

Techniki klasteryzacyjne KM i KHM w przetwarzaniu cyfrowych obrazów barwnych

KM and KHM Clustering Techniques in Digital Color Image Processing

Mariusz Frąckiewicz, *Politechnika Śląska*
(26.05.2009, dr hab. inż. Henryk Palus, *Politechnika Śląska*)

Abstract

This paper shows examples of the clustering techniques KM and KHM in digital color image processing. These techniques have been used for operations such as quantization and segmentation of digital color images, which are a very important stage of image processing in vision systems. The study was conducted on a comprehensive, numbering 300 items, a set of test images. Obtained results confirm large usefulness of clustering techniques in the field of image processing compared to other known algorithms.

Streszczenie

Niniejszy praca pokazuje przykładowe zastosowanie technik klasteryzacyjnych KM i KHM w przetwarzaniu obrazów barwnych. Techniki te zostały wykorzystane do operacji takich jak: kwantyzacja barwy i segmentacja obrazów, które stanowią bardzo ważny etap przetwarzania obrazu w systemach wizyjnych. Pokazano związek pomiędzy liczbą barw w obrazie a błędem kwantyzacji. Badania prowadzono na obszernym, liczącym 300 elementów, zbiorze obrazów testowych. Uzyskane wyniki potwierdzają dużą przydatność technik klasteryzacyjnych w dziedzinie przetwarzania obrazu na tle innych znanych algorytmów.

1. Wiadomości wstępne

Techniki grupowania danych (klasteryzacji) mają bardzo szeroki zakres zastosowań. Mogą one być wykorzystywane w procesach takich jak np. grupowanie zadań, ekstrakcja informacji, eksploracja danych oraz również w cyfrowym przetwarzaniu obrazów barwnych. Piksele składowe obrazu cyfrowego, w procesie grupowania, przypisywane są do poszczególnych klasterek. Elementy jednego klastra są do siebie bardziej podobne ze względu na pewne kryteria podobieństwa np. ich barwę, położenie w obrazie itp.

Obraz cyfrowy jest uporządkowanym zbiorem pikseli opisanych zazwyczaj za pomocą trzech składowych barwy. Różne kombinacje tych składowych definiują konkretne barwy. Barwy w obrazach naturalnych tworzą grupy (skupienia, klastery) w trójwymiarowej przestrzeni barw.

Grupowanie w obrazie barwnym to proces nienadzorowanej klasyfikacji setek tysięcy lub milionów pikseli na podstawie podobieństwa ich barwy. Rozdzielczość obrazu decyduje o liczbie pikseli poddawanych grupowaniu a ich składowe opisujące (najczęściej RGB) są cechami decydującymi o przynależności do klasterek.

Zasadniczą wadą najpopularniejszej techniki grupowania k -średnich (ang. *k-means*) [1,2] jest zależność uzyskanego wyniku od inicjalizacji procesu grupowania, na którą składa się określenie liczby klasterek k , zadanie początkowych środków klasterek i kryterium stopu. W celu określenia liczby klasterek można korzystać, albo z wiedzy a priori o obrazie, albo z analizy histogramu obrazu, albo z wielokrotnego grupowania z różnymi wartościami k . Głównym problemem inicjalizacji jest jednak sposób zadania początkowych środków klasterek. W większości opisywanych w literaturze zastosowań technik KM proponowany jest losowy wybór środków klasterek; np. dla obrazów w postaci losowania współrzędnych pikseli w obrazie. Wynik losowania ma więc decydujący wpływ na ilość iteracji w procesie KM i uzyskaną jakość grupowania. Niektóre sposoby inicjalizacji KM prowadzą do tworzenia pustych klasterek. Technika KM jest w dalszym ciągu badana i poddawana modyfikacjom, aby usunąć jej wady.

W latach 1999-2000 Bin Zhang zaproponował technikę k -średnich harmonicznych (ang. *k-harmonic means*, KHM) [3,4]. Technika ta, będąca rozwinięciem KM, minimalizuje funkcję celu wykorzystującą średnią harmoniczną odległości punktów od środków klasterek.

1.1 Kwantyzacja barwy

Kwantyzacja barwy [5,6] jest procesem redukcji liczby barw w obrazie połączonym z zachowaniem maksymalnego podobieństwa pomiędzy oryginałem a obrazem kwantowanym. Jest to zagadnienie które powstało w wyniku ograniczeń technologicznych występujących w urządzeniach pozyskujących, drukujących i wyświetlających cyfrowe obrazy barwne. Kluczowym problemem w procesie kwantyzacji jest poszukiwanie optymalnej palety barw, która zostanie użyta do prezentacji wyniku – obrazu po kwantyzacji (stała paleta, arbitralna, adaptacyjna). Zdecydowana większość algorytmów kwantyzacji nie wykorzystuje informacji o strukturze obrazu. Kwantyzacja może być traktowana jako problem grupowania (klasteryzacji) pikseli – poszukujemy klasterów, które najlepiej reprezentują barwy obrazu. W takich procesach liczba klasterów k utożsamiana jest z liczbą barw jaką chcemy jaką chcemy osiągnąć w obrazie po kwantyzacji. Zwykle $k=2^n$, gdzie $n=1,2,3,\dots,8$ i więcej.

Obecnie proces kwantyzacji barwy jest traktowany jako pomocnicza operacja w przetwarzaniu obrazów, widzeniu i grafice komputerowej. Jednym z przykładów zastosowań kwantyzacji barwy jest etap presegmentacji, który redukuje złożony proces segmentacji obrazu [7]. Innym przykładem jest zastosowanie kwantyzacji w procesie wstawiania znaków wodnych w obrazach barwnych (ang. *color image watermarking*) [8]. Systemy wyszukiwania obrazów w bazach danych (ang. *kontent-based image retrieval*, CBIR) wykorzystują histogramy o możliwe zredukowanych skalach barw, powstałe w wyniku kwantyzacji barwy [9].

1.2 Segmentacja obrazu

Techniki segmentacji obrazu odgrywają podstawową rolę w różnych zastosowaniach systemów wizyjnych [10,11]. Segmentacja obrazu polega na jego podziale na obszary odpowiadające obiektom lub ich częściom, znajdującym się w scenie. Od jakości segmentacji zależą rezultaty rozpoznawania i śledzenia obiektów, przeszukiwania obrazowych baz danych itd. Segmentacja obrazu w postaci nadsegmentacji (zbyt duża liczba obszarów) lub niedosegmentacji (zbyt mała liczba obszarów) pociąga za sobą błędy w dalszych etapach przetwarzania obrazu. Uniwersalna metoda segmentacji obrazu barwnego prawdopodobnie nie istnieje. Głównie spowodowane jest to tym, że cele segmentacji wyraźnie zależą od zadania, którego elementem jest proces segmentacji. Rosnące możliwości obliczeniowe sprzętu komputerowego sprawiają, że wzrasta również możliwość stosowania coraz bardziej złożonych technik segmentacji i uzupełnianie segmentacji procesami przetwarzania wstępnego i końcowego.

Wśród wielu technik segmentacji obrazu swoje miejsca zajmują również techniki wykorzystujące grupowanie pikseli takie jak *k-means*, *mean shift* i inne [12]. Spowodowało to zainteresowanie możliwością wykorzystania techniki KHM do segmentacji obrazów barwnych.

2. Idea klasteryzacji

Zakładając, że obraz barwny przedstawiony jest w trójwymiarowej przestrzeni barw oraz posiada n pikseli, otrzymujemy trój-wymiarowy wektor $X=\{x_1, \dots, x_n\}$ jako dane do klasteryzacji. Na starcie algorytmu definiowana jest liczba klasterów – k oraz ich wartości początkowe, które tworzą trój – wymiarowy wektor $C=\{c_1, \dots, c_k\}$. Definiowane są także funkcje: przynależności $m(c_k | x_i)$ (określa w jakiej proporcji dany piksel należy do klastera c_k) oraz wagi $w(x_i)$ (określa jaki udział będzie miał punkt x_i podczas obliczania nowych współrzędnych c_k w kolejnej iteracji).

Ogólna idea klasteryzacji:

1. Określenie liczby k oraz początkowych środków klasterów $C=\{c_1, \dots, c_k\}$.
2. Wyznaczenie, dla każdego piksela x_i funkcji przynależności $m(c_k | x_i)$ oraz funkcji wagi $w(x_i)$
3. Wyznaczenie nowych wartości c_k zgodnie ze wzorem:

$$c_k = \frac{\sum_{i=1}^n m(c_k | x_i) w(x_i) x_i}{\sum_{i=1}^n m(c_k | x_i) w(x_i)} \quad (1)$$

4. Sprawdzenie warunku stopu. W przypadku nie spełnienia, skok do punktu 2.

2.1 Zależności dla KM i KHM

Dla techniki KM funkcja wagi jest zawsze równa 1 (każdy piksel ma równy udział przy obliczaniu nowych środków c_k . Technika ta wykorzystuje „twardą” przynależność (2,3). Minimalizowana funkcja celu ma postać (4).

$$m(c_k | x_i) \in \{0,1\} \quad w(x_i) = 1 \quad (2)$$

$$m(c_k | x_i) = \begin{cases} 1 & \text{if } l = \arg \min_k \|x_i - c_k\|^2 \\ 0 & \text{otherwise} \end{cases} \quad (3)$$

$$KM(X, C) = \sum_{i=1}^n \min_{j \in 1..k} \|x_i - c_j\|^2 \quad (4)$$

Technika KHM używa dla poszczególnych pikseli zmiennej funkcji wagi (5) oraz „miękkiej” funkcji przynależności (6, 7). Minimalizowana funkcja celu ma postać (8). Ponadto wymagane jest zdefiniowanie dodatkowego parametru p . Autor techniki proponuje stosowanie wartości niemniejszych od 2.

$$w(x_i) = \frac{\sum_{j=1}^k \|x_i - c_j\|^{-p-2}}{\left(\sum_{j=1}^k \|x_i - c_j\|^{-p}\right)^2}, \quad p \geq 2 \quad (5)$$

$$0 \leq m(c_j | x_i) \leq 1 \quad (6)$$

$$m(c_j | x_i) = \frac{\|x_i - c_j\|^{-p-2}}{\sum_{j=1}^k \|x_i - c_j\|^{-p-2}}, \quad p \geq 2 \quad (7)$$

$$KHM(X, C) = \sum_{i=1}^n \frac{k}{\sum_{j=1}^k \frac{1}{\|x_i - c_j\|^p}} \quad (8)$$

3. Ocena uzyskanych wyników

Wyniki kwantyzacji jak i segmentacji można poddawać ocenie percepcyjnej - wizualnej. Inne podejście polega na pokazywaniu uzyskanych wyników grupie obserwatorów w celu dokonania oceny jakości i następnie wyciągnięciu wniosków opierając się na statystyce.

$$MSE = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N \left[(R_{ij} - R_{ij}^*)^2 + (G_{ij} - G_{ij}^*)^2 + (B_{ij} - B_{ij}^*)^2 \right] \quad (9)$$

$$\Delta E = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N \sqrt{(L_{ij} - L_{ij}^*)^2 + (a_{ij} - a_{ij}^*)^2 + (b_{ij} - b_{ij}^*)^2} \quad (10)$$

$$Q(I) = \frac{1}{10000(M \cdot N)} \sqrt{R} \sum_{i=1}^R \left[\frac{e_i^2}{1 + \log A_i} + \left(\frac{R(A_i)}{A_i} \right)^2 \right] \quad (11)$$

Ze względu na duży subiektywizm powyższych rozwiązań do oceny wyników kwantyzacji stosowano dodatkowo miary teorii - sygnałowe : MSE (9), PSNR (12) oraz miarę uważaną jako percepcyjną (10) ΔE . Im mniejszy wskaźnik MSE, a tym samym większy wskaźnik PSNR tym lepszy rezultat. Dodatkową miarą była strata barwności obrazu [13] w wyniku kwantyzacji (13,14) - ΔM [14]. Strata barwności obrazu ΔM jest wskaźnikiem minimalizowanym - im mniejsza strata barwności tym wynik lepszy. Ocena wyników segmentacji była dokonywana zarówno wizualnie, jak i ilościowo na podstawie empirycznej funkcji oceny [15] - $Q(I)$ (11). Wysokiej jakości wynik segmentacji powinien charakteryzować się niskim wskaźnikiem $Q(I)$.

$$PSNR = 20 \log_{10} \frac{255}{\sqrt{MSE}} \quad (12)$$

$$M = \sqrt{\sigma_{rg}^2 + \sigma_{yb}^2} + 0,3 \sqrt{\mu_{rg}^2 + \mu_{yb}^2} \quad (13)$$

$$\Delta M = |M_{orig} - M_{kwant}| \quad (14)$$

4. Eksperyment

Badania były przeprowadzane na naturalnych obrazach barwnych pochodzących z bazy danych University of Berkeley (USA) [16]. Przykładowe obrazy wybrane z tego zbioru pokazuje Rys. 1.

Dla technik KM i KHM przyjęto następujące parametry: liczba iteracji: 30, metoda inicjalizacji SD, dla KHM parametr $p = 2.7$. Parametry te wynikają z doświadczenia i wiedzy autora na temat algorytmów KM i KHM [17, 18].

Wyniki kwantyzacji uzyskane technikami klasteryzacyjnymi zostały zestawione z wynikami otrzymanymi po zastosowaniu popularnych algorytmów kwantyzacji. Przeprowadzono także badania konfrontujące jakość segmentacji technikami KM i KHM.

4.1 KM i KHM w kwantyzacji barwy

Rys. 2. przedstawia wynik kwantyzacji na 16 barw obrazu kanion (56781 unikalnych barw) po

Tab.1.

Wartości wskaźnika PSNR
PSNR index values

Img	POP	MC	Wu's	KM	KHM
a	25,08	28,48	31,54	31,87	32,02
b	21,20	28,36	31,60	32,05	32,11
c	22,39	29,89	33,43	33,61	33,77
d	26,02	28,91	31,70	32,27	31,82
e	27,57	29,85	33,18	33,44	33,84
f	27,18	29,76	32,59	32,95	32,99
avg	25,34	28,78	32,34	32,70	32,76

Tab.2.

Wartości wskaźnika ΔE
 ΔE index values

Img	POP	MC	Wu's	KM	KHM
a	8,12	6,58	4,97	4,92	4,98
b	10,77	6,12	4,75	4,47	4,45
c	7,33	6,03	4,23	4,06	4,41
d	7,64	6,37	4,71	4,67	4,88
e	8,17	6,63	4,12	4,26	4,14
f	7,08	6,43	4,10	4,14	4,19
avg	8,19	6,36	4,48	4,42	4,51

Wartości wskaźnika ΔM
 ΔM index values

Img	POP	MC	Wu's	KM	KHM
a	1,87	0,74	1,62	1,23	1,21
b	25,95	1,46	1,23	1,14	0,80
c	0,62	0,19	1,90	1,61	2,35
d	2,87	1,34	1,60	1,30	1,63
e	1,14	0,32	1,14	1,04	0,85
f	4,13	2,11	0,39	0,55	0,70
avg	6,10	1,02	1,31	1,15	1,26

Tab.3.

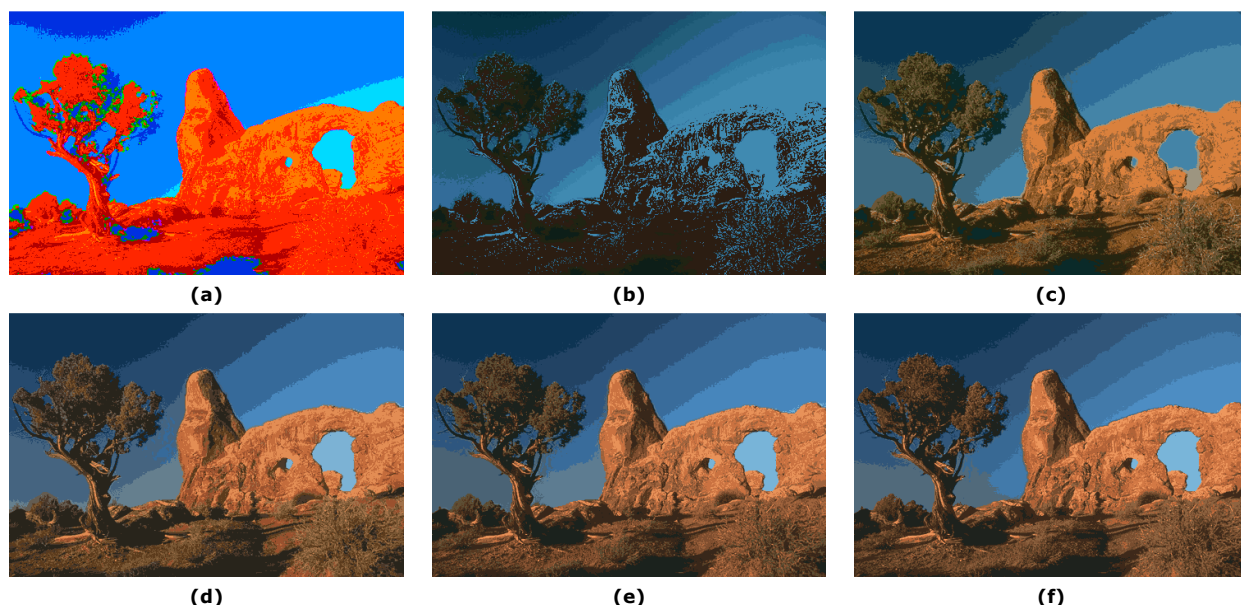
obrazów z Rys.1. po operacji kwantyzacji na 64 barwy, technika Uniform została pominięta ze względu na niskiej jakości wyniki. Maksymalizowany wskaźnik PSNR pokazuje przewagę techniki KHM nad pozostałymi algorytmami. Tylko przypadek obrazu przedstawiającego konie przemawia na korzyść techniki KM. Minimalizowany wskaźnik ΔE , przedstawiony w Tab. 2. także przemawia za technikami klasteryzacyjnymi z tym wyjątkiem że teraz w większości jest on lepszy dla techniki KM a w 2 przypadkach dla algorytmu Wu's. Tab. 3. zawiera minimalizowany wskaźnik straty barwności obrazu ΔM . Dla 3 badanych obrazów jest on minimalny dla techniki KHM co świadczy o sile tego algorytmu. Dla jednego z badanych obrazów bardzo dobry wynik osiągnięto tutaj stosując algorytm MC.

zastosowaniu znanych algorytmów kwantyzacji: Uniform, Popularity, Median cut, Wu's w zestawieniu z rezultatami uzyskanymi dzięki KM i KHM. Tab. 1. przedstawia wartość PSNR dla




Rys.1. Obrazy wybrane z bazy obrazowej [16]: (a) rozgwiazda, (b) projekt, (c) tygrys, (d) konie, (e) mnich, (f) kanion (nazwy przyjęte).

Fig.1. Image samples from image database [16]: (a) starfish, (b) project, (c) tiger, (d) horses, (e) monk, (f) canyon (names adopted) .



Rys.2. Kwantyzacja obrazu kanion: (a) Uniform, (b) Popularity, (c) Median Cut, (d) Wu's, (e) KM, (f) KHM.

Fig.2. Canyon image quantization: (a) Uniform, (b) Popularity, (c) Median Cut, (d) Wu's, (e) KM, (f) KHM.



Rys.3. Segmentacja obrazu rozgwiazda $k=3$: (a) KM, (b) KM pseudo - kolory, (c) KHM $p=2,7$, (d) KHM pseudo - kolory.

Fig.3. Starfish image segmentation $k=3$: (a) KM, (b) KM pseudo - colors, (c) KHM $p=2,7$, (d) KHM pseudo - colors.

4.2 KM i KHM w segmentacji obrazów

Rys. 3. prezentuje wynik segmentacji obrazu rozgwiazda przy zastosowaniu technik KM i KHM. Rezultat został także przedstawiony w pseudo-kolorach w celu lepszego zobrazowania przyporządkowania poszczególnych pikseli do uzyskanych obiektów w wyniku segmentacji. W obu przypadkach widać że pomimo wyboru małej liczby klastrów $k=3$ wyniki charakteryzuje dość duża nadsegmentacja. Dalsza analiza takiego obrazu wymaga wykonania operacji postprocessingu. Tab. 4. przedstawia relację wskaźnika $Q(I)$ po zastosowaniu KM i KHM na obrazach z Rys. 1. Minimalizowany wskaźnik $Q(I)$ nie pokazuje w jasny sposób przewagi KHM nad KM i odwrotnie. Dla $k=6$ przewaga jest po stronie techniki KM biorąc pod uwagę wartości średnie $Q(I)$, natomiast dla $k=12$ sytuacja się odwraca.

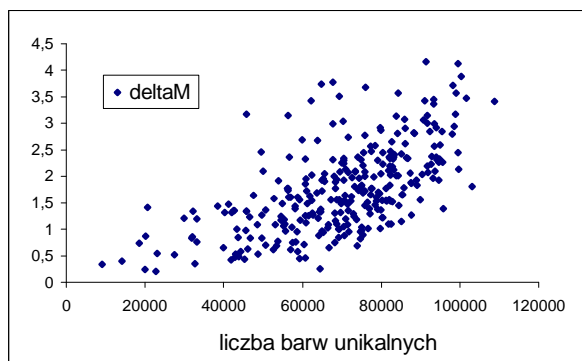
Tab.4.

Wartości wskaźnika $Q(I)$
 $Q(I)$ index values

img	$k=6$		$k=12$	
	KM	KHM	KM	KHM
a	387	417	15707	16635
b	1305	1195	25230	20687
c	18692	11914	375512	380234
d	57562	67842	187608	238484
e	11850	3635	89007	88033
f	692	719	31872	27890
avg	15081	14287	120823	128661

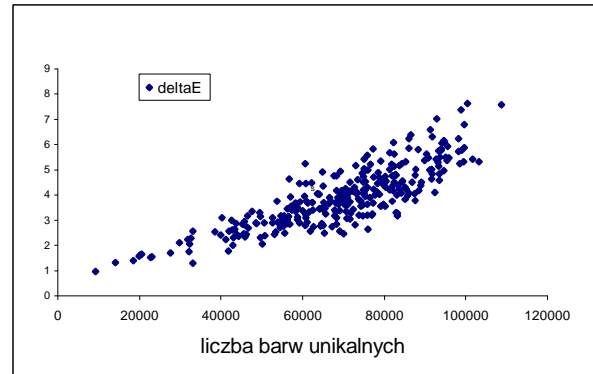
4.3 Liczba barw i błąd kwantyzacji

Każdy cyfrowy obraz barwny charakteryzuje się liczbą unikalnych barw.



Rys.4. Liczba barw i strata barwności ΔM .

Fig.4. Unique colors number and loss of colorfulness ΔM .



Rys.5. Liczba barw i błąd kwantyzacji ΔE .

Fig.5. Unique colors number and quantization error ΔE .

Dysponując zbiorem 300 naturalnych obrazów barwnych zbadano relację pomiędzy liczbą unikalnych barw w obrazie a stratą barwności i błędem ΔE w procesie kwantyzacji. Rys. 4. i Rys. 5. pokazują odpowiednio zależności pomiędzy liczbą unikalnych barw w obrazie a wskaźnikami ΔE i ΔM . Kwantyzacja była przeprowadzana techniką KM na całym 300 elementowym zbiorze obrazów, liczba klastrów $k=32$. Współczynnik korelacji pomiędzy liczbą unikalnych barw a błędem ΔE wyniósł 0,85, natomiast ten sam współczynnik dla wskaźnika ΔM był na poziomie 0.62. Tym samym można stwierdzić że, błąd kwantyzacji jest tym większy im więcej unikalnych barw posiada obraz przed procesem kwantyzacji.

5. Ocena uzyskanych wyników

Techniki klasteryzacyjne mogą być z powodzeniem wykorzystywane w operacjach przetwarzania obrazów cyfrowych. Uzyskiwane wyniki kwantyzacji są na bardzo wysokim poziomie, nie gorszym od znanych algorytmów takich jak np. Wu's. Patrząc z punktu widzenia wskaźnika PSNR wyniki kwantyzacji uzyskanych techniką KHM są wręcz najlepsze. Technika KHM jest znacznie bardziej złożona obliczeniowo, co wpływa na czas przetwarzania obrazu. Z pomocą przychodzą tutaj współczesne rozwiązania wieloprocesorowe i programowanie wielowątkowe. Wyniki segmentacji wybranych sześciu obrazów nie pokazują przewagi KHM nad KM i odwrotnie. Liczba unikalnych barw w obrazie poddawany kwantyzacji ma silny wpływ na błąd wyniku kwantyzacji.

5. Conclusion

Clustering techniques can be successfully used in digital image processing operations. Quantization results obtained are very high, no worse than the well known algorithms, such as Wu's. Looking from the perspective of the PSNR quantization index results obtained from KHM technique are almost the best. KHM technique is much more computationally complex, which affects the image processing time. Modern hardware solutions and multithreaded programming come here with help. The results of segmentation selected six images do not show superiority KHM over KM and vice versa. Number of unique colors in the image quantization has a strong influence on the result of the quantization error.

Literatura

1. Mac Queen, J.: Some methods for classification and analysis of multivariate observations, In Le Cam L.M, Neyman J., (Eds), Proceedings of the Fifth Berkeley Symposium on Mathematics, Statistics, and Probabilities: vol. 1, 281-297, University of California Press, Berkeley and Los Angeles 1967.
2. Anderberg, M.: Cluster Analysis for Applications, Academic Press, New York 1973.
3. Zhang, B., Hsu, M., Dayal, U.: K-harmonic means – data clustering algorithm, Technical Report HPL-1999-124, Hewlett-Packard Labs, Palo Alto 1999.
4. Zhang, B.: Generalized k-harmonic means – boosting in unsupervised learning, Technical Report HPL-2000-137, Hewlett-Packard Labs, Palo Alto 2000.
5. Domański M., Bartkowiak M.: Compression, In Sangwine S.J., Horne R.E.N (Eds), Color Image Processing Handbook, 242-304, Chapman and Hall, London 1998.
6. Brun L., Tremeau A.: Color quantization, In G. Sharma (Ed.), Digital Color Imaging Handbook, 589-637, CRC, Boca Raton 2003.
7. Deng Y.N., Manjunath B.S.: Unsupervised segmentation of color-texture regions in images and video, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol.23, no.8, 800-810, 2001.
8. Tsai P., Hu Y.C., Chang C.C.: A color image watermarking scheme based on color quantization, Signal Processing, vol.84, no.1, 95-106, 2004
9. Wang J., Yang W., Acharya R.: Color clustering techniques for color-content-based image retrieval from image databases, Proc. of IEEE Int. Conf. on Multimedia Computing and Systems, 442-449, Ottawa 1997.
10. Cheng H.D., Jiang X.H., Sun Y., Wang J.: Color image segmentation: advances and prospects, Pattern Recognition, vol. 34, 2259-2281, 2001.
11. Palus H.: Color image segmentation: selected techniques, In Lukac R., Plataniotis K.N., (Eds.), Color image processing: methods and applications, 103-128, CRC Press, Boca Raton 2006.
12. Turi R.H.: Clustering-based color image segmentation, Ph.D. Thesis, Monash University, Australia, 2001.
13. Hasler D., Suesstrunk S.: Measuring colorfulness for natural images, Proc. IS&T/SPIE Electronic Imaging: Human Vision and Electronic Imaging VIII, SPIE vol. 5007, 87-95, 2003.
14. Palus H.: Colorfulness of the image and its application in image filtering, Proc. of the 5th IEEE International Symposium on Signal Processing and Information Technology (ISSPIT' 2005), 884-889, Athens 2005.
15. Borsotti M., Campadelli P., Schettini R.: Quantitative evaluation of color image segmentation results, Pattern Recognition Letters, vol. 19, 741-747, 1998.
16. Martin, D., Fowlkes, C., Tal, D., Malik, J.: A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics. In: Proceedings of the 8th International Conference on Computer Vision, pp. 416–423. Vancouver, Canada (2001).
17. Frąckiewicz M., Palus H., KM and KHM clustering techniques for colour image quantisation, in: Joao Manuel R.S. Tavares and R. M. Natal Jorge /eds./, Computational Vision and Medical Image Processing, VipIMAGE 2009, 151-155, Taylor & Francis Group, London 2009.
18. Frąckiewicz M., Palus H., Initialization methods for clustering in colour quantization techniques, In: Tadeusiewicz R., Ligęza A., Mitkowski W., Szymkat M., /eds./, Computer Methods and Systems (CMS)'09, 469-472, Kraków 2009.

Adres służbowy Autora:



Mgr inż. Mariusz Frąckiewicz
Politechnika Śląska
ul. Akademicka 16
44-100 Gliwice
tel. (32) 237 21 19
fax (32) 237 21 19

email: Mariusz.Frackiewicz@polsl.pl