ZESZYTY NAUKOWE POLITECHNIKI ŚLĄSKIEJ 2000
Seria: AUTOMATYKA z. 131 Nr kol. 1476

Henryk PALUS, Damian BERESKA, Sebastian GRELA
Politechnika Śląska

TRANSFORMACJA KARHUNENA-LOEVEGO DLA OBRAZÓW BARWNYCH

Streszczenie. Transformacja K-L wymaga obliczania macierzy transformującej dla każdego obrazu oddzielnie. W pracy opisano szczegóły efektywnej implementacji takiej transformacji dla obrazów barwnych. Przedstawiono przegląd ważniejszych dotychczasowych zastosowań transformacji w dziedzinie przetwarzania obrazów barwnych. Stosując standardowe obrazy barwne pokazano zasadnicze właściwości transformacji K-L: dekorelację składowych barwnych i skupienie energii obrazu w pierwszych składowych. Wykazano doświadczalnie mniejszą wrażliwość składowej K_1 w stosunku do składowej intensywnościowej I ze względu na zmiany luminancji obrazu.

KARHUNEN-LOEVE TRANSFORM OF COLOUR IMAGES

Summary. The K-L transform needs calculating of transform matrix for each image separately. In the paper details of effective implementation such transform of colour images are described. The short review of KLT applications in the field of colour image processing is presented. Using the standard colour images, principal properties of KLT are shown, i.e. a complete decorrelation of colour components and energy compaction in first components. The lesser luminance sensitivity of K_1 component compared to I component is experimentally proved.

1. Wprowadzenie

Analizując informację zawartą w obrazach barwnych można zauważyć jej redundancję przestrzenną (ang. *spatial redundancy*) i redundancję widmową (ang. *spectral redundancy*). Rezultatem redundancji widmowej jest znaczny stopień skorelowania składowych RGB. Badania doświadczalne pokazały [1], że dla obrazów uzyskanych za pomocą jednoprzetwornikowej kamery CCD wartości współczynników korelacji składowych RGB wynoszą 0,7-0,9. Stwierdzono również, że transformacje przestrzeni barw RGB na przestrzenie typu „jedna składowa luminancyjna, dwie składowe chrominancyjne" (np. YUV, YIQ, IHS itp.) częściowo dekorelują składowe barw. Podobne wyniki doświadczalne dla przestrzeni IHS przedstawiono w pracy [2]. Metodą dokonującą całkowitej dekorelacji składowych RGB jest tzw. transformacja Karhunena-Loevego (KLT) [3], znana również w

literaturze jako transformacja Hottelinga [4] czy analiza głównych składowych (ang. *principal components analysis, PCA*) [5]. Transformacja ta, opierająca się na statystycznych właściwościach obrazu barwnego, zapewnia otrzymanie 3 obrazów składowych o nieskorelowanych wartościach i malejącym znaczeniu statystycznym (coraz mniejsze wartości własne). Z energetycznego punktu widzenia można stwierdzić, że na ogół zdecydowana większość energii sygnału jest skupiona w pierwszej składowej. Tak więc KLT minimalizując korelację pomiędzy składowymi jednocześnie maksymalizuje zawartość informacji w pierwszej składowej. Można postrzegać KLT jako obrót układu współrzędnych w przestrzeni barw, pozwalający osi K_1 ustawić się w kierunku największej zmienności barwy w obrazie. Wzrost mocy obliczeniowej komputerów, który nastąpił w ostatnich latach, umożliwił nowe zastosowania tej klasycznej metody przetwarzania sygnałów o stosunkowo dużej złożoności obliczeniowej.

2. Transformacja Karhunena-Loevego

Transformacja Karhunena-Loevego dla obrazu barwnego RGB zdefiniowana jest następująco [3]:

$$\begin{bmatrix} K_1 \\ K_2 \\ K_3 \end{bmatrix} = \begin{bmatrix} m_{11} & m_{12} & m_{13} \\ m_{21} & m_{22} & m_{23} \\ m_{31} & m_{32} & m_{33} \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \tag{1}$$

Powyższa macierz transformacji sprowadza macierz kowariancji obrazu RGB do postaci diagonalnej:

$$\begin{bmatrix} m_{11} & m_{12} & m_{13} \\ m_{21} & m_{22} & m_{23} \\ m_{31} & m_{32} & m_{33} \end{bmatrix} \begin{bmatrix} u_{11} & u_{12} & u_{13} \\ u_{12} & u_{22} & u_{23} \\ u_{13} & u_{23} & u_{33} \end{bmatrix} \begin{bmatrix} m_{11} & m_{21} & m_{31} \\ m_{12} & m_{22} & m_{32} \\ m_{13} & m_{23} & m_{33} \end{bmatrix} = \begin{bmatrix} \lambda_1 & 0 & 0 \\ 0 & \lambda_2 & 0 \\ 0 & 0 & \lambda_3 \end{bmatrix} \tag{2}$$

gdzie: λ_1, λ_2, λ_3 - wartości własne macierzy kowariancji z elementami u_{ij}, a $[m_{11}, m_{12}, m_{13}]$, $[m_{21}, m_{22}, m_{23}]$, $[m_{31}, m_{32}, m_{33}]$ - wektory własne tej macierzy.

KLT ustanawia przestrzeń opartą na osiach skierowanych w kierunkach, w których dane obrazowe wykazują największą wariancję. Podobne równania transformacji można zapisać również dla innych od RGB przestrzeni barw. Wyznaczenie obrazu po transformacji K-L wymaga następujących działań:

- obliczenia macierzy kowariancji dla obrazu w przestrzeni wyjściowej,

- obliczenia wartości własnych i wektorów własnych tej macierzy składających się na macierz transformacji,
- pomnożenia macierzy transformacji przez macierz obrazu wyjściowego,
- przeskalowania otrzymanych wartości do zakresu 0-255.

3. Dotychczasowe zastosowania KLT w przetwarzaniu obrazów barwnych

3.1. Kodowanie obrazów barwnych

Główną tendencją w dziedzinie kompresji obrazów barwnych pozostaje, od czasu klasycznej publikacji Pratta [6], dekorelacja (przynajmniej częściowa) składowych obrazu barwnego i dalsza kompresja pojedynczych składowych metodami opracowanymi wcześniej dla obrazów monochromatycznych (np. kwantyzacja wektorowa, metoda transformacyjna itd.). W pracy [2] twierdzi się, że sama tylko transformacja z RGB na KLT pozwala zmniejszyć liczbę bitów na piksel w opisie barwy z 24 do 19 bez specjalnego obniżenia jakości obrazu. Złożoność obliczeniowa KLT spowodowała poszukiwanie nowych przestrzeni barw powstałych w wyniku liniowych i możliwie prostych obliczeniowo transformacji składowych RGB, a jednocześnie dekorelujących składowe. W pracy [7] zaproponowano 3 takie przestrzenie: KLA (*uśredniona KLT*), SIM oraz $I_1I_2I_3$. KLT znajduje zastosowanie zarówno w algorytmach kompresji bezstratnej, jak i stratnej. Można pokazać, że chociaż usunięcie redundancji przestrzennej w wielu obrazach ma większy wpływ na zwiększenie współczynnika kompresji niż usunięcie redundancji spektralnej [8], to jednak w wielu zastosowaniach poprawa kompresji o 0,5-2 bitów/piksel uzyskana w wyniku redukcji redundancji spektralnej ma swoje znaczenie. Nowoczesne metody kompresji stratnej [9] najpierw dokonują segmentacji obrazu, a dopiero potem wykorzystują KLT do kompresji. Złożoność obliczeniowa KLT spowodowała prawdopodobnie zainteresowanie separowalną transformacją Karhunena-Loevego (SKLT) [10], która jest szybsza i wymagająca mniej pamięci niż KLT.

3.2. Segmentacja obrazów barwnych

W literaturze można spotkać w ostatnich latach próby wykorzystania transformacji K-L w procesie segmentacji obrazu barwnego. W szczególności dotyczy to barwnych obrazów biomedycznych. W pracy [11] do segmentacji obrazu skóry na obszar podejrzany o zmiany

nowotworowe i jego otoczenie zastosowano z pozytywnym skutkiem metodę złożoną z transformacji K-L obrazu RGB i progowania histogramu najważniejszego obrazu składowego powstałego w wyniku transformacji. Do podobnych celów w pracy [12] używano KLT w połączeniu z algorytmem trójwymiarowego podziału medianowego (ang. *median 3-D split*). Jest to klasyczna metoda kompresji kwantyzacyjnej umożliwiająca np. przejście z obrazu z 24-bitami/piksel na obraz z 2 bitami/piksel. Badania wstępne pokazały, że nie poprzedzając metody podziału medianowego transformacją K-L otrzymujemy wyniki o 5-15% gorsze. Transformację K-L stosowano nie tylko dla obrazów RGB, ale i dla 5 innych przestrzeni barw (IHS, rgb, XYZ, LUV, sferycznej przestrzeni barw). W artykule [13] pokazano, że segmentacja barwnego obrazu skóry zastosowana do 2 pierwszych składowych KLT daje lepsze wyniki niż ta sama metoda zastosowana na obrazie w innej przestrzeni barw, np. IHS, LUV, LAB. Szczegóły tej metody segmentacji zostały przedstawione w [14]. Dla 2 składowych KLT zbudowano dwuwymiarowy histogram i znaleziono jego wierzchołki (środki klasterów), a następnie zastosowano klasyczną metodę klasteryzacyjną *fuzzy c-means* (FCM).

W artykule [15] segmentację wododziałową (ang. *watershed segmentation*) obrazu barwnego poprzedzono dekorelacją składowych RGB za pomocą transformacji K-L. Wykorzystywany w tej metodzie segmentacji tzw. obraz aktywności (ang. *activity image*) obliczono jako sumę ważoną obrazów aktywności obliczonych dla obrazów składowych powstałych po transformacji K-L. Współczynniki wagi przy pierwszym i drugim obrazie składowym były na ogół wyższe niż przy trzecim. Wynik uzyskany za pomocą tej metody segmentacji obrazu barwnego porównano z odpowiednim wynikiem dla obrazu intensywnościowego wskazując na znacznie mniejszą nadsegmentację (ang. *oversegmentation*) w przypadku obrazu barwnego.

Również wśród technik segmentacji krawędziowej próbuje się wykorzystać KLT [16]. Dla pewnej klasy filtrów krawędziowych trójkę (R, G , B) w bieżącym oknie, np. 3×3, zastępuje się jej odległością od trójki złożonej z wartości średnich (R_{sr}, G_{sr}, B_{sr}). Następnie odległości te dla pikseli danego okna sortuje się od najmniejszej do największej. Obraz krawędziowy zostaje wygenerowany na podstawie np. zakresu, tzn. różnicy maksymalnej i minimalnej odległości w oknie. Odległości mogą być wyznaczane na podstawie różnych metryk, np. metryki Mahalanobisa, która korzysta z macierzy kowariancji. W [16] stosuje się nową definicję odległości, która wykorzystuje wektor własny macierzy kowariancji o największej wartości własnej. Na tej definicji opiera się proponowany zakresowy filtr

krawędziowy. W cytowanej pracy stwierdzono efektywność obliczeniową metody i otrzymano wyniki porównywalne z innymi metodami tej klasy.

Powyższe przykłady pokazują, że transformacja K-L na obrazach barwnych, mimo iż odmienna od innych transformacji na przestrzeni RGB, jest coraz częściej stosowana w przetwarzaniu obrazów barwnych.

4. Efektywna implementacja KLT

Z punktu widzenia efektywności algorytmu KLT można wyróżnić w nim dwie części wymagające złożonych obliczeń numerycznych – wyznaczanie macierzy kowariancji (algorytm liczenia kowariancji stosowany w środowisku Matlab: plik cov.m) oraz trudniejsze w realizacji: obliczanie wartości i wektorów własnych tej macierzy. Ponieważ macierz kowariancji dla obrazów barwnych ma wymiar 3×3, to należy wyznaczyć 3 wartości własne i następnie odpowiadające im 3 wektory własne. W powstałym programie zostały zastosowane dwa algorytmy obliczania wartości własnych – algorytm oparty na metodzie iteracyjnej Kryłowa [17] oraz algorytm oparty na rozwiązywaniu równań 3 stopnia metodą Cardana [18]. Metoda Kryłowa umożliwia poprawne wyznaczenie maksymalnej wartości własnej macierzy w sposób iteracyjny, natomiast pozostałe 2 wartości własne można obliczyć analitycznie rozwiązując równanie 2 stopnia, co jest już proste w realizacji numerycznej. Iteracyjność metody powoduje, że nie zawsze prowadzi ona do rozwiązania, ponieważ jej zbieżność silnie zależy od punktu początkowego. W części programu wykorzystującej metodę Kryłowa zastosowano dwa punkty startowe, tzn. jeżeli metoda nie daje wyników z założoną dokładnością po określonej liczbie iteracji, to obliczenia są rozpoczynane ponownie dla drugiego punktu startowego. Mimo tego zabezpieczenia, które ma znaczący wpływ na czas obliczeń, istnieją obrazy, dla których metoda Kryłowa nie jest w stanie wyznaczyć wartości własnych macierzy kowariancji. Metoda Cardana pozwala bezpośrednio rozwiązać równanie 3 stopnia w sposób analityczny, a zatem dokładny, jednak jest bardziej złożona obliczeniowo (obliczanie wartości funkcji arc cos).

Po wyznaczeniu wartości własnych macierzy kowariancji należy wyznaczyć odpowiadające im wektory własne. Obliczenie 3 wektorów własnych wymaga rozwiązania 3 układów 3 równań z 3 niewiadomymi. Równania te są jednak równaniami, w których wyraz wolny jest równy 0, dlatego metody numeryczne rozwiązywania takich układów równań dają rozwiązanie trywialne: zerowe. W celu poprawnego rozwiązania tych układów równań

została wykorzystana własność wektorów własnych polegająca na tym, iż wektory własne mogą być skalowane, a zatem wektor, który nie jest wektorem zerowym, po przeskalowaniu może zawierać składową równą 1. Wstawiając zatem wartość 1 w miejsce kolejno pierwszej, drugiej i trzeciej niewiadomej możemy redukując rozmiar takiego układu równań znaleźć poprawne rozwiązanie. Gdy układ równań pomimo zastosowania takiej metody nie ma rozwiązania oznacza to, że wektor własny jest wektorem zerowym. Jeżeli rozwiązań jest więcej niż jedno, to są one liniowo zależne i do obliczeń można przyjąć dowolne z nich. W celu przyspieszenia algorytmu KLT po znalezieniu pierwszego rozwiązania obliczenia są przerywane i pozostałe rozwiązania nie są już szukane.

Po wyznaczeniu wszystkich wektorów własnych są one normalizowane tak, aby ich długości były równe 1. Ze znormalizowanych wektorów własnych zostaje zestawiona macierz transformacji K-L. Program realizujący opisany algorytm wyświetla: wczytany obraz barwny, macierz kowariancji, jej wartości i wektory własne, współczynniki korelacji oraz powstałe w wyniku transformacji K-L obrazy składowe K_1, K_2 i K_3. Numeryczną poprawność implementacji sprawdzono poprzez wprowadzenie do programu obrazu $K_1K_2K_3$, zamiast obrazu RGB. Program w takim przypadku, zgodnie z oczekiwaniami, informował o braku korelacji pomiędzy składowymi oraz nie zmieniał orientacji układu współrzędnych. Na rys.1. przedstawiono przykładowy obraz w rozbiciu na składowe $K_1K_2K_3$.

Dla obrazu barwnego o rozmiarach 512×512 (czas KLT zależy od rozmiarów obrazu) transformacja zajmuje komputerowi klasy PC z mikroprocesorem Pentium II (333 MHz) mniej niż 3,5 sekundy niezależnie od sposobu wyznaczania wartości własnych macierzy kowariancji. Metoda Kryłowa jest z natury bardziej czasochłonna, ze względu na swój iteracyjny charakter, od metody Cardana. Jednak przy mocach obliczeniowych dzisiejszych komputerów są to różnice ułamków sekund, a czas obliczania wartości i wektorów własnych ma znikomy wpływ na szybkość transformacji. Najbardziej czasochłonne są operacje wykonywane na pełnych obrazach, a nie na ich charakterystykach. W tym przypadku najwięcej czasu pochłania wyznaczanie macierzy kowariancji. Dalsze przyspieszenie transformacji Karhunena-Loevego jest możliwe poprzez zastosowanie do obliczeń szybszych procesorów.

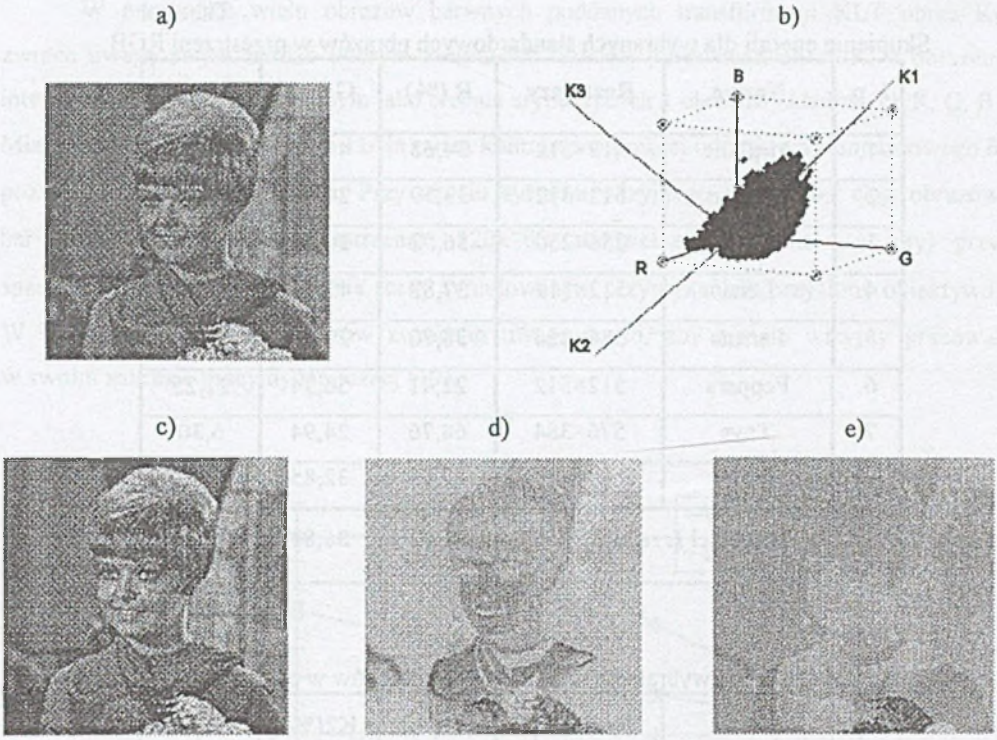

Rys. 1. a) Przykładowy obraz poddany KLT, b) rozkład pikseli obrazu w sześcianie RGB z naniesionym układem współrzędnych $K_1K_2K_3$, powstałe po KLT składowe: c) K_1 (wartość własna: 4434,08), d) K_2 (wartość własna: 605,08), e) K_3 (wartość własna: 126,55)

Fig. 1. a) Example of original image, b) scatter plot in the RGB cube with $K_1K_2K_3$ coordinate system, c) K_1 component (eigenvalue: 4434,08), d) K_2 component (eigenvalue: 605,08), e) K_3 component (eigenvalue: 126,55)

5. Podstawowe właściwości KLT

Dysponując programem dokonującym transformacji RGB/KLT można przekonać się doświadczalnie o dwóch podstawowych właściwościach transformacji: braku korelacji pomiędzy składowymi $K_1K_2K_3$ oraz o skupieniu energii sygnału (*energy compaction*) głównie w pierwszej składowej. Niezależnie od obrazu transformacja KLT dokonuje pełnej dekorelacji składowych. Do oceny skupienia energii w poszczególnych składowych sygnału zastosowano wariancje tych składowych. Wybrano 8 szeroko znanych i rozpowszechnionych w Internecie obrazów barwnych, kwantowanych z użyciem 24 bitów/piksel tzn., 8 bitów/piksel dla każdej składowej R, G, B.

Tabela 1

Skupienie energii dla wybranych standardowych obrazów w przestrzeni RGB

L.p.	Nazwa	Rozmiary	R (%)	G (%)	B (%)
1.	Airplane	512×512	34,68	47,10	18,21
2.	Baboon	512×512	33,59	24,90	41,51
3.	Girl	256×256	36,52	34,60	28,88
4.	Lena	512×512	37,82	43,95	18,23
5.	Parrots	384×256	38,70	29,83	31,48
6.	Peppers	512×512	22,41	56,34	21,25
7.	Toys	576×384	68,76	24,94	6,30
8.	Tulip	640×480	57,85	32,85	9,30
Wartości średnie			**41,96**	**36,81**	**21,90**

Tabela 2

Skupienie energii dla wybranych standardowych obrazów w przestrzeni $K_1K_2K_3$

L.p.	Nazwa	Rozmiary	K1(%)	K2(%)	K3(%)
1.	Airplane	512×512	88,05	10,17	1,78
2.	Baboon	512×512	44,99	39,00	16,01
3.	Girl	256×256	57,36	31,90	10,74
4.	Lena	512×512	70,61	25,63	3,76
5.	Parrots	384×256	26,70	30,65	42,65
6.	Peppers	512×512	43,27	40,50	16,23
7.	Toys	576×384	83,81	13,30	2,90
8.	Tulip	640×480	61,56	29,06	9,37
Wartości średnie			**59,54**	**27,53**	**12,93**

Wyznaczono skupienie energii jako udział wariancji pojedynczej składowej w sumie wariancji składowych obrazu. Wyniki dla składowych RGB zebrano w tabeli 1, a dla składowych $K_1K_2K_3$ w tabeli 2. Wyniki w tabelach zasadniczo potwierdzają zjawisko skupienia energii sygnału głównie w pierwszej składowej KLT. Istnieją jednak obrazy (np. obraz Parrots), dla których transformacja nie zapewnia skupienia energii w pierwszej składowej.

W przypadku wielu obrazów barwnych poddanych transformacji KLT obraz K_1 zwraca uwagę swym bardzo dobrym kontrastem. Poniżej porównano obraz K_1 z obrazem intensywnościowym I, uzyskanym jako średnia arytmetyczna 3 obrazów składowych R, G, B. Miarą jakości dla obrazów K_1 i I była miara kontrastu w postaci odchylenia standardowego δ poziomów szarości w obrazie. Przy użyciu systemu wizyjnego pozyskano ciąg obrazów barwnych (rozdzielczość przestrzenna: 320×200, rozdzielczość barwna: 24 bity) przy spadającym natężeniu oświetlenia sceny symulowanym przymykaniem przysłony obiektywu. W czasie pozyskiwania obrazów zwracano uwagę na to, aby system wizyjny pracował w swoim zakresie pracy dynamicznej [19].

a)

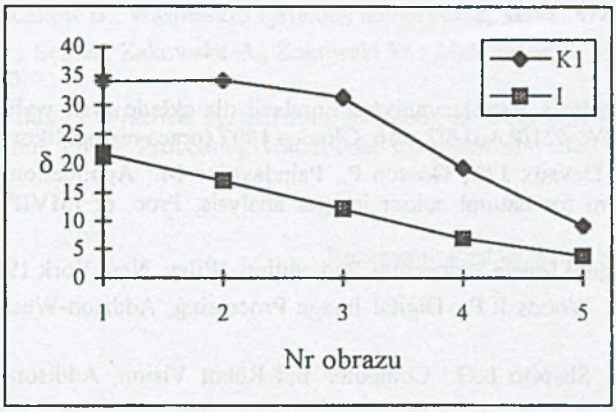

b)

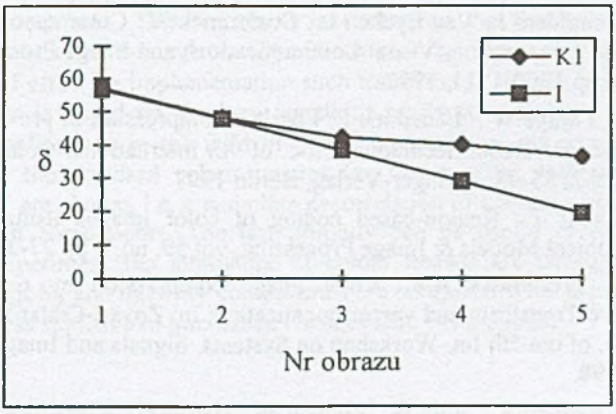

Rys.2. Wykresy zmian kontrastu wywołanych zmianą luminancji: a) poprzez ingerencję w system wizyjny, b) poprzez cyfrowe przetwarzanie pozyskanego obrazu

Fig.2. Contrast sensitivity to luminance changes a) case of modifications of vision system, b) case of digital image processing

6. Podsumowanie

W kontekście coraz liczniejszych zastosowań KLT w przetwarzaniu obrazów barwnych (kompresja, segmentacja) dużego znaczenia nabiera efektywność implementacji tej transformacji. Przeprowadzone doświadczenia na standardowych obrazach barwnych potwierdzają zasadnicze właściwości transformacji K-L: dekorelację składowych barwnych i skupienie energii obrazu w pierwszych składowych. Zwrócono uwagę na mniejszą wrażliwość składowej K_1 w stosunku do składowej intensywnościowej I ze względu na zmiany luminancji obrazu.

LITERATURA

1. Bereska D.: Badania współczynników korelacji dla składowych wybranych przestrzeni barw, Raport BW-421/RAu1/97, t.16, Gliwice 1997 (praca nie publikowana).
2. Kouassi R.K., Devaux J.C., Gouton P., Paindavoine M.: Application of the Karhunen-Loeve transform for natural colour images analysis, Proc. of IMVIP'97, University of Ulster, 1997.
3. Pratt W.K.: Digital Image Processing, 2nd edition, Wiley, New York 1991.
4. Gonzalez R.C., Woods R.E.: Digital Image Processing, Addison-Wesley, Reading, MA, 1992.
5. Haralick R.M., Shapiro L.G.: Computer and Robot Vision, Addison-Wesley, Reading, MA, 1993.
6. Pratt W.K.: Spatial transform coding of color images. IEEE Transactions on Communication Technology, vol.COM-19, no.6, 980-992, 1971.
7. Deknuydt B., Smolders J., Van Eycken L., Oosterlinck A.: Color space choice for nearly reversible image compression, Visual Communications and Image Processing'92, Proc. of SPIE vol.1818, pp.1300-1311, 1992.
8. Van Assche S., Philips W., Lemahieu I.: Lossless compression of pre-press images using a novel colour decorrelation technique, Proc. of 9th International Conference, ICIAP '97 Proceedings, vol.2, 85-92, Springer-Verlag, Berlin 1997.
9. Carevic D., Caelli T.: Region-based coding of color images using Karhunen-Loeve transform, Graphical Models & Image Processing, vol.59, no.1, pp.27-38, Jan. 1997.
10. Cavagnino D., Werbrouck A.E.: Color image compression by means of separable Karhunen Loeve Transform and vector quantization, in: Zovko-Cihlar B., Grgic S., Grgic M., /eds./, Proc. of the 5th Int. Workshop on Systems, Signals and Image Processing, 235-238, Zagreb 1998.
11. Schindewolf T., Albert R., Stolz W., Abmayr W., Harms H.: Klassifikation melanozytärer Hautveränderungen anhand makroskopischer Farbaufnahmen, In: Pöppel, S. J., Handels, H. (Hrsg.): Mustererkennung 1993, pp.436-443, Springer-Verlag, Berlin 1993.

12. Umbaugh S.E., Moss R.H., Stoecker W.V., Hance G.A.: Automatic color segmentation algorithms with applications to skin tumor feature identification, IEEE Eng. in Med. and Biol., pp.75-82, September 1993.
13. Fischer S., Schmid Ph., Guillod J.: Analysis of skin lesions with pigmented networks, Proc. of 3rd IEEE International Conference on Image Processing, vol.1, pp.323-6, Lausanne 1996.
14. Schmid Ph., Fischer S.: Colour segmentation for the analysis of pigmented skin lessions, Proc. of 6th IEE Int. Conf. on Image Processing and Appl., Dublin 1997.
15. De Smet P., Pires R., De Vleeschauwer D.: The activity image in image enhancement and segmentation, Proc. of IEEE Benelux Signal Processing Chapter Signal Processing Symposium, Leuven 1998.
16. Bayik T., Akarun L.: Color edge detection using vector order statistic filters, Proceedings of Summer School on Morphological Image and Signal Processing, pp.1-5, Zakopane 1995.
17. Fortuna Z., Macukow B., Wąsowski J.: Metody numeryczne, WNT, Warszawa 1998.
18. Empacher A.B., Sęp Z., Żakowska A., Żakowski W.: Mały słownik matematyczny, WP, Warszawa 1970.
19. Connolly C., Palus H.: Practical system considerations, in: Sangwine S.J., Horne R.E.N., /eds/, The Colour Image Processing Handbook, Chapman and Hall, 129-146, London 1998.

Recenzent: Prof.dr hab.inż. K.Wojciechowski

Abstract

The growing interest in colour image processing and poor knowledge of colour science achievements imply the need of research on colour spaces and their transformations used in image processing systems. It is possible to find a linear transform removes correlation between RGB components. This transform is known as the Karhunen-Loeve transform (KLT). The KLT needs however calculating of transform matrix for each image separately. In the paper details of effective implementation such transform of colour images are described. Proposed algorithm is based on Cardano equations or iterative Krylov method. The short review of KLT applications in the field of image compression and image segmentation is presented. Using the standard colour images (e.g. Lena, Girl, Baboon etc.), principal properties of KLT are shown, i.e. a complete decorrelation of colour components and energy compaction in first components. The last property can be useful in image segmentation process. In the experiment the luminance of colour images are changed and contrast of principal component K_1 and intensity component I are compared. This experiment shown that K_1 component is less sensitive to luminance changes than I component.