

## **PORÓWNANIE KLASYFIKACJI OBIEKTOWEJ Z TRADYCYJNĄ KLASYFIKACJĄ PIKSELOWĄ Z PUNKTU WIDZENIA AUTOMATYZACJI PROCESU TWORZENIA BAZY DANYCH O POKRYCIU I UŻYTKOWANIU TERENU**

### **COMPARISON OF OBJECT-ORIENTED CLASSIFICATION TO TRADITIONAL PIXEL-BASED CLASSIFICATION WITH REFERENCE TO AUTOMATION OF THE PROCESS OF LAND COVER AND LAND USE DATA BASE CREATION**

**Stanisław Lewiński**

Institut Geodezji i Kartografii

**Słowa kluczowe: klasyfikacja obiektowa, klasyfikacja pikselowa, użytkowanie ziemi, pokrycie terenu, Landsat ETM+**

Keywords: object oriented classification, pixel based classification, land use, land cover, Landsat ETM+

### **Wstęp**

Klasyfikacja obiektowa jest stosunkowo nową techniką klasyfikacji zdjęć satelitarnych, która w najbliższym czasie może zastąpić tradycyjne tzw. pikselowe metody klasyfikacji, dlatego też interesujące jest wykonanie porównania nowej metody z dotychczas stosowanymi. W tym celu na przykładzie tego samego terenu badań oraz danych satelitarnych wykonano dwie klasyfikacje form pokrycia i użytkowania ziemi: obiektową i tradycyjną pikselową. W obu przypadkach uzyskane wyniki poddano generalizacji w celu uzyskania informacji o zadanym stopniu szczegółowości: 1 ha dla zabudowy i wód oraz 4 ha dla pozostałych klas. Klasyfikowano to samo zdjęcie satelitarne Landsat ETM+ zarejestrowane 7 maja 2000 r., obrazujące teren badań o powierzchni 423 km<sup>2</sup>, zlokalizowany na Nizinie Mazowieckiej w pobliżu Warszawy. W jego centralnej części, między rzekami Wisłą i Narwią, znajduje się miasto Legionowo.

### **Klasyfikacja obiektowa**

Klasyfikacja obiektowa została wykonana z zastosowaniem oprogramowania eCognition. Sposób jej wykonania oraz analiza wyników przedstawiona jest w artykule „Rozpoznanie

form pokrycia i użytkowania ziemi na zdjęciu satelitarnym Landsat ETM+ metodą klasyfikacji obiektowej” (Lewiński, 2006a).

W czasie klasyfikacji obiektowej przebadano przydatność danych wielospektralnych i panchromatycznych (po korekcji atmosferycznej) zdjęcia Landsat ETM+ oraz kanałów PanSharp2, PanSharp3 i PanSharp4 uzyskanych w wyniku połączenia (*data fusion*) kanału panchromatycznego z 2., 3. i 4. kanałem wielospektralnym. Połączenie danych zostało wykonane z zastosowaniem algorytmu PanSharp autorstwa dr. Zhang’a (Zhang, 1999; 2002), stanowiącego jeden z modułów oprogramowania PCI Geomatica. Połączone dane zastosowano w procesie segmentacji, natomiast w rozpoznaniu klas wykorzystano oryginalne dane wielospektralne i panchromatyczne.

Na terenie badań, stosując standardową metodę najbliższego sąsiada oraz kryteria parametryczne, rozpoznano 18 klas pokrycia i użytkowania ziemi. Wynik klasyfikacji obiektowej został następnie opracowany z zastosowaniem algorytmu (Lewiński, 2005; 2006b), którego celem było uzyskanie bazy danych pokrycia i użytkowania ziemi o stopniu szczegółowości 1 ha dla klas związanych z zabudową i wodami oraz 4 ha dla pozostałych klas. Dane klasyfikacyjne zostały zgeneralizowane a następnie na ich podstawie utworzono wektorową bazę danych, w której granice wydzielen zostały wygładzone w taki sposób, aby były zbliżone do wyniku interpretacji wizualnej. Kolejnym etapem opracowania było sprawdzenie klasyfikacji metodą interpretacji wizualnej, w czasie której interpretator korygował kody oraz kształt wydzielen. Wynik interpretacji został wykorzystany do oceny dokładności klasyfikacji oraz do utworzenia końcowej, skorygowanej bazy danych.

W wyniku przeprowadzonej generalizacji zmianie uległo jedynie 1,1% powierzchni terenu badań, co świadczy o odpowiednim doborze parametrów segmentacji. Przeprowadzona weryfikacja pozwoliła na ocenę dokładności klasyfikacji, która w całościowej ocenie wyniosła 94,54% przy równoczesnej wysokiej wartości statystyki  $K_{HAT}$  wynoszącej 93,76% (Congalton, 1991).

W prezentowanej pracy końcowa baza danych (po weryfikacji metodą wizualną) została wykorzystana jako poziom odniesienia w ocenie tradycyjnej klasyfikacji pikselowej.

## Klasyfikacja pikselowa

Klasyfikacja pikselowa została wykonana na przykładzie identycznych danych jak w przypadku klasyfikacji obiektowej. W tym celu zastosowano tzw. algorytm klasyfikacji hybrydowej (Image Analyst, 2002) składającej się z dwóch części: z klasyfikacji nadzorowanej oraz nienadzorowanej. Najpierw na podstawie zdefiniowanych przez operatora pól treningowych wykonywana jest klasyfikacja nadzorowana, następnie piksele niesklasyfikowane są ponownie klasyfikowane metodą nienadzorowaną. Taki sposób postępowania przyjęto ze względu na specyfikę terenu badań, który charakteryzuje się dużym rozdrobnieniem form pokrycia terenu. W wielu przypadkach utrudnia to, a nawet uniemożliwia, określenie reprezentatywnych pól treningowych.

W przypadku obu klasyfikacji stosowano algorytm klasyfikacyjny największego prawdopodobieństwa; w klasyfikacji nienadzorowanej charakterystyki klas spektralnych określono z zastosowaniem algorytmu *Competitive training*.

Pierwszym etapem klasyfikacji nadzorowanej jest wybór pól treningowych. Następnie na ich podstawie określone są charakterystyki spektralne poszczególnych klas oraz optymalny zestaw kanałów zdjęcia, na podstawie których można uzyskać najlepsze wyniki.

Przeprowadzone analizy pozwoliły na określenie pól treningowych 8 klas: zabudowa, grunty orne z pokrywą roślinną, grunty orne bez pokrywy roślinnej, łąki, las liściasty, las iglasty, osadniki oraz wody. Mimo podjętych prób nie udało się zdefiniować większej liczby klas związanych z zabudową. Klasa „grunty orne z pokrywą roślinną” reprezentuje uprawy ozime, które w wiosennym okresie rejestracji zdjęcia w znacznym stopniu pokrywają już powierzchnię ziemi, w późniejszym etapie klasyfikacji klasa ta została połączona z klasą „grunty orne bez pokrywy roślinnej”, związaną głównie z uprawami jarymi, tworząc w ten sposób jedną klasę gruntów ornych. Zrezygnowano z określenia pól treningowych dla klasy lasów mieszanych, które przy ręcznym sposobie zaznaczenia reprezentatywnych obszarów na kompozycji barwnej zdjęcia zawsze prowadzą do błędów, związanych z rozpoznaniem zmieszanych drzew liściastych i iglastych. W polach treningowych uwzględniono nieliczną lecz rozpoznawalną klasę osadników.

Na rysunku 1 przedstawiono wykresy rozkładu wartości pikseli pól treningowych (*scatter plot*), dla par kanałów spektralnych 5 i 4, 4 i 3 oraz 2 i 5. Na wykresach zaznaczono średnie wartości pól treningowych klas oraz elipsy reprezentujące zasięgi wartości. Na ich podstawie można stwierdzić, że najlepiej odseparowanymi klasami od innych są „wody”, „las iglasty” oraz „osadniki”. Wyraźnie widoczna jest bliskość spektralna łąk i gruntów ornych z uprawami ozimymi, które są najlepiej rozróżnialne na wykresie kanałów 2 i 5. Na wszystkich wykresach klasą najmniej oddaloną od pozostałych jest „zabudowa”.

Na podstawie pól treningowych wykonano porównanie przydatności w procesie klasyfikacji kanału panchromatycznego PAN oraz kanałów PanSharp2, PanSharp3 i PanSharp4, uzyskanych w wyniku połączenia kanału panchromatycznego z 2., 3. i 4. kanałem danych wielospektralnych, porównując je z odpowiadającymi im kanałami wielospektralnymi. W tym celu posłużono się średnimi wartościami odległości między klasami w przestrzeni spektralnej: euklidesową oraz odległością J-M (Jeffreys-Matusita) (Jensen, 1996), obliczonymi między polami treningowymi dla poszczególnych kanałów. Obliczono je oddzielnie dla poszczególnych kanałów na podstawie pól treningowych wszystkich klas.

Odległość J-M, w przeciwieństwie do odległości euklidesowej, nie jest informacją jedynie o odległości między środkami klas, lecz uwzględnia również stopień ich rozproszenia. Przyjmuje ona wartości z przedziału  $< 0, 2 >$ , wartość maksymalna 2 świadczy o całkowitej rozdzielności klas natomiast wartości poniżej 1,4 świadczą o braku rozdzielności klas (Image Analyst, 2002).

W ocenie możliwości klasyfikacyjnych poszczególnych kanałów wykorzystano również całkowitą i średnią dokładność klasyfikacji pól treningowych, wykonaną metodą

**Tabela 1.** Porównanie średnich odległości euklidesowych, odległości J-M oraz dokładności klasyfikacji pól treningowych w poszczególnych kanałach zdjęcia Landsat ETM+

Kanał	Odległość		Dokładność klasyfikacji	
	euklidesowa	J-M	średnia	całkowita
Pan	28,76	1,55	68,28	66,88
1	13,23	1,45	58,71	64,35
2	21,82	1,72	79,59	83,86
3	28,67	1,57	61,98	67,22
4	46,53	1,51	68,03	66,36
5	50,08	1,81	84,45	90,34
6	27,88	1,47	63,62	65,21
7	41,88	1,69	75,79	80,26
PanSharp 2	28,26	1,51	56,99	66,55
PanSharp 3	21,62	1,65	73,90	79,25
PanSharp 4	45,61	1,42	63,15	61,56

największego prawdopodobieństwa. W tabeli 1 przedstawiono ocenę możliwości klasyfikacyjnych analizowanych kanałów. Zawiera ona średnie wartości odległości między klasami oraz dokładność klasyfikacji pól treningowych. Jak widać, na podstawie kanałów PanSharp2 i PanSharp4 nie uzyskano lepszych rezultatów w porównaniu z kanałami 2 i 4, natomiast na podstawie kanału PanSharp3 można uzyskać lepszą rozróżnialność klas w porównaniu z kanałem 3. Największe zróżnicowanie między klasami związane jest z kanałami 2, 5 i 7. Na podstawie kanału panchromatycznego uzyskano rezultaty na poziomie kanału 2 i 4.

Zestaw optymalnych kanałów pozwalający na najlepsze rozróżnienie pól treningowych, określono stosując średnią wartość transformowanej dywergencji (Jensen, 1996). Na jej podstawie wybrano kanały 2, 3, 4, 5 i 7 zdjęcia Landsat ETM+.

Klasyfikacja nadzorowana została wykonana na podstawie zdefiniowanych pól treningowych oraz 5 wybranych kanałów z zastosowaniem metody największego prawdopodobieństwa. Pierwsza klasyfikacja wykazała występowanie na obrazie klasyfikacyjnym zdecydowanie zbyt dużej liczby pikseli klasy „zabudowa”. Modyfikacja pól treningowych oraz zastosowanie bardzo niskiego współczynnika wagowego dla tej klasy nie wpłynęło na zadawalającą poprawę wyników. Dlatego też podjęto decyzję o rezygnacji na tym etapie klasyfikacji z klasy „zabudowa” i ponownie wykonano klasyfikację na podstawie pól treningowych pozostałych 7 klas. W sumie sklasyfikowano 14 852 ha co stanowi 35% powierzchni terenu badań, pozostała część terenu badań została sklasyfikowana w drugim etapie klasyfikacji hybrydowej.

Drugi etap polegał na wykonaniu klasyfikacji nienadzorowanej pikseli dotychczas niesklasyfikowanych. Parametry klas spektralnych zostały określone z zastosowaniem algorytmu Competitive Training (Image Analyst, 2002; Hung, 1993). Automatycznie zdefiniowano 15 klas spektralnych i wykonano klasyfikację z zastosowaniem metody największego prawdopodobieństwa. Następnie klasy spektralne pogrupowano w klasy tematyczne. W sumie utworzono 6 klas tematycznych. Cztery z nich odpowiadały klasom klasyfikacji nadzorowanej: „grunty orne”, „łąki”, „las liściasty” i „wody”. Utworzono też dwie nowe klasy nierozpoznane poprzednio: „zabudowa” i „las mieszany”.

Końcowy etap klasyfikacji hybrydowej polegał na połączeniu klasyfikacji nienadzorowanej z nadzorowaną. Obraz wynikowy klasyfikacji hybrydowej przedstawiony jest na rysunku 2.

Podobnie jak w przypadku klasyfikacji obiektowej (będącej poziomem odniesienia) wynik klasyfikacji pikselowej poddano generalizacji. Wykonano ją według takich samych zasad jak w przypadku klasyfikacji obiektowej, przyjmując wielkość pola odniesienia 1 ha dla klasy „zabudowa” i „wody” oraz 4 ha dla pozostałych klas. Uzyskane wyniki przedstawiono w zbiorczej tabeli 2. Zamieszczono w niej powierzchnie poszczególnych klas przed i po generalizacji, ich procentowy udział w powierzchni terenu badań oraz wielkość zmian.

Uzyskane wyniki generalizacji świadczą o dużym rozdrobieniu klas. Powierzchnia zabudowy zmalała aż o 32% natomiast powierzchnia łąk wzrosła o ponad 19%. Klasa „grunty orne” uległa zmniejszeniu o 7%, podobnie stało się w przypadku klasy „las liściasty”, natomiast powierzchnia wód zwiększyła się o 5,8%. Najbardziej stabilnymi klasami okazały się „las iglasty” i „las mieszany”. W wyniku generalizacji przestała istnieć najmniej liczna klasa „osadniki”. Jednym z pozytywnych rezultatów jest zmniejszenie liczby terenów niesklasyfikowanych aż o 80% co oznacza, że po generalizacji zajmują one jedynie 0,46% powierzchni obszaru badań.

Dane przedstawione w tabeli 2 są jedynie danymi ilościowymi. W celu uzyskania informacji jakościowej związanej z porównaniem klasyfikacji przed i po generalizacji wykonano

**Tabela 2.** Wyniki klasyfikacji hybrydowej przed i po generalizacji

Klasa	Klasyfikacja hybrydowa		Generalizacja		Zmiany <sup>1</sup>		
	ha	%	ha	%	ha	%	
1	Zabudowa	2494,91	5,89	1683,34	3,97	-811.57	-32.53
2	Grunty orne	8026,02	18,94	7453,98	17,59	-572.04	-7.13
3	Łąki	11929,37	28,15	14243,42	33,60	2314.05	19.40
4	Las liściasty	3433,48	8,10	3160,67	7,46	-272.81	-7.95
5	Las iglasty	4330,24	10,22	4326,86	10,21	-3.38	-0.08
6	Las mieszany	8748,41	20,64	8735,38	20,61	-13.03	-0.15
7	Osadniki	3,46	0,01	0,00	0,00	-3.46	-100.00
8	Wody	2446,16	5,77	2588,13	6,11	141.97	5.80
9	Niesklasyfikowane	973,01	2,30	193,28	0,46	-779.73	-80.14
Suma		42385,06	100,00	42385,06	100,00		

<sup>1</sup> zmiany – porównanie klasyfikacji hybrydowej przed i po generalizacji.

porównanie wartości poszczególnych pikseli klasyfikacji. Największą zgodność danych uzyskano dla klas „wody” 93,3% oraz „zabudowa” 86,3%, Natomiast najniższą, wynoszącą jedynie 67,0% uzyskano dla klasy „łąki”. Niska zgodność wystąpiła również w przypadku klas: „las mieszany” 70,8%, „grunty orne” 72,7% oraz „las liściasty” 73,8%. Uzyskane wyniki świadczą o dużym stopniu rozdrobnienia tych klas w porównaniu z przyjętymi parametrami generalizacji. Całkowity stopień zgodności wynosi jedynie 73,3% co oznacza, że na 26,7% powierzchni terenu badań nastąpiła zmiana wyników klasyfikacji (w przypadku klasyfikacji obiektowej zmiany nastąpiły jedynie na 1,1% terenu badań).

Obraz klasyfikacji po generalizacji przedstawiono na rysunku 3. Wyraźnie widoczna jest zmiana stopnia szczegółowości klasyfikacji terenu badań w porównaniu z danymi klasyfikacyjnymi (rys. 2). Dodatkowo na przykładzie Kanału Zegrzyńskiego łączącego Zalew Zegrzyński z Wisłą widoczne jest w kilku miejscach przerwanie dobrze zdefiniowanej struktury liniowej kanału.

Na przebieg generalizacji wpływ mają również typowe błędy klasyfikacji pikselowej, polegające na przyporządkowywaniu tzw. pikseli brzegowych występujących na granicach lasów oraz pikseli związanych z ciągami komunikacyjnymi do klasy „zabudowa”. W wielu przypadkach konsekwencją błędnej klasyfikacji pojedynczych pikseli jest przerwanie ciągłości klas i ich generalizacja, jeżeli powierzchnia grup pikseli jest mniejsza od założonego pola odniesienia. Zmiany w wyniku generalizacji są zbyt duże, aby taki sposób postępowania mógł być stosowany w celu uzyskania wiarygodnej bazy danych o pokryciu i użytkowaniu ziemi o stopniu szczegółowości 4 ha.

## Ocena klasyfikacji

Ocena dokładności klasyfikacji pikselowej została wykonana przez porównanie jej z klasyfikacją obiektową. Porównano zgeneralizowany wynik klasyfikacji hybrydowej z klasyfi-

kacją obiektową uwzględniającą zmiany wprowadzone przez interpretatora w czasie weryfikacji metodą wizualną. W celu uzyskania miarodajnych wyników porównania należało rozwiązać problem różnej liczebności klas rozpoznanych w obu klasyfikacjach. Wymagało to wykonania agregacji wybranych klas klasyfikacji obiektowej z 18 do 7. Łącząc klasy kierowano się przede wszystkim charakterystykami spektralnymi oraz dodatkowo w przypadku nielicznie występujących klas zastosowano kryterium tematyczne. Z czterech klas „obiektywych” zabudowy (1121, 1122, 1223 i 121) oraz klasy „uprawy szklarniowe (2113) utworzono klasę „zabudowa”. Klasa „place budów” (133) oraz „plaże” (3311) zostały dołączone do klasy „grunty orne wieloblokowe” (21111), z której utworzono klasę „grunty orne”. Nieliczna klasa „miejskie tereny zielone” (141) oraz „lasy i roślinność krzewiasta w stanie zmian” (324) została dodana do „łąk” (231), natomiast „osadniki” (1322) dodano do klasy „woda” (51). Klasy „las liściasty” (311), „las iglasty” (312) oraz „las mieszany” (313) nie wymagały agregacji i pozostały niezmienione. Dwie pozostałe klasy klasyfikacji obiektowej; „grunty orne drobnoblokowe” (21112) oraz „tereny z dużym udziałem roślinności naturalnej” (243) ze względu na swój charakter nie pozwoliły na wykonanie agregacji do klas klasyfikacji pikselowej, gdyż obie te klasy nie są klasami jednorodnymi spektralnie. Pierwsza z nich reprezentuje tzw. mozaikową strukturę upraw, w granicach której występują drobne struktury gruntów ornych oraz łąk. Druga związana jest głównie z łąkami, jednakże w jej granicach występują również małe wydzielenia pól, lasów oraz wody. W obu przypadkach wydzielenie występujących podklas jest niemożliwe, równocześnie klasy te zajmują znaczącą powierzchnię terenu badań i mają wpływ na ocenę porównywanej klasyfikacji. W celu rozwiązania tego problemu przyjęto dwa sposoby postępowania. W pierwszym założono, że wszystkie klasy klasyfikacji pikselowej rozpoznane na obszarze klas 21112 i 243 są rozpoznane prawidłowo. Taki sposób postępowania z oczywistych względów powoduje wzrost dokładności ocenianej klasyfikacji. Drugi sposób postępowania polegał na pominięciu tych

obszarów w czasie analizy porównawczej. Uzyskane wyniki przedstawione są w tabeli 3.

Zgodnie z przewidywaniami większą dokładność klasyfikacji pikselowej uzyskano w przypadku oceny wykonanej metodą 1 z założeniem poprawnego rozpoznania obszarów związanych z klasami klasyfikacji obiektowej 21112 i 231; wynosi ona 72%. W metodzie 2, nie uwzględniając tych klas w ocenie, uzyskujemy znacznie mniejszą dokładność całkowitą na poziomie 61%. W obu przypadkach uzyskano również niskie wartości statystyki  $K_{HAT}$ ; odpowiednio 0,66 i 0,54%. Bez względu na przyjęty sposób oceny naj-

**Tabela 3.** Ocena klasyfikacji pikselowej po generalizacji, porównanie z klasyfikacją obiektową po agregacji klas

Klasa klasyfikacji pikselowej	Dokładność			
	metoda 1 <sup>1</sup>		metoda 2 <sup>2</sup>	
	producenta	użytkownika	producenta	użytkownika
Zabudowa	23,94	77,53	21,10	74,57
Grunty orne	97,22	71,55	88,28	35,13
Łąki	90,56	78,80	81,69	63,34
Lasy liściaste	77,77	67,56	71,23	59,58
Lasy iglaste	49,86	97,85	49,55	97,83
Lasy mieszane	77,60	44,99	71,51	37,20
Wody	92,33	96,24	92,15	96,15
Dokładność całkowita	72,45%		61,23%	
$K_{HAT}$	0.66%		0.54%	

<sup>1</sup> Założenie poprawnej klasyfikacji klas obiektowych 21112 i 243 w klasyfikacji pikselowej.

<sup>2</sup> Pominięcie w ocenie powierzchni klas obiektowych 21112 i 243.

niższą dokładność, świadcząca o dużym niedoszacowaniu, uzyskano dla klasy „zabudowa” oraz dla klasy „lasy mieszane”, które zostały przeszacowane. Natomiast wyniki uzyskane dla klasy „lasy iglaste” są prawie jednakowe. Stosując pierwszą metodę stosunkowo dobre wyniki (w porównaniu z innymi klasami) uzyskano dla klas „grunty orne” i „łąki”. Jedynie zgodność klasy „wody” nie może budzić zastrzeżeń.

Podsumowując – uzyskano wyniki świadczące o bardzo niskiej dokładności klasyfikacji pikselowej w porównaniu z klasyfikacją obiektową.

## Zakończenie

Prace związane z porównaniem klasyfikacji obiektowej i tradycyjnej są wykonywane na świecie i prowadzą do podobnych wniosków. Oruc z zespołem (2004) na przykładzie zdjęcia Landsat ETM, obrazującego teren badań o charakterze przemysłowo-rolniczym w Turcji, stosując klasyfikację nienadzorowaną ISODATA z algorytmem klasyfikacyjnym największego prawdopodobieństwa rozpoznał 7 klas pokrycia i użytkowania ziemi i uzyskał całkowitą dokładność na poziomie 66,8% i 81,3% dla klasyfikacji obiektowej. Różnica wyniosła 14,5%. Również na przykładzie zdjęć Landsat ETM i też z zastosowaniem klasyfikacji ISODATA na poligonie zlokalizowanym w zurbanizowanej okolicy Huntsville (Stan Alabama) rozpoznano 9 klas z dokładnością 80,2% oraz 89,4% w przypadku klasyfikacji obiektowej (Tadesse i in., 2003). Whitesido i Ahmad (2005) wykonali porównanie możliwości klasyfikacyjnych na zdjęciu satelitarnym ASTER. Na terenie Parku Narodowego Litchfield w północnej Australii rozpoznali 10 klas, dla których uzyskali dokładność 69% metodą pikselowej klasyfikacji nadzorowanej, natomiast klasyfikacja obiektowa została oceniona na poziomie 78%.

W przytoczonych publikacjach porównanie klasyfikacji zawsze było wykonane na przykładzie jednakowej liczby klas bez względu na sposób klasyfikacji. Świadczy to o niewykorzystaniu pełnych możliwości klasyfikacji obiektowej. Pominięto również zagadnienie generalizacji, która jest związana nierozdzielnie z tworzeniem baz danych na podstawie zdjęć satelitarnych.

Prezentowane w tym artykule wyniki badań świadczą o tym, że klasyfikacja obiektowa w przeciwieństwie do tradycyjnych technik klasyfikacji pikselowej może być wykorzystana do tworzenia wektorowych baz danych o pokryciu i użytkowaniu ziemi, takich jak, w przypadku tradycyjnej metody interpretacji wizualnej.

## Literatura

- Congalton R.G., 1991: A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, vol. 37, pp. 35-46.
- Hung C-C., 1993: Competitive learning networks for unsupervised training. *Int. J. Remote Sensing*, vol. 14, no. 12, pp. 2111-2115.
- Image Analyst 2002: User Guide. Z/I Imaging.
- Jensen J.R., 1996: *Introductory digital image processing, a remote sensing perspective*. Second edition. Prentice Hall, Upper Saddle River, New Jersey.
- Lewiński St., 2005: Klasyfikacja obiektowa narzędziem wspomagającym proces interpretacji zdjęć satelitarnych. *Polskie Towarzystwo Informatyki Przestrzennej, Roczniki Geomatyki*, t. III, z. 2, s. 97-106. Warszawa.
- Lewiński S., 2006a: Rozpoznanie form pokrycia i użytkowania ziemi na zdjęciu satelitarnym Landsat ETM+ metodą klasyfikacji obiektowej. *Polskie Towarzystwo Informatyki Przestrzennej, Roczniki Geomatyki*, tom IV, z. 3, s. 139-150. Warszawa.

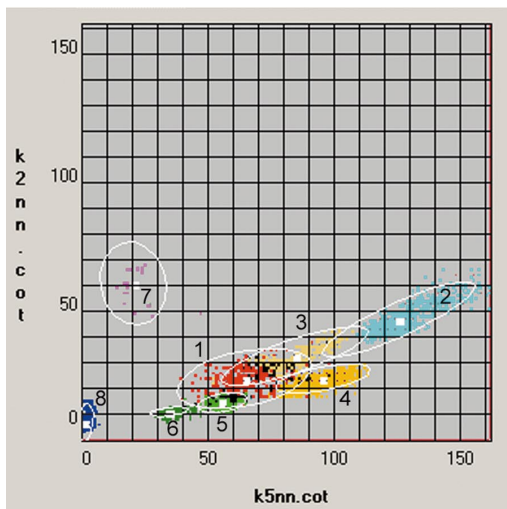

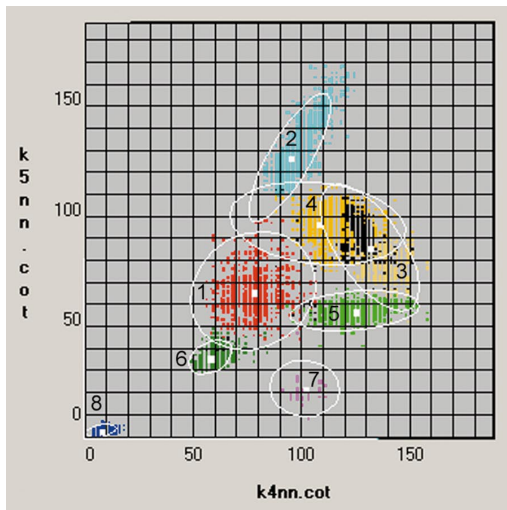
- Lewiński S., 2006b: Land use classification of ASTER image – Legionowo test site. Proc. of the 25<sup>th</sup> Symposium of the European Association of Remote Sensing Laboratories, Porto, Portugal, 6-9 June 2005. Global Developments in Environmental Earth Observation from Space.
- Oruc M., Marangoz A.M., Buyuksalih G., 2004: Comparison of pixel-based and object-oriented classification approaches using Landsat-7 ETM spectral bands. Proceedings of the ISRPS 2004 Annual Conference, Istanbul, Turkey. July 19-23.
- Tadesse W., Coleman T. L., Tsegaye T.D., 2003: Improvement of Land Use and Land Cover Classification of an Urban Area Using Image Segmentation from Landsat ETM+ Data. Proceedings of the 30th International Symposium on Remote Sensing of the Environment. November 10-14, 2003. Honolulu, Hawaii.
- Whiteside T., Ahmad W., 2005: A comparison of object-oriented and pixel-based classification methods for mapping land cover in northern Australia. Proceedings of SSC2005 Spatial intelligence, innovation and praxis, The National Biennial Conference of the Spatial Sciences Institute, September 2005. Melbourne: Spatial Sciences Institute. ISBN 0-9581366-2-9.
- Zhang Y., 1999: A new merging method and its spectral and spatial effects. *International Journal of Remote Sensing*, vol. 20, No. 10, pp. 2003-2014.
- Zhang Y., 2002: Problems in the fusion of commercial high-resolution satellite images as well as Landsat 7 images and initial solutions. *International Archives of Photogrammetry and Remote Sensing (IAPRS)*, vol. 34, part 4.

### Summary

*The capabilities of land cover and land use classes identification using object-oriented classification and traditional, so-called pixel-based classification are compared in the paper. The comparison is based on the Landsat satellite image showing a study area of over 423 km<sup>2</sup>, located within the borders of the Commune of Legionowo (near Warsaw). The results of both classifications were generalised, using a working unit of 1 ha for built-up areas and water and 4 ha for the remaining classes. Object-oriented classification was performed within eCognition software environment. The applied tools of object-oriented classification enabled identification of 18 classes. Subsequent generalisation caused changes only to the area constituting 1.1% of the entire study area. Classification accuracy assessment using the method of visual interpretation and creation of the final land cover and land use database was the final stage of works. The accuracy for the entire study area reached over 94%. Traditional pixel-based classification was performed using so-called hybrid classification, which involves performing supervised classification and then unsupervised classification for unclassified pixels. The pixel-based approach enabled identification of only 8 classes. In the process of generalisation, based on the same principles as in the case of object-oriented classification, 26% of the area of the analysed image was changed. The accuracy of pixel-based classification, assessed by comparing the post-generalisation image to the database obtained after the visual verification of object-oriented classification, reached 72% and 61%, according to the comparison method applied. The results of comparing these two methods of classification prove a significant advantage of object-oriented classification over traditional pixel-based classification. The tools of object-oriented classification enabled identification of twice as many number of classes and a high level of accuracy of the classification process. Moreover, object-oriented classification enables proper generalisation, necessary for creating a land use and land cover database with a defined level of spatial resolution of class recognition.*


dr inż. Stanisław Lewiński  
stanislaw.lewinski@igik.edu.pl







- POLA TRENINGOWE KLAS:
- 1 - ZABUDOWA
  - 2 - GRUNTY ORNE BEZ POKRYWY ROSLINNEJ
  - 3 - GRUNTY ORNE Z POKRYWĄ ROSLINNĄ
  - 4 - ŁĄKI
  - 5 - LAS LISCIASTY
  - 6 - LAS IGLASTY
  - 7 - OSADNIKI
  - 8 - WODY

Rys. 1. Wykresy rozkładu wartości pikseli pól treningowych, dla par kanałów spektralnych 5 i 4, 4 i 3 oraz 2 i 5



Rys. 2. Obraz klasyfikacji hybrydowej



Rys. 3. Obraz klasyfikacji hybrydowej po generalizacji