 4.31. Anizotropia obrazu powierzchni "nowej" względem cechy LRE

Rozkład kierunkowy cechy LRE i wartości anizotropii ( $An$ ) obrazów z Rys. 4.30 względem RLE pokazuje Rys. 4.31 i Rys. 4.32. Pomiar anizotropii cechy LRE pozwala rozróżnić obie klasy obrazów gdyż średnia wartość anizotropii maleje przeszło dwukrotnie.



Rys. 4.32. Anizotropia obrazu powierzchni "zużytej" względem cechy LRE

Jako miernik zdolności dyskryminacyjnej cechy LRE dla badanych klas obrazów wy-

znaczono współczynnik Fisher'a  $F_c$  opisany w rozdziale 1.2.8 . Wartość tego współczynnika wyniosła:  $F_c = 8.4$

Oceniając przydatność cechy LRE warto zwrócić uwagę na fakt, że dla obrazu z Rys. 4.30a wartość anizotropii cechy LRE wynosi jedynie ok. 0,15 podczas gdy wzrokowa ocena tego obrazu pozwala stwierdzić anizotropię bliską maksymalnej. Dla obrazu z Rys. 4.30b anizotropia cechy LRE spada natomiast poniżej 0,07.

Warto te wyniki skonfrontować z radykalnie lepszymi wynikami przedstawionymi w p.4.3.6, uzyskanymi dla cechy UDSW. Dla tych samych obrazów anizotropia zamiast 0,15 i 0,07 osiąga wartości rzędu 0,95 i 0,9.

Jak więc widać cecha  $LRE$  - jedyna brana pod uwagę z cech wyznaczanych z macierzy długości pasm  $R$  - jest mało przydatna do oceny anizotropii i ukierunkowania elementów tekstury obrazów.

### 8.3.6 Cechy wierszy obrazu - UDSW, UDMedW, UMxDW

Przetestowane w poprzednich rozdziałach cechy - częściowo oparte na znanych z literatury charakterystykach obrazów teksturowych - wykazały niezadowalającą przydatność dla oceny anizotropii i detekcji kierunków głównych obrazów tribologicznych. Dlatego kolejne badania skoncentrowano na badaniu przydatności statystyk wierszy - w oparciu o wstępnie przebadane w rozdziale 5.2.2 charakterystyki wierszy i kolumn.


Pierwszą z badanych cech była cecha nazwana przez autora **UDSW** - „**unormowana dewiacja średnich z wierszy**” - wyznaczana z obrazu  $X$  bardzo łatwo bo przy pomocy standardowych funkcji następującym wzorem:

$$UDSW = 2 * std(mean(X'), I) \quad (4.18)$$

gdzie:  $std(x, I)$  - odchylenie standardowe z populacji  $x$   
 $X'$  - transponowana macierz obrazu  
 $mean(X)$  - wektor średnich z kolumn macierzy  $X$


Cecha ta, w połączeniu z pobieraniem wycinka prostokątnego, okazała się **najczulsza** z przetestowanych, zarówno przy ocenie anizotropii jak i detekcji kierunków głównych tekstury obrazu.

Rozkład kierunkowy cechy UDSW dla obrazu z Rys. 4.30b o dwu kierunkach głównych pokazuje Rys. 4.33, a Rys. 4.34 pokazuje wyniki dla obrazu honowanej powierzchni cylindrów silnika spalinowego Perkins (zaznaczono pobierany wycinek).




Rys. 4.33. Anizotropia i kierunki główne obrazu z Rys. 4.30b w/g cechy UDSW






Rys. 4.34. Anizotropia i kierunki główne obrazu rzeczywistego w/g cechy UDSW



Rys. 4.35. Anizotropia i kierunki główne w/g cechy UDSW po zwiężeniu wycinka


Metoda staje się jeszcze bardziej czułą przy zmniejszeniu szerokości wycinka, jednak przebieg rozkładu kierunkowego wykazuje coraz większą zmienność losową (Rys. 4.35).



Rys. 4.36. Anizotropia i kierunki główne w/g cechy UDSW po filtracji górnoprzepustowej

Wynika to z faktu, że zmniejsza się część wspólna zbioru wycinków i po kolejnych obrotach wycinane są coraz to inne obszary obrazu. Minimalna szerokość wycinka musi być oczywiście większa niż podwójna szerokość wykrywanych pasm podłużnych obrazu.

Badanie obrazu pokazane na ostatnim rysunku, powtórzono dla obrazu przetworzonego przy zastosowaniu filtracji medianowej górnoprzepustowej (okno: 9x9) i wyrównywania histogramu. Mimo iż wizualnie kierunki pasm są wyraźniejsze to wyniki nie były lepsze, a składowa losowa wzrosła, jak to widać na Rys. 4.36




Rys. 4.37. Wykrywanie dwu kierunków elementów tekstury przy zastosowaniu wycinka kołowego

Zastosowanie filtracji dla usunięcia lub zmniejszenia składowej losowej rozkładu kierunkowego pogarsza rozdzielczość kątową metody. Składowa losowa maleje wprawdzie przy zastosowaniu metody pobierania stałego wycinka kołowego – dzięki większemu polu i stałości wycinka - co pokazuje Rys. 4.37, jednakże metodę tę w obecnej postaci dyskwalifikują błędne wyniki jakie uzyskuje się dla wielu obrazów.

A więc metodę wykorzystującą cechę **UDSW** oraz pobieranie wycinka prostokątnego należy uznać za najlepszą metodę wyznaczania anizotropii i kierunków głównych z metod analizowanych dotąd w tym rozdziale.


Przebadano również przydatność innych statystyk wierszy obrazu do wykrywania kierunków pasm obrazu.

Znane własności średniej pozwalają w przybliżeniu przewidzieć czułość metody na wykrywanie kierunku pasm o różnych odcieniach. Przykładowo na Rys. 4.38 kierunek pojedynczej białej kreski (82°) okazał się istotniejszy niż kierunek pasm szarego tła.




Rys. 4.38. Wrażliwość cechy UDSW na jasne pasma

Zastosowanie innej cechy oznaczonej jako **UDMedW** – „unormowana dewiacja median wierszy” pozwoliło prawidłowo wykryć kierunek szarych pasm tła (Rys. 4.39). Rozkład cechy posiada składową losową skutkującą szeregiem małych nieistotnych lokalnych maksimum (Rys. 4.39b), które usunięto (Rys. 4.39c) przy pomocy filtracji medianowej.



Rys. 4.39. Cecha UDMedW pozwala wykrywać kierunek szarych pasm tła



Rys. 4.40. Cecha UMxDW pozwala wykrywać kierunki najbardziej kontrastowych pasm

Z kolei dla wykrywania tylko kierunków najbardziej kontrastowych (np. czarnych i białych) pasm można zastosować jeszcze inną cechę nazwaną **UMxDW** – „unormowana maksymalna dewiacja wierszy” – co pokazuje Rys. 4.40.

### 8.3.7 Porównanie czasów wyznaczania anizotropii cech

Porównanie czasów obliczeń w poszczególnych metodach detekcji anizotropii i kierunków głównych tekstury wykonano dla obrazu *Per-N4.bmp* bez filtracji, przy pomocy programu Anizo [P32] pobierającego prostokątne wycinki obracanych obrazów. Jak widać metoda wykorzystująca cechę UDSW nie tylko pozwala poprawnie wykryć kierunki główne ale cechuje się też maksymalną wartością wykrywanej anizotropii i minimalnym czasem obliczeń rzędu 13 sekund (dla zbioru 180 obrazów obróconych) przy wykorzystaniu komputera z procesorem AMD 2 GHz i pamięcią RAM 1,25 GB.


**Tabela 4.2.** Porównanie czasów obliczeń przy wyznaczaniu anizotropii i kierunków głównych

Cecha wykorzystana do detekcji anizotropii i kierunków głównych tekstury	Czas obliczeń [s]	Meta-cecha		
		Anizo	Dir1	Dir2
<b>UDSW</b>	<b>13,18</b>	0.73	105	71
URZKW (d=3, prog=10)	16,28	0,16	102	100
LRE $\varphi=0; 1; 2; \dots, 180$	49,70	0,29	90	0
LRE $\varphi=-1; 1; 3; \dots, 179$	26,76	0,07	94	88


## 8.4 Analiza pól wyodrębnionych obiektów

### 8.4.1 Rozkłady pól obiektów

Rozkłady statystyczne pól obiektów wyodrębnionych na obrazach binarnych przy pomocy segmentacji i indeksacji zdefiniowano już w rozdziale 2.4.2. Jak stwierdzono tam – najłatwiej zinterpretować informacje wynikające z przebiegu skumulowanego, ważonego, znormalizowanego rozkładu pól plam.



Rys.4.41. Skumulowane rozkłady pól plam dla obrazów TA1 – TB2



Rys.4.42. Skumulowane rozkłady pól plam dla obrazów TC1 – TE1

Rys.4.41 i Rys.4.42 pokazują takie rozkłady skumulowane, wyznaczone dla testowych


obrazów programem *Rozklplam* [P38], przy użyciu opracowanej w Matlabie funkcji *rozkl\_pl(Obraz, kumulacja)* [P39]. Z pokazanych tam wykresów łatwo można odczytać:

- pokrycie względne powierzchni obrazu (zdefiniowane w 2.2.1) – jako wartość maksymalną na osi rzędnych do której dochodzi wykres,
- pole największej plamy (w procentach pola obrazu) – jako odcięta punktu osiągnięcia tego maksimum,
- relacje liczby plam o różnych polach np.: równomierność rozkładu skutkująca liniowym (w przybliżeniu) wzrostem (TC1, TC2, TD2) lub przewagą plam małych (TA1, TA2) albo dużych (TB2, TE1).

Analogiczne do tych ostatnich informacji można uzyskać także przy pomocy wcześniej zdefiniowanych deskryptorów *Kr*, *Sr*, *Dl* (2.2.3) lub definiując analogiczne deskryptory dla pól obiektów zamiast dla pasm.

### 8.4.2 Metoda MRHS analizy różnic histogramów skumulowanych

Pojawianie się lub zanikanie obiektów typu jasna lub ciemna „plama” można także wykrywać przy pomocy opracowanej przeze mnie **metody różnic histogramów skumulowanych**. Metoda ta – oznaczona akronimem MRHS – została opisana w [W15] a polega na odejmowaniu histogramu skumulowanego pierwszego obrazu od histogramów skumulowanych pozostałych obrazów danej sekwencji.



Rys. 4.43. Testowanie metody MRHS na sztucznych obrazach

Metodę przetestowano m.in. na obrazach sztucznie wygenerowanych programem [P21]. Program ten oddzielnie wygenerował (Rys. 4.43) obraz A - jaśniejszego tła jako macierzy kwadratowej o boku  $DX$ , w której jasność pikseli losowano według rozkładu normalnego o średniej 180 i odchyleniu standardowym 30. Obraz B – reprezentujący ciemny obiekt - uzyskano wstępnie jako kopię obrazu A i następnie zmodyfikowano zastępując jego

fragment ciemniejszym kwadratem o boku  $dx < DX$ , również generowanym w/g rozkładu normalnego (o parametrach: średnia=45, odchylenie standardowe=25).

Testowanie polegało na obserwacji wykresów przy różnych parametrach rozkładów oraz zmienianym polu obiektu nazwanego „ciemną plamą”.

Rys. 4.43 przedstawia przykładowe sztuczne obrazy (a), (d), histogramy tych obrazów (b), (e) i histogramy skumulowane (c) oraz różnicę histogramów skumulowanych (f).

Wartość rzędnej maksimum różnicy histogramów znormalizowanych, skumulowanych jest liczbowo równa sumie pól ciemnych obiektów wyrażonej jako procent pola całego obrazu, natomiast wartość odciętej wskazuje położenie „doliny” histogramu – przyjmowanej jako graniczny poziom szarości właściwy dla wyodrębniania obiektów z tła i stosowany jako próg w procesie binaryzacji obrazu.

Metoda nie wymaga arbitralnego określania takich współczynników jak próg binaryzacji i jest odporna zarówno na drobne przemieszczenia kadru obrazów jak i na fluktuacje jasności tła w ramach sekwencji obrazów.

Dalsze badania wykazały jednak, że metoda zawodzi przy bardzo małych różnicach jasności obiektów względem teksturowego tła oraz po operacjach wyrównywania lub rozciągania histogramów.

## 8.5 Przykład klasyfikacji obrazów testowych

Użyteczność niektórych ze zdefiniowanych dotąd deskryptorów cech sprawdzono na obrazach testowych (p.3.2), po zbinaryzowaniu tych obrazów metodą BN99 (p.2.1).

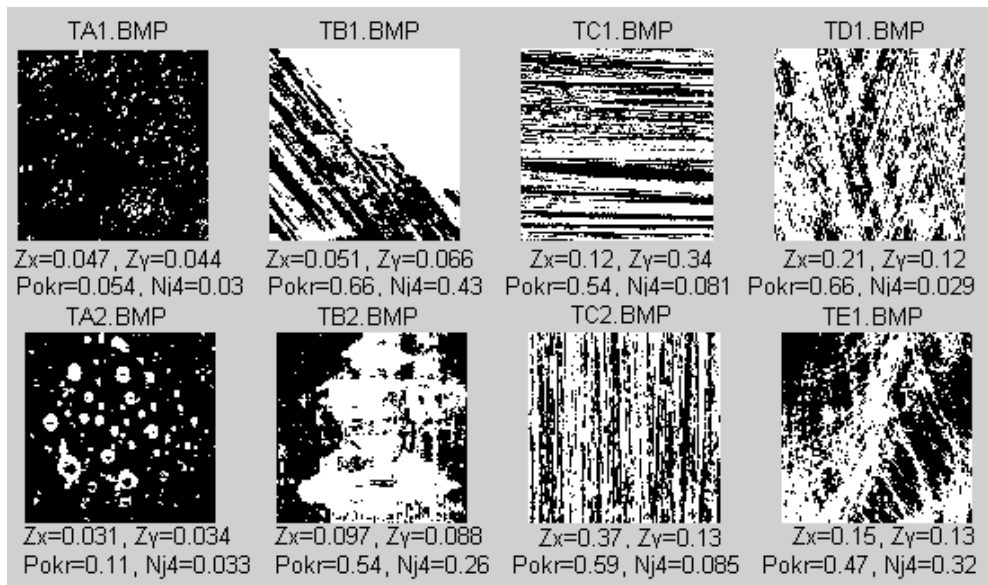
Wyznaczano mianowicie wartości następujących cech i meta-cech:

- hiperbolicznej unormowanej ortotropii względnej (p.4.3.2) ziarnistości (p.2.2.2):  
 $Orto\_h(X, Zyx) = 1 - Z_y / Z_x$ ,
- względnego pokrycia bielą (p.2.2.1) powierzchni obrazu oraz
- niejednorodności ćwiartkowej średniej jasności (p.4.2.3).


Wyniki przedstawiono na Rys. 4.44 oraz Rys. 4.45.

Podsumowując można stwierdzić:

- 1) dla obrazów TA1, TA2 - przedstawiających zmiany punktowe typu „pitting” – wartości wszystkich czterech cech są niewielkie; w szczególności pokrycie nie przekracza 0,2, a pozostałe cechy są mniejsze od 0,1
- 2) pozostałe obrazy prezentujące zmiany typu „rysy” oraz „plamy” charakteryzują się pokryciem powierzchni przekraczającym 0,4;
- 3) obrazy „rys” (TC1, TC2), wykazujących dominujący kierunek, łatwo odróżnić od obrazów „plam” (TB1, TB2) dzięki zróżnicowanym wartościom cech  $Z_x$ ,  $Z_y$  wykazującym anizotropię;
- 4) jedynie cechy ostatniego rysunku (TE1) prezentującego rysy krzywoliniowe o nierównomiernym zagęszczeniu mało różnią się od obrazów plam, a odróżnianie wymagałoby zastosowania precyzyjniejszych metod analizy – na przykład lokalnego badania kierunków tekstury w poszczególnych podobrazach i wyznaczania niejednorodności tego rodzaju cech.



Rys. 4.44. Wartości wybranych cech obrazów testowych



Rys. 4.45. Wykres wartości czterech cech dla obrazów testowych

## 9. Przetwarzanie i analiza sekwencji obrazów tribologicznych

W niniejszym rozdziale przedstawiam metody przetwarzania i analizy sekwencji obrazów tribologicznych, opracowywane, badane i stosowane przeze mnie w ramach projektu badawczego KBN: 7T07C 03318 „Metodyka szybkiego oznaczania parametrów tribologicznych tworzyw konstrukcyjnych współpracujących ślizgowo w wybranych ośrodkach gazowych lub próżni”.

Badania dotyczyły procesów tarcia próbek kompozytowych materiałów konstrukcyjnych zawierających poli-tetra-fluoro-etylen (PTFE), współpracujących ślizgowo z powierzchnią stalową. W szczególności przedmiotem zainteresowań było zjawisko **transferu PTFE** i warunki w jakich powoduje ono tworzenie się tzw. **filmu transferowego** czyli cienkiej warstwy polimeru na powierzchni stali korzystnej dla zmniejszania współczynnika tarcia oraz wzrostu trwałości par kinematycznych.

W niniejszym rozdziale przedstawiono cel i środki analizy, omówiono istotne dla sekwencji obrazów błędy i zakłócenia procesu akwizycji oraz ich korektę a także zaprezentowano metody analizy sekwencji zarejestrowanych obrazów, ukazujące rozwój filmu transferowego.

Analizie poddawano sekwencje obrazów zarejestrowane w tribotesterze podczas tarcia ślizgowego próbek konstrukcyjnych materiałów polimerowych o powierzchnię stalowej tarczy. Z punktu widzenia tribologii istotne było uchwycenie zależności tworzenia się i narastania lub zanikania warstewki „filmu transferowego PTFE” w funkcji warunków tarcia (nacisku, prędkości ślizgania) oraz drogi tarcia lub czasu.

W zakresie badań nad rozwojem narzędzi dla tribologii zarejestrowane sekwencje obrazów stanowiły bogaty, a zarazem trudny materiał dla przetestowania różnych metod analizy. Oprócz występowania szeregu wad i zakłóceń niektóre analizowane zmiany miały bowiem bardzo subtelny charakter i wymagały doboru specjalnych metod.

Uwydatnienie badanych zmian na obrazach powierzchni uzyskiwano m.in. dzięki przetwarzaniu obrazów szarych na czarno-białe czyli binaryzacji (p.1.2.6). Oprócz dwu metod binaryzacji przedstawionych w rozdziale 2.1 przetestowano także inne metody. Ogółem przetestowano i opisano dwie grupy metod. Pierwsza to **binaryzacja progowa** - ze stałym lub dostosowywanym do obrazów progiem, a druga to **binaryzacja różnicowa** bazująca na porównywaniu obrazów. BINARYZACJĘ poprzedzono przetwarzaniem mającym na celu **korekcję błędów** procesu akwizycji, jak szumy, fluktuacje jasności oraz drgania obrazów.

W ramach analizy badano – jako funkcje drogi i warunków tarcia - przebiegi zmian procentowego pokrycia powierzchni obrazu plamami filmu transferowego, zmian rozkładów



wielkości pól plam oraz zmian ortotropii ich kształtu. Przetestowano i przedstawiono także zastosowanie autorskich metod analizy oznaczonych akronimami MRHS (p. 5.9) oraz UC (p. 5.10).

## 9.1 Cel i przedmiot badań

Celem opisywanego fragmentu badań było zbadanie przebiegu powstawania i zmian filmu transferowego w trakcie tarcia, dla kilku materiałów kompozytowych przy różnych wartościach sił nacisku oraz prędkości ślizgania i wychwycenie charakterystycznych różnic tych przebiegów.

Przedmiotem badań tribologicznych były próbki czterech materiałów kompozytowych wyprodukowanych w Zakładach Azotowych w Tarnowie i przedstawionych w tabeli 9.1. Powierzchnia czoła próbek poddawanych tarcia wynosiła 96 mm<sup>2</sup> (8x12 mm).

**Tabela 5.1.** Badane materiały

Nazwa materiału	Skład
SM-K22G3	PTFE + 22% koksu + 3% grafitu
SM-2 lub PTFE	czysty PTFE o handlowej nazwie „tarflen”
SM-B40G2	PTFE + 40% brązu +2% grafitu
SM-S25	PTFE + 25% włókna szklanego

## 9.2 Stanowisko badawcze

Stanowisko badawcze składało się z tribotestera OSA-2 typu trzpień tarcza (Rys. 5.1) – zaprojektowanego przez kierownika projektu badawczego dr inż. Zbigniewa Oleksiaka [17] – oraz układów: akwizycji obrazów i rejestracji parametrów procesu tarcia.

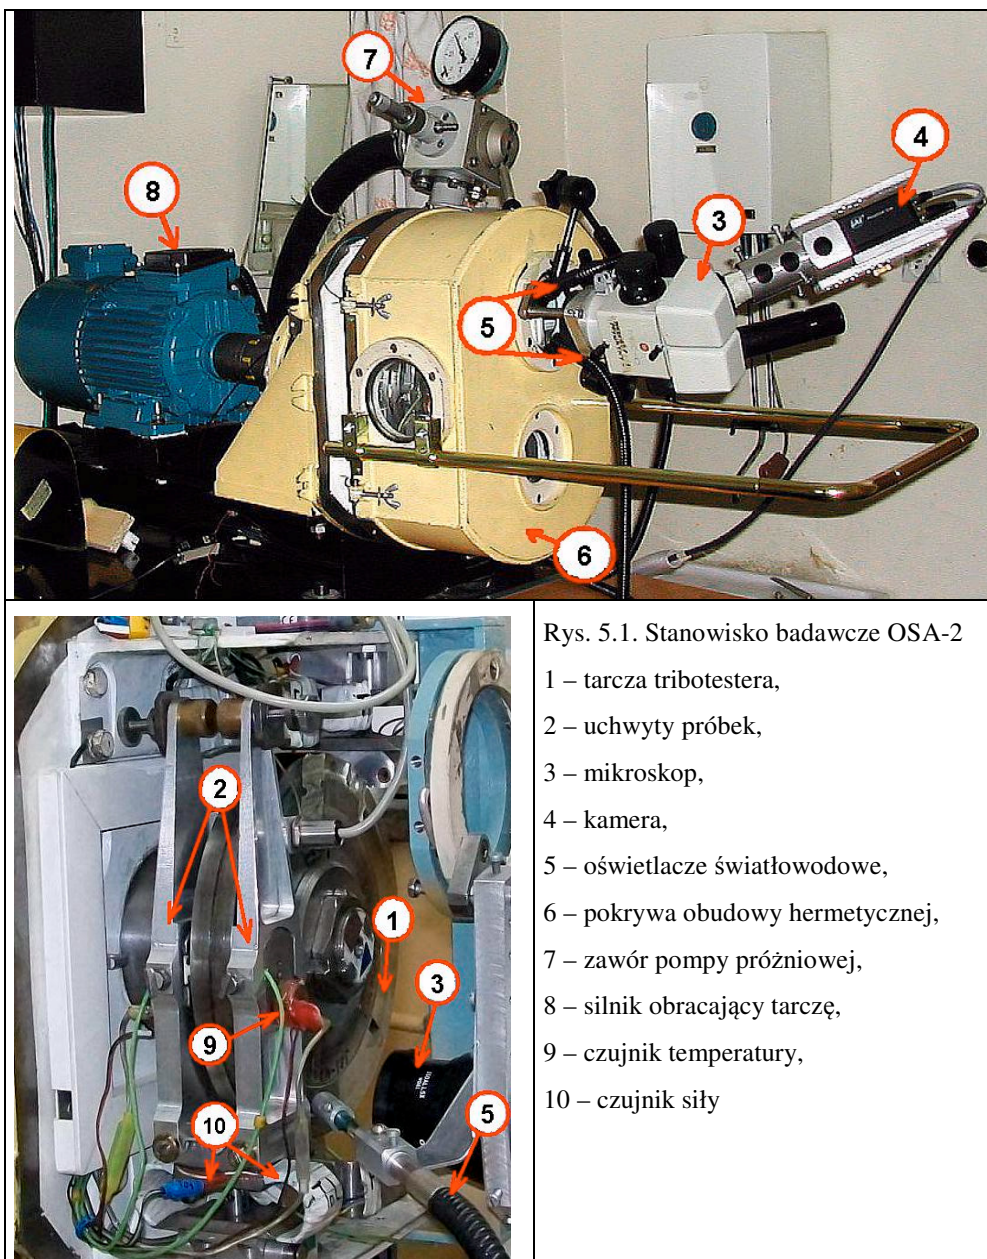
Eksperymenty tribologiczne polegały na tarcia próbek badanych materiałów – montowanych w dwu uchwytach (2) tribotestera (Rys. 5.1) - o stalową tarczę przeciwpróbkową (1), przy określonej sile docisku i prędkości obrotowej tarczy. Tarcza tribotestera wraz z próbkami umieszczona była w hermetycznej obudowie pozwalającej na realizację badań przy obniżonym ciśnieniu atmosferycznym oraz w atmosferze określonych gazów. Do pokrywy obudowy tribotestera przymocowane były elementy układu akwizycji obrazów - oświetlacz oraz mikroskop (3) z kamerą (4).

W finalnych badaniach używano **mikroskop** stereoskopowy Olympus SZ-51o następujących podstawowych parametrach:

- korpus o ogniskowej 22 i zakresie powiększeń 0,8 do 4x (zoom 5:1),
- nasadka obiektywowa 110AL o powiększeniu 1,5x,
- okulary o powiększeniu 10x,
- odległość robocza 110 mm.

Przy stosowanym powiększeniu 60x pole obserwacji wynosiło 1,2mm x 2mm.

Wykorzystywana kamera była kamerą analogową M10 pracującą bez przepłotu w standardzie CCIR.




Rys. 5.1. Stanowisko badawcze OSA-2

- 1 – tarcza tribotestera,
- 2 – uchwyty próbek,
- 3 – mikroskop,
- 4 – kamera,
- 5 – oświetlacz światłowodowe,
- 6 – pokrywa obudowy hermetycznej,
- 7 – zawór pompy próżniowej,
- 8 – silnik obracający tarczę,
- 9 – czujnik temperatury,
- 10 – czujnik siły

Oświetlacz posiadał lampę ksenonową BH-0647 PRC 2A Heimann 60W 250V zdolną do wykonywania do 12 błysków na sekundę (żywość 10 mln błysków) zdalnie wyzwalanych impulsami z czujnika obrotów. Przy każdym obrocie tarczy przeciwpróbkowej tribotestera generowany był jeden impuls.

Stosowano oświetlenie boczne z użyciem światłowodów oraz prętów szklanych lub ze szkła organicznego (plexiglas'u), a w pewnym okresie testowano również oświetlenie przez jeden z okularów mikroskopu, jak na Rys. 5.2.




Rys. 5.2. Schemat systemu akwizycji obrazów: 1-mikroskop stereoskopowy, 2-oświetlacz, 3-kamera, 4-wejście impulsów wyzwalających, 5-przesuwnik fazowy, 6-dzielnik częstotliwości, 7-przetwornik analogowo-cyfrowy, 8-komputer z programem "Video-stroboskop"

Kamera i oświetlacz stanowiły elementy urządzenia do akwizycji obrazów o nazwie „Video-Stroboscope MOCON-RT” (Motion Control - Real Time System), skonstruowanego w firmie Hardsoft. Pozostałymi elementami tego urządzenia były współpracujące z komputerem elektroniczne układy sterowania i akwizycji obrazu pokazane schematycznie na Rys. 5.2 oraz program komputerowy również nazywający się "VideoStroboscope".

Parametry oświetlacza i elektronicznej migawki pozwalały osiągać minimalny czas ekspozycji rzędu jednej milionowej sekundy.

Dzięki zsynchronizowaniu błysków oświetlacza i momentów akwizycji obrazów z obrotami tarczy, uzyskiwano przy każdym obrocie obraz tego samego wycinka tarczy (Rys. 5.3). Program "VideoStroboscope" pozwalał też na dzielenie częstotliwości impulsów wyzwalających oraz opóźnianie momentów akwizycji obrazu względem tych impulsów.



Rys. 5.3. Fragment tarczy przeciwpróbkowej ze śladem tarcia i obserwowanym wycinkiem

Podczas procesu tarcia rejestrowano również - w osobnym komputerze - parametry tego procesu: siłę docisku próbek, prędkość obrotową tarczy, składowe siły tarcia oraz temperaturę wewnątrz próbki w pobliżu powierzchni trącej. Chropowatość tarczy stalowej (sta-

nowiącej „przeciwpróbkę”) dla pierwszych sekwencji oznaczonych symbolami „A” i „1A” wynosiła  $R_a = 0,3$ , a dla kolejnych,  $R_a = 0,03$ .

### 9.3 Materiał badawczy z zakresu analizy obrazów

Bezpośrednim obiektem badań w zakresie analizy obrazów były dostarczone przez zespół tribologów, a zarejestrowane w trakcie tarcia sekwencje obrazów cyfrowych szarych (pliki typu BMP) o nominalnie 256-ciu poziomach szarości i rozmiarach 744 x 468 pikseli z których w pewnych przypadkach obcinano marginesy wykraczające poza ślad tarcia. Liczba obrazów w sekwencji wynosiła najczęściej 150, przy czym stosowano również łączenie kilku sekwencji w grupę.

Do przetwarzania i analizy obrazów opracowywano w języku Matlab programy wykorzystujące pakiet oprogramowania Matlab Image Analysis Toolbox.

### 9.4 Automatyzacja przetwarzania i analizy

Automatyzacja przetwarzania i analizy polegała w pierwszym rzędzie na zbudowaniu systemu zarządzania plikami, obejmującego m.in.:

- zasady nazewnictwa obrazów i ich sekwencji – związane z parametrami tarcia,
- automatyczne tworzenie spisów sekwencji i należących do nich obrazów,
- obsługę automatycznego przetwarzania i analizy sekwencji obrazów,
- generowanie animacji (plików filmowych \*.avi),
- kontroli czasu obliczeń.

#### 9.4.1 Typy plików

Występujące w systemie typy plików identyfikowano według rozszerzeń nazw (członów nazw występujących po kropce). W tabeli poniżej objaśniono znaczenie poszczególnych rozszerzeń nazw plików.

Tabela 5.2. Typy plików w systemie przetwarzania i analizy obrazów

Typ	Objaśnienie typu plików
BMP	Obrazy szare źródłowe lub obrazy szare po korekcie
TIF	Obrazy czarno-białe uzyskane po korektach i binaryzacji
INF	Pliki informacyjne generowane w systemie akwizycji dla każdego obrazu
SPS	Pliki tekstowe ze spisami sekwencji oraz spisem wszystkich obrazów
SEQ	Pliki tekstowe zawierające spisy obrazów w poszczególnych sekwencjach
AVI	Film (animacja) dla danej sekwencji
M	Program w języku Matlab
TXT	Pliki wyników lub inne pliki pomocnicze

## 9.4.2 Nazewnictwo plików z obrazami

Obrazy uzyskiwane z kamery po konwersji na zapis cyfrowy (dokonanej w wideo-stroboskopie) posiadały zakres szarości 0-255 i rozmiary w pikselach 744x468. Obrazy te uzyskiwano w postaci plików typu BMP (*grayscale Windows Bitmap*).

Przyjęto, że nazwa każdego pliku zawierającego obraz ma składać się z trzech części:

- a) stałego w danej serii członu początkowego stanowiącego nazwę serii,
- b) członu zawierającego trzycyfrowy numer obrazu poprzedzony znakiem "\_",
- c) kropki i po niej rozszerzenia nazwy ".BMP" zgodnego z typem pliku.

Przykładowe dopuszczalne nazwy plików graficznych:

**A\_004.BMP, 30P03A\_013.BMP, SMK22G3\_p60\_v1\_e\_041.bmp**

W pierwszych eksperymentach człon (a) składał się z numeru badanego kompozytu (pominiętego dla pierwszego badanego materiału) oraz pojedynczej litery stanowiącej oznaczenie serii badań. Zgodnie z tym: A, B, C, D, E - to serie badań kompozytu SM-K22G3 natomiast serie 1A, 1B, 1D, 1E - to serie badań tarflenu SM-2.

W dalszej części badań przyjęto konwencję określania nazw sekwencji tak aby zawierały informacje identyfikujące:

- badany materiał (numer lub nazwa)
- wartość siły nacisku w [N], (np.: 0 (bez tarcia), 10 , 30 , 60)
- kierunek obrotów tarczy (L - w lewo, P - w prawo),
- prędkość ślizgania (przeważnie zadawano prędkości: 0,3 m/s, 1 m/s, 3 m/s)

## 9.4.3 Automatyczne sporządzanie spisów

Dla umożliwienia automatycznego wczytywania i analizowania obrazów należących do poszczególnych sekwencji konieczne było utworzenie plików tekstowych zawierających informacje o lokalizacji oraz spisy nazw sekwencji a także obrazów stanowiących zawartość każdej sekwencji. W tym celu opracowano w Matlabie funkcję *spisy5* [P41].

Argumentem funkcji powinna być nazwa utworzonego wcześniej głównego foldera wynikowego – przeznaczonego dla wyników analizy. W przypadku braku argumentu zostaje przyjęta nazwa foldera wynikowego przypisana w treści programu zmiennej *dir2n*. Po wywołaniu funkcji „spisy5” zażąda ona wybrania i otwarcia foldera źródłowego z obrazami, a następnie tworzy w głównym folderze wynikowym podfolder o takiej samej nazwie jak źródłowy. Do foldera tego funkcja „spisy5” generuje:

- plik SPIS\_BMP.sps - spis wszystkich obrazów,
- pliki \*.SEQ - ze spisami obrazów dla każdej sekwencji osobno,
- plik SERIE.SPS - spis sekwencji,
- plik SOURCE.DIR zawierający ścieżkę do foldera źródłowego.

Przy opracowaniu funkcji wykorzystano fakt, że 8 ostatnich znaków w nazwie każdego pliku z obrazem to:

- podkreślnik i trzy cyfry - numer pliku w serii, oraz
- kropka i trzy litery - określające typ pliku (zgodnie z istniejącym standardem)

#### 9.4.4 Generowanie animacji (plików filmowych \*.avi)

Po zarejestrowaniu każdej sekwencji obrazów istotna jest możliwość oglądania jej w postaci filmu lub inaczej mówiąc animacji. Opracowano w Matlabie program *filmy* [P42] do automatycznego tworzenia plików filmowych (typu \*.avi) na podstawie zbiorczego spisu nazw obrazów zawartego w pliku SPIS\_BMP.SPS

Ponieważ niektóre sekwencje obrazów są słabej jakości, bardzo ciemne lub zaszumione więc stosowano w takich przypadkach różne warianty filtracji medianowej szumu oraz poprawiania wyrazistości obrazu – na przykład wyrównywanie histogramu (w Matlabie *histeq*) lub przedstawianie obrazu w postaci barwnej mapy warstwicznej (*imagesc*).

#### 9.4.5 Kontrola czasu obliczeń i przetwarzania obrazów

Niektóre operacje przetwarzania sekwencji obrazów są dla komputera dość czasochłonne i dla tysięcy obrazów mogą trwać nawet kilka godzin. W celu znalezienia szybkich metod przetwarzania testowano różne metody i porównywano czasy przetwarzania. W takich przypadkach, aby programy przetwarzające obrazy podawały czas przetwarzania umieszczano na początku programów pisanych w Matlabie instrukcję:

```
t0 = clock;
```

a na końcu:

```
czas=etime(clock,t0)
fprintf(fid, ' %s', 'czas obliczeń =');
fprintf(fid, ' %12.3f\n', czas);
```

Użyto systemowego wektora *clock* przechowującego aktualną datę i czas w postaci sześciu liczb określających: rok, miesiąc, dzień, godzinę, minuty, sekundy.

Funkcja *etime* podaje różnicę między dwoma momentami czasu podanymi jako jej argumenty, a więc w tym przypadku podaje czas działania programu w sekundach z dokładnością do 0,001 (co wynika z zastosowanego formatu).

### 9.5 Dodatkowe korekty stosowane dla sekwencji obrazów

Sekwencje obrazów zarejestrowanych na stanowisku badawczym OSA-2 były najpierw poddawane wstępnej jakościowej ocenie opartej zarówno na przeglądaniu pojedynczych obrazów jak i zmontowanych z nich filmów (animacji). Obserwacja wykazała m.in. istnienie takich błędów i zakłóceń jak:

1. przestrzenna nierównomierność jasności tła obrazu,
2. fluktuacje jasności tła w ramach serii obrazów,
3. nierównomierność ostrości w polu widzenia (inna na obrzeżach niż w środku),
4. różnice ostrości dla poszczególnych sekwencji obrazów,
5. przesunięcia między kolejnymi obrazami w ramach serii (powodujące drgania przy odtwarzaniu animacji),
6. szumy, szczególnie widoczne dla obrazów ciemnych rejestrowanych przy nieruchomej tarczy przeciwpróbkowej.

Dokładniejsza ocena błędów i zakłóceń wymagała szczegółowych analiz dokonywanych przy pomocy programów opracowanych w Matlabie. Wymienione wady występowały

w poszczególnych seriach w różnym stopniu i były stopniowo eliminowane w ramach postępu prac, zarówno poprzez pewne modyfikacje stanowiska pomiarowego lub doskonalenie metod akwizycji jak i przez dokonywanie opisywanych w tym rozdziale korekt przy pomocy opracowanych programów.

Występujące błędy i zakłócenia należą do różnych kategorii, a mianowicie:

1. błędy o charakterze losowym występujące na przestrzeni każdego pojedynczego obrazu to **szumy** termiczne i elektronowe przetwornika CCD i układów elektronicznych;
2. błędy o charakterze losowym występujące w ramach sekwencji to **fluktuacje jasności** obrazów oraz **przemieszczenia kadru obrazów** (mających prezentować stale to samo miejsce tarczy przeciwpróbkowej);
3. błędy systematyczne obserwowane w ramach obrazu (lecz zawierające również składową losową) - **nierównomierność przestrzenna ostrości, jasności i kontrastu** – wynikająca z wad optycznych oraz refleksyjności powierzchni stali, a być może także w pewnych przypadkach nieostrość wynikająca z ruchu tarczy;
4. błędy systematyczne, stałe w ramach jednej lub kilku serii to m.in. niedoskonałość ustawienia **ostrości** oraz **oświetlenia**
5. błędy grube – wystąpiły tylko w fazie sprawdzania pewnych metod i były łatwo zauważalne, a więc i eliminowane. Jednym z nich było przypadkowe włączenie do danej serii obrazów innego miejsca tarczy – wynikające z wadliwego działania układów wideostroboskopu lub sposobów jego zaprogramowania, innym była przypadkowa znaczna zmiana oświetlenia przy przejściu do rejestrowania nowej sekwencji.

Przed opracowaniem i zastosowaniem metod korekty, konieczne było oszacowanie tych błędów. Metody oceny i korekty niektórych błędów i zakłóceń – istotne zarówno w statycznej jak dynamicznej analizie obrazów – omówiono już wcześniej w rozdziale 4, natomiast poniżej opisano metody oceny i korekty błędów istotnych jedynie w analizie sekwencji obrazów.

### 9.5.1 Ocena i korekta zakresu jasności sekwencji obrazów

W przypadkach nieprawidłowego oświetlenia lub czasu ekspozycji, obrazy mogą być zbyt ciemne lub zbyt jasne. Przykładowo, akwizycja omawianych w dalszych rozdziałach sekwencji obrazów, prowadzona w trakcie tarcia, wymagała stosowania bardzo krótkich czasów ekspozycji - rzędu milionowych części sekundy - w wyniku czego uzyskiwano ciemne obrazy. Zakres poziomów szarości jest w takich przypadkach na ogół mniejszy od dopuszczalnego  $\langle 0; 255 \rangle$ , co łatwo zbadać wyznaczając histogram lub maksimum i minimum macierzy obrazu.

Tego rodzaju niedogodność nie stanowi istotnej przeszkody dla komputerowej analizy, jednak może być korygowana dla ułatwienia wzrokowej obserwacji i oceny obrazów.

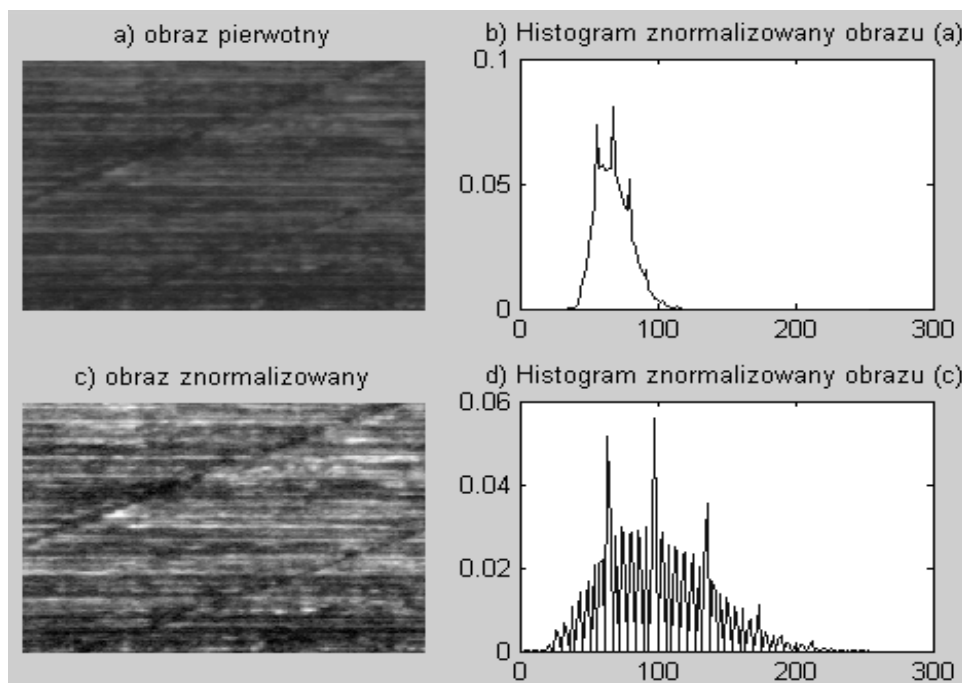
Najczęściej stosowaną metodą korygowania jasności pikseli obrazu, tak aby wykorzystany był cały dopuszczalny zakres, jest **normalizacja** obrazu [38], [44]. Jest ona przekształceniem liniowym wykonywanym na poszczególnych pikselach obrazu.

Jeśli obraz źródłowy oznaczymy przez  $X$ , a obraz docelowy przez  $Y$  to normalizację można zapisać jako:

$$Y=(X-xmin)*((ymax-ymin)/(xmax-xmin))+ymin \quad (5.1)$$

gdzie:  $ymin=0$ ,  $ymax=GR(Lg)$  – granice dopuszczalnego zakresu jasności pikseli,  
 $xmin$ ,  $xmax$  – granice rzeczywistego zakresu jasności pikseli.

Przykład normalizacji pojedynczego obrazu, wraz z prezentacją histogramów pokazuje zamieszczony poniżej rysunek (Rys. 5.4) wygenerowany programem [P4].



Rys. 5.4. Przykład normalizacji obrazu powierzchni wraz z histogramami.

Jak jednak już wspomniano – przekształcenia realizowane z parametrami dobraćnymi indywidualnie dla każdego obrazu mogą całkowicie fałszować wyniki analizy.

Szkodliwość indywidualnej normalizacji obrazów wykonywanej przy badaniu sekwencji lub klas obrazów pokazują wyniki uzyskane przy badaniu zmian pokrycia badanej powierzchni tarczy stalowej materiałem polimerowym przenoszonym w trakcie tarcia. Obrazy pewnej sekwencji oznaczonej roboczo literą „C” wykazywały wzrost obszaru pokrytego jasnymi śladami nanoszonego materiału kompozytowego na ciemnym tle. Przeprowadzono dwa warianty binaryzacji tej sekwencji – jeden bez normalizacji, a drugi poprzedzony indywidualną normalizacją każdego obrazu. Różnice między pierwszym i ostatnim obrazem sekwencji dla obu wariantów pokazują rysunki poniżej.


Jak pokazuje Rys. 5.6 normalizacja całkowicie zafałszowała wyniki, wykazując spadek pokrycia powierzchni zamiast wzrostu, poprawnie wykazanego (Rys. 5.5) bez normalizacji. Wynika to z faktu, że normalizacja indywidualna działa tak jak automatyczna regulacja wzmocnienia – wzmacniając kontrast najwięcej dla obrazów pustych nie zawierających badanych motywów, co skutkuje maksymalnym wzmocnieniem szumu.

Tak więc jeszcze raz potwierdzono zasadę, że badając sekwencję obrazów nie można dokonywać indywidualnych operacji na poszczególnych obrazach. Możliwe jest natomiast




dokonanie na wszystkich obrazach operacji korekty kontrastu jeśli jej parametry będą dla każdego obrazu identyczne.

Rozpatrując więc normalizację jako element analizy populacji  $X$  obrazów  $X_i$ , musimy tak ustalić parametry przetwarzania  $xmin$ ,  $xmax$  aby mogły służyć dla całej populacji.



Rys. 5.5. Pierwszy i ostatni obraz sekwencji „C” po binaryzacji bez normalizacji



Rys. 5.6. Pierwszy i ostatni obraz sekwencji „C” po binaryzacji z normalizacją

Teoretycznie  $xmin$ ,  $xmax$  powinny być równe jasności odpowiednio najciemniejszego i najjaśniejszego piksela w populacji obrazów. W praktyce należy jednakże uwzględnić, że pewna liczba najjaśniejszych i najciemniejszych pikseli reprezentuje zakłócenia lub artefakty (np. pyłki kurzu w układzie optycznym, lub wady matrycy CCD) i należy je pominąć. W związku z tym korzystniej jest przyjąć nieco węższy zakres rzeczywistej jasności pikseli, ustalając  $xmin$ ,  $xmax$  na przykład jako średnie z percentyli macierzy obrazów danej sekwencji, tak jak pokazano poniżej:

$$xmin = (1/Li)\sum\{percentyl_1\%(X_i)\}, \quad xmax = (1/Li)\sum\{percentyl_99\%(X_i)\} \quad (5.2)$$

gdzie:  $i=1..Li$  - to numer obrazu w populacji.

Tak więc, normalizacja nie zmienia liczby odcieni lub – przy zastosowaniu percentyli jak wyżej - powoduje utratę 2% odcieni, natomiast zwiększa różnice między poszczególnymi odcieniami, poszerzając zakres do maksymalnego dopuszczalnego  $\langle 0; 255 \rangle$  i zwiększając **kontrast** obrazu.

Oprócz normalizacji stosowana może być nieliniowa **korekcja gamma** pozwalająca w różnym stopniu zmieniać jasność ciemniejszych lub jaśniejszych partii obrazu.


Normalizacja i korekcja gamma może być realizowana w Matlabie przy pomocy funkcji *imadjust(...)*. Bardziej radykalne wzmocnienie kontrastu – połączone z utratą części od-

cieni - można uzyskać operacją wyrównywania histogramu do czego w Matlabie służy funkcja *histeq(...)*.

Błędy akwizycji polegające na zastosowaniu zbyt jasnego oświetlenia lub nadmiernego kontrastu obrazów – mimo wizualnie wyrazistych obrazów – mogą skutkować nieodwracalną utratą części informacji, gdy zawierają elementy których jasność doszła do maksimum.

### 9.5.2 Ocena i korekta fluktuacji jasności w sekwencjach obrazów

Oprócz opisywanych wyżej korekt: normalizacji zakresu odcieni szarości oraz wyrównywania przestrzennej nierównomierności jasności tła, spotkano się z fluktuacjami średnich jasności obrazów w danej sekwencji.

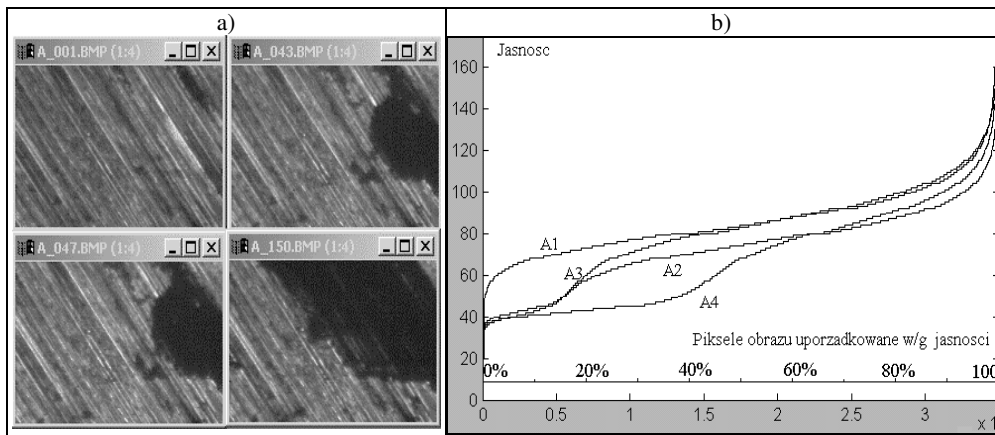


Rys. 5.7. Percentyle 0%, 5%, ..100% obrazów sekwencji "A"

Fluktuacje jasności wynikały najprawdopodobniej z takich czynników jak: niestabilność błysków oświetlacza błyskowego oraz drgania mechaniczne i spowodowane tym zmiany warunków odbicia i rozpraszania światła od obserwowanej wirującej tarczy stalowej.

Procentowe odchylenie standardowe średniej jasności zawierało się w granicach 2-3% lecz wahania maksymalnej jasności i kontrastu były większe (3.5-4.5%). Jest to zrozumiałe gdyż najjaśniejsze obszary powierzchni odbijając największy procent padającego światła zarazem w największym stopniu odzwierciedlają zmiany oświetlenia, a obszary ciemniejsze czynią to proporcjonalnie słabiej. Dodatkowo mamy do czynienia z błyszczącą powierzchnią metalową zawierającą szereg subtelnych rys (z procesu obróbki), a odbijanie i rozpraszanie światła przez taką powierzchnię w kierunku obiektywu może zmieniać się nawet przy bardzo niewielkich zmianach kąta położenia wywołanych drganiami mechanicznymi.

Fluktuacje jasności w ramach serii obrazów badano między innymi przy pomocy wyznaczania percentyli jasności pikseli obrazu. Pojęcie percentyla przypomniano w rozdziale 5.1.2. Wykresy wartości percentyli (od zera do 100% co 5%) dla obrazów przykładowej sekwencji „A” pokazuje Rys. 5.7. Jak widać na tym rysunku - największe fluktuacje zachodzą w obszarze maksymalnej jasności obrazu co jest o tyle zrozumiałe, że jest to obraz światła odbijanego od powierzchni metalu.




Rys. 5.8. Przykładowe obrazy (a) oraz ich krzywe percentylowe (b)

Rozwój ciemnej plamy jaki w tej sekwencji obrazów następuje, jest widoczny w zmianach percentyli 5% do 45% dla których fluktuacje jasności są stosunkowo niewielkie jednak dla pewnych subtelnych metod analizy obrazów (jak np. metody różnicowe) fluktuacje te muszą być kompensowane.

Możliwość dokonania korekty fluktuacji jasności tła wiąże się z zagadnieniem: co w zmieniających się obrazach teksturowych uznać za tło, a co za obiekt zainteresowań. Bardzo pomocne są w tym względzie opisane w 5.1.2 krzywe percentylowe (Rys. 5.8b).

Rys. 5.8b pokazuje wyraźnie jak pojawienie się zmiany w postaci ciemnej plamy powoduje załamania na wykresach krzywych percentylowych. Równocześnie pionowy odstęp między częściami krzywych przebiegającymi równoległe pokazuje różnice jasności tła tych obrazów. Korekta jasności obrazów powinna zlikwidować ten odstęp, tak jak to pokazano na Rys. 5.9.




Rys. 5.9. Krzywe percentylowe po stabilizacji jasności tła na poziomie percentyla 80%

Tak więc przy założeniu, że badane są ciemne plamy na obrazach, uznano [W15] na podstawie przebiegu pokazanych powyżej krzywych, że piksele w zakresie percentyli 70%-90% są reprezentatywne dla jasnego tła obrazu i należy dążyć do ustabilizowania ich jasności w ramach całej serii obrazów.

Ostatecznie przyjęto jasność percentyla 80% pierwszego obrazu jako poziom do którego należy doprowadzić jasności percentyli 80% pozostałych obrazów dla ustabilizowania jasności tła obrazów. Korekty dokonano następująco:

$$X'=[x'_{w,k,i}] = [x_{w,k,i} \cdot P80_1/P80_i, i=1,2..Li, k=1,2..Lk, w=1,2..Lw] \quad (5.3)$$


gdzie: P80<sub>1</sub> - percentyl 80% pierwszego obrazu, P80<sub>i</sub> - percentyl 80% i-tego obrazu




Rys. 5.10. Percentyle obrazów sekwencji "A" po stabilizacji jasności percentyla 80%

Percentyle obrazów sekwencji A po stabilizacji jasności tła pokazuje Rys. 5.10. Dokładniej metoda ta opisana jest w publikacji [W15].

Rozwój ciemnych plam w sekwencji obrazów „A” oraz skutki korekty fluktuacji jasności przez stabilizację percentyla 80% można także bardzo dobrze zaobserwować na wykresach histogramów skumulowanych pokazanych na Rys. 5.11 i Rys. 5.12.



Rys. 5.11. Histogramy skumulowane sekwencji „A” przed korektą fluktuacji jasności



b) Rys. 5.12. Histogramy skumulowane obrazów sekwencji „A” po korekcie fluktuacji jasności

### 9.5.3 Pomiar i korekta przemieszczeń obrazów w ramach sekwencji

Przemieszczenia kadru poszczególnych obrazów należących do danej sekwencji obliczono i kompensowano przy pomocy programów w Matlabie. Opracowano kilka niezależnych algorytmów dla korygowania wzajemnych przemieszczeń obrazów.

**Algorytm 1** - realizowany był przez funkcję  $[dx,dy] = BtransA(B,A)$  [P43]. Funkcja ta wyznacza wektor  $dx,dy$  o jaki trzeba przesunąć obraz B aby był maksymalnie podobny do A. Założone przesunięcie nie może być większe od 64 lub 1/3 krótszego boku obrazu (jeśli stanowi to mniej niż 64), przy czym obrazy A i B muszą mieć jednakowe rozmiary.

Kolejne kroki zastosowanej metody są następujące:


1. obrazy poddane są operacji wyrównywania histogramu
2. z obrazu B brany jest kwadrat B' o wymiarze  $3*64$ , a jeśli jest to zbyt dużo to o rozmiarze krótszego boku obrazu
3. z obrazu A brany jest kwadrat A1 o trzykrotnie krótszym boku, wycięty z centrum identycznego kwadratu jak w (1)
4. następnie wycinane z B' małe kwadraty są porównywane z A1 (najpierw ze skokiem 4 lub 2 potem 1) tak aby znaleźć minimum sumy wartości bezwzględnych różnic pikseli (znaki dx, dy ustalane są według współrzędnych obrazowych tzn. dodatnie w dół i w prawo)

Ponieważ stwierdzono, że w pierwszych rejestrowanych seriach przesunięcia nie przekraczają ok. 6-ciu pikseli więc w tych przypadkach dla mniejszego kwadratu o boku D ustalono rozmiar boku większego kwadratu na  $D+24$ , a skok przesuwania najpierw ma wartość 3, a potem przesunięcie jest precyzowane ze skokiem 1.


Przebiegi przemieszczeń  $D_x, D_y$  obrazów w kilku wczesnych sekwencjach, wyznaczone przy pomocy tego algorytmu (programem *oclser.m* i funkcją *BtransA6*) ilustrują pokazane na kolejnych rysunkach wykresy. Pomiar przemieszczeń tą metodą jest dość czasochłonny, przykładowo czas oceny serii 1A wyniósł 791.64s.

Jak widać, w pierwszych analizowanych sekwencjach obrazów przemieszczenia nie przekraczały sześciu pikseli. Średnia bezwzględna wartość przemieszczeń nie przekraczała

2 pikseli dla kierunku poziomego oraz 1 pikseli dla kierunku pionowego co przy rozmiarach obrazów wynoszących 744 x 468 pikseli było równoważne średnim błędom względnym  $DX_w < 0,0027$  i  $DY_w < 0,0021$ .



Rys. 5.13. Drgania (Dx, Dy) obrazów w sekwencji 1A



Rys. 5.14. Drgania (Dx, Dy) obrazów w sekwencji 1B

Niestety w kolejnych seriach przemieszczenia radykalnie wzrosły i zmienił się również charakter obrazów co spowodowało konieczność opracowania innych metod pomiaru przemieszczeń.

**Algorytm 2** - korygowanie znacznych przemieszczeń poziomych – funkcja dx3 [P44]

Dla każdego obrazu:


- wyznaczano wiersz obrazu szarego o maksymalnej sumie,
- wyznaczano jego otoczenie o szerokości  $dw=10$ ,
- wyznaczano wektor sum kolumn tego otoczenia,
- dla obrazu pierwszego pozostawiano z niego odcinek środkowy, który następnie porównywano z wieloma wycinkami wektora (sum kolumn otoczenia najjaśniejszego wiersza) obrazu korygowanego dla znalezienia takiego wycinka dla którego suma wartości bezwzględnych różnic jest minimalna.

Ponieważ dla pewnych obrazów nie uzyskiwano poprawnych wyników więc opracowano również kolejny algorytm:

**Algorytm 3** składa się z następujących kroków:

1. Należy przeglądnąć całą sekwencję (na przykład programem Irfan View) oraz:
  - a) usunąć obrazy zupełnie niepodobne do pozostałych (błędy grube),
  - b) wybrać jeden charakterystyczny element przemieszczający się na poszczególnych obrazach lecz nie znikający poza granicami żadnego obrazu.
2. Należy zaznaczyć ten element (jako prostokątny obszar) z niewielkim marginesem i zapisać jako obraz referencyjny typu BMP z nazwą taką jak nazwa serii (bez końcowego numeru)
3. Należy określić (na podstawie obserwacji) współrzędne maksymalnego prostokąta w jakim ten element będzie się poruszał  $X_0, Y_0, DX, DY$

Ideę ilustruje Rys. 5.15. Program *lokel* [P45] wyznacza dla każdego (i-tego) obrazu współrzędne  $X_r(i), Y_r(i)$  referencyjne odpowiadające takiemu przemieszczeniu obrazka referencyjnego  $EL$  (począwszy od  $X_0, Y_0$ ) aby nałożył się on na odpowiadający mu element obrazu.



Rys. 5.15. Korygowanie przemieszczeń obrazów

4. Po wyznaczeniu wszystkich  $X_r(i), Y_r(i)$  wyznaczane są minima wektorów  $X_r, Y_r$   $MiX = \min(X_r); MiY = \min(Y_r)$  i odejmowane od wszystkich  $X_r(i), Y_r(i)$ . W ten sposób minimalne przesunięcie wyniesie zero, natomiast rozstęp współrzędnych referencyjnych określi margines o jaki trzeba zmniejszyć wszystkie obrazy aby po kompensacji przemieszczeń miały jednakowy rozmiar
5. Program *POM\_PRZES* [P46] – mierzy i zapisuje do pliku <seria>.TRA wartości  $X_r, Y_r$  oraz *Mindif*.

Po dokonaniu pomiaru przemieszczeń – jedną z opisanych wyżej metod - korygowano kadry obrazów przez pozostawienie części wspólnej dla wszystkich obrazów sekwencji oraz obcinaniu reszty. Niektóre ze stosowanych dalej metod analizy wymagały jednak aby wszystkie obrazy miały ten sam rozmiar. Wyniknęła stąd potrzeba wyznaczenia maksymalnych przemieszczeń, które pozwoliły określić rozmiar obrazów wynikowych. Ponieważ jednak w sporadycznych przypadkach przemieszczenia przekraczały 80 pikseli więc wprowadzono ograniczenie eliminujące z sekwencji obrazy przesunięte o więcej niż 60 pikseli. Takie obrazy nawet po kompensacji przesunięcia zazwyczaj różnią się od siebie co wynika z innej ostrości obrazu w środku i na brzegach, będącej rezultatem pewnych zniekształceń optycznych.

## 9.6 Przykład analizy sekwencji obrazów poddanych binaryzacji progowej

### 9.6.1 Operacje wstępne

Analizę sekwencji obrazów zarejestrowanych poprzedzało:

- utworzenie animowanych filmów z sekwencji obrazów (patrz 5.4.4);
- obserwacja utworzonych filmów oraz przejrzanie sekwencji – ogólnie dostępnym programem graficznym (np.: Ifran View) i usunięcie obrazów ewidentnie błędnych;
- wygenerowanie spisów obrazów i sekwencji (przy pomocy programu SPISY5);
- oszacowanie błędów i zakłóceń (szumu, fluktuacji maksymalnej jasności, przestrzennej nierównomierności jasności tła, ukierunkowania elementów obrazu oraz przemieszczeń kadru);
- dokonanie niezbędnych korekt – jednakowych dla całej sekwencji.


Generowanie spisów sekwencji oraz plików z obrazami opisano w rozdziale 5.4.3. W razie potrzeby – na przykład usunięcia błędnych obrazów lub scalania sekwencji - wygenerowane spisy mogą być poddawane edycji. Scalać można tylko sekwencje rejestrowane przy jednakowym oświetleniu, a więc takie dla których wyznaczone automatycznie (programem *progi2*) progi binaryzacji są jednakowe.

### 9.6.2 Wyznaczanie progu binaryzacji dla sekwencji obrazów

W przypadku sekwencji obrazów ważne było aby ten sam stały próg binaryzacji dotyczył wszystkich obrazów w sekwencji, a więc także - aby był dobierany optymalnie dla całej sekwencji, pozwalając maksymalnie uwidatnić zmiany powodowane procesem tarcia.


Zalecany w literaturze [17, 24] sposób określania progu binaryzacji (p.2.1) na poziomie szarości stanowiącym „dolinę” między lokalnymi maksimami histogramu nie mógł być ogólnie przyjętym ponieważ w wielu badanych sekwencjach obrazy śladów tarcia słabo odróżniały się od tła, a histogramy tych obrazów nie posiadały kształtu dwumodalnego.

Wyraźna "dolina" histogramu występowała tylko dla niektórych obrazów serii „A” (Rys. 5.16), natomiast kształt przykładowego histogramu obrazu z innej serii pokazuje Rys. 5.17.



Rys. 5.16. Histogramy trzech obrazów sekwencji „A”





Rys. 5.17. Histogram obrazu SMB40G2\_p20v3\_j020

Dla niektórych sekwencji wyznaczanie progu binaryzacji metodą „doliny histogramu” można było jednak zastosować wyznaczając tą metodą próg dla jednego obrazu z wyraźnie już ukształtowaną plamą (i dwumodalnym histogramem), a następnie stosując ten próg jako stały dla całej sekwencji. Na przykład wyznaczony tak próg dla sekwencji „A” wynosił 62 – stąd wykresy wzrostu pokrycia powierzchni (Pokr) w sekwencji binarnej otrzymanej przy tym progu oznaczano roboczo BIN62.

Dla badania rezultatów uzyskiwanych przy różnych progach binaryzacji opracowano program *profil\_150* [P48], który pozwala:

- wczytać dwa obrazy danej sekwencji, różniące się stopniem pokrycia powierzchni filmem transferowym
- usunąć z obrazów marginesy pokazujące obszary poza śladem tarcia
- dokonać filtracji medianowej szumu
- sprowadzić poziom czerni do zera i zwiększyć zakres odcieni szarości
- wyznaczyć przekroje (profile) obrazów
- dokonać binaryzacji obrazów z danym progiem
- wyznaczyć procentowe pokrycie pola obrazu obszarem ciemnych plam
- wyświetlić wyniki w postaci graficznej

Rys. 5.18 pokazuje przykładowy ekran wyświetlony tym programem.

Widoczne są profile (przekroje) dwu obrazów wybranych z początku i końca danej sekwencji, przy czym zaznaczono na nich poziom progu binaryzacji. Pod profilami są obrazy będące wynikiem binaryzacji. Zaznaczono na nich linię, wzdłuż której prowadzono przekrój, jednak oczywiście przekrój dotyczył pierwotnych obrazów szarych.


Binaryzacja sekwencji SMB40G2\_p20v3\_h przy progu 55 wykazuje wzrost pokrycia filmem transferowym ok.2,6 razy, przy maksymalnej wartości pokrycia 36,6%.

Profile wykazują duży poziom szumów obrazów przedstawiających jasne ślady filmu transferowego na ciemnym tle.

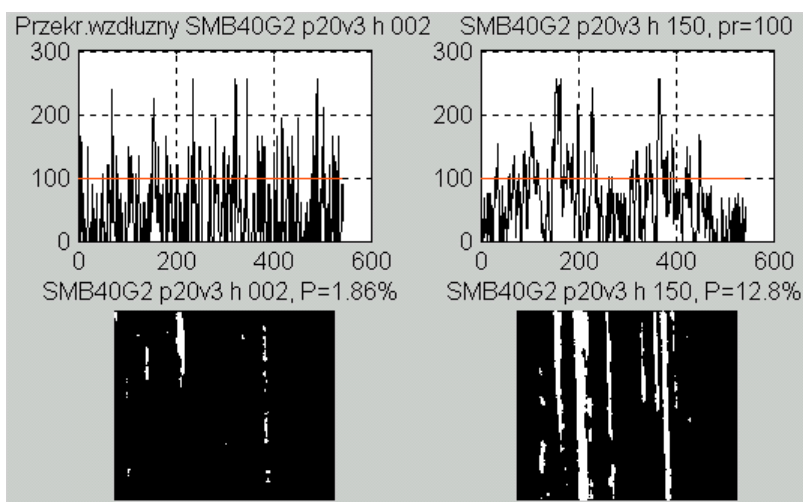
Podwyższenie progu binaryzacji dla tej sekwencji do 100 pozwala znacznie lepiej pokazać wzrost pokrycia, który tym razem wynosi ok. 6,9 razy (Rys. 5.19) mimo, że wartość maksymalnego pokrycia wynosi tym razem tylko 12,8%, a nie jak poprzednio 36,6%.

Widać więc wyraźnie, że otrzymywane wartości bardzo znacznie zależą od doboru progu binaryzacji i bez precyzyjnie określonej procedury ustalania tego progu nie mogą

odzwierciedlać intensywności zmian, a jedynie ich tendencję.



Rys. 5.18. Test binaryzacji sekwencji SMB40G2\_p20v3\_h dla progu 55 (wzrost 2,6)




Rys. 5.19. Test binaryzacji sekwencji SMB40G2\_p20v3\_h dla progu 100 (wzrost 6,9)


Dążąc do maksymalizacji czułości wykrywania zmian pokrycia badanych powierzchni przenoszonym w trakcie tarcia materiałem, przetestowano także wpływ normalizacji obrazów dostępnej w niektórych programach analizy (np, w programie MaZda).

Program o nazwie BIN6 [P49] pozwolił równocześnie oglądać wyniki binaryzacji dla sześciu różnych progów i zastosowaniu normalizacji obrazów lub bez niej. Przy pomocy tego programu – dla sekwencji obrazów w której rośnie obszar pokryty jasnymi śladami nanoszonego materiału kompozytowego na ciemnym tle – porównano wyniki binaryzacji pierwszego i ostatniego obrazu dokonanej w dwu wariantach: bez normalizacji (Rys. 5.20) oraz z normalizacją (Rys. 5.21) o parametrach ustalanych dla każdego obrazu.

Jak widać normalizacja (Rys. 5.21) całkowicie zafałszowała wyniki – wykazując spadek pokrycia powierzchni zamiast wzrostu, poprawnie wykazanego (Rys. 5.20) bez normalizacji. Wynika to z faktu, że normalizacja działa tak jak automatyczna regulacja wzmocnienia – wzmacniając kontrast najwięcej dla obrazów pustych nie zawierających badanych motywów, co skutkuje maksymalnym wzmocnieniem szumu.



Rys. 5.20. Pierwszy i ostatni obraz sekwencji „C” po binaryzacji bez normalizacji



Rys. 5.21. Pierwszy i ostatni obraz sekwencji „C” po binaryzacji z normalizacją

Tak więc jeszcze raz potwierdzono zasadę, że **badając sekwencję obrazów nie można dokonywać indywidualnych operacji na poszczególnych obrazach**. Możliwe jest natomiast dokonanie na wszystkich obrazach operacji korekty kontrastu jeśli jej parametry będą dla każdego obrazu identyczne.

Kolejnym problemem sprowadzał się do pytania: „czy pojedynczy próg binaryzacji ma być wyznaczony dla wielu sekwencji czy dla każdej sekwencji z osobna?”


W niektórych przypadkach rejestrowano bowiem - dla danego materiału kompozytowego i dla tych samych warunków tarcia ślizgowego – grupę kilku sekwencji liczących po 150 obrazów.

Testowy wariant analizy dla grupy sekwencji oznaczonej SMB40G2\_p60v1\_cdef dokonano przy dobranym eksperymentalnie stałym progu binaryzacji równym 26.

Rejestrowano parametr *Pokr* - względne pokrycie powierzchni oraz iloraz średnich długości pasm  $Dy/Dx$  i percentyl 98%.

Obserwacja wyników tej analizy wykazała wystąpienie nagłego skoku w przebiegu zmian pokrycia powierzchni przy przejściu z sekwencji „C” do „D” (Rys. 5.22) wynikającego z dwu błędów. Pierwszy z nich wynikał z przerwy w rejestracji podczas gdy proces

tarcia i narastania pokrycia filmem transferowym trwa. Przerwa ta nie mogła być uwzględniona na wykresie na którym zmienną niezależną jest numer obrazu, a nie czas przebiegu procesu. Jednak wystąpił także drugi błąd, a mianowicie przypadkowa skokowa zmiana oświetlenia – najprawdopodobniej spowodowana niepewnym zamocowaniem oświetlacza.



Rys. 5.22. Zmiany cech obrazów w grupie sekwencji SMB40G2\_p60v1\_cdef

Występowanie tego rodzaju zjawisk wywołało konieczność wyznaczania progu binaryzacji **indywidualnie dla każdej sekwencji**.

Ostatecznie przyjęto więc, że próg binaryzacji będzie ustalany **dla każdej sekwencji** obrazów według wzoru:

$$PR_{msp} = \text{mediana}(wp * (\text{percentyl}_1\%(X_i) + \text{percentyl}_{99}\%(X_i))) \quad (5.4)$$

gdzie:  $X_i$  – i-ty obraz w sekwencji  
 $wp$  – stały współczynnik

Zgodnie z tym wzorem, program o nazwie *Progi2* [P50] wyznacza progi binaryzacji dla poszczególnych sekwencji obrazów i zapisuje je w pliku „progi .txt” razem z nazwami sekwencji.


Początkowo ustalono wartość współczynnika  $wp$  na 0,5 czyli wyznaczano medianę ze średnich arytmetycznych percentyli 1% i 99% poszczególnych obrazów danej sekwencji.

Ostatecznie – przyjmując kryterium maksymalnego odzwierciedlenia zmian pokrycia powierzchni nanoszonym materiałem kompozytowym - ustalono eksperymentalnie wartość współczynnika  $wp=0,35$ . Obniżenie w ten sposób progu - w stosunku do opisanej w 2.1 metody BN99 – pozwoliło maksymalnie zwiększyć czułość wykrywania pojawiających się w trakcie tarcia plam nanoszonego materiału.

W omawianym przypadku dla grupy sekwencji SMB40G2\_p60v1\_cdef program „*progi2*” wyznaczył próg 17 dla pierwszej sekwencji (C) oraz 23 dla pozostałych (D, E, F).

Wyniki analizy – tym razem w funkcji czasu, a nie numerów obrazów - dla tej grupy sekwencji pokazano na Rys. 5.23. Momenty rejestracji obrazów były – przy pomocy funkcji „*inf\_obraz*” [P52] odczytywane z plików informacyjnych „\*.inf” tworzonych w trakcie rejestracji dla każdego obrazu.

Jak widać (Rys. 5.23) pokrycie przy przejściu z serii C do D rośnie w takim przypadku o 9%, a nie o 40 jak poprzednio, co jest wynikiem wiarygodnym przy uwzględnieniu przerwy między rejestrowaniem serii C i D, w trakcie której tarcie było kontynuowane i nastąpił dalszy wzrost pokrycia powierzchni jasnymi pasmami.



Rys. 5.23. Wyniki analizy grupy sekwencji SMB40G2\_p60v1\_cdef dla progów dobieranych oddzielnie dla każdej sekwencji w/g wzoru: 8.5

### 9.6.3 Program do analizy binarnych sekwencji obrazów

Do analizy sekwencji binarnych opracowano w Matlabie program o nazwie Analiza4CB [P51]. Przed uruchomieniem tego programu - a po wygenerowaniu plików spisów oraz dokonaniu oceny konieczności ewentualnych korekt błędów i zakłóceń procesu akwizycji - należy określić wartości parametrów pracy programu Analiza4CB objaśnione w tabeli poniżej i ewentualnie dokonać modyfikacji linii programu definiujących te parametry.

**Tabela 5.3.** Parametry pracy programu Analiza4CB

Parametr	Dopuszczalne wartości i ich znaczenie
<i>czb</i>	<i>czb</i> =0 to analiza plam ciemnych, <i>czb</i> =1 to analiza plam jasnych
<i>KierTarcia</i>	Kierunek śladów tarcia 1=poziomy, 0=pionowy, wymagający transpozycji
<i>skala</i>	<i>skala</i> =0.2 - zmniejszanie obrazu dla przyspieszenia analizy
<i>xp</i>	<i>xp</i> (w pikselach) lewy margines – obcinany z obrazu
<i>xk</i>	<i>xk</i> (w pikselach) prawy margines – obcinany z obrazu
<i>wsp</i>	<i>wsp</i> = 0.35; współczynnik progowania
<i>kat_obr</i>	<i>kat_obr</i> = 0; kąt obrotu w zakresie 0-90 stopni

Po uruchomieniu program Analiza4CB realizuje następujące operacje:

- 1) Wyświetla wartości parametrów pracy wraz z objaśnieniami i pozwala je skorygować.

- 2) Po akceptacji wartości parametrów pojawi się okno dialogowe z poleceniem otwarcia w folderze wyników pliku *source.dir*. Jeśli brak tego pliku to znaczy, że należy wcześniej uruchomić program Spisy6. Po wybraniu pliku *source.dir* reszta analizy odbywa się samoczynnie.
- 3) Następuje sprawdzenie czy istnieje plik PROGI.TXT, a jeśli nie to zostaje wywołana procedura *progi2*, która tworzy taki plik wyznaczając i zapisując w nim progi binaryzacji dla poszczególnych sekwencji obrazów. Następnie pojawia się napis: „Aby poprawić progi naciśnij CTRL-C. Aby kontynuować naciśnij ENTER”
- 4) Po zatwierdzeniu kontynuowania pracy, plik PROGI.TXT zostaje otwarty i wykorzystany przy binaryzacji i otwieraniu spisów obrazów poszczególnych sekwencji. Następuje wczytywanie obrazów z każdej sekwencji i poddawanie ich odpowiednim operacjom, a między innymi:
  - obcinaniu ustalonych wcześniej marginesów *xp*, *xk* (jeśli są większe od zera),
  - obróceniu – jeśli zadeklarowany kąt obrotu (*kat\_obr*) jest większy od zera,
  - transpozycji macierzy obrazu gdy kierunek tarcia (*KierTarcia*) jest pionowy,
  - binaryzacji progowej – według wyznaczonego dla danej sekwencji progów,
  - skalowaniu obrazu dla przyspieszenia analizy,
  - filtracji medianowej (okno medianizacji 3x3),
- 5) W trakcie tych operacji program rejestruje nazwę obrazu o minimalnym pokryciu powierzchni oraz nazwę obrazu o maksymalnym pokryciu powierzchni śladami tarcia oraz wyświetla te obrazy.
- 6) Ostatecznie - spełniając swą podstawową funkcję - program wyznacza dla poszczególnych obrazów cechy opisane w p. 2.2 i prezentuje je w postaci wykresów (w funkcji czasu rejestracji - odczytywanego z plików „\*.inf”), a mianowicie:
  - przebieg zmian deskryptora *Pokr* - pokrycia procentowego powierzchni obrazów śladami tarcia - reprezentującymi naniesiony w trakcie tarcia materiał;
  - przebieg zmian ortotropii względnej obrazów *Dy/Dx*;
  - udział pasm „krótkich”, „średnich” i „długich” w pokryciu obrazu.
- 7) Oprócz wyświetlania wyników w postaci obrazów i wykresów, generowany jest plik tekstowy z wynikami. Plik ten posiada nazwę „**Wy\_seria.txt**” gdzie *seria* jest nazwą badanej sekwencji obrazów.

#### 9.6.4 Funkcja aproksymująca przebieg zmian pokrycia powierzchni stali materiałem kompozytowym

Jak wynika z obserwacji wyników analiz przebieg zmian względnego **pokrycia** powierzchni obrazu naniesionym materiałem (filmem transferowym) w funkcji liczby ślizgów *Ls* lub drogi tarcia *S*, jest jedną z najistotniejszych charakterystyk związanych z własnościami badanego materiału.

Przy rejestracji obrazów automatycznie rejestrowano czas **t [sek]**. Na podstawie tego czasu i prędkości ślizgania **v [m/s]** (zawartej w nazwie sekwencji) można wyznaczyć drogę

ślizgania  $S=v*t$ , a ponieważ obwód śladu tarcia na tarczy przeciwpróbkowej wynosi  $Obw = 0,5 [m]$  więc:

$$Ls = S/Obw = (v [m/s] * t [sek] ) / 0,5[m] = 2*v*t \quad (5.5)$$

Dopasowywano różnego rodzaju krzywe teoretyczne do poszczególnych wykresów próbując znaleźć ogólną zależność dla wszystkich typów przebiegu zmian filmu transferowego.

Po wielu próbach i eksperymentach stwierdzono, że najlepiej można opisać praktycznie wszystkie te przebiegi przy pomocy następującej funkcji złożonej z dwu członów wykładniczych o różnych stałych czasowych:

$$pk(Ls) = Pk0 + Pk1 \cdot (1 - e^{-\frac{(Ls-Ls1)}{T1}}) + Pk2 \cdot (1 - e^{-\frac{(Ls-Ls2)}{T2}}) \quad (5.6)$$

W powyższej funkcji należy jeszcze wyzerować tą część przebiegu, która przyjmie wartości ujemne przez dodatkowe zastosowanie funkcji IF:

$$PK(Ls) = IF(pk(Ls) > 0, pk(Ls), 0) \quad (5.7)$$

Oto znaczenie poszczególnych oznaczeń w powyższych wzorach:

- $PK(Ls)$  – funkcja aproksymująca przebieg zmian pokrycia względnego pola obrazu filmem transferowym (0=brak pokrycia, 1=pełne pokrycie)
- $Ls$  – liczba ślizgów czyli obrotów tarczy
- $Pk0$  – początkowy poziom pokrycia - dla czystej tarczy powinien wynosić zero
- $Ls1$  – liczba ślizgów po której rozpoczyna się wzrost pokrycia
- $Pk1$  – poziom ustalony pierwszego członu wykładniczego
- $T1$  – stała czasowa pierwszego członu wykładniczego
- $Ls2$  – liczba ślizgów po której rozpoczyna się działanie drugiego członu wykładniczego
- $Pk2$  – poziom ustalony drugiego członu wykładniczego funkcji
- $T2$  – stała czasowa drugiego członu wykładniczego

Funkcję [P53] aproksymującą przebiegi zgodnie z powyższymi wzorami opracowano dla Excel'a w języku VBA.

## 9.6.5 Wyniki analizy

Jako wyniki działania programu ANALIZA4CB dla każdej serii otrzymano:

- obrazy pierwszy i ostatni w danej sekwencji,
- obrazy ekstremalne czyli obraz o minimalnym oraz obraz o maksymalnym pokryciu powierzchni filmem transferowym w danej serii - po binaryzacji,
- wykresy cech zdefiniowanych w p.2.2 - pokrycia względnego, ortotropii względnej oraz udziału pasm krótkich, średnich i długich.


### 9.6.5.1 Materiał SM-K22G3

Materiał ten ma ciemną barwę wskutek domieszek koksu i grafitu, jednak zmieniając sposób oświetlenia badano pozostawiane przez niego ślady w polu jasnym a także w polu ciemnym.


Pierwsze zarejestrowane sekwencje wykazują brak równoległości kierunku tarcia względem któregośkolwiek boku kadru obrazu, co wymagało obrócenia obrazów o +52 stopnie i odpowiedniego przycięcia. W tej serii rejestrowano obrazy przy każdym obrocie tarczy, bez przerw, więc numeracja obrazów jest proporcjonalna do skali czasu.

Nazwy sekwencji zawierają:

- nazwę badanego materiału kompozytowego np.: SM-K22G3
- wartość zadawanego nacisku w [N] np.: p20
- wartość liniowej prędkości ślizgowej w [m/s] np.: v3
- oznaczenie literowe sekwencji lub grupy sekwencji np.: „c” lub „ijk”




Rys. 5.24. Obrazy ekstremalne sekwencji SM-K22G3\_p30\_v0.84\_a (wycinek po obróceniu)




Rys. 5.25. Charakterystyki sekwencji SM-K22G3\_p30\_v0.84\_a (bez obracania)







Rys. 5.26. Charakterystyki sekwencji SM-K22G3\_p30\_v0.84\_a po obróceniu obrazów o 52 stopnie




Rys. 5.27. SMK22G3\_p30v0.84. Aproksymacja pokrycia względnego funkcją wykładniczą. Wzrost pokrycia o 60%. Szybkość wzrostu: ok.57% na 100 ślizgów




Rys. 5.28. Obrazy o ekstremalnym pokryciu w serii SMK22G3\_P30\_V2.52\_c (wycinek po obróceniu)




Rys. 5.29. Cechy sekwencji SMK22G3\_P30\_V2.52\_c (bez obracania)




Rys. 5.30. Cechy sekwencji SMK22G3\_P30\_V2.52\_c po obrocie obrazów – szybkość wzrostu pokrycia ok.15% na 100 ślizgów




Rys. 5.31. Obrazy ekstremalne w grupie sekwencji SM-K22\_p20\_v3\_cdefgh




Rys. 5.32. Charakterystyki grupy sekwencji SM-K22\_p20\_v3\_cdefgh




Rys. 5.33. . SMK22G3\_p20v3\_ch. Aproksymacja pokrycia względnego funkcją wykładniczą




Rys. 5.34. Najciemniejszy i najjaśniejszy obraz grupy SM-K22G3\_p60v1\_mno




Rys. 5.35. Charakterystyki grupy sekwencji SM-K22G3\_p60v1\_mo




Rys. 5.36. SMK22G3\_p60v1\_mno. Aproksymacja pokrycia względnego funkcją wykładniczą




Rys. 5.37. Najciemniejszy i najjaśniejszy obraz w sekwencji SM\_K22G3\_p30\_v3\_cdef po ograniczeniu pola kadru (margines 480 pikseli.)




Rys. 5.38. Zmiany pokrycia powierzchni i innych parametrów obrazów w sekwencji SM\_K22G3\_p30\_v3\_cdef po ograniczeniu pola kadru




Rys. 5.39. SMK22G3\_p30v3\_cf. Aproksymacja pokrycia względnego funkcją wykładniczą



Rys. 5.40. Obrazy ekstremalne grupy sekwencji obrazów SM-K22G3\_p20\_v3\_cdef.




Rys. 5.41. Charakterystyki grupy sekwencji obrazów SM-K22G3\_p20\_v3\_cdef.




Rys. 5.42. SMK22G3\_p20v3\_cdef. Aproksymacja pokrycia względnego funkcją wykładniczą


### 9.6.5.2 Materiał SM-2




Rys. 5.43. Obrazy ekstremalne w serii SM2\_P30\_V0.84\_1a (1A) - wycinek po obroceniu




Rys. 5.44. Charakterystyki sekwencji SM2\_P30\_V0.84\_1a (1A) po obroceniu obrazów o 52 stopnie




Rys. 5.45. Obrazy ekstremalne w sekwencji SM2\_P61\_V2.52\_1d (1D) - wycinek po obroceniu




Rys. 5.46. Charakterystyki sekwencji SM2\_P61\_V2.52\_1d (1D) po obroceniu obrazów o 52 stopnie




Rys. 5.47. Obrazy: najciemniejszy i najjaśniejszy w sekwencji PTFE\_p20v3\_c



Rys. 5.48. Charakterystyki sekwencji PTFE\_p20v3\_c




Rys. 5.49. Obrazy: najciemniejszy i najjaśniejszy w sekwencji PTFE\_p20v3\_ef




Rys. 5.50. Charakterystyki grupy sekwencji PTFE\_p20v3\_ef






Rys. 5.51. Obrazy: najciemniejszy i najjaśniejszy w sekwencji "PTFE po tarcu g"




Rys. 5.52. Charakterystyki sekwencji "PTFE po tarcu g"


### 9.6.5.3 Materiał SM-B40G2 – analiza pasm jasnych w polu ciemnym




Rys. 5.53. Obrazy pierwszy i ostatni w grupie sekwencji SM-B40G2\_p20\_v3\_cg




Rys. 5.54. Charakterystyki grupy sekwencji SMB40G2 p20v3 C do G (11.I.2006)



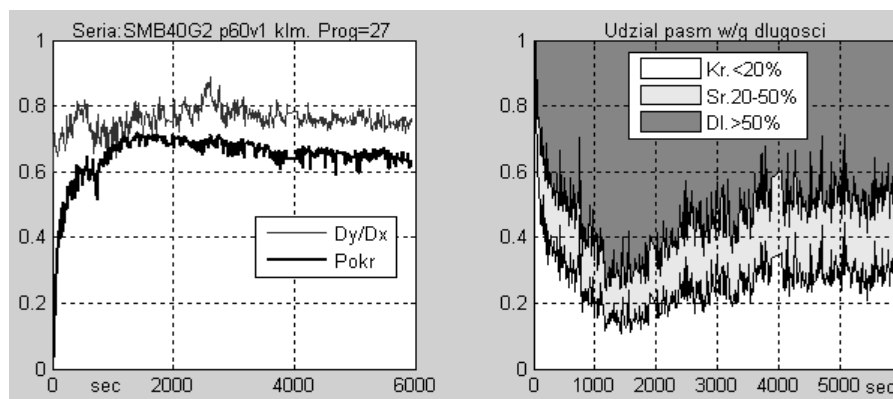
Rys. 5.55. SMB40G2\_p20v3\_cg. Aproksymacja pokrycia względnego funkcją wykładniczą




Rys. 5.56. SMB40G2\_p20v3\_cg. Aproksymacja pokrycia względnego po korekcie drgań




Rys. 5.57. Najjaśniejszy i najciemniejszy obraz w grupie sekwencji SMB40G2\_p60v1\_klm




Rys. 5.58. Charakterystyki grupy sekwencji SMB40G2 p60v1\_KLM




Rys. 5.59. SMB40G2\_p60v1\_klm. Aproksymacja pokrycia względnego funkcją wykładniczą




Rys. 5.60. Obrazy: najciemniejszy i najjaśniejszy w sekwencji SM-B40G2\_p20\_v3\_h




Rys. 5.61. Charakterystyki sekwencji SMB40G2\_p20v3\_h (12.I.2006)




Rys. 5.62. Obrazy: najciemniejszy i najjaśniejszy w grupie sekwencji SMB40G2\_p20\_v3\_ijk



Rys. 5.63. Charakterystyki grupy sekwencji SMB40G2\_p20v3\_ijk (12.I.2006)




Rys. 5.64. SMB40G2\_p20v3\_hijk. Aproksymacja pokrycia względnego funkcją wykładniczą




Rys. 5.65. SMB40G2\_p60v1\_cdef. Aproksymacja pokrycia względnego funkcją wykładniczą

#### 9.6.5.4 Materiał SM-S25 – analiza pasm jasnych w polu ciemnym




Rys. 5.66. Obrazy: najciemniejszy i najjaśniejszy w grupie sekwencji SM-S25\_p20v3\_cdef




Rys. 5.67. Charakterystyki grupy sekwencji SM-S25\_p20v3\_cdef


Bardzo wolny wzrost pokrycia powierzchni do ok.7%. Przewaga pasm krótkich w całym procesie.




Rys. 5.68. SM-S25\_p20v3\_cf. Aproxymacja pokrycia względnego funkcją wykładniczą




Rys. 5.69. Obrazy: najciemniejszy i najjaśniejszy w grupie sekwencji SM-S25\_p60v1\_klmm




Rys. 5.70. Charakterystyki grupy sekwencji SM-S25\_p60v1\_klmm



Rys. 5.71. SM-S25\_p60v1\_kn. Aproksymacja pokrycia względnego funkcją wykładniczą




Rys. 5.72. Obrazy o minimalnym i maksymalnym pokryciu – bez filtracji i obcinania



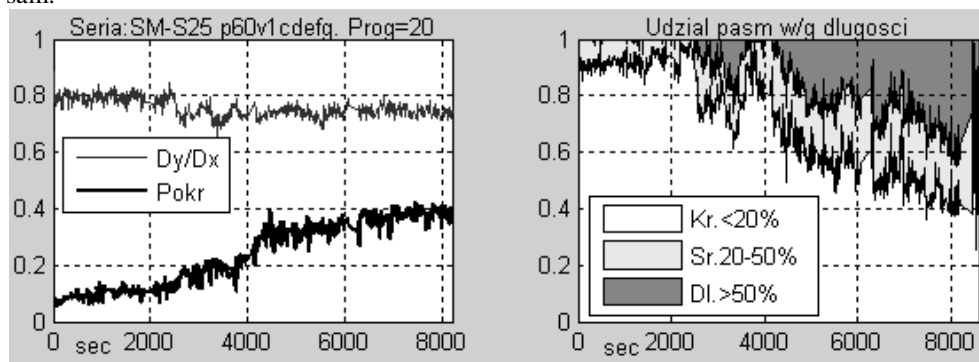
Rys. 5.73. Charakterystyki grupy sekwencji SM-S25\_p60v1\_cf






Rys. 5.74. SM-S25\_p60v1\_cf. Aproksymacja pokrycia względnego funkcją wykładniczą

Po skorygowaniu progu binaryzacji do 20 oraz dołączeniu sekwencji „g” otrzymano nieco inny wynik co do wartości, jednak charakter krzywej zmian pokrycia pozostał taki sam.




Rys. 5.75. Charakterystyki grupy sekwencji SM-S25\_p60v1\_cdefg

Pokrycie wykazuje stały wolny wzrost, w przybliżeniu liniowy.




Rys. 5.76. Obrazy o najmniejszym i największym pokryciu względnym w grupie SM-S25\_p20\_v3\_im


Rys. 5.76 przedstawiona obrazy bez filtracji i obcinania. Filtracja usunęła większość drobnych punktów wynikających z szumu oraz obcięto część obrazu znajdującą się poza obszarem tarcia co pokazano na rysunku kolejnym.



Rys. 5.77. Obrazy ekstremalne w grupie SM-S25\_p20\_v3\_im po filtracji i obcinaniu



Rys. 5.78. Charakterystyki grupy sekwencji SM-S25\_p20v3\_im




Rys. 5.79. SM-S25\_p20v3\_im. Aproksymacja pokrycia względnego funkcją wykładniczą

## 9.6.6 Podsumowanie wyników i wnioski


Stosunkowo niewielka liczba przeprowadzonych eksperymentów i uzyskanych w ich wyniku przebiegów nie pozwala wprowadzić na wiarygodne statystycznie uogólnienia, jednak zestawienie i obserwacja krzywych uzyskanych dla poszczególnych materiałów pozwala sformułować następujące podsumowania i wnioski:

- a) Materiał SM2 czyli czysty PTFE nie tworzył w przeprowadzonych eksperymentach stabilnego pokrycia powierzchni, najczęściej występowało chwilowe pojawianie się cząstek materiału i bardzo szybkie ich zanikanie.




Rys. 5.80. Przebiegi wzrostu pokrycia powierzchni materiałem SM-S25

- b) Pokrycie powierzchni materiałem SM-S25 (Rys. 5.80) - zawierającym 25% włókna szklanego – stabilizowało się na poziomie nie przekraczającym trzydziestu procent. Przebieg dawał się opisać pojedynczą funkcją wykładniczą o stałej czasowej odpowiadającej liczbie 3000 – 7000 ślizgów. Inicjacja wzrostu pokrycia następowała często po losowo zmieniającej się pauzie. Nie zaobserwowano spadku pokrycia.
- c) W przypadku materiału SM-B40G2 - zawierającego 40% brązu i 2% grafitu – narastanie pokrycia powierzchni (Rys. 5.81) rozpoczynało się bez jakiegokolwiek zwłoki i zachodziło z około 10 razy większą szybkością niż dla SM-S25 lub SM-K22G3. Maksymalne osiągnięte pokrycie było również kilkukrotnie większe i dochodziło do 70%. Przebiegi aproksymowano kombinacją dwu krzywych wykładniczych o różnych stałych czasowych, gdyż po szybkim wzroście następował na ogół dalszy wolny wzrost, a w jednym przypadku powolny spadek.
- d) Przebiegi wzrostu pokrycia materiałem SM-K22G3 (Rys. 5.82) – zawierającym 22% koksu i 3% grafitu – wykazywały większy rozrzut stałych czasowych. W większości przypadków pokrycie nie było stabilne i po osiągnięciu w sposób wykładniczy pewnego poziomu następowało również wykładnicze zmniejszanie się pokrycia powierzchni z podobną jak przy wzroście lub większą szybkością. W niektórych przypadkach narastanie rozpoczynało się po zwłóce czasowej.



Rys. 5.81. Przebiegi wzrostu pokrycia powierzchni materiałem SM-B40G2




Rys. 5.82. Przebiegi wzrostu pokrycia powierzchni materiałem SM-K22G3

## 9.7 Zmiany kurtozy i niejednorodności w sekwencjach obrazów


Wykorzystując niewrażliwość kurtozy populacji pikseli oraz kurtozy histogramu na fluktuacje jasności i kontrastu przeprowadzono próbę zbadania ich zmian na testowej sekwencji obrazów „A” – analizowanej także innymi metodami. Rys. 5.83 przedstawia porównanie zmian kurtozy populacji pikseli z przebiegiem zmian względnego pokrycia obrazu

binarnego. Jak widać – nieliniowość kurtozy powoduje zmianę kształtu przebiegu jednak jego tendencja jest analogiczna.



Rys. 5.83. Porównanie zmian kurtozy populacji pikseli z przebiegiem BIN60 - zmian względnego pokrycia obrazu binarnego uzyskanego przy progu binaryzacji  $p=60$


Kolejne próby pokazano w publikacji [W6] gdzie wykorzystano niejednorodność kurtozy histogramów obrazów. Przebieg tej cechy dla tej samej sekwencji obrazów pokazuje Rys. 5.84. Ze względu na nieliniowość, zastosowanie takich cech jest dyskusyjne.



Rys. 5.84. Niejednorodność kurtozy histogramów obrazów sekwencji „A” oraz „1A”

## 9.8 Przykład analizy różnic binarnych sekwencji obrazów

Sekwencja obrazów SM2\_P30\_V0.84\_1a oznaczona skrótowo symbolem „1A” została zarejestrowana w trakcie tarcia półprzezroczystych próbek czystego tarflenu o stalową tarczę tribotestera. Przy dokładnej obserwacji utworzonej z niej animacji widać krótkotrwałe pojawianie się, na niektórych obrazach (Rys. 5.85a), cząstek materiału słabo odróżniających się od tła – ze względu na ich pół-przezroczystość - nawet po maksymalnym zwiększeniu kontrastu (Rys. 5.85b).



Rys. 5.85. Przykładowy obraz z wykrywaną plamą. a) oryginał, b) po wyrównaniu histogramu, c) mapa cechy „Odwrotny moment uwydatnienia krótkich pasm dla kierunku 90°”

W ramach analizy cech obrazów teksturowych szarych dokonano – przy pomocy programów MaZda i Convert - próby automatycznej selekcji ekstensywnej cech dyskryminacyjnych, pozwalających odróżniać obrazy z tego rodzaju subtelnymi plamami od obrazów bez plam. Próba ta nie dała zadowalających rezultatów co m.in. uwidacznia Rys. 5.85c, na którym pokazano mapę bitową wyznaczonej w ten sposób najlepszej cechy dyskryminacyjnej o nazwie: „Odwrotny moment uwydatnienia krótkich pasm dla kierunku 90°”.

Zastosowanie binaryzacji ze stałym progiem oraz metod analizy skutecznych dla innych sekwencji okazało się w tym przypadku także niezadowalające m.in. dlatego, że zmiany cech wywołane zakłóceniami procesu akwizycji (a szczególnie fluktuacje jasności) były większe niż wywołane badanymi zjawiskami.

Zastosowano więc bardzo czułą metodę jaką jest **binaryzacja różnicowa** w celu wyznaczenia cechy *Pokr* (patrz 2.2.1 i wzór 5.1) - procentowego pokrycia pola obrazu obszarem ciemnych „plam” – jako detektora zjawisk nanoszenia i usuwania materiału polimerowego na powierzchni stalowej tarczy tribotestera.

Jak się również okazało – niezbędne było poprzedzenie binaryzacji różnicowej eliminacją niektórych zakłóceń – o czym dokładniej napisano poniżej, a także w pracy [W7] .

### 9.8.1 Binaryzacja różnicowa bez korekty zakłóceń

**Binaryzacja różnicowa** polega na uzyskiwaniu wartości pikseli wynikowego obrazu czarno-białego jako wartości logicznych relacji między odpowiadającymi sobie pikselami dwu obrazów szarych o jednakowych rozmiarach. Operacja ta jest równoważna złożeniu dwu operacji: odejmowania obrazów oraz binaryzacji ze stałym progiem  $kp$ .

W przypadku sekwencji obrazów szarych  $X$  - prezentującej zmiany wybranego wycinka badanej powierzchni – binarną sekwencję różnicową  $B$  uzyskuje się przez porównanie drugiego i kolejnych obrazów sekwencji  $X$  z pierwszym obrazem tej sekwencji. Dokładniej, binarną sekwencję różnicową  $B$  uzyskuje się jako logiczny wynik następującej relacji:

$$B_i = X_i > (X_1 - kp); i=2,3, .. L_i \quad (5.8)$$

gdzie  $kp$  – to współczynnik korygujący próg binaryzacji, którym jest pierwszy obraz.



Rys. 5.86. Binarystacja różnicowa obrazów: (a) i (b) różne progi binaryzacji, (c) po dodatkowej filtracji medianowej (okno medianizacji: 15x15)

Zastosowanie tej operacji dla badanej sekwencji  $X=„IA”$  dało - dla  $kp=0$  - efekt pokazany na Rys. 5.86a. Drobne przemieszczenia kadru obrazów w ramach sekwencji oraz fluktuacje jasności wywołują błędy w postaci widocznych na tych rysunkach ukośnych pasm. Lekkie skorygowanie progu binaryzacji ( $B_i = X_i > X_{i-4}$ ) rozjaśniło obraz wynikowy (Rys. 5.86b), a dodatkowa filtracja medianowa [38] usunęła (Rys. 5.86c) część drobnych zakłóceń wynikających z przesunięcia obrazów, chociaż także wprowadziła dodatkowo czarną ramkę jako efekt uboczny tej metody filtracji.



Rys. 5.87. Wyniki odejmowania i binaryzacji ze stałym progiem. Obraz środkowy błędny.

Wydawało się, że metoda jest do przyjęcia, niestety po przeglądnięciu sekwencji otrzymanej w wyniku takiej binaryzacji różnicowej, okazało się że dla niektórych obrazów występują błędy grube - takie jak pokazany na Rys. 5.87 obraz środkowy - wynikające z fluktuacji jasności i przesunięć obrazów. W związku z tym opracowano metody kompensacji zarówno efektów przemieszczeń obrazów jak i fluktuacji ich jasności.


## 9.8.2 Binarystacja różnicowa z zastosowaniem korekt

Dla rozwiązania powyżej opisanego problemu opracowano w języku Matlab programy realizujące:

- detekcję przesunięć obrazów,
- korektę tych przesunięć,
- ujednoczenie rozmiarów obrazów po korekcie,
- korektę fluktuacji jasności obrazów (wynikających najprawdopodobniej z niestabilności błysków oświetlacza) – poprzez stabilizację jasności percentyla 80% reprezentującego jasność tła obrazów,
- binaryzację różnicową,
- filtrację medianową szumów z korektą błędów medianizacji na brzegach obrazów.

Korektę fluktuacji jasności zrealizowano metodą opisaną w 5.5.2.

Program do binaryzacji różnicowej z korektą przemieszczeń i fluktuacji jasności *kormin2009* [P47] wykorzystuje funkcje  $C=korminus9(B,A)$  oraz opisaną w 5.5.3. funkcję  $[dx,dy] = BtransA(B,A)$  [P43]. Przykładowy wynik pokazano na Rys. 5.88.



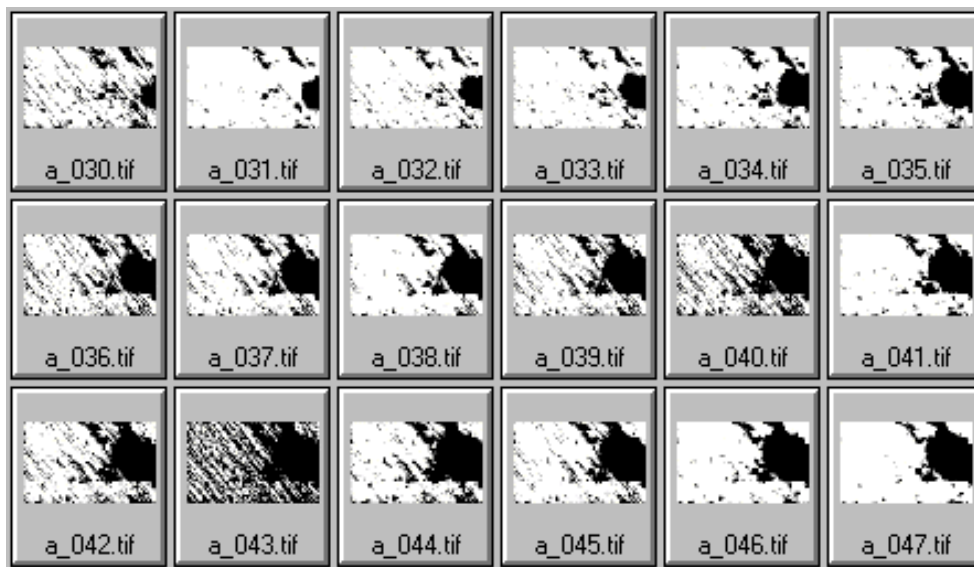
Rys. 5.88. Różnica binarna obrazów po korekcie przesunięcia i jasności:  
a) różnica, b) różnica po filtracji medianowej (okno 9x9)

Rys. 5.88a pokazuje także szum elementów elektronicznych, a w szczególności matrycy CCD kamery – uwidaczniony przez tak czułą metodę różnicową. Szum ten odfiltrowano przy pomocy dolnoprzepustowej filtracji medianowej.

Kolejne rysunki (Rys. 5.89, Rys. 5.90, Rys. 5.91) pokazują wyraźniej uzyskane efekty dla fragmentu sekwencji „A” (SM-K22G3\_p30\_v0.84\_a) obrazującej transfer materiału kompozytu K-22G3 na powierzchnię stali.

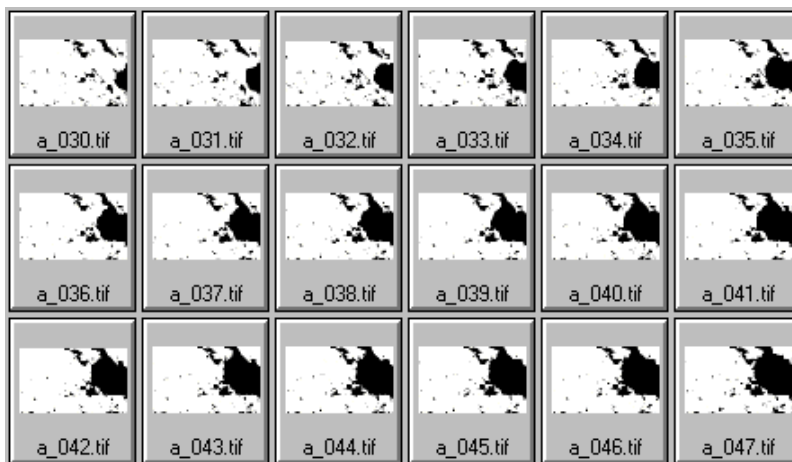
Rys. 5.89 to fragment sekwencji uzyskanej z zastosowania metody różnicowej bez korekty przesunięć i jasności obrazów. Rys. 5.90 zawiera te same obrazy uzyskane po korekcie i binaryzacji różnicowej, a Rys. 5.91 pokazuje przebieg zmian parametru  $L_c$  (liczba czarnych pikseli) przed i po korekcie.

Analogiczne wykresy lecz dla różnicowej detekcji śladów transferu materiału SM-2 (czysty tarflen) przed i po korekcie przesunięć i jasności obrazów w sekwencji „1A” pokazano na kolejnych rysunkach oraz na animacjach udostępnionych na stronie [S1].




Rys. 5.89. Rezultaty binaryzacji różnicowej bez korekty przesunięć i jasności obrazów






Rys. 5.90. Rezultaty binaryzacji różnicowej po korekcie przesunięć i jasności obrazów



Rys. 5.91. Wzrost pokrycia powierzchni tarczy tribotestera materiałem SM-K22G3




Rys. 5.92. Rezultaty korekty przesunięć i fluktuacji jasności obrazów śladów materiału SM-2

## 9.9 Przykład analizy różnic histogramów skumulowanych


W rozdziale 4.4.2 oraz publikacji [W10] opisano metodę **MRHS - maksimum różnic histogramów skumulowanych** pozwalającą na badanie zmian sumarycznego pola ciemnych (lub jasnych) obiektów pojawiających się w sekwencji obrazów, względem obrazu pierwszego traktowanego jako tło.

Metodę przetestowano m.in. na obrazach sztucznie wygenerowanych a także na sekwencji 150 rzeczywistych obrazów tribologicznych SM-K22G3\_p30\_v0.84\_a oznaczonej skrótowo symbolem "A" na której zarejestrowano rozwój ciemnej plamy filmu transferowego, aż do rozmiarów przekraczających 50% pola obrazu. Sekwencja ta była wcześniej analizowana innymi metodami, których wyniki przyjęto za materiał porównawczy.

Cztery wybrane obrazy z tej sekwencji (A\_001, A\_043, A\_047, A\_150) oznaczone skrótowo jako A1, A2, A3, A4 pokazuje Rys. 5.93.



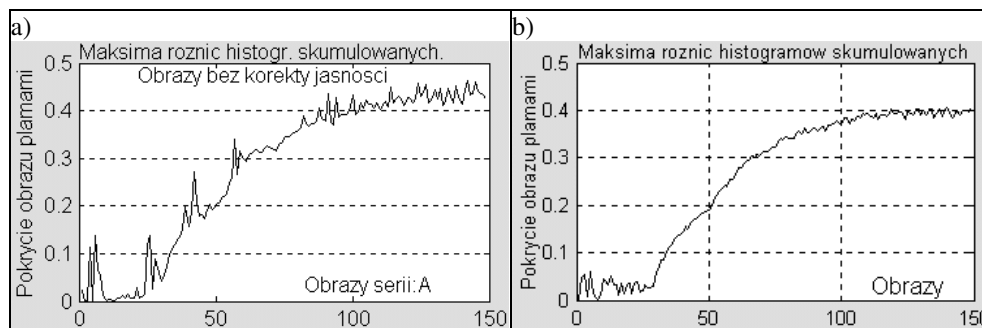
Rys. 5.93. Przykładowe obrazy z sekwencji "A", nazywane dalej: A1, A2, A3, A4




Analizowane sekwencje obarczone były zakłóceniami (omawianymi dokładniej w osobnym rozdziale) do których należały: szумы, fluktuacje jasności i drgania powodujące niewielkie przemieszczenia kadru obrazu. W pewnych przypadkach - szczególnie przy dużej powierzchni pola plam filmu transferowego i dużej ich zmienności, utrudniona lub niemożliwa była automatyczna identyfikacja i korekta przemieszczeń obrazów, dlatego poszukiwano jeszcze innych metod analizy sekwencji obrazów, a w szczególności odpornych na przemieszczenia kadru obrazów. Nasunął się więc pomysł wykorzystania histogramów obrazów jako charakterystyk niezależnych od informacji o rozkładzie przestrzennym pikseli i co za tym idzie mało wrażliwych na drgania kadru.

Jednak, jak widać na Rys. 5.94, są to histogramy wielomodalne o niestabilnym przebiegu z szeregiem szpilkowych maksimumów. Analizowanie takich histogramów oraz ich różnic było niewygodne. Znacznie łatwiej było analizować różnice histogramów skumulowanych pokazane na Rys. 5.95 i taka była geneza metody MRHS.

Analizowane sekwencje były wcześniej poddane filtracji szumu, normalizacji, oraz stabilizacji fluktuacji jasności – na poziomie percentyla 80% (opisanej w 5.5.2). Metoda jest bowiem wrażliwa na fluktuacje jasności obrazów. Przebieg wzrostu pokrycia obrazu rozwijającą się ciemną plamą bez zastosowania tej korekty pokazuje przebieg na Rys. 5.96a, natomiast przebieg po zastosowaniu korekty pokazuje Rys. 5.96b.



Rys. 5.96. Rozwój plamy filmu transferowego w/g metody MRHS



Rys. 5.97. Rozwój plamy filmu transferowego w/g metod KorMin oraz Bin62

Rys. 5.97 pokazuje dla porównania przebieg rozwoju plamy filmu transferowego w sekwencji „A” uzyskany stosowanymi poprzednio metodami - binaryzacji ze stałym progiem (Bin62) oraz binaryzacji różnicowej (KorMin).

Jak widać, przebieg uzyskany metodą MRHS (Rys. 5.97) wykazuje wartości niższe niż w metodach Bin62 i KorMin. Wyjaśnienie tego wymaga dalszych badań.

W metodach KORMIN i BIN62 bezwzględne wartości wyników zależą od przyjęcia poziomu binaryzacji obrazu, podczas gdy metoda MRHS nie wymaga takich arbitralnych decyzji. Niestabilny przebieg początkowego odcinka krzywej MRHS oraz dodatkowe badania na seriach w których brak było wyraźnego pojawiania się plam pozwoliły stwierdzić, że metoda daje tym większe błędy im mniej różnią się od siebie histogramy skumulowane. Należy się więc liczyć z tego rodzaju ograniczeniem zastosowań metody MRHS, to znaczy w przypadku bardzo subtelnych różnic obrazów.

## 9.10 Przykład analizy migracji skupisk nanoszonego materiału metodą UC

Zgodnie z definicją w p.1.2.3 sekwencje obrazów reprezentowane są macierzami trójwymiarowymi lub funkcjami trzech zmiennych i jako takie mogą być prezentowane dynamicznie w postaci filmów animowanych. Czasem jednak wymagana jest statyczna uproszczona prezentacja graficzna, uzyskiwana poprzez redukcję liczby wymiarów.

Poniżej opisano jeden z możliwych sposobów uzyskiwania takiej uproszczonej graficznej prezentacji sekwencji obrazów szarych.

**Tabela 5.4.** Parametry przy których rejestrowano badane sekwencje obrazów

Sekwencja obrazów:	A	1A	30P03	30P10	30P30
<b>Parametr:</b>					
Materiał próbki	K22G3	SM-2	K22G3	K22G3	K22G3
Chropowatość tarczy <b>Ra</b> [ $\mu\text{m}$ ]	0,3	0,3	0,03	0,03	0,03
Nacisk <b>F</b> [N]	30	30	30	30	30
Nacisk jednostkowy <b>p</b> [kPa]	312,5	312,5	312,5	312,5	312,5
Prędk. obr. [obr/min]	100	100	35,7	119	357,1
Prędkość liniowa ślizgania <b>v</b> [m/s]	0,84	0,84	0,3	1	3
Iloczyn <b>p<math>\cdot</math>v</b> [kP·m/s]	262,5	262,5	93,75	312,5	937,5
Kier. oświetlenia [ $^{\circ}$ ]	60	60	90	90	90
Czas ekspoz. <b>te</b> [ $\mu\text{s}$ ]	8	8	8	8	8
Liczba obrazów w sekwencji <b>Ns</b>	150	150	4 x 20	3 x 20	3 x 20
Liczba obrotów między ekspozycjami	1	1	2	4	12

Przedmiotem zainteresowania były ciemne ślady nanoszonego na powierzchnię tarczy stalowej materiału kompozytowego, a dokładniej zmiany obszaru powstających plam

oraz ich przemieszczenia. Stosowano próbki: czystego tarflenu SM-2, oraz materiału K22G3 zawierającego oprócz PTFE dodatki 22% koksu i 3% grafitu. Szczegóły dotyczące stanowiska i przebiegu eksperymentów opisano już w p.5.2, natomiast parametry przy jakich rejestrowano poszczególne sekwencje przedstawia **Tabela 5.4**.


W celu zbadania zmian obszaru i położenia skupisk przeniesionego materiału opracowano metodę opisaną w pracy [W13] nazwaną metodą UC – „udziału czerni”. Między innymi dokonano korekty orientacji kadru obrazów, tak aby ślady tarcia miały kierunek poziomy. W niezbędnych przypadkach przeprowadzano także „korektę cienia” czyli przestrzenne wyrównywanie jasności tła.

Po zastosowaniu korekt, obrazy szare badanej sekwencji **X** poddano binaryzacji negatywowej (patrz wzór 1.5) otrzymując sekwencję obrazów binarnych **BN**. Dla skompensowania fluktuacji oświetlenia obrazów zastosowano przy tym adaptacyjne progi binaryzacji  $p_i$  określone wyrażeniem:

$$p_i = 0,51 * (\text{mediana}(X_i) + \text{mediana}(\min(X_i))) \quad (5.9)$$

W późniejszych badaniach zrezygnowano z tej metody ustalania progu zastępując ją metodą opisaną w p. 5.6.2.

Następnie wyznaczano UCW – procentowy udział czarnych pikseli w wierszach obrazów i UCK - procentowy udział czarnych pikseli w kolumnach obrazów, według metody opisanej w p.5.3.2. Niektóre z uzyskanych przebiegów widać na Rys. 5.98 - Rys. 5.102.




Rys. 5.98. Udział czarnych pikseli w kolumnach i wierszach obrazów sekwencji A.


W sekwencji A (Rys. 5.98) widoczny jest rozwój dużej ciemnej plamy w prawej (ostatnie kolumny) i górnej (pierwsze wiersze) części obrazów. Widać też jak pole plamy przekraczające rozmiar połowy obrazu obniża adaptacyjny próg binaryzacji co powoduje zanik widoczności drobnych plam.

W sekwencji 1A (Rys. 5.99) dominują stałe elementy tła aczkolwiek widać też pojawianie się na krótkie momenty nietrwałych plam odpowiadających cząstkom PTFE.


W sekwencji 30P03 (Rys. 5.100) widoczna jest linia odpowiadająca szczelinie pokazywanej na obrazach. Po pierwszych 20 obrazach wyraźne obniżenie skupisk plam na obrazach (z wierszy 250-310 do 380-440). Poza tym w pierwszych 40 obrazach zmiany niewielkie. W kolejnych obrazach widać rozwój i zanik plam, asymetrycznie względem szczeliny.



Rys. 5.99. Udział czarnych pikseli w kolumnach i wierszach obrazów sekwencji 1A.




Rys. 5.100. Udział czarnych pikseli w kolumnach i wierszach obrazów sekwencji 30p03.



Rys. 5.101. Udział czarnych pikseli w kolumnach i wierszach obrazów sekwencji 30p10

W sekwencji 30P10 (Rys. 5.101) przebieg ma podobny charakter jak w 30P03 lecz nieco większa jest trwałość plam oraz ich równomierność w poziomie natomiast w pionie następuje jeszcze większa koncentracja w dolnych partiach obrazów.

W sekwencji 30P30 (Rys. 5.102) przebieg jest podobny jak 30p10 lecz jeszcze bardziej ustabilizowany co do umiejscowienia w dolnych partiach obrazu i wykazujący dynamiczne zmiany w pasach poziomych.



Rys. 5.102. Udział czarnych pikseli w kolumnach i wierszach obrazów sekwencji 30p30

Zamieszczone przykłady ukazują różny charakter rozwoju i zaniku śladów tarcia i skonfrontowane z pomiarami innych parametrów mogą stanowić element szerszych badań tribologicznych.

Przebiegi otrzymano przy pomocy opracowanego w języku Matlab programu Analiza\_UC [P54].

## 9.11 Podsumowanie metod analizy sekwencji obrazów

Głównym celem analizy sekwencji było badanie zmian pokrycia powierzchni nanoszonym materiałem kompozytowym. Dla materiału półprzezroczystego (PTFE) konieczne było zastosowanie binaryzacji różnicowej poprzedzonej korektą przemieszczeń kadru obrazu i korektą fluktuacji jasności oświetlenia błyskowego.

W przypadku pozostałych badanych materiałów kompozytowych wystarczająca była binaryzacja stałoprologowa przy czym próg wyznaczano dla każdej sekwencji osobno co pozwoliło zapobiec skutkom przypadkowych zmian warunków akwizycji w przerwach między sekwencjami.

Jak zwykle najmniej dyskusyjne są wyniki uzyskane metodami najprostszymi i o ile to możliwe - takie metody powinny być preferowane. Zastosowanie metody MRHS należy uznać za nowość wymagającą jeszcze dokładniejszego sprawdzenia i dalszych prac.

Natomiast zarówno uzyskane przebiegi zmian pokrycia, oraz udziału pasm krótkich, średnich i długich jak i otrzymane zobrazowania dwuwymiarowe zmian skupisk nanoszonego materiału przedstawione w p.5.10. mogą być zdaniem autora źródłem cennych informacji dla dalszych badań w obszarze tribologii.

Zbadano także m.in. możliwości wykorzystania kurtozy histogramów obrazów jako cechy odpornej na fluktuacje jasności wynikające ze zmian oświetlenia obrazu. Stwierdzono że stanowi ona cechę użyteczną szczególnie dla detekcji powstawania zmian słabo widocznych na obrazach natomiast ma ograniczone zastosowanie przy śledzeniu rozwoju wyraźnych zmian – ze względu na swój nieliniowy charakter.



## 10. Podsumowanie i wnioski

Komputeryzacja i robotyzacja pozwala coraz częściej wyręczać ludzi także w obserwacji i wzrokowej ocenie stanu powierzchni. Komputerowa analiza i klasyfikacja obrazów wymaga dostosowywania różnorodnych metod do konkretnych typów obrazów. Obrazy powierzchni poddawanych tarcia – nazwane tu obrazami tribologicznymi – stanowią specyficzną grupę dla której dotychczas rzadko stosowano metody analizy komputerowej.

Niniejsza praca skupiła się na dwu oddzielnych choć pokrewnych grupach zagadnień. Jedną z nich stanowiły problemy doboru i rozwijania metod komputerowej analizy, skutecznych dla **rozdzielania obrazów tribologicznych**, odwzorowujących stany powierzchni uczestniczących w tarcia. Drugą grupę zagadnień stanowiły metody **analizy sekwencji obrazów** tribologicznych rejestrowanych podczas procesu tarcia pozwalające uzyskać przebiegi zmian cech powierzchni w funkcji czasu lub drogi tarcia, przy uwzględnieniu różnych parametrów tego procesu.

Wyodrębniono podstawowe klasy obrazów tribologicznych oraz dokonano systematyzacji niektórych pojęć – m.in. rozróżniając obrazy obiektowe i teksturowe, oraz klasyfikując charakterystyki i cechy obrazów według grup pikseli, których dotyczą (pojedynczych pikseli, par, otoczeń, pasm, wierszy i kolumn oraz wyodrębnionych obiektów). Podkreślono wagę cech jakościowych i potrzebę zgodności cech ilościowych z jakościowymi.

Wyróżniono cechy kierunkowe i bezkierunkowe. Wprowadzono pojęcie meta-cech jako własności cech i zaliczono do nich niejednorodność oraz anizotropię. Zaproponowano sposoby określania niejednorodności obrazu względem wybranych cech oraz zdefiniowano miary anizotropii.

Przeanalizowano szereg znanych cech obrazów teksturowych szarych testując ich przydatność dla rozróżniania przykładowych klas obrazów tribologicznych.

Oprócz tego zdefiniowano szereg nowych cech – głównie dla obrazów binarnych, stosując je następnie z powodzeniem w analizie obrazów i sekwencji obrazów. Między innymi wyselekcjonowano cechy UDSW (unormowaną dewiację średnich z wierszy) i UDMedW (unormowaną dewiację median wierszy), które w połączeniu z metodą tworzenia tzw. zbioru obrazów obróconych (i pobierania prostokątnego wycinka obrazu) okazały się najskuteczniejsze dla oceny anizotropii i wyznaczania kierunków głównych tekstury obrazu.

Dzięki opracowanym metodom udało się precyzyjnie określać nie tylko dominujący kierunek śladów tarcia ale także drugi podrzędny kierunek jeśli taki występował.

Rozróżniono i przetestowano dwie grupy metod selekcji cech dyskryminacyjnych, pozwalających rozróżniać klasy obrazów tribologicznych – ekstensywną automatyczną oraz ukierunkowaną według przesłanek badacza, stwierdzając większą skuteczność drugiej natomiast łatwość stosowania pierwszej z nich.

Przedstawiono metody badania wybranych zakłóceń i błędów procesu akwizycji sekwencji obrazów oraz opracowano efektywne metody ich kompensacji. W szczególności dotyczy to kilku skutecznych metod korekty przemieszczeń kadru obrazu, metod wyrównywania przestrzennej nierównomierności jasności tła obrazu oraz metody kompensacji fluktuacji jasności obrazów w ramach sekwencji – polegającej na stabilizacji percentyla odpowiadającego jasności tła.

Zaprezentowano także kilka nowych skutecznych metod wizualizacji zmian zachodzących w sekwencjach obrazów jak metoda MRHS polegająca na badaniu maksimów różnic histogramów skumulowanych oraz metoda UC - wizualizacji zmian „udziału czerni” w kolumnach i wierszach obrazów.

Wyniki badań zilustrowano przy pomocy 189 rysunków i 18 tabel.

W wyniku badań opisanych w niniejszej monografii można sformułować zamieszczone niżej wnioski.

1. Metody komputerowej analizy obrazów mogą być skutecznym środkiem detekcji jakościowych zmian powierzchni, zarówno w procesach obróbki ciernej jak i monitorowania zużycia.
2. Metody przetwarzania i analizy obrazów tribologicznych muszą być dobierane do poszczególnych typów obrazów, przy czym najlepiej gdy badacz określa jakie cechy obrazów są przedmiotem zainteresowania a jakie zmiany stanowią zakłócenia. Również do badacza należy przygotowanie wzorcowych zbiorów obrazów należących do poszczególnych klas.
3. Różne typy obrazów tribologicznych z powodzeniem udało się rozróżnić m.in. przy zastosowaniu takich meta-cech jak niejednorodność danej cechy, oraz anizotropia i ukierunkowanie. Wykazano, że w analizie uporządkowania morfologii obrazów szarych najistotniejsze są cechy o nazwach „niejednorodność szarości” oraz „korelacja”. W większości przypadków, najlepsze rezultaty uzyskiwano jednak po przetworzeniu obrazów na czarno białe i analizie cech obrazów binarnych.
4. W przypadkach ilościowych ocen parametrów stanu powierzchni – metody komputerowej analizy obrazów mogą na ogół stanowić źródło informacji uzupełniających, natomiast traktowanie ich jako podstawowego źródła informacji wymaga dużej ostrożności i spełnienia wielu wymagań m.in. co do jakości otrzymywanych obrazów, możliwości skalowania wybranych cech i statystycznej oceny błędów.
5. Ryzyko błędnej klasyfikacji obrazów może być zminimalizowane w przypadku stosowania cech ilościowych o znanym znaczeniu i odpowiadających cechom jakościowym związanym z istotą badanych procesów.
6. Wykazano na szeregu przykładach, że przy zastosowaniu metod przedstawionych w opracowaniu możliwa jest jakościowa ocena stanu powierzchni oraz wychwycenie tendencji zmian morfologii powierzchni zachodzących podczas procesów tarcia. Udało się to również w obecności wielu błędów i zakłóceń procesu akwizycji obrazów, dzięki opracowanym metodom korygowania tych błędów.
7. W zakresie analizy sekwencji obrazów prezentujących transfer PTFE na powierzchnię stali, udało się z dużą dokładnością aproksymować przebieg zmian powierzchni „filmu transferowego” PTFE przy pomocy krzywych wykładniczych.

## 11. Literatura

### Publikacje własne (w kolejności chronologicznej)

- [W1] Rudnicki Z.: *Wybrane metody przetwarzania i analizy cech obrazów teksturowych*. Informatyka w Technologii Materiałów. Nr 1, Tom 2, Rok 2002, s. 1-18.
- [W2] Oleksiak Z., Rudnicki Z.: *Computer analysis of images of worn surfaces*. Zagadnienia Eksploatacji Maszyn. Zeszyt 3 (131) 2002, s. 73-84.
- [W3] Rudnicki Z., Oleksiak Z., Pytko S., Szydło Z.: *A Method of Processing and Feature Extraction of Tribological Surface Images*. Papers of 6th International Tribology Conference - AUSTRIB'02, Perth, Australia, 2-5 Dec.2002. s. 701-707.
- [W4] Oleksiak Z., Rudnicki Z.: *Wstępna ocena szybkiej metody badania odporności na zużywanie kompozytów tarflenowych*. Mat. X Seminarium: "Tworzywa Sztuczne w Budowie Maszyn". Kraków: Politechnika Krakowska Wydział Mechaniczny IMS KMDiB, 2003. s. 285-289
- [W5] Rudnicki Z., Oleksiak Z.: *Próba oceny zmian filmu nanoszonego podczas tarcia ślizgowego kompozytów PTFE przy pomocy analizy sekwencji obrazów*. Mat. X Seminarium: "Tworzywa Sztuczne w Budowie Maszyn". Kraków : Politechnika Krakowska Wydział Mechaniczny IMS KMDiB , 2003. s.337-341
- [W6] Rudnicki Z.: *Analiza sekwencji obrazów niejednorodnych*. Informatyka w Technologii Materiałów : kwartalnik AGH. - 2003 t. 3 nr 2 s. 86-96.
- [W7] Rudnicki Z., Daca J.: *Komputerowa analiza obrazów metalograficznych w badaniach warstwy wierzchniej oczek ciągnadeł*. Mat. IV Krajowej Konferencji "Metody i Systemy Komputerowe ...". Kraków 2003. s. 361-366.
- [W8] Daca J., Rudnicki Z., Warszyński M.: *Analiza wpływu topografii powierzchni na przebieg zjawisk tribologicznych*. XXI Sympozjon PKM. Ustroń 2003. T.1. s. 213-218.
- [W9] Rudnicki Z.: *Analiza subtelnych zmian obrazów w warunkach błędów procesu akwizycji*. Mat. IV Krajowej Konferencji "Metody i Systemy Komputerowe ...". Kraków. 2003. s. 371-376.
- [W10] Rudnicki Z., Figiel W., Daca J.: *Próby liczbowej oceny degeneracji materiału oczek ciągnadeł przy użyciu metod komputerowej analizy obrazów*. Informatyka w Technologii Materiałów : kwartalnik AGH. Kraków 2004. t. 4. nr 3. s. 76-86.

- [W11] Rudnicki Z., Figiel W., Daca J.: *Badania strukturalne materiału przeciąganego*. Materiały XII francusko-polskiego seminarium naukowego mechaniki. IPBM Politechnika Warszawska, Ecole Polytechnique Universitaire de Lille, PAN, Université de Perpignan. Warszawa 2004. s. 225–230.
- [W12] Daca J., Figiel W., Rudnicki Z.: *Badania przyczyn występowania różnic w zużyciu oczek ciągnadł*. „Friction 2004 - modelling and simulation of the friction phenomena in the physical and technical systems. Proceedings of the international conference. Warsaw University of Technology. Warszawa, 2004, s. 149–154.
- [W13] Rudnicki Z., Mikrut Z.: *Analiza obrazów powierzchni w procesie tarcia ślizgowego*. „Informatyka w Technologii Materiałów” kwartalnik AGH. 2005 t. 5 nr 1–2 s. 16–25.
- [W14] Mikrut Z., Rudnicki Z.: *Ekstrakcja cech z sekwencji cyfrowych obrazów tarcia ślizgowego*. Automatyka : półrocznik AGH. Kraków. 2005. t. 9, z. 3, s. 335–346.
- [W15] Rudnicki Z.: *Analiza skumulowanych histogramów sekwencji obrazów*. V Konferencja „Computer Methods and Systems”. Kraków 2005. s. 211–216
- [W16] Rudnicki Z.: *"Analiza sekwencji obrazów śladów tarcia ślizgowego kompozytów PTFE"* – Automatyka : półrocznik AGH, Kraków 2006. t. 10 z. 3 s. 251–264.
- [W17] Rudnicki Z., Figiel W.: *"Computer analysis and disturbance compensation of sliding friction surface images"* – Zagadnienia Eksploatacji Maszyn. 2006 vol. 41, z. 2, s. 171–183.
- [W18] Rudnicki Z.: *„Komputerowa rejestracja oraz przetwarzanie i analiza obrazów śladów tarcia ślizgowego.”* Część druga sprawozdania z pracy w ramach projektu badawczego nr 7 T07C 033 18 „Metodyka szybkiego oznaczania parametrów tribologicznych tworzyw konstrukcyjnych współpracujących ślizgowo w wybranych ośrodkach gazowych lub w próżni”. AGH w Krakowie Wydział Inżynierii Mechanicznej i Robotyki Katedra Podstaw Budowy i Eksploatacji Maszyn. Praca niepublikowana. Kraków 2006.
- [W19] Rudnicki Z., Mruk M.: *Detection of anisotropy of friction surface images*. Materiały VI konferencji: Computer Methods and Systems. 21–23. XI. 2007, Kraków. s. 271-276
- [W20] Rudnicki Z.: *Badania własności wybranych cech dyskryminacyjnych obrazów tekstur* (Investigation of some discrimination features of texture images). Automatyka: półrocznik Akademii Górniczo-Hutniczej im. Stanisława Staszica w Krakowie ; ISSN 1429-3447. 2009. t. 13 z. 3 [cz.] 1. s. 959–969.

## Publikacje obce (alfabetycznie)

- [1] Chiu-Chun Ngan, Hon-Yuen Tam: *A non contact technique for the on-site inspection of molds and dies polishing*. Journal of Materials Processing Technology 155-156 (2004) 1184-1188
- [2] Davidescu D.A. et al.: *The importance of accuracy values of the Abbot-Firestone parameters curve for fractal and non fractal calculus*. The Annals of Univ. "Dunarea de Jos" of Galati Frascicle VIII, 2004
- [3] Denslow S., Zhang Z., Thompson R.P., Lam, C.F.: *Numerical Characterization Of Feature Directionality In Digital Images: Application To Laser Scanning Confocal*

- Microscopy*. Engineering in Medicine and Biology Society, 1991. Vol.13: 1991., Proceedings of the Annual International Conference of the IEEE. 31 Oct-3 Nov 1991 Pages: 245 - 246
- [4] Franklin S.E., de Kraker A. 2003: *Investigation of counterface surface topography effects on the wear and transfer behaviour of a POM–20% PTFE composite*. *Wear* 255, 766–773
  - [5] Haralick R.M., Shanmugan K., Dinstein I., 1973, *Textural Features for Image Classification*; *IEEE Trans. Syst., Man, Cybern.* 3 (1973) 610-621
  - [6] Image Processing Toolbox For Use with Matlab – Users Guide v.5. MathWorks Inc. 2005
  - [7] Kassim A.A., Mannan M.A. , Ma Jing: *Machine tool condition monitoring using workpiece surface texture analysis*. *Machine Vision and Applications*. Vol.11, No.5, pp. 257-263, February 2000
  - [8] Kassim A.A., Mian Z., Mannan M.A.: *Tool condition classification using Hidden Markov Model based on fractal analysis of machined surface textures*. *Machine Vision and Applications*, Vol.17, No.5, pp. 327-336, October, 2006
  - [9] Liu F., Picard Rosalind W.: *Periodicity, Directionality, and Randomness: Wold Features for Image Modeling and Retrieval*. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 18, no. 7, pp. 722-733, July, 1996.
  - [10] Magoulas G.D., Karkanis S.A., Karras D.A., Vrohatis M.V., 1999, *Comparison study of Textural Descriptors for Training Neural Networks Classifiers*; *IMACS/IEEE CISC'99 Proc.* pp.6221-6226
  - [11] Materka A., Strzelecki M., 1998, *Texture Analysis Methods - A Review*, Technical University of Lodz, , COST B11 Report.
  - [12] Materka A., Strzelecki M., Lerski R., Schad L., 1999, *Evaluation of Texture Features of Test Objects for Magnetic Resonance Imaging*, June , Infotech Oulu Workshop on Texture Analysis in Machine Vision, Oulu, Finland. pp.13-19
  - [13] Materka A., Strzelecki M., Lerski R., Schad L., 2000, *Toward Automatic Feature Selection of Texture Test Objects for Magnetic Resonance Imaging*, RECPAD 2000, 11th Portugese Conference on Pattern Recognition, Porto, May 2000, 11-16.
  - [14] Mikrut Z., Rogoż K., 1996, *Zastosowanie sieci neuronowych do wykrywania chorych tkanek na obrazach ultrasonograficznych wątroby*. *Elektrotechnika*. T.15. Zeszyt 2, 107-117
  - [15] Mruk Marek: Praca dyplomowa magisterska: "*Ocena anizotropii powierzchni z wykorzystaniem komputerowej analizy obrazów*". Akademia Górniczo-Hutnicza w Krakowie, Wydział Inżynierii Mechanicznej i Robotyki. Kraków 2007.
  - [16] Myshkin N.K., Kwon O.K., Grigoriev A.Y., Ahn H.S., Kong H.: *Classification of wear debris using a neural network*. *Wear* 203-204 (1997) 658-662
  - [17] Oleksiak Z. 1993: *Urządzenie do testowania tworzyw konstrukcyjnych na tarcie i zużywanie*. XVI Sympozjon PKM, Komunikaty, Politechnika Warszawska, W-wa.
  - [18] Pavlidis Theo: *Grafika i przetwarzanie obrazów*. Wyd. Nauk.-Techn. W-Wa 1987.
  - [19] Podsiadlo P., Stachowiak G.W., 2000, *Scale invariant analysis of wear particle morphology*. *Wear* 242, 160-179
  - [20] Podsiadlo, P.; Stachowiak, G.W.: *Scale-invariant analysis of wear particle morphology—a preliminary study*. *Tribology International* Volume: 33, Issue: 3-4, April, 2000, pp. 289-295

- [21] Podsiadlo, P.; Stachowiak, G.W.: *Scale-invariant analysis of wear particle surface morphology I: Theoretical background, computer implementation and technique testing*. Wear Volume: 242, Issue: 1-2, July 10, 2000, pp. 160-179
- [22] Podsiadlo, P.; Stachowiak, G.W.: *Scale-invariant analysis of wear particle surface morphology: II. Fractal dimension*. Wear Volume: 242, Issue: 1-2, July 10, 2000, pp. 180-188
- [23] Podsiadlo, P.; Stachowiak, G.W.: *Scale-invariant analysis of wear particle surface morphology: III: Pattern recognition*. Wear Volume: 242, Issue: 1-2, July 10, 2000, pp. 189-201
- [24] Podsiadlo, P. and Stachowiak, G.W.: *Applications of Hurst Orientation Transform to the Characterization of Surface Anisotropy*. Tribology International, 32: pp 387-392 (2000)
- [25] Podsiadlo, P.; Stachowiak, G.W.: *3-D imaging of surface topography of wear particles found in synovial joints*. Wear, Vol.: 230, Issue: 2, May, 1999, pp. 184-193
- [26] Rhee S., Ludema K., 1978, *Mechanisms of formation of polymeric transfer films*. Wear 46, 231-240
- [27] Rymuza Z., 1986, *Trybologia polimerów ślizgowych*. WNT. Warszawa
- [28] Senatrev A.N., Smurugov V.A., Savkin V.G. 1991: *K mechanizmu frikcyjnego pierenosa i samosmazivanja PTFE*. Trenie i Iznos. t.12 nr 6.
- [29] Snyder W.E., Hairong Qi: *Machine Vision*. Cambridge University Press. 2004
- [30] Sobczak W., Malina W.: *Metody selekcji i redukcji informacji*. Wyd. Naukowo-Techniczne. Warszawa 1985
- [31] Stachowiak G.W., Batchelor A.W. 2001: *Engineering Tribology*. Butterworth-Heinemann, USA
- [32] Stachowiak G.W., 1998, *Numerical characterization of wear particles morphology and angularity of particles and surfaces*. Tribology Internat. Vol.31, No1-3, 139-157
- [33] Stachowiak, G.W.; Podsiadlo, P.: *Characterization and classification of wear particles and surfaces*. Wear Volume: 249, Issue: 3-4, May, 2001, pp. 194-200
- [34] Stachowiak, G.W.; Podsiadlo, P.: *Surface characterization of wear particles*. Wear Volume: 225-229, Part 2, April, 1999, pp. 1171-1185
- [35] Szala J.: *Zastosowanie metod komputerowej analizy obrazu do ilościowej oceny struktury materiałów*. Politechn. Śląska. Zeszyty Naukowe. Nr 1518. Gliwice 2001
- [36] Tadeusiewicz R.: *Systemy wizyjne robotów przemysłowych*. WNT, W-wa 1992
- [37] Tadeusiewicz R., Flasiński M., 1991, *Rozpoznawanie obrazów*. PWN W-wa
- [38] Tadeusiewicz R., Korohoda P. 1997: *Komputerowa analiza i przetwarzanie obrazów*. Wyd. Fundacji Postępu Telekomunikacji, Kraków.
- [39] Telejko T.: *Wstęp do metod opracowania wyników pomiarów z przykładami*. AGH Uczelniane Wyd. Naukowo-Dyd. Kraków 1999
- [40] Umeda A., Sugimura J., Yamamoto Y.: *Characterization of wear particles and their relations with sliding conditions*. - Wear 216 (1998) 220-228
- [41] Walker R.F., 1997, *Adaptive Multi-Scale Texture Analysis with Application to Automated Cytology*; PhD Thesis; Univ. of Queensland
- [42] Wen-Chieh Lin, J.H. Hays, Chenyu Wu, Vivek Kwatra, Yanxi Liu: *A Comparison Study of Four Texture Synthesis Algorithms on Regular and Near-regular Textures*. Tech.Report. January 2004. Carnegie Mellon University.
- [43] Wojnar L., Kurzydłowski K.J., Szala J.: *Praktyka analizy obrazu*. Polskie Towarzystwo Stereologiczne, Kraków 2002.

- [44] Wróbel Z., Koprowski L.: *Przetwarzanie obrazów w programie Matlab*. Wyd. Uniw. Śląskiego, Katowice 2001
- [45] Wrona M.: *Wykorzystanie analizy fourierowskiej w analizie cyfrowych obrazów cząstek zużycia*. Tribologia, 2007, nr 6, s. 235-245,
- [46] Zawada-Tomkiewicz A., Storch B.: *Classifying the wear of turning tools with neural networks*. Journ of Materials Proc.Technol. 109, 2001, pp.300-304
- [47] Zawada-Tomkiewicz Anna: *Analiza obrazu powierzchni obrobionej do celów estymacji parametrów tej powierzchni*. Acta mechanica et automatica, vol.1 no.2 (2007)
- [48] Zawada-Tomkiewicz, A. Storch, B.: The application of wavelet analysis in identification of surface roughness parameters. Advances in Manufacturing Science and Technology, 2006 Vol. 30, nr 3
- [49] Zawada-Tomkiewicz, A. Storch, B.: Tool wear estimation based on wavelet analysis of a machined surface image. Advances in Manufacturing Science and Technology. 2006 Vol. 30, nr 1.
- [50] Zhou G., Leu M., Blackmore D., 1995, *Fractal geometry modeling with applications in surface characterisation and wear prediction*. Int. Journ. of Machine Tools and Manufact. Vol.35 No.2 pp.203-209
- [51] Zieliński K.W., Strzelecki M.: *Komputerowa analiza obrazu biomedycznego*. PWN W-wa-Łódź 2002
- [52] Zizzari A., Seifert U., Michaelis B., Gademann G., Swiderski S., 2001, *Detection of Tumor in Digital Images of the Brain*; Proc. of IASTED Int. Conference; July 3-6, Rhodes

## Odsyłacze do stron internetowych

- [S1] [www.kkiem.agh.edu.pl/dydakt/obrazy](http://www.kkiem.agh.edu.pl/dydakt/obrazy) – strona Katedry KiEM AGH poświęcona przetwarzaniu i analizie obrazów oraz udostępniająca opracowane programy
- [S2] [www.siu.edu/~cafs/surface/file10.html](http://www.siu.edu/~cafs/surface/file10.html) - Surfaces and Contact Mechanics
- [S3] [www.eletel.p.lodz.pl/cost/](http://www.eletel.p.lodz.pl/cost/) – projekt badawczy COST B11
- [S4] [www.mech.uwa.edu.au/Tribology/](http://www.mech.uwa.edu.au/Tribology/) - Tribology Lab. University of Western Australia
- [S5] [rsb.info.nih.gov/ij/](http://rsb.info.nih.gov/ij/) - “ImageJ” - Image Processing and Analysis in Java
- [S6] [www.machinerylubrication.com/article\\_printer\\_friendly.asp?articleid=664](http://www.machinerylubrication.com/article_printer_friendly.asp?articleid=664) - Bruce T. Kuhnell: "Wear in Rolling Element Bearings and Gears - How Age and Contamination Affect Them". Machinery Lubrication Magazine. September 2004
- [S7] [www.fp.ucalgary.ca/mhallbey/tutorial.htm](http://www.fp.ucalgary.ca/mhallbey/tutorial.htm) - Hall-Beyer M.: GLCM Texture Tutorial
- [S8] [iria.math.pku.edu.cn/~jiangm/courses/mm-cv-ip/vision.html](http://iria.math.pku.edu.cn/~jiangm/courses/mm-cv-ip/vision.html) - Ming Jiang, Mathematical Models in Computer Vision and Image Processing, lecture notes, Department of Information Science, School of Mathematics, Peking University, 1998, 1999, 2001.
- [S9] [murphylab.web.cmu.edu/services/SLF/features.html](http://murphylab.web.cmu.edu/services/SLF/features.html) - MurphyLab - witryna internetowa: *Subcellular Location Features descriptions*
- [S10] [www.eng.iastate.edu/ee528/Papers/texturecomparison.pdf](http://www.eng.iastate.edu/ee528/Papers/texturecomparison.pdf) - Sharma M., Markou M., Singh S.: *Evaluation of texture methods for image analysis*;
- [S11] [www.engineering.uiowa.edu/~sonka/MSteaching.html](http://www.engineering.uiowa.edu/~sonka/MSteaching.html) - Sonka Milan
- [S12] [www.ph.tn.tudelft.nl/Courses/FIP/](http://www.ph.tn.tudelft.nl/Courses/FIP/) - Image Processing Fundamentals - I.T. Young, J.J. Gerbrands, L.J. van Vliet

## Programy i filmy udostępnione na stronie internetowej [S1]

- P1. Funkcja CLBORDER() – usuwa obiekty graniczące z brzegami obrazu
- P2. Program SZUM0 – badanie szumu w sekwencji obrazów danego wycinka tarczy
- P3. Program SZUM2A - Badanie szumów oraz filtracja medianowa
- P4. Program TESTNORM - Test normalizacji
- P5. Program PROFI\_CIEN1 - wyświetla profile oraz „powierzchnię cienia”
- P6. Program Profi\_Cien2 - wyświetla profile oraz obraz o wyrównanej jasności
- P7. Funkcja Norm99 – normalizuje obraz według percentyli 1% i 99%
- P8. Funkcja prog=dolina(OBRAZ, Lgr) – wyznacza próg binaryzacji
- P9. Funkcja Nxy06 - wyznacza liczbę przejść z bieli do czerni w kier. 0 i 90 stopni
- P10. Program Obiekt – segmentacja i indeksacja obiektów oraz ich cechy
- P11. ROZKL\_SKUM - rozkład skumulowany pól poindeksowanych obiektów
- P12. Funkcja Wyr\_tlo - wyrównywanie jasności tła obrazu szarego
- P13. Program Wyr\_T2 - prezentacja wyrównywania cienia wraz z profilami
- P14. Funkcja DET\_KIER - przybliżona detekcja kierunkowości obrazu
- P15. Funkcja DET\_KIER6 – detekcja kierunkowości na podstawie 6-ciu podobrazów
- P16. Funkcja B=wycinki(A,Ny,Nx) – dzieli obraz A na Nx\*Ny części
- P17. Funkcja OBROT - obraca obraz o zadany kąt
- P18. Funkcja OBROT2- obraca obraz o zadany kąt
- P19. Program hist3 - obrazy i ich histogramy
- P20. Program HS\_Perc - histogramy skumulowane i percentyle
- P21. SKUMTEST2 - testowanie histogramów skumulowanych
- P22. Program test\_GLCM – wyznacza macierze GLCM dla testowanych obrazów
- P23. Funkcja Nj13med – niejednorodność median podobrazów
- P24. Test Nj13med – wyznacza niejednorodność testowych obrazów
- P25. Funkcja wyznaczająca macierz przejść tonalnych C (inaczej GLCM)
- P26. Funkcja [Zw Zk] = ZWK(OBR, prog) – zmienność wierszy i kolumn
- P27. Funkcja RunLengthMatrix(OBRAZ) – wyznacza macierz długości pasm
- P28. Funkcja RunLengthFeature(OBRAZ, nr\_cechy) – wyznacza cechy macierzy R
- P29. Funkcja PASKI(Lw, Lk, Lokr, typ) - generuje obraz szary z pasm poziomych
- P30. Funkcja LOSPAS(Lw, Lk, N) - generuje obraz z losowymi pasmami
- P31. Program LOS\_PAS2 - generuje obraz z losowymi pasmami w dwu kierunkach
- P32. Program ANIZO – badanie anizotropii przez obracanie obrazu
- P33. Funkcja maks3(Wektor) - wyznacza największe maksima lokalne
- P34. Program CECHY4 - wykresy anizotropii czterech cech RLM obrazu szarego
- P35. Program Bad\_anizoZWK - badanie ortotropii zmienności kolumn i wierszy
- P36. Funkcja OwZWK(OBRAZ,prog) - wyznacza liniową miarę ortotropii względnej
- P37. Funkcja OwZWKh(OBRAZ,prog) - hiperboliczna miara ortotropii względnej
- P38. Program Rozklplam – rozkłady pól obiektów białych
- P39. Funkcja rozkl\_pl(X, kumulacja) - rozkład skumulowany pól obiektów
- P40. Funkcja G=Mgrad(A,d) - wyznacza macierz gradientu
- P41. Funkcja spisy5 - generuje spisy obrazów i sekwencji z wskazanego foldera
- P42. Program filmy - tworzy filmy z sekwencji obrazów według SPIS\_BMP.SPS
- P43. Funkcja [dx,dy] = BtransA(B,A) - wektor przemieszczenia obrazu B wzgl. A
- P44. Funkcja Xprzes = dx3(B,A,dmax) - poziome przesunięcie obrazu B względem A
- P45. Funkcja lokel – na obrazie A wyszukuje element podobny do danego EL
- P46. Program Pom\_przes - pomiar przesunięć w serii obrazów



- P47. Program kormin2009 i Funkcja C=korminus9(B,A) – binaryzacja różnicowa
- P48. Program Profil\_150 – wyświetla pierwszy i ostatni obraz sekwencji i ich profile
- P49. Program BIN6 - 6-ciokrotnie binaryzuje obraz z różnymi progami i wyświetla
- P50. Program Progi2 – percentyle i próg binaryzacji dla sekwencji obrazów
- P51. Analiza4CB - analiza obrazów z sekwencji wymienionych w pliku PROGI.TXT
- P52. Funkcja Inf\_Obraz - odczytuje dane obrazu z pliku INF
- P53. Funkcja Exp2 – funkcja złożona z dwu funkcji wykładniczych
- P54. Program Analiza\_UC – wizualizacja udziału czerni w kolumnach i wierszach
- P55. Program Fur3 – test przekształcenia Fourier’a
- P56. Program BinKolor

**Filmy:**

1. PTFE\_P30V084\_1a0.avi – przebieg tarcia próbki czystego tarflenu o tarczę stalową o chropowatości  $Ra=0,3\mu m$  obserwowany w sekwencji obrazów szarych nazwanej skrótowo „1A”.
2. PTFE\_P30V084\_1a\_bez.avi – sekwencja „1A” po binaryzacji różnicowej bez stosowania korekt.
3. PTFE\_P30V084\_1a\_skor.avi – sekwencja „1A” po binaryzacji różnicowej z zastosowaniem korekty drgań kadru obrazu i fluktuacji jasności obrazów.
4. SM-K22G3\_p30v084\_a0.avi – przedstawia rozwój plamy nanoszonego materiału kompozytowego SM-K22G3 w trakcie tarcia o tarczę stalową o chropowatości  $Ra=0,3\mu m$ , zaobserwowany w sekwencji obrazów szarych nazwanej krótko „A”.
5. SM-K22G3\_p30v084\_a\_bez.avi – sekwencja „A” po binaryzacji różnicowej bez stosowania korekt.
6. SM-K22G3\_p30v084\_a\_skor.avi – sekwencja „A” po binaryzacji różnicowej z zastosowaniem korekty drgań kadru obrazu i fluktuacji jasności obrazów.
7. SM-K22G3\_p30v03A.AVI – przebieg tarcia materiału SM-K22G3 o tarczę stalową o chropowatości  $Ra=0.03\mu m$
8. SM-K22G3\_p30v3A.AVI – przebieg tarcia materiału SM-K22G3 o tarczę stalową o chropowatości  $Ra=0.03\mu m$
9. SM-K22G3\_p30v3C.AVI – przebieg tarcia materiału SM-K22G3 o tarczę stalową o chropowatości  $Ra=0.03\mu m$
10. SMB40G2\_p20v3\_k.avi – przebieg tarcia próbki materiału SMB40G2 pokazany w tzw. pseudokolorach.
11. SMB40G2\_p60v1\_d.avi – przebieg tarcia próbki materiału SMB40G2 pokazany w tzw. pseudokolorach.