

WYKORZYSTANIE DECYZYJNYCH AUTOMATÓW KOMÓRKOWYCH W KLASYFIKACJI WYSOKOROZDZIELCZYCH OBRAZÓW SATELITARNYCH

THE USE OF DECISION-MAKING CELLULAR AUTOMATA IN THE CLASSIFICATION OF REMOTE SENSING IMAGES

Ireneusz Wyczałek

Zakład Geodezji, Politechnika Poznańska

SŁOWA KLUCZOWE: Klasyfikacja, segmentacja, metoda gęstościowa, Automat Komórkowy

STRESZCZENIE: Klasyfikacja jest jednym z najczęściej stosowanych sposobów określania pokrycia terenów w teledetekcji. Metody stosowane w podejściu klasycznym są w dużym stopniu nieskuteczne i wymagają działań wspomagających, takich jak wstępna segmentacja, uwzględnianie dodatkowych parametrów lub zależności, stosowanie metod rozpoznawania wzorów, sztucznej inteligencji, sieci neuronowych itp. Rozwijane są też metody obiektowe, bazujące na różnorodnych relacjach między zbiorami hierarchicznie uporządkowanych segmentów o zbliżonych cechach radiometrycznych. W pracy zaproponowano podejście, w którym grupowane są wyniki klasyfikacji nienadzorowanej w oparciu o analizę gęstości. Metoda gęstościowa w wersji opracowanej na użytek niniejszej pracy uwzględnia zarówno cechy spektralne jak i relacje przestrzenne między grupami pikseli, przypisując do nowotworzonych klas zarówno piksele klasy dominującej, jak i nielicznie występujące na danym obszarze piksele pozostałych klas. Jako narzędzie informatyczne służące rozwiązaniu powyższej idei wykorzystano automat komórkowy wyposażony w mechanizmy decyzyjne. Proces grupowania klas ma charakter iteracyjny, sterowany za pomocą specyficznej „funkcji przejścia” o dopuszczalnych stanach zgodnych z zadanymi klasami pokrycia terenu. Decyzyjny charakter automatu wynika z typowej dla metod podejmowania decyzji postaci funkcji kryterialnej, a także charakterystycznego zestawu jej parametrów – czynników decyzyjnych i ograniczeń. Przedstawione podejście zweryfikowano na przykładzie praktycznym polegającym na wskazaniu terenów pokrytych zielenią wysoką na 4-kanalowym obrazie QuickBird, wyostrzonym metodą PanSharpeningu. W tym celu wybrano trzy fragmenty sceny obejmujące tereny zieleni miejskiej o różnym przeznaczeniu. Uzyskano wysoką dokładność selekcji szukanej klasy pokrycia terenu. Metoda będzie rozwijana w kierunku powiązania z wektorową informacją bazodanową.

1. WPROWADZENIE

Obrazy satelitarne o bardzo dużej rozdzielczości w coraz większym stopniu zastępują średnioskalową fotografię lotniczą, głównie dzięki łatwiejszemu trybowi ich pozyskiwania i opracowania, a także – zapisowi wielospektralnemu o stosunkowo dużej szczegółowości. Obecnie trwają prace nad sensorami o rozdzielczości poniżej 0.5 m (DigitalGlobe, 2006). Jednocześnie dąży się do zwiększenia liczby kanałów spektralnych, co znacznie uatrakcyjni

informację zawartą na tych obrazach. Zachodzi zatem potrzeba rozwijania technik, które efektywnie wykorzystają potencjalne możliwości, jakie daje zwiększona rozdzielczość obrazów satelitarnych. Metody klasyfikacji pikselowej, mimo wielorakich zastosowań i bogatego dorobku badawczego nad ich rozwojem, znajdują się obecnie w pewnym regresie wynikającym zarówno z wdrażania tych nowych, szczegółowych technik rejestracji obrazów jak i rozwoju konkurencyjnych podejść klasyfikacyjnych, które wydają się lepiej radzić sobie z obrazami wysokorozdzielczymi. Wielkie osiągnięcia w tej dziedzinie ma podejście obiektowe (Baatz *et al.*, 1999). Bazuje ono na znanym od czasów starożytnych doświadczeniu, że rzeczy oglądane z różnych odległości dostarczają obserwatorowi odmiennych wrażeń, dzięki czemu w pełniejszy sposób buduje on sobie obraz świata. Obiektowe podejście do klasyfikacji charakteryzuje się takim właśnie wieloskalowym i hierarchicznym opisem cech obiektów klasyfikowanych na obrazie. Z drugiej zaś strony, ten sam pogląd każe doszukiwać się innych cech obiektów, wykraczających poza ocenę barwną. Rozwijane są zatem podejścia analizujące inne niż barwa cechy obiektów oraz relacje między nimi. Dotyczy to w znacznej mierze metod obiektowych, lecz ma także zastosowanie w klasyfikacji pikselowej.

W niniejszej pracy podjęto próbę połączenia tradycyjnej klasyfikacji z gęstościowym podejściem do grupowania obiektów (Dash *et al.*, 2001). Rozwiązanie bazuje na założeniu, że obiekty związane z powierzchnią ziemi składają się z różnych komponentów, pozostających względem siebie w różnorodnych relacjach. Na obrazie obiekty te posiadają różne cechy radiometryczne, zmienne w zależności od oświetlenia, okresu wegetacji itp. Klasyczna klasyfikacja nienadzorowana daje w efekcie obraz bardzo rozdrobniony, zaś pola treningowe wskazane pod kątem klasyfikacji nadzorowanej są albo bardzo selektywne (metoda *Region Growing* o małym progu) albo posiadają bardzo rozmyte granice (duże wartości odchylenia standardowego).

Ideę adaptacji segmentacji baz danych metodą gęstościową do zadań teledetekcyjnych przybliżyłem w pracy Wyczałek (2005), opisując proponowany algorytm i podając zalety jego użycia. Dash *et al.*, 2001 zaproponowali metodę łączącą klasteryzację odległościową (K-średnich) z gęstościową (DBSCAN) w odniesieniu do niegeometrycznych baz danych, uzyskując wyniki testów obiecujące pod względem skuteczności i szybkości obliczeniowej. Za zaletę metody autorzy uznali skuteczność w eliminowaniu szumu z klastrów, co odzwierciedliło się w zawężeniu przedziałów ich wartości. W klasyfikacji obrazów piksele stanowiące szum można włączyć w granice klasy dominującej na danym fragmencie obrazu uzyskując jednorodne wypełnienie obiektów z poszczególnych klas (Wang *et al.*, 1999; Wyczałek, 2005). Podejście opisane w niniejszej pracy łączy zalety mieszanej klasyfikacji z korzyściami płynącymi z włączenia szumu w granice wydzielonych obiektów.

Ponieważ klasyfikacja obrazów odbywa się na powierzchni wyznaczonej przez siatkę pikseli, wykorzystano metodykę Automatów Komórkowych (*Cellular Automata - CA*) jako narzędzie do rozwiązania omawianego zadania klasyfikacyjnego. W dalszej części pracy zostaną przybliżone poszczególne elementy proponowanego rozwiązania wraz z krótkim przykładem praktycznego zastosowania w wydzieleniu obszarów zadrzewionych na obrazie QuickBird'a.

2. SPOSÓB UŻYCIA AUTOMATÓW KOMÓRKOWYCH W KLASYFIKACJI

2.1. Idea segmentacji gęstościowej

Klasyczne klasyfikacje obrazów zaliczane są do metod bazujących na odległościach. Typowa dla tej grupy jest metoda K-średnich, która przydziela poszczególne piksele do K klastrów w oparciu o kryterium różnic wartości ich składowych spektralnych od wartości obliczonej dla środka klasy. Średnia wartość wyznaczona z pikseli przypisanych dla danej klasy przyjmowana jest jako nowa wartość środka klasy. Proces przebiega iteracyjnie do momentu, kiedy nie ma dalszych zmian przypisania do klasy. W metodach tego typu odstające piksele są włączane arbitralnie do najbliższej klasy. Stosowane w fotointerpretacji metody odległościowe, paradoksalnie, zwykle nie uwzględniają relacji przestrzennych między pikselami, powodując zbyt duże rozdrobnienie klastrów na powierzchni obrazu.

W klasyfikacji obrazów metody gęstościowe wyszukują grupy pikseli występujące w dużym zagęszczeniu. Miarą gęstości poddawaną ocenie jest liczba pikseli o ustalonych cechach, zawartych w zadanej jednostce objętości, przy czym pojęcia „liczba” i „odległość” rozumiane są bardzo elastycznie, a ich jednostki zależą od typu i zakresu wartości cechy danej warstwy informacyjnej. Szczególnie wyróżniona jest cecha przestrzenna i związana z nią miara odległości euklidesowej. Q. Ye i in. (Ye *et al.*, 2003) dodają do tego drugą miarę odległości jako promień elipsoidy wyznaczonej z wartości cech spektralnych. Zagęszczenie pikseli uznaje się za odpowiednie, jeśli przekracza zadany próg ilościowy. Ta klasa metod posiada specyficzną nomenklaturę obejmującą takie pojęcia jak: punkty załączkowe i brzegowe, sąsiedztwo obiektów, odległość (waga), bezpośrednia i pośrednia dostępność gęstościowa, a także połączenie i zbiór połączeń gęstościowych oraz szum (Ester *et al.*, 1996). Efektem użycia tej metody jest zbiór segmentów wypełniających całą przestrzeń obrazu, które w pewnym zasięgu przestrzennym posiadają zbliżone cechy radiometryczne. Piksele, które w tym zasięgu nie spełniają zadanych kryteriów traktowane są jako szum i są wyłączone ze zgrupowań. M. Dash i in. (Dash *et al.*, 2001) wykorzystali wspomnianą właściwość jako czynnik dyskryminacyjny dla wyników klasyfikacji odległościowej. W pracy (Wyczałek, 2005) proponuje się zliczanie tych odrzuconych pikseli leżących wewnątrz klastrów, i w przypadku ich niewielkiego zagęszczenia (dodatkowe kryterium gęstości) sugeruje włączenie ich do tychże klastrów. Daje to efekt jednolitego wypełnienia większych fragmentów zdjęcia.

W niniejszej pracy przedmiotem zainteresowania jest możliwość połączenia dwóch klasyfikacji przeprowadzonych na wysokorozdzielczym obrazie satelitarnym. Podstawą pomiaru gęstości jest liczba pikseli przypisanych do klastrów dominujących na powierzchni określonych klas pokrycia określona w zasięgu przyjętego „promienia” wybierania.

2.2. Proponowane podejście

W pracy zaproponowano następujący algorytm klasyfikacji obrazów omawianą metodą:

1. Wstępna klasyfikacja nienadzorowana metodą K-średnich z zadaną dużą liczbą klas.
2. Ustalenie zestawu klastrów dominujących na określonej klasie pokrycia terenu.
3. Przeprowadzenie klasyfikacji gęstościowej dla przyjętego zestawu klastrów.

2.2.1. Wstępna klasyfikacja

Metoda K-średnich jest jedną z najprostszych metod klasyfikacji nienadzorowanej i cechuje się dużą szybkością obliczeń. Wymaga zadania wyjściowej liczby klas oraz liczby iteracji. W zadaniach fotointerpretacyjnych można ją opisać następującym algorytmem:

- wejście: zbiór pikseli obrazowych $\{p_i\}_{i=1..m \times n}$, liczba klastrów K ,
 wynik: zbiór definicja K klastrów
 działania: 1. Licz iteracje od $j=1$
 2. *Inicjuj* K środków klastrów: $c_k, k = 1..K$
 3. *Przypisz* każdy z pikseli p_i do najbliższego klastra
 4. *Przelicz* na nowo średnią wartość klastra: $c_k(j+1) = \text{średnia}(p_i/c_k)$
 5. to *zwiększ* ($j,1$)
 6. Jeśli nie *koniec* to *skocz* do 3.

Funkcja *koniec* porównuje przyrosty zmian między kolejnymi iteracjami oraz liczbę iteracji z przyjętymi wartościami progowymi i na tej podstawie decyduje o zakończeniu obliczeń. Efektem jest zbiór przypisań klastrów dla każdego z pikseli, który zwykle ilustrowany jest za pomocą barwnej mapy bitowej. Sugerowana wyjściowa liczba klastrów prowadzi do mniej lub bardziej szczegółowego wydzielenia poszczególnych fragmentów obrazu. Dla podanych tu potrzeb zakładam, że trzeba będzie wydzielić co najmniej 16 klas.

2.2.2. Ustalenie zestawu dominujących klastrów w ramach danej klasy

Jest to typowe zadanie wyboru danych uczących do klasyfikacji nadzorowanej. Nasz algorytm wymaga ustalenia, które klastry można zaliczyć do dominujących na danym obszarze. Przyjąłem, że takim kryterium będzie próg sumaryczny dla 2-4 najbardziej licznych klas. Wartość tego progu ustalana jest albo poprzez zliczenie punktów w próbie uczącej, albo heurystycznie ustalona wartość domyślna. Algorytm wyboru można zapisać następująco:

- wejście: zbiory pikseli w zaznaczonych próbach uczących $\{p_i\}_{i=1..m}$
 wynik: procentowy udział poszczególnych klastrów w próbach
 działania: 1. *Sumuj* piksele z poszczególnych klastrów w próbach uczących
 2. *Wyznacz* klastry dominujące: $\text{suma}(p_i, c_k) > \%dom$
 3. *Wyznacz* klastry zdominowane i *szum*: $\text{suma}(p_i, c_k) > dop$

2.2.3. Grupowanie klastrów o odpowiednim zagęszczeniu

Kryterium połączenia jest gęstość występowania pikseli zaliczonych do klastrów dominujących, zgodnie z algorytmem metody gęstościowej:

- wejście: zbiór pikseli obrazowych $\{p_i\}_{i=1..m \times n}$, klastry K
 wynik: klasa (lub klasy) wydzielona na podstawie kryterium gęstości
 działania: 1. Dla każdego piksela
 2. Jeśli *niezaklasyfikowany*
 3. i spełnia *kryterium dostępności*
 3. lub *szumu* w granicach klasy
 4. *przypisz* go do tej klasy.

Zwroty zapisane powyżej *pismem pochyłym* mają swoją informatyczną implementację w postaci algorytmicznej, a w efekcie całość przyjmuje postać programu lub procedury.

Kryterium dostępności jest odpowiednie zagęszczenie pikseli dominujących w zasięgu o przyjętym promieniu. *Szum* stanowią piksele spoza klastrów dominujących a położenie ich w *granicach klasy* sprawdzane jest w kole o określonym promieniu.

2.3. Rozwiązanie zadania w logice Automatów Komórkowych

Automat Komórkowy (*Cellular Automat - CA*) jest narzędziem, które działając w granicach zadanej przestrzeni dyskretnej dąży do przypisania poszczególnym jej fragmentom jednej z cech z danego zbioru. Zgodnie z ideą J. von Neumanna (Wolfram, 2003), o tym, jaki stan zostanie nadany komórce decyduje jej dotychczasowy stan oraz stan jej bezpośrednich sąsiadów. Zmiana stanu następuje w procesie iteracyjnym, zgodnie z określoną „regułą przejścia” (*transition rule*). Proces realizowany przez Automat kończy się po zadanej liczbie iteracji, albo po dojściu do stanu, w którym nie ma już możliwości zmiany żadnej komórki.

Automat rozpoznaje stan otoczenia za pomocą pewnego rodzaju detektora, który w projekcie J. von Neumanna składa się z czterech komórek sąsiadujących z komórką badaną, zaś jego modyfikacja zaproponowana przez Moore’a uwzględnia też komórki sąsiadujące po przekątnej (Wolfram, 2003). Komórki detektora posiadają zdolność rozpoznawania cech z określonej dziedziny. Można zatem przypisać im zdolności sensoryczne, wyrażające się pewnym stopniem uczulenia na określone kategorie stanów (komórek), a w rozszerzonej postaci także stanów środowiska. Rozpoznane wartości cech środowiska zostają użyte jako dodatkowe parametry funkcji przejścia. Automat musi więc mieć możliwość ilościowej oceny badanych cech. Wynik tej oceny jest podstawowym czynnikiem wpływającym na decyzję o zmianie stanu komórki. Niekiedy nowy stan komórki może nawet doprowadzić do zmiany wartości atrybutów środowiska, co wprowadza dodatkowy element dynamizmu do procesu przekształcania komórek.

W rozpatrywanym tu zagadnieniu klasyfikacyjnym gra odbywa się na powierzchni obrazu, z jego rastrową strukturą i wieloatrybutowym stanem oczek rastra. Po wstępnej klasyfikacji nienadzorowanej komórki zostają przypisane do poszczególnych klastrów, które dla automatów są zasadniczym źródłem informacji o cechach środowiska. Zadaniem Automatu jest takie przekształcenie własnych komórek, aby przyjęły wartość zadanej klasy albo pozostały puste. Reguła przejścia musi realizować zasady grupowania gęstościowego, przy czym zgodnie z podstawową właściwością Automatu – czynności grupujące następują w sposób iteracyjny.

3. IMPLEMENTACJA

Zaprojektowany tu Automat ma na celu wydzielenie obszarów zdrzewionych na fragmentach obrazu z satelity QuickBird poddanego wstępnej klasyfikacji nienadzorowanej metodą K-średnich. Sformułowano zatem zadanie, aby określił on warunki połączenia klastrów, a następnie te warunki zrealizował. Dla ilustracji problemu pokazano fragment

jednego z obszarów testowych i wynik jego klasyfikacji (rys. 1). Zróżnicowanie klas jest oczywistą konsekwencją bogactwa barw i cieni występujących w przyrodzie.



Rys. 1. Widok terenów zalesionych i ich otoczenia na obrazie QuickBird oraz wynik jego klasyfikacji nienadzorowanej dla zadanej liczby 16 klas


Zdefiniowano następującą procedurę decyzyjną dla Automatu:

1. Wykryj kombinację klastrów stanowiących komponenty klasy DRZEWA;
2. Jeśli w sąsiedztwie punktu $p(i,j)$ znajduje się określona liczba pikseli należących do określonych klas, to zalicz go do zbioru załączków klasy DRZEWA;
3. W kolejnych iteracjach:
 - jeśli w otoczeniu dowolnego punktu $p(i,j)$ jest odpowiednia liczba załączków, to nadaj mu rangę bezpośredniego sąsiada załączka i włącz go do klasy;
 - jeśli w otoczeniu punktu załączkowego $p(i,j)$ jest niewystarczająco mała liczba innych punktów załączkowych, to odbierz mu atrybut przynależności do klasy;
4. Powtarzaj punkt 3 aż do momentu, gdy zostanie spełniony jeden z warunków:
 - a. nie będzie istotnego przyrostu punktów dopisanych do zbioru tworzącego klasę,
 - b. proces zacznie przybierać charakter rozbieżny,
 - c. wyczerpie się zadana liczba iteracji.


Efektym działań jest pewna grupa pikseli ilustrująca na tle obrazu rozmieszczenie danej klasy pokrycia terenu, albo jej opis w konwencji wektorowej.

Wykonanie zadania wymaga zatem wcześniejszego wskazania obszarów uczących, stanowiących dla Automatu źródło niezbędnej informacji o stanie środowiska. Ponieważ zakres przestrzenny analizy zależy od wielkości i kształtu użytego detektora, przyjęto heurystycznie, że będzie to 25-elementowy kwadrat skrzyżony o 45 stopni. Detektor zlicza wartości cech wewnątrz pól uczących tak jak to ilustruje rysunek 2. Wynikiem jest ocena statystyczna określająca procentowy udział poszczególnych klastrów w granicach sensora. Wszystkie dalsze oceny wpływające na decyzje są realizowane w oparciu o ten sam kształt i uczenie sensora.

Efektom drugiej fazy algorytmu jest zbiór punktów załączkowych klasy DRZEWA, co ilustruje rysunek 3. Kolejne czynności następnej fazy odbywają się w procesie iteracyjnym, przy czym piksele włączone do klasy mogą uaktualniać statystyczną ocenę środowiska.




Rys. 2. Sensor Automatu Komórkowego podczas oceny cech środowiska



Rys. 3. Ilustracja kolejnych faz procedury decyzyjnej Automatu Komórkowego w zakresie grupowania cech; kolorem białym zaznaczono: (a) punkty załączkowe klasy DRZEWA, (b) punkty bezpośrednio dostępne przypisane do klasy, (c), (d) wynik pośredni i końcowy połączenia komórek w granicach klasy

Ukazane na rysunku 3 wyniki kolejnych faz procesu wyłaniania klasy DRZEWA, przede wszystkim zaś wynik końcowy ukazują znaczną skuteczność opisanego podejścia. Trudno dokonać tu klasycznej oceny ilościowej, gdyż pominięte miejsca w granicach klasy w znacznym stopniu odzwierciedlają otoczenie drzew lub rzucane przez nie cienie. Na pewno czyste są obiekty sportowe, ulice, tor kolejowy i jezioro, a więc obszary należące do odmiennych klas pokrycia terenu.

Podobny proces grupowania przeprowadzono na dwóch kolejnych obiektach: parku Cytadela, o dużym zróżnicowaniu elementów architektury parkowej (rys. 4) oraz skupisk drzew wokół terenów ogrodów działkowych, ulic, rzeki i łągów nadrzecznych (rys. 5).



Rys. 4. Wynik klasyfikacji nienadzorowanej (a) i ostatecznego wyłonięcia drzew (b) na obiekcie o charakterze parkowym



Rys. 5. Wynik klasyfikacji nienadzorowanej (a) i ostatecznego wyłonięcia drzew (b) na zróżnicowanych terenach zielonych z przewagą ogrodów działkowych

Na obu rysunkach, po lewej stronie ukazano obraz po klasyfikacji nienadzorowanej, a po prawej – ostateczny wynik użycia opisanej metody do wyłonięcia klasy DRZEWA. Z uwagi na zdecydowanie większe zróżnicowanie terenów problem klasyfikacyjny okazał się bardziej skomplikowany niż w pierwszym z opisywanych przypadków, a wyniki mniej jednoznaczne. Niemniej, na ostatnim obiekcie zaznaczone na białą są wysokie drzewa, przy pominięciu zieleni ogrodów działkowych, co jest zgodne z przyjętym celem klasyfikacji.

4. WNIOSKI

Wyłanianie pojedynczej klasy pokrycia terenu na obrazach teledetekcyjnych jest procesem trudnym, a więc zagrożonym większym ryzykiem nieskuteczności. Prezentowana tu metoda okazała się bardzo skuteczna wobec tego zadania. Niemniej można oczekiwać lepszych wyników w zastosowaniu jej do zagadnień wielokryterialnych, jakie występują w pełnej klasyfikacji. Prowadzone są aktualnie prace nad wdrożeniem metody Automatów Komórkowych do analiz zmian pokrycia terenu w zagadnieniach wieloczasowych.

5. LITERATURA

- 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, Netherland, s. 7-13.
- Dash M., Liu H., Xu X., 2001. '1+1>2': Merging distance and density based clustering. Database Systems for Advanced Applications. Hong Kong, China, s. 32-39.
- 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, s. 226-231.
- Wang J., Yang W., A. Rai, 1997. Color clustering technologies for color-content based image retrieval from image databases. Intern. Conf. on Multimedia Computing and System.
- Wolfram S., 2002. A new kind of science. <http://www.wolframscience.com/nksonline/toc.html>
- Wyczalek I., 2005. Teledetekcyjne wykorzystanie metody grupowania obiektów w oparciu o analizę gęstości. *Geodesia et Descriptio Terrarum*, 4(1), s. 29-40.
- 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, s. 345-348.
- DigitalGlobe. 2006: <http://www.digitalglobe.com>

Praca została wykonana w ramach grantu KBN nr 4T12E 016 26 realizowanego w latach 2004-2007.

THE USE OF DECISION-MAKING CELLULAR AUTOMATA IN THE CLASSIFICATION OF REMOTE SENSING IMAGES

KEY WORDS: classification, segmentation, consistence assessment method, Cellular Automata

Summary

Classification is one of the most often used methods for land cover detection in remote sensing applications. The classic approach is not always efficient and needs using various additional criteria or methods such as segmentation, pattern recognition, artificial intelligence, neural networks and so on.

In this paper, a new approach based on density-based clustering is presented using a method dealing with previously-classified images. The decision-making Cellular Automata has been proposed as a tool for solving this task. The iterative process of clustering has been driven by a specific transition rule of CA, with an earlier established set of states. The decision-making nature of AK arises from a criterion function typical for decision making methods, and the set of their factors and constraints.

The proposed method lies in multiplied crossing of the classified image (K-means method) by Automata at a certain shape. The task aggregate classes fulfilling defined criteria concerning density of existence, and its iterative form serves to bridge gaps and eliminate dispersed pixels which don't fulfill the threshold values of the used criterion.

The approach presented here has been verified on the example aimed at showing trees on 4-canal pan-sharpened multispectral QuickBird imagery. Three parts of a scene of enclosed urban green areas of various destinations have been chosen. Selected phases of clustering are shown in images 3, 4 and 5 containing a decreased number of tall trees. An assessment of the results shows the great potential capabilities of the method and is expected to be useful in further change detection of land cover.

Dr inż. Ireneusz Wyczałek
e-mail: ireneusz.wyczalek@put.poznan.pl
tel. +61 6652420