

Ewa Snitkowska*, Włodzimierz Kasprzak*

Procedura analizy składowych niezależnych i jej wykorzystanie do opisu tekstur w obrazach cyfrowych

1 Wprowadzenie

Jedną z metod wykorzystywanych w analizie obrazów [1-3] jest **analiza tekstury** [4, 13]. Tekstura reprezentuje takie właściwości obrazu jak kierunkowość (kierunek układania się wzorca) czy porowatość. Na tej podstawie można rozróżnić dwa obrazy od siebie, jak również wyznaczyć w danym obrazie obszary spełniające określone warunki. W niniejszej pracy zaproponowane zostanie **aktualnie intensywnie rozwijane podejście** do pozyskiwania cech tekstur, oparte na statystycznej **analizie składowych niezależnych** (ICA) [5-6], które w przekonaniu autorów może służyć za (nisko-poziomowy) model percepcji wizyjnej człowieka.

Typowe podejścia do **detekcji cech** – wykorzystywane w problemach reprezentacji lub kompresji obrazu cyfrowego - w oparciu o liniowe przekształcenie [7], takie jak Fouriera, Hadamarda [2], transformata kosinusowa [8] czy filtry Gabora [9-10] **nie są dopasowane** do konkretnych obrazów danego rodzaju, gdyż mają uniwersalny charakter. W przeciwieństwie do nich przekształcenia uzyskiwane w wyniku analizy PCA (analiza składowych głównych) lub ICA (przewidziana przez nas analiza składowych niezależnych) **są estymowane w oparciu o same dane uczące** – przykłady obrazów danego rodzaju.

Z tych dwóch metod PCA przeznaczona jest raczej do kompresji – orientując się na podobieństwa obrazów różnych klas – a ICA powinna nadawać się do klasyfikacji, gdyż orientuje się na różnice pomiędzy obrazami różnych klas. Nasze dotychczasowe doświadczenia z metodami ICA [17]-[20] oraz pierwsze wyniki prac dostępne w literaturze potwierdzają to przypuszczenie [21, 22]. ICA jest odmianą statystycznej **dekompozycji wzorców**, czyli poszukiwania „ciekawych” (oddających strukturę rozkładów statystycznych) rzutów (na osie układu) wielowymiarowych danych. Rozkład Gaussa jest najmniej ciekawy a kierunki najmniej gaussowskie są „najciekawsze”. Obszary w przestrzeni nie pokrywane przez niezależne składowe są wypełniane przez szum Gaussa - znajdując kierunki nie-gaussowskie znajdujemy efektywnie niezależne składowe – czyli docelowe osie przestrzeni cech.

W pracy pokazujemy, że odpowiednio dobierając (do próbek danych) **już same przestrzenie cech tekstury** (a nie dopiero na późniejszym etapie klasyfikacji uniwersalnych przestrzeni cech), można stworzyć narzędzie dużo skuteczniejsze w analizie tekstur, niż dotychczas znane metody.

*Instytut Automatyki i Informatyki Stosowanej Politechniki Warszawskiej, ul. Nowowiejska 15/19, 00-665 Warszawa. E-mail: E.Snitkowska@elka.pw.edu.pl , W.Kasprzak@ia.pw.edu.pl

2 Procedura szybkiego obliczenia przekształcenia ICA

2.1 Istota problemu ICA

Podstawowym zastosowaniem metody ICA (ang. *Independent component analysis*) jest estymacja wielu sygnałów źródłowych jedynie na podstawie obserwacji ich mieszanin. Nie jest wymagana żadna informacja ani o kierunku źródła ani o warunkach pomiaru. Zakłada się, że obserwowany n -wymiarowy sygnał wektorowy $\mathbf{x}(t)$ jest wynikiem „punktowego” (nieznanego) wymieszania m niezależnych statystycznie (nieznanych) sygnałów źródeł $\mathbf{s}(t)$:

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) + \mathbf{n}(t) = \sum_{i=1}^m s_i(t)\mathbf{a}_i + \mathbf{n}(t) \quad (1)$$

Celem ICA jest **jednoczesna** estymacja nieznanych źródeł i $m \times n$ - wymiarowej macierzy separującej $\mathbf{W}(t)$ takiej, że m -wymiarowy wektor:

$$\mathbf{y}(t) = \mathbf{W}(t) \mathbf{x}(t) \quad (2)$$

staje się (z dokładnością do skali i permutacji sygnałów) aproksymacją nieznanych źródeł.

Z punktu widzenia zapisu matematycznego wykorzystuje ona również liniowe przekształcenie przestrzeni wektorowej, podobnie jak przekształcenie Fouriera, Hadamarda, transformata kosinusowa, itp. Jednak w ICA następuje każdorazowa estymacja przekształcenia („na ślepo”) w oparciu jedynie o wektorowe dane pomiarowe - uzyskane w ten sposób przekształcenie jest **dopasowane** do aktualnej dziedziny problemu (zastosowania).

Znanych jest szereg algorytmów do ICA. Zasadnicze kryteria ich różnicowania to:

- (A) algorytm pracujący w trybie „wsadowym” lub adaptacyjny algorytm typu „on-line”;
- (B) algorytm wymagający obróbki wstępnej lub algorytm jedno-przebiegowy.

Najbardziej znane algorytmy do ICA to: C. Jutten, 1990 (historycznie 1-szy algorytm oparty jedynie o dekokorelację wyższego rzędu), P. Common, 1994 (definicja pojęcia ICA), J. Cardoso, 1989-95 (algorytm *Jade ICA*), A. Cichocki i inni, 1994 (adaptacyjny algorytm typu „on-line”), T. Bell - T. Sejnowski, 1995 (algorytm *Infomax ICA*), S. Amari – A. Cichocki i inni, 1995-96 (adaptacyjny algorytm *Natural gradient ICA*), A. Hyvarinen - E.Oja - J. Karhunen, 1998-2000 (algorytm *Fast ICA*).

2.2 Niezależność a dekokorelacja

Niech $p(y_1, y_2)$ oznacza gęstość rozkładu łącznego zmiennych y_1 i y_2 , a $p_1(y_1)$ - gęstość rozkładu brzegowego dla y_1 i podobnie dla y_2 . Zmienne losowe y_1 i y_2 są **niezależne** wtedy i tylko wtedy, gdy :

$$p(y_1, y_2) = p_1(y_1) p_2(y_2). \quad (3)$$

Dla dwóch funkcji niezależnych zmiennych losowych h_1 i h_2 , zachodzi :

$$E\{h_1(y_1)h_2(y_2)\} = E\{h_1(y_1)\}E\{h_2(y_2)\}. \quad (4)$$

Dwie zmienne y_1 i y_2 są **zdekokorelowane** jeśli ich kowariancja jest zerowa:

$$E\{y_1 y_2\} - E\{y_1\}E\{y_2\} = 0. \quad (5)$$

Zmienne niezależne są jednocześnie zdekokorelowane, ale nie na odwrót. Np. niech (y_1, y_2) są dyskretnymi zmiennymi o prawdopodobieństwie $1/4$ dla wartości $(0,1)$, $(0,-1)$, $(1,0)$,

(-1,0). Wtedy y_1 i y_2 są zdekorelowane. Ale jednocześnie zachodzi:

$$E\{y_1^2 y_2^2\} = 0 \neq 1/4 = E\{y_1^2\}E\{y_2^2\} \quad (6)$$

czyli zmienne nie są niezależne.

Dwie zmienne Gaussowskie nie mogą być odseparowane w modelu ICA. Mieszanie dwóch zmiennych Gaussa wymieszane ortogonalną macierzą zachowują rozkłady Gaussa. Gęstość rozkładu łącznego dwóch mieszanin jest wtedy w pełni symetryczna - nie zawiera ona żadnej informacji o kierunku wektorów w macierzy mieszającej. Taka macierz nie może zostać znaleziona w analizie ICA.

2.3 Przetwarzanie wstępne dla ICA

Usuwanie wartości średniej: stosuje się w celu uproszczenia algorytmów ICA. Niech $\mathbf{m}$ będzie wektorem wartości średnich wektora obserwacji $\mathbf{x}(t)$. Po estymacji sygnałów wyjściowych w ICA ich wymagane wartości średnie mogą zostać odtworzone jako:

$$\mathbf{A}^{-1}\mathbf{m}, \quad (7)$$

gdzie $\mathbf{A}^{-1}$ jest odwrotnością macierzy mieszającej (określonej w procesie ICA).

„Whitening” (ortogonalizacja, „wybielanie”) - liniowe przekształcenie wektora, tak aby poszczególne składowe obserwowanego wektora były nieskorelowane i posiadały jednostkowe wariancje:

$$E\{\tilde{\mathbf{x}}\tilde{\mathbf{x}}^T\} = \mathbf{I} \quad (8)$$

Po przeprowadzeniu „wybielenia” obserwacji w procesie ICA zamiast estymacji n^2 elementów (swobodnej) macierzy wystarczy teraz estymacja $n(n-1)/2$ elementów macierzy ortogonalnej. W graficznej interpretacji dla 2-wymiarowego rozkładu - po „wybieleniu” uzyskujemy rozkład próbek w obszarze kwadratu, - wystarczy teraz znalezienie jednego kąta obrotu, aby boki kwadratu były równoległe do osi układu współrzędnych. Możliwa też staje się też ewentualna redukcja rozmiaru macierzy - wtedy, gdy pewne wartości własne λ_j są już zbyt małe.

2.4 "Wsadowy" algorytm *Fast ICA*

Teraz podamy i przeanalizujemy algorytm *FastICA*, opracowany przez Hyvarinena, Karhunen i Oja [5]. Pracuje on w trybie wsadowym i dlatego też możliwe jest zastosowanie kroków wstępnej obróbki danych, które przyspieszają i ułatwiają proces zbiegania się procesu uczenia wag macierzy $\mathbf{W}$. Ten algorytm oparty jest na iteracyjnej regule modyfikacji macierzy wag i takim kryterium kosztu, które wymusza takie wartości macierzy $\mathbf{W}$, przy których następuje maksymalizacja niegaussowskiego charakteru wektora wyjściowego $\mathbf{y}=\mathbf{W}\mathbf{x}$. Ten niegaussowski charakter jest wyrażony np. przez dywergencję Kulbacka-Leiblera (negatywną entropię):

$$KL(W) = \int p(\mathbf{y}) \log \frac{p(\mathbf{y})}{\prod_{k=1}^K p(y_k)} d\mathbf{y} \quad (9)$$

$$KL(W) = -H(\mathbf{Y}; W) + \sum_{k=1}^K H(Y_k; W) . \quad (10)$$

Pierwszy składnik wyraża entropię rozkładu łącznego, a drugi - sumę entropii 1-wymiarowych rozkładów brzegowych. Wartość $KL(W)$ jest minimalna wtedy, gdy poszczególne zmienne są wzajemnie niezależne. Ponieważ bezpośrednie obliczenie $KL(W)$ jest zbyt złożone, w praktyce stosuje się aproksymacje rozkładów przy pomocy momentów wyższego rzędu i nieliniowych funkcji. Sam proces iteracji, którego celem jest minimalizacja kryterium kosztu $KL(W)$, jest zbliżony do metody Newtona. Ale szczegółowe wyprowadzenie reguły modyfikacji wag pomijamy.

1) Wymagana obróbka wstępna sygnału wektorowego

1. Usuń wartość średnią wektora obserwacji;
2. Wykonaj „wybielenie” obserwacji.

2) Algorytm "Fast ICA

A. Inicjalizacja - dowolna (niezerowa) wartość początkowa macierzy wag $\mathbf{W}$.

B.

1. Iteracja: dla wyjść $p = 1, \dots, n$; wykonuj kroki (2-4):
2. Oblicz zmodyfikowany wektor:

$$\mathbf{w}^+ = E\{\mathbf{x} \cdot g(\mathbf{w}^T \mathbf{x})\} - E\{g'(\mathbf{w}^T \mathbf{x})\} \cdot \mathbf{w} , \quad (11)$$

gdzie g jest funkcją nieliniową, g' jej pierwszą pochodną względem czasu.

3. Normalizuj do wektora o długości jednostkowej:

$$\mathbf{w} = \frac{\mathbf{w}^+}{\|\mathbf{w}^+\|} . \quad (12)$$

4. Aby zapobiec zbieżaniu poszczególnych wektorów do tego samego maksimum należy dokonywać dekorelacji kolejnego wektora względem poprzednich wektorów wag. Możliwy jest tu np. schemat deflacji oparty na dekorelacji Grama-Schmidta (od aktualnego wektora odejmij sumę rzutów poprzednich „ustalonych” wektorów a następnie znormalizuj tak otrzymany nowy wektor):

$$\mathbf{w}_{p+1} = \mathbf{w}_{p+1} - \sum_{j=1}^p \mathbf{w}_{p+1}^T \mathbf{w}_j \mathbf{w}_j ; \quad \mathbf{w}_{p+1} = \frac{\mathbf{w}_{p+1}}{\sqrt{\mathbf{w}_{p+1}^T \mathbf{w}_{p+1}}} \quad (13)$$

Jeśli nie chcemy nadawać określonej kolejności wektorom wag to możliwa jest też symetryczna dekorelacja „macierzowa”

$$\mathbf{W} = (\mathbf{W}\mathbf{W}^T)^{-1/2} \mathbf{W} \quad (14)$$

5. Jeśli zbieżność $\mathbf{W}$ nie wystąpiła to powtórz od kroku 1.

2.5 Algorytm "on-line" NG ICA a metoda wsadowa "FastICA"

W poprzednich pracach autorzy korzystali z metody *NG ICA* [17, 19], która jest typu „on-line” - jej wyprowadzenie oparte jest o tzw. *naturalny gradient* [6]. W takim przypadku nie jest realistyczne żądanie istnienia kroku wstępnego „wybielenia” danych i sam proces uczenia jest wolniej zbieżny aniżeli w metodzie *FastICA*. Macierzowa reguła modyfikacji wag w

metodzie NG ICA jest postaci:

$$\mathbf{W}^+ = \mathbf{W} + \eta(\mathbf{I} - \mathbf{g}(\mathbf{y})\mathbf{y}^T)\mathbf{W} \quad (15)$$

gdzie $\mathbf{y} = \mathbf{W} \mathbf{x}$, $\mathbf{I}$ jest macierzą jednostkową a η współczynnikiem uczenia wag (zmiennym w czasie).

Można zauważyć, że reguła modyfikacji wag w algorytmie FastICA może być zapisana w zbliżonej postaci do adaptacyjnego algorytmu gradientowego „on-line”

$$\mathbf{W}^+ = \mathbf{W} + \Gamma[\text{diag}(-[\dots\beta_i\dots]) + E\{\mathbf{g}(\mathbf{y})\mathbf{y}^T\}]\mathbf{W} \quad (16)$$

gdzie

$$\beta_i = E\{y_i \cdot g(y_i)\} \text{ i } \Gamma = \text{diag}([\dots 1/(\beta_i - E\{g'(y_i)\}) \dots]) \quad (17)$$

Dzięki dysponowaniu „całym” zbiorem danych na raz, metoda wsadowa zapewnia optymalny dobór szybkości zbiegania się macierzy wag - poprzez każdorazowe dobieranie współczynnika uczenia Γ i macierzy diagonalnej β do której ma zbiegać produkt wektorów $\mathbf{g}(\mathbf{y})\mathbf{y}^T$. Obliczanie Γ i β w trakcie uczenia wag jako zależnych od funkcji $g(\cdot)$ pozwala również na uniezależnienie algorytmu ICA od typu sygnału. W innym przypadku, gdy proces ma zbiegać przy $\mathbf{g}(\mathbf{y})\mathbf{y}^T$ zbiegającym do macierzy diagonalnej $\mathbf{I}$ konieczne jest stosowanie dwóch różnych funkcji nieliniowych $g(\cdot)$ - jednej dla sygnałów *pod-Gaussowskich* a drugiej dla sygnałów *nad-Gaussowskich*.


3 Procedura opisu tekstury wykorzystująca ICA

W tym podejściu potraktujemy prostokątne bloki obrazu (każdy o rozmiarze $k \cdot l = N$) jako mieszaniny m niezależnych składowych (źródeł w modelu ICA). Obserwowane prostokątne bloki obrazu są skanowane w ustalonym z góry porządku do postaci sygnałów $x_i(t)$ ($i=1, \dots, n$; $t = 1, \dots, N$). Zakładamy, że te sygnały (zebrane w wektor $\mathbf{x}(t)$) spełniają model punktowego mieszania przyjęty w ICA:

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) = \sum_{i=1}^m s_i(t)\mathbf{a}_i \quad (18)$$

Czyli $\mathbf{x}(t)$ jest wektorową reprezentacją obserwowanych bloków obrazów (jest to wektor n sygnałów, każdy z nich o długości $N = k \cdot l$, jako wynik skanowania bloków obrazu).

$\{\mathbf{a}_i\}$ to n wektorów cech (każdy o długości m) tworzących wiersze macierzy (mieszej) $\mathbf{A}$ (każdy wiersz stanowi wartości cech, poszukiwane dla opisu tekstury w obserwowanym bloku obrazu). $\{s_i\}$ to m N -elementowych sygnałów źródeł (Rys. 1).



Rysunek 1. Ilustracja składania tekstury obrazu z niezależnych składowych: x_i - obserwowany i -ty blok obrazu; $\mathbf{a}_i$ współczynniki wymieszania źródeł (tu: wartości cech obserwowanego bloku obrazu); $\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_m$ - źródła w ICA (ich 2-wymiarowa ilustracja) niezależne składowe (wektory bazowe).

Dysponując obserwacjami danymi w postaci kolejnych bloków obrazu $\mathbf{x}_i(t)$ stosujemy algorytm ICA pozwalający na jednoczesną estymację nieznanymi niezależnymi składowymi $\mathbf{s}$ i pewnej macierzy $\mathbf{W}$. Po „zamrożeniu” macierzy $\mathbf{W}$ określany jest ostateczny wektor wyjściowy $\mathbf{y}$, taki, że:

$$\hat{\mathbf{s}} = \mathbf{y} = \mathbf{W} \cdot \mathbf{x}; \quad \mathbf{W} \approx \mathbf{A}^{-1}. \quad (19)$$

Macierz $\mathbf{W}$ znaleziona w procesie uczenia systemu składowych niezależnych nie jest przez nas dalej brana pod uwagę. Dopiero w fazie **aktywnej pracy** systemu detekcji cech tekstury celem jest ustalenie dla każdego analizowanego bloku obrazu jego wektora cech $\mathbf{a}_i$

$$\mathbf{x}(t) = \mathbf{a}_i \mathbf{s}(t) = \sum_{i=1}^m s_i(t) \mathbf{a}_i \quad (20)$$

Ten problem sprowadza się do standardowego problemu **identyfikacji kanału** przesyłowego o wejściu $\mathbf{s}$ i wyjściu $\mathbf{x}$.

Podsumujmy własności metody ICA w procesie opisu tekstury obrazu:

- ICA znajduje najbardziej „nie-Gaussowską” dekompozycję obrazu;
- funkcje bazowe (źródła $\mathbf{s}$) są dopasowane do konkretnej klasy obrazów;
- wektory $\mathbf{s}_i$ posiadają naturalną interpretację po przekształceniu ich w bloki obrazu - są detektorami krawędzi w obrazie - interesujący aspekt dla „biologicznych badań percepcji człowieka”.


Aby uzyskać redukcję rozmiaru przestrzeni cech w stosunku do rozmiaru oryginalnego bloku obrazu, należy zastosować **obróbkę wstępną** typową dla kompresji obrazu, np. w postaci PCA. Dla przykładu blok o rozmiarze 12 x 12 prowadzi do wektora obserwacji o długości 144; w procesie PCA można wybrać np. 50 największych składowych głównych, dokonać kompresji wektorów $\mathbf{x}$ do rozmiaru 50 x 1 i znaleźć w procesie ICA macierz $\mathbf{W}$ o rozmiarze 50 x 50. Oczywiście w celu 2-wymiarowej ilustracji wektorów bazowych (wierszy macierzy $\mathbf{W}$) należy najpierw przywrócić każdy 50-elementowy wektor do postaci 144-elementowego wektora i dopiero wtedy zamieniać je na bloki 12 x 12-elementowe.

4 Testy


Celem eksperymentów była weryfikacja idei zastosowania ICA dla detekcji cech tekstur a także analiza porównawcza poprawności detekcji cech (tzn. czy odpowiednie jest „rozdzielenie” cech dla różnych tekstur i „zwartość” obszarów w przestrzeni cech odpowiadających poszczególnym teksturom) dla dwóch metod: *filtracji Gabora* i *ICA*.

Funkcje bazowe stosowane w filtracji Gabora mają uniwersalny charakter i nie zależą od zawartości obrazu (Rys. 2). Obrazy będące 2-wymiarową ilustracją wektorów bazowych filtracji Gabora charakteryzują się: sinusoidalną strukturą o różnych częstościach - pomiędzy 0.05 Hz a 0.38 Hz; różnym zorientowaniem „fal” w przestrzeni obrazu - pomiędzy 0° a 180°. Będą one stosowane w niezmienniej postaci zarówno wtedy, gdy mają zostać ustalone względem nich cechy obrazów tekstur Brodatza (Rys. 3) jak i cechy obrazów angiograficznych (Rys. 4). Tymczasem wektory bazowe, które znaleźliśmy metodą FastICA dla przykładowych tekstur Brodatza różnią się znacznie od wektorów ICA znalezionych dla obrazów angiograficznych. Dla standardowego zbioru 20 tekstur Brodatza danych


wybraliśmy do analizy niezależnych komponentów po jednym bloku o rozmiarze 40 x 40 pikseli z każdego obrazu – otrzymaliśmy w ten sposób 20 „mieszanin” niezależnych komponentów o długościach odpowiadających 1600 próbkom czasowym. Znalezione przez nas niezależne komponenty ilustruje Rys. 5(a) – po przekształceniu wektorów w bloki obrazu. Analiza ICA wykonana na blokach obrazów angiograficznych pozwoliła na detekcję 20 niezależnych komponentów, przedstawionych na Rys. 5(b).



Rysunek 2. 2-wymiarowa ilustracja 50 funkcji bazowych dla filtracji Gabora (w postaci bloków obrazu o rozmiarach 12 x 12 pikseli) [22].



Rysunek 3. 20 obrazów tekstur Brodatza, które wykorzystano w testach metody ICA.



Rysunek 4. 16 obrazów angiograficznych, z których pobierane są bloki o rozmiarze 40 x 40 i przekształcane w wektory wejściowe (sygnały mieszanin) dla analizy ICA.

Celem sprawdzenia, czy znalezione komponenty są rzeczywiście niezależne, przeprowadzono prosty test polegający na pomiarach korelacji wzajemnej par wektorów komponentów. Uzyskane wyniki nie przekraczały wartości 1%, można więc w praktyce uznać, że udało się znaleźć (wystarczająco niezależne) składowe.


W analizie porównawczej („zwartości” i „rozdzielenia”) obszarów cech można stosować kryterium oparte na tzw. informacji Fishera [14]. Zastosowaliśmy uproszczone kryterium będące sumą odległości pomiędzy parami punktów przestrzeni cech reprezentujących cechy różnych tekstur. Przeprowadzone zostały wstępne testy porównawcze cech uzyskanych w filtracji Gabora i w analizie ICA. Wskazują one na dokładniejszą separację klas w przestrzeni cech uzyskanej w metodzie ICA, ale też na mniejszą wrażliwość cech Gabora na przekształcenia tekstury nie zmieniające jej klasy (np. skalowanie, obrót).

5 Podsumowanie


Można interpretować funkcje Gabora jako detektory krawędzi o różnych (dyskretnych) orientacjach i różnych częstotliwościach. W odróżnieniu od przekształcenia ICA funkcje Gabora są przyjmowane uniwersalnie - niezależnie od zastosowania. Stąd wynika obserwacja, potwierdzona wynikami eksperymentów, że przekształcenie ICA jako dopasowane do konkretnych klas tekstur, rozpatrywanych w konkretnym zastosowaniu, pozwala na dokładniejszą klasyfikację niż klasyfikacja cech uzyskanych w wyniku filtracji Gabora.

Podziękowanie

Niniejszą pracę wykonano w ramach projektu badawczego finansowanego przez grant MNiI - 3T11A 015 26.



(a) Ilustracja 20 komponentów ICA dla obrazów Brodatza.



(b) Ilustracja 20 komponentów ICA dla obrazów angiograficznych.

Rysunek 5. 20 wektorów bazowych (przekształconych w bloki obrazu) znalezionych metodą ICA dla (a) obrazów tekstur Brodatza i (b) obrazów angiograficznych.

Literatura

- [1] Gonzalez R.C., Wintz P. : *Digital Image Processing*, Addison-Wesley, Reading Mass. etc., 1987.
- [2] Niemann H.: *Pattern Analysis and Understanding*. Springer, Berlin etc., 1990.
- [3] Tadeusiewicz R., Korohoda P.: *Komputerowa analiza i przetwarzanie obrazów*. Wydawnictwo Fundacji

Postępu Telekomunikacji, Kraków, 1997.

- [4] Brodatz P.: *Textures. A photographic album for artists and designers*. Dover Publ., New York, 1966.
- [5] Hyvarinen A., Karhunen J., Oja E.: *Independent Component Analysis*, John Wiley & Sons, New York etc., 2001.
- [6] Cichocki A., Amari S.: *Adaptive Blind Signal and Image Processing*, John Wiley, Chichester, UK, 2002.
- [7] Randen T., Husøy J.H.: Filtering for texture classification: A comparative study, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 21 (1999), No.4, 291–310.
- [8] Skarbek W.: *Metody reprezentacji obrazów cyfrowych*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1993.
- [9] Turner M.R.: Texture discrimination by Gabor functions, *Biological Cybernetics*, vol. 55 (1986), 71–82.
- [10] Jain A.K., Farrokhnia F.: Unsupervised texture segmentation using Gabor filters, *Pattern Recognition*, vol. 24 (1991), No. 12, 1167–1186.
- [11] Turk M., Pentland A.: Eigenfaces for recognition. *Journal of Cognitive Neuroscience*, vol. 3 (1991), 71–86.
- [12] Swets D.L., Weng J.J.: Using discriminant eigenfeatures for image retrieval, *IEEE Trans. Patt. Anal. Mach. Intell.*, PAMI-18 (1996), No.8, 831-836.
- [13] Haralick R.M.. et al.: Textural features for image classification, *IEEE Transactions on Systems, Man and Cybernetics*, SMC-3 (1973), No. 6, 610 - 621.
- [14] Duda R.O., Hart P.E.: *Pattern Classification and Scene Analysis*, New York, John Wiley and Sons, 1973.
- [15] Schurmann J.: *Pattern classification. A unified view of statistical and neural approaches*. John Wiley and Sons, New York, 1996.
- [16] Osowski S.: *Sieci neuronowe w ujęciu algorytmicznym*, WNT, Warszawa, 1996.
- [17] Kasprzak W.: *Adaptive computation methods in image sequence analysis*. Prace Naukowe - Elektronika, Nr. 127 / 2000, Oficyna Wydawnicza Politechniki Warszawskiej, 170 stron.
- [18] Snitkowska E. *Deskryptory tekstury w standardzie MPEG-7*, VIII Sympozjum Nowości w Technice Audio i Wideo, Warszawa 2001.
- [19] Cichocki A., Kasprzak W., Skarbek W.: *Adaptive learning algorithm for principal component analysis with partial data*, Cybernetics and Systems '96, Austrian Society for Cybernetic Studies, Vienna, 1996, 1014-1019.
- [20] Kasprzak W., Cichocki A., Amari S.: *Blind Source Separation with Convolutional Noise Cancellation*, Neural Computing and Applications, Springer, London, vol. 6(1997), 127-141.
- [21] Inki M.: ICA features of image data in one, two and three dimensions. ICA 2003, 4-th Int. Symposium on Independent Component Analysis and Blind Signal Separation, April 1-4, Nara, Japan. 2002, 863-868.
- [22] Jenssen R., Eltoft T.: ICA filter bank for segmentation of textured images. ICA 2003, 4-th Int. Symposium on Independent Component Analysis and Blind Signal Separation, April 1-4, Nara, Japan, 2003, 827-832.