

Jakub SMOŁKA
Maria SKUBLEWSKA-PASZKOWSKA

PORÓWNANIE FUNKCJI OCENY SEGMENTACJI W KONTEKŚCIE METODY REDUKCJI NADSEGMENTACJI OBRAZÓW BARWNYCH

STRESZCZENIE *Artykuł dotyczy jednego z problemów transformacji wododziałowej, jakim jest nadmierna segmentacja (nadsegmentacja) obrazów. Przedstawia on porównanie funkcji oceny segmentacji, które były wykorzystywane do określenia jakości wyniku redukcji nadsegmentacji w obrazach poddanych działaniu transformacji wododziałowej. Przedstawiono krótko zaproponowaną wcześniej, a opartą na analizie skupień, metodę redukcji nadsegmentacji oraz scharakteryzowano zastosowane funkcje oceny. Dzięki wspomnianym funkcjom możliwy jest półautomatyczny wybór liczby klas w końcowej segmentacji. Wyniki porównania funkcji omówiono i zilustrowano za pomocą wykresów oraz przykładowych segmentacji obrazów testowych.*

Słowa kluczowe: *transformacja wododziałowa, analiza skupień, ocena segmentacji, porównanie*

dr inż. Jakub SMOŁKA
e-mail: jakub.smolka@pollub.pl

dr inż. Maria SKUBLEWSKA-PASZKOWSKA
e-mail: maria.paszowska@pollub.pl

Instytut Informatyki
Wydział Elektrotechniki i Informatyki
Politechnika Lubelska

1. WSTĘP

W przypadku większości obrazów transformacja wododziałowa prowadzi do nadsegmentacji. Jest to zjawisko polegające na tym, że w wyniku segmentacji obrazu liczba klas znacząco przewyższa liczbę jego rzeczywistych obiektów. W [19] zaproponowano metodę redukcji nadsegmentacji, w której wykorzystano hierarchiczne metody analizy skupień [13]. Ze względu na właściwości wspomnianych metod możliwe jest dostosowanie algorytmu redukcji nadsegmentacji (w pewnym zakresie) do różnych zadań. Po przeprowadzeniu procesu klasteryzacji, algorytm wymaga ustalenia poziomu, na którym zostanie przecięta otrzymana hierarchia podobieństwa. Umożliwia to uzyskanie segmentacji o zadanej z góry liczbie klas. Czasami jednak liczba klas nie jest znana/dokładnie znana. Warto wtedy wykorzystać funkcje oceny jakości segmentacji, których można użyć przy wyborze ostatecznego poziomu lub do wyznaczenia sugerowanych poziomów podziału hierarchii podobieństwa. Poniżej przedstawiono porównanie trzech wybranych funkcji oceny jakości segmentacji zastosowanych do realizacji wyżej wymienionego celu.

2. METODA REDUKCJI NADSEGMENTACJI

Istnieje wiele metod redukcji nadsegmentacji. Najbardziej popularną metodą jest przetwarzanie wstępne. Zazwyczaj jego celem jest zmniejszenie liczby minimów lokalnych w obrazie gradientowym. Może ono polegać na przetwarzaniu obrazu oryginalnego lub gradientowego i wykorzystywać filtry morfologiczne [2, 3], selektywne filtry rozmywające [8, 16], progowanie [8, 9]. Dodatkowo przed wykonaniem transformacji wododziałowej mogą być wybierane markery [1, 7].

Inną bardzo popularną grupą metod redukcji nadsegmentacji jest wykorzystanie grafu regionów (ang. region adjacency graphs). Zazwyczaj metody te polegają na łączeniu sąsiadujących regionów na podstawie ich średnich [8, 16]. Innym rozwiązaniem, jest stosowanie algorytmów rozrostu regionu na grafach [17, 22] czy ponowne wykonanie transformacji wododziałowej [23, 24].

Nowszym podejściem do redukcji nadsegmentacji jest analiza wielo-rodzielcza. Proponowane rozwiązania polegają najczęściej na projekcji minimów obrazu gradientowego [7, 15] lub wyników transformacji wododziałowej na obraz o wysokiej rozdzielczości [11, 21].

Wreszcie do redukcji nadsegmentacji można zaadaptować inne algorytmy takie jak optymalne progowanie [18] lub aktywne kontury [5, 26].

Metody wymienione powyżej są projektowane z myślą o konkretnym zadaniu lub tak aby były uniwersalne. Metod pierwszego rodzaju nie można łatwo dostosować do innych zadań, a metody uniwersalne nie zawsze dają najlepsze wyniki. Z tego względu, jak wspomniano wyżej, autorzy zaproponowali metodę redukcji nadsegmentacji wykorzystującą analizę skupień [19]. Zlewiska (działy wodne, obszary), które powstają w wyniku transformacji wododziałowej są traktowane jak obiekty analizy skupień.

Każdy obiekt (każde zlewisko) może być opisany za pomocą wektora atrybutów. Autorzy zaimplementowali następujące atrybuty [20]: (1) średnią, (2) odchylenie standardowe, (3) wariancję, (4) rozmiar zlewiska, (5) rozrzut wartości, (7) minimalną wartość w zlewisku, (8) maksymalną wartość w zlewisku. Należy dodać, że w przypadku obrazów barwnych wartości poszczególnych atrybutów były obliczane dla każdej składowej barwnej osobno (np. trzy osobne średnie - po jednej dla składowej R, G i B).

Poszczególne atrybuty w wektorze mogą znacząco różnić się rzędem wielkości. Aby zapobiec sytuacji, w której jeden atrybut będzie dominujący, opcjonalnym krokiem analizy skupień jest standaryzacja [13]. Zaimplementowano następujące cztery metody skalowania każdego z atrybutów: (1) skalowanie w taki sposób, aby wartości należały do przedziału [0;1], przy czym wartość maksymalna zawsze odpowiada jedności, (2) skalowanie w taki sposób, aby wartości należały do przedziału [0;1], przy czym wartość minimalna zawsze odpowiada zeru a maksymalna jedności, (3) skalowanie w taki sposób, aby suma jego wartości wynosiła 1, (4) skalowanie w taki sposób, aby jego średnia wartość wynosiła 0, a odchylenie standardowe 1. Należy dodać, że w przypadku obrazów barwnych, mimo że wartości atrybutów obliczano osobno dla każdej składowej (np. trzy średnie), to skalowano je razem (efektywnie traktowano jak jeden atrybut obiektu – czyli np. jedną średnią). Miało to zapobiegać zniekształcaniu informacji o barwie.

Na podstawie wartości atrybutów wyznaczana jest macierz odległości między obiektami. Do wyznaczenia tej macierzy służą miary odległości lub współczynniki podobieństwa. Zaimplementowano następujące miary/ współczynniki [13]: (1) odległość euklidesową, (2) średnią odległość euklidesową, (3) współczynnik różnicy kształtu, (4) współczynnik kosinusowy, (5) współczynnik korelacji, (6) metrykę Canberry oraz (7) współczynnik Bray'a-Curtisa. Aby uprościć implementację wykorzystano wyłącznie miarę odległości. Wymienione powyżej współczynniki podobieństwa (współczynnik kosinusowy, współczynnik korelacji) przekształcono w miary odległości za pomocą następującej zależności: $d = \frac{1-s}{2}$; gdzie d – to miara odległości a s to miara podobieństwa.

W trakcie procesu klasteryzacji macierz odległości jest modyfikowana. Wspomniana modyfikacja polega na połączeniu dwóch klastrów w jeden. Wymaga to obliczenia odległości nowego klastra od wszystkich pozostałych. Służą do tego metody grupowania. Zaimplementowano następujące metody [13]: (1) pojedynczego wiązania (ang. single linkage – SLINK), (2) średniego wiązania (ang. unweighted pair-group method using arithmetic averages – UPGMA), (3) pełnego wiązania (ang. complete linkage – CLINK). Dodatkowo zaimplementowano metodę minimalnej wariancji Warda [6, 13], w której nie korzysta się z macierzy odległości.

Warto zauważyć, że modularność hierarchicznych metod analizy skupień umożliwia łatwe rozszerzenie opisywanego rozwiązania o nowe współczynniki czy metody klasteryzacji pozwalające na dostosowanie jej do konkretnego zadania.

Wynikiem działania algorytmu jest hierarchia podobieństwa, w której zarejestrowane są wszystkie wykonane połączenia klastrów. Aby uzyskać ostateczny podział, należy dokonać „przecięcia” hierarchii na dwie części. Aby uzyskać ostateczną segmentację, należy wykonać połączenia zlewisk/klastrów zlewisk w kolejności od rozpoczęcia klasteryzacji do momentu wyznaczonego poziomem przecięcia hierarchii. Końcowe połączenia są odrzucane. Wybór poziomu określa liczbę klas. Może zostać on wybrany ręcznie lub z pomocą funkcji oceny segmentacji prezentowanych w niniejszym artykule. Takie podejście umożliwia tworzenie segmentacji z zadaną liczbą klas lub automatyczny/pół-automatyczny dobór optymalnej ich liczby.

Formalny opis procesu redukcji nadsegmentacji przedstawia się następująco:

1. Określone są parametry klasteryzacji: zestaw atrybutów zlewiska, metoda grupowania, miara odległości oraz metoda standaryzacji atrybutów.
2. Obliczane są wartości atrybutów zlewisk.
3. Opcjonalnie wartości są standaryzowane.
4. Budowana jest macierz odległości klastrów (początkowo każdy klastery składa się z jednego zlewiska) z wykorzystaniem wybranej miary odległości.
5. Algorytm wybiera dwa najbardziej podobne klastry i łączy je w jeden.
6. Macierz odległości jest aktualizowana zgodnie z wybraną metodą grupowania.
7. Do hierarchii podobieństwa (drzewa podobieństwa) dodawany jest nowy węzeł.
8. W przypadku, gdy nie wszystkie obiekty znajdują się w jednym klastrze, algorytm wraca do punktu 5-go.
9. Algorytm generuje segmentacje, które zawierają liczbę klas z przedziału będącego parametrem metody.
10. Segmentacja powstaje poprzez przecięcie hierarchii podobieństwa na poziomie powodującym uzyskanie określonej liczby klas i wykonanie wszystkich połączeń klastrów w dolnej części drzewa.

11. Otrzymane segmentacje oceniane są za pomocą wybranej funkcji oceny.
12. Wybierana jest najlepsza segmentacja.

3. FUNKCJE OCENY JAKOŚCI SEGMENTACJI

W niniejszym porównaniu funkcji oceny jakości segmentacji wykorzystano trzy wybrane funkcje mające zastosowanie w przypadku segmentacji obrazów barwnych. Na wstępie trzeba zauważyć, że w przypadku wszystkich omawianych funkcji mniejsza wartość oznacza lepszą segmentację.

Pierwszą z nich jest funkcja F zaproponowana przez Liu i Yang [12]. Ma ona postać:

$$F(I) = \sqrt{n_c} \cdot \sum_{i=1}^{n_c} \frac{e_i^2}{\sqrt{A_i}} \quad (1)$$

gdzie:

- I – obraz,
- n_c – liczba klas w segmentacji,
- A_i – pole i -tej klasy,
- e_i – błąd barwy i -tej klasy.

Przy czym [27]:

$$e_i = \sum_{x \in R_i} \sqrt{\sum_{s \in S} (I_s(x) - \bar{I}_{sR_i})^2} \quad (2)$$

gdzie:

- S – zbiór wszystkich składowych barwnych obrazu,
- R_i – i -ta klasa,
- I_s – składowa barwna s obrazu oryginalnego,
- \bar{I}_{sR_i} – średnia wartość składowej barwnej s pikseli w klasie R_i .

Na wartość funkcji oceny F mają wpływ dwa czynniki. Pierwszy czynnik tzn. $\sqrt{n_c}$ jest globalnym współczynnikiem kary, który zapewnia przyznanie gorszej oceny segmentacjom ze zbyt dużą liczbą klas. Drugi czynnik, czyli $\sum_{i=1}^{n_c} \frac{e_i^2}{\sqrt{A_i}}$, ma charakter lokalny, ponieważ odnosi się do poszczególnych klas.

Klasy, które posiadają duży błąd barwy e_i , podobnie jak klasy o niewielkim polu powierzchni A_i powodują zwiększenie wartości F , a więc pogorszenie oceny. Czasami wartość funkcji jest normalizowana za pomocą czynnika $\frac{1}{1000 \cdot N \cdot M}$, który uwzględnia rozmiary (N i M) obrazu. Funkcja F ma jedną istotną wadę – w przypadku segmentacji, w której znajduje się bardzo dużo małych klas – wysoki czynnik kary $\sqrt{n_c}$ nie ma znaczenia lub ma niewielkie znaczenie, ponieważ sumaryczny błąd barwy będzie bliski zeru. W skrajnym przypadku, gdy każdy piksel obrazu stanowi osobną klasę, wartość błędu i co za tym idzie wartość funkcji F wynosi 0, a to oznacza idealną segmentację.

M. Borsotti, P. Campadelli oraz R. Schettini [4] opracowali dwie kolejne funkcje, które miały dawać wartości lepiej odpowiadające ocenie jakości segmentacji wystawionej przez człowieka. Pierwszą zaproponowaną przez nich funkcją jest funkcja F' . Ma ona postać:

$$F'(I) = \frac{1}{10^4 \cdot M \cdot N} \sqrt{\sum_{a=1}^{A_{\max}} [r(a)]^{1+\frac{1}{a}}} \cdot \sum_{i=1}^{n_c} \frac{e_i^2}{\sqrt{A_i}} \quad (3)$$

gdzie:

- M i N – rozmiary obrazu,
- $r(a)$ – liczba klas o polu a ,
- A_{\max} – pole największej klasy, pozostałe oznaczenia identyczne jak we wzorze (1).

W funkcji zmieniła się postać współczynnika kary: zamiast $\sqrt{n_c}$ pojawił się $\sqrt{\sum_{a=1}^{A_{\max}} [r(a)]^{1+\frac{1}{a}}}$. Wykładnik $1 + 1/a$ dla $a = 1$ wynosi 2, dla $a = 2$ wynosi 1,5, a dla $a = 10000$ wynosi 1,0001, tak więc gdy segmentacja składa się głównie z dużych klas, to wyrażenie pod pierwiastkiem jest zbliżone do liczby klas n_c . Gdy jednak segmentacja zawiera wiele małych klas wykładnik $1 + 1/A$ powoduje zwiększenie wartości funkcji – a więc jej pogorszenie. Niestety podobnie jak F , także funkcja oceny F' osiąga wartość minimalną (zero) dla obrazów, które nie są posegmentowane tzn. piksele nie są połączone w klasy i każdy z nich stanowi osobną klasę. Problem ten wynika z faktu, iż obie funkcje składają się z dwóch podstawowych czynników.

Drugim problemem zauważonym przez Borsottiego i in. [4] jest to, że funkcja podobnym segmentacjom przyznaje zbyt różniące się oceny – przyczyną jest to, że nowy czynnik kary znajduje się poza sumą mierzącą błędy barwy. Dlatego też, Borsotti i in. zaproponowali [4] kolejną funkcję. Ma ona postać:

$$Q(I) = \frac{1}{1000 \cdot M \cdot N} \sqrt{n_c} \cdot \sum_{i=1}^{n_c} \left[\frac{e_i^2}{1 + \log A_i} + \left(\frac{r(A_i)}{A_i} \right)^2 \right] \quad (4)$$

(oznaczenia identyczne jak we wzorach (1) i (3)).

Funkcja Q podobnie jak F oraz F' składa się z trzech czynników. Pierwszy z nich to czynnik normalizujący wartości funkcji oceny względem rozmiaru analizowanego obrazu. Drugi, czyli $\sqrt{n_c}$ (identyczny jak w funkcji F), jest współczynnikiem kary zwiększającym wartość oceny, gdy segmentacja składa się z wielu klas. Ostatni czynnik jest bardziej rozbudowany niż w przypadku wcześniej opisanych funkcji. Kładzie on większy nacisk na karanie klas charakteryzujących się dużym błędem barwy, a także klas o małej powierzchni. Pierwszym składnikiem kary jest $\frac{e_i^2}{1 + \log A_i}$. Przyjmuje on duże wartości dla klas, które są niejednorodne, ponieważ posiadają one duży błąd barwy e_i . Zastąpienie $\sqrt{A_i}$ przez $1 + \log A_i$ powoduje silniejsze karanie niejednorodnych klas o tej samej powierzchni.

Drugim składnikiem kary jest $\left(\frac{r(A_i)}{A_i} \right)^2$. Powoduje on pogorszenie oceny

dla segmentacji, w których liczba klas jest zbyt duża. Na przykład jeżeli jeden z obrazów testowych o rozmiarach 384×384 piksele zostanie podzielony na klasy o takiej samej powierzchni wynoszącej 4 piksele, wtedy wartość tego składnika wynosić będzie ponad 84 miliony. Gdyby jednak klasy były większe i składały się z 384 pikseli każda, to wtedy składnik drugi będzie równy tylko 1.


Oznacza to, że składnik osiąga duże wartości, gdy segmentacja składa się z wielu małych klas o tym samym rozmiarze. Dodanie składnika, który jest niezależny od błędu barwy e_i , spowodowało również to, że w odróżnieniu od funkcji F i F' , funkcja Q nie osiąga wartości minimalnej dla obrazu, w którym każdy piksel stanowi osobną klasę. Według Borsotti'ego i in. wartości funkcji Q najlepiej odpowiadają wzrokowej ocenie jakości segmentacji [4].

4. PORÓWNANIE FUNKCJI OCENY

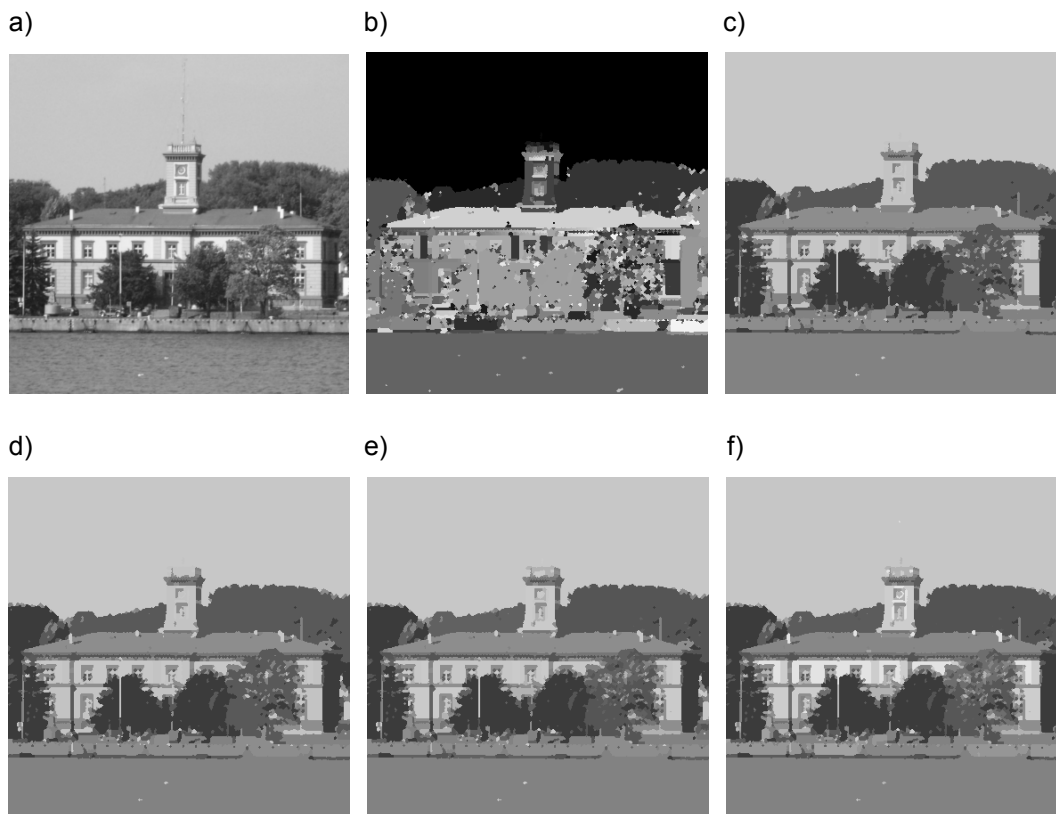
W celu porównania przedstawionych w punkcie trzecim funkcji oceny, wykonano segmentacje obrazów testowych. Obrazy poddano przetwarzaniu wstępnemu. Pierwszym jego etapem było zastosowanie selektywnego filtra roz-

mywającego opartego na metodzie poziomic (ang. level-set). Filtr ten (curvature anisotropic diffusion filter) został zaproponowany przez R. Whitakera i X. Xue [25]. Jego parametrami są: liczba iteracji n , przyrost czasu Δt oraz konduktancja K . Dla obrazów testowych przyjęto następujące wartości: $n = 5$, $\Delta t = 0,12$, $K = 0,3$. Na podstawie rozmytego obrazu wyznaczono obraz gradientowy. Zastosowano dwa różne filtry gradientowe dostosowane do przetwarzania obrazów barwnych. Dla obrazu testowego budynek_1 zastosowano filtr wykorzystujący analizę głównych składowych [14] natomiast do obrazu sufit_2 filtr oparty na heurystyce, która definiuje moduł gradientu w punkcie, jako sumę kwadratów wszystkich pochodnych cząstkowych w tym punkcie, we wszystkich składowych [10]. W przypadku obrazu testowego sufit_2 obraz gradientowy był progowany z wartością progu wynoszącą 5% różnicy między największą i najmniejszą wartością w obrazie gradientowym ponad wartość minimalną. Na podstawie obrazu gradientowego wyznaczono wynik transformacji wododziałowej. Następnie przeprowadzono zalewanie płytkich zlewisk na podstawie ich głębokości [10]. Parametrem algorytmu jest poziom zalewania, który w przypadku obrazu budynek_1 wynosił 9% a w przypadku obrazu sufit_2 10% różnicy między największą i najmniejszą wartością w obrazie gradientowym. Zastosowanie filtru rozmywającego, progowania obrazu gradientowego oraz łączenie płytkich zlewisk, stanowią część wstępnej redukcji nadsegmentacji. W dalszej kolejności wyznaczono wartości atrybutów każdego zlewiska oraz przeprowadzono ich klasteryzację z wykorzystaniem hierarchicznych metod analizy skupień. Postępowano zgodnie z opisem w punkcie 2, z tą różnicą, że zachowywano wszystkie segmentacje z zadanego przedziału (nie tylko najlepszą).

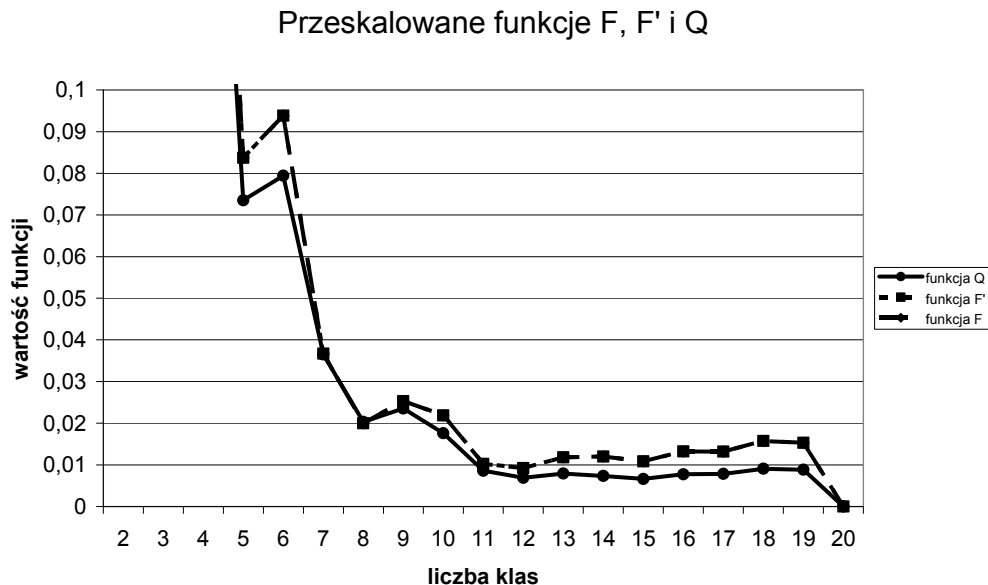
Funkcje F , F' oraz Q znacząco różnią się zakresem wartości. Dla przykładu w przypadku obrazu testowego budynek_1 otrzymane wartości funkcji zawierają się w następujących przedziałach: F [$2,64 \cdot 10^{10}$; $4,24 \cdot 10^{11}$], F' [18; 288], Q [438; 17901]. W celu dokładniejszego porównania wszystkie funkcje przeskalowano, tak aby przyjmowały wartości z zakresu [0; 1]. Wykresy znormalizowanych funkcji, otrzymanych dla dwóch przykładowych obrazów testowych, umieszczono na rysunkach 1 i 3. Aby dodatkowo uwypuklić różnice, zakres przedstawiony na wykresie ograniczono do [0; 0,1]. Jak widać przebieg przeskalowanych funkcji jest podobny. Funkcje F , F' i Q w przypadku obrazu budynek_1 osiągnęły minima dla 7, 11 i 19 klas, natomiast w przypadku obrazu sufit_2 dla 5, 8, 12, 15 i 20 klas. W przypadku obrazu budynek_1 funkcja Q osiągnęła dodatkowe, czwarte minimum dla 9 klas. Obrazy testowe oraz ich segmentacje wybrane za pomocą porównywanych funkcji znajdują się na rysunkach 2 i 4 (barwne wersje, zarówno obrazów testowych jak i wyników dostępne są pod adresem: http://pluton.pol.lublin.pl/~jsmolka/test_images/2012_iel/).



Rys. 1. Zależność przeskalowanych wartości funkcji oceny od liczby klas dla segmentacji obrazu *budynek_1*



Rys. 2. Segmentacje obrazu testowego *budynek_1* (parametry analizy skupień – metoda: CLINK, miara odległości: euklidesowa, brak standaryzacji, atrybuty zlewiska: średnia, wariancja): a) obraz oryginalny (384 × 384 piksele), b) nadsegmentacja po transformacji wododziałowej i wstępnej redukcji nadsegmentacji (1873 zlewiska), c) segmentacja zawierająca 7 klas, d) 9 klas, e) 11 klas, f) 19 klas




Rys. 3. Zależność przeskalowanych wartości funkcji oceny od liczby klas dla segmentacji obrazu *sufit_2*

Należy zaznaczyć, że w kontekście rozpatrywanej metody przedstawionej w punkcie 2 istotna jest liczba klas, dla której funkcja oceny jakości segmentacji osiąga minimum. Nie jest istotna jej wartość. Dlatego też można stwierdzić, że różnice między funkcjami F , F' i Q są niewielkie, w przypadku pracy z segmentacjami, które otrzymano poprzez grupowanie zlewisk za pomocą analizy skupień i zaproponowanej przez autorów metody. Jest to istotna różnica w porównaniu z wynikami prezentowanymi w pracy [4], której autorzy testowali funkcje w innym kontekście i z wykorzystaniem innych metod segmentacji. Również w [27] wykazana została np. większa skłonność funkcji F i F' do niedostatecznej segmentacji, czy ich mniejsza dokładność niż funkcji Q .

5. WNIOSKI

W przypadku segmentacji uzyskanych w wyniku wykonania transformacji wododziałowej i grupowania zlewisk za pomocą metod analizy skupień różnice między funkcjami F oraz F' są znikome. Obie funkcje, w przypadku obrazów testowych, osiągały swoje minima dla identycznej liczby klas. Funkcja Q charakteryzuje się nieco innym przebiegiem, jednak zazwyczaj osiąga minima dla tej samej liczby klas co funkcje F i F' . Jej zaletą jest to, że nie osiąga wartości 0 dla segmentacji, w której każda klasa składa się z jednego piksela. Brak różnic



Rys. 4. Segmentacje obrazu testowego *sufit_2* (parametry analizy skupień – metoda: CLINK, miara odległości: euklidesowa, brak standaryzacji, atrybuty zlewiska: średnia, minimum, maksimum, rozrzut): a) obraz oryginalny (384×384 piksele), b) nadsegmentacja po transformacji wododziałowej i wstępnej redukcji nadsegmentacji (2144 zlewiska), c) segmentacja zawierająca 5 klas, d) 8 klas, e) 12 klas, f) 15 klas, g) 20 klas

między funkcjami stosowanymi w połączeniu z zaprezentowaną metodą redukcji nadsegmentacji, umożliwia zastosowanie najprostszej z nich (czyli funkcji F), co ułatwia i przyspiesza obliczenia. Wspomniany brak różnic wynika prawdopodobnie z faktu, iż funkcje oceny służące do wyboru najlepszej z wszystkich wykonanych segmentacji – zawierającej niewielką liczbę klas – stosowane są w ostatnim etapie ich powstawania. W przypadku innych metod i w innym kontekście, różnice między poszczególnymi funkcjami są większe [4, 27].

LITERATURA

1. Beucher S., Bilodeau M., Yu X.: Road segmentation by watersheds algorithms. In Proc. of PROMETHEUS workshop, Sophia-Antipolis, 1990.
2. Beucher S., Bilodeau M.: Road segmentation and obstacle detection by a fast watershed transformation. In Intelligent Vehicles '94 Symposium, Proceedings of the, 296–301, 1994.
3. Beucher S., Yu. X.: Road recognition in complex traffic situations. In 7th IFAC/IFORS Symposium on Transportation Systems: Theory and Application of Advanced Technology, 413–418, 1994.
4. Borsotti M., Campadelli P., Schettini R.: Quantitative evaluation of color image segmentation results. *Pattern Recognition Letters*, 19, 741–747, 1998.
5. Dagher I., Tom K. E.: Waterballoons: A hybrid watershed balloon snake segmentation. *Image and Vision Computing*, 26(7), 905–912, 2008.
6. Everitt B. S., Landau S., Leese M.: *Cluster Analysis*. Arnold, 2001.
7. Frucci M., Ramella G., Sanniti di Baja G.: Using resolution pyramids for watershed image segmentation. *Image and Vision Computing*, 25(6), 1021–1031, 2007.
8. Haris K., Estradiadis S. N., Maglaveras N., Katsaggelos A. K.: Hybrid image segmentation using watersheds and fast region merging. *IEEE Transactions on Image Processing*, 7(12), 1684–1699, 1998.
9. Hsieh F. Y., Han C. C., Wu N. S., Chuang T. C., Fan. K. C.: A novel approach to the detection of small objects with low contrast. *Signal Processing*, 86(1), 71–83, 2006.
10. Ibanez L., Schroeder W., Ng L., Cates J. i in.: *The ITK Software Guide*. Kitware Inc., 2005.
11. Jung C. R.: Unsupervised multiscale segmentation of color images. *Pattern Recognition Letters*, 28(4), 523–533, 2007.
12. Liu J., Yang Y. H.: Multiresolution color image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 16(7), 689–700, 1994.
13. Romesburg H. Ch.: *Cluster Analysis for Researchers*. Lulu Press, 2004.
14. Sapiro G., Ringach D. L.: Anisotropic diffusion of multivalued images with applications to color filtering. *Image Processing, IEEE Transactions on*, 5 (11), 1582–1586, 1996.
15. Scheunders P., Sijbers J.: Multiscale watershed segmentation of multivalued images. In 16th International Conference on Pattern Recognition, 3, 2002.
16. Sijbers J., Scheunders P., Verhoye M., Van der Linden A., van Dyck D., Raman E.: Watershed-based segmentation of 3D MR data for volume quantization. *Magnetic Resonance Imaging*, 15(6), 679–688, 1997.
17. Smółka J.: Watershed based region growing algorithm. *Annales UMCS Informatica*, AI 3, 169–178, 2005.
18. Smółka J.: Multilevel near optimal thresholding applied to watershed grouping. *Annales UMCS Informatica*, AI 5, 191–200, 2006.
19. Smółka J.: Hierarchical cluster analysis methods applied to image segmentation by watershed merging. *Annales UMCS Informatica*, AI 6, 73–84, 2007.
20. Smółka J., Skublewska-Paszkowska M.: Usuwanie nadmiernej segmentacji w transformacji wododziałowej za pomocą analizy skupień, *AGH Automatyka*, Tom 12, Zeszyt 2, 463-482, 2008

21. Smółka J., Skublewska-Paszkowska M., Wojdyga A.: Improving performance of watershed clustering algorithm by using wavelet transform. *Polish Journal of Environmental Studies*, 18(3B), 341–346, 2009.
22. Trémeau A. and Colantoni P.: Regions adjacency graph applied to color image segmentation. *IEEE Trans. Image Processing*, 9(4), 735–744, 2000.
23. Wegner S., Harms T., Oswald H., Fleck E.: Medical image segmentation using the watershed transformation on graphs. In *ICIP*, III, 37–40, 1996.
24. Wegner S, Harms T., Oswald H., Fleck E.: The watershed transformation on graphs for the segmentation of CT images. In *ICPR*, III, 498–502, 1996.
25. Whitaker R. T., Xue. X.: Variable-conductance, level-set curvature for image denoising. *Proceedings of 3rd International Conference on Image Processing*, 142–145, 2001.
26. Zhao C. G. and Zhuang T. G.: A hybrid boundary detection algorithm based on watershed and snake. *Pattern Recognition Letters*, 26(9), 1256–1265, 2005.
27. Zhang H., Fritts J. E., Goldman S. A.: Image segmentation evaluation: A survey of unsupervised methods. *Computer Vision and Image Understanding*, 110(2), 260-280, 2008.

Rękopis dostarczono dnia 13.08.2012 r.

COMPARISON OF SEGMENTATION QUALITY ASSESSMENT FUNCTIONS IN CONTEXT OF COLOR IMAGE OVER-SEGMENTATION REDUCTION METHOD

Jakub SMÓŁKA, Maria SKUBLEWSKA-PASZKOWSKA

ABSTRACT *The paper concerns one problem in watershed transformation: over-segmentation. It compares segmentation quality assesment functions used to assess the quality of over-segmentation reduction in images first segmented by means of watershed transformation. It presents briefly a method of over-segmentation reduction based on cluster analysis, a method proposed earlier by the authors. Using the above functions allows for semi-automatic selection of the number of classes in the final segmentation. Results are discussed and illustrated with charts and sample test images of segmentation.*



Dr inż. Jakub SMÓŁKA – Pracownik naukowo-dydaktyczny w Instytucie Informatyki Wydziału Elektrotechniki i Informatyki Politechniki Lubelskiej. Tytuł magistra uzyskał na Politechnice Lubelskiej natomiast stopień doktora na Politechnice Śląskiej. Jego działalność naukowa związana jest z przetwarzaniem obrazów cyfrowych w szczególności z ich segmentacją oraz kompresją.

Dr inż. Maria SKUBLEWSKA-PASZKOWSKA – Pracownik naukowo-dydaktyczny pracujący w Instytucie Informatyki Wydziału Elektrotechniki i Informatyki Politechniki Lubelskiej. Tytuł magistra uzyskała na Politechnice Lubelskiej. Stopień doktora otrzymała na Politechnice Śląskiej. Działalność naukowa związana jest głównie z transformatami falkowymi, miarami jakości oceny wizualnej kolorowych obrazów i zastosowania ich w adaptacyjnej kompresji obrazów.

