

**ZASTOSOWANIE METODY PARAMETRYCZNEJ W KLASYFIKACJI
OBIEKTOWEJ OBRAZU SATELITARNEGO SPOT**

**APPLICATION OF RULE-BASED APPROACH
TO OBJECT-ORIENTED CLASSIFICATION OF SPOT
SATELLITE IMAGE**

Stanisław Lewiński, Zbigniew Bochenek

Instytut Geodezji i Kartografii

SŁOWA KLUCZOWE: klasyfikacja obiektowa, SPOT, pokrycie i użytkowanie ziemi

STRESZCZENIE: W artykule przedstawione są wyniki klasyfikacji obiektowej zdjęcia satelitarne SPOT, o rozdzielczości przestrzennej 20 m. W klasyfikacji zastosowano zasady postępowania zbliżone do stosowanych w metodzie tzw. drzewa decyzyjnego. Podstawowe klasy pokrycia terenu są identyfikowane podczas sekwencji niezależnych procesów, w czasie których analizowane są obiekty jeszcze niesklasyfikowane w toku poprzednich procesów. Dodatkowo przyjęto założenie wykonania klasyfikacji bez stosowania metody Najbliższego Sąsiada (dostępnej w oprogramowaniu eCognition). Treść zdjęcia satelitarne została podzielona z zastosowaniem parametrów charakteryzujących w sposób bezpośredni obiekty. Wykorzystano również specjalnie w tym celu opracowane funkcje. Algorytm postępowania rozpoczyna się od rozpoznania klasy wody, której obiekty są definiowane w wyniku procesu wielopoziomowej segmentacji. Następnie wykonywana jest nowa segmentacja dla pozostałych klas. Z treści zdjęcia zostaje wydzielana ogólna klasa lasów a po niej zabudowa; obie klasy dzielone są później na podklasy. Pozostałe, jeszcze nierozpoznane, obiekty dzielone są na łąki i pola. W drugim etapie klasyfikacji, na podstawie już sklasyfikowanych obiektów wyłaniane są dodatkowe klasy: tereny podmokłe, działki i sady, zieleń miejska, place budów oraz zmiany w lesie. W sumie rozpoznano 13 klas. Końcowy wynik klasyfikacji został opracowany z zastosowaniem procedury generalizacji mającej na celu uzyskanie danych spełniających kryterium jednostki odniesienia o wielkości 4 ha. Całkowita dokładność klasyfikacji wyniosła ponad 89%.

1. WPROWADZENIE

Koncepcja podziału treści zdjęcia na tzw. obiekty nie jest nowa (Gonzalez i Wintz, 1977). Jednakże dopiero pojawienie się 8 lat temu na rynku oprogramowania eCognition spowodowało gwałtowny rozwój obiektowych metod klasyfikacji zdjęć satelitarnych. Nowe możliwości rozpoznania obiektów najlepiej widoczne są na przykładzie udoskonalania narzędzi, które są oferowane użytkownikom w kolejnych wersjach oprogramowania. W różnych ośrodkach naukowych podjęto prace badawcze zmierzające do utworzenia optymalnych metod klasyfikacji treści zdjęć satelitarnych z wykorzystaniem podejścia obiektowego. Prace te koncentrowały się na dwóch głównych aspektach tego podejścia: wielopoziomowej segmentacji obrazu, umożliwiającej odpowiednie określenie granic jednorodnych form pokrycia terenu oraz na wszechstronnej charakterystyce klas, uwzględniającej cechy spektralne, teksturalne,

geometrię obiektów oraz zależności zachodzące między nimi. Autorzy prac wykorzystywali do badań wieloźródłowe obrazy satelitarne (Whiteside, 2005), jak również zdjęcia wysokorozdzielcze (QuickBird, Ikonos), pozwalające na bardziej efektywne użycie cech tekstury i kształtu obiektu (Wei i in., 2005, Kressler i in., 2005). Najczęściej stosowanym klasyfikatorem była reguła Najbliższego Sąsiada (Nearest Neighbour Classifier), bazująca na wyborze reprezentatywnych pól dla poszczególnych klas pokrycia terenu (Yuan i Bauer, 2006, Hajek, 2005). W ostatnich latach, w związku z rozwojem oprogramowania eCognition, podjęto prace nad zastosowaniem nowego podejścia w klasyfikacji obiektowej, bazującego na wartościach parametrycznych wyznaczanych klas i hierarchicznej klasyfikacji metodą tzw. drzewa decyzyjnego. Na ogół działania te koncentrowały na wybranych, antropogenicznych lub naturalnych elementach pokrycia terenu (Ehlers i in., 2006, Lucas i in., 2007). Prezentowana praca wpisuje się w nurt poszukiwań nowych rozwiązań dla klasyfikacji obiektowej, stanowiąc propozycję zastosowania podejścia parametrycznego dla utworzenia mapy pokrycia terenu na podstawie obrazów satelitarnych o rozdzielczości terenowej 10–30 m.

2. TEREN BADAŃ I DANE SATELITARNE

Przedstawione w artykule metody klasyfikacji obiektowej zostały zastosowane na przykładzie wielospektralnego zdjęcia satelitarnego SPOT 4 o rozdzielczości przestrzennej 20 m. Zdjęcie zostało zarejestrowane w dniu 16 lipca 2007 roku. Przedstawia ono obszar północno-środkowej części Polski, w granicach którego znajduje się region Kujawy.

Na terenie badań podstawową formą pokrycia terenu są pola uprawne (o różnej wielkości), obok nich występują duże kompleksy łąk oraz lasów liściastych i iglastych. Ze wschodu na zachód przepływa rzeka Noteć, która łączy się kanałami z Wisłą w mieście Bydgoszcz (850,000 mieszkańców).

Przed rozpoczęciem klasyfikacji obiektowej zdjęcie satelitarne zostało wstępnie przetworzone. Polegało to na wykonaniu geometryzacji oraz korekty atmosferycznej. W czasie geometryzacji do przepróbkowania obrazu zastosowano metodę Najbliższego Sąsiada, natomiast w celu wykonania korekty atmosferycznej posłużono się algorytmem ATCOR w środowisku oprogramowania PCI Geomatica .

3. ZASADY KLASYFIKACJI

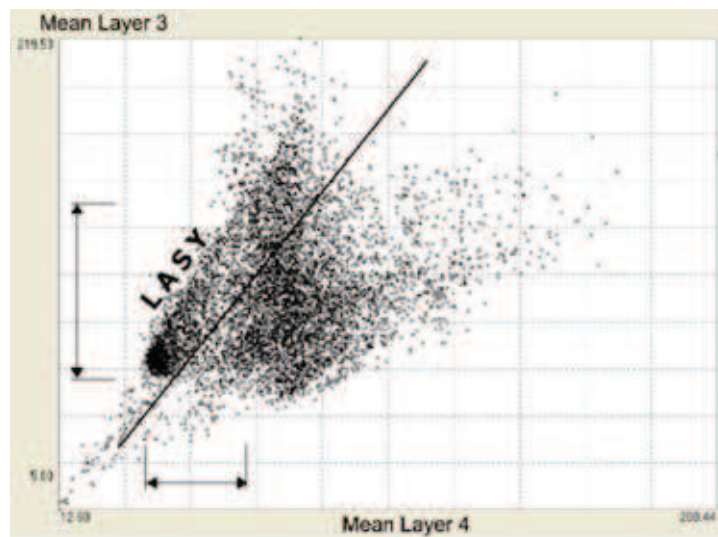
Przyjęte zasady klasyfikacji są procesem hierarchicznym. Rozpoczyna się on od rozpoznania obiektów związanych z klasą „wody”. Następnie wydzielana jest ogólna klasa lasów, zabudowy oraz klasy łąk i pól. Podział na podklasy wykonywany jest w kolejnych procesach klasyfikacyjnych. W dalszej kolejności klasyfikowane są obiekty, w rozpoznaniu których wykorzystywane są relacje zachodzące między wcześniej rozpoznanymi klasami. Są to: zieleń miejska, place budów oraz wylesienia.

Podobnie jak w przypadku każdej innej klasyfikacji obiektowej, najpierw jest wykonywana segmentacja. Zadaniem pierwszej segmentacji jest utworzenie obiektów reprezentujących tylko obiekty klasy „woda”. Jest ona wykonywana wielostopniowo wyłącznie na podstawie trzeciego kanału zdjęcia SPOT. W czasie pięciu kolejnych cykli

parametr skali przybiera wartości od 5 do 25. Przyjęty sposób postępowania pozwala na uzyskanie obiektów dobrze opisujących kształty jezior i rzek o różnej wielkości i długości. Następnie klasa „woda” rozpoznawana jest przede wszystkim z zastosowaniem wartości progowych w 3 i 4 kanale oraz z uwzględnieniem parametrów kształtu, które pomagają w identyfikacji długich koryt rzek.

Po rozpoznaniu klasy „woda” na obszarze zdjęcia reprezentowanego przez niesklasyfikowane obiekty wykonywana jest nowa segmentacja, która wykorzystana jest w rozpoznaniu pozostałych klas. Zastosowano zasadę podziału treści zdjęcia na obiekty z udziałem informacji pochodzących ze wszystkich czterech kanałów zdjęcia SPOT. Wartość parametru skali ustalono na 10.

Na podstawie nowej segmentacji najpierw wydzielana jest ogólna klasa lasów (początkowo bez podziału na podklasy). W tym celu przyjęto nietypowe rozwiązanie polegające na zdefiniowaniu klasyfikatora, którym jest równanie prostej oddzielającej obiekty lasów od pozostałych obiektów w dwuwymiarowej przestrzeni wartości odbicia w kanałach 3 i 4. Współczynniki równania prostej określone zostały na podstawie analizy graficznej tzw. *scatterplotów* 3 i 4 kanału. Taki sposób postępowania nie jest skomplikowany, wymaga jedynie umiejętnego wyboru fragmentu zdjęcia. Przykład wykresu z zaznaczoną prostą przedstawiony jest na rysunku 1. Punkty reprezentujące obiekty lasów są usytuowane powyżej prostej. Dodatkowo zastosowano wartości progowe w kanałach 1, 3 i 4.




Rys. 1. Zasada rozpoznania ogólnej klasy lasów z zastosowaniem równania prostej określonej na podstawie wykresu rozkładu średnich wartości obiektów w 3 i 4 kanale spektralnym zdjęcia SPOT

Następnie wykonano podział lasów na podklasy związane z lasem liściastym, iglastym i mieszanym. W tym celu posłużono się parametrem „*brightness*” reprezentującym średnie wartości obiektów w 1, 2, 3 i 4 kanale zdjęcia SPOT. Taki sposób podziału lasów na podklasy jest zbliżony do postępowania przedstawionego

w pracach de Kok'a i innych (2000) i Lewińskiego (2006), w których rozróżnienie klas lasów wykonano na podstawie analizy wartości obiektów w kanale panchromatycznym.

W kolejnym etapie klasyfikacji analizowana jest przynależność jeszcze niesklasyfikowanych obiektów do klas związanych z zabudową. Podobnie jak w przypadku klasy lasów najpierw definiowana jest ogólna klasa zabudowy a następnie wykonywany jest jej podział. Na podstawie przeprowadzonych prób ustalono, że podstawowym klasyfikatorem zabudowy będą wartości tekstury GLCM Contrast funkcji Haralick (Haralick i inni, 1973). Jednakże wartości tekstury nie zostały obliczone na podstawie oryginalnych danych satelitarnych, lecz na podstawie obrazu przetworzonego. Podobny sposób postępowania zaproponowany jest w pracy de Kok'a (de Kok *et al.*, 2005) w procesie klasyfikacji lasów.

Drugi kanał zdjęcia SPOT został poddany filtracji z zastosowaniem filtra krawędziowego Laplacian Edge Detector (Type 1) oprogramowania PCI Geomatica. Zastosowane przetworzenie uwydatniło krawędzie zobrazowanych obiektów zabudowy. Wynik filtracji przedstawiony jest na rysunku 2. Dodatkowo w celu zwiększenia dokładności w klasyfikacji zabudowy wykorzystano wartości funkcji GLCM Homogenity kanału 2, stosunek średnich wartości obiektów w kanałach 3 i 2 oraz wartości progowe w kanałach 2, 3 i 4. Następnie ogólna klasa zabudowy została podzielona na trzy podklasy związane z zabudową przemysłową, zwartą i rozproszoną. Podział został wykonany z zastosowaniem kryterium *ZABUD2*, którego wartość jest obliczana na podstawie 1, 2 i 4 kanału zdjęcia SPOT: $ZABUD2=10*(spot2-2*spot3+spot4)$.



Rys. 2. Przykład zastosowania filtracji Laplacian Edge Detector (Type 1) na zdjęciu SPOT obrazującym teren zabudowany

Po rozpoznaniu zabudowy sklasyfikowane są łąki, a następnie pola. W tym celu, podobnie jak w przypadku lasów, zastosowano równanie linii prostej. Zdefiniowano ją w przestrzeni średnich wartości obiektów w 4 kanałach i współczynnika NDVI. Obiekty znajdujące się powyżej tej prostej zostały zaliczone do ogólnej klasy „podobne do łąk” natomiast pozostałe obiekty (poniżej prostej) do ogólnej klasy pól uprawnych. Kolejny podział klasy „podobne do łąk” został wykonany na podstawie stosunku wartości obiektów w 3 i 4 kanałach. Uzyskano dwie klasy „łąki koszone + pola” oraz „łąki naturalne

+ pola”. Z podklasy „łąki koszone + pola”, stosując wartości progowe w kanale 4, wyłoniono końcową klasę obiektów „łąki koszone” oraz „pola bez roślinności”. Z drugiej podklasy wyłoniono „łąki naturalne” posługując się różnicą średnich wartości obiektów w kanałach 2 i 1 oraz wartościami z kanału 4. Pozostałe obiekty podklasy „łąki naturalne + pola” zostały podzielone na „pola z roślinnością” oraz na „pola bez roślinności” – zastosowano wartość progową w kanale 4.

Obiekty wstępnie sklasyfikowane jako ogólna klasa pól podzielono na dwie podklasy „pola bez roślinności” oraz „pola z pokrywą roślinną”. Podział wykonano stosując wartości progowe w 1 i w 4 kanale spektralnym.

Na tym etapie klasyfikacji rozpoznano wszystkie obiekty reprezentujące treść zdjęcia satelitarnego. Dalsze postępowanie, związane z rozpoznaniem kolejnych klas, polegało na wykonaniu reklasyfikacji już istniejących klas. Wykonano to na podstawie bezpośrednich właściwości obiektów oraz relacji występujących między nimi.

Klasa „ogrody działkowe” została wyłoniona z podklasy „pola z roślinnością” klasy pól uprawnych. Obiekty tej klasy zostały rozróżnione od pozostałych z zastosowaniem funkcji GLCM Contrast kanału 1, stosunku kanałów 3 i 4 oraz średnich wartości obiektów w kanale 4 i odchylenia standardowego w kanale 3. Wykorzystano również informację o odległości od prostej dzielącej obiekty na ogólną klasę pól i łąki w przestrzeni wartości kanału 4 i współczynnika NDVI. Zastosowanie stosunkowo dużej liczby parametrów było konieczne ze względu na spektralną niejednorodność tej klasy oraz zróżnicowanie tekstury zobrazowania, co wynika z różnego sposobu zagospodarowania działek.

Następną klasą, zdefiniowaną na podstawie już sklasyfikowanych obiektów, jest „zielenie miejskie”. Analizie poddano obiekty reprezentujące lasy, łąki oraz pola z pokrywą roślinną. Podstawowym kryterium klasyfikacyjnym był stopień otoczenia tych obiektów przez zabudowę. Warunki graniczenia z zabudową wykorzystano również w przypadku rozpoznania klasy „place budowy”, które zostały początkowo sklasyfikowane jako pola bez roślinności.

Ostatnim etapem klasyfikacji było rozpoznanie klasy „wylesienia”. W tym celu przyjęto złożony proces postępowania wymagający wykonania dodatkowej segmentacji treści zdjęcia satelitarnego. Powstała ona poniżej sklasyfikowanej warstwy obiektów, w taki sposób, aby było możliwe utworzenie a następnie zidentyfikowanie stosunkowo małych obiektów, które mogą być miejscami wyrębu lasu. Segmentację wykonano na podstawie czwartego kanału SPOT z zastosowaniem małej wartości parametru skali. Miejsca wyrębu lasu identyfikowano z uwzględnieniem założenia, że są one reprezentowane przez obiekty, które są jaśniejsze (większe średnie wartości) w kanale 3 i 4 w porównaniu z bezpośrednio otaczającymi je obiektami. Następnie wykonano reklasyfikację lasów wykorzystując relacje z warstwą, na której rozpoznano miejsca wyrębu lasów oraz małe obiekty otoczone lasem.

Na końcowym obrazie klasyfikacyjnym klasy, rozpoznane oddzielnie lecz zbliżone pod względem tematycznym, zostały połączone. Klasa „łąki” została utworzona z połączenia łąk naturalnych i łąk koszonych. Podobnie, w przypadku terenów rolniczych, połączono obiekty reprezentujące pola, z pokrywą i bez pokrywy roślinnej, w jedną klasę „pola uprawne”. W sumie uzyskano 13 klas, których zestawienie przedstawione jest w tabeli 1.

4. OPRACOWANIE I OCENA WYNIKÓW KLASYFIKACJI

Jednym z założeń wykonanej klasyfikacji było uzyskanie informacji o pokryciu i użytkowaniu ziemi o zdefiniowanym stopniu dokładności przestrzennej. W tym celu przyjęto wartość podstawowej jednostki odniesienia, wynoszącą 4 hektary, co jest równoważne 100 pikselom zdjęcia SPOT. Wielkość jednostki odniesienia nie została ustalona przypadkowo. Z punktu widzenia tradycyjnej interpretacji wizualnej 4 hektary czyli kwadrat o boku 200 m jest praktycznie najmniejszą powierzchnią, którą można wydzielić pracując w skali 1:50000; w skali mapy jest to powierzchnia o wielkości 2 x 2 mm. Wielkość jednostki odniesienia jest również uzasadniona z punktu widzenia przyjętych zasad klasyfikacyjnych, w których między innymi wykorzystywane są informacje pozyskiwane na podstawie funkcji Haralick. Wyniki tych funkcji są wiarygodne jeżeli obliczenia przeprowadzane są na podstawie odpowiednio dużej liczby pikseli. De Kok (2000) podaje, że wielkość obiektów, na podstawie których obliczana jest tekstura, powinna wynosić co najmniej 30 pikseli.

Tabela 8. Zestawienie powierzchni klas na zdjęciu SPOT po przeprowadzeniu generalizacji z zastosowaniem jednostki odniesienia 4 ha

Nr klasy	Nazwa klasy	Powierzchnia (ha)	%
1	Zabudowa zwarta	1 432.3	0.40
2	Zabudowa rozproszona	4 772.8	1.32
3	Zabudowa przemysłowa	4.6	0.001
4	Place budów	71.9	0.02
5	Zieleń miejska	561.9	0.16
6	Pola uprawne	206 097.8	57.01
7	Łąki	52 633.7	14.56
8	Działki i ogrody	1 857.3	0.51
9	Lasy iglaste	49 899.1	13.80
10	Lasy liściaste	13 487.8	3.73
11	Lasy mieszane	23 548.1	6.51
12	Wylesienia	487.6	0.13
13	Wody	6 674.6	1.85
	suma	361 529.5	100.00

Ujednolicenie stopnia szczegółowości przestrzennej wykonano z zastosowaniem generalizacji. Wynik klasyfikacji w postaci obrazu rastrowego poddano generalizacji z zastosowaniem standardowych funkcji oprogramowania PCI Geomatica. Przyjęto założenie, że grupa pikseli o jednakowych wartościach niespełniająca zadanego kryterium wielkości jest przyporządkowywana do jednej z graniczących z nią grup pikseli - do grupy, która jest najliczniejsza. Analiza wielkości grup pikseli została wykonana wielostopniowo, dzięki czemu zminimalizowano liczbę możliwych wystąpień „nielogicznych” zmian klasyfikacji. W tabeli 1 przedstawione są powierzchnie poszczególnych klas oraz ich procentowy udział w całkowitej powierzchni klasyfikowanego terenu.

Kolejnym etapem opracowania było wykonanie oceny poprawności uzyskanych wyników. Na obrazie klasyfikacyjnym, proporcjonalnie do powierzchni rozpoznanych klas, rozrzucono losowo 1400 punktów. Wyniki oceny w postaci macierzy błędów oraz uzyskanych dokładności producenta i użytkownika przedstawione są w tabeli 2.

Całkowita dokładność klasyfikacji została oceniona na poziomie 89.1%. Ze względu na liczbę rozpoznanych klas oraz wielkość powierzchni zobrazowanej na klasyfikowanym zdjęciu (ponad 3600 km²) uzyskany wynik należy uznać za dobry. Świadczy o tym również stosunkowo wysoka wartość statystyki Kappa wynosząca 0.87.

Tabela 9. Ocena klasyfikacji zdjęcia SPOT wykonana metodą punktów rozrzuconych losowo

Nr klasy *)	Dane referencyjne													suma
	1	2	3	4	5	6	7	8	9	10	11	12	13	
1	37	1	3			5								46
2		46	1			4								51
3			46											46
4		5	1	31	1	7								45
5		7		1	38									46
6		7	1			498	11		2	11	4		1	535
7						12	145			1	1			159
8					1	17	4	17			1			40
9									156	1	2	1		160
10						1	2		1	56	10	1		71
11									10	1	80		1	92
12							1		3	2	1	33		40
13								1	2				65	69
suma	37	66	52	32	40	544	164	17	174	72	100	35	67	1400

Dokładność %

producenta	100	69.7	88.5	96.9	95.0	91.5	88.4	100	89.7	77.8	80.0	94.3	97.0
użytkownika	80.4	90.2	100	68.9	82.6	93.1	91.2	42.5	97.5	78.9	87.0	82.5	94.2

Dokładność całkowita 89.1%, całkowita wartość statystyki Kappa 0.87

*) pełne nazwy klas podane są w tabeli 1

Najlepsze wyniki uzyskano dla klasy „wody”. Dokładność rozpoznania najliczniej występującej klasy „pola” wyniosła ponad 90% na podobnie dobrym poziomie zostały rozpoznane łąki. Spośród trzech klas lasów najlepsze wyniki uzyskano dla lasów iglastych. Błędy w ich rozpoznaniu wynikają przede wszystkim z błędów klasyfikacji lasów mieszanych. Pewne zastrzeżenia może budzić klasyfikacja lasów liściastych, które zostały rozpoznane poprawnie w ok. 80%. Podstawowe błędy klasyfikacyjne tej klasy związane są z zaliczeniem tej klasy do klasy „lasy mieszane” oraz „pola uprawne”. W pierwszym przypadku jest to wynik przede wszystkim nie precyzyjnej definicji lasów mieszanych, natomiast w drugim pola z pokrywą roślinną, są klasyfikowane jako las liściasty ze względu na występujące podobieństwa spektralne.

Stosunkowo dobre wyniki związane są z trzema klasami zabudowy. Omawiając je należy jednak pamiętać, że klasa zabudowy przemysłowej po generalizacji jest reprezentowana tylko przez jeden obiekt o powierzchni przekraczającej 4 hektary.

Mniejsze wydzielienia zostały przyłączone w czasie generalizacji do dwóch pozostałych klas zabudowy. Wyniki uzyskane dla zabudowy rozproszonej charakteryzują się znacznymi różnicami pod względem dokładności producenta i użytkownika. W klasyfikacji powinno być rozpoznanych więcej obiektów związanych z tą klasą.

Zadawalające wyniki uzyskano w przypadku „zieleni miejskiej” oraz „placów budów”, przy czym „placów budów” rozpoznano z nadmiarem. Również z nadmiarem rozpoznano obiekty reprezentujące „wylesienia”. Zdecydowanie najmniejszą dokładność klasyfikacji uzyskano dla klasy „działki”, mimo wysokiej dokładności producenta wynoszącej aż 100% dokładność użytkownika wynosi jedynie 42.5%. Świadczy to, że rozpoznano zbyt wiele obiektów, które w rzeczywistości nie są tą klasą. Z danych zamieszczonych w tabeli 2 wynika, że jako „działki i ogrody” zostały błędnie rozpoznane niektóre podklasy pól uprawnych. W przypadku „działek i ogrodów” zastosowane metody klasyfikacyjne okazały się niewystarczające. Jest to spowodowane przede wszystkim różnorodnością spektralną występującą w ramach tej klasy oraz rozdzielczością przestrzenną zdjęcia SPOT, która nie jest wystarczająca do poprawnego rozpoznania cech tekstury tworzonej przez stosunkowo małe obiekty.

5. PODSUMOWANIE

W artykule zaprezentowano sposób postępowania w klasyfikacji obiektowej, w którym przyjęto założenia rozpoznania obiektów (utworzonych w czasie segmentacji) tylko z zastosowaniem wartości parametrów, całkowicie rezygnując z metody Najbliższego Sąsiada. Stosując narzędzia oprogramowania eCognition (ver. 5), w kolejnych procesach, rozpoznawane są klasy pokrycia i użytkowania ziemi. Podobnie jak w przypadku algorytmów drzewa decyzyjnego klasy są rozpoznawane stopniowo w kolejnych etapach (procesach) klasyfikacyjnych. Najpierw identyfikowane są tzw. klasy ogólne: wody, lasy, zabudowa, łąki i pola. Później wykonywany jest podział na podklasy, a następnie kolejne klasyfikacje z wykorzystaniem relacji, które zachodzą między już rozpoznanymi obiektami.

Nowością w przyjętym sposobie klasyfikacji jest zastosowanie, obok wartości progowych parametrów opisujących obiekty, klasyfikatorów zdefiniowanych na podstawie równań prostych. Dzięki nim wykonywany jest podział obiektów na klasy w dwuwymiarowej przestrzeni cech. Współczynniki równań określane są na podstawie analizy wizualnej tzw. scatterplotów.

Zastosowane metody pozwoliły na uzyskanie obrazu klasyfikacyjnego, którego poprawność została oceniona na poziomie 89%. Wynik ten należy ocenić jako bardzo dobry. Analizie poddano nie wybrany fragment, lecz całą scenę zdjęcia SPOT o wymiarach 60 x 60 km. Na tak dużej powierzchni zawsze mogą, w ramach poszczególnych klas, występować struktury form pokrycia terenu, charakteryzujące się odmiennymi parametrami w ramach poszczególnych klas tematycznych.

Przedstawiony sposób postępowania został zastosowany nie tylko na przykładzie jednego zdjęcia satelitarnego. Zgodnie z opracowanymi założeniami opracowano jeszcze dwa inne zdjęcia SPOT. Zdjęcia te obrazowały zachodnią i wschodnią część Polski, które różnią się zasadniczo pod względem stopnia rozdrobnienia form pokrycia terenu; zachodnia część kraju charakteryzuje się występowaniem dużych kompleksów pól uprawnych. W obu przypadkach, w celu uzyskania poprawnej klasyfikacji niezbędna

była modyfikacja wartości parametrów identyfikujących poszczególne klasy w tym również współczynników równań prostych, co jednak nie spowodowało zmiany ustalonych zasad. Za każdym razem uzyskano zadawalające wyniki końcowe. Całkowita dokładność klasyfikacji została oceniona na poziomie 90%, co świadczy o zasadności przyjętych założeń.

„Praca naukowa finansowana ze środków na naukę w latach 2006-2008 jako projekt badawczy”

6. LITERATURA

De Kok R., Buck A., Schneider T., Ammer U., Baatz M., 2000. Data fusion with Landsat 7 imagery. *STROBL, J. et al. (Hrsg), Angewandte Geographische Informationsverarbeitung XII, Beiträge zum AGIT-Symposium Salzburg 1999*, Karlsruhe, s. 90-97.

De Kok R., Koziol K., Wezyk P., 2005. Zastosowanie klasyfikacji obiektowej wysokorozdzielczych obrazów teledetekcyjnych oraz analiz przestrzennych GIS w kartowaniu drzewostanów. *Roczniki Geomatyki*, t. 3, z. 4, s. 99-108.

Ehlers, M., U. Michel, G. Bohmann and D. Tomowski, 2006. Decision based data fusion techniques for the analysis of settlement areas from multisensor satellite data. *Proceedings of ASPRS 2006 Annual Conference, Reno, Nevada; May 1-5, 2006*.

Gonzalez R. C., Wintz P., 1977. *Digital image processing*. Addison-Wesley Publishing Company.

Hajek, F. 2005. Object-oriented classification of remote sensing data for the identification of tree species composition. *Proceedings of ForestSat 2005 conference, May 31 - June 3, 2005, Borås, Sweden*.

Haralick R. M., Shanmugan K., Dinstein I., 1973. Textural Features for Image Classification. *IEEE Transactions on Systems, Man and Cybernetics*, Vol. SMC-3, No.6, s. 610-621.

Kressler, F.P., K. Steinnocher and Y.S. Kim, 2005. Enhanced Semi-Automatic Image Classification of High-Resolution Data. *Proceedings of the IGARSS 2005 Symposium. Seoul, Korea. July 25-29, 2005*.

Lewinski St., 2006. Land use classification of ASTER image – Legionowo test site. *Proceedings of the 25th Symposium of the European Association of Remote Sensing Laboratories, Porto, Portugal, 6-9 June 2005*, s. 441-447.

Lucas R., Rowlands A., Brown A., Keyworth S., Bunting P., 2007. Rule-based classification of multi-temporal satellite imagery for habitat and agricultural land cover mapping. *ISPRS Journal of Photogrammetry and Remote Sensing, Volume 62, Issue 3, August 2007*, s. 165-185.

Wei, W., X. Chen and A. Ma, 2005. Object-oriented Information Extraction and Application in High-resolution Remote Sensing Image. *Proceedings of the IGARSS 2005 Symposium. Seoul, Korea. July 25-29, 2005*.

Whiteside, T., 2005. A multi-scale object-oriented approach to the classification of multi-sensor imagery for mapping land cover in the top end. *Proceedings of NARGIS 2005 – Application in Tropical Spatial Science. 4th - 7th July 2005 Charles Darwin University, Darwin, NT, Australia*.

Yuan, F., Bauer M.E., 2006. Mapping impervious surface area using high resolution imagery: A comparison of object-based and per pixel classification. *Proceedings of ASPRS 2006 Annual Conference, Reno, Nevada; May 1-5, 2006.*

APPLICATION OF RULE-BASED APPROACH TO OBJECT-ORIENTED CLASSIFICATION OF SPOT SATELLITE IMAGE

KEY WORDS: object-oriented classification, SPOT, land use, land cover word

Summary

The paper presents results of object-oriented classification of whole 20-meter resolution SPOT scene covering the Kujawy region.

The classification approach applied in this work was similar to that used in the so-called decision tree method. The main land cover classes were identified in a sequence of independent processes, assuming that each subsequent process deals solely with objects not classified yet. Another assumption was to implement rule-based approach rather than the Standard Nearest Neighbor classifier (available in eCognition software). In this approach, contents of satellite image were characterized by various spectral/texture parameters directly describing individual land cover/land use classes; in addition, by pre-defined functions, determined on the basis of graphical analysis of feature space constructed for particular terrain objects were used.

The classification process begins with recognition of water class the objects of which were delineated using multiresolution segmentation. New segmentation is prepared for the remaining land cover classes. Subsequently, the general forest class and the urban class are discriminated; at the next stage, both classes are divided into sub-categories. Consequently, broad agricultural and grassland classes are determined. At the second stage of classification, more detailed classes are discriminated within the general land cover categories: wetlands, orchards, urban green areas, construction sites, and deforestations. Overall, 13 land cover/land use categories were discriminated in the work presented. The final classification map was prepared using the aggregation procedure to obtain a map resolution fulfilling the 4ha size of Minimum Mapping Unit. The accuracy was assessed using the method of randomly distributed points; the number of points assigned to each class for checking was proportional to the acreage of that class. The overall accuracy of all classes checked in the verification process reached 89%.

The method presented was applied to two other test sites in Poland: the regions of Podlasie and Wielkopolska. Despite differences in land cover/land use patterns, both regions were classified with a comparable, high accuracy.

dr hab. inż. Stanisław Lewiński
e-mail: stanislaw.lewinski@igik.edu.pl
tel. 0 22 3291976

dr inż. Zbigniew Bochenek
e-mail: zbigniew.bochenek@igik.edu.pl
tel. 0 22 3291977