

Mapy podstawowych form pokrycia i użytkowania terenu zlewni Raby powyżej Zbiornika Dobczyckiego – porównanie dokładności klasyfikacji pikselowej i obiektowej obrazów LANDSAT TM¹

Mapping of basic land-use / land cover types in upper Raba watershed – accuracy comparison of pixel-based and object-based approaches to LANDSAT TM images classification

Monika BADURSKA, Wojciech DRZEWIECKI, Piotr TOKARCZYK

Słowa kluczowe: Landsat TM, klasyfikacja pikselowa, klasyfikacja obiektowa, ocena dokładności klasyfikacji, zlewnia Raby, pokrycie i użytkowanie terenu

Key words: Landsat TM, pixel-based classification, object-based classification, classification accuracy assessment, Raba watershed, land-use / land cover

The research presented in the paper has been aimed at mapping the basic types of land-use in the upper Raba watershed (south Poland). The maps have been prepared for a study of the influence of land-use changes within the watershed on the sediment yields introduced into the reservoir. Because the erosion models used for sediment yields prediction need only to identify the main land-use / land cover classes (arable land, meadows and pastures, forests, waters, developed areas), the maps have been based on classification of middle-resolution satellite images (Landsat TM).

In the research the results of traditional pixel-based classification were compared to the ones obtained in the object-

based approach. Six different Landsat TM images were classified. The methodology of both classification approaches have been described in the paper. The accuracy assessment of the classification results was based on their comparison with the land use types defined by the photo interpretation of colour composite images. The assessment was done by two operators. Each of them used different set of two hundred and fifty randomly generated sample points.

In most cases the pixel-based approach resulted in higher overall accuracy. However, if overall accuracy confidence intervals are taken into consideration, none of the methods can be definitely recognised as a better one.

Wprowadzenie

Prezentowane w niniejszym artykule prace wykonane zostały w ramach projektu badawczego mającego na celu określenie wpływu zmian sposobu użytkowania terenu na obszarze zlewni zbiornika retencyjnego w Dobczykach na ładunek zawieszin wprowadzanych do zbiornika wraz z zasilającymi go wodami powierzchniowymi. Oszacowanie ilości osadów docierających do zbiornika wymaga przeprowadzenia modelowania przestrzennego zachodzących w zlewni procesów erozji wodnej gleb oraz

transportu wyerodowanego materiału glebowego do cieków wodnych. Ze względu na rozmiar modelowanej zlewni zdecydowano się wykorzystać do tego celu modele erozyjne, które umożliwiając ilościowe określenie efektu erozyjnego i wielkości depozycji transportowanego materiału glebowego w zlewni, posiadają jednocześnie stosunkowo niewielkie wymagania dotyczące niezbędnych danych wejściowych. Przykładami tego typu narzędzi, stosowanych z powodzeniem do oceny ładunku osadów wprowadzanych wskutek procesów erozji do rzek i zbiorników wodnych w skali zlewni, są m. in. modele RUSLE/SDR (Bhattarai i Dutta, 2000; Krasa *et al.*, 2005; Drzewiecki *et al.*, 2008) i Watem/SEDEM (Van Rompaey *et al.*, 2001; Van Rompaey *et al.*, 2003).

Skonstruowanie modelu umożliwiającego określanie wpływu zmian sposobu użytkowania na wielkość dosta-

¹ Praca naukowa finansowana ze środków na naukę w latach 2007-2009 jako projekt badawczy „Modelowanie wpływu zmian użytkowania na wielkość ładunku osadów potencjalnie akumulowanych w zbiornikach retencyjnych z wykorzystaniem wieloczasowych wielospektralnych danych teledetekcyjnych i systemów informacji geograficznej” (N520 021 31/2970)

wy osadu wymaga przeprowadzenia procesu kalibracji i weryfikacji w oparciu o dane pomiarowe pochodzące z różnych stanów czasowych. W ramach projektu przeprowadzono pomiary pozwalające na określenie ładunków zawieszin transportowanych w ciekach zlewni i wprowadzanych do zbiornika. Analogiczne informacje dla wcześniejszych stanów czasowych uzyskano z wykorzystaniem wyników pomiarów prowadzonych w zlewni Zbiornika Dobczyckiego przez Instytut Melioracji i Użytków Zielonych O/Kraków. Posiadane pomiarowe dane kalibracyjne i weryfikacyjne determinowały określenie stanów czasowych, dla których konieczne było skompletowanie niezbędnych danych wejściowych do modelowania przestrzennego. W odniesieniu do informacji o sposobie użytkowania i pokryciu terenu, dla przewidzianych do zastosowania modeli erozyjnych, wystarczające jest rozróżnienie podstawowych klas, takich jak: grunty orne, trwałe użytki zielone, lasy, zabudowa, wody powierzchniowe. Fakt ten oraz wielkość obszaru modelowania spowodowały, iż dane te zdecydowano się pozyskać na drodze klasyfikacji zobrażeń satelitarnych Landsat TM.

W ramach prowadzonych badań zdecydowano się na dokonanie porównania wyników klasyfikacji wykonywanych z zastosowaniem tradycyjnego podejścia pikselowego oraz metody obiektowej. Pomimo, że koncepcja segmentacji obrazu oraz klasyfikacji obiektowej nie jest nowa (Kettig i Landgrebe, 1976), jednak w praktyce klasyfikacji obrazów teledetekcyjnych podejście obiektowe pojawiło się stosunkowo niedawno i wciąż stanowi interesujący problem badawczy. Metody te zyskały dużą popularność zwłaszcza w klasyfikacji wysokorozdzielczych zobrażeń satelitarnych (Lennartz i Congalton, 2004). Gwałtowny rozwój podejścia obiektowego został uznany za jedno z głównych osiągnięć ostatnich lat w dziedzinie przetwarzania obrazów teledetekcyjnych (Benz *et al.*, 2004). W literaturze pojawiają się już nawet głosy o zachodzącej w dziedzinie klasyfikacji obrazów teledetekcyjnych zmianie paradygmatu oraz stwierdzenia, że podejście obiektowe zaczyna przewyższać popularnością tradycyjne metody klasyfikacji pikselowej (Gamanya *et al.*, 2009).

Wielu autorów stwierdziło w swoich badaniach wyższą dokładność klasyfikacji przeprowadzonej metodą obiektową w porównaniu z metodami opartymi na podejściu pikselowym. Wyniki takie uzyskiwano również w porównaniach dotyczących klasyfikacji obrazów z satelity Landsat (Tadesse *et al.*, 2003; Oruc *et al.*, 2004; Lewiński, 2007; Qian *et al.*, 2007). Jednak wyniki niektórych porównań dokładności klasyfikacji obrazów landsatowskich wskazują, iż nie jest to regułą. Dorren *et al.* (2003) przeprowadzając klasyfikację obszarów leśnych w alpejskim regionie Montafon (zachodnia Austria) uzyskali dla podejścia pikselowego (klasyfikacja metodą największego prawdopodobieństwa) całkowitą dokładność klasyfikacji wynoszącą 73%, natomiast przy zastosowaniu metody obiektowej – 70%. Robertson i King (2009) porównywali wyniki uzyskane metodą największego prawdopodobieństwa oraz przy użyciu

podejścia obiektowego w klasyfikacji form pokrycia i użytkowania terenu na obszarze wschodniego Ontario (Kanada). Klasyfikację przeprowadzono dla dwóch stanów czasowych (1995 i 2005) na pojedynczych obrazach z Landsata TM. W obu przypadkach uzyskana dokładność całkowita klasyfikacji w podejściu pikselowym była wyższa niż w obiektowym – odpowiednio 79,2 i 75,6 (dla roku 1995) oraz 75,7 i 75,6 procent (dla roku 2005). Autorzy ci podkreślają jednak, że w oparciu o uzyskane przez nich wyniki nie można stwierdzić, że hipoteza o większej dokładności klasyfikacji metodą pikselową jest istotna statystycznie. Ciekawy eksperyment mający na celu porównanie dokładności obu metod klasyfikacji przeprowadzili Gao i Mas (2008). Autorzy ci poddali klasyfikacji obrazy satelitarne SPOT 5, Landsat ETM+ i MODIS oraz dodatkowo symulowane obrazy o rozdzielczości przestrzennej 30, 100 i 250 metrów uzyskane na bazie obrazu SPOT-a o rozdzielczości 10 m. Klasyfikacja miała na celu wydzielenie podstawowych form pokrycia i użytkowania terenu w górskim rejonie Tancitaro (Meksyk). W przypadku obrazów SPOT-a większą dokładność całkowitą klasyfikacji uzyskano metodą obiektową. Metoda ta dała również lepsze rezultaty w przypadku obrazu z satelity Landsat i symulowanego obrazu o rozdzielczości 30 metrów. W tych przypadkach jednak dokładność całkowita klasyfikacji metodą największego prawdopodobieństwa była niższa jedynie o odpowiednio 1,6 i 1,0 procent. Dla większych rozmiarów piksela klasyfikowanego obrazu lepsze rezultaty osiągnano z zastosowaniem podejścia pikselowego. Biorąc pod uwagę uzyskany poziom dokładności klasyfikacji i ilość punktów użytych do weryfikacji należy jednak stwierdzić, że we wszystkich analizowanych przypadkach różnice dokładności całkowitej mieszczą się w zakresie błędu jej oszacowania.

Podsumowaniem tego krótkiego przeglądu literatury może być stwierdzenie Blaschke (w druku), który zauważa, że chociaż podejście obiektowe stosowane jest w klasyfikacji obrazów o niskiej i średniej rozdzielczości, to tylko w przypadku obrazów wysokorozdzielczych (gdzie rozmiar piksela jest znacząco mniejszy od rozmiaru obiektów obrazowych) można w pełni wykorzystać jego zalety. Górski charakter zlewni Zbiornika Dobczyckiego ze specyficzną mozaiką użytkowania – mała powierzchnia działek rolnych, ich wydłużony kształt i duża zmienność użytkowania – powoduje, iż obszar ten stanowi interesujący obiekt testowy dla porównania wyników klasyfikacji metodą pikselową i obiektową. Przeprowadzenie takiego porównania uzasadnia również fakt, iż przykłady implementacji metod obiektowych w odniesieniu do klasyfikacji średniorozdzielczych obrazów optycznych w obszarach górskich są stosunkowo nieliczne.

Obszar badań i dane

Charakterystyka obszaru badań. Zbiornik Dobczycki zlokalizowany jest około 30 km na południe od

Krakowa w dolinie rzeki Raby pomiędzy Myślenicami i Dobczycami. Całkowita powierzchnia zlewni rzeki Raby do przekroju w Dobczycach wynosi około 768 km², zaś zlewnia własna zbiornika obejmuje obszar około 72 km². Zlewnia Raby powyżej zbiornika posiada typowo górski charakter. Na jej obszarze dominują lasy i tereny wykorzystywane rolniczo. Działki rolne posiadają niewielką powierzchnię i charakteryzują się wydłużonym kształtem przy niewielkiej szerokości. Poza rolnictwem dominującą działalnością na obszarze zlewni jest rekreacja. Główne ośrodki miejskie położone w obszarze badań to Myślenice, Mszana Dolna i Rabka-Zdrój.

Dane satelitarne. Dobór obrazów satelitarnych do klasyfikacji determinowany był koniecznością uzyskania obrazu stanu pokrycia i użytkowania terenu dla stanów czasowych korespondujących z okresami prowadzenia w zlewni pomiarów, których wyniki wykorzystane mają zostać do kalibracji i weryfikacji modeli erozyjnych. W efekcie do klasyfikacji wytypowano sześć obrazów z satelity Landsat TM (fragmenty sceny 188/25) o następujących datach rejestracji: 20.04.1985, 27.09.1985, 24.08.1996, 12.09.1997, 1.04.2007 oraz 24.09.2007.

Opracowanie obrazów satelitarnych

Ortorektyfikacja obrazów satelitarnych. Ortorektyfikację wszystkich obrazów satelitarnych wykonano z zastosowaniem ścisłego modelu orbitalnego przy użyciu modułu Ortho Engine oprogramowania PCI Geomatica. Ortofotomapa o terenowym rozmiarze piksela wynoszącym 30 m została wygenerowana w Państwowym Układzie Współrzędnych Geodezyjnych 1992. Wykorzystywane w procesie ortorektyfikacji punkty dostosowania i punkty kontrolne wybrano w oparciu o zdjęcia lotnicze wykonane w ramach programu PHARE (nalot z roku 1997). Zostały one równomiernie roz-

mieszczone na całym obszarze opracowania, a ponadto wybierane tak, aby zapewnić możliwie najwyższą zdolność ich identyfikacji zarówno na zdjęciu lotniczym, jak i obrazie satelitarnym. Punkty wybierane były na obiektach zapewniających niezmiennosc w czasie, takich jak: krawędź lasu, krawędzie dużych obiektów antropogenicznych, skrzyżowania dróg. Dokładność położenia punktu (XY) na uzyskanych ortofotomapach waha się w granicach od 0.36 do 0.56 piksela (tj. 10.8÷16.8 m).

Klasyfikacja pikselowa. Klasyfikacja pokrycia terenu w podejściu pikselowym została przeprowadzona w sposób nadzorowany z wykorzystaniem algorytmu największego prawdopodobieństwa w oprogramowaniu ENVI. Celem klasyfikacji było wyodrębnienie pięciu podstawowych typów pokrycia terenu: wody, lasu, zabudowy, użytków zielonych i gruntów ornych, ale w procesie klasyfikacji stosowano większą ilość wydzielen. Dotyczyło to głównie rozdzielenia klasy lasów na lasy liściaste i iglaste oraz gruntów ornych w zależności od poziomu wegetacji (oznaczonych jako „grunty orne A” i „grunty orne B”). Zestawy wydzielanych klas pokrycia terenu dla poszczególnych obrazów wielospektralnych przedstawiono w tabeli 1.

Podczas digitalizacji pól treningowych kierowano się zasadą, że powinny one reprezentować od 1% do 5% ogółu pikseli obrazu z minimalną liczbą pikseli dla pojedynczej klasy na poziomie 10N, a zalecaną 100N, gdzie N oznacza wymiar przestrzeni wielospektralnej danych wejściowych (Richards, 1993). Otrzymane pola treningowe sprawdzono pod względem jednorodności i rozłączności na podstawie analizy wybranych statystyk. Przeanalizowano histogramy dwuwymiarowe oraz miary statystyczne ilustrujące stopień rozłączności par sygnatur pól treningowych. W pracy wykorzystano miary separatywności pól treningowych obliczonych według formuły Jeffries-Matusita (Richards, 1993). Odległość Jeffries-Matusita (JM) występuje w przedziale od 0 do 2, przy czym przyjmuje się, że separatywność klas na

Tabela 1. Klasy pokrycia terenu stosowane w procesie klasyfikacji pikselowej

Table 1. Land cover classes used for pixel-based classification

1.04.2007	24.09.2007	12.09.1997	24.08.1996	20.04.1985	27.09.1985
woda <i>water</i>	woda <i>water</i>	woda <i>water</i>	woda <i>water</i>	woda <i>water</i>	woda <i>water</i>
las <i>forest</i>	las iglasty <i>conifer forest</i> las liściasty <i>deciduous forest</i>	las	las iglasty <i>conifer forest</i> las liściasty <i>deciduous forest</i>	las <i>forest</i>	las <i>forest</i>
zabudowa <i>developed land</i>	zabudowa <i>developed land</i>	zabudowa <i>developed land</i>	zabudowa <i>developed land</i>	zabudowa <i>developed land</i>	zabudowa <i>developed land</i>
użytki zielone <i>pastures and meadows</i>	użytki zielone <i>pastures and meadows</i>	użytki zielone <i>pastures and meadows</i>	użytki zielone <i>pastures and meadows</i>	użytki zielone <i>pastures and meadows</i>	użytki zielone <i>pastures and meadows</i>
grunty orne A <i>arable land – type A</i>	grunty orne A <i>arable land – type A</i>	grunty orne A <i>arable land – type A</i>	grunty orne A <i>arable land – type A</i>	grunty orne A <i>arable land – type A</i>	grunty orne A <i>arable land – type A</i>
grunty orne B <i>arable land – type B</i>	grunty orne B <i>arable land – type B</i>	grunty orne B <i>arable land – type B</i>	grunty orne B <i>arable land – type B</i>	grunty orne B <i>arable land – type B</i>	grunty orne B <i>arable land – type B</i>
śnieg <i>snow</i>	-----	-----	chmury <i>clouds</i>	-----	chmury <i>clouds</i>

Tabela 2. Pary klas pokrycia terenu o odległości Jeffries-Matusita poniżej wartości 1.81
 Table 2. Pairs of land cover classes with Jeffries-Matusita distance values below 1.81

Zestaw danych <i>Data Set</i>	Klasy pokrycia terenu <i>Land Cover Classes</i>	Odległość JM <i>JM Distance Value</i>
1.04.2007	zabudowa – grunty orne A <i>developed land – arable land type A</i>	1.49
	las – zabudowa <i>forest – developed land</i>	1.63
	las – grunty orne A <i>forest – arable land type A</i>	1.77
24.09.2007	zabudowa – grunty orne A <i>developed land – arable land type A</i>	1.49
	las liściasty – użytki zielone <i>deciduous forest – pastures and meadows</i>	1.75
12.09.1997	zabudowa – grunty orne A <i>developed land – arable land type A</i>	1.63
24.08.1996	zabudowa – grunty orne A <i>developed land – arable land type A</i>	1.30
27.09.1985	----	----
20.04.1985	zabudowa – grunty orne A <i>developed land – arable land type A</i>	1.71
	zabudowa – woda <i>developed land – water</i>	1.76

poziomie 1.81 – 1.90 jest dobra, a bardzo dobra dla wartości 1.91 – 2.00. W tabeli 2 przedstawiono pary klas pokrycia terenu, dla których wartości odległości JM nie przekroczyły poziomu 1.81.

Przy klasyfikacji poszczególnych zestawów danych posłużono się różnymi zestawami kanałów spektralnych. Dodatkowo, w przypadku obrazów z 24.08.1996 i 27.09.1985 roku, w procesie klasyfikacji wykorzystano obliczone indeksy wegetacji NDVI (*Normalized Difference Vegetation Index*). Selekcji optymalnej liczby kanałów spektralnych dokonano na podstawie analizy współczynników korelacji międzykanałowej oraz odległości JM ilustrujących stopień rozłączności par sygnałów pól treningowych. Wybór kanałów dla poszczególnych zestawów danych został przedstawiony poniżej (Tab. 3). Wyniki klasyfikacji poddano generalizacji poprzez zastosowanie opcji *Majority*, polegającej na filtracji modalnej w oknie 3x3 piksele.

Tabela 3. Wykorzystane kanały spektralne
 Table 3. Spectral bands used

Data rejestracji obrazu <i>Image Acquisition Date</i>	Kanały spektralne <i>Spectral Bands</i>
1.04.2007	1, 2, 3, 4, 5, 7
24.09.2007	1, 2, 3, 4, 5, 7
12.09.1997	1, 5, 7
24.08.1996	1, 2, 3, 4, 5, 7, NDVI
27.09.1985	1, 2, 3, 4, 5, 7, NDVI
20.04.1985	1, 2, 3, 4, 5, 7

Klasyfikacja obiektowa. W podejściu obiektowym, inaczej niż w pikselowym, klasyfikacji nie podlegają pojedyncze piksele, lecz obiekty obrazowe – grupy sąsiadujących pikseli spełniających zadane kryteria doty-

czące ich jednorodności i zachodzących pomiędzy nimi relacji. Podział na obiekty obrazowe dokonywany jest na etapie wstępnej segmentacji obrazu.

W porównaniu do klasyfikacji metodą pikselową, klasyfikacja obiektowa pozwala na wykorzystanie zdecydowanie większej ilości informacji. Z każdym utworzonym na etapie segmentacji obiektem obrazowym związane są jego charakterystyki spektralne obliczane na podstawie wartości pikseli stanowiących obiekt: wartość średnia, minimum, maksimum, odchylenie standardowe. Ponadto do dyspozycji są informacje o kształcie obiektu (np. wielkość, długość, szerokość), jego teksturze (na podstawie obiektów niższego poziomu lub funkcji Haralick) oraz zależnościach między sąsiadującymi obiektami. Wszystkie te charakterystyki, a także charakterystyki zdefiniowane na ich podstawie przez użytkownika (np. dzielenie międzykanałowe, NDVI) można wykorzystać w celu utworzenia reguł klasyfikacyjnych (eCognition, 2004). W ramach prezentowanych badań klasyfikację obiektową przeprowadzono z użyciem oprogramowania eCognition 5.0 firmy Definiens.

Segmentacja obrazu przeprowadzona została na różnych poziomach szczegółowości, co pozwoliło na późniejsze utworzenie hierarchii obiektów obrazowych. Zastosowano dwa poziomy szczegółowości charakteryzowane przez parametr skali: 5 i 10. Przy wyborze wartości tego parametru główne znaczenie miał charakter działek, występujących na obszarach południowej Polski. Z uwagi na fakt, że użytkowanie terenu jest bardzo różnorodne, a działki posiadają niewielką powierzchnię i wydłużone kształty, wymagane było utworzenie dużej ilości obiektów obrazowych (segmentacja z parametrem skali o wartości 5), gdyż w przeciwnym wypadku jeden obiekt mógłby obejmować dwie lub więcej sąsiadujących

ze sobą działek. Obiekty wydzielone z zastosowaniem segmentacji o wartości parametru skali równej 10 użyte zostały do wydzielenia lasów oraz zbiornika wodnego w Dobczycach.

Kolejnym kryterium mającym wpływ na ilość i kształt obiektów obrazowych jest kryterium homogeniczności, gdzie do dyspozycji mamy cztery parametry: kolor oraz kształt, który dzieli się na zwartość i gładkość. Parametry te pozostawiono bez zmian wprowadzając wartości 0.9 dla parametru koloru, 0.1 dla kształtu oraz 0.5 dla zwartości i gładkości. Dodatkową opcją jest możliwość wprowadzenia wag dla poszczególnych kanałów spektralnych, które pozwalają na określenie priorytetu dla konkretnego spektrum promieniowania zarejestrowanego przez satelitę. W tym przypadku dla kanału niebieskiego zastosowano wagę 0.1 z powodu jego niskiej zawartości informacyjnej, natomiast pozostałe kanały spektralne otrzymały wagę 1. Jako tryb segmentacji wybrano *multiresolution segmentation*. W wyniku segmentacji powstały obiekty obrazowe, które stanowią podstawę do klasyfikacji metodą obiektową.

Następnie przystąpiono do utworzenia hierarchii wydzielanych klas. Podobnie jak w przypadku klasyfikacji metodą pikselową, wyodrębniono pięć podstawowych typów pokrycia terenu: wody lasy, zabudowa, grunty orne i użytki zielone. Z uwagi na zachmurzenie występujące na czterech scenach, do wydzielanych kategorii pokrycia terenu zostały dodane klasy chmur oraz cieni.

Dla większości klas przeprowadzono klasyfikację przy zastosowaniu zdefiniowanych przez użytkownika funkcji przynależności. W przypadku lasów reguły klasyfikacyjne oparto na średnich wartościach w kanale zielonym i czerwonym oraz wskaźniku NDVI. Funkcje przynależności dla klasy użytków zielonych oparto o wartości średnie i odchylenie standardowe w kanale zielonym oraz wartości wskaźnika NDVI i dzielenia międzykanałowego kanału zielonego i bliskiej podczerwieni. W przypadku wód posługiwano się przede wszystkim wskaźnikiem NDVI i stosunkiem wartości w kanałach piątym i pierwszym. W przypadku

zabudowy i gruntów ornych wykorzystano opcję automatycznego wyznaczenia reguł bazującego na próbkach wskazanych przez obserwatora – *Feature Space Optimization*.

Wyniki – ocena dokładności klasyfikacji

Ocena dokładności wyników klasyfikacji pikselowej i obiektowej została przeprowadzona poprzez porównanie ich wyników z klasami użytkowania określonymi na drodze fotointerpretacji kompozycji barwnych utworzonych z klasyfikowanych obrazów. Weryfikację przeprowadzano w 250-ciu punktach (pojedynczych pikselach) wybranych w sposób losowy, przy czym ich ilość dla poszczególnych klas pokrycia terenu była proporcjonalna do powierzchni danej klasy na sklasyfikowanym obrazie. Ocena dokładności klasyfikacji przeprowadzana była dla każdego obrazu niezależnie przez dwóch operatorów, z których każdy posługiwał się innym zestawem punktów kontrolnych.

Przedział ufności dla oszacowania dokładności całkowitej klasyfikacji obliczono zgodnie ze wzorem:

$$e = z \sqrt{\frac{p(1-p)}{n}}$$

gdzie:

z – zmienna standardowego rozkładu normalnego; przyjęto z = 1.96 (obliczenia przeprowadzono dla poziomu ufności wynoszącego 95%)

p – dokładność całkowita klasyfikacji,

n – liczba pikseli testowych.

W wyniku przeprowadzonej oceny dokładności w większości przypadków wyższe wartości dokładności całkowitej klasyfikacji uzyskano dla podejścia pikselowego. Jednak, uwzględniając przedziały ufności w jakich mieszczą się oszacowane poziomy dokładności klasyfikacji, należy stwierdzić, iż uzyskane wyniki nie dają podstaw do uznania w sposób jednoznaczny, że metoda ta przewyższyła swoimi rezultatami podejście obiektowe (por. Tab. 4).

Tabela 4. Wyniki oceny dokładności klasyfikacji

Table 4. Results of classification accuracy assessment

Data rejestracji Image Acquisition Date	Operator 1 Operator 1				Operator 2 Operator 2			
	Klasyfikacja pikselowa Pixel-based Approach		Klasyfikacja obiektowa Object-based Approach		Klasyfikacja pikselowa Pixel-based Approach		Klasyfikacja obiektowa Object-based Approach	
	Dokładność całkowita [%] Overall Accuracy	Kap-pa Kappa	Dokładność całkowita [%] Overall Accuracy	Kap-pa Kappa	Dokładność całkowita [%] Overall Accuracy	Kap-pa Kappa	Dokładność całkowita [%] Overall Accuracy	Kap-pa Kappa
1.04.2007	61.2 ±6.0	0.47	62.0 ±6.0	0.51	65.2 ±5.9	0.49	63.0 ±6.0	0.48
24.09.2007	80.4 ±4.9	0.74	71.6 ±5.6	0.62	74.8 ±5.4	0.61	73.1 ±5.5	0.60
12.09.1997	76.0 ±5.3	0.67	72.0 ±5.6	0.62	71.6 ±5.6	0.56	68.7 ±5.7	0.53
24.08.1996	73.2 ±5.5	0.64	69.1 ±5.7	0.59	70.8 ±5.6	0.56	63.4 ±6.0	0.46
20.04.1985	76.4 ±5.3	0.68	69.2 ±5.7	0.58	63.6 ±6.0	0.46	65.9 ±5.9	0.51
27.09.1985	64.4 ±6.0	0.51	61.6 ±6.0	0.50	64.8 ±5.9	0.47	63.4 ±6.0	0.47

Podsumowanie

Celem prezentowanych badań był wybór metody klasyfikacji obrazów satelitarnych Landsat TM na potrzeby opracowania, stanowiących dane wejściowe do modeli erozji wodnej gleb, map głównych form pokrycia terenu w zlewni Raby powyżej Zbiornika Dobczyckiego. Przeprowadzone porównanie dokładności klasyfikacji w tradycyjnym podejściu pikselowym (metodą największego prawdopodobieństwa) i w podejściu obiektowym nie pozwoliło na sformułowanie jednoznacznej odpowiedzi na pytanie, który z produktów powinien być wykorzystywany na kolejnych etapach prowadzonego projektu badawczego.

Nieco lepszymi parametrami dokładnościowymi charakteryzują się produkty otrzymane na drodze klasyfikacji pikselowej. Jednak uzyskane różnice dokładności całkowitej klasyfikacji mieszczą się w przedziałach ufności tego parametru. Należy w tym miejscu zaznaczyć, iż dla obu testowanych podejść uzyskano stosunkowo niskie wartości dokładności całkowitej klasyfikacji. W dużej mierze wynikają one z trudności w rozdzieleniu charakteryzujących się znacznym podobieństwem spektralnym klas gruntów ornych i zabudowy (por. wartości odległości Jeffries-Matusita w Tab. 2).

Należy również wziąć pod uwagę fakt, iż w przypadku metody obiektowej ocena dokładności klasyfikacji oparta na weryfikacji użytkowania w pikselach kontrolnych, może dawać wynik zaniżony (Gao i Mas, 2008). Dodatkowo, nieco niższe wartości dokładności całkowitej nie muszą oznaczać mniejszej przydatności produktu końcowego dla docelowego zastosowania (Dorren et al., 2003).

Powyższe przesłanki powodują, iż nie zdecydowano się na wybór którejś z metod klasyfikacji. W oparciu o przeprowadzoną ocenę dokładności podjęto natomiast decyzję dotyczącą wyboru obrazów, których klasyfikacja dostarczy dla modeli erozyjnych danych wejściowych o użytkowaniu terenu dla poszczególnych stanów czasowych. Na podstawie analizy wyników zawartych w Tabeli 4 wybrano obrazy zarejestrowane 20.04.1985, 12.09.1997 oraz 24.09.2007. Kalibracja i weryfikacja modeli erozyjnych przeprowadzona zostanie przy użyciu wyników klasyfikacji uzyskanych obiema metodami. Dopiero porównanie uzyskanych wyników modelowania pozwoli wyrobić sobie pogląd o ewentualnej większej przydatności któregoś z zestawu produktów klasyfikacyjnych dla tego konkretnego zastosowania.

Literatura

Benz U., Hofmann P., Willhauck G., Lingenfelder I., Heynen M., 2004, Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS Journal of Photogrammetry and Remote Sensing*, 58, 239-258.

Bhattacharai, R., Dutta, D., 2007, Estimation of Soil Erosion and Sediment Yield Using GIS at Catchment Scale. *Water Resour Management*, 21, 1635-1647.

Blaschke T., (w druku). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing* (2009), doi:10.1016/j.isprsjprs.2009.06.004.

Dorren L. K. A., Maier B., Seijmonsberger A. C., 2003, Improved Landsat-based forest mapping in steep mountainous terrain using object-based classification. *Forest Ecology and Management*, 183, 31-46.

Drzewiecki W., Mularz S., Twardy S., Kopacz M., 2008, Próba kalibracji modelu RUSLE/SDR dla oceny ładunku zawiesiny wprowadzanego do Zbiornika Dobczyckiego z zlewni bezpośrednio. *Archiwum Fotogrametrii, Kartografii i Teledekcji*, Vol. 18, 83-98.

eCognition, 2004, *User Guide*. Definiens Imaging.

Gamanya R., De Mayer P., De Dapper M., 2009, Object-oriented change detection for the city of Harare, Zimbabwe. *Expert Systems with Applications*, 36, 571-588.

Gao Y., Mas J. F., 2008, A comparison of the performance of pixel-based and object-based classifications over images with various spatial resolutions. [w:] G.J. Hay, T. Blaschke and D. Marceau (Eds). *GEOBIA 2008 – Pixels, Objects, Intelligence. GEOgraphic Object Based Image Analysis for the 21st Century. University of Calgary, Calgary Alberta, Canada, August 05-08*. ISPRS Vol. No. XXXVIII-4/C1.

Kettig R. L., Landgrebe D. A., 1976, Classification of multispectral image data by extraction and classification of homogeneous objects. *IEEE Transactions on Geoscience Electronics*, GE-14, 19-26.

Krasa J., Dostal T., Van Rompaey A., Vaska J., Vrana K., 2005, Reservoirs' siltation measurements and sediment transport assessment in the Czech Republic, the Vrchlice catchment study. *Catena*, 64, 348-362.

Lennartz S. P., Congalton R. G., 2004, Classifying and mapping forest cover types using IKONOS imagery in the northeastern United States [w:] *ASPRS Annual Conference Proceedings, 23-28 May, (Denver, Colorado)*.

Lewiński S., 2007, Porównanie klasyfikacji obiektowej z tradycyjną klasyfikacją pikselową z punktu widzenia automatyzacji procesu tworzenia bazy danych o pokryciu i użytkowaniu terenu. *Roczniki Geomatyki*, Tom V, zeszyt 1, 63-70.

Oruc M., Marangoz A. M., Buyuksalih G., 2004, Comparison of pixel-based and object-oriented classification approaches using Landsat-7 ETM spectral bands. *Geo-Imagery Bridging Continents, XXth ISPRS Congress, 12-23 July 2004 Istanbul, Turkey*, Commission 4, 1118-1122.

Qian J., Zhou Q., Hou Q., 2007, Comparison of pixel-based and object-oriented classification methods for extracting built-up areas in aridzone. *ISPRS Workshop on Updating Geo-spatial Databases with Imagery & The 5th ISPRS Workshop on DMGISs, XXXVI(4/W54)*, 163-171.

Richards J.A., 1993, *Remote Sensing Digital Image Analysis*, Springer-Verlag, Berlin.

Robertson L. D., King D., 2009, *Comparison of pixel and object-based classification in land cover change mapping*. http://http-server.carleton.ca/~dking/papers/LC_change_mapping_LDR.pdf, (dostęp 29.10.2009)

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 Environment (ISRES) – Information for Risk Management and Sustainable Development*. PS-I.35, CD-ROM. The International Society of Photogrammetry and Remote Sensing (ISPRS). 10-14 November 2003 Honolulu, HI

Van Rompaey, A., Vestraeten, G., Van Oost, K., Govers G., Poesen, J., 2001, Modelling mean annual sediment yield using a distributed approach. *Earth Surface Processes and Landforms*, 26, 1221-1236.

Van Rompaey, A., Krasa, J., Dostal, T., Govers, G., 2003, Modeling sediment supply to rivers and reservoirs in Eastern Europe during and after the collectivisation period. *Hydrobiologia*, 494, 169-176.



Mgr inż. Monika Badurska, absolwentka Wydziału Geodezji Górniczej i Inżynierii Środowiska Akademii Górniczo-Hutniczej w Krakowie, specjalność: geoinformatyka i teledetekcja. Od października 2006 roku studentka Studium Doktoranckiego w Katedrze Geoinformacji, Fotogrametrii i Teledetekcji Środowiska.
e-mail: monika.badurska@gmail.com; tel.: 12 617 3993; fax: 12 617 3993



Dr inż. Wojciech Drzewiecki, adiunkt w Katedrze Geoinformacji, Fotogrametrii i Teledetekcji Środowiska AGH w Krakowie. Swoje zainteresowania naukowo-badawcze koncentruje na zastosowaniach teledetekcji i systemów informacji geograficznej w badaniach środowiska i kształtowaniu przestrzeni.
e-mail: drzewiec@agh.edu.pl; tel.: 12 617 2288; fax: 12 617 3993



Mgr inż. Piotr Tokarczyk, absolwent Wydziału Geodezji Górniczej i Inżynierii Środowiska Akademii Górniczo-Hutniczej w Krakowie. Od 2009 roku jest doktorantem w Katedrze Geoinformacji, Fotogrametrii i Teledetekcji Środowiska. Swoje zainteresowania koncentruje wokół nawigacji, fotogrametrii oraz zastosowania teledetekcji i GIS w modelowaniu zmian przestrzennych.
e-mail: piotr.tokarczyk@gmail.com; tel.: 12 617 3993; fax: 12 617 3993