

Artur BAL

Politechnika Śląska, Instytut Automatyki

## METODA POPRAWY WYNIKÓW SEGMENTACJI OBRAZÓW ZAWIERAJĄCYCH TEKSTURY \*

**Streszczenie.** W pracy zaproponowano metodę poprawy jakości segmentacji obrazów zawierających tekstury. Proponowana metoda wykorzystuje własności segmentacji obszarowej w celu pozyskania nowej cechy, która wykorzystywana jest w procesie segmentacji obrazu. W pracy zamieszczone zostały wyniki segmentacji obrazów otrzymane bez i z zastosowaniem opisanej metody.

## METHOD FOR IMPROVEMENT OF SEGMENTATION RESULT OF IMAGES INCORPORATED TEXTURE

**Summary.** A method for the improvement of the segmentation result of images involving textures is proposed in this paper. The presented method uses properties of region based segmentation method for obtaining a new feature, which is used in the image segmentation process. The results of image segmentation which have been obtained with and without using the proposed method are also presented.

### 1. Wprowadzenie

Segmentacja obrazów należy do najważniejszych i najtrudniejszych zagadnień widzenia maszynowego. Proces ten prowadzony jest zwykle na poziomie poszczególnych pikseli, ma on jednak kluczowe znaczenie dla innych, prowadzonych na wyższym poziomie abstrakcji, zadań widzenia maszynowego, takich jak np. wyszukiwanie wzorca w obrazie,

---

\* Praca została zrealizowana w ramach projektu badawczego BW-424/RAu-1/2004/5.

wyznaczanie cech i klasyfikacja obiektów. Zależność ta jest skutkiem występowania silnego wpływu wyniku segmentacji obrazu na wynik jego analizy. W praktyce prawidłowa analiza obrazów jest możliwa tylko wówczas, gdy poprzedzająca ją segmentacja daje prawidłowe wyniki.

Segmentacja obrazu  $O$  jest zwykle rozumiana ([2, 4, 8]) jako podział zupełny tego obrazu na skończony zbiór jednorodnych i rozłącznych części nazywanych obszarami. Nadto zakłada się, że wyróżnione w obrazie obszary  $o_k$  są spójne w sensie wybranej definicji spójności (jest to najczęściej 4- lub 8-spójność). Poważnym problemem jest segmentacja obrazów zawierających tekstury (z punktu widzenia procesu segmentacji tekstura jest fragmentem obrazu o niejednorodnych cechach fotometrycznych). Metodą poprawy wyników segmentacji takich obrazów jest wykorzystanie w procesie segmentacji dodatkowych cech pozwalających wyodrębnić fragmenty obrazu zawierające teksturę.

W niniejszej pracy zaprezentowano nową cechę  $\delta_i$ , mogącą stanowić uzupełnienie cech fotometrycznych, zwykle stosowanych do opisu pikseli obrazów. Przydatność nowej cechy do segmentacji obrazów zawierających tekstury została zaprezentowana na przykładzie uniwersalnego wieloetapowego algorytmu segmentacji obrazów; został on przedstawiony w rozdziale 2. Nowa cecha  $\delta_i$  oraz transformata  $d$ -level, prowadząca do jej otrzymania, zostały przedstawione w rozdziale 3. Porównanie rezultatów segmentacji różnego typu obrazów bez i z zastosowaniem cechy  $\delta_i$  zawiera rozdział 4. W rozdziale 5 zawarto podsumowanie dotychczasowych prac oraz przedstawione zostały zagadnienia wymagające dalszych badań.

## 2. Wieloetapowa metoda segmentacji obszarowej

### 2.1. Uwagi wstępne

Na wynik segmentacji, oprócz wyboru wspomnianego już kryterium jednorodności, wpływ ma m.in. wybór metody segmentacji obrazu (można ją postrzegać jako metodę przydziału pikseli do obszarów). W literaturze (np. [2, 8]) często spotyka się podział metod segmentacji według rodzaju informacji, jaka wykorzystywana jest w procesie segmentacji. Według tego kryterium metody segmentacji dzieli się na metody: 1) pikselowe,



*ii*) krawędziowe, *iii*) obszarowe, *iv*) bazujące na modelach fizycznych, *v*) hybrydowe. Ostatnia z wymienionych grup obejmuje te rozwiązania, które nie zostały zaliczone do jednej z poprzednich klas.

Prezentowany w pracy algorytm segmentacji należy do obszarowych metod segmentacji. W przypadku tej grupy metod segmentacji decyzja o sposobie podziału obrazu na obszary podejmowana jest na podstawie własności samych obszarów — jest to podstawowa zasada wyróżniająca ten sposób realizacji zadania segmentacji obrazu. Segmentacja obrazu otrzymywana jest w wyniku wielokrotnie powtarzanego procesu dzielenia i/lub łączenia tymczasowych obszarów. W zależności od kolejności i sposobu realizacji tych operacji można wyróżnić cztery podstawowe metody realizacji idei segmentacji obszarowej. Są to: *i*) metoda rozrostu obszaru (ang. *seeded region growing*), *ii*) metoda łączenia obszarów (ang. *region merging*), *iii*) metoda podziału obszarów (ang. *region splitting*), *iv*) metoda dzielenia i łączenia obszarów (ang. *split and merge*).

Celem opracowania prezentowanego algorytmu była segmentacja obrazów na potrzeby zadania poszukiwania odpowiedniości obszarów 1, a przy pracach nad nim starano się połączyć zalety dwóch z ww. metod segmentacji, tj. metody łączenia obszarów i metody rozrostu obszaru. O ich wykorzystaniu zadecydowały własności tych metod, takie jak m.in.: spójność otrzymywanych obszarów, stosunkowo duża odporność na zakłócenia występujące w obrazach, łatwość realizacji segmentacji wieloetapowej pozwalająca na zmniejszenie złożoności obliczeniowej algorytmu poszukiwania odpowiedniości obszarów oraz ograniczona liczba intuicyjnie zrozumiałych parametrów. Uwzględnienie ww. wymagań nie spowodowało jednak ograniczenia uniwersalności opracowanego algorytmu segmentacji.

Przy opracowywaniu algorytmu zwrócono uwagę na, prawie nieobecne w literaturze, zagadnienie uniezależnienia wyniku segmentacji od orientacji obrazu. Problem ten uwidacznia się zwłaszcza w przypadku segmentacji obrazów o trudnej do określenia orientacji (np. obrazy medyczne, zdjęcia lotnicze i satelitarne) oraz w przypadku segmentacji sekwencji obrazów pozyskanych z różnych sensorów (np. obrazy stereo).

## 2.2. Opis algorytmu

W stosowanym w pracy wieloetapowym algorytmie segmentacji zadanie segmentacji realizowane jest w dwóch krokach, które są różnymi realizacjami metody segmentacji obrazu przez łączenie obszarów.

**Krok 1.** Dokonywane jest w nim łączenie w grupy pikseli, dla których zachodzi

$$\Delta(i, j) \leq d, \quad (1)$$

gdzie  $\Delta(i, j)$  jest wyznaczaną w przestrzeni cech obrazu miarą podobieństwa między sąsiadującymi ze sobą (w sensie wybranego rodzaju sąsiedztwa) pikselami  $i$  i  $j$ , wartość  $d$  jest parametrem tego kroku algorytmu. Piksele traktowane są w tym przypadku jako elementarne obszary, tzn. obszary o jednostkowej powierzchni. Sposób wyznaczania wartości  $\Delta(i, j)$  jest uzależniony od rodzaju obrazu (obraz barwny lub monochromatyczny), przestrzeni barw, w jakiej opisane są barwy (w przypadku obrazów barwnych) np. *RGB*, *HSV*, *CIELAB* oraz wybranej metryki. Proces łączenia realizowany jest równoległe dla wszystkich obszarów — efektem jest uniezależnienie wyniku tego procesu od sposobu przeglądu obrazu i tym samym jego orientacji.

**Krok 2.** W kroku tym usuwana jest nadsegmentacja uzyskana poprzez odpowiedni dobór parametru  $d$  w kroku 1 — obszary o powierzchni  $a_i \leq \bar{a}$  są łączone z innymi obszarami, jeżeli spełnione są odpowiednie warunki;  $a_i$  jest polem powierzchni  $i$ -tego obszaru, a wartość  $\bar{a}$  jest parametrem. Stosowane w tym kroku warunki łączenia obszarów dotyczą: różnicy  $\Delta$  między cechami łączonych obszarów, wielkości pól łączonych obszarów oraz ich wzajemnych relacji. Proces łączenia jest powtarzany do momentu, gdy

$$\forall_i a_i > \bar{a}. \quad (2)$$

Sposób organizacji procesu łączenia sprzyja przejściowemu tworzeniu obszarów stanowiących rodzaj zarodków segmentacji. W ten sposób segmentacja przez łączenie obszarów nabiera cech segmentacji przez rozrost obszarów.

Opisany powyżej proces łączenia obszarów jest jednoetapowy. Jego rozwinięciem jest *wieloetapowa metoda łączenia obszarów*. Polega ona na wielokrotnej realizacji opisanego powyżej procesu łączenia obszarów dla różnych wartości  $\bar{a} \in \mathbf{A} = [\bar{a}_1, \dots, \bar{a}_k, \dots, \bar{a}_K]$ , przy czym  $\forall_{k \in \{1, \dots, K-1\}} \bar{a}_k < \bar{a}_{k+1}$ . Proces łączenia obszarów powtarzany jest  $K$ -krotnie, a obraz



będący wynikiem łączenia obszarów dla wartości progu  $\bar{a} = \bar{a}_k$  jest obrazem wejściowym do łączenia obszarów dla  $\bar{a} = \bar{a}_{k+1}$ . Jak widać metoda jednoetapowa jest szczególnym przypadkiem metody wieloetapowej, dla której wektor  $A = [\bar{a}]$  jest jednoelementowy. Podobnie jak w kroku 1 łączenie obszarów w kroku 2, zarówno metodą jednoetapową jak i wieloetapową, odbywa się równoległe.

Realizacja pierwszego kroku nie jest wymagana, jednak jego wykonanie w zdecydowanej większości przeprowadzonych badań dało wynik co najmniej tak samo dobry jak w przypadku, gdy krok ten nie był wykonywany. Nierealizowanie kroku 1 algorytmu powoduje, że proces łączenia obszarów w kroku 2 prowadzony jest na obszarach elementarnych, co ma wpływ nie tylko na jakość otrzymywanych wyników, ale powoduje również wydłużenie czasu realizacji tego kroku algorytmu.

Ze względu na ograniczenia wynikające z sekwencyjnej architektury systemu komputerowego wykorzystanego do badań konieczna była odpowiednia implementacja równoległego sposobu łączenia obszarów zastosowanego w obu krokach prezentowanego algorytmu. Wymaganie to zostało zrealizowane poprzez rozdzielenie procesu podejmowania decyzji o połączeniu obszarów od procesu wprowadzania zmian w obrazie i uaktualniania danych. Każdorazowo proces łączenia obszarów przebiega w dwóch etapach: *i*) najpierw sprawdzane są wszystkie obszary obrazu pod kątem możliwości ich połączenia z siadującymi z nimi obszarami, *ii*) następnie na podstawie podjętych decyzji aktualizowane są dane oraz wprowadzane są zmiany w obrazie.

### 3. Transformata $d$ -level i wyznaczanie wartości $\delta_i$

Dobór kryteriów jednorodności obszarów zależy w znacznym stopniu od cech, jakie zostały użyte do opisu pikseli obrazu. Najprostsze kryteria jednorodności wykorzystują założenia o podobnej jasności lub barwie pikseli należących do poszczególnych obszarów. W przypadku obrazów zawierających tekstury tak proste kryteria są zwykle niewystarczające do prawidłowego przeprowadzenia segmentacji obrazu. Problemem w przypadku segmentacji tekstur jest ich olbrzymie zróżnicowanie; odzwierciedleniem tego faktu może być prezentowana w literaturze przedmiotu wielość cech służących do ich opisu ([3, 6]).

Prezentowana w pracy nowa cecha  $\delta_i$  pozwala uwzględnić w procesie segmentacji wielkość i zróżnicowanie elementów tworzących teksturę. W odróżnieniu od zwykle stosowanych metod opisu tekstur bazujących na metodach statystycznych w opracowanej metodzie wykorzystano wielokrotnie powtarzaną segmentację obrazu metodą łączenia obszarów z różnymi wartościami  $d$ ; zastosowany algorytm segmentacji jest identyczny z 1 krokiem metody segmentacji opisanej w rozdziale 2.2. Proces pozyskania wartości  $\delta_i$  jest określany w dalszej części pracy jako transformata  $d$ -level. Wartość  $i$ -tego piksela obrazu po transformacji wyznaczana jest według następującego wzoru:

$$\delta_i = \frac{1}{n} \sum_{d \in \mathbf{D}} n - a_i^d, \quad (3)$$

gdzie  $a_i^d$  jest polem powierzchni obszaru, do którego należy  $i$ -ty piksel po segmentacji obrazu z progiem  $d$ ;  $\mathbf{D}$  jest wektorem wartości progów  $d$ , dla którego wyznaczana jest wartość  $\delta_i$ ;  $n$  jest liczbą pikseli w danym obrazie. Wektor  $\mathbf{D}$  może zawierać wszystkie możliwe wartości różnic między pikselami obrazu, jednak w praktyce największa wartość  $d$  przyjmowana jest na poziomie zapewniającym zaliczenie prawie wszystkich pikseli obrazu do jednego obszaru. W celu zastosowania  $\delta_i$  jako cechy w procesie segmentacji przeprowadzana jest normalizacja wartości  $\delta_i$  do zakresu  $\langle 0,1 \rangle$  oraz wyrównywany jest histogram macierzy wartości  $\delta_i$  po normalizacji.

Aktualnie wartość  $\delta_i$  jest uwzględniana jedynie w drugim kroku prezentowanego algorytmu segmentacji. Wartość  $\Delta$  wyznaczana jest w tym przypadku jako średnia ważona

$$\Delta(i, j) = \frac{w_f \cdot \Delta_f(i, j) + w_{d\text{-level}} \cdot \Delta_{d\text{-level}}(i, j)}{w_f + w_{d\text{-level}}}, \quad (4)$$

gdzie  $w_f$  jest wagą różnicy cech fotometrycznych  $\Delta_f(i, j)$  między obszarami  $i$ -tym i  $j$ -tym, natomiast  $w_{d\text{-level}}$  jest wagą różnicy  $\Delta_{d\text{-level}}(i, j)$  między wartościami  $\delta_i$  i  $\delta_j$  tych obszarów. Wartość różnicy  $\Delta_{d\text{-level}}(i, j)$  wyznaczana według metryki  $L_1$

$$\Delta_{d\text{-level}}(i, j) = |\delta_i - \delta_j|. \quad (5)$$

Stosowanie średniej ważonej (3) do wyznaczania  $\Delta(i, j)$  oraz przyjęcie znormalizowanego zakresu wartości  $\Delta_f(i, j)$  zapewnia, że wartość różnicy  $\Delta(i, j) \in \langle 0,1 \rangle$ . Ułatwia to wykorzystanie tak wyznaczonych wartości różnic między obszarami np. w procesie poszukiwania odpowiedniości obszarów.



#### 4. Przykładowe wyniki

Badania wpływu wartości  $\delta_i$  na segmentację obrazów przeprowadzono dla różnego rodzaju obrazów cyfrowych. Niektóre z uzyskanych wyników prezentowane są w niniejszej pracy (rys. 1–6). Rezultaty segmentacji przedstawione są w postaci konturów obszarów a ich tło stanowią oryginalne obrazy po rozjaśnieniu; wartość  $r$  jest liczbą wyróżnionych obszarów. By ułatwić porównywanie wyników we wszystkich prezentowanych testach zastosowano jednakowe wartości wag  $w_f$  i  $w_{d-level}$ . Dla uproszczenia opisu przyjęte wartości wag reprezentuje parametr  $DL$ ; związek między  $DL$  a wartościami wag przedstawia tabela 1.

Przyjęty zestaw wartości wag  $w_f$  i  $w_{d-level}$  pozwala na stosunkowo dokładną analizę wpływu wartości  $\delta_i$  na wynik segmentacji: wartość  $DL = 0$  reprezentuje pełne uzależnienie wyniku segmentacji od wartości cech fotometrycznych; wartości  $DL \in \{1, 2\}$  odpowiadają sytuacji, gdy wynik segmentacji uzależniony jest zarówno od cech fotometrycznych jak też od wyniku transformaty  $d$ -level; dla  $DL = \infty$  realizacja drugiego kroku algorytmu zależy wyłącznie od wartości  $\delta_i$ . Dla niektórych obrazów, oprócz wpływu  $w_f$  i  $w_{d-level}$ , pokazany został także wpływ wartości wektora  $A$  na otrzymywane wyniki segmentacji.

Tabela 1

Wartość wag  $w_f$  i  $w_{d-level}$  w zależności od wartości parametru  $DL$


$DL$	0	1	2	$\infty$
$w_f$	1	1	1	0
$w_{d-level}$	0	1	2	1

#### 5. Podsumowanie

Celem prowadzonych prac badawczych było opracowanie metody poprawy jakości segmentacji obrazów zawierających tekstury w celu zastosowania jej do algorytmu segmentacji prezentowanego w rozdziale 2. Prezentowane rezultaty są wstępnymi wynikami prowadzonych w tym kierunku badań. Przy porównywaniu rezultatów, ze względu



na nie do końca potwierdzoną przydatność numerycznych funkcji oceny jakości segmentacji ([5, 7, 9]), zdecydowano się wykorzystać jedynie wizualną ocenę otrzymanych wyników.



a) Texture



b) House



c) Pentagon



d) Peppers


Rys. 1. Przykładowe obrazy testowe

Fig. 1. Examples of test images

Porównanie wyników segmentacji otrzymanych bez użycia wartości  $\delta_i$  (tzn. dla  $DL = 0$ ) z wynikami otrzymanymi z jej użyciem (tzn. dla  $DL = \{1, 2, 3\}$ ) pozwala stwierdzić poprawę otrzymanych rezultatów dzięki zastosowaniu nowej cechy. Poprawa uzyskanych rezultatów najlepiej widoczna jest na przykładzie obrazu Texture (rys. 1a, wyniki rys. 2, 3). Najlepsze rezultaty osiągnięte zostały dla  $DL = 2$ , jednak we wszystkich przypadkach, gdy w procesie segmentacji tego obrazu wykorzystano wartość  $\delta_i$ , uzyskano lepsze rozdzielenie pikseli należących do różnych tekstur niż w przypadku stosowania tylko cech fotometrycznych. Podobna zależność zachodzi również dla pozostałych obrazów (rys. 4–6). Poprawa jakości



uzyskanych wyników zauważalna jest zwłaszcza dla fragmentów obrazów utworzonych z drobnych elementów; takimi fragmentami są np. krzaki widoczne na obrazie House (rys. 1b, wyniki segmentacji tego obrazu prezentuje rys. 4) lub części budynku widoczne na obrazie Pentagon (rys. 1c, wyniki segmentacji tego obrazu przedstawia rys. 5).




Rys. 2. Porównanie wyników segmentacji obrazu Texture dla różnych wartości  $DL$ ,  $d=0,02$ ,  $A=30000$

Fig. 2. Comparison of segmentation results of Texture image for different values of  $DL$ ,  $d=0,02$ ,  $A=30000$

W przypadku prezentowanego algorytmu segmentacji oprócz określenia wartości wag  $w_f$  i  $w_{d-level}$  konieczne jest również podanie wartości progu  $d$  i wektora  $A$  (tak jak to zaznaczono w rozdziale 2.2 parametr  $A$  może być również wektorem jednoelementowym). Z przeprowadzonych do tej pory badań wynika, że wieloetapowa realizacja procesu łączenia obszarów pozwala na osiągnięcie lepszych wyników segmentacji niż ma to miejsce




w przypadku stosowania metody jednoetapowej. Co więcej, wyniki uzyskiwane w takim przypadku zwykle nie są gorsze niż w przypadku zastosowania metody jednoetapowej. Jako przykład na rys. 2 przedstawiono wyniki uzyskane dla obrazu Texture i  $A = 30000$  — jakość segmentacji jest w tym przypadku znacznie gorsza niż dla  $A = [50, \dots, 30000]$  (rys. 3). Dobór wektora  $A$  nie jest jednak zadaniem trywialnym, wydaje się jednak, że zalety stosowania wieloetapowego łączenia obszarów rekompensują tę wadę. Przykładowy wpływ doboru  $A$  na wynik segmentacji zaprezentowany został na rys. 4 i 5.



a)  $DL = 0, r = 5$



b)  $DL = 1, r = 5$



c)  $DL = 2, r = 5$




d)  $DL = \infty, r = 5$


Rys. 3. Porównanie wyników segmentacji obrazu Texture dla różnych wartości  $DL$ ,  $d = 0,02$ ,  $A = [50, \dots, 30000]$

Fig. 3. Comparison of segmentation results of Texture image for different values of  $DL$ ,  $d = 0,02$ ,  $A = [50, \dots, 30000]$



Rys. 4. Porównanie wyników segmentacji obrazu House,  $d = 0,019$ Fig. 4. Comparison of segmentation results of House image,  $d = 0,019$





Rys. 5. Porównanie wyników segmentacji obrazu Pentagon,  $d = 0,0325$

Fig. 5. Comparison of segmentation results of Pentagon image,  $d = 0,0325$



a)  $DL=0, r=15$ b)  $DL=1, r=18$ c)  $DL=2, r=18$ d)  $DL=\infty, r=17$ 

Rys. 6. Porównanie wyników segmentacji obrazu Peppers dla różnych wartości  $DL$ ,  $d=0,015$ ,  $A=[50,\dots,5000]$

Fig. 6. Comparison of segmentation results of Peppers image for different  $DL$  values,  $d=0,015$ ,  $A=[50,\dots,5000]$

Tak jak to zaznaczono na początku tego rozdziału prezentowane wyniki są wstępnymi rezultatami badań nad transformatą  $d$ -level i zastosowaniem wartości  $\delta_i$  w segmentacji obrazów. Celem kolejnych badań w tym zakresie będzie sprawdzenie wpływu na wyniki segmentacji rodzaju metryki zastosowanej w transformacie  $d$ -level oraz sposobu integracji wartości  $\delta_i$  z innymi cechami stosowanymi w procesie segmentacji. Ważnymi i nieomawianymi do tej pory cechami transformaty  $d$ -level są: mała liczba parametrów, brak ograniczeń wynikających ze stosowania ruchomego okna (co jest cechą wielu metod opisu tekstur), uniwersalność oraz możliwość łatwego wykorzystania wartości  $\delta_i$  jako kolejnej cechy w dowolnym innym algorytmie segmentacji bądź analizy obrazu. Cechy transformaty  $d$ -level sugerują możliwość wykorzystania jej również w zadaniu wyznaczania krawędzi

w obrazach oraz zadaniu wyznaczania ziaren segmentacji w segmentacji metodą rozrostu obszarów lub znaczników w metodzie segmentacji wododziałowej.

Poprawa wyników segmentacji uzyskana dzięki zastosowaniu w prezentowanym algorytmie segmentacji wieloetapowej metody łączenia obszarów w porównaniu do metody jednoetapowej skłania do dokładniejszego przebadania wpływu doboru wektora  $A$  na wynik segmentacji. Zagadnienie to ma duże znaczenie praktyczne, ponieważ zadanie usuwania nadsegmentacji — a jest to cel realizacji drugiego kroku prezentowanego algorytmu — jest spotykane w znacznej części algorytmów segmentacji 5.

## LITERATURA

1. Bal A.: Poszukiwanie odpowiedniości elementów obrazów z wykorzystaniem niedokładnej odpowiedniości grafów, Zeszyty Naukowe Politechniki Śląskiej, s. Automatyka, z. 138, Gliwice 2003
2. Cheng H. D., Jiang X. H., Sun Y., Wang J.: Color image segmentation: advances and prospects, Pattern Recognition, vol. 34, pp. 22592281, 2001
3. Chmielewski L., Kulikowski J. L., Nowakowski A. (redaktorzy tomu), Biocybernetyka i inżynieria biomedyczna 2000, tom 8, Obrazowanie biomedyczne, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2003
4. Jain R., Kasturi R., Schunck B. G.: Machine Vision, McGraw-Hill International Editions, 1995
5. Lucchese L., Mitra S. K.: Advances in color image segmentation, Proceeding of Globecom'99, vol.4, pp. 20382044, Rio de Janeiro, 1999
6. Malik J., Belongie S., Leung T., Shi J.: Contour and Texture Analysis for Image Segmentation, International Journal of Computer Vision 43(1), pp. 7–27, 2001
7. Palus H.: Region-based colour image segmentation: control parameters and evaluation function, Proc. of The 1<sup>st</sup> European Conference on Colour in Graphics, Image and Vision CGIV 2002
8. Skarbek W., Koschan A.: Colour image segmentation — a survey, Technical Report 94-32, Tech. Univ. of Berlin, October 1994
9. Zhang Y. J.: A Survey on evaluation methods for image segmentation, Pattern Recognition, vol. 29, no. 8, pp. 1335–1346, 1996



## Abstract

A method of the improvement of segmentation result of the images involving textures is proposed in this paper. An original multi-level region-based algorithm for segmentation of monochrome and colour images is also described. The experimental results of using those novel methods are presented.

The improving method of textured images segmentation uses region segmentation for obtaining a new image feature  $\delta_i$ . The  $\delta_i$  value is a result of  $d$ -level transformation which is based on image segmentation with different values of  $d$  threshold, where  $d$  is a distance in region feature space between adjacent regions. In (3) the formula for obtaining  $\delta_i$  is given;  $a_i^d$  is an area of region to which the  $i^{\text{th}}$  image pixel after segmentation with threshold  $d$  belongs,  $d \in \mathbf{D}$ . For using  $\delta_i$  feature during the image segmentation process the raw values of  $\delta_i$  are normalized to range  $[0,1]$  and the histogram equalization of  $\delta_i$  matrix is performed. For using a modified value of  $\delta_i$  with regions photometric features (4) and (5) are used.

For the image segmentation multi-level segmentation algorithm is used. The segmentation is performed in two stages. The 1<sup>st</sup> stage (not an obligatory one) performs region merging algorithm with a merging condition given in regions feature space by threshold  $d$  — the result of this stage is an oversegmented image. This oversegmentation is removed in the 2<sup>nd</sup> stage of the presented algorithm. In this stage the region merging algorithm is used for merging all regions with area  $a_i \leq \bar{a}$ , where  $\bar{a} \in \mathbf{A}$ . If  $\mathbf{A}$  is given by a vector then multi-level region merging is performed. There is a possibility of performing 2<sup>nd</sup> stage with a scalar value of  $\mathbf{A}$ , but the results obtained in this case are worse in comparison to the results from the multi-level method. Results obtained using different  $\mathbf{A}$  values are presented at Fig. 2–Fig. 6. In both stages the parallel region merging technique is used for obtaining the image orientation (pixel order) independent segmentation results.