

## TELEDETEKCYJNE WYKORZYSTANIE METODY GRUPOWANIA OBIEKTÓW W OPARCIU O ANALIZĘ GĘSTOŚCI

Ireneusz Wyczałek

Politechnika Poznańska

**Streszczenie.** Klasyczne podejście do klasyfikacji obiektów na obrazach teledetekcyjnych, zakładające rozpoznawanie szczegółów terenowych pogrupowanych w kilka kategorii tematycznych, reprezentowanych przez cechy radiometryczne kilkukanałowego obrazu rastrowego, nadal wymaga coraz bardziej zaawansowanych metod podnoszenia skuteczności. Spośród współcześnie wprowadzanych rozwiązań na szczególną uwagę zasługują metody określane mianem obiektowych, które bazują na analizach fragmentów obszaru mapy bitowej, pogrupowanych według określonych kryteriów homologiczności. Segmentację obrazu można uzyskać różnymi metodami, które rozwijane są w licznych dziedzinach zastosowań informatyki. W interpretacji obrazów teledetekcyjnych opracowano rozwiązania dostosowane do specyfiki tychże obrazów. W niniejszej pracy podjęto temat takiego szczególnego wykorzystania techniki grupowania obiektów spełniających określone kryteria dokładnościowe. Scharakteryzowano metodę gęstościową analiz baz danych i jej modyfikację dostosowaną do analiz obrazów rastrowych, a następnie podano proponowany sposób dalszego rozwoju metody z wykorzystaniem dostępnej informacji wektorowej. Wywód zilustrowano za pomocą uproszczonego modelu obrazu teledetekcyjnego.

**Słowa kluczowe:** teledetekcja, segmentacja obiektowa, grupowanie gęstościowe

### 1. WPROWADZENIE

Historia fotointerpretacji bogata jest w szereg znaczących odkryć w dziedzinie rozpoznawania obiektów terenowych na podstawie zdjęć lotniczych i zobrazowań satelitarnych. Główne źródła aktywności naukowej na tym polu wynikały z potrzeby i chęci szczegółowego i skutecznego rozpoznawania obiektów terenowych. Rozwój coraz bardziej zaawansowanych technik pozyskiwania obrazów, który przejawia się między innymi znaczącym wzrostem ich rozdzielczości, jest niepohamowanym motorem roz-

woju technik rozpoznawania obrazów. Niekwestionowanym kanonem fotointerpretacji jest klasyfikacja, dzielona na nadzorowaną i nienadzorowaną, w zależności od stopnia wykorzystania dostępnej wiedzy na temat rozpoznawanych obiektów [Baltsavias 2002]. W obu podejściach analityk wprzęgany jest w proces klasyfikacji, w celu podniesienia jej skuteczności, zwykle niewystarczającej podczas stosowania rozwiązań automatycznych. Poszukiwane są metody analityczne poprawy tego stanu rzeczy, poprzez zastępowanie mechanizmów zachodzących w mózgu analityka. Znane są wnioski wynikające z badań zmysłu wzroku, że obiekty rozpoznawane są przez człowieka nie tylko poprzez barwę, ale także kształt, wzór i ruch. Podejmowane są próby algorytmicznego opisu wspomnianych zachowań.

Sprawdzonym rozwiązaniem jest wspomaganie algorytmów klasyfikacyjnych poprzez informacje dodatkowe, takie jak wzorce klasyfikacyjne, ograniczenia powierzchniowe, pola uczące pozyskiwane z zasobów kartograficznych lub „wektorowego” SIP, a także „ręczne” wskazywanie poprawnie lub niepoprawnie rozpoznanych obiektów. Zwyczajowo stosuje się klasteryzację, jako efekt wstępnej klasyfikacji nienadzorowanej, przed podjęciem zadania przypisania poszczególnych fragmentów obrazu do określonych kategorii obiektów. Praktycznym skutkiem takiego podejścia jest radykalne ograniczenie ilości analizowanej informacji oraz agregacja danych wyjściowych w struktury składowe poszukiwanych obiektów. Podział badanego obszaru na klasy ogranicza się wówczas praktycznie do odpowiedniego pogrupowania klastrów i przypisania ich do poszczególnych klas na podstawie analizy ustalonych kryteriów przydziału.

Pośród wielu dostępnych algorytmów segmentacji w niniejszej pracy poddano analizie metodę badania skupień występujących w wielkich zbiorach danych, w oparciu o kryterium gęstości. Kryterium to zakłada, że pewne grupy danych posiadają zbliżone cechy w sensie przyjętej miary odległości. Te obiekty, w sąsiedztwie których stwierdza się istnienie innych o podobnych cechach, przypisywane są do odrębnego skupienia. W dalszym ciągu niniejszego opracowania, w rozdziale drugim zostanie przedstawiona idea metody gęstościowej w przypadku ogólnym oraz w jej wersji odnoszącej się do obrazów barwnych, zaś rozdział trzeci poświęcony jest proponowanej modyfikacji. W podsumowaniu wyszczególnione zostaną te aspekty, które wskutek modyfikacji powinny zwiększyć atrakcyjność metody dla zastosowań teledetekcyjnych.

## **GĘSTOŚCIOWA METODA WYKRYWANIA SKUPIEŃ W ZBIORACH DANYCH**

### **Idea metody gęstościowej**

Analiza gęstościowa jest, obok progowego, powierzchniowego i konturowego, jednym z klasycznych sposobów ekstrakcji obiektów na obrazach świata fizycznego.

W ujęciu bardzo uogólnionym, badając skupienia tą metodą zakłada się, że w analizowanej przestrzeni obiekty rozmieszczone są nierównomiernie, a czynnikiem świadczącym o łączeniu się ich w grupy jest gęstość ich występowania. Miarą gęstości w przestrzeni euklidesowej jest liczba obiektów znajdujących się wewnątrz okręgu (na płaszczyźnie) lub kuli (w przestrzeni 3D) o zadanym promieniu. Jeśli okrąg (kula) przemierzający się w jakiś uporządkowany sposób w rozpatrywanej przestrzeni natrafia na zagęszczenie obiektów przekraczające przyjęty próg ilościowy, wówczas obiektom tym zostaje przypisany atrybut przynależności do skupienia (klastra). Skupienie obej-


muje wszystkie obiekty, wobec których stwierdzono zawieranie się we wnętrzu okręgu (kuli), a także sąsiadujące z nimi obiekty znajdujące się w miejscu zagęszczenia. Pierwsze z nich nazwiemy punktami wewnętrznymi, a drugie – granicznymi lub skrajnymi. Obiekty występujące w badanej przestrzeni poza stwierdzonym skupieniem mogą tworzyć inne skupienia lub nie. Natomiast rzadsze miejsca wewnątrz danego skupienia mogą być przez nie wchłonięte, jeśli mieszczą się w zadanych granicach ilościowych lub stanowią wyłączone enklawy, jeśli tego warunku nie spełniają.

W klasycznym ujęciu nie analizuje się typu obiektów tworzących skupienia, a jedynie gęstość ich występowania [Ester i in. 1996], zatem dany klaster może mieć mniej lub bardziej jednorodną strukturę. Można jednak rozbudować metodę o analizę typologiczną i poddawać badaniu tylko obiekty spełniające kryterium przynależności do jakiejś klasy lub kryterium to uwzględniać w procesie wyszukiwania skupień o różnych cechach.

Jednym ze sposobów klasyfikacji obiektów może być uwzględnienie atrybutu barwy [Ye i in. 2003]. Wówczas do danego skupienia zostaną przypisane obiekty posiadające ten atrybut, i tylko te są poddawane badaniom przynależności albo obiekty o różnych barwach badane są ze względu do przynależności do różnych skupień. Takie podejście może znaleźć zastosowanie w analizach obrazów teledetekcyjnych, gdzie skuteczne pogrupowanie pikseli o określonych cechach barwnych stanowi podstawowe kryterium klasyfikacyjne.

### Podstawy teoretyczne metody gęstościowej

Ilustracją dla wyjaśnienia algorytmu metody gęstościowej niech będzie zbiór punktów rozmieszczonych na prostokątnym fragmencie powierzchni płaskiej, tak jak to przedstawiono na rysunku 1. Zakładamy przy tym, że nieistotne są inne cechy punktów niż ich położenie.



Rys. 1. Przykłady grup obiektów w bazach danych punktowych  
Fig. 1. Examples of object groups in point-type databases

Zgodnie z ustaleniami autorów metody DBSCAN podstawowymi jej parametrami są promień wyszukiwania Eps i graniczna liczba punktów MinPts. Parametry te zastosowane indywidualnie do wszystkich obiektów, w naszym przykładzie punktów, leżących w granicach analizowanej dziedziny D stanowią kryterium zawierania się wewnątrz skupienia, co można wyrazić matematycznie:

$$\text{jeżeli } \forall p \text{ że } |\text{NEps}(p)| \geq \text{MinPts} \text{ wówczas } p \in C \quad (1)$$

gdzie:

- p – punkt z dziedziny D,
- C – kłaster (skupienie) wewnątrz dziedziny D,
- NEps – sąsiedztwo w promieniu Eps (Eps-sąsiedztwo).

NEps jest podstawową miarą oceny bliskiego położenia dwóch punktów. Eps-sąsiedztwo punktu p, oznaczane NEps(p), jest definiowane jako:

$$\text{NEps}(p) = \{q \in D \mid \text{dist}(p, q) \leq \text{Eps}\} \quad (2)$$

Kryterium przynależności kilku punktów  $p_i$  do skupienia wyznaczonego przez punkt q jest jednocześnie spełnienie warunku (1) i warunku Eps-sąsiedztwa, czyli:

$$p_i \in \text{NEps}(q) \quad (3)$$

Jest to tak zwany warunek bezpośredniej dostępności gęstościowej punktów q i  $p_i$ .

Warunek ten jest oczywiście przemienny dla pary punktów wewnętrznych, a nieprzemienny wówczas, gdy któryś z punktów  $p_i$  leży na granicy klastra. Para punktów, z których choć jeden jest dostępny z drugiego, nazywana jest też parą połączoną. W konsekwencji, atrybut łączności pary p, q jest przemienny w obie strony.

W przypadku skupień o nieregularnych kształtach może się okazać, że część punktów nie spełnia warunku bezpośredniej dostępności, wówczas znajduje zastosowanie uogólniona jego postać, zakładająca istnienie punktu s bezpośrednio dostępnego z obu punktów p i q. W ten sposób definiuje się warunek pośredniej dostępności gęstościowej:

$$\begin{aligned} p \in \text{NEps}(s) \text{ i } q \in \text{NEps}(s) \\ |\text{NEps}(s)| \geq \text{MinPts} \end{aligned} \quad (4)$$

Ten ostatni warunek jest niezwykle użyteczny w analizie punktów leżących na obrzeżu skupień, gdyż stanowi kryterium ich przynależności do określonego klastra.

W oparciu o powyższe ustalenia można zatem zdefiniować pojęcie klastra. Niech D będzie dziedziną pewnej grupy obiektów (punktów). Kłaster C, spełniający kryterium gęstości (Eps, MinPts) jest niepustym podzbiorem zbioru D spełniającym następujące warunki:

- jeśli  $\forall p, q$  że, jeśli  $p \in C$  a q jest dostępne gęstościowo z p, wówczas  $q \in C$
- jeśli  $\forall p, q \in C$  że p jest dostępne gęstościowo z q.

Punkty nie wchodzące w strukturę klastra stanowią szum.

Ostatecznie procedura wyszukiwania skupień w dowolnej bazie danych, według Estera i in. [1996], przebiega następująco:

- ocena wszystkich punktów pod względem zawierania się w jakimkolwiek skupieniu, poprzez spełnienie warunku (1); punkty spełniające ten warunek uzyskują etykietę punktu wewnętrznego;
- ocena bezpośredniej dostępności punktów za pomocą kryterium (2); wszystkie punkty wzajemnie dostępne uzyskują etykietę przynależności do wspólnego klastra;
- spośród pozostałych punktów wyszukiwanie tych, które są pośrednio dostępne względem punktów przypisanych wcześniej do poszczególnych klastrów.

Czynność trzecia przebiega iteracyjnie do momentu, kiedy żaden z punktów nie przypisanych jeszcze do żadnego skupienia nie spełnia warunku dostępności gęstościowej.

### **Adaptacja metody skupień gęstościowych uwzględniająca barwę obiektów**


Rodzi się pytanie, czy opisaną wyżej metodę można skutecznie wykorzystać w fotointerpretacji. W tym kontekście obraz Ziemi uznamy jako szczególny zbiór danych przestrzennych, w którym każdy piksel posiada odniesienie przestrzenne oraz charakterystykę barwną. Metoda użyta do wyszukiwania skupień w zbiorach bazodanowych powinna zatem być użyteczna w wyznaczaniu klastrów na obrazie teledetekcyjnym.

Zgodnie z tym, co wspomniano w ujęciu klasycznym, metodę gęstościową można rozbudować o kryteria dodatkowe, których celem jest rozróżnienie skupień o odmiennych cechach. Adaptacji tej można dokonać jednym z następujących sposobów:

- poddanie analizie jedynie obiektów spełniających określone kryterium – położenia, kształtu, wielkości, barwy lub innej cechy typologicznej,
- wydzielenie skupień obiektów przynależnych do różnych typów.

Połączone przestrzennie piksele o podobnej barwie mogą zostać zgrupowane w celu utworzenia posegmentowanych obszarów na powierzchni obrazu. Przyjmując kryterium barwy jako dodatkowe kryterium segmentacyjne, Ye, Gao i Zeng [2003] opracowali ramy teoretyczne takiego podejścia, nazywając je metodą gęstościową segmentacji barwnej. Przez porównanie z metodą gęstościową w ujęciu klasycznym, wprowadzili oni dalsze definicje:

- jako SpatialEps oznaczyli oni przestrzenne sąsiedztwo piksela, które na obrazie teledetekcyjnym można je zilustrować jako koło o środku w tym pikselu;
- wielkością SpatialEps jest liczba pikseli zawierających się we wnętrzu tego koła;
- sąsiedztwo barwne danego piksela nazwano ColorEps, przy czym jako miarę tego sąsiedztwa autorzy przyjęli wymiary elipsoidy wartości barwnych w przestrzeni HVC;
- jeśli przestrzenne sąsiedztwo określonego piksela obejmuje co najmniej minimalną liczbę pikseli (MinPts) mieszczących się w granicach zadanej elipsy w przestrzeni barw, wówczas piksel ten zostaje oznaczony jako wewnętrzny, tworząc wraz z otaczającymi pikselami spełniającymi ten sam warunek załączek nowego segmentu;
- dla zbioru pikseli tworzących obraz I stwierdza się, że dany piksel  $p$  jest bezpośrednio osiągalny gęstościowo z dowolnego punktu wewnętrznego  $q$ , jeśli znajduje się wewnątrz koła SpatialEps otaczającego ten punkt;
- definicje pośredniej osiągalności i łączności gęstościowej są podobne jak w ujęciu klasycznym.



Rys. 2. Przykłady wyników segmentacji gęstościowej obrazów metodą Ye i in. [2003]

Fig. 2. Examples of density segmentation results using method Ye at al. [2003]

efekty jej stosowania, z których najważniejszym jest możliwość segmentacji obrazów cechujących się dużym szumem i nieostrych konturami. Próbkę zastosowań w odniesieniu do różnej jakości obrazów (niefotogrametrycznych) przedstawiono na rysunku 2.

## TELEDETEKCYJNA ADAPTACJA METODY GĘSTOŚCIOWEJ

Metoda Ye i in. [2003] opracowana została z przeznaczeniem do segmentacji dowolnych obrazów. Trudno znaleźć wzmianki, czy znalazła zastosowanie w fotointerpretacji. Wydaje się, że są co najmniej dwie tego przyczyny: przede wszystkim, metody segmentacji poprzedzającej klasyfikację z trudem przez lata znajdowały drogę do interpretacji zdjęć i obrazów teledetekcyjnych. Dopiero za sprawą grupy naukowców [Baatz, Shape, 1999] zgrupowaną w firmie Definiens Imaging dostrzegano się znaczące ożywienie w tej dziedzinie. Ponadto, obrazy pozyskiwane za pomocą wielokanałowych systemów o średniej rozdzielczości (TM, HRV) nie nadawały się zbyt do segmentacji tym sposobem. Przyszłość i nadzieję można znajdować w opracowywaniu zdjęć cyfrowych i obrazów o bardzo wysokiej rozdzielczości – zarówno przestrzennej, jak i spektralnej.

Metoda wymaga kilku komentarzy. Pierwszym jest przestrzeń barwna HVC, którą uzyskuje się poprzez parametryczną transformację przestrzeni RGB. Opracowana przez Munsella definicja barw w tym standardzie miała na celu znalezienie takiego algorytmu, który podczas porównania dwóch par dowolnych kolorów rozróżnialnych przez człowieka jako różniących się barwą w sposób identyczny, dawałby dla obu par tę samą liczbową wartość różnicy [Wyble i Fairchild, 2000]. Transformacja RGB na HVC chroniona jest prawnie, jednak znane są i publikowane jej algorytmy opracowane na podstawie analiz empirycznych. Istotne dla metody jest też podejście do ustalenia podobieństwa barwnego. Autorzy proponują podział skali barwnej na równe części w liczbie wynikającej z ilości zagłębień histogramu.

Podsumowując barwną metodę gęstościową trzeba zwrócić uwagę na niespodziewanie skuteczne

## Projekt zastosowania metody w fotointerpretacji

Miarą podstawowego parametru gęstości obrazów teledetekcyjnych – Eps-  
sąsiedztwa (NEps) jest lub może być:

- odległość euklidesowa w jednorodnej przestrzeni geometrycznej, afiniczna w przestrzeni niejednorodnej (różne skale lub kąty przecięcia osi) lub rzutowa w opracowaniu bezpośrednich danych fotogrametrycznych,
- odległość w sensie Mahalanobisa w odniesieniu do rozkładu składowych barwnych,
- inna miara odległości (lub uszeregowania) w zależności od cechy przyjętej do analizy oraz rozkładu prawdopodobieństwa przyjętej próby.

Sposób poszukiwania centrów skupień może bazować na jakimś wstępnym uszeregowaniu danych, na przykład w kolejności ich zapisu, lecz także może „rozlewać się” wokół spodziewanych albo zadanych miejsc koncentracji. W fotointerpretacji takimi centrami mogą być szczyty lub zagłębienia histogramu cech barwnych lub miejsca wskazane przez analityka (albo niezależny od niego system wspomagający) jako pola uczące procedurę klasyfikacyjną.


Zarówno dziedzinę parametrów lokalizacyjnych, jak i barwnych można ograniczyć, wyłączając miejsca nieistotne lub wręcz utrudniające segmentację, ale – w szerszym ujęciu – możliwe powinno być zastosowanie jakiegokolwiek funkcji relatywizującej wartości analizowanych cech (wagi), a także czynników hierarchizujących lub kontekstowych.

Powyższe wnioski posłużyły do zdefiniowania uogólnionej metody segmentacji gęstościowej obrazów teledetekcyjnych wspomaganych przez informację zawartą w bazach systemu informacji przestrzennej. Współpraca z systemem GIS-owym jest o tyle istotna, że spodziewanym polem zastosowań metody ma być analiza zmian i aktualizacja informacji bazodanowej. W odróżnieniu od znanych z literatury rozwiązań proponowana metoda wykorzystuje dostępne informacje o elementach obrazu, które posiadają swoje odpowiedniki w modelu terenu zapisanym w bazach danych systemu informacji przestrzennej. W takim podejściu parametry atrybutów barwnych dla poszczególnych klastrów można określić na podstawie informacji pozyskanych z pikseli wskazanych przez automatyczny moduł uczący.

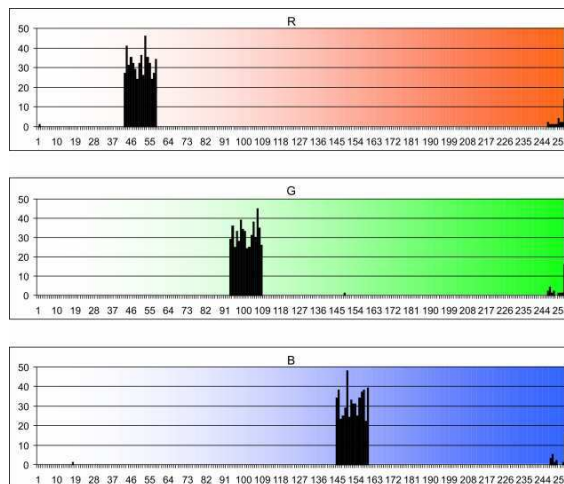
### Przykład zastosowania

Rysunek 3 przedstawia uproszczony obraz osiedla domów jednorodzinnych, których cechy barwne uzmienniono za pomocą generatora liczb pseudolosowych. Po trzy obiekty poszczególnych klas barwnych wykorzystano jako dane uczące.

Na rysunku 4 zilustrowano histogramy dla trzech wybranych obiektów uczących z klasy oznaczonej na niebiesko. Podobną postać mają histogramy dla pozostałych klas obiektów. Rysunek 5 przedstawia wyniki kolejnych przybliżeń do uzyskania jak najlepszego wyniku segmentacji – kolejno: a) punkty wewnętrzne wyłoniłone za pomocą okna wyszukiwania o wymiarach 2x2 piksele, b) okna 3x3 piksele, c) okna 4x4 piksele oraz d) po przyłączeniu pikseli brzegowych do zbioru punktów centralnych wyznaczonych oknem 3-pikselowym.




Rys. 3. Symulowany obraz testowy wykorzystany do analizy gęstościowej (3 grupy obiektów)  
 Fig. 3. Simulated test image used for density analysis (3 groups of objects)



Rys. 4. Histogramy składowych RGB zdefiniowanych losowo dla obiektów niebieskich obrazu testowego  
 Fig. 4. Histograms of RGB components defined randomly for blue objects of test image






Rys. 5. Wyniki kolejnych iteracji wyłaniania obiektów na badanym obrazie: a, b, c) punkty centralne wyznaczone oknem 2x2, 3x3 i 4x4 pikselowym, d) obiekty z próby b wraz z punktami brzegowymi

Fig. 5. Results of successive iterations of objects extraction on tested image: a, b, c) core points obtained using window of 2x2, 3x3 and 4x4 pixels respectively, d) 3x3 core points with border points

Rysunek 6 zawiera wyselekcjonowane obiekty dla wszystkich trzech badanych klas. Tak wysoki stopień skuteczności metody uzyskano dzięki uproszczonemu modelowi obrazu wyjściowego. Obecnie trwają prace nad wdrożeniem metody do analiz oryginalnych teledetekcyjnych danych obrazowych.



Rys. 6. Wynik barwnej segmentacji gęstościowej trzech klas obiektów obrazu testowego

Fig. 6. Result of color density segmentation of three classes of objects on test image

## WNIOSKI

Przedstawiona wyżej gęstościowa metoda segmentacji obrazu, bazująca na jednoczesnym uwzględnieniu wartości składowych barwnych i sąsiedztwa geometrycznego, wydaje się być szczególnie użyteczna w proponowanej wersji rozwiązania, w której inicjalne wartości uczące dobierane są na podstawie cech obiektów wyselekcjonowanych z dostępnej bazy danych typu GIS. Uzyskane i zaprezentowane w niniejszym opracowaniu wyniki dla obrazu testowego służą testowaniu metody na etapie wstępnym i z pewnością nie będą tak korzystne dla realnych obrazów teledetekcyjnych. Prace aplikacyjne będą przedmiotem dalszych badań w tym zakresie, przy czym w większym stopniu planuje się wykorzystywać informację kontekstową i inne źródła wiedzy [Baltsavias, 2002].

Opracowanie to powstało w ramach realizacji indywidualnego tematu badawczego KBN nr 4 T12E 016 26 na temat: Predykcja stanu wieloczasowych fenomenów przestrzennych przy użyciu zautomatyzowanego systemu analiz obrazów rastrowych. Planuje się dalszy rozwój metody, jak również innych prac informatycznych mających na celu rozbudowę wektorowego systemu informacji przestrzennej o podsystem analiz rastrowych.

## PIŚMIENNICTWO

- Baatz M., Shape A., 1999. Object-oriented and multi-scale image analysis in semantic networks. 2nd International Symposium: Operationalization of Remote Sensing, 16-20 August, ITC, Netherlands, 7-13.
- Baltsavias E.P., 2002. Object extraction and revision by image analysis using existing geospatial data and knowledge: State-of-the-art and steps towards operational systems. International Archives of Photogrammetry and Remote Sensing, Vol. 34, Part 2, Comm. II, 13-22.
- Ester M., Kriegel H-P., Sander J., Xu X., 1996. A density-based algorithm for discovering clusters in large spatial databases with noise. Proceedings of 2nd Int. Conference on Knowledge and Data Mining, 226-231.
- Wang J., Yang W., Raj A., 1997. Color clustering technologies for color-content based image retrieval from image databases. International Conference on Multimedia Computing and Systems (ICMCS'97), Ottawa, June 03-06 1997, 442-450.
- Wyble D.R., Fairchild M.D., 2000. Prediction of Munsell Appearance Scales Using Various Color Appearance Models. Color Res. Appl., 25, 132-144.
- Ye Q., Gao W., Zeng W., 2003. Color image segmentation using density-based clustering. ICME Proceedings, 2003 Int. Conference on Multimedia and Expo, Vol. 3, 345-348.

## USING OBJECT GROUPING METHOD BASED ON DENSITY ANALYSIS IN REMOTE SENSING

**Abstract.** Typical approach to classification of objects on remote sensing images, which assume detection of terrain details being grouped into several thematic categories, represented by radiometric properties of the multispectral raster image, still needs more and more sophisticated methods of increasing efficiency. Among currently used solutions, on special attention claimed methods stated as the object-oriented, which are based on analy-

ses of parts of the bitmap, grouped according to criteria of homogeneity. It is possible to carry out the image segmentation using various methods, which are developed within couple of informatics' sciences. In interpretation of remote sensing images there were elaborated approaches adapted to specific of those types of images. Such special use of grouping technique of objects fulfilled the particular accuracy criteria were investigated here. There were described the density-based clustering method of large databases and their implementation adapted to raster image analyses, and then, the possible solution using accessible vector information was suggested. The text is illustrated using the simplified model of remote sensing image.

**Key words:** remote sensing, object segmentation, density-based clustering

Zaakceptowano do druku – Accepted for print: 28.10.2005