

Zbigniew Rudnicki*

Badania własności wybranych cech dyskryminacyjnych obrazów tekstur

1. Wprowadzenie

Obrazy tekstur lub inaczej obrazy teksturowe (*texture image*), to obrazy na których nie występują obiekty lub wyodrębnianie obiektów z jakichś względów nie jest sensowne. Przykładowo, są to obrazy różnego rodzaju powierzchni, materiałów sypkich, chmur, pól uprawnych, zdjęcia satelitarne, itp. Analiza i klasyfikacja obrazów teksturowych ma duże znaczenie w bardzo wielu dziedzinach nauki i techniki jak choćby: metalografia [7] i krytalografia, tribologia [5, 8] (obrazy powierzchni trących), geologia (powierzchnie skał), medycyna [4, 9] (tomogramy, rentgenogramy itd.) i wiele innych.

Analiza obrazów teksturowych ma na celu wyznaczanie ich cech, a w szczególności takich, które pozwolą rozróżnić istotne dla badacza klasy obrazów – odpowiadające różnym stanom badanych obiektów. Cechy takie – nazywane dyskryminacyjnymi – zazwyczaj wyznacza się na podstawie zbiorów obrazów stanowiących wzorce klas (zbiorów uczących), a następnie używa do rozpoznawania i klasyfikowania innych obrazów.

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 Fishera F_c . Jest on proporcjonalny do wariancji różnic między klasami, a odwrotnie proporcjonalny do sumy wariancji 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 oraz im mniejsze są te różnice dla obrazów należących do tej samej klasy. Dla dwu równolicznych klas:

$$F_c = \frac{2(\mu_2 - \mu_1)^2}{V_1 + V_2} \quad (1)$$

gdzie:

μ_1, μ_2 – średnie wartości badanej cechy dla klas 1 i 2,
 V_1, V_2 – wariancje badanej cechy dla klas 1 i 2.

* Katedra Konstrukcji i Eksploatacji Maszyn, Akademia Górniczo-Hutnicza w Krakowie

Współczynnik F_c jest prostą i dość uniwersalną miarą dyskryminacji dla pojedynczej cechy, dlatego właśnie z niego korzystano w niniejszej pracy.

2. Geneza i cel pracy

Przy selekcji najlepszych dyskryminatorów możliwe są dwa różne podejścia:

1. Selekcja ekstensywna, którą można też nazwać ślepą – polega na sprawdzeniu w sposób automatyczny zdolności dyskryminacyjnej możliwie jak największej liczby cech, bez stawiania hipotez wstępnych. Taką selekcję realizowano przy wykorzystaniu opisanych dalej programów komputerowych MaZda i Convert [1, 9]. 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. [8] stosując dwa parametry Haralicka (kontrast i drugi moment kątowy) do analizy obrazów powierzchni po tarcu.
2. Podejście analityczne, ukierunkowane – postawienie i weryfikacja hipotez co do przypuszczalnych najlepszych dyskryminatorów, na podstawie obserwacji oraz znajomości genezy powstawania obrazów oraz metod analizy obrazów cyfrowych – najlepiej w zespole złożonym z informatyka oraz specjalisty z tej dziedziny której dotyczą obrazy.

W obu przypadkach przydatna jest wiedza o tym – jakie wizualnie widoczne cechy jakościowe lub zmiany takich cech obrazów mogą być wykrywane przez poszczególne cechy ilościowe (obliczeniowe). W związku z bardzo dużą liczbą możliwych cech obliczeniowych badacz może czuć się nieco zagubiony i nie wiedzieć, jak zmiany takich cech, jak: jasność, kontrast, ostrość oraz stopień uporządkowania struktury obrazu – wpływają na zmiany poszczególnych cech obliczeniowych. Stąd wyniknęła potrzeba zbadania wrażliwości poszczególnych cech tekstur na tego rodzaju zmiany parametrów obrazów.

Istotna jest także odporność cech ilościowych na zmiany jasności, kontrastu i ostrości, gdyż mogą one przypadkowo zachodzić przy akwizycji obrazów, szczególnie gdy prowadzona jest etapami – przy rejestracji obrazów odpowiadających różnym stanom badanych obiektów. Równocześnie, cechy odporne na takie zmiany powinny być czułe na inne istotne zmiany, na przykład na zmiany uporządkowania struktury obrazu.

Tak więc określono dwa cele niniejszej pracy:

- a) znalezienie cech najbardziej wrażliwych na zmiany jasności, kontrastu i ostrości;
- b) znalezienie cech najbardziej wrażliwych na zmiany uporządkowania struktury obrazu a możliwie mało wrażliwych na zmiany jasności, kontrastu i ostrości.

Analiza dotyczyła obrazów monochromatycznych zwanych tutaj obrazami szarymi.

3. Badane cechy obrazów teksturowych

Analiza oraz klasyfikacja obrazów teksturowych wymaga określenia cech, które mogą być podstawą tej klasyfikacji.

Rozróżnić można:

- cechy jakościowe – określane przez obserwatora obrazów i związane z ich treścią,
- cechy ilościowe – w postaci liczbowych deskryptorów obliczanych z różnorodnych charakterystyk obrazów cyfrowych.

Cechy jakościowe – określane w sposób opisowy na podstawie obserwacji wzrokowej, mogą być podstawą apriorycznej selekcji materiału badawczego, natomiast cechy ilościowe są podstawą komputerowej klasyfikacji obrazów i wynikającego z niej rozpoznawania stanów badanych obiektów.

Cechy ilościowe obrazów teksturowych szarych obliczano z charakterystyk wyznaczonych dla obrazów traktowanych jako populacje pojedynczych pikseli lub populacje par czy innych grup pikseli (np. otoczeń czy pasm). W przypadku par lub pasm pikseli analiza dokonywana jest sekwencyjnie, według określonego porządku zwanego kierunkiem skanowania macierzy obrazu. Stosowano kierunki skanowania φ : 0° i 90° oraz 45° i 135° .

W niniejszej pracy wyznaczano cechy – a dokładniej: liczbowe skalarnie deskryptory cech – na podstawie następujących charakterystyk:

- wektora znormalizowanego histogramu obrazu **Hn**: 9 cech,
- macierzy gradientu obrazu **G**: 5 cech,
- macierzy rozkładu długości pasm **R**: 5 cech \times 4 kierunki = 20 cech,
- macierzy przejść tonalnych **C**: 11 cech \times 4 kierunki \times 5 odległości = 220 cech,
- modelu autoregresji **AR**: 5 cech.

Histogram znormalizowany obrazu to wektor **Hn** = $[Hn_j]$ o Lh składowych odpowiadających poszczególnym przedziałom na jakie podzielono nominalny zakres poziomów szarości. Każda składowa Hn_j podaje względną częstość występowania pikseli obrazu o wartościach jasności mieszczących się w odpowiadającym tej składowej przedziale:

$$Hn_j = \frac{1}{Lw \cdot Lk} \sum_{w=1}^{Lw} \sum_{k=1}^{Lk} L((j-1,5) \cdot dg \leq x_{w,k} < (j-0,5) \cdot dg), \quad j = 1, 2, \dots, Lh \quad (2)$$

gdzie:

- Lh – liczba składowych histogramu (zadana),
- Lg – nominalna liczba odcieni szarości,
- $dg = (Lg-1)/(Lh-1)$ – długość przedziału,
- Lw – liczba wierszy macierzy obrazu,
- Lk – liczba kolumn macierzy obrazu,
- $x_{w,k}$ – wartość jasności pikseli w wierszu w i kolumnie k ,
- $L(\text{wyrażenie})$ – wartość logiczna wyrażenia ($1 = \text{prawda}$, $0 = \text{fałsz}$).

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

$$\mathbf{G} = [G_{w,k}], \quad G_{w,k} = \sqrt{((x_{w+d,k} - x_{w-d,k})^2 + (x_{w,k+d} - x_{w,k-d})^2)} \quad (3)$$

Macierz rozkładu długości pasm \mathbf{R} (określana też w literaturze akronimem RLM – *Run Length Matrix*) zawiera informacje o częstości występowania pasm o poszczególnych odcieniach oraz długościach (mierzonych liczbą pikseli). Jest ona wyznaczana dla określonego kierunku skanowania φ , a każdy jej element $R_{g,j}$ zawiera informację, ile razy wystąpiło pasmo pikseli o jasności g oraz długości j . Macierz \mathbf{R} ma wymiary $(Lg \cdot Lr)$ gdzie Lr to maksymalna długość pasma (w pikselach), a Lg jak poprzednio – liczba odcieni szarości.

Macierz przejść tonalnych \mathbf{C} zwana też macierzą sąsiedztwa, macierzą zdarzeń, lub macierzą współwystąpień ($COM = Co-Occurrence Matrix$, $GLCM - Gray Level Co-Occurrence Matrix$), wyraża relacje między odcieniami określonych par pikseli. Macierz \mathbf{C} jest macierzą kwadratową o rozmiarze Lg , wyznaczaną dla określonego kierunku φ oraz danych odległości (dw, dk) między badanymi parami pikseli. Element $C_{a,b}$ powstaje przez zliczanie wszystkich takich par pikseli, które posiadają odpowiednio odcienie a i b :

$$C(dw, dk)_{a,b} = \frac{1}{m} \sum_w \sum_k p(a, b, x_{w,k}, x_{w+dw, k+dk}) \quad (4)$$

gdzie:

$$a = 0, 1, 2, \dots, Lg;$$

$$b = 0, 1, 2, \dots, Lg$$

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

Macierz ta jest zazwyczaj normalizowana przez podzielenie wartości jej elementów przez liczbę wszystkich badanych par pikseli. Nadaje to macierzy \mathbf{C} znaczenie rozkładu prawdopodobieństwa.

Model autoregresji zakłada, że jasność badanego piksela jest uzależniona od jasności pikseli z jego otoczenia.

Dla otoczenia obejmującego tylko najbliższe piksele wyraża to zależność:

$$x_{w,k} = \theta_1 \cdot x_{w,k-1} + \theta_2 \cdot x_{w-1,k-1} + \theta_3 \cdot x_{w-1,k} + \theta_4 \cdot x_{w-1,k+1} + Er \quad (5)$$

gdzie:

Er – odchyłka losowa o średniej zero i odchyleniu standardowym σ ,

$\theta_1, \theta_2, \theta_3, \theta_4$ – parametry wyznaczane tak, aby zminimalizować odchyłkę Er .

Nazwy badanych cech zamieszczono w tabeli 1, natomiast ich dokładniejsze opisy zawarto w publikacjach [1–3, 6, 9].

Tabela 1
Badane cechy obrazów teksturowych

Cechy histogramu	Cechy macierzy G	Cechy macierzy długości pasm R	Cechy macierzy przejść tonalnych C	C. AR
Średnia	Średnia	Nierównomierność pasm	Drugi moment kątowy	θ_1
Wariancja	Wariancja	Nierównomierność szarości	Kontrast	θ_2
Skośność	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	Odwr. moment różnicowy	σ
Percentyl 10%			Sumaryczna średnia	
Percentyl 50%			Sumaryczna wariancja	
Percentyl 90%			Sumaryczna entropia	
Percentyl 99%			Entropia	
			Wariancja różnicowa	
			Entropia różnicowa	

4. Oprogramowanie

W badaniach wykorzystano własne programy komputerowe opracowane w MATLAB-ie z zastosowaniem pakietu Image Processing Toolbox oraz programy MaZda i Convert opracowane w Instytucie Elektroniki Politechniki Łódzkiej w ramach międzynarodowego projektu badawczego „COST-B11 Ilościowa analiza tekstury obrazów tomograficznych rezonansu magnetycznego” i udostępnione bezpłatnie do celów naukowych na stronie internetowej www.eletel.p.lodz.pl/cost/cost_b11.html.

Programy własne użyto m.in. do generowania i przetwarzania obrazów testowych.

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

Za pomocą programu MaZda obliczano dla każdego z badanych obrazów 259 wartości cech wymienionych w rozdziale 3.

Program Convert używano do automatycznej selekcji dziesięciu najlepszych dyskryminatorów spośród kilkuset cech wyznaczonych programem MaZda dla dwu klas obrazów.

W niektórych prostych operacjach pomocne były także uniwersalne programy graficzne jak Paint-Shop Pro i Ifran View oraz arkusz kalkulacyjny Ms Excel.


5. Badanie wrażliwości cech obrazów teksturowych na zmiany jasności, kontrastu i ostrości obrazu

Do badania wrażliwości cech na zmiany jasności, kontrastu i ostrości obrazów sporządzono serię czterech obrazów, w skład której wchodził wybrany obraz oryginalny (1a) oraz

trzy obrazy wtórne otrzymane przez przetworzenie obrazu oryginalnego w programie Paintshop-Pro, a mianowicie:

- 1aj – obraz rozjaśniony,
- 1ak – obraz o zwiększonym kontraście,
- 1as – obraz rozmyty (operacja *more soft*).

Fragmety uzyskanych w ten sposób obrazów przedstawia rysunek 1.



Rys. 1. Obrazy użyte do analizy wrażliwości cech na zmiany jasności, kontrastu i ostrości

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

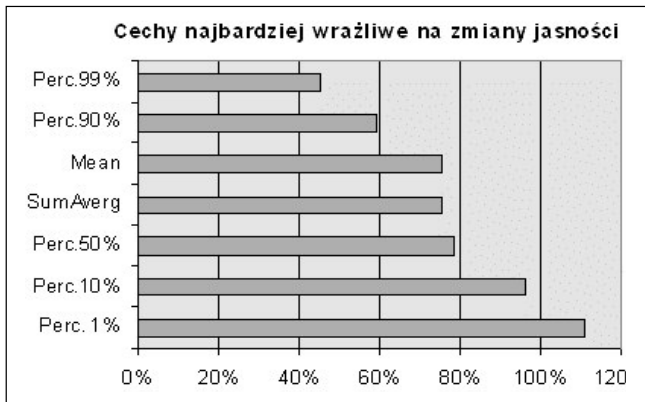
Wyniki przedstawiono na wykresach, przy czym dla danej cechy wyznaczanej w różnych kierunkach i odległościach pikseli, brano do wykresu wartość największą.

Na zmiany jasności wrażliwe są jedynie – pokazane na rysunku 2 – cechy wyznaczane z histogramu oraz cecha „sumaryczna średnia” (*SumAverg*) wyznaczana z macierzy przejść tonalnych *C*.

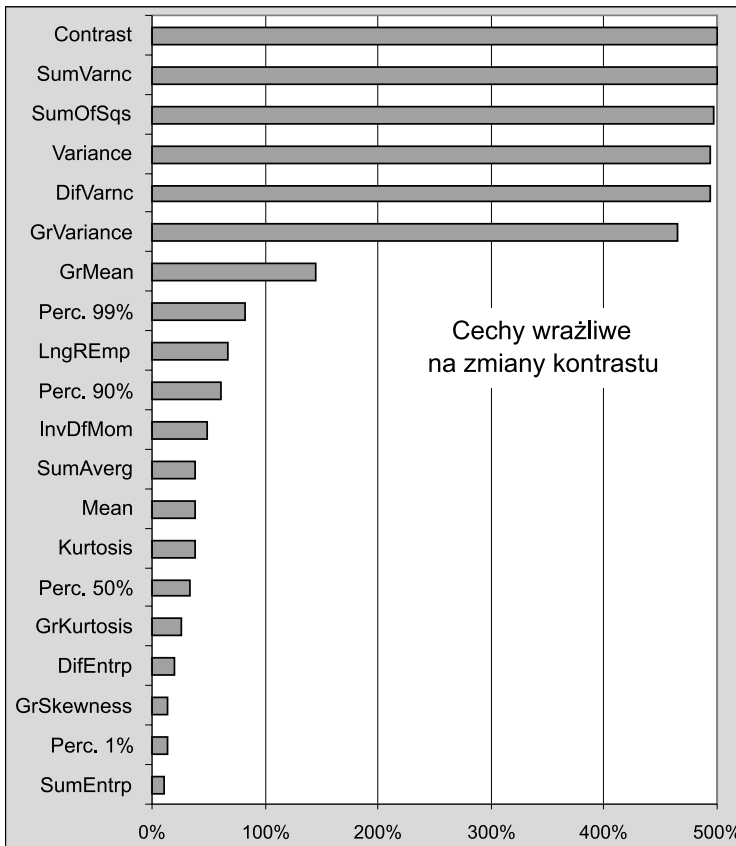
Wrażliwość na zmiany kontrastu wykazuje wiele cech. Część z nich – dla których zmiana była większa niż 5% – przedstawia wykres na rysunku 3. Jak widać, na pierwszym miejscu jest cecha „kontrast” (zgodnie ze swą nazwą) oraz pięć wariancji różnych cech, które zmieniły się aż o blisko 500%.

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

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”.

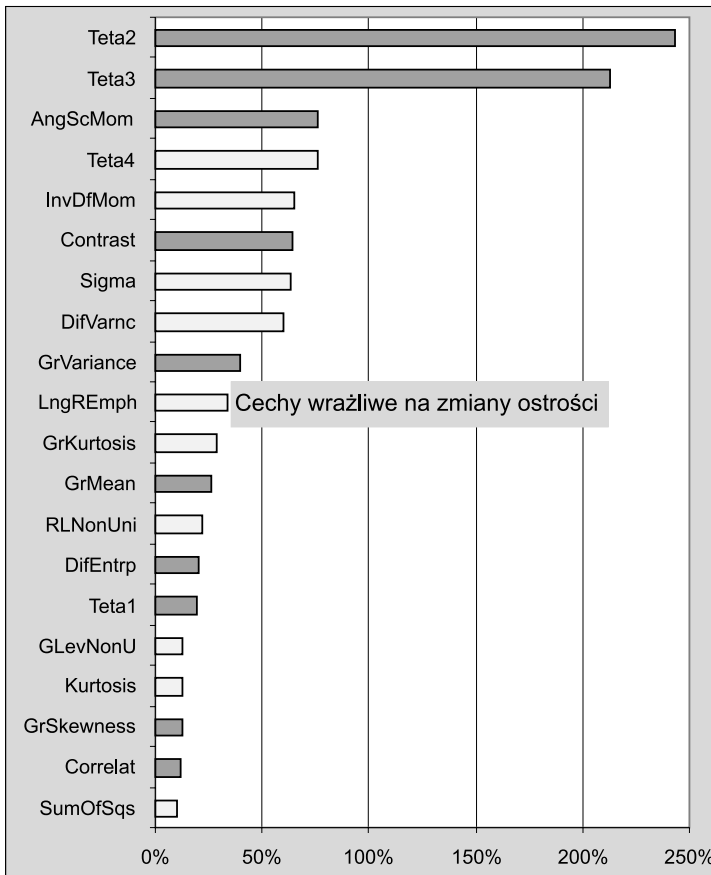


Rys. 2. Procentowe zmiany cech wrażliwych na zmiany jasności obrazu



Rys. 3. Cechy wrażliwe na zmiany kontrastu (uwzględniono zmiany $\geq 10\%$)

Cechy najbardziej wrażliwe na zmiany ostrości obrazu przedstawiono na rysunku 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. Cechy wrażliwe na zmiany ostrości obrazu (uwzględniono zmiany $\geq 10\%$)

Rozpatrując grupy cech można stwierdzić:

- cechy histogramu są wrażliwe zarówno na zmianę jasności, jak i kontrastu, z wyjątkiem wariancji (*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* – z wyjątkiem *Vertl_LngREmp* – są odporne na zmiany kontrastu;
- z cech wyznaczanych z macierzy *C* najbardziej odporna na zmiany kontrastu jest korelacja (*Corelat*); cecha „sumaryczna średnia” (*SumAverg*) jest odporna na rozmycie ostrości.

6. Wrażliwość cech tekstur na zmianę uporządkowania struktury obrazu

Dla badań wrażliwości cech na zmianę uporządkowania struktury obrazu wygenerowano – za pomocą programu napisanego w MATLAB-ie – serie obrazów tworzących dwie klasy testowe. Wszystkie obrazy miały te same rozmiary 128×128 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. 5a, b)

Klasa druga zawierała obrazy o takiej samej liczbie jasnych pikseli jak w klasie pierwszej, o losowo zmienianej jasności – w takich samych jak poprzednio granicach – lecz rozmieszczenie pikseli było losowe (według rozkładu równomiernego), jak to pokazuje rysunek 5c.



Rys. 5. Przykładowe obrazy testowe
Objaśnienia w tekście

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* ($F_c = 37$),
- „korelacja” (*Correlat*) – wyznaczana z macierzy *C* ($F_c = 33$),
- „sumaryczna wariancja” (*SumVarnc*) – wyznaczana z macierzy *C* ($F_c = 30$).

Jednak ta ostatnia cecha jest także mocno zależna od zmian kontrastu, a pozostałe reagują jedynie w niewielkim stopniu na zmiany ostrości (rys. 4).

7. Podsumowanie

Przebadano 35 kategorii cech, wyznaczanych na podstawie pięciu różnych charakterystyk obrazów teksturowych szarych. Przy uwzględnieniu kierunków skanowania obrazów oraz dystansów par pikseli, badaniu podlegało 259 cech. Wytypowano cechy – pokazane w tabeli 2 – najsilniej reagujące na zmiany jasności, kontrastu i ostrości oraz cechy niezależne od tych zmian. Oddzielnie wyselekcjonowano cechy najlepiej wykrywające uporządkowanie struktury obrazu, którymi okazały się: nierównomierność szarości – wyznaczana z macierzy R oraz korelacja – wyznaczana z macierzy C . Cechy te są zarazem niewrażliwe na zmiany jasności i kontrastu oraz mało wrażliwe na zmiany ostrości.

Tabela 2
Wyselekcjonowane cechy

Charakterystyka	Cecha	Zmieniany parametr obrazu			
		Jasność	Kontrast	Ostrość	Uporządk.
Histogram	<i>Perc. 1%</i>	111%	13%	0%	0%
	<i>Perc.10%</i>	96%	8%	0%	0%
	<i>Variance</i>	0%	494%	9%	1%
Macierz R	<i>GLevNonU</i>	0%	0%	13%	106%
Macierz C	<i>SumOfSqs</i>	0%	497%	10%	1%
	<i>AngScMom</i>	0%	0%	76%	15%
	<i>Correlat</i>	0%	0%	12%	102%
Model AR	<i>Teta2</i>	0%	9%	243%	99%
	<i>Teta3</i>	0%	5%	213%	100%

Literatura

- [1] COST B11 – witryna internetowa, www.eletel.p.lodz.pl/cost/cost_b11.html.
- [2] Haralick R.M., Shanmugan K., Dinstein I., *Textural Features for Image Classification*. IEEE Trans. Syst., Man, Cybern. 3, 1973, 610–621.
- [3] Materka A., Strzelecki M., *Texture Analysis Methods – A Review*. Technical University of Lodz, COST B11 Report, 1998.
- [4] Mikrut Z., Rogoż K., *Zastosowanie sieci neuronowych do wykrywania chorych tkanek na obrazach ultrasonograficznych wątroby*. Elektrotechnika, t. 15. z. 2, 1996, 107–117.

-
- [5] Oleksiak Z., Rudnicki Z., *Computer analysis of images of worn surfaces*. Zagadnienia Eksploatacji Maszyn, z. 3 (131), 2002, 73–84.
 - [6] Rudnicki Z., *Wybrane metody przetwarzania i analizy cech obrazów teksturowych*. Informatyka w Technologii Materiałów, nr 1, t. 2, 2002, 1–18.
 - [7] Rudnicki Z., Dąca J., *Komputerowa analiza obrazów metalograficznych w badaniach warstwy wierzchniej oczek ciągnadeł*. Mat. IV Krajowej Konferencji „Metody i Systemy Komputerowe”. Kraków, 2003, 361–366.
 - [8] Umeda A., Sugimura J., Yamamoto Y., *Characterization of wear particles and their relations with sliding conditions*. Wear, 216, 1998, 220–228.
 - [9] Zieliński K.W., Strzelecki M., *Komputerowa analiza obrazu biomedycznego*. PWN, Warszawa-Łódź, 2002.