



WYBRANE METODY PRZETWARZANIA I ANALIZY CECH OBRAZÓW TEKSTUROWYCH

ZBIGNIEW RUDNICKI

SOME METHODS OF PROCESSING AND FEATURE ANALYSIS OF TEXTURE IMAGES

Abstract

Texture images have significant meaning in a number of disciplines in science and engineering, such as metallography and crystallography, tribology (images of slipping surfaces and particles produced by wear), geology (surfaces of rocks), medicine (fragments of tomographs and X-ray pictures) etc. The present paper characterizes various computer methods used for initial processing of images and, further, analysis and extraction of features of these images. The work concentrates on discussion of selected methods and tools, which are used now (determination of statistical parameters, Haralick's parameters based on matrices of events etc.), as well as on methods proposed by the Author and validated for the case of analysis of slipping surfaces. Some abilities of the software Matlab and Mazda-Convert-B11 (developed for the analysis of tomographs) are also discussed. Among numerous features those were selected, which reflect essential differences in textures and allow their classification and drawing conclusions regarding the features of materials, objects and processes represented by texture images.

1. WPROWADZENIE

Niniejsze opracowanie przedstawione było w formie referatu na seminarium „Neuromet'2002” zorganizowanym jak co roku na Wydziale Metalurgii i Inżynierii Materiałowej AGH w Krakowie. Ponieważ tradycyjnie tematyka seminarium dotyczy głównie (choć nie jedynie) zastosowań sieci neuronowych więc może warto wyjaśnić czy i jak prezentowane tu zagadnienia wiążą się z tą tematyką. Przy okazji ujawnią się też ogólniejsze powiązania z interpretacją dowolnych danych pomiarowych, zagadnieniami ekstrakcji cech oraz selekcji i redukcji informacji. Warto także wyjaśnić na wstępie co w metodach kom-

puterowych znaczy termin „obrazy teksturowe” oraz jakie znaczenie ma ich analiza.

1.1. Zagadnienia ekstrakcji cech oraz klasyfikacji złożonych danych

Rozpatrywany problem – automatycznej, komputerowej klasyfikacji pewnych obrazów – jest zaawansowaną wersją bardzo powszechnie występującego problemu klasyfikacji i interpretacji złożonych danych odzwierciedlających stany badanych obiektów lub procesów. Przykładami takich danych są nie tylko obrazy ale i chociażby zarejestrowane przebiegi różnego rodzaju wielkości fizycznych.


Jak wiadomo sieci neuronowe mogą być bardzo dobrymi klasyfikatorami danych nawet w przypadkach gdy człowiek nie określi apriori klas (takie są sieci uczące się „bez nauczyciela” jak SOM Kohonena lub ART-2). Jednakże aby obraz lub złożony sygnał mógł być wprowadzony do sieci musi być wyrażony w postaci ciągu liczb a dokładniej w postaci wielowymiarowego wektora.

Wprowadzenie do sieci całego obrazu wymagałoby tysięcy składowych wektora a zarazem tej samej liczby neuronów wejściowych sieci. Uczenie sieci o tysiącach neuronów wejściowych (i porównywalnych ich liczbach w warstwach ukrytych) wymaga proporcjonalnie dużej liczby przykładów uczących, o co nie zawsze łatwo i co przedłuża znacznie proces uczenia. Z tych powodów dąży się do selekcji i redukcji liczby informacji starając się zastąpić całe obrazy wektorami kilku czy kilkunastu najistotniejszych ich cech.


Ekstrakcja i selekcja cech obrazów najlepiej nadających się do ich rozróżniania i klasyfikowania czyli **cech dyskryminacyjnych** oraz wyznaczanie ich **liczbowych deskryptorów** a także **porównanie procedur automatycznych z planowymi** (opartymi na wiedzy i intuicji badacza) – są właśnie tematem niniejszego opracowania. Zastosowano tylko niektóre z wielu metod. Wyznaczone (liczbowo) cechy mogą stanowić wektory wejściowe dla sieci neuronowych – ale to temat na inny artykuł.

1.2. Obrazy teksturowe i ich analiza

Analiza i rozpoznawanie obrazów są dziedzinami znajdującymi bardzo szerokie zastosowania i bardzo



Rysunek 1. Przykłady obrazów teksturowych.




Rysunek 2. Obrazy o niejednorodnej teksturze.

dynamicznie wciąż rozwijającymi się. Wśród różnych kategorii obrazów bardzo często mamy do czynienia z obrazami, które w całości lub w pewnych obszarach wypełnione są powtarzającymi się (wzajemnie podobnymi lub jednakowymi) motywami czyli **fakturą** określaną obecnie powszechnie angielskim terminem „**texture**” czyli po spolszczeniu **tekstura**. Inne znaczenie ma ten termin w metalurgii czy mineralogii.

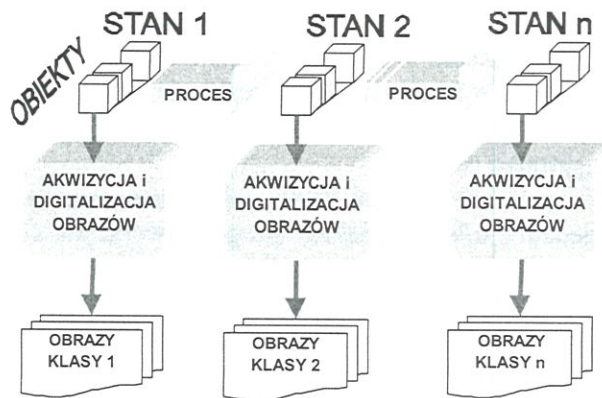
Na rysunkach 1 i 2 pokazano przykłady obrazów teksturowych. Jak widać w każdym z tych obrazów występuje w mniejszym czy większym stopniu chaos i przypadkowość lecz jednak obrazy wyraźnie różnią się od siebie czyli każdy z nich posiada zestaw cech wyraźnie różnych od cech obrazu z innej klasy ale zbliżony do zestawu cech obrazów tej samej klasy.

A oto niektóre z wielu zastosowań analizy i klasyfikacji obrazów teksturowych:

- analiza obrazów w **medycynie**: tomogramy, rentgenogramy, obrazy USG i in. [COST; Materka, Strzelecki i in. 1998, 1999, 2000; Mikrut Z., Rogoż K., 1996; MurphyLab; Walker 1997; Sharma i in., Zizzari A. i in.2001],
- kontrola **stopnia zużycia** lub **jakości produktów** jak: wyroby metalowe, tkaniny, papier, artykuły spożywcze [Li J. i in., 1999, Zhou G. i in., 1995, Umeda i in. 1998],
- kontrola **zużycia narzędzi** – przez analizę obrazu powierzchni obrabianych [Zawada-Tomkiewicz A., Storch B., 2001],
- analiza **obrazów mikroskopowych** struktury materiałów,
- analiza **zdjęć satelitarnych** i meteorologicznych.



W procesach technologicznych (jak produkcja) zarówno przedmioty poddawane obróbce jak i narzędzia ulegają zmianom przechodząc do kolejnych stanów. Jedną z metod rozpoznawania tych stanów (na przykład jakości powierzchni czy zużycia narzędzia) może być analiza odpowiadających im obrazów (rysunek 3).



Rysunek 3. Klasy obrazów odwzorowujących stany obiektów.

2. TŁO I PRZEDMIOT BADAŃ – OBRAZY POWIERZCHNI PO TARCIU

Aby dalsze rozważania dotyczące metod analizy obrazów teksturowych nie były zbyt szerokie i zbyt abstrakcyjne zostaną w dużej mierze oparte na konkretnym przykładzie.

W tribologii (nauce o tarceniu, smarowaniu i ich konsekwencjach) jedną z metod badania ścieralności materiałów jest testowanie ich w urządzeniu zwanym „tribotesterem typu pin-on-disk”, w którym badana próbka w postaci krótkiego pręta jest dociskana do obracającej się tarczy stalowej (przeciwpróbki). W tradycyjnym przebiegu badań miarą ścieralności jest ubytek wagi próbki, a dla jego uzyskania potrzebne są badania conajmniej kilkugodzinne. W ten sposób bada się m.in. materiały kompozytowe. Aby jednak móc skró-

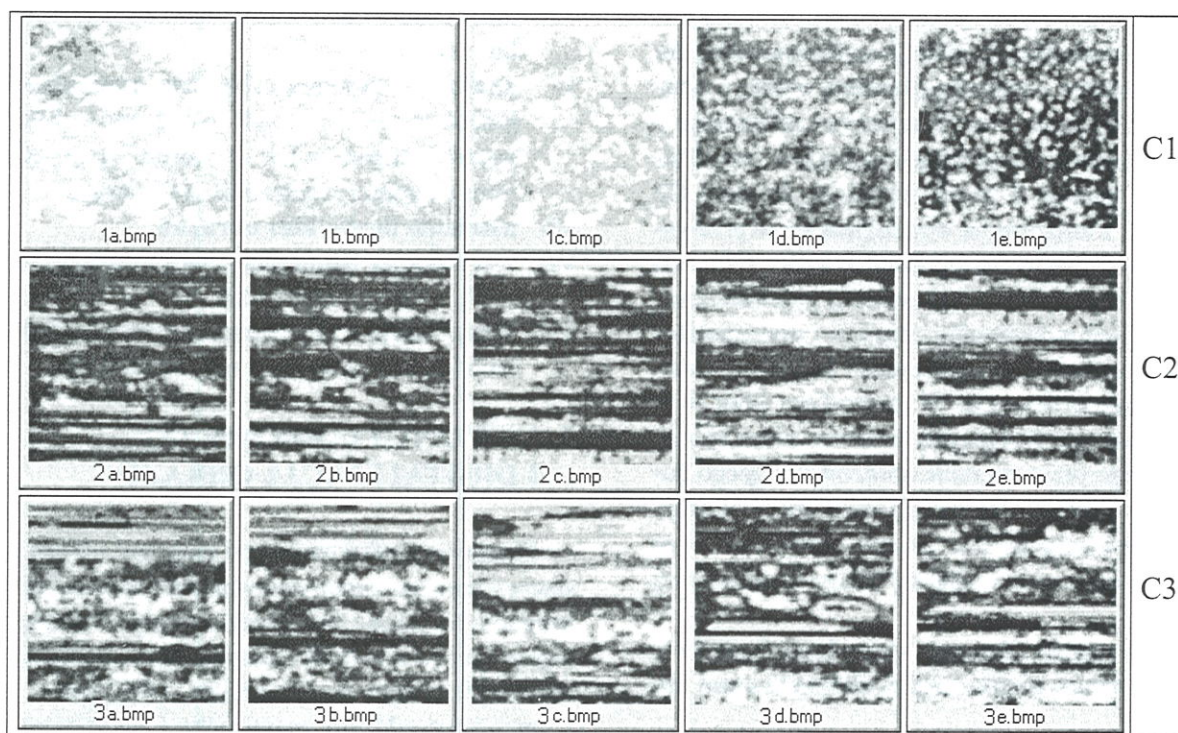
cić czas testowania podjęto próbę badania obrazów śladów zostawianych przez próbki z różnych materiałów na stalowej tarczy i wnioskowania z nich o ścieralności badanego materiału.

Wskutek ambitnego skracania czasu testów uzyskiwane obrazy śladów tarcia będą jednak coraz mniej wyraźne a różnice między nimi coraz bardziej subtelne. Licząc się z tym postanowiono najpierw dla wyraźnych i wizualnie różnych obrazów wybrać możliwie najlepsze metody komputerowej analizy aby mogły one służyć także dla obrazów trudniejszych do rozróżniania.

W przedstawianym tutaj wstępnym etapie, do badań celowo wybrano najłatwiejszy przypadek a mianowicie z serii fotografii badanych powierzchni wybrano tylko trzy najlepszej jakości – odpowiadające trzem różnym materiałom kompozytowym, w tym dwie wyraźnie wizualnie różniące się i trzecią zawierającą elementy obu poprzednich. Ponieważ właściwe stanowisko badawcze nie było jeszcze gotowe więc wykorzystano archiwalne fotografie z poprzednich eksperymentów, traktując je tylko jak przykładowe obrazy do testowania metod komputerowej analizy a nie jako właściwy materiał do badań tribologicznych. Tak więc tribologia będzie tu jedynie tłem badań cech obrazów.

Z każdej z trzech wybranych fotografii wycięto po 5 fragmentów o rozmiarach 200x200 pikseli uzyskując w ten sposób trzy serie (klasy) obrazów C1, C2, C3 przedstawione na rysunku 4.

Ponieważ te trzy serie obrazów odpowiadają róż-



Rysunek 4. Badane obrazy (1a-1e) - klasa C1, (2a-2e) - klasa C2, (3a-3e) - klasa C3. Wymiary 200x200 pikseli, 256 odcieni szarości.

nym materiałem więc w niniejszych badaniach traktowane będą jako odrębne klasy mimo, że tylko serie C1 i C2 wyraźnie wizualnie różnią się od siebie (stopniem anizotropii). Seria C3 zawiera elementy wizualnie podobne do występujących w obu poprzednich klasach (głównie w C2) a więc jej cechy powinny uplasować się pomiędzy cechami klas C1, C2.

Na marginesie można zauważyć, że wycinanie różnych fragmentów tego samego obrazu tworzy klasę obrazów tym bardziej do siebie podobnych im bardziej jednorodny jest obraz pierwotny, czego nie można powiedzieć o obrazach ostatniej z trzech klas. Dla wyodrębnienia w miarę jednorodnych fragmentów stosuje się **segmentację**, którą w tym artykule nie będziemy się zajmować.

3. CELE BADAŃ I HIPOTEZY BADAWCZE

Głównym celem tego wstępnego etapu badań jest **znalezienie najlepszych cech dyskryminacyjnych** czyli cech pozwalających rozróżniać dane klasy obrazów oraz ich liczbowych deskryptorów czyli **dyskryminatorów klas**. W szczególności wartości liczbowe dobrych dyskryminatorów powinny wykazywać możliwie dużą różnicę między przedstawicielami istotnie różnych klas C1, C2 a możliwie małe różnice dla elementów wewnątrz danej klasy – w naszym przypadku będących w istocie fragmentami tej samej fotografii. Wartości deskryptorów obrazów z klasy C3 powinny się zawierać pomiędzy wartościami dla klas C1 i C2.

Drugi cel to **porównanie skuteczności metody automatycznej ekstrakcji i selekcji cech** stosowanej dla dowolnych tekstur z **metodą planową** opartą o intuicję i wiedzę badacza oraz obserwacje i informacje o badanych obrazach. W przypadku obrazów przedstawionych na rysunku 4 widać wyraźnie, że klasa C2 różni się od C1 anizotropią wyrażającą się w przewadze podłużnych pasm (na obrazach z klasy C2). Jest to oczywiście związane z kierunkiem przemieszczania się badanych powierzchni trących i oraz spoistością i przyczepnością komponentów badanych materiałów kompozytowych. W metodzie planowej zastosowane przetestowanych zostanie kilka sposobów wstępnego przetwarzania obrazów mającego doprowadzić do uwydatnienia cech anizotropii. Następnie przedstawiony będzie prosty (obliczeniowo) algorytm wyznaczania wydajnej miary liczbowej tej cechy.

W ramach metody planowej sprawdzone będą dwie hipotezy dotyczące różnic między oboma klasami obrazów:

- Hipoteza 1: główną cechą różnicującą jest anizo-

tropia niewielkich obszarów ciemniejszych od swego otoczenia

- Hipoteza 2: główną cechą różnicującą jest anizotropia dużych obszarów ciemniejszych od średniej jasności obrazu

Trzeci cel to ocena możliwości zastosowania w dziedzinie tribologii pakietu programów MaZda, Convert, B11 – opracowanego dla analizy obrazów medycznych (tomograficznych rezonansu magnetycznego) i udostępnionego w Internecie bezpłatnie do celów naukowych – oraz ocena przydatności i wydajności różnych metod obliczeniowych dostępnych w tym pakiecie do automatycznej ekstrakcji i selekcji cech dyskryminacyjnych.

4. ETAPY ANALIZY I OZPOZNAWANIA OBRAZÓW TEKSTUROWYCH

W dziedzinach analizy i rozpoznawania obrazów teksturowych można rozróżnić następujące etapy:

- I. **akwizycja i digitalizacja obrazu** – proces pozyskiwania danych w postaci obrazu;
- II. **selekcja obrazów lub ich fragmentów** czyli tzw. regionów zainteresowania (ROI – ang.: Region Of Interest);
- III. **wytypowanie adekwatnych cech obrazów** – takich, które najprawdopodobniej pozwolą rozróżnić obrazy odpowiadające różnym stanom badanych obiektów;
- IV. **przetwarzanie obrazów** (transformacje) – mające na celu uwydatnienie lub wyodrębnienie wybranych cech (lub fragmentów obrazu) a sflumienie (odfiltrowanie) innych uznanych za nieistotne lub zakłócające;
- V. **analiza i deskrypcja obrazów** oryginalnych lub przetworzonych – czyli określenie i obliczenie wartości skalarów lub wektorów będących miarami charakterystycznych cech obrazu;
- VI. **ustalenie liczby klas obrazów**;
- VII. **weryfikacja istotności cech** (redukcja nieistotnych, selekcja istotnych);
- VIII. **klasyfikacja** – zaliczanie obrazów do odpowiednich klas na podstawie wektorów cech.

5. AKWIZYCJA (RECEPCJA) I DIGITALIZACJA OBRAZU

Finalnym produktem etapu mają być obrazy w postaci cyfrowego zapisu na komputerowym nośniku informacji. Na jakość tych obrazów wpływa bardzo wiele parametrów urządzeń i całego procesu pozyskiwania obrazu [Tadeusiewicz, Korohoda, 1997] jak:

- parametry **układu optycznego** i jego dostrojenia
- **oświetlenie i ekspozycja**,

- **zakłócenia i zniekształcenia** wprowadzane przez niedoskonałości aparatury i otoczenie,
- parametry **przetwornika obrazowego** (najczęściej typu CCD) m.in. rozdzielczość, charakterystyka przenoszenia barw, bezwładność czasowa,
- wybór rozdzielczości i liczby kolorów przy **digitalizacji**,
- sposób **kodowania obrazu** (format pliku graficznego) i ewentualna kompresja (bezstratna czy stratna),
- sposób odwzorowywania powierzchni trójwymiarowych.

Od czynników tych zależy wierność odwzorowania stanu powierzchni badanego obiektu.

Jeśli nie da się wyeliminować wpływu pewnych niekorzystnych czynników to przynajmniej należy dążyć do utrzymania ich na możliwie stałym poziomie.

W przypadku gdy zależy na wiernym odwzorowaniu trójwymiarowej geometrii powierzchni – dobrym sposobem jest otrzymanie najpierw dokładnego cyfrowego modelu trójwymiarowego (na przykład przy pomocy skanera trójwymiarowego, lub profilografu lub z trzech obrazy perspektywicznych) a następnie przedstawienie go w postaci obrazu w którym poziomy szarości – od czerni do bieli – są proporcjonalne do wysokości nierówności. Takie obrazy nazywane są w literaturze anglojęzycznej *gray scale images* lub *gray level images* lub *range images*.

Problemy akwizycji NIE będą dokładniej rozpatrywane w niniejszym opracowaniu. Nie będziemy się również zajmować segmentacją obrazu [Tadeusiewicz, Korohoda, 1997] czyli wydzieleniem obiektów lub fragmentów różniących się od innych na przykład typem tekstury lub rozgraniczonych wyraźnymi krawędziami.

6. WYBRANE CECHY OBRAZÓW TEKSTUROWYCH I ICH LICZBOWE DESKRYPTORY

Obrazy tekstur są obrazami **rastrowymi** czyli prostokątnymi tablicami punktów zwanych **pikselami** (ang.: pixel od picture element). Każdy piksel zapisany jest liczbą wyrażającą jego kolor – w naszym przypadku poziom szarości (ang.: gray level). Cyfrowy zapis obrazu teksturowego jest więc macierzą liczb $x_{w,k}$ – poziomów szarości punktów obrazu w kolejnych wierszach w i kolumnach k . Kolory pikseli $x_{w,k}$ mogą przyjmować dowolne wartości z palety czyli uporządkowanego ciągu dostępnych kolorów w liczbie Lg .

Dla badanych obrazów dostępne poziomy szarości to: $g = 0, 1, \dots, Lg-1$ w naszym przypadku $Lg = 256$.

Tak więc formalnie cyfrowy obraz teksturowy o rozmiarach: $(Lw \cdot Lk)$ gdzie:

Lw – liczba wierszy (pikseli w pionie),
 Lk – liczba kolumn (pikseli w poziomie),
to macierz pikseli $x_{w,k}$ takich, że:

$$k = 1, 2, \dots, Lk, \quad w = 1, 2, \dots, Lw, \quad 0 \leq x_{w,k} \leq Lg-1 \quad (1)$$

Deskryptory obrazów teksturowych obliczane są na podstawie różnorodnych charakterystyk statystycznych wyznaczanych albo z bezpośrednio z cyfrowego zapisu obrazu (pierwotnego lub przetworzonego) albo (najczęściej) z wektorów lub macierzy będących jego charakterystykami. W niniejszej pracy wykorzystano deskryptory oparte na:

- wektorze histogramu obrazu,
- macierzy gradientu obrazu,
- macierzy rozkładu długości pasm (RLM = Run-Length Matrix),
- macierzy zdarzeń (COM = Co-Occurrence Matrix),
- modelu autoregresji,
- algorytmie kierunkowego zliczania zbczy (wg koncepcji autora).

Kolejne podrozdziały tego rozdziału zawierają opisy ważniejszych parametrów z tych grup a szczególnie tych, które będą wyznaczane dla badanych obrazów przy zastosowaniu opisanego dalej programu o nazwie MaZda. Ponieważ na ich temat jak dotychczas napotkałem wyłącznie anglojęzyczne pozycje literatury więc oprócz własnych (niekoniecznie trafnych) tłumaczeń ich nazw zamieściłem w nawiasach oryginalne nazwy lub ich skróty stosowane w programie MaZda. Przy opisywaniu tych deskryptorów wykorzystałem dokumentację programu MaZda [COST B11] oraz pozycje literatury [Haralick i in. 1973, Li i in. 1999, Magoulos i in. 1999, Mikrut, Rogoż, 1996, Sharma i in., Umeda i in. 1998] a w szczególności interesujące omówienie metod analizy tekstur w pracy doktorskiej [Walker, 1997]

Oprócz wymienionych grup deskryptorów, stosowanych jest także wiele innych metod przydatnych do charakteryzowania obrazów teksturowych (a nie wykorzystanych w tej pracy) jak:

- analiza Fourier'a [Tadeusiewicz, Korohoda, 1997],
- analiza falkowa,
- wyznaczanie wymiarów fraktalnych [Zhou i in., 1995],
- analiza syntaktyczna i wiele innych metod opisanych w pracy [Tadeusiewicz, Flasiński, 1991],
- zastosowanie sieci neuronowych, algorytmów genetycznych i innych metod sztucznej inteligencji [Magoulos 1999, Mikrut, Rogoż, 1996, Umeda i in. 1998],

i inne.



6.1. Histogram obrazu i jego cechy

Histogram obrazu cyfrowego to wektor posiadający Lg składowych:

$\mathbf{H} = [H]_0, H_1, \dots, H_{Lg-1}$ odpowiadających poszczególnym poziomom szarości.

Dla kolejnych poziomów szarości $g = 0, 1, 2, \dots, Lg-1$ wartość składowej H_g to liczba pikseli obrazu posiadających ten poziom szarości g co można zapisać [2] w postaci wzoru:

$$H_g = \sum_{w=1}^{Lw} \sum_{k=1}^{Lk} p(g, x_{w,k}) \quad (2)$$

gdzie:

$$p(g, x_{w,k}) = \begin{cases} 1 & \text{gdy } x_{w,k} = g \\ 0 & \text{w przeciwnym przypadku} \end{cases}$$

Wartości **histogramu znormalizowanego** Hn_g otrzymuje się przez podzielenie odpowiednich wartości H_g przez całkowitą liczbę pikseli:

$$Hn_g = \frac{H_g}{Lw \cdot Lk} \quad (3)$$

Histogram znormalizowany określa prawdopodobieństwo z jakim piksel może przyjąć kolor g . Dla histogramu traktowanego jako ciąg danych doświadczalnych można obliczać różnorodne parametry statystyczne. Kilka z nich przedstawiono w tabeli 1. Wśród wielu innych wyznaczane bywają:

- mediana czyli środkowy element w uporządkowanym rosnąco ciągu badanych wartości
- kwartyle – analogicznie wyznaczane elementy położone na pozycjach stanowiących 0% (minimalny element), 25%, 50% (czyli mediana), 75%, 100% (maksymalny element)
- percentyle – analogicznie wyznaczane różne pozycje tego ciągu np.: 10%, 90%

6.2. Macierz gradientu obrazu G i jej cechy

Macierz gradientu obrazu charakteryzuje różnice kolorów par pikseli sąsiadujących z badanym pikselem lub położonych od niego w odległości d :

Tabela 1. Niektóre parametry statystyczne znormalizowanego histogramu obrazu.

| | | | |
|-----------------------|---|----------------------|--|
| średnia (Mean): | $\mu = \sum_{g=0}^{Lg-1} g \cdot Hn_g \quad (4)$ | skośność (Skewness): | $\mu_3 = \sigma^{-3} \cdot \sum_{g=0}^{Lg-1} (g - \mu)^3 \cdot Hn_g \quad (6)$ |
| wariancja (Variance): | $\sigma^2 = \sum_{g=0}^{Lg-1} (g - \mu)^2 \cdot Hn_g \quad (5)$ | kurtoza (Kurtosis): | $\mu_4 = \sigma^{-4} \cdot \sum_{g=0}^{Lg-1} (g - \mu)^4 \cdot Hn_g - 3 \quad (7)$ |

$$G_{w,k} = \sqrt{((x_{w+d,k} - x_{w-d,k})^2 + (x_{w,k+d} - x_{w,k-d})^2)} \quad (8)$$

zazwyczaj: $d = 2$ lub $d = 1$

Dla macierzy gradientu analogicznie można obliczać różne parametry statystyczne (Tabela 2).

6.3. Macierz R – rozkładu długości pasm

Macierz ta jest wyznaczana dla określonego kierunku α a każdy jej element $R_{g,j}$ zawiera informację ile razy wystąpiło pasmo pikseli o kolorze g oraz długości j . Zazwyczaj osobne macierze wyznaczane są dla kierunków α : $0^\circ, 45^\circ, 90^\circ, 135^\circ$.

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

Ważniejsze parametry obliczane na podstawie tej macierzy przedstawiono w tabeli 3.

6.4. Macierz zdarzeń C (Co-Occurrence Matrix)

Macierz zdarzeń C zwana też macierzą przejść lub ko-incydencji albo histogramem drugiego rzędu wyraża relacje między kolorami par pikseli. Macierz **C** jest macierzą kwadratową $(Lg \cdot Lg)$ wyznaczaną dla określonego kierunku oraz odległości między parami pikseli. Element $C_{a,b}$ powstaje przez zliczanie wszystkich takich par pikseli, które posiadają odpowiednio kolory a i b . Macierz ta może być normalizowana przez podzielenie wartości jej elementów przez liczbę wszystkich badanych par pikseli m . Nadaje to macierzy **C** znaczenie rozkładu prawdopodobieństwa. Macierz **C** jest symetryczna co wynika z założenia symetryczności relacji między pikselami. Program MaZda używa nieznormalizowanej macierzy **C**.

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

$$C(dw, dk)_{a,b} = \frac{1}{m} \sum_w \sum_k p(a, b, x_{w,k}, x_{w+dw, k+dk}) \quad (19)$$

Tabela 2. Niektóre parametry statystyczne macierzy gradientu obrazu

| | |
|---|---|
| średni gradient (GrMean): | $G\mu = \frac{1}{m} \sum_{w,k} G_{w,k}$ (9) |
| wariancja gradientu (GrVariance): | $(G\sigma)^2 = \frac{1}{m} \sum_{w,k} (G_{w,k} - G\mu)^2$ (10) |
| skośność gradientu (GrSkewness): | $G\mu_3 = \frac{1}{m \cdot (G\sigma)^3} \cdot \sum_{w,k} (G_{w,k} - G\mu)^3$ (11) |
| kurtoza gradientu (GrKurtosis): | $G\mu_4 = \frac{1}{m \cdot (G\sigma)^4} \cdot \sum_{w,k} (G_{w,k} - G\mu)^4 - 3$ (12) |
| $m = \text{liczba elementów macierzy } G$ | |

można wyznaczać dla odległości: $d = 1, 2, \dots, 5$.

Ideę budowania macierzy zdarzeń pokazuje rysunek 5 na przykładzie bardzo prostego obrazu (rys. 5a) o trzech odcieniach szarości 0, 1, 2 i wymiarach 6x4. Analizowane są sąsiadujące piksele ($d = 1$) w kierunku poziomym (0°). Macierz (rys. 5b) pokazuje liczbę przejść z kolorów 0,1,2 opisanych z lewej strony macierzy do kolorów opisanych nad macierzą. Jak widać jest to macierz asymetryczna. Aby jednakowo traktować kierunki skanowania i kierunki do nich przeciwne na przykład 0° oraz 180° , dokonuje się symetryzacji macierzy (rys. 5e) przez zsumowanie macierzy pierwotnej (rys. 5b) i jej transpozycji (rys. 5d). Macierze (b) i (e) znormalizowane przez podzielenie wartości wszystkich elementów przez liczbę

Tabela 3. Wybrane parametry obliczane na podstawie macierzy długości pasm (RLM)

| | |
|--|---|
| Odwrotny moment uwydatnienia krótkich pasm (Short Run Emphasis inverse moment): | $ShrtREmph = (\sum_{g=0}^{Ng-1} \sum_{j=1}^{Nr} \frac{R_{g,j}}{j^2}) / c1$ (13) |
| Moment uwydatnienia długich pasm (Long Run Emphasis moment): | $LngREmph = (\sum_{g=0}^{Ng-1} \sum_{j=1}^{Nr} j^2 \cdot R_{g,j}) / c1$ (14) |
| Niejednorodność poziomu szarości (Grey Level Nonuniformity): | $GLevNonUni = (\sum_{g=0}^{Ng-1} (\sum_{j=1}^{Nr} R_{g,j})^2) / c1$ (15) |
| Niejednorodność pasm (Run Length Nonuniformity): | $RLNonUni = (\sum_{j=1}^{Nr} (\sum_{g=0}^{Ng} R_{g,j})^2) / c1$ (16) |
| Część obrazu w pasmach (Fraction of image in runs): | $Fract = c1 / (\sum_{g=0}^{Ng-1} \sum_{j=1}^{Nr} j \cdot R_{g,j})$ (17) |
| Współczynnik $c1$ jest zdefiniowany następująco: | $\hat{c}1 = \sum_{g=0}^{Ng-1} \sum_{j=1}^{Nr} R_{g,j}$ (18) |

gdzie: $a = 0, 1, 2, \dots, Lg$; $b = 0, 1, 2, \dots, Lg$ (numery kolorów)

$$p(a, b, x_{w,k}, x_{w+dw, k+dk}) = \begin{cases} 1 & \text{gdy: } (x_{w,k} = a) \wedge (x_{w+dw, k+dk} = b) \\ 0 & \text{w przeciwnym przypadku} \end{cases} \quad (20)$$

Podobnie jak dla macierzy R badanymi kierunkami są najczęściej $0^\circ, 45^\circ, 90^\circ, 135^\circ$ co dla odległości d odpowiada wektorom $[dw, dk]$: $[0, d], [-d, d], [d, 0], [d, d]$ – dla numeracji macierzowej wierszy i kolumn (pocz. w lewym górnym rogu) lub po przejściu na współrzędne (x, y) punktów (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

wszystkich skanowanych par widać na rysunkach 5c i 5f. Rysunek 6 pokazuje macierze zdarzeń dla serii C1 i C2 badanych obrazów po wyrównaniu ich histogramów.

Z macierzy zdarzeń C wyznaczane są parametry zaproponowane po raz pierwszy przez Haralick'a i in. [1973] i przedstawione w tabeli 4.

Oznaczenia w tabeli 4 (dla macierzy symetrycznej):

$$\mu = \mu_x = \mu_y = \sum_a a \sum_b C_{a,b} = \sum_b b \sum_a C_{a,b} \quad (32)$$

• oznacza średnią z sumy wierszy lub kolumn,

$$\sigma = \sigma_x = \sigma_y = \sum_a (a - \mu)^2 \cdot \sum_b C_{a,b} \quad (33)$$



| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
|--|-------|-------|-------|---|---|----|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|-----|-------|--|---|-------|-----|---|---|-------|---|-----|---|---|---|---|---|---|---|---|---|--|---|---|---|---|-----|------|-----|---|-----|-----|---|---|------|---|-----|--|--|---|---|---|---|----|---|---|---|---|---|---|---|---|---|---|
| <p>a)</p> <table border="1" style="border-collapse: collapse; text-align: center;"> <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 | <p>b)</p> <table border="1" style="border-collapse: collapse; text-align: center;"> <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 | <p>c)</p> <table border="1" style="border-collapse: collapse; text-align: center;"> <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 | <p>d)</p> <table border="1" style="border-collapse: collapse; text-align: center;"> <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 |
| 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 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| | 0 | 1 | 2 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 0 | 10 | 2 | 1 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 1 | 1 | 2 | 0 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 2 | 2 | 0 | 2 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| <p>e)</p> <table border="1" style="border-collapse: collapse; text-align: center;"> <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 | <p>f)</p> <table border="1" style="border-collapse: collapse; text-align: center;"> <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 | 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 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |

Rysunek 5. Przykłady macierzy zdarzeń: a) wartości pikseli obrazu; b) macierz dla $dw = 0$, $dk = 1$; c) macierz (b) po normalizacji; d) transponowana macierz (b); e) suma macierzy (b) i (d); f) macierz (e) po normalizacji.

Tabela 4. Parametry teksturowe Haralick'a wyznaczone z symetrycznej znormalizowanej macierzy zdarzeń

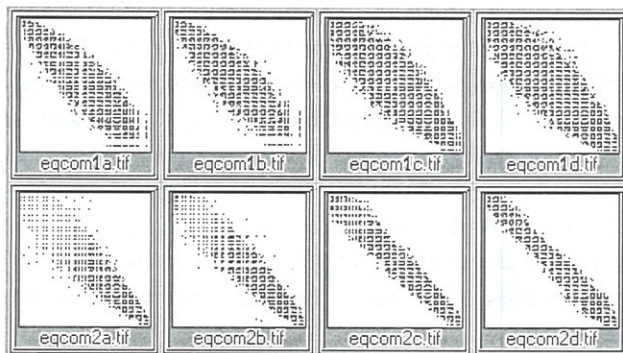
| Nazwy parametru | Wzór |
|--|--|
| Energia (Drugi moment kątowy) <i>Angular second moment</i> | $AngScMom = \sum_{a,b} (C_{a,b})^2$ (21) |
| Kontrast <i>Contrast (Inertia)</i> | $Contrast = \sum_{a,b} ((a-b)^2 \cdot C_{a,b})$ (22) |
| Korelacja <i>Correlation</i> | $Correlat = -\sum_{a,b} \frac{(a-\mu) \cdot (b-\mu)}{\sigma^2} \cdot C_{a,b}$ (23) |
| Wariancja (Suma kwadratów) <i>Sum of squares; Variance</i> | $SumOfSqs = \sum_{a,b} (a-\mu)^2 \cdot C_{a,b}$ (24) |
| Jednorodność (Odwrotny moment różnicowy) <i>Inverse difference moment; Homogeneity:</i> | $InvDfMom = \sum_{a,b} \frac{C_{a,b}}{1 + (a-b)^2}$ (25) |
| Sumaryczna średnia <i>Sum average:</i> | $SumAverg = \sum_{k=2}^{2-Lg} k \cdot P_{x+y}(k)$ (26) |
| Sumaryczna wariancja <i>Sum variance:</i> | $SumVar = \sum_{k=2}^{2-Lg} (k - SumAverg)^2 \cdot P_{x+y}(k)$ (27) |
| Sumaryczna entropia <i>Sum entropy:</i> | $SumEntrp = -\sum_{k=2}^{2-Lg} P_{x+y}(k) \cdot \log(P_{x+y}(k))$ (28) |
| Entropia <i>Entropy:</i> | $Entropy = -\sum_{a,b} C_{a,b} \cdot \log(C_{a,b})$ (29) |
| Wariancja różnicowa <i>Difference variance:</i> | $DifVarnc = \sum_{k=0}^{Lg-1} k^2 \cdot P_{x-y}(k)$ (30) |
| Entropia różnicowa <i>Difference entropy:</i> | $DifEntrp = -\sum_{k=0}^{Lg-1} P_{x-y}(k) \cdot \log(P_{x-y}(k))$ (31) |

- oznacza odchylenie standardowe z sumy wierszy lub kolumn,

$$P_{x+y}(k) = \sum_{a,b|a+b=k} C_{a,b} \quad P_{x-y}(k) = \sum_{a,b|a-b=k} C_{a,b} \quad (34)$$

wzory w tab. 4 wymagają zakresu wartości poziomów szarości od 1 do Lg .





Rysunek 6. Wizualizacja (negatywy) macierzy zdarzeń obrazów serii C1 i C2.

6.5. Parametry modelu autoregresji

Model autoregresji zakłada, że jasność badanego piksela jest uzależniona od jasności poprzedzających go (w macierzy) pikseli (z pewnego otoczenia). Dla otoczenia obejmującego tylko najbliższe (poprzedzające) piksele (jak w programie MaZda) wyraża to zależność:

$$x_{w,k} = \theta_1 \cdot x_{w,k-1} + \theta_2 \cdot x_{w-1,k-1} + \theta_3 \cdot x_{w-1,k} + \theta_4 \cdot x_{w-1,k+1} + Er \quad (35)$$

gdzie Er jest funkcją losową o średniej równej zero i odchyleniu standardowym s .

Parametry $\alpha_1, \alpha_2, \alpha_3, \alpha_4$ są wyznaczone tak aby minimalizować odchyłkę Er .

6.6. Anizotropia tekstury (w/g koncepcji autora)

Dla określenia cech anizotropii zgodnie ze sformułowanymi hipotezami zdefiniowano parametr nazywany **anizotropią** tekstury At . Parametr ten określono dla obrazu binarnego (czarno-białego) – uzyskanego w wyniku przekształceń opisanych w rozdziałach 8.2 i 8.3.

Ogólnie obraz binarny uzyskiwany jest w wyniku operacji progowania:

$$xb_{w,k} = FPR(x_{w,k}) = \begin{cases} 0 & \text{dla } x_{w,k} \leq t \\ 1 & \text{dla } x_{w,k} > t \end{cases} \quad (36)$$

gdzie t jest wartością proggu (określoną w rozdziale 8.2).

$$\text{Anizotropia tekstury: } At = \frac{Nx}{Ny} = \frac{Nx\%}{Ny\%} \quad (37)$$

gdzie:

N_x – ziarnistość pozioma:

$$N_x = \sum_{w=1}^{L_w} \sum_{k=2}^{L_k} Step0(xb_{w,k}, xb_{w,k-1}),$$

$$Step0(xb_{w,k}, xb_{w,k-1}) = \begin{cases} 1 & \text{dla } xb_{w,k} > xb_{w,k-1} \\ 0 & \text{dla } xb_{w,k} \leq xb_{w,k-1} \end{cases} \quad (38)$$

N_y – ziarnistość pionowa:

$$N_y = \sum_{k=1}^{L_k} \sum_{w=2}^{L_w} Step0(xb_{w,k}, xb_{w-1,k}),$$

$$Step0(xb_{w,k}, xb_{w-1,k}) = \begin{cases} 1 & \text{dla } xb_{w,k} > xb_{w-1,k} \\ 0 & \text{dla } xb_{w,k} \leq xb_{w-1,k} \end{cases} \quad (39)$$

Są więc to po prostu liczby przejść z czerni do białych wierszach oraz kolumnach. Współczynniki N_x, N_y można uważać za pewien miernik liczby czarnych plam odpowiednio w kierunkach x i y . Dla uniezależnienia od rozmiarów obrazu można zamiast nich użyć: **średnie (procentowe) ziarnistości** (na sto pikseli) poziome i pionowe:

$$Nx\% = \frac{N_x \cdot 100}{L_w \cdot L_k}, \quad Ny\% = \frac{N_y \cdot 100}{L_w \cdot L_k} \quad (40)$$

Z kolei współczynniki D_x i D_y odwrotnie proporcjonalne do liczby plam można przyjąć za pewien miernik średnich rozmiarów plam:

$$D_x = \frac{100}{Nx\%} = \frac{L_w \cdot L_k}{N_x}, \quad D_y = \frac{100}{Ny\%} = \frac{L_w \cdot L_k}{N_y} \quad (41)$$

Współczynnik At zastosowany dla pojedynczych plam określa stosunek ich rzutów w kierunkach x i y (0° i 90°) przy czym dla plam wklęsłych są to rzuty rozwinięte [Tadeusiewicz, Korohoda 1997]. Współczynnik ten nie pozwala natomiast określać kierunku nachylenia plam ani stopnia wypełnienia prostokąta wyznaczonego przez te rzuty – co pokazano w tabeli 5.

Tabela 5. Przykładowe figury i ich współczynniki N_x, N_y, At .

| | | | | |
|--------------------------------------|--------------------------------------|--------------------------------------|---------------------------------------|---------------------------------------|
| | | | | |
| a) $N_x=30$ $N_y=40$ $At=0.75$ | b) $N_x=30$ $N_y=40$ $At=0.75$ | c) $N_x=30$ $N_y=40$ $At=0.75$ | d) $N_x=30$ $N_y=80$ $At=0.375$ | e) $N_x=30$ $N_y=80$ $At=0.375$ |

7. WYBRANE NARZĘDZIA PRZETWARZANIA I ANALIZY OBRAZÓW

Pod względem typu uzyskiwanych rezultatów należy rozróżnić:

- narzędzia do przetwarzania obrazów a więc wszelkich przekształceń obrazu na obraz,
- narzędzia do analizy obrazów, której rezultatem są wyniki liczbowe.

7.1. Narzędzia do przetwarzania obrazów

Wiele operacji może być dokonywanych w programach malarskich i graficznych przeznaczonych do skanowania i obróbki fotografii, jak choćby Paint-Shop Pro (program typu shareware) czy komercyjny Photo-Shop.

Przegląd programów graficznych m.in. zamieszcza prof. Włodzisław Duch w swej książce „Fascynujący świat programów komputerowych” (<http://www.phys.uni.torun.pl/~duch/books-fsk/adr-fspk06.html>)

Wspomniany program Paint-Shop Pro oprócz różnorodnych narzędzi malarskich i bogatego zestawu filtrów pozwala na także na definiowanie własnych filtrów kontekstowych (dla otoczenia maksimum 5x5) oraz umożliwia odczytywanie, zapisywanie i konwertowanie (także wsadowe) obrazów z bardzo wielu formatów graficznych. Posiada także własną przeglądarkę miniatur obrazów.

7.2. Narzędzia do analizy obrazów

7.2.1. Analiza tekstur w pakietach programów matematycznych

Uniwersalne możliwości przetwarzania i analizy obrazów daje większość profesjonalnych pakietów oprogramowania matematycznego jak choćby MathCAD firmy MathSoft, jednak prawdopodobnie najczęściej stosowanym narzędziem jest MATLAB z dodatkowo zakupionymi modułami (toolbox'ami) a konkretnie z pakietem „Image Analysis Toolbox” [Wróbel, Koprowski, 2001] i bardzo obszerną, dokładną i przystępną napisaną dokumentacją.

Niektóre operacje dokonywane przy pomocy Matlab na badanych obrazach opisano w rozdziale 8.

7.2.2. Programy analizy tekstur – MaZda, Convert i B11 – o pracowane dla projektu badawczego COST-B11

Programy MaZda, Convert i B11 należą do pakietu analizy i klasyfikacji obrazów teksturowych opar-

cowanych w Instytucie Elektroniki Politechniki Łódzkiej w ramach międzynarodowego projektu badawczego „COST-B11 Ilościowa analiza tekstury obrazów tomograficznych rezonansu magnetycznego”. Programy te – uznane oficjalnie za główne narzędzie software'owe tych badań – udostępnione są bezpłatnie do celów naukowych na stronie internetowej www.eletel.p.lodz.pl/cost/cost_b11.html wraz z plikami pomocy zawierającymi ich dokumentację.

Program MaZda (nazwa pochodzi od „macierz zdarzeń”) analizuje obrazy teksturowe (lub ich zaznaczone regiony) i wyznacza obszerny zestaw (maksimum 259) parametrów określających różnorodne cechy tych obrazów.

Program Convert wykorzystywany jest do selekcji i redukcji liczby parametrów wygenerowanych za pomocą programu MaZda oraz konwertuje je do formatu wymaganego przez program B11. Program B11 pozwala na przeprowadzenie szeregu analiz w celu klasyfikacji danych między innymi wykorzystując metodę sieci neuronowych.

W niniejszym etapie badań wykorzystano tylko programy MaZda i Convert.

8. Przetwarzanie obrazów

Przetwarzanie obrazów jest zazwyczaj etapem wstępnym ale może występować na różnych etapach a czasem może być pominięte. W przypadku badanych obrazów teksturowych zastosowano takie przekształcenia jak:

- wycinanie fragmentu obrazu
- obracanie i skalowanie
- wyrównywanie (equalizacja) histogramu
- filtracja
- binaryzacja

Bardzo wiele różnorodnych przekształceń opisano w książkach [Tadeusiewicz, Korohoda, 1997] oraz [Wróbel, Koprowski, 2001].

Należy być świadomym, że każde przetwarzanie zmienia oryginał a więc choć uwydatnia pewne informacje jednak może bezpowrotnie wyeliminować inne informacje co do których należałoby być pewnym że są nieistotne.

8.1. Przetwarzanie wstępne w programie MaZda

Możliwości przetwarzania wstępnego w programie MaZda ograniczają się do możliwości:

- zaznaczenia (ręcznego) maksimum 6-ciu fragmentów obrazu jako regionów zainteresowania (ang.: ROI – region of interest),

- normalizacji kontrastu przez wyrównywanie histogramu – dostępne są dwie metody polegające na rozciągnięciu na cały dostępny zakres: a) przedziału $(\mu - 3\sigma, \mu + 3\sigma)$; b) przedziału od miejsca gdzie liczba pikseli od początku histogramu wynosi 1% całości do miejsca gdzie wynosi ona 99%. Wykorzystano metodę (a) oraz drugi wariant – bez normalizacji.
- rekwantyzacji czyli zmiany liczby poziomów szarości. Do dyspozycji są liczby 4–8 bitów na piksel czyli: 16, 32, 64, 128, 256 poziomów szarości.. Badania prowadzono dla 4b/pix.


8.2. Przetwarzanie w Matlabie dla uwydatnienia cech w/g hipotezy 1 – filtracja górno-przepustowa

Hipoteza 1 brzmiała: główną cechą różnicującą jest anizotropia niewielkich obszarów ciemniejszych od swego otoczenia

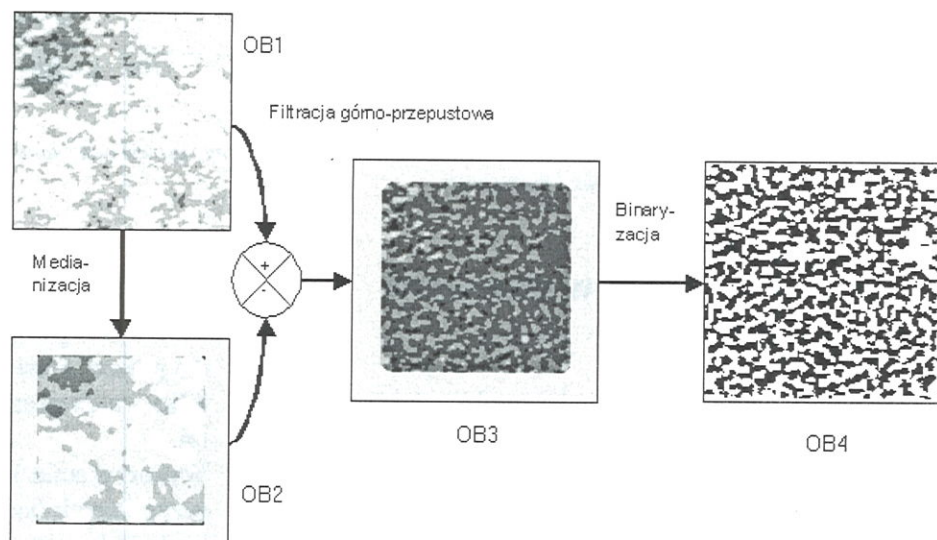
Dla uwydatnienia tych obszarów zastosowano filtrację (przestrzenną) górno-przepustową oraz binaryzację czyli przetworzenie rysunku na czarno-biały (jeden bit koloru) jak to przedstawiono na rys. 7. Zastosowano próg binaryzacji o wartości równej (w przybliżeniu) połowie zakresu poziomów szarości $0,5(Lg-1)$.

Filtrację górnoprzepustową zrealizowano przez odjęcie obrazu zmedianizowanego od oryginału – rys. 7 i 8.

Skorzystano m.in. z następujących komend i funkcji Matlab'a:



Rysunek 8. Przekrój obrazu OB1 i jego mediana.



Rysunek 7. Przekształcenia uwydatniające cechy w/g hipotezy 1.

Tabela 6. Ważniejsze zastosowane komendy Matlab'a.

| Komendy Matlab'a | Działania |
|--|---|
| Clear; OB1 = imread('obraz.bmp'); | wczytanie obrazu z pliku do tablicy "OB1" |
| imshow(OB1) | wyświetlenie obrazu |
| OB1=histeq(OB1) | wyrównywanie histogramu |
| OB2=medfilt2(OB1,[K K]); | medianizacja w polu KxK pikseli |
| OB3=uint8(double(OB1)+127-double(OB2)); | odejmowanie |
| OB4=OB3>126; | binaryzacja |
| c=improfile(OB1,[1 200],[30 30]); d=improfile(OB2,[1 200],[30 30]); i=1:1:199; figure; plot(i,c,'k',i,d,'k') | przekroje poziome w 30-tej linii obrazu od góry, dla obrazów OB1, OB2 oraz ich wykres |


8.3. Przetwarzanie w Matlabie w/g hipotezy 2 – histogram obrazu i jego wyrównywanie

Hipoteza 2 brzmiała: główną cechą różnicującą jest anizotropia dużych obszarów ciemniejszych od średniej jasności obrazu.

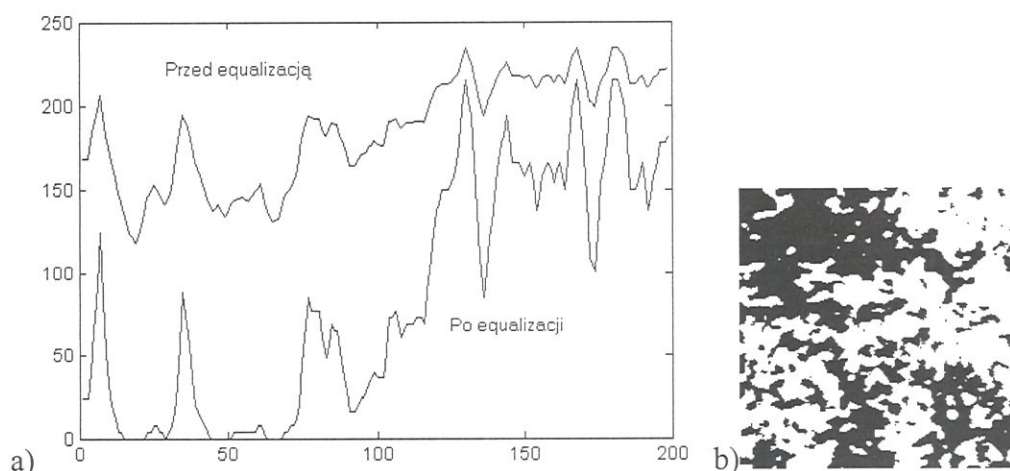
Dla uwydatnienia tych cech obraz poddano:

- wyrównywaniu histogramu,
- oraz binaryzacji.

Histogram obrazu (formalnie opisany w 6.1) można przedstawić jako wykres zawierający na osi poziomej wszystkie dostępne numery odcieni (kolorów lub poziomów szarości) a na osi pionowej liczby pikseli zliczone dla poszczególnych kolorów. Wyrównywanie polega na „rozgęszczeniu” a więc zwiększeniu różnic między odcieniami tak aby został wykorzystany pełny dostępny ich zakres:



Rysunek 9. Przetwarzanie obrazu (a) przez wyrównywanie jego histogramy (b).



Rysunek 10.a) Wykres jasności pikseli w jednej linii (przekroju) obrazu przed i po wyrównywaniu (equalizacji) histogramy; b) Obraz po operacjach wyrównywania histogramy i binaryzacji.

9. SELEKCJA CECH – DYSKRYMINATORÓW OBRAZÓW TEKSTUROWYCH

W każdym obrazie można badać bardzo wiele cech związanych na przykład z liczbą i rozłożeniem kolorów, kontrastem, ostrością, wielkością i kształtem motywów tekstury. Różne metody analizy obrazów pozwalają uzyskiwać bardzo wiele różnorodnych parametrów liczbowych będących deskryptorami czyli miarami tych cech jednak tylko niewiele z nich może okazać się **dobrymi dyskryminatorami konkretnych badanych klas obrazów**.

Można wyobrazić sobie wiele analogicznych sytuacji w codziennym życiu. Na przykład poprawnymi dyskryminatorami liczbowymi złych i dobrych kandydatów na studia techniczne są oceny z matematyki i fizyki a nie wzrost i obwód w pasie, które mogą z kolei być istotne w szkole komandosów.

Wracając do dziedziny obrazów - w poszukiwaniu najlepszych dyskryminatorów spotykamy najczęściej trzy podejścia:

1. Automatyczne wyznaczenie nadmiarowego zestawu cech oraz ich weryfikacja, selekcja i redukcja – czyli sprawdzenie wielu (np. kilkuset) deskryptorów bez stawiania hipotez wstępnych. Na przykład

autorzy opisanych dalej programów MaZda, Convert i B11 [Materka i in. 1999, 2000] przebadali dla pewnej klasy obrazów ponad 250 cech i tylko kilka z nich okazało się dobrymi dyskryminatorami.

2. Wykorzystanie kilku deskryptorów stosowanych przez innych badaczy w analogicznych przypadkach. Tak postąpili m.in. A. Umeda i in. [1998] stosując dwa parametry Haralick'a (kontrast i drugi moment kątowy) do analizy powierzchni po tarciu.
3. Postawienie i weryfikacja hipotez co do przypuszczalnych najlepszych dyskryminatorów – w oparciu o obserwacje oraz znajomość dziedziny i genezy powstawania obrazów oraz metod analizy obrazów cyfrowych – najlepiej w zespole złożonym z informatyka oraz specjalisty z tej dziedziny z której pochodzą obrazy [Tadeusiewicz, Flasiński, 1991]. Określenie przetwarzania uwydatniającego wybrane cechy oraz algorytmu obliczania deskryptorów.

Tą ostatnią metodę – nazwaną **planową** – wybrał autor niniejszego opracowania, a celem tego artykułu jest przedstawienie i porównanie metod (1) oraz (3).

Tabela 7. Parametry tekstur obliczane w programie MaZda.

| Z histogramu | Z macierzy gradientu | Z macierzy długości pasm | Z macierzy zdarzeń | Z AR |
|-----------------|---|------------------------------|-----------------------------|------------|
| – średnia | – średnia | – nierównomierność pasma | – drugi moment kątowy | θ_1 |
| – wariancja | – wariancja | – nierównomierność szarości | – kontrast | θ_2 |
| – skosność | – skośność | – uwydatnienie krótkich pasm | – korelacja | θ_3 |
| – kurtoza | – kurtoza | – uwydatnienie długich pasm | – suma kwadratów | θ_4 |
| – percentyl 1% | – procent pikseli z niezerowym gradientem | – część obrazu w pasmach | – odwrotny moment różnicowy | σ |
| – percentyl 10% | | | – sumaryczna średnia | |
| – percentyl 50% | | | – sumaryczna wariancja | |
| – percentyl 90% | | | – sumaryczna entropia | |
| – percentyl 99% | | | – entropia | |
| | | | – wariancja różnicowa | |
| | | | – entropia różnicowa | |

9.1. Automatycznie wyznaczane, testowanie i redukcjonowanie nadmiarowego zbioru cech – programami MAZDA i CONVERT

9.1.1. Wyznaczanie cech programem MAZDA

Przy pomocy programu MaZda obliczono dla każdego z 15-tu badanych obrazów 259 miar liczbowych cech wymienionych w tabeli 7 i w większości opisanych w rozdziale 6, a wyznaczanych na podstawie:

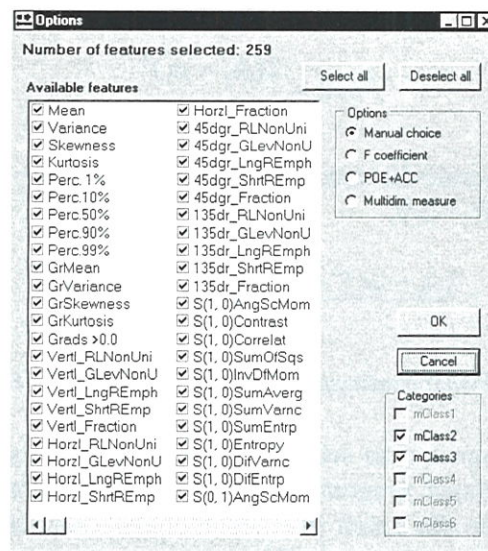
- wektora histogramu obrazu – 9 cech,
- macierzy gradientu obrazu – 5 cech,
- macierzy rozkładu długości pasm (RLM = run-length matrix) – 5 cech x 4 kierunki,
- macierzy zdarzeń (COM = co-occurrence matrix) – 11 cech x 4 kierunki x 5 odległości = 220,
- modelu autoregresji (AR = autoregressive model) – 5 cech.

Jak zaznaczono powyżej niektóre współczynniki wyznaczano dla kilku różnych odległości pikseli (1 do 5) oraz czterech kierunków: 0°, 45°, 90°, 135°. Dodatkowo można przed analizą obrazów włączyć opcję ich normalizacji. Dla badanych obrazów wyznaczono wartości cech zarówno dla obrazów oryginalnych jak i normalizowanych.

9.1.2. Redukcja i selekcja cech programem CONVERT

Program pozwala wczytać pakiet plików wyników wygenerowanych programem MAZDA, przy czym nazwy plików muszą być zgodne z pewnymi regułami aby sygnalizować które wyniki dotyczą obrazów z tej samej klasy i ilu klas obrazów dotyczą wyniki. Następnie należy dokonać ręcznej lub automatycznej selekcji cech (rys. 11).

Przy pomocy selekcji automatycznej wyznaczono po 10 najlepszych cech, przy pomocy trzech dostępnych metod oceny zdolności dyskryminacyjnej a mianowicie cechy:



Rysunek 11. Okno selekcji cech programu CONVERT.

- o największym współczynniku Fisher'a,
- dla których występuje zarówno minimalne prawdopodobieństwo błędu klasyfikacji (POE – probability of error) jak i minimalne średnie skorelowanie z innymi cechami (ACC – average correlation coefficient),
- najlepsze cechy według miary dyskryminacji wielowymiarowej (MDM – multidimensional discrimination measure).

Pewną charakterystykę tych metod zawiera dokumentacja stosowanych programów [COST].

Praktycznie najlepszym (z trzech sprawdzanych) miernikiem zdolności dyskryminacyjnej cech okazał się współczynnik Fisher'a F_c .

Jest on proporcjonalny do wariancji różnic między klasami D a odwrotnie proporcjonalny do wariancji cech wewnątrz klas V:



$$Fc = \frac{D}{V} \quad (42)$$

$$D = \frac{1}{1 - \sum_{i=1}^k P_i^2} \cdot \sum \sum P_i \cdot P_j \cdot (\mu_i - \mu_j)^2 \quad (43)$$

$$V = \sum_{i=1}^k P_i \cdot V_i \quad (44)$$

gdzie: m_i – średnia wartość parametru w klasie i , K – liczba klas, V_i – wariancja parametru w klasie i , P_i – prawdopodobieństwo klasy i (stosunek liczby obrazów tej klasy do wszystkich),
a więc dla dwu równolicznych klas: $k = 2$, $P_1 = 0,5$, $P_2 = 0,5$

$$Fc12 = \frac{2(\mu_2 - \mu_1)^2}{V_1 + V_2} \quad (45)$$

analogicznie dla trzech równolicznych klas: $k = 3$, $P_1 = P_2 = P_3 = 1/3$,

$$Fc123 = \frac{(\mu_2 - \mu_1)^2 + (\mu_3 - \mu_2)^2 + (\mu_1 - \mu_3)^2}{V_1 + V_2 + V_3} \quad (46)$$

9.1.3. Wyniki analizy programami MAZDA + COVERT

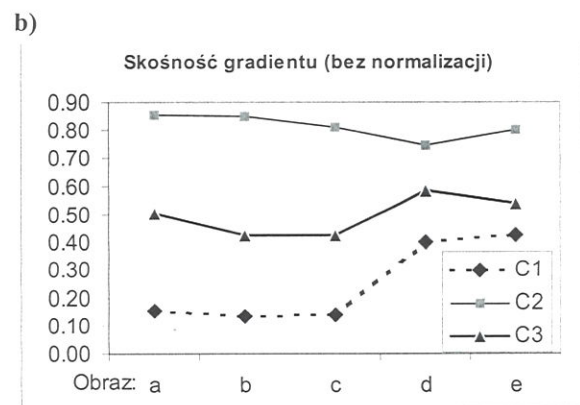

Automatyczną selekcję najlepszych cech dyskryminacyjnych programami MaZda i Convert przeprowadzono dla trzech (równoprawnych) klas obrazów C1(1a-1e), C2(2a-2e), C3(3a-3e) w dwu wariantach dla wyników analizy:

- a) obrazów oryginalnych nie poddanych normalizacji,
- b) obrazów po automatycznej normalizacji przez wyrównywanie histogramu (patrz 8.1 2b).

Z obszernego zestawu cech obliczonych programem Mazda program CONVERT wytypował jako najlepsze, trzema metodami, po 10 cech pokazanych w

Tabela 8. Cechy o najwyższych współczynnikach Fisher'a F_c , wybrane przez program Convert.

| a) Bez normalizacji, 8 bitów koloru | | b) Po normalizacji (3σ), 4 bity koloru | |
|-------------------------------------|-------|--|-------|
| 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 |



Rysunek 12. Dwie cechy o najwyższych wsp. Fisher'a dla obrazów z klas C1, C2, C3 bez normalizacji.

tabelach i na wykresach poniżej.

Parametry zostały scharakteryzowane w rozdziale 6. Liczby w nawiasach okrągłych oznaczają wektory skanowania macierzy (dx, dy) .

Tabela 8 przedstawia 10 cech o maksymalnym (dla trzech klas) współczynniku Fisher'a.

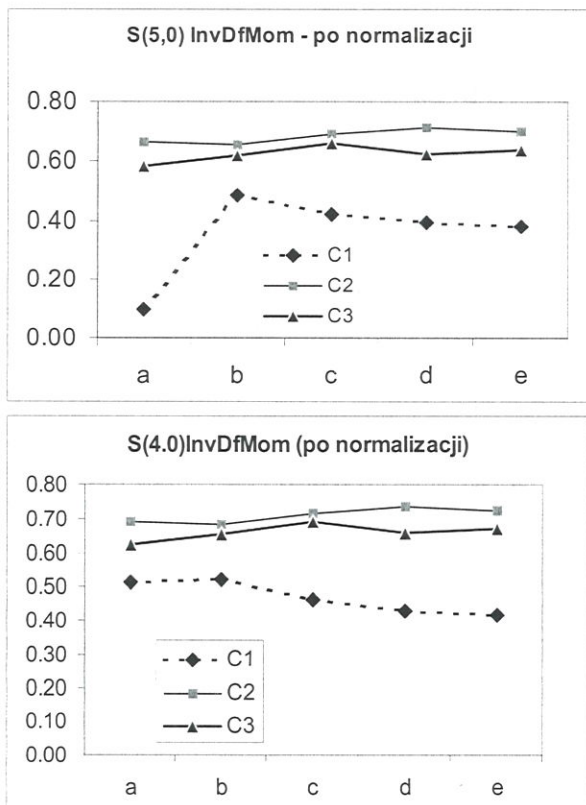
Wykresy wartości dwu najlepszych cech z tabeli 8 pokazano na rysunku 12 – dla obrazów nie normalizowanych oraz na rysunku 13 – dla obrazów normalizowanych.

Jak widać cecha najlepsza w/g współczynnika Fisher'a (rys. 12a) nie rozróżnia klas C2 i C3 natomiast

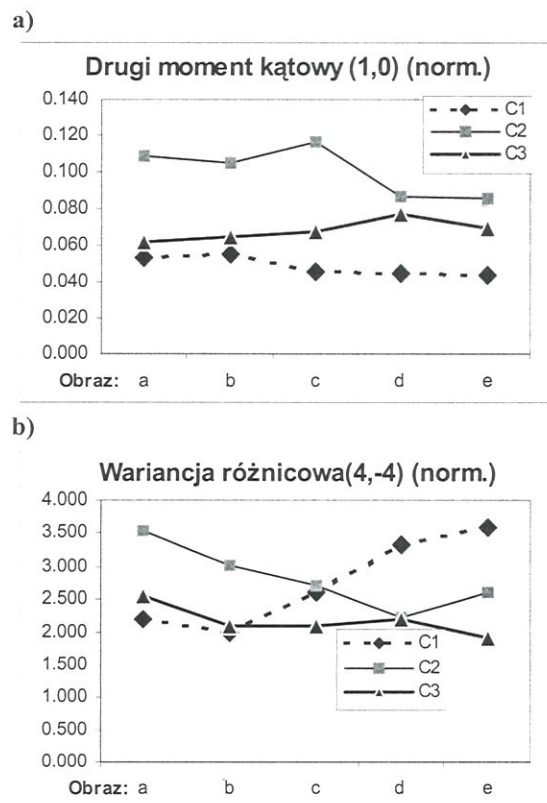
skośność gradientu (rys. 12b) daje wyniki w dużym stopniu zgodne z wynikami obserwacji obrazów (wykazuje podobieństwo obrazów 2d, 2e, 3d, 3e ale i 1d, 1e).

Wybrane jako najlepsze cechy w/g wsp. Fisher'a dla obrazów po normalizacji można także zakwalifikować jako poprawne.

Z wyników w tabeli 8 a i b widać, że normalizacja znacznie poprawiła możliwość rozróżniania obrazów. Podobnie



Rysunek 13. Cechy w/g maksimum miary dyskryminacji wielowymiarowej (MDM) – po normalizacji.



Rysunek 14. Cechy o minimalnym współczynniku POE+ACC dla obrazów po normalizacji.

Tabela 9. Cechy wybrane przez program Convert w/g minimum miary dyskryminacji POE+ACC.

| a) Bez normalizacji, 8 bitów koloru | | b) Po normalizacji (3σ), 4 bity koloru | |
|-------------------------------------|-------|--|-------|
| 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 |

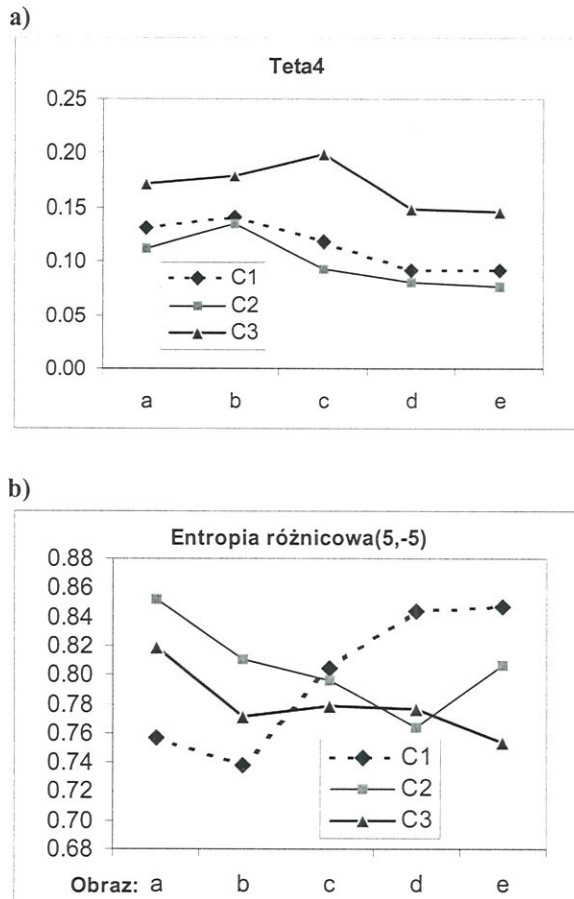
jest przy wyborze cech najlepszych według drugiej miary zdolności dyskryminacyjnej (tabela 9) oznaczonej w programie Convert akronimem POE+ACC (w tym przypadku im mniejsza miara tym lepsza cecha) chociaż interesujące jest to, że jako najlepsze cechy rozróżniające klasy obrazów tym razem program Convert wytypował całkiem inne cechy (tabela 9).

Niestety wykres (rys. 14b) wykazał że metoda druga (POE+ACC) wybiera dla obrazów znormalizowanych cechy, które nie rozróżniają prawidłowo klas C1, C2, C3.

Tabela 10. Cechy wybrane przez program Convert w/g maksimum miary MDM.

| a) Bez normalizacji, 8 bitów koloru | | b) Po normalizacji (3σ), 4 bity koloru | |
|-------------------------------------|---------|--|---------|
| 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 |

Nieprawidłowe wyniki (rys. 15b) dają także trzecia metoda (tabela 10) selekcji cech w programie Convert (metoda dyskryminacji wielowymiarowej) określona akronimem MDM przy czym program lojalnie ostrzega użytkownika wyświetlając komunikat o „możliwości bardzo niedokładnych wyników” ze względu na „prawie osobliwą” macierz w równaniach. Dodatkowo widać, że dla metody MDM normalizacja pogorszyła wartości miary.



Rysunek 15. Cechy w/g maksimum miary dyskryminacji wielowymiarowej (MDM) - po normalizacji.

9.2. Wyniki analizy obrazów zgodnie z postawionymi hipotezami

Wstępne etapy planowej analizy omówiono już wcześniej a mianowicie: w rozdziale 3 – postawienie hipotez dotyczących przypuszczalnie najlepszych cech dyskryminacyjnych, w rozdziale 6.6 zdefiniowanie deskryptorów tych cech oraz w rozdziałach 8.2, 8.3 opis przetwarzania uwydatniającego te cechy. Pozostał etap właściwej analizy czyli wyznaczenia wartości deskryptorów.

Zarówno przetwarzanie obrazów (warianty dla hipotez 1 i 2) jak obliczanie opisanych w 8.2, 8.3 parametrów zrealizowano przy pomocy programów napi-

sanych dla Matlab'a.

Program wczytywał kolejne obrazy, przetwarzał je i obliczał liczbę przejść z czerni do bieli osobno dla kierunku poziomego N_x oraz pionowego N_y , oraz obliczał współczynnik $At = N_x/N_y$.

Omówię kolejno wyniki uzyskane dla obu postawionych w rozdziale 3 hipotez.

9.2.1. Wyniki analizy anizotropii drobnych elementów obrazu – wg hipotezy 1

Obliczano współczynnik anizotropii $At(H)$ dla wynikowych obrazów drobnoziarnistych (jak na rys. 7 OB4) uzyskanych w wyniku przetwarzania opisanego w 8.2 z zastosowaniem medianowej filtracji górno-przepustowej – co zaznaczono symbolem (H) przy oznaczeniu At – oraz binaryzacji.

Przeprowadzono badania z zastosowaniem różnej wielkości okien medianizacji a zdolność dyskryminacji badanych klas obrazów przy pomocy współczynnika $At(H)$ oceniono obliczając dla wszystkich trzech klas i różnych okien medianizacji współczynnik Fisher'a co przedstawiono w tabeli 11.

Jak widać najlepsze wyniki dla danych obrazów o rozmiarach 200x200 pikseli uzyskano dla okna medianizacji filtru górno-przepustowego 40x40 pikseli.


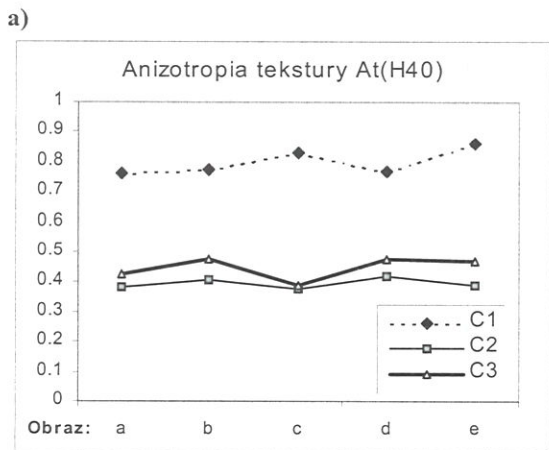
Tabela 11. Zdolność dyskryminacyjna cechy anizotropii drobnych plam dla różnych okien mediany filtracji górno-przepustowej.

| Okno medianizacji | $FC_{123}(At(H))$ |
|-------------------|-------------------|
| 10x10 | 38.02 |
| 20x20 | 57.32 |
| 30x30 | 69.51 |
| 40x40 | 80.20 |
| 50x50 | 67.19 |

Według tych cech obraz 3c (z klasy C3) jest podobny do obrazów z klasy C2 co wydaje się nieco dyskusyjne gdyż wizualnie obrazy 3d, 3e wydają się bardziej od niego podobne do klasy C2. Niezależnie od tego według współczynnika Fisher'a uzyskano dla cechy $At(H40)$ ponad dwukrotnie lepszą średnią zdolność dyskryminacyjną ($Fc = 80,2$) niż najlepsza cecha – odwrotny moment różnicowy (5, 0) – znaleziona automatycznie przez program Convert ($Fc = 38,28$).

9.2.2. Wyniki analizy anizotropii dużych elementów obrazu – w/g hipotezy 2

Podobnie jak w poprzednim przypadku – program w Matlabie wyznaczył współczynniki anizotropii tym razem dużych plam – dla obrazów poddanych wyrównaniu histogramu czyli equalizacji (E) i binaryzacji



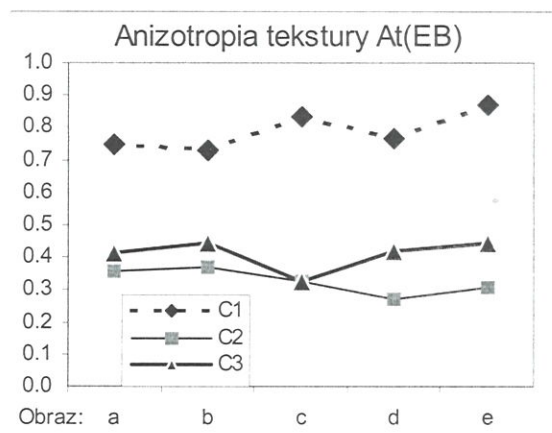
Rysunek 16. a) Anizotropia drobnych plam, b) Średnie liczby plam Nx%, Ny% na 100 pikseli.

(B). Współczynnik ten oznaczono $At(EB)$.

Wykresy te są bardzo podobne do przedstawionej na rys. 15a anizotropii małych plam co w pewnym sensie może być potwierdzeniem fraktalnego charakteru obrazów jak również może wiązać się ze stosunkowo słabą filtracją przy optymalnym oknie medianowym 40x40. Uzyskany dla trzech klas współczynnik Fishera ($Fc123 = 48,1$) również jest większy od mak-

Tabela 12. Anizotropia dużych plam i ocena jej zdolności dyskryminacyjnej współczynnikami Fishera' dla trójki i par klas

| a) Anizotropia $At(EB)$ | | | |
|----------------------------|-----------------|----------------|-----------------|
| Obraz | klasa C1 | klasa C2 | klasa C3 |
| a | 0,7449 | 0,3576 | 0,4166 |
| b | 0,7311 | 0,3715 | 0,4419 |
| c | 0,8329 | 0,3290 | 0,3260 |
| d | 0,7640 | 0,2716 | 0,4212 |
| e | 0,8707 | 0,3098 | 0,4433 |
| Srednia | 0,78872 | 0,3279 | 0,4098 |
| Wariancja | 0,003631 | 0,00157 | 0,002338 |
| b) Współczynniki Fisher'a: | | | |
| $Fc123=48,1$ | $Fc12=81,65$ | $Fc23=3,43$ | $Fc31=48,11$ |



Rysunek 17. Cecha anizotropii dla dużych plam $At(EB)$.

symalnego uzyskanego w metodzie automatycznej. W tabeli 12b przedstawiono też współczynniki Fishera' dla poszczególnych par klas.

10. PODSUMOWANIE

Na przykładzie pewnych wstępnych badań obrazów tribologicznych przedstawiono niektóre podstawowe zagadnienia z dziedziny przetwarzania i analizy obrazów i wybrane metody **wyznaczania i selekcji cech rozróżniających klasy obrazów**, wyodrębniając podejście **automatyczne i planowe**.

W metodzie automatycznej wyznaczano 259 cech każdego obrazu przy pomocy dostępnych w sieci Internet programów MaZda i Convert – a przy okazji testując trzy sposoby **oceny zdolności dyskryminacyjnej cech** (będące podstawą ich selekcji).

Jak widać z przedstawionych wyników każda z trzech metod automatycznego wyboru cech typuje inne cechy jako najlepsze co nasuwa pierwsze wątpliwości a analiza sporządzonych wykresów (przecinanie się linii) praktycznie dyskwalifikuje dwie z metod oceny zdolności dyskryminacyjnej cech (POE+ACC i MDM) pozostawiając metodę **współczynnika Fishera'a**. Metoda ta też nie jest doskonała co łatwo zaobserwować na przykładzie cechy *skośność gradientu* o najlepszym przebiegu wykresu (rys. 12b) lecz posiadającej drugi w rankingu współczynnik Fishera'a.

Uzyskane wyniki metody planowej – w/g koncepcji autora – wykazały, że w pewnych przypadkach proste lecz odpowiednio dobrane metody przetwarzania wstępnego i analizy obrazów oparte na obserwacji i wiedzy mogą dać znacznie lepsze wyniki niż rozbudowane i pracochłonne obliczeniowo metody automatyczne.

Jak widać z wyznaczonego współczynnika Fishera'a ($Fc = 80,2$) – **deskryptor anizotropii tekstury At** obliczony w/g koncepcji autora posiada dla analizowanych obrazów najlepszą zdolność dyskryminacyjną w

szczegółności w wariancie $At(H)$ wg hipotezy 1 czyli przy określaniu anizotropii drobnych elementów obrazów uzyskanych dzięki filtracji medianowej górno-przepustowej.

Na drugim miejscu są wyniki osiągnięte deskryptorem anizotropii $At(EB)$ a na trzecim miejscu cecha wyznaczana metodą automatyczną: *Odwrotny moment różnicowy (5,0)* dla obrazów znormalizowanych ($F_c = 38,28$).

11. PODZIĘKOWANIA

Autor dziękuje Komitetowi Badań Naukowych RP za finansowanie grantu KBN 7 T07C 03318, w ramach którego realizowano badania. Dziękuję też koledze Zbigniewowi Oleksiakowi pod kierunkiem którego badania są prowadzone oraz anonimowemu Recenzentowi, dzięki sugestiom którego to opracowanie stało się precyzyjniejsze a mam nadzieję, że i czytelniejsze.

12. LITERATURA

- COST B11 – witryna internetowa, www.eletel.p.lodz.pl/cost/cost_b11.html.
- Haralick, R.M., Shanmugan, K., Dinstein, I., 1973, Textural Features for Image Classification; *IEEE Trans. Syst., Man, Cybern.* 3/1973 610-621.
- Li, J., Tan J., Martz, F.A., Heymann, H., 1999, Image texture features as indicators of beef tenderness; *Meat Science* 53
- 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 CICC'99 Proc.* (www.brunel.ac.uk/~csstgdm/622.pdf)
- Materka, A., Strzelecki, M., 1998, *Texture Analysis Methods - A Review*, Technical University of Lodz, COST B11 Report.
- 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.
- 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, pp. 11-16.
- Mikrut, Z., Rogoż, K., 1996, Zastosowanie sieci neuronowych do wykrywania chorych tkanek na obrazach ultrasonograficznych wątroby. *Elektrotechnika*. T.15. Zeszyt 2, s. 107-117.
- MurphyLab - witryna internetowa: Subcellular Location Features descriptions: <http://murphylab.web.cmu.edu/services/SLF/features.html>;
- Sharma, M., Markou, M., Singh, S.: Evaluation of texture methods for image analysis; www.eng.iastate.edu/ee528/Papers/texturecomparison.pdf
- Tadeusiewicz, R., Flasiński, M., 1991, *Rozpoznawanie obrazów*. PWN Warszawa
- Tadeusiewicz, R., Korohoda, P., 1997, *Komputerowa analiza i przetwarzanie obrazów*. Wydawnictwo Fundacji Postępu Telekomunikacji, Kraków.
- Umeda, A., Sugimura, J., Yamamoto, Y., 1998, Characterization of wear particles and their relations with sliding conditions. *Wear* 216, 220-228
- Walker, R.F., 1997, Adaptive Multi-Scale Texture Analysis with Application to Automated Cytology; *PhD Thesis*; Univ. of Queensland.
- Wróbel, Z., Koprowski, R., 2001, *Przetwarzanie obrazu w programie MATLAB*. Wyd. Uniwersytetu Śląskiego. Katowice.
- Zawada-Tomkiewicz, A., Storch, B., 2001, Classifying the wear of turning tools with neural networks. *Journ of Materials Proc. Technol.* 109, pp. 300-304.
- Zhou, G. i in., 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.
- 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.

Artykuł otrzymano 15 maja 2002 r.

