

Henryk PALUS
Politechnika Śląska

WYBRANE TECHNIKI KLASTERYZACYJNE W PRZESTRZENI BARW


Streszczenie. W pracy są rozpatrywane 3 techniki klasteryzacyjne: klasyczna k-means oraz dwie nowe (*optimal-cut*, *max quantization error*). Ich porównanie przeprowadzono na 5 obrazach scen naturalnych przy klasteryzacji na 12 i 6 klasterów i zastosowaniu 2 kryteriów: błędu kwantyzacji barwy oraz oceny jakości segmentacji obrazu. Badania potwierdziły efektywność techniki optymalnego cięcia (OpC).

SELECTED CLUSTERING TECHNIQUES IN THE COLOUR SPACE

Summary. In this paper are investigated three following clustering techniques: the classical k-means and two new techniques: the optimal-cut (OpC) and the max quantization error (MQE). The comparison presented here is based on testing of five natural color images for clustering into 12 and 6 clusters. In evaluation process two criteria were used: the colour quantization error and the image segmentation quality measure. During tests the effectivity of OpC technique has been proved.

1. Wprowadzenie

Jednym z silnie rozwijanych podejść do kwantyzacji barwy i segmentacji obrazów barwnych jest klasteryzacja (grupowanie danych) pikseli, przedstawianych jako punkty w trójwymiarowej przestrzeni barw, w oparciu o podobieństwo ich barwy.



Rys. 1. Obraz *Klocki* i klasterzy jego pikseli w przestrzeni barw RGB: a) obraz oryginalny, b) wizualizacja klasterów

Klasteryzacja jest często traktowana jako nienadzorowana klasyfikacja setek tysięcy lub milionów pikseli obrazu. W procesie tym nie jest wykorzystywana wiedza a priori o obrazie. Barwy dominujące w obrazie w sposób naturalny tworzą klaster w przestrzeni barw. Rysunek 1 pokazuje odpowiadające klasterom trzy „chmury pikseli” w przestrzeni RGB. Wiele różnych technik klasteryzacji zaproponowanych w literaturze z zakresu rozpoznawania obrazów [1] może być wykorzystanych do kwantyzacji barwy (redukcji liczby barw w obrazie) [2] lub segmentacji obrazów barwnych [3]. Obydwa te procesy stanowią istotny etap cyfrowego przetwarzania i analizy obrazów barwnych.

2. Opis badanych technik klasteryzacyjnych

Jedną z bardziej popularnych i najszybszych technik klasteryzacyjnych jest technika k-means (k-średnich). Technikę k-means zaproponowano w latach 60. [4]. Pierwszy etap wymaga określenia liczby klasterów k oraz wyboru ich początkowych środków C_i , co jest istotnym ograniczeniem tej metody:

$$C_1, C_2, \dots, C_k \text{ gdzie } C_i = [C_{Ri}, C_{Gi}, C_{Bi}], \quad i=1, 2, \dots, k \quad (1)$$

Podczas klasteryzacji każdy punkt obrazu x jest przyporządkowany do klasteru K_j , do którego środka odległość punktu jest najmniejsza. Miarą odległości może być metryka Euklidesa, metryka L1, metryka Mahalanobisa uwzględniająca korelację między składowymi itp. Warunek przynależności punktu do klasteru K_j w czasie n -tej iteracji można zapisać następująco:

$$x \in K_j(n) \Leftrightarrow \forall i = 1, 2, \dots, j-1, j+1, \dots, k, \quad \|x - C_{j(n)}\| < \|x - C_{i(n)}\| \quad (2)$$

gdzie: C_j jest środkiem klasteru K_j .

Zasadniczą ideą techniki k-means jest modyfikacja położenia środków klasterów przeprowadzana tak długo, aż suma odległości pomiędzy wszystkimi punktami klasterów a ich środkami będzie minimalna. Dla klasteru K_j minimalizowany wskaźnik J przyjmuje postać:

$$J_j = \sum_{x \in K_j(n)} \|x - C_j(n+1)\|^2 \quad (3)$$

Po alokacji punktów obliczane są składowe barwy nowych środków klasterów. Wychodząc ze wzoru (3), można zapisać składowe barwy środka klasteru K_j po $(n+1)$ iteracji jako średnie arytmetyczne składowych barwy punktów należących do tego klasteru:

$$C_{jR}(n+1) = \frac{1}{N_j(n)} \sum_{x \in K_j(n)} x_R \quad (4)$$

$$C_{jG}(n+1) = \frac{1}{N_j(n)} \sum_{x \in K_j(n)} x_G \quad (5)$$

$$C_{jB}(n+1) = \frac{1}{N_j(n)} \sum_{x \in K_j(n)} x_B \quad (6)$$

gdzie: $N_j(n)$ – liczba pikseli należących do klastery K_j w n -tej iteracji.

Ponieważ uśrednianie według wzorów (4-6) odbywa się dla wszystkich k klastery, więc stąd pochodzi nazwa metody: k -means (k -średnich). W następnym etapie sprawdzana jest różnica pomiędzy położeniem nowych i starych środków klastery. Jeżeli ta różnica jest powyżej pewnego progu δ , to w ramach następnej iteracji obliczane są odległości punktów od nowych środków klastery, zmienia się przynależność punktów itd. Jeżeli ta różnica jest poniżej pewnego progu δ , to proces klasteryzacji zostaje zatrzymany.

$$\forall i = 1, 2, \dots, k \quad \|C_{i(n+1)} - C_{i(n)}\| < \delta \quad (7)$$

Innym możliwym kryterium stopu jest wykonanie wcześniej założonej liczby iteracji. W ramach ostatniego etapu działania techniki k -means barwa każdego pikseli zostaje zastąpiona barwą odpowiadającą barwie środka klastery, do którego należy dany piksel. Tak więc liczba barw w obrazie posegmentowanym zostaje zredukowana do k barw. Algorytm k -means jest zbieżny, ale jedynie do minimum lokalnego [5]. Wyniki segmentacji metodą k -means istotnie zależą od położenia początkowych środków klastery. Te dane wejściowe najczęściej wybierane są losowo spośród barw występujących w obrazie.

W posegmentowanym obrazie piksele przyporządkowane do jednego klastery należą na ogół do wielu różnych obszarów. Im większa liczba klastery, tym więcej obszarów występuje w obrazie po segmentacji. Techniki klasteryzacyjne ze swej natury nie uwzględniają położenia poszczególnych pikseli (sąsiedztwo) w obrazie, czego skutkiem jest ich wrażliwość na szum. Stąd wynika potrzeba przetwarzania końcowego, które zmniejsza lub likwiduje nadsegmentację obrazu. Klasteryzację można przeprowadzić w przestrzeni RGB lub innej przestrzeni barw będącej wynikiem transformacji przestrzeni RGB.

Niedawno w pracy [6] opisano 2 nowe techniki klasteryzacji w przestrzeni barw: optymalnego cięcia (OpC) i maksymalnego błędu kwantyzacji (MQE). Badając 3 obrazy, pokazano również ich zdecydowaną przewagę nad 3 znanymi technikami kwantyzacji barw: *median-cut*, *octree* i *pairwise clustering*. Obydwie nowe techniki wykorzystują histogram barw, tzn. dla każdego pikseli o barwie c_i wyznaczono $H(c_i)$ liczbę pikseli w obrazie o tej barwie.

Technika OpC jest techniką podziału wygenerowanych w przestrzeni barw klastery w kształcie trójwymiarowych skrzynek (*3D boxes*) na podskrzyńki, których układ minimalizuje błąd kwantyzacji. Błąd kwantyzacji dla danej skrzyńki jest wyznaczany za pomocą następującego wzoru:

$$E_{box} = \sum_{i \in box} H(c_i) \|c_i - \bar{c}_{box}\|^2 \quad (8)$$

gdzie \bar{c}_{box} oznacza średnią barwę skrzynki obliczaną według wzoru:

$$\bar{c}_{box} = \frac{\sum_{c_i \in box} H(c_i) c_i}{\sum_{c_i \in box} H(c_i)} \quad (9)$$

Najpierw wyznacza się wyjściową skrzynkę, obejmującą wszystkie barwy występujące w obrazie I zdefiniowaną poprzez 8 wierzchołków prostopadłościanu. Zostaje ona wpisana na listę klasterów. Algorytm poszukuje optymalnego cięcia, tj. podziału skrzynki płaszczyzną równoległą do osi układu współrzędnych na 2 podskrzynki, który to podział w największym stopniu zmniejsza błąd kwantyzacji. Nowe podskrzynki po sprawdzeniu, czy nie są puste, zostają wpisane na listę klasterów itd. Proces klasteryzacji trwa do momentu uzyskania w przestrzeni barw k klasterów (skrzynek).

Technika MQE zmniejsza błąd kwantyzacji, tworząc nowe klasterzy dla barw generujących jego maksymalne wartości. Błąd kwantyzacji dla barwy c_i w obrazie wyznacza się za pomocą wzoru:

$$E_i = H(c_i) \|c_i - c_{nearest}\|^2 \quad (10)$$


gdzie przez $c_{nearest}$ rozumie się barwę klasteru najbliższego w stosunku do barwy c_i . Korzystając z danych histogramu, technika MQE najpierw znajduje w obrazie I zawierającym N barw najbardziej popularną barwę c , tj. taką, że:

$$\forall i=1, 2, \dots, N \quad H(c) \geq H(c_i) \quad (11)$$

Barwa ta zostaje wpisana na listę środków klasterów. Następnie stosując wzór (10), algorytm liczy błędy kwantyzacji dla wszystkich pozostałych barw w stosunku do barwy c . Barwa z największym błędem stanowi środek następnego klasteru itd. Proces ten trwa do momentu utworzenia w przestrzeni barw wymaganych k środków klasterów. W ostatnim etapie algorytmu każda barwa w obrazie zostaje przyporządkowana do klasteru, którego środek jest jej najbliższy.

3. Wyniki przeprowadzonych badań

Badania porównawcze opisanych powyżej technik przeprowadzono na 5 obrazach barwnych, których monochromatyczne miniatury przedstawiono na rysunku 2. Badane obrazy miały rozdzielczość 640x480 pikseli i głębię bitową 24 bity/piksel.

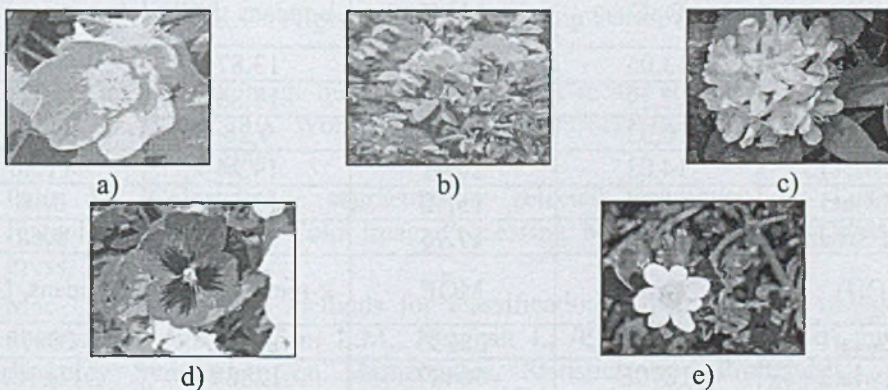


Rys 2. Testowane obrazy barwne: a) Kwiat 1, b) Kwiat 2, c) Kwiat 3, d) Kwiat 4, e) Kwiat 5

Przeprowadzono 2 serie klasteryzacji, w których generowano odpowiednio 12 (rys. 3) i 6 klasterów. Do oceny wyników zastosowano 2 kryteria oceny. Pierwsze kryterium było czysto kwantyzacyjne, tzn. średni błąd kwantyzacji barwy w przestrzeni CIELAB:

$$\Delta E = \frac{1}{MN} \sum_{j=1}^M \sum_{i=1}^N \sqrt{(L_{ij} - L_{ij}^*)^2 + (a_{ij} - a_{ij}^*)^2 + (b_{ij} - b_{ij}^*)^2} \quad (12)$$

gdzie: M , N , to wymiary obrazu, składowe L_{ij} , a_{ij} , b_{ij} oznaczają barwę piksela o współrzędnych (i, j) w obrazie wyjściowym, a ich odpowiedniki z gwiazdką dotyczą obrazu po klasteryzacji.



Rys. 3. Przykładowe wyniki klasteryzacji w przestrzeni RGB techniką OpC (wersja 12 klasterów): a) Kwiat1, b) Kwiat2, c) Kwiat3, d) Kwiat4, e) Kwiat5

Drugie kryterium dotyczyło jakości obrazu posegmentowanego w wyniku klasteryzacji. Dlatego uwzględnia ono nie tylko błąd barwy, ale i liczbę obszarów

w posegmentowanym obrazie. Borsotti i in. w pracy [7] zaproponowali empiryczną funkcję $Q(I)$ do oceny klasteryzacyjnych technik segmentacji:

$$Q(I) = \frac{1}{10000 NM} \sqrt{R \sum_{i=1}^R \left[\frac{e_i^2}{1 + \log A_i} + \left(\frac{R(A_i)}{A_i} \right)^2 \right]} \quad (13)$$

Tabela 1

Wartości kryteriów w procesie klasteryzacji na 12 klasterów

ΔE	OpC	MQE	k-means_RGB	k-means_LAB
Kwiat1	10,38	13,26	10,41	7,84
Kwiat2	9,68	11,93	9,1	7,78
Kwiat3	7,12	7,59	7,51	5,93
Kwiat4	10,53	16,01	10,55	8,07
Kwiat5	8,63	11,18	8,82	6,18
Wart. średnia	9,27	11,99	9,28	7,16
Q(I)	OpC	MQE	k-means_RGB	k-means_LAB
Kwiat1	3969	6620	6782	5984
Kwiat2	7028	23417	9472	78050
Kwiat3	19787	21716	26644	8472
Kwiat4	5776	13871	7417	15860
Kwiat5	4279	3354	16466	6741
Wart. średnia	8168	13796	13356	23021

Tabela 2

Wartości kryteriów w procesie klasteryzacji na 6 klasterów

ΔE	OpC	MQE	k-means_RGB	k-means_LAB
Kwiat1	13,05	18,49	13,87	11,13
Kwiat2	12,19	21,21	11,86	10,05
Kwiat3	10,02	14,18	9,28	7,69
Kwiat4	14,03	20,41	14,24	11,36
Kwiat5	11,76	15,52	11,08	8,16
Wart. średnia	12,21	17,96	12,07	9,68
Q(I)	OpC	MQE	k-means_RGB	k-means_LAB
Kwiat1	15872	28753	14605	25878
Kwiat2	10706	56487	12868	118161
Kwiat3	7840	35251	6794	22274
Kwiat4	22414	86680	15942	63101
Kwiat5	4325	9539	4872	6252
Wart. średnia	12231	43342	11061	47133

gdzie: I to obraz po segmentacji, M, N – wymiary tego obrazu, R – liczba obszarów w posegmentowanym obrazie, A_i – pole obszaru z indeksem i , a e_i – błąd barwy obszaru z indeksem i . Błąd barwy w przestrzeni RGB jest liczony jako suma odległości euklidesowych pomiędzy składowymi barwy pikseli obszaru i składowymi średniej barwy, która jest atrybutem obszaru w posegmentowanym obrazie.

Im mniejsze wartości obu kryteriów, tym lepsza jest kwantyzacja barwy i segmentacja obrazu. Uzyskane wartości kryteriów w 2 seriach badań zestawiono w poniższych tabelach. Technikę k-means stosowano w 2 wersjach: w przestrzeni RGB i w przestrzeni LAB.

4. Wnioski

Badania porównawcze opisanych powyżej technik przeprowadzono na 5 obrazach scen naturalnych. Porównując między sobą 2 nowe techniki klasteryzacji, należy stwierdzić wyraźną przewagę techniki OpC nad techniką MQE zarówno w zakresie błędu kwantyzacji, jak i jakości segmentacji. Odnosząc wyniki techniki optymalnego cięcia do k-means można zauważyć podobne wartości obu kryteriów dla OpC i k-means w RGB. Natomiast k-means w przestrzeni LAB daje bardzo mały błąd kwantyzacji, ale jednocześnie uzyskuje słabą ocenę jakości segmentacji obrazu. Zmniejszenie liczby klasterek z 12 do 6 zgodnie z intuicją zwiększa błąd kwantyzacji barwy i jednocześnie na ogół obniża jakość segmentacji obrazu.

Jak wiadomo z literatury, dalszą poprawę wyników w zastosowaniach segmentacyjnych można osiągnąć dołączając do technik klasteryzacyjnych procedury przetwarzania końcowego, służące do łączenia przylegających do siebie w płaszczyźnie obrazu podobnych obszarów barwnych.

LITERATURA

1. Jain A.K., Dubes R.C.: Algorithms for Clustering Data. Prentice Hall, Englewood Cliffs, N.J, 1988.
2. Palus H.: On color image quantization by the k-means algorithm. In: Droege D., Paulus D., /Eds./, 10. Workshop Farbbildverarbeitung, p. 58-65, Der Andere Verlag, Toenning 2004.
3. Palus H.: Color image segmentation: selected techniques. In: Lukac R., Plataniotis K.N., /Eds./, Color Image Processing: Methods and Applications, CRC Press, 2006 /in press/.
4. 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, Berkeley and Los Angeles, University of California Press, 1967, p. 281-297.
5. Selim S.Z., Ismail M.A.: K-means-type algorithms. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol.6, no.1, 1984, p. 81-87.
6. Chen T.Q., Murphey Y.L., Karlsen L., Gerhart G., Color image segmentation in color and spatial domain. In: Chung P.W.H., Hinde C.J., Ali M., /Eds./, IEA/AEI

2003, Lecture Notes in Artificial Intelligence, vol.2718, Springer-Verlag, Heidelberg 2003, p. 72-82.

7. Borsotti M., Campadelli P., Schettini R.: Quantitative evaluation of color image segmentation results. Pattern Recognition Letters, vol.19, no.8, 1998, p. 741-747.

Recenzent: Prof. dr hab. inż. Marek Kurzyński

Abstract

Clustering is the process of partitioning a set of objects (pattern vectors) into subsets of similar objects called clusters. Pixel clustering in three-dimensional colour space on the basis of their colour similarity is one of popular approaches in the field of colour quantization and colour image segmentation. Clustering is often seen as an unsupervised classification of pixels. Colours, dominated in the image, create dense clusters in the colour space in natural way. Many different clustering techniques can be applied in colour image processing. One of the most popular and fastest clustering techniques is the k-means technique. In this paper are investigated two new clustering techniques: the optimal-cut (OpC) and the max quantization error (MQE). Both techniques are referenced to k-means technique implemented in RGB and CIELAB colour spaces. The comparison is based on testing of five natural colour images for clustering into 12 and 6 clusters. In the evaluation process two criteria were used: the colour quantization error and the image segmentation quality measure. During tests the effectivity of OpC technique has been proved. This last technique is also definitely better than the MQE clustering technique. We can observe that both used criteria are opposite in some sense: a technique with small quantization error can at the same time oversegment (split it up into too many regions) an image. In the segmented image, the pixels that belong to one cluster can belong to many different regions. The larger is the number of clusters k , the image will be segmented into more regions. The processing of pixels without taking into consideration their neighborhoods is inherent to the nature of clustering techniques. It often results in sensitivity to noise and therefore there needs to be postprocessed for the elimination of oversegmentation.