

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], [2], [3] jest analiza tekstury [4]. 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.

Zaproponowane zostanie nowe podejście do pozyskiwania cech tekstur, oparte na statystycznej analizie składowych niezależnych (ICA) [5], [6], które w przekonaniu autorów może służyć za (niskopoziomowy) model percepcji wizyjnej człowieka. Nasze dotychczasowe doświadczenia z metodami ICA [10]-[13] oraz pierwsze wyniki prac dostępne w literaturze potwierdzają to przypuszczenie [14, 15].

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 niegaussowskie znajdujemy efektywnie niezależne składowe - czyli docelowe osie przestrzeni cech.

2 Procedura szybkiego obliczenia przekształcenia ICA

W pracy omówiono implementację dwóch algorytmów wielo-kanalowego rozplatania źródeł (problem MBD) z ich mieszanin - tzw. algorytm CPA (Constant Power separation Algorithm - algorytm separacji stałoenergetycznej) i CDA (Constant Diagonal separation Algorithm - algorytm separacji stałodiagonalnej), których ideę podano w pracy [7] i rozwinięto w [8]. Oba algorytmy (CPA i CDA) oparte są na założeniu tzw. stałodiagonalnej macierzy mieszającej.

3 Procedura opisu tekstury wykorzystująca ICA

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

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

Czyli $x(t)$ jest wektorową reprezentacją obserwowanych bloków obrazów (jest to wektor n sygnałów, każdy z nich o długości $N = k \times l$, jako wynik skanowania bloków obrazu). $\mathbf{a}_i$ to n wektorów cech (każdy o długości m) tworzących wiersze macierzy (mieszającej) $\mathbf{A}$ (każdy wiersz stanowi wartości cech, poszukiwane dla opisu tekstury w obserwowanym bloku obrazu). s_i to m N -elementowych sygnałów źródeł (Rys. 3).

*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

$$\mathbf{X}_i = a_{i1} \mathbf{s}_1 + a_{i2} \mathbf{s}_2 + \dots + a_{im} \mathbf{s}_m$$

Rysunek 3 Ilustracja składania tekstury obrazu z niezależnych składowych: x_i - obserwowany i-ty blok obrazu; a_i współczynniki wymieszania źródeł (tu: wartości cech obserwowanego bloku obrazu); $s_1, s_2, \dots, s_m$ - źródła w ICA (ich 2-wymiarowa ilustracja) niezależne składowe (wektory bazowe).

Dysponując obserwacjami danymi w postaci kolejnych bloków obrazu $x_i(t)$ stosujemy algorytm ICA pozwalający na jednoczesną estymację nieznaną niezależnych składowych s_i i pewnej macierzy W . Po "zamrożeniu" macierzy W określany jest ostateczny wektor wyjściowy y , taki, że:

$$\hat{\mathbf{s}} = \mathbf{y} = \mathbf{W} \cdot \mathbf{x}; \quad \mathbf{W} \approx \mathbf{A}^{-1}. \quad (2)$$

Macierz W znaleziona w procesie "nauczenia" 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 $\mathbf{a}_i$:

$$\mathbf{x}(t) = \mathbf{a}_i \mathbf{s}(t) = \sum_{i=1}^m s_i(t) \mathbf{a}_i \quad (3)$$

Ten problem sprowadza się do standardowego problemu identyfikacji kanału przesyłowego o wejściu s i wyjściu x . Podsumujmy własności metody ICA w procesie opisu tekstury obrazu: (1) ICA znajduje najbardziej "nie-Gaussowska" dekompozycję obrazu; (2) funkcje bazowe (źródła s) są dopasowane do konkretnej klasy obrazów; (3) wektory 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 x do rozmiaru 50x1 i znaleźć w procesie ICA macierz W o rozmiarze 50 x 50. Oczywiście w celu 2-wymiarowej ilustracji wektorów bazowych (wierszy macierzy W) należy najpierw zdekomprimować każdy 50-elementowy wektor do postaci 144-elementowego wektora i dopiero wtedy zamieniać je na bloki 12 x 12-elementowe.

4 Testy

Celem eksperymentów jest 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 trzech metod: (1) macierzy spójności (standardowa metoda [9]) (2) filtracji Gabora; (3) ICA (po uprzedniej kompresji - zmianie rozdzielczości). Dla standardowego zbioru 20 tekstur danych blokami obrazu o rozmiarach 12 x 12 określiliśmy 50 funkcji bazowych (źródeł) stosując metodę FastICA (po uprzedniej kompresji wektorów danych do 50). Obrazy dla wektorów bazowych (składowych niezależnych w ICA) charakteryzują się: (1) sinusoidalną strukturą o różnych częstościach, (2) różnym zorientowaniu "fal" w przestrzeni obrazu, (3) są w miarę jednorodnie rozmieszczone w obszarze pomiędzy 0.05 Hz a 0.38 Hz i kierunku pomiędzy 0° a 180°.

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.

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] Skarbek W.: Metody reprezentacji obrazów cyfrowych, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1993.
- [8] 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.
- [9] Haralick R.M. et al.: Textural features for image classification, IEEE Transactions on Systems, Man and Cybernetics, SMC-3 (1973), No. 6, 610 – 621.
- [10] Kasprzak W.: Adaptive computation methods in image sequence analysis. Prace Naukowe - Elektronika, Nr. 127 / 2000, Oficyna Wydawnicza Politechniki Warszawskiej, 170 stron.
- [11] Snitkowska E. Deskryptory tekstury w standardzie MPEG-7, VIII Sympozjum Nowości w Technice Audio i Wideo, Warszawa 2001.
- [12] 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.
- [13] Kasprzak W., Cichocki A., Amari S.: Blind Source Separation with Convolutional Noise Cancellation, Neural Computing and Applications, Springer, London, vol. 6(1997), 127-141.
- [14] 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.
- [15] 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.