

ISBN: 978-83-60024-10-2

INSTYTUT GEODEZJI I KARTOGRAFII

SERIA MONOGRAFICZNA NR 12

STANISŁAW LEWIŃSKI

**OBIEKTOWA KLASYFIKACJA
ZDJĘĆ SATELITARNYCH
JAKO METODA POZYSKIWANIA
INFORMACJI O POKRYCIU
I UŻYTKOWANIU ZIEMI**

Warszawa 2007



Rada Wydawnicza
przy Instytucie Geodezji i Kartografii
Editorial Council
at the Institute of Geodesy and Cartography

Adam Linsenbarth (przewodniczący, chairman),
Andrzej Ciołkosz (zastępca przewodniczącego, deputy chairman),
Teresa Baranowska, Stanisław Białousz (Wydział Geodezji i Kartografii PW),
Wojciech Janusz, Jan R. Olędzki (Wydział Geografii i Studiów Regionalnych UW),
Andrzej Sas-Uhrynowski, Janusz Zieliński (Centrum Badań Kosmicznych),
Hanna Ciołkosz (sekretarz, secretary)

Redaktor naukowy wydawnictwa
Scientific Editor
Adam Linsenbarth

Zastępca redaktora naukowego wydawnictwa
Deputy Scientific Editor
Andrzej Ciołkosz

Zespół redakcyjny
Editorial Staff
Wojciech Janusz
Andrzej Sas-Uhrynowski
Agata Styk

Adres Redakcji
Instytut Geodezji i Kartografii
02-679 Warszawa, ul. Modzelewskiego 27
Address of the Editorial Board:
Institute of Geodesy and Cartography
02-679 Warsaw, Modzelewskiego 27 St.
Poland
e-mail: boi@igik.edu.pl

© Copyright by Instytut Geodezji i Kartografii

ISBN: 978-83-60024-10-2

IGiK, Warszawa 2007 r.
Skład komputerowy i druk: IGiK

Recenzent:
prof. dr hab. Andrzej Ciołkosz

Słowa kluczowe: zdjęcia satelitarne, klasyfikacja obiektowa, klasyfikacja pikselowa, baza danych o pokryciu i użytkowaniu ziemi

SPIS TREŚCI

1. Wstęp.....	9
2. Bazy danych o pokryciu i użytkowaniu ziemi.....	17
2.1. Bazy danych o pokryciu i użytkowaniu ziemi opracowane w ramach programu CORINE Land Cover.....	21
2.1.1. Technologia opracowania baz danych CLC90 i CLC2000.....	22
2.1.2. Interpretacja wizualna zdjęć satelitarnych.....	24
3. Zastosowania klasycznych metod klasyfikacji treści zdjęć satelitarnych do rozpoznania form pokrycia i użytkowania ziemi.....	26
3.1. Charakterystyka terenu badań oraz danych satelitarnych Landsat ETM+.....	30
3.2. Wstępne przetworzenie danych obrazowych.....	33
3.3. Połączenie danych wielospektralnych i panchromatycznych.....	34
3.3.1. Metody łączenia danych.....	35
3.3.2. Połączenie danych z zastosowaniem algorytmu PanSharp.....	36
3.4. Klasyfikacja hybrydowa.....	41
3.4.1. Pola treningowe.....	41
3.4.2. Dobór optymalnego zestawu kanałów w klasyfikacji.....	43
3.4.3. Klasyfikacja nadzorowana treści zdjęcia.....	48
3.4.4. Klasyfikacja nierozpoznawalnych pikseli metodą nienadzorowaną.....	49
3.4.5. Generalizacja i ocena wyników klasyfikacji hybrydowej.....	51
4. Wykorzystanie metody obiektowej klasyfikacji treści zdjęć satelitarnych do rozpoznania form pokrycia i użytkowania ziemi.....	56
4.1. Klasyfikacja obiektowa w środowisku oprogramowania eCognition.....	58
4.2. Algorytm opracowania wektorowej bazy danych na podstawie klasyfikacji obiektowej.....	65
4.3. Utworzenie wektorowej bazy danych o pokryciu i użytkowaniu ziemi z zastosowaniem klasyfikacji obiektowej treści zdjęcia satelitarnego Landsat ETM+.....	68
4.3.1. Segmentacja treści zdjęcia.....	68
4.3.2. Klasyfikacja obiektowa.....	70
4.3.3. Zasady klasyfikacji poszczególnych klas.....	75
4.3.4. Generalizacja wyników klasyfikacji.....	81
4.3.5. Utworzenie wektorowej bazy danych.....	85
4.3.6. Analiza wyników klasyfikacji obiektowej.....	85

INSTYTUT GEODEZJI I KARTOGRAFII

Seria monograficzna nr 12

5. Porównanie klasyfikacji treści zdjęcia wykonanej metodą pikselową i obiektową.....	90
6. Propozycja automatyzacji procesu pozyskiwania informacji o pokryciu i użytkowaniu ziemi.....	92
7. Zastosowanie proponowanej metody tworzenia bazy danych o pokryciu i użytkowaniu ziemi na przykładzie arkusza mapy topograficznej M-34-20-D „Puławy”.....	99
8. Podsumowanie.....	110
Literatura.....	113

CONTENTS

1. Introduction.....	9
2. Land cover and land use databases.....	17
2.1. Land cover and land use databases prepared within CORINE Land Cover Program.....	21
2.1.1. Technology of creating CLC90 and CLC2000 databases.....	22
2.1.2. Visual interpretation of satellite images.....	25
3. Application of conventional methods of classification of satellite image for recognizing land cover and land use types.....	26
3.1. Characteristics of study area and Landsat ETM+ satellite data.....	30
3.2. Pre-Processing of image data.....	33
3.3. Fusion of multispectral and panchromatic data.....	34
3.3.1. Methods of data fusion.....	35
3.3.2. Data fusion with the use of PanSharp algorithm.....	36
3.4. Hybrid classification.....	41
3.4.1. Training fields.....	41
3.4.2. Selection of optimal band combination for classification.....	43
3.4.3. Supervised classification of image content.....	48
3.4.4. Unsupervised classification of non-recognized pixels.....	49
3.4.5. Generalization and evaluation of the results of hybrid classification.....	51
4. Application of object-oriented classification of satellite images for recognizing land cover and land use types.....	56
4.1. Object-oriented classification in eCognition software.....	58
4.2. Algorithm of creating vector database on the basis of object- oriented classification.....	65
4.3. Algorithm of creating vector database on the basis of object- oriented classification.....	68
4.3.1. Image segmentation.....	68
4.3.2. Object-oriented classification.....	70
4.3.3. Rules of classification of particular classes.....	75
4.3.4. Generalization of the results of classification.....	81
4.3.5. Preparation of vector database.....	85
4.3.6. Analysis of the results of object-oriented classification.....	85

INSTITUTE OF GEODESY AND CARTOGRAPHY

Monographic Series No 12

5. Comparison of image classification using pixel-based and object-oriented approach.....	90
6. Proposal on automation of deriving information on land cover and land use.....	92
7. Application of the proposed method of creating land cover/land use database for “Pulawy” M-34-20-d topographic map sheet.....	99
8. Conclusions.....	110
References.....	113

ZARYS TREŚCI: Tematem publikacji jest automatyzacja procesu tworzenia baz danych o pokryciu i użytkowaniu ziemi na podstawie zdjęć satelitarnych średniej rozdzielczości.

Na przykładzie zdjęcia satelitarnego wykonanego skanerem ETM+ z pokładu satelity Landsat przedstawiono zasady klasyfikacji obiektowej oraz opracowanie wyników klasyfikacji. Zaproponowany algorytm postępowania pozwala na automatyczne utworzenie wektorowej bazy danych o zdefiniowanej jednostce odniesienia i o granicach wydzielen zblizonych swoim charakterem do granic uzyskiwanych metodami tradycyjnej interpretacji wizualnej. Wykonano również porównanie uzyskanych automatycznie baz danych z wynikami tradycyjnej klasyfikacji pikselowej oraz z bazą danych CLC2000 opracowaną metodą interpretacji wizualnej w ramach programu CORINE.

Przeprowadzone badania wykazały, że zaproponowany sposób postępowania, może w istotny sposób wspomagać lub nawet zastąpić interpretację wizualną. Pozwala on na skrócenie czasu opracowania bazy danych o podobnym zakresie tematycznym jak w przypadku interpretacji wizualnej i równocześnie charakteryzującej się dużo większym stopniem szczegółowości przestrzennej.

1. WSTĘP

Jednym z podstawowych celów polityki Unii Europejskiej jest tzw. rozwój zrównoważony, który ma służyć wzrostowi ekonomicznemu oraz równoczesnej poprawie poziomu i jakości życia mieszkańców krajów członkowskich. Pojęcie zrównoważonego rozwoju związane jest przede wszystkim z relacjami zachodzącymi między działalnością człowieka a środowiskiem naturalnym.

W roku 1998 w Baveno (Włochy), podczas spotkania organizacji zajmujących się badaniami kosmicznymi i satelitarnymi z Komisją Europejską, zainicjowano utworzenie ogólnoeuropejskiego programu GMES (Global Monitoring for Environment and Security), którego celem miało być zapewnienie warunków realizacji polityki zrównoważonego rozwoju. Trzy lata później w roku 2001 program GMES został przyjęty przez Komisję Europejską oraz Europejską Agencję Kosmiczną (European Space Agency, ESA). Czas trwania projektu wstępnie określono na co najmniej 10 lat. W ramach GMES formułowane są nie tylko prawne uwarunkowania działań krajów europejskich, lecz powstają również mechanizmy i narzędzia umożliwiające osiągnięcie założonych celów. Zakres działań można podzielić na dwa podstawowe kierunki związane z ogólnie pojętym środowiskiem naturalnym oraz z bezpieczeństwem (GMES, 2004). W ramach pierwszego kierunku szczególny nacisk położony jest na badania dotyczące zmian klimatycznych, różnorodności przyrodniczej, wykorzystania zasobów

naturalnych oraz na działania związane z poprawą warunków życia mieszkańców Europy. Uruchomiono projekty związane z badaniem środowiska morskiego i strefy przybrzeżnej, rozprzestrzenianiem się zanieczyszczeń powietrza, monitorowania zmian pokrycia i użytkowania ziemi, w tym lasów i przestrzeni rolniczej. W ich ramach pozyskiwane i analizowane są różnorodne dane w skali lokalnej, regionalnej oraz kontynentalnej, dzięki czemu możliwe będzie kompleksowe poznanie relacji zachodzących na różnych poziomach między działalnością człowieka a środowiskiem naturalnym. Drugi kierunek działań związany jest z szeroko pojętym bezpieczeństwem. Dotyczy to przede wszystkim zagrożeń środowiskowych (susze, pożary, powodzie, huragany) oraz zagrożeń powstających w wyniku awarii przemysłowych. Opracowanie procedur postępowania pozwoli na minimalizowanie ich skutków oraz na podejmowanie zorganizowanych akcji w celu udzielania pomocy ofiarom i mieszkańcom zagrożonych terenów.

Realizacja założeń programu GMES wymaga dostępu do aktualnych oraz historycznych danych, na podstawie których można prowadzić analizy, ustalać trendy procesów i zjawisk zachodzących w środowisku oraz podejmować decyzje. Jednym z podstawowych źródeł danych, niezbędnych do osiągnięcia tych celów, są zdjęcia satelitarne obrazujące powierzchnię Ziemi w zakresie promieniowania widzialnego, podczerwieni, podczerwieni termalnej oraz w zakresie mikrofal. Wykorzystywane są nie tylko dane satelitarne dostarczane przez ESA, lecz również dane z satelitów amerykańskich oraz z innych krajów dysponujących systemami obserwacji satelitarnej. Ze względu na ściśle powiązania programu GMES z przemysłem kosmicznym wybrane działania traktowane są jako europejski wkład w ogólnoświatowy program obserwacji Ziemi EO (Earth Observation), utworzony w roku 2003 w Stanach Zjednoczonych.

W pracach GMES-u aktywnie uczestniczy Europejska Agencja Środowiska (European Environment Agency, EEA). Z jej inicjatywy zostały opracowane i wprowadzone do prawa unijnego liczne dyrektywy regulujące zasady wykorzystania zasobów naturalnych. Agencja jest również inicjatorem licznych projektów związanych z szeroko pojętym monitoringiem środowiska, w tym tworzenia baz o pokryciu i użytkowaniu ziemi, dzięki którym można m.in. śledzić trendy zmian w sposobie wykorzystania ziemi, rozwój osadnictwa, infrastruktury transportu. Dane o pokryciu terenu wykorzystywane są do modelowania i oceny wpływu zanieczyszczeń powietrza, gleby i wody. Są one również niezbędne do prowadzenia skutecznej polityki w zakresie koordynacji działań na rzecz ochrony środowiska, ochrony szczególnie cennych struktur krajobrazowych, zbiorowisk roślinnych oraz populacji zamieszkujących je zwierząt. Agencja ta nadzorowała m.in. wykonanie programu CLC – CORINE Land Cover (CO-ordination of INFORMATION on the Environment), którego celem było opracowywanie na podstawie zdjęć satelitarnych ogólnoeuropejskich baz danych o pokryciu i użytkowaniu ziemi. W programie założono aktualizację informacji w bazach danych raz na 10 lat. Do tej chwili

opracowano dwie bazy danych CLC90 i CLC2000 obrazujące stan pokrycia i użytkowania ziemi w latach 1990 i 2000 oraz bazę zmian pokrycia terenu w ostatniej dekadzie XX w.

Obecnie, za sprawą działań w ramach programu GMES, wyraźnie widoczne jest przyspieszenie i intensyfikacja prac związanych z monitoringiem zmian zachodzących na powierzchni Ziemi. Uruchomiono m.in. program FTSP (Fast Track Service Precursor) – „European Land Monitoring”. Jego zadaniem jest dostarczenie początkowych danych dla docelowego programu FTS (Fast Track Service), którego uruchomienie planowane jest w 2008 r. W ramach FTSP zostanie przygotowana baza danych, będąca kontynuacją programu CORINE Land Cover, obrazująca stan pokrycia i użytkowania ziemi w 2005 roku. Zostaną także opracowane dwie nowe warstwy o większej rozdzielczości przestrzennej związane z zabudową oraz lasami. Wiadomo już, że nowa baza CLC2005, podobnie jak dwie poprzednie, będzie opracowana metodą interpretacji wizualnej zdjęć satelitarnych z zastosowaniem jednostki odniesienia 25 ha i 5 ha w przypadku rejestracji zmian pokrycia terenu. Natomiast dwie nowe warstwy o podwyższonej rozdzielczości będą charakteryzować się dużo większym stopniem szczegółowości, wynoszącym 1 ha. W celu uzyskania tak szczegółowych informacji najprawdopodobniej zostanie zastosowana technologia automatycznej klasyfikacji zdjęć satelitarnych. Jednakże jak dotąd nie została ona jednoznacznie zdefiniowana we wstępnych materiałach związanych z projektem FTSP (GMES, 2006).

Wprowadzenie nowej technologii tworzenia baz danych o pokryciu i użytkowaniu ziemi jest koniecznością ze względu na coraz większy stopień szczegółowości pozyskiwania informacji oraz większą częstotliwość aktualizacji baz danych zawierających te informacje. Program GMES zakłada opracowywanie nowych, kompleksowych baz danych lub też pojedynczych warstw tematycznych (np. lasy, zabudowa) co 5 lub nawet co 3 lata, zależnie od zakresu tematycznego, dynamizmu zmian i skali opracowania. Część prac wykonywana jest w ramach Core Service Land Cover (CSL) zintegrowanego programu GEOLAND (GMES-GEOLAND Project, 2005).

Wzrost znaczenia zdjęć satelitarnych w monitoringu środowiska, o czym świadczą podejmowane działania w ramach programu GMES, związany jest przede wszystkim z szybko postępującym w ciągu ostatnich lat rozwojem systemów obrazujących powierzchnię Ziemi. Zwiększyła się liczba dostępnych zdjęć satelitarnych, charakteryzujących się coraz większą rozdzielczością przestrzenną. Obok zdjęć wielospektralnych średniej rozdzielczości rejestrowanych m.in. z pokładu satelity Landsat, SPOT lub IRS o rozdzielczością przestrzenną 30–20 m, pojawiły się zdjęcia wysokiej rozdzielczości. Dane z satelity IKONOS, charakteryzujące się rozdzielczością 4 m w zakresie wielospektralnym i 1 m w zakresie panchromatycznym, są dostępne od października 1999 r. Dwa lata później został wprowadzony na orbitę satelita QuickBird, wyposażony w skaner rejestrujący obrazy wielospektralne o rozdziel-

czości 2,4 m oraz panchromatyczne – 0,6 m. Od grudnia 2000 r. dostępne są panchromatyczne zdjęcia z satelity EROS-A o rozdzielczości 1,8 m, a od 2004 r. rejestruje zdjęcia panchromatyczne i wielospektralne o rozdzielczości 0,82 m i 3,48 m satelita EROS-B. W 2002 r. w ramach programu SPOT satelita SPOT-5 rozpoczął rejestrację zdjęć wielospektralnych o rozdzielczości 10 m i panchromatycznych o rozdzielczości przestrzennej 5 i 2,5 m. Należy również wspomnieć o rosyjskich zdjęciach wykonywanych przez satelitę SPIN-2 o metrowej rozdzielczości. Równoległe do zdjęć rejestrujących obraz powierzchni Ziemi w zakresach promieniowania widzialnego i bliskiej podczerwieni rozwijane są systemy obserwacji radarowych oraz lotnicze i satelitarne skanery hiperspektralne.

W latach 90. rozwój technik pozyskiwania obrazów satelitarnych nie był wspierany nowymi technikami ich analiz. Zdjęcia najnowszych generacji opracowywano z zastosowaniem technik klasyfikacyjnych, których podstawowe założenia zostały zdefiniowane w latach 70. (Blaschke i inni, 2000). Dopiero pod koniec 2000 r. pojawiło się pierwsze komercyjne oprogramowanie klasyfikacji obiektowej eCognition, które zmieniło zasady i możliwości klasyfikacji (Baatz i inni, 2001). Od tego czasu klasyfikacja obiektowa jest gwałtownie rozwijającą się techniką klasyfikacji treści zdjęć satelitarnych. Sześć lat to okres wystarczająco długi dla rozwoju technologii informatycznej. Równocześnie jednak jest on zbyt krótki z punktu widzenia wypracowania i ustalenia metodologii i zastosowania jej w działaniach o charakterze operacyjnym.

Obecnie istnieje już duża i stale rosnąca liczba publikacji omawiających zagadnienia klasyfikacji obiektowej. Analizując dostępną literaturę, można zaryzykować jej podział na dwie grupy. Pierwsza grupa publikacji z lat 2000–2003 związana jest z prezentacją i popularyzacją nowej techniki klasyfikacji. Przedstawiane są w niej wyniki segmentacji, przykłady rozpoznania obiektów oraz zalety nowego podejścia w porównaniu z metodami tradycyjnymi – pikselowymi. Ze zrozumiałych względów autorzy tej grupy artykułów są najczęściej związani z producentem oprogramowania, posiadają znakomite przygotowanie teoretyczne oraz warsztatowe. Wielokrotnie prezentują oni nowe sposoby podejścia do zagadnień klasyfikacji, jednak bez położenia nacisku na sprawy związane z analizą dokładności uzyskiwanych wyników. Autorzy koncentrują się przede wszystkim na opisie zjawiska, sygnalizując jedynie uzyskiwane wyniki. Często analizy wykonywane są na przykładzie małych fragmentów zdjęć, co może budzić wątpliwości w odniesieniu do powtarzalności wyników w przypadku większego i bardziej zróżnicowanego terenu. Druga grupa publikacji związana jest z opracowaniami wykonywanymi przede wszystkim w ośrodkach naukowych. Prezentacja wyników związana jest z oceną ilościową i jakościową klasyfikacji obiektowej treści zdjęć satelitarnych oraz z porównywaniem ich z dotychczas stosowanymi metodami analiz. W wielu przypadkach wspólną cechą dostępnych artykułów jest brak

pełnej dokumentacji związanej z klasyfikacją obiektową. Do rzadkości należą publikacje, które pozwalają na wykonanie identycznej segmentacji, a następnie klasyfikacji. Sygnalizowany jest przede wszystkim sposób podejścia. Chcąc uzyskać zbliżone wyniki, należy samodzielnie rozwiązać zagadnienia merytoryczne oraz warsztatowe, związane ze złożonymi możliwościami oprogramowania eCognition. Można odnieść wrażenie, że autorzy nie chcą ujawniać opracowanych przez siebie fragmentów technologii klasyfikacji obiektowej. Nie można też wykluczyć prozaicznej przyczyny takiej sytuacji, związanej z koniecznością przytaczania w publikowanym tekście dużej liczby parametrów związanych z klasyfikacją. Należy jednak sądzić, że wynika to przede wszystkim z chęci pełnego wykorzystania zdobytych doświadczeń w projektach o charakterze komercyjnym. Potwierdzeniem tej opinii jest analiza zadań aplikacyjnych i zapotrzebowania na dane o pokryciu i użytkowaniu ziemi wynikające z programu GMES. Najprawdopodobniej doświadczenia firm i zespołów badawczych będą ujawnione dopiero w trakcie realizacji konkretnych zadań w ramach ustalonych kontraktów.

W przeciwieństwie do metod tradycyjnych w klasyfikacji obiektowej treści zdjęć satelitarnych nie są analizowane pojedyncze piksele obrazu, lecz tzw. obiekty, będące grupami pikseli spełniającymi zadane warunki jednorodności. Obiektowa struktura danych pozwala na stosowanie różnorodnych parametrów (niedostępnych w metodach tradycyjnych) oraz umożliwia badanie relacji zachodzących między poszczególnymi obiektami. Możliwe jest równoczesne analizowanie różnorodnych danych satelitarnych oraz danych, których źródłem są systemy informacji przestrzennej (Burnett i Blaschke, 2003). Dodatkowo, uzyskiwane wyniki ze względu na swój charakter przestrzenny (zdefiniowane granice obiektów) mogą być wykorzystywane do bezpośredniego zasilania baz danych (Benz i inni, 2004).

Metoda klasyfikacji obiektowej odgrywa szczególnie istotną rolę podczas analizy wysokorozdzielczych zdjęć satelitarnych, których opracowanie metodami tradycyjnymi jest szczególnie mało efektywne. Jest to wyjątkowo dobrze widoczne w przypadku klasyfikacji terenów zurbanizowanych charakteryzujących się wielką różnorodnością obiektów związanych nie tylko z odwzorowaniem budynków, lecz także z ich cieniami oraz całą infrastrukturą miejską, w której skład wchodzi również roślinność. Metoda obiektowa pozwala na wykorzystanie w procesie klasyfikacji informacji dodatkowych oraz przetworzonych danych satelitarnych. Przykładem mogą być prace Hofmanna. Prezentuje on możliwości podejścia obiektowego do rozpoznania infrastruktury miejskiej oraz drogowej na podstawie analizy zdjęcia satelitarnego IKONOS oraz numerycznego modelu terenu (DTM), uzyskanego na podstawie lotniczych pomiarów laserowych (Hofmann, 2001a; 2001b). Informacje wysokościowe z DTM pozwoliły między innymi na prawidłową identyfikację cieni budynków. Dodatkowo przed klasyfikacją zdjęcie zostało wstępnie przetworzone poprzez połączenie kanałów wielospektralnych z kanałem pan-

chromatycznym, z zastosowaniem metody Principal Components Analysis (PCA). Na podstawie podobnego zestawu danych klasyfikowane były również tereny rolnicze. W tym przypadku integracja obrazu satelitarnego i danych DTM pozwoliła na rozpoznanie 12 klas użytkowania ziemi na zróżnicowanym wysokościowo terenie (Neubert, 2001).

Z kolei Rego i Koch na podstawie zdjęcia z satelity IKONOS sklasyfikowali rozległe i zróżnicowane tereny miasta Rio de Janeiro, wydzielając zabudowę i równocześnie minimalizując liczbę pozostałych klas jedynie do roślinności i pól uprawnych (Rego i Koch, 2003). Problematyką klasyfikacji terenów zurbanizowanych zajmował się także zespół de Koka. W celu określenia na podstawie wysokorozdzielczych zdjęć satelitarnych stopnia pokrycia terenu formami antropogenicznymi zastosowano analizę tekstury obiektów oraz wartości współczynnika NDVI (de Kok i inni, 2003). Informacje o teksturze znalazły również zastosowanie w identyfikacji osiedli mieszkaniowych (na terenie Niemiec) w metodzie zaproponowanej przez Ehlersa (Ehlers i inni, 2006). W procesie klasyfikacji wykorzystał on, podobnie jak de Kok, wartości współczynnika NDVI, jednakże były one uzyskane na podstawie zdjęć satelitarnych średniej rozdzielczości, a nie wysokorozdzielczych.

Stosując klasyfikację obiektową, podjęto także próbę rozwiązania problemu identyfikacji obozów uchodźców w Tanzanii. Niezorganizowane skupiska różnej wielkości namiotów zostały rozpoznane na połączonych wielospektralnych i panchromatycznych zdjęciach z satelity IKONOS (Giada i inni, 2003). Ich poprawna automatyczna identyfikacja byłaby prawie niemożliwa przy zastosowaniu tradycyjnych metod rozpoznania. Natomiast klasyfikacja obiektowa zdjęć lotniczych o centymetrowej rozdzielczości pozwala na jeszcze bardziej precyzyjną identyfikację pojedynczych obiektów – dachów budynków, koron drzew oraz ich cieni – dzięki którym można z wielką precyzją określić granice zabudowy (Kressler i inni, 2005; Syed i inni, 2005). W literaturze znajdujemy również próby zastosowania podejścia obiektowego w klasyfikacji danych hiperspektralnych. Przykładem jest klasyfikacja terenów miejskich na podstawie 128 kanałów zarejestrowanych przez skaner HyMap (Greiwe i Ehlers, 2005).

Liu i inni (2005) na podstawie klasyfikacji obiektowej opracowali algorytm postępowania, który pozwala na automatyzację procesu aktualizacji map topograficznych oraz danych katastralnych. Składa się on z dwóch etapów. Najpierw na zdjęciu wysokiej rozdzielczości rozpoznawane są obiekty reprezentujące dachy budynków, a następnie ich granice są filtrowane w celu uzyskania prostokątnego kształtu. Tak przygotowane kontury dachów mogą być bezpośrednio wykorzystane w procesie aktualizacji bazy danych.

Nowa technika klasyfikacji obiektowej znajduje również zastosowanie w licznych badaniach lasów z wykorzystaniem metod teledetekcji. Podobnie jak w przypadku innych opracowań tematycznych, równocześnie z informacją spektralną analizowana jest tekstura obrazów, co pozwala na lepsze rozpo-

znanie drzewostanów. Jednym z przykładów jest klasyfikacja zdjęć satelity QuickBird obrazujących Puszczę Niepołomicką (Wężyk i inni, 2004; Wężyk i Bednarczyk, 2005). Również na przykładzie wysokorozdzielczych zdjęć satelitarnych, stosując w rozpoznaniu obiektowym funkcje filtrów krawędziowych, wykonano identyfikację terenów z sukcesją leśną (Wężyk i inni, 2006). W celu uzyskania większego zróżnicowania struktury powierzchni leśnych de Kok wykorzystał w swojej pracy obrazy po przetworzeniu filtrami krawędziowymi (de Kok i inni, 2005), natomiast Tiede i jego zespół do celów inwentaryzacji lasów w Bawarii wykorzystali wyniki pomiarów LiDARowych, na podstawie których uzyskano cyfrowy model terenu oraz koron drzew (Tiede i inni, 2004). W procesie klasyfikacji dane te były analizowane wspólnie z cyfrowymi zdjęciami wielospektralnymi zarejestrowanymi kamerą lotniczą. Dobre wyniki klasyfikacji obiektowej lasów uzyskano również na podstawie czarno-białych zdjęć lotniczych (Halounova, 2005). Nawet w skrótowym omówieniu zagadnień związanych z klasyfikacją lasów nie można pominąć analiz związanych z satelitarnymi danymi radarowymi. Kellndorfer i Ulaby (2003) wykazali m.in. związek biomasy lasu z parametrami obiektów zdefiniowanymi w czasie segmentacji treści zdjęć ERS i JERS.

Zastosowania klasyfikacji obiektowej są związane nie tylko ze zdjęciami wysokiej rozdzielczości. Rossner i Bock prezentują klasyfikację form pokrycia i użytkowania ziemi otrzymanych na podstawie analizy zdjęć wykonanych skanerem TM (Thematic Mapper) z satelity Landsat, a więc zdjęć o rozdzielczości 30 m. Na obszarze dwóch niemieckich prowincji o powierzchni ponad 4000 km² rozpoznali 10 klas z całkowitą dokładnością 80% (Rossner i Bock, 2005). Zdjęcia wykonane przez tego satelitę zastosowano również do identyfikacji terenów po pożarach w rejonie śródziemnomorskim (Mitri i Gitas, 2002). W Portugalii na zdjęciach otrzymanych za pomocą skanera ASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer) z satelity Terra rozpoznano 9 klas pokrycia i użytkowania ziemi (Gomes i Marçal, 2003), natomiast w Polsce, na poligonie badawczym w okolicach Warszawy, zastosowanie metody obiektowej umożliwiło rozpoznanie na zdjęciach z tego samego skanera 19 klas z całkowitą dokładnością 86,3% (Lewiński, 2005; 2006). Porównanie wyników klasyfikacji obiektowej wykonanej dla wybranych typów upraw w południowej części stanu Michigan, na podstawie zdjęć zarejestrowanych przez skanery TM, MODIS (Moderate Resolution Imaging Spectroradiometer) i ASTER, przedstawia publikacja Brooksa i innych (2006).

Jednym z podstawowych zagadnień monitoringu pokrycia i użytkowania ziemi na zdjęciach satelitarnych jest rozpoznawanie tzw. zmian. Zagadnienie to jest również analizowane z zastosowaniem podejścia obiektowego. Civco i inni (2002) przedstawili porównanie tradycyjnych i obiektowych metod określania zmian. Wykonane analizy nie pozwoliły na jednoznaczne określe-

nie optymalnego sposobu postępowania, jednakże metoda klasyfikacji obiektowej została określona jako bardzo obiecująca. Natomiast Blaschke (2005) koncentruje się na teoretycznym aspekcie detekcji zmian. Naumann i Siegmund (2006), stosując klasyfikację obiektową na podstawie zdjęć zarejestrowanych z pokładów satelitów serii Landsat skanerem MSS (MultiSpectral Scanner) w roku 1978 i TM w roku 2002, opracowali mapę zmian pokrycia terenu na wyspie Teneryfa, na której w ostatnich latach nastąpił znaczący rozwój przemysłu turystycznego. Uzyskane dane pozwoliły również na modelowanie dynamiki rozwoju zabudowy.

W niektórych pracach zamieszczone są porównania klasyfikacji obiektowej z klasyfikacjami wykonanymi innymi metodami. Oruc i inni (2004) na przykładzie zdjęcia ETM+ (Enhanced Thematic Mapper +) z satelity Landsat, obrazującego teren badań o charakterze przemysłowo-rolniczym w Turcji, wykonali porównanie wyników klasyfikacji obiektowej i nienadzorowanej przeprowadzonej metodą ISODATA. W obu przypadkach rozpoznano 7 klas pokrycia i użytkowania ziemi i uzyskano całkowitą dokładność na poziomie 81,3% i 66,8% – na podstawie klasyfikacji obiektowej otrzymano dokładność większą o 14,5%. Również na przykładzie zdjęć ETM+ z satelity Landsat i też z zastosowaniem klasyfikacji ISODATA na poligonie zlokalizowanym w zurbanizowanej okolicy Huntsville (Alabama) rozpoznano 9 klas z dokładnością 80,2%, a w przypadku klasyfikacji obiektowej z dokładnością 89,4% (Tadesse i inni, 2003). Whiteside i Ahmad (2005) wykonali porównanie różnych metod klasyfikacyjnych na podstawie zdjęcia wykonanego skanerem ASTER z satelity Terra. Na terenie Parku Narodowego Litchfield w północnej Australii rozpoznali 10 klas, dla których uzyskali dokładność 69% metodą pikselowej klasyfikacji nadzorowanej, natomiast wynik klasyfikacji obiektowej został oceniony na poziomie 78%. W przytoczonych publikacjach porównanie klasyfikacji było wykonane na przykładzie jednakowej liczby klas, bez względu na sposób wykonania klasyfikacji. Sugeruje to niewykorzystanie pełnych możliwości klasyfikacji obiektowej. Pominięto również zagadnienie jednostki odniesienia (Working Unit), która jest zawsze zdefiniowana w przypadku tworzenia baz danych o pokryciu i użytkowaniu ziemi na podstawie zdjęć satelitarnych.

Klasyfikacja obiektowa stwarza nowe, niedostępne w tradycyjnych metodach, możliwości analizy zdjęć satelitarnych. Pozwala na rozpoznanie klas, których nie można poprawnie sklasyfikować, stosując jedynie analizę wartości jaskrawości pojedynczych pikseli obrazu.

Chcąc zatem wykazać możliwości obiektowej analizy zdjęć w procesie automatyzacji pozyskiwania informacji na podstawie danych satelitarnych średniej rozdzielczości, podjąłem próbę zastosowania klasyfikacji obiektowej do utworzenia wektorowej bazy danych o pokryciu i użytkowaniu ziemi. Na przykładzie zdjęcia zarejestrowanego skanerem ETM+ z pokładu satelity Landsat wykonałem klasyfikację obiektową, a następnie przetworzyłem uzy-

skane wyniki, stosując specjalnie w tym celu opracowany algorytm postępowania. Zastosowane metody pozwoliły na automatyczne utworzenie bazy danych o zdefiniowanej jednostce odniesienia i o granicach wydzielen zbliżonych swoim charakterem do baz danych uzyskiwanych metodami tradycyjnej interpretacji wizualnej.

2. BAZY DANYCH O POKRYCIU I UŻYTKOWANIU ZIEMI

Systemy satelitarne umożliwiają obecnie wykonywanie ciągłych obserwacji powierzchni Ziemi. Na podstawie zdjęć o różnej rozdzielczości przestrzennej oraz spektralnej prowadzony jest monitoring różnorodnych komponentów środowiska naturalnego, w tym również pokrycia terenu i użytkowania ziemi. Informacje te pozwalają na zdobywanie wiedzy o naturalnych procesach zachodzących w środowisku, jak również będących wynikiem bezpośredniej działalności człowieka. Na ich podstawie można śledzić i prognozować konsekwencje zachodzących przemian w różnych skalach przestrzennych i czasowych, w tym również w skali globalnej. Przykładem mogą być analizy anomalii klimatycznych, wynikających między innymi ze zmian albedo powierzchni Ziemi, które są spowodowane istotnymi zmianami w pokryciu terenu. Liczba opracowań związanych z interpretacją pokrycia i użytkowania ziemi oraz z tworzeniem na tej podstawie baz danych systemów informacji geograficznej jest olbrzymia. Realizowane są projekty obejmujące swoim zasięgiem setki lub tysiące km², pojedyncze kraje, regiony, kontynenty oraz całą kulę ziemską. Charakteryzują się one dużym zróżnicowaniem tematycznym. Zależnie od potrzeb pozyskiwane są kompleksowe informacje, jak również wybrane, związane przykładowo tylko z lasami, terenami rolniczymi, osadnictwem czy też hydrologią.

Skala opracowań jest ściśle związana z rozdzielczością przestrzenną zdjęć satelitarnych, określaną przez wymiar piksela na powierzchni Ziemi. Zdjęcia o kilometrowej rozdzielczości, rejestrowane skanerem AVHRR (Advanced Very High Resolution Radiometer) z satelity NOAA lub skanerem Vegetation z satelity SPOT-4 oraz zdjęcia o rozdzielczości kilkuset metrów rejestrowane skanerem MODIS z pokładów satelitów Terra i Aqua są źródłem informacji dla opracowań małoskalowych, w skali kontynentów. Opracowania wielkoskalowe wykonywane są natomiast na podstawie zdjęć o rozdzielczości kilkudziesięciu metrów, ich przykładem są zobrazowania pozyskiwane za pomocą skanerów z pokładów satelitów Landsat, SPOT i IRS. Zdjęcia satelitarne o metrowej rozdzielczości, zbliżone do zdjęć lotniczych, rejestrowane m.in. przez skanery satelitów IKONOS i QuickBird, pozwalają na wykonanie opracowania nawet w skali 1:5000.

Bazy danych zawierające informacje o pokryciu i użytkowaniu ziemi, podobnie jak zdjęcia będące podstawą ich pozyskania, charakteryzują się różnym stopniem szczegółowości przestrzennej. Wynika to nie tylko z rozdzielczości przestrzennej analizowanych materiałów, lecz również jest związane z celem, któremu mają służyć. Różnice między bazami wynikają także z przyjętych założeń tematycznych, zasięgu powierzchniowego oraz z przyjętej metodyki ich opracowania.

Najwięcej baz danych, różnorodnych pod względem tematycznym i lokalizacji geograficznej, powstało w ramach projektów finansowanych przez FAO. Również w instytucie badawczym Joint Research Centre (JRC) działającym w ramach Komisji Europejskiej opracowywane są bazy danych w skali Europy i globalnej. Na kontynencie amerykańskim prace nad nimi prowadzone są przede wszystkim w U.S. Geological Survey, na uniwersytetach Maryland, Boston, Nebraska-Lincoln oraz oczywiście w NASA (Kniivila, 2004). Poza tym istnieje wielka liczba regionalnych, krajowych i lokalnych baz danych, opracowanych jednorazowo lub też cyklicznie aktualizowanych. Poniżej przedstawione są jedynie wybrane, najbardziej znane przykłady baz danych o pokryciu i użytkowaniu ziemi.

W latach 1995–2002 prowadzono prace w ramach projektu AFRICOVER (www.africover.org), koordynowanego przez FAO/UN. Na podstawie interpretacji wizualnej zdjęć satelitarnych zarejestrowanych przez skanery satelitów Landsat oraz SPOT, IRS i ERS uzyskano informacje o pokryciu terenu dla 10 krajów wschodniej Afryki, w tym dla 7 wykonano szczegółowe opracowania. Rozpoznano 24 klasy użytkowania ziemi z dokładnością geometryczną odpowiadającą mapom w skalach od 1:200 000 do 1:250 000; w przypadku małych krajów oraz wybranych obszarów o istotnym znaczeniu gospodarczym zastosowano skalę 1:100 000. Celem projektu AFRICOVER było nie tylko opracowanie map i baz danych o użytkowaniu ziemi, niezbędnych do planowania i kontroli rozwoju na poziomie narodowym i regionalnym, lecz również promocja nowych technologii w krajach afrykańskich. Stworzono współpracującą sieć instytucji posiadających personel przeszkolony w zakresie przetwarzania zdjęć satelitarnych, ich interpretacji oraz użytkowania systemów GIS, określono też zasady udostępniania i korzystania z danych. W ramach projektu opracowano specjalistyczne, dostępne bezpłatnie oprogramowania stanowiące zestaw niezbędnych narzędzi i metod służących do przetwarzania zdjęć i wspomagania ich interpretacji, tworzenia wektorowej bazy danych oraz wykonywania analiz. W ramach projektu AFRICOVER powstał międzynarodowy system klasyfikacyjny LCCS (Land Cover Classification System). Dzięki zastosowanej hierarchicznej strukturze klas oraz standaryzacji ich opisu i sposobu rozpoznania uzyskano narzędzie pozwalające na definiowanie klas każdego typu pokrycia terenu, bez względu na stopień szczegółowości rozpoznania. Obecnie system LCCS oceniany jest jako jedy-

ny uniwersalny system klasyfikacyjny i jest zalecany do stosowania we wszystkich pracach prowadzonych przez FAO.

Założeniem projektu GLC2000 (Global Land Cover 2000) było opracowanie bazy danych dla całej kuli ziemskiej w celu uzyskania informacji porównawczej dla już istniejących i przyszłych programów monitorowania zmian pokrycia terenu. Pracami kierował instytut badawczy JRC (Bartholome i inni, 2002; Bartholome i Belward, 2005). Wykonanie tak dużego projektu związane było ze ścisłą współpracą 30 międzynarodowych zespołów badawczych. Informację o pokryciu terenu uzyskano na podstawie zdjęć satelitarnych zarejestrowanych przez wielospektralny skaner Vegetation o rozdzielczości przestrzennej 1 km, zainstalowany na pokładzie satelity SPOT-4. Wstępnie przetworzone zdjęcia, zarejestrowane między listopadem 1990 r. i grudniem 2000 r., pochodziły z bazy danych obrazowych VEGA 2000. Dodatkowo, dla strefy okołorównikowej charakteryzującej się długotrwałym zachmurzeniem oraz do identyfikacji obszarów zabudowanych, wykorzystano zdjęcia radarowe zarejestrowane przez satelity: JERS, ERS i DMSP oraz pomiary skanera ATSR, zainstalowanego na pokładzie satelity ERS. Kontynenty podzielono na 18 regionów, dla których wykonano klasyfikację zdjęć Vegetation z zastosowaniem miesięcznych kompozycji współczynnika zieleni NDVI (Cabral i inni, 2003). Ze względu na wielkie zróżnicowanie terenów badawczych nie zastosowano jednakowych zasad klasyfikacyjnych, jednakże podstawowym narzędziem była klasyfikacja nienadzorowana. Następnie wyniki były uściślane na podstawie materiałów pomocniczych. W projekcie GLC2000 zastosowano tematyczny system klasyfikacyjny LCCS opracowany w ramach projektu AFRICOVER. Bazy danych GLC2000 są udostępniane w postaci rastrowej oraz wektorowej.

Na podstawie zdjęć wykonanych skanerem AVHRR z satelity meteorologicznego NOAA, w latach 1992–1993, w ramach projektu IGBP (International Geosphere-Biosphere Programme) opracowano światową bazę o pokryciu terenu o rozdzielczości 1 km – IGBP-DISCover global land cover. Powstała ona w wyniku współpracy U.S. Geological Survey, Uniwersytetu Nebraska-Lincoln oraz europejskiego instytutu JRC. Do rozpoznania 17 klas pokrycia terenu zastosowano klasyfikację nienadzorowaną, której wyniki były następnie weryfikowane i analizowane metodą interpretacji wizualnej. Danymi wejściowymi były miesięczne kompozycje wartości współczynnika NDVI. Do klasyfikacji zastosowano algorytm „Los Alamos”, przystosowany do przetwarzania dużych zbiorów obrazowych, bazujący na metodzie K-Means oraz stosujący metodę Monte Carlo do określania początkowych wartości klastrów w iteracyjnym procesie klasyfikacji. Klasyfikowano jedynie klasy pokrycia terenu związane z roślinnością, dla pozostałych obszarów (wody i tereny bez roślinności) opracowano system masek. Prace interpretacyjne wykonywane były na podstawie klasyfikacji treści zdjęć zarejestrowanych w różnych terminach, z podziałem powierzchni kuli ziemskiej na 961 regio-

nów. Interpretacja wspomagana była różnorodnymi materiałami pomocniczymi. Przyjęto zasadę, że każdy z regionów jest analizowany przez co najmniej trzech interpretatorów. Wyniki ich pracy były następnie porównywane i modyfikowane (Loveland i inni, 1999; Loveland i inni, 2000).

Baza danych o pokryciu terenu w Europie – Pan-European Land Cover Monitoring (PELCOM) powstała w latach 1996–1999 w ramach 4. Programu Ramowego. Na podstawie wielospektralnych zdjęć AVHRR rejestrowanych z satelity NOAA opracowano bazę danych o przestrzennym stopniu szczegółowości wynoszącym 1 km². Celem projektu było stworzenie systemu pozwalającego na szybką aktualizację informacji o pokryciu terenu na podstawie zdjęć satelitarnych z okresu wegetacyjnego. Stosując złożony sposób postępowania, opracowano metodologię klasyfikacji w skali całej Europy oraz metodę monitorowania zmian pokrycia terenu. Dla klas: lasy, zabudowa i wody opracowano maski. Maskę lasów powstała na podstawie zdjęć wykonanych przez satelity serii NOAA, natomiast w dwóch pozostałych przypadkach wykorzystano dane ze szczegółowej bazy CORINE, zawierającej informacje o pokryciu terenu. Baza CORINE została wykorzystana również w celu wyboru pól testowych, które porównano z wynikami klasyfikacji nienadzorowanej, wykonanej z zastosowaniem współczynnika NDVI, obliczonego na podstawie zdjęć AVHRR. W algorytmie klasyfikacyjnym wykorzystano także informację o odległościach spektralnych między klasyfikowanymi pikselami a najbliższą i drugą co do odległości klasą tematyczną. Stosunek tych odległości określał stopień pewności uzyskanego wyniku. Opracowano też zasady uwiarygodniania klasyfikacji poprzez porównywanie jej z materiałami pomocniczymi. Rozdzielczość zdjęć AVHRR pozwoliła na rozpoznanie 10 podstawowych klas pokrycia terenu (Mücher i inni, 2000)

W ostatnich latach bazy danych o pokryciu terenu w skali całego globu opracowywane są również na podstawie zdjęć satelitarnych wykonanych za pomocą skanera MODIS o rozdzielczości 250, 500 i 1000 m, pracującego na pokładzie satelitów Terra i Aqua. Na Uniwersytecie Bostońskim opracowano algorytm klasyfikacji zdjęć MODIS stosowany do pozyskiwania informacji o pokryciu terenu z rozdzielczością 1 km. Bazuje on na założeniach klasyfikacji nadzorowanej, jednakże pola treningowe są określane z zastosowaniem drzew decyzyjnych (Field i inni, 2002). Natomiast zdjęcia wykonane skanerem MODIS o rozdzielczości 250 m wykorzystano w systemie monitorowania zmian pokrycia terenu (Zhan i inni, 2002). System ten został stworzony na Uniwersytecie Maryland w celu szybkiego pozyskiwania informacji o zmianach powierzchni lasów, terenów zurbanizowanych, rolniczych oraz obszarów po pożarach lub zalanych wodą. Po stwierdzeniu występowania zmian wskazane miejsca są monitorowane na podstawie zdjęć o większej rozdzielczości.

Przytoczone przykłady pokazują, że bazy danych o pokryciu i użytkowaniu ziemi opracowywane są z zastosowaniem różnych metod. Stosuje się interpretację wizualną, automatyczną klasyfikację treści zdjęć oraz algorytmy, w których

praca interpretatora wspierana jest klasyfikacją. Ze względu na sposób zapisu i strukturę danych, bazy mogą być tworzone w formacie rastrowym lub wektorowym. Format rastrowy jest związany z klasyfikacją danych obrazowych, natomiast wynikiem interpretacji wizualnej jest wektor. W obecnej chwili trudno jednoznacznie stwierdzić, który z formatów jest lepiej dostosowany do potrzeb baz danych o pokryciu terenu. W formacie wektorowym granice wydzieleni są bardziej naturalne, równocześnie jednak format rastrowy pozwala na szybsze wykonywanie obliczeń i analiz (Tomlin, 1990). Potencjał analityczny i prezentacyjny baz danych jest w dużym stopniu uzależniony od oprogramowania, którego możliwości nieustannie są rozwijane.

2.1. Bazy danych o pokryciu i użytkowaniu ziemi opracowane w ramach programu CORINE Land Cover

W celu gromadzenia informacji o środowisku krajów europejskich w roku 1985 Komisja Europejska uruchomiła program CORINE. Jedną z jego części jest program CORINE Land Cover, którego założeniem jest dostarczanie, raz na 10 lat, aktualnej informacji o pokryciu i użytkowaniu ziemi w krajach europejskich. Dotychczas opracowano dwie bazy CLC90 (CORINE Land Cover 1990) oraz CLC2000, obrazujące stan pokrycia i użytkowania ziemi w roku 1990 oraz w roku 2000. Informacje te uzyskano na podstawie zdjęć z satelity Landsat zarejestrowanych skanerem TM (pierwsza baza) oraz skanerem ETM+ (druga baza) o rozdzielczości przestrzennej 30 m dla obszaru niemal całej Europy. W obu przypadkach w pozyskiwaniu informacji zastosowano metodę wizualnej interpretacji zdjęć satelitarnych według zasad postępowania szczegółowo przygotowanej metodyki.

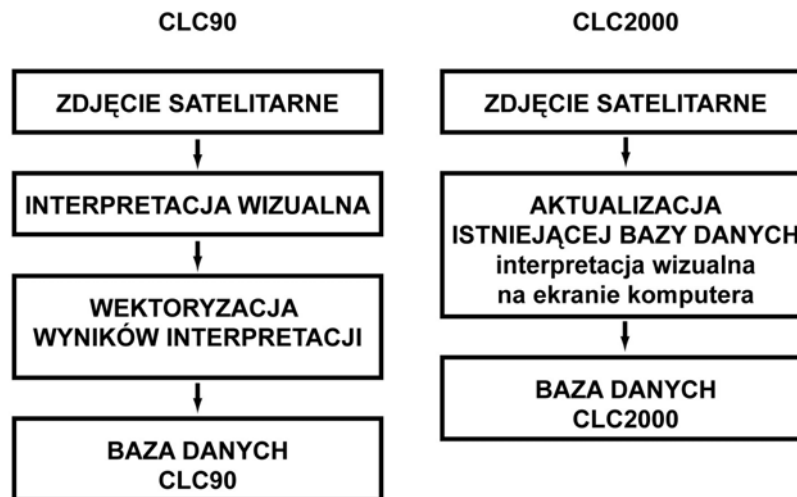
Bazy danych opracowane w ramach programu CORINE Land Cover prezentują jednolity obraz pokrycia i użytkowania ziemi w krajach europejskich. W przypadku Polski są pierwszym kompleksowym opracowaniem tego typu wykonanym w formie numerycznej. Doświadczenia programu CORINE posłużyły do powstania wielu tradycyjnych map pokrycia terenu. Ciołkosz i Bielecka (2005) opisują szereg zastosowań baz CORINE w Polsce w analizach przestrzennych, wykonywanych na potrzeby programów badawczych oraz administracji państwowej. Dane programu CORINE zostały również wykorzystane do utworzenia nowych baz o większym stopniu szczegółowości (Ferenec i inni, 1995; Bielecka, Ciołkosz, 2000; Białousz i inni, 2004) oraz do weryfikacji i uzupełniania innych baz (Pirog, 2004). Na ich podstawie określono m.in. formy pokrycia i użytkowania ziemi terenów zalanych falą powodziową w dolinie Odry (Bielecka, Ciołkosz, 1998). Bazy CORINE były również wykorzystywane do opracowania Bazy Danych Ogólno-geograficznych (Baranowski, 2004) oraz baz danych gleb (Białousz, 2004).

2.1.1. Technologia opracowania baz danych CLC90 i CLC2000

Bazy danych o pokryciu i użytkowaniu ziemi programu CORINE zostały opracowane z zastosowaniem hierarchicznej, trzypoziomowej legendy, której budowa pozwala na agregowanie wydzieleń. Na pierwszym poziomie legendy zdefiniowano 5 podstawowych klas: tereny zantropogenizowane, tereny rolne, lasy i ekosystemy seminaturalne, obszary podmokłe oraz obszary wodne. Następny poziom zawiera 15 bardziej szczegółowych klas, a na ostatnim trzecim poziomie zdefiniowano 44 klasy pokrycia i użytkowania ziemi, występujące na terenie całej Europy. Interpretacja wizualna została wykonana z zastosowaniem jednostki odniesienia o wielkości 25 ha oraz dodatkowo ustalono minimalną szerokość interpretowanych wydzieleń wynoszącą 100 m (CORINE Land Cover..., 1993).

Bazy danych CLC90 i CLC2000 dla obszaru całej Polski opracowane zostały w Instytucie Geodezji i Kartografii. Etapy tworzenia pierwszej bazy są szczegółowo opisane przez Baranowskiego i Ciołkosza (1997). Dokonano interpretacji 297 fotomap w skali 1:100 000, opracowanych na podstawie zrezyfikowanych kompozycji barwnych RGB utworzonych ze zdjęć wykonanych w 4, 5 i 3 kanale rejestrowanym za pomocą skanera TM. Zasięgi poszczególnych klas wyznaczano na kalkach interpretacyjnych, które następnie zdigitalizowano i granice wydzieleń zamieniono na format wektorowy. Stosując oprogramowanie ARC/INFO, utworzono topologię warstwy wektorowej i następnie ręcznie wprowadzano kody wydzieleń (zgodnie z legendą). W ten sposób powstała jednolita baza danych dla obszaru całego kraju, zawierająca informacje o 33 formach pokrycia terenu występujących w kraju. Proces pozyskiwania i przetwarzania danych był bardzo pracochłonny. Interpretacja zdjęć zajęła 1480 osobogodzin, wykonanie opracowania numerycznego również zajęło setki godzin.

W roku 2001 w IGiK rozpoczęto prace nad bazą CLC2000 zakończone 3 lata później. Nowa baza utworzona została także z zastosowaniem wizualnej interpretacji zdjęć satelitarnych, jednakże technologia w porównaniu z poprzednią została udoskonalona (Nunes de Lima, 2005). Polegało to na innym sposobie interpretacji, w którym wykorzystano już istniejącą bazę CLC90. Interpretacji dokonano bezpośrednio na monitorze komputera. Interpretator, obserwując na monitorze bazę CLC90 nałożoną na aktualne zdjęcia satelitarne, koncentrował się przede wszystkim na wydzieleniach, które były związane ze zmianami form pokrycia terenu o wielkości większej od 5 ha. W ten sposób powstała baza CLC2000 oraz baza zmian, które zostały zaobserwowane między latami 1990 i 2000. Przyjęta zasada aktualizacji już istniejącej bazy danych oraz nowy sposób interpretacji, wspomagany oprogramowaniem Inter-Change (Buttner i inni, 2003), w istotny sposób pozwolił na skrócenie czasu opracowania. Uproszczone schematy procesu opracowania bazy CLC90 i CLC2000 przedstawione są na rysunku 1.



Rys. 1. Schemat opracowania baz danych CORINE CLC90 i CLC2000

W celu zachowania ustalonych standardów wszystkie etapy tworzenia baz CORINE związane były z kontrolą wykonania. Wiarygodność interpretacji zdjęć satelitarnych z obszaru Polski została oceniona na poziomie 92,7% dla lat 1990 i 2000 oraz 99% w przypadku bazy zmian (Bielecka, Ciołkosz, 2004).

Na przykładzie tych samych zdjęć satelitarnych zarejestrowanych skanarami TM i ETM+ z satelitów serii Landsat, które wykorzystano w programie CORINE, opracowano bazę danych o pokryciu i użytkowaniu ziemi również w RPA. Zespół prowadzący prace w RPA nie posłużył się metodą interpretacji wizualnej, lecz przyjął inne założenia i zastosował metodę klasyfikacji nienadzorowanej (NLC2000..., 2005). Dzięki automatyzacji klasyfikacji ograniczono czasochłonność wykonania opracowania, równocześnie jednak na końcowych wydrukach bazy danych wyraźnie widoczna jest rastrowa struktura obrazu klasyfikacyjnego. Objawia się ona nie tylko w czasie prezentacji bazy w skali większej niż 1:50 000, w której można już zaobserwować pojedynczy piksel zdjęcia satelitarnego reprezentującego w terenie obszar o wymiarach 30x30 m. Jest ona również widoczna w mniejszych skalach, przede wszystkim w przypadku obszarów charakteryzujących się dużym zróżnicowaniem struktury pokrycia występującym w ramach jednej klasy. Wynika to ze specyfiki metody klasyfikacji, w której analizowane są wartości poszczególnych pikseli obrazu bez uwzględnienia ich związków nawet z najbliższym otoczeniem. Dlatego też piksele reprezentujące ekstremalne wartości klas, niespełniające warunków określonych przez ich wzorce (pola treningo-

we), są klasyfikowane inaczej niż ich otoczenie. Przykładem takiej klasy może być zabudowa, zwłaszcza rozproszona, oraz tereny rolnicze, na których występuje roślinność naturalna. W przypadku interpretacji wizualnej tego rodzaju sytuacje (występujące bardzo często) nie stanowią istotnego problemu. Interpretator jest w stanie poprawnie rozpoznać formy pokrycia terenu bez względu na stopień ich niejednorodności. Optymalnym rozwiązaniem w aspekcie tworzenia baz danych o pokryciu i użytkowaniu ziemi jest stosowanie metod postępowania charakteryzujących się wysokim stopniem automatyzacji i równocześnie pozwalających na uzyskanie wyników zbliżonych do tradycyjnej interpretacji wizualnej.

2.1.2. Interpretacja wizualna zdjęć satelitarnych

Bazy danych wykonane w ramach programu CORINE są opracowywane z zastosowaniem tradycyjnej, wizualnej metody interpretacji zdjęć satelitarnych. Automatyczne metody cyfrowe znajdują zastosowanie jedynie w celu opracowania końcowej wektorowej bazy danych.

Interpretacja wizualna może być wykonywana na podstawie zdjęć w formie wydruków lub obrazu wyświetlonego na ekranie komputera. Zależnie od rodzaju danych satelitarnych i sposobu ich przetworzenia obraz może być monochromatyczny lub barwny. Wynikiem analizy zdjęć satelitarnych są tzw. wydzielienia, czyli powierzchnie obrysowane granicą lub informacje liniowe, naniesione bezpośrednio na zdjęcie, kalkę interpretacyjną lub wprowadzone do wektorowej bazy danych. Zasady postępowania zbliżone są do interpretacji zdjęć lotniczych (Sabins, 1978). Różnice związane są przede wszystkim z parametrami zdjęć, mianowicie z rozdzielczością przestrzenną oraz spektralną wynikającą z możliwości technicznych kamer i skanerów obrazujących powierzchnię Ziemi.

Opisując szczegółowo zasady interpretacji zdjęć lotniczych Ciołkosz i inni (1986) podają trzy podstawowe etapy procesu interpretacji, rozpatrywane w aspekcie psychologiczno-fizjologicznym, które mają miejsce niezależnie od metodyki pracy: wykrycie obiektu, szczegółowe rozpoznanie oraz ocena i interpretacja rezultatu. Wykrycie obiektu polega na spostrzeżeniu jego cech (kształt, wielkość, tekstura, barwa). Potem następuje rozpoznanie na podstawie bezpośrednich cech rozpoznawczych obiektu, cech pośrednich związanych z zależnościami między obiektami oraz cech kompleksowych, stanowiących naturalne kombinacje wszystkich cech rozpoznawczych. Bezpośrednimi cechami rozpoznawczymi obiektów są ich kształt, wielkość, foton lub barwa, tekstura oraz struktura, która jest uzależniona od rozdzielczości przestrzennej zdjęcia oraz od skali prezentacji obrazu. Pośrednimi cechami interpretacyjnymi są wzajemne relacje między obiektami, ich położenie względem sytuacji topograficznej, układ cieni (widoczny na zdjęciach o wysokiej roz-

dzielczości) oraz zależności między poszczególnymi komponentami środowiska zobrazowanymi na zdjęciu.

Przystępując do interpretacji zdjęć, należy mieć precyzyjnie zdefiniowany cel i zakres pracy. Istotne jest również posiadanie niezbędnej wiedzy o interpretowanym zjawisku, o jego relacjach z otaczającym środowiskiem geograficznym oraz wiedzę o sposobie rejestracji obrazu powierzchni Ziemi. Podstawową zasadą interpretacji jest postępowanie „od ogółu do szczegółu”. Najpierw rozpoznawane są obiekty o dobrze zdefiniowanych cechach rozpoznawczych, następnie obiekty charakteryzujące się niższym kontrastem względem otoczenia. Każda praca interpretacyjna związana jest z koniecznością zdefiniowania systemu klasyfikacyjnego, zwanego również legendą, oraz z ustaleniem jednostki odniesienia.

Sposób pracy interpretatora zależy w dużej mierze od jego doświadczenia oraz od rodzaju interpretowanego zjawiska. Campbell (2002) podaje pięć rodzajów strategii stosowanych w fotointerpretacji; są nimi: obserwacja terenowa, rozpoznanie bezpośrednie, interpretacja przez wnioskowanie, interpretacja probabilistyczna oraz interpretacja deterministyczna. Wykonanie obserwacji terenowych jest związane z wizytacją terenu badań, która jest niezbędna w przypadku braku jednoznacznych przesłanek definiujących zobrazowany na zdjęciu obiekt. Przeciwnieństwem powyższej sytuacji jest rozpoznanie bezpośrednie wykonane na podstawie cech rozpoznawczych widocznych na zdjęciu oraz wiedzy interpretatora. Interpretacja przez wnioskowanie polega natomiast na rozpoznananiu zjawisk, które nie są widoczne bezpośrednio, lecz są skorelowane z występowaniem innych zjawisk. Stosując taki sposób postępowania, należy korzystać z materiałów pomocniczych, którymi są najczęściej mapy topograficzne i tematyczne. Czasem interpretator, nie mając jednoznacznej pewności co do swojej oceny, może podać stopień prawdopodobieństwa wystąpienia analizowanego zjawiska, mówimy wtedy o interpretacji probabilistycznej. Ostatnia, deterministyczna strategia interpretacji związana jest z ilościowymi zależnościami, które można uzyskać bezpośrednio na podstawie zdjęcia. Przykładem takiego postępowania może być obserwacja stereoskopowa. W praktyce osoby dokonujące interpretacji zdjęć posługują się różnymi sposobami postępowania, zależnie od sytuacji, wiedzy i doświadczenia.

Odmiernym sposobem interpretacji jest metoda polegająca na określeniu tzw. regionów fotomorficznych (Campbell, 2002), charakteryzujących się podobnym sposobem odwzorowania na zdjęciu, zbliżonym fototonie (barwie) i teksturze. Określanie regionów fotomorficznych jest skutecznym sposobem postępowania, jednakże musi być wykonane ze szczególną uwagą i wiedzą o środowisku geograficznym, gdyż wygląd regionów ściśle związany jest z geologią, hydrologią i topografią terenu oraz z występującym użytkowaniem ziemi. Na drugim etapie interpretacji regiony są identyfikowane (klasyfikowane) na podstawie dodatkowych informacji. Olędzki (2001) przedstawia szczegółowy opis postępowania i charakterystykę regionów fotomorficznych,

które zostały przez niego wyznaczone dla całego obszaru Polski na podstawie zdjęć satelitarnych zarejestrowanych skanerem MSS z satelity Landsat.

Ograniczenia interpretacji wizualnej związane są przede wszystkim z tzw. ograniczeniami naturalnymi, czyli z możliwościami przetwarzania informacji przez interpretatora. Każdy z nas może rozróżnić od 8 do 16 tonów szarości (Jensen, 1996), co jest niewielką liczbą w porównaniu z 256 poziomami szarości, które są możliwe do uzyskania na podstawie choćby 8-bitowych danych satelitarnych, nie mówiąc już o liczbie barw występujących na kompozycji barwnej, będącej złożeniem trzech kanałów spektralnych. Interpretator, analizując zdjęcie satelitarne, koncentruje się na obrazie przedstawionym na wybranej kompozycji barwnej lub otrzymanym na podstawie jednego kanału spektralnego. W przypadku zdjęć wielospektralnych często zachodzi potrzeba korzystania z obrazów pozostałych kanałów lub innych kompozycji barwnych, nie mówiąc już o dodatkowych materiałach pomocniczych. Jedynie od doświadczenia interpretatora zależy zdolność wykonania skutecznej analizy tak dużej liczby informacji. W praktyce korzysta się najczęściej z jednego lub dwóch zestawów danych obrazowych. Kolejne ograniczenie interpretacji wizualnej związane jest z brakiem całkowitej powtarzalności uzyskanych wyników. Mimo ustalonych zasad postępowania nie jest możliwe uzyskanie identycznych rezultatów nawet w przypadku interpretacji powtórzonej przez tę samą osobę. Podstawową wadą interpretacji wizualnej jest jej czasochłonność. Przyspieszenie prac interpretacyjnych (pomijając aspekt organizacyjny) może nastąpić jedynie przez zwiększenie liczebności zespołu opracowującego zdjęcia, z czym związane są dodatkowe koszty.

Mimo wymienionych ograniczeń interpretacja wizualna jest i nadal będzie jedną z podstawowych metod analizy zdjęć satelitarnych. Nawet w przypadku opracowania niezawodnych algorytmów obliczeniowych rolę człowieka będzie końcowa ocena wyników automatycznej klasyfikacji.

3. ZASTOSOWANIE KLASYCZNYCH METOD KLASYFIKACJI TREŚCI ZDJĘĆ SATELITARNYCH DO ROZPOZNANIA FORM POKRYCIA I UŻYTKOWANIA ZIEMI

Automatyczne metody klasyfikacji zdjęć satelitarnych bazują na właściwościach odbicia promieniowania elektromagnetycznego przez obiekty znajdujące się na powierzchni Ziemi. Wykorzystując wielkość odbicia w różnych zakresach widma, określa się charakter obiektu, co prowadzi do jego rozpoznania.

W tradycyjnych metodach klasyfikacji treści zdjęć analizowane są wyłącznie wartości jaskrawości każdego piksela tworzącego obraz, w każdym z zarejestrowanych zakresów promieniowania (w kanałach spektralnych). Wyróżnia się dwa podstawowe typy klasyfikacji: klasyfikację nadzorowaną i nienadzorowaną.

Różnica między nimi polega przede wszystkim na odmiennym sposobie tworzenia wzorców klas, na podstawie których na kolejnym etapie klasyfikacji następuje rozpoznanie poszczególnych form pokrycia terenu.

W klasyfikacji nadzorowanej definiowane są tzw. pola treningowe pełniące rolę wzorca klasy. Są one określane przez operatora a priori na podstawie analizy wizualnej obrazu oraz materiałów pomocniczych (mapy tematyczne, pomiary terenowe). Natomiast w klasyfikacji nienadzorowanej wzorce klas tworzone są w sposób odmienny z zastosowaniem automatycznych algorytmów statystycznych, które pozwalają na zdefiniowanie tzw. klastrów będących odpowiednikami pól treningowych. Liczba stosowanych metod w klasyfikacji nienadzorowanej jest bardzo duża, Jensen (1996) pisze nawet o setkach opracowanych algorytmów. Lillesand i inni (2004) podają algorytm K-mean jako podstawowy, na którego założeniach powstały kolejne, w tym jeden z najbardziej popularnych ISO-DATA (Interactive Self-Organizing Data Analysis).

Wspólną cechą algorytmów klasyfikacji nienadzorowanej jest iteracyjny sposób obliczeń, którego celem jest zdefiniowanie grup pikseli tworzących klastry. Obliczenia wykonywane są w n -wymiarowej przestrzeni spektralnej. Rozpoczynają się one od losowego wybrania lub wskazania przez operatora tzw. punktów początkowych, którymi są piksele obrazu. Wartości ich jasności stają się pierwszymi reprezentantami klas spektralnych. Następnie kolejne piksele obrazu (definiowana jest liczba pikseli biorących udział w tych obliczeniach) przydzielane są do poszczególnych klas na podstawie kryteriów związanych z ich wartościami. W ten sposób powstają grupy pikseli, które w kolejnych cyklach obliczeniowych są łączone lub dzielone w celu uzyskania jednorodnych klastrów. Iteracje wykonywane są aż do momentu osiągnięcia danego poziomu jednorodności, określonego parametrami statystycznymi, zdefiniowanymi przez operatora lub przez wewnętrzne funkcje algorytmu. W większości znanych rozwiązań operator podaje maksymalną liczbę możliwych do wykonania iteracji oraz dodatkowo ma możliwość przeglądania parametrów statystycznych pośrednich wyników, które mogą wskazywać na konieczność kontynuacji obliczeń lub na ich przerwanie.

Po zdefiniowaniu wzorców klas metodą nadzorowaną lub nienadzorowaną wykonywana jest klasyfikacja treści całego obrazu. W przypadku klasyfikacji nadzorowanej po zakończeniu tej operacji uzyskujemy już wynik końcowy, natomiast w klasyfikacji nienadzorowanej kolejnym zadaniem operatora jest wykonanie podziału uzyskanych klas na klasy tematyczne, gdyż ten aspekt klasyfikacji nie jest uwzględniany w czasie tworzenia klastrów, które są wzorcami klas jedynie w aspekcie ich właściwości spektralnych.

Można wyróżnić trzy podstawowe algorytmy klasyfikacyjne: metodę równoległoboków, najmniejszej odległości oraz największego prawdopodobieństwa. Pierwsza z nich, metoda równoległoboków (Parallelepiped), charakteryzuje się stosunkowo prostym algorytmem. Kolejne piksele obrazu

przyporządkowywane są do poszczególnych klas na podstawie prostej zależności (Jensen, 1996):

$$L_{ak} \leq x_k \leq H_{ak} \quad (1)$$

gdzie:

L_{ak} – dolna granica zakresu wartości jaskrawości pikseli klasy a w kanale k ,

H_{ak} – górna granica zakresu wartości jaskrawości pikseli klasy a w kanale k ,

x_k – wartość jaskrawości analizowanego piksela w kanale k .

Zakresy klas określone są na podstawie średniej wartości oraz odchylenia standardowego obliczonego dla pól treningowych:

$$L_{ak} = s_{ak} - \delta_{ak} \quad H_{ak} = s_{ak} + \delta_{ak} \quad (2, 3)$$

gdzie:

s_{ak} – średnia jaskrawość klasy a w kanale k ,

δ_{ak} – odchylenie standardowe klasy a w kanale k .

Piksel obrazu jest klasyfikowany do danej klasy, jeżeli znajduje się w przedziale jej wartości. W interpretacji graficznej 2-wymiarowej przestrzeni spektralnej granice klasy wokół średniej tworzą prostokąt o wymiarach związanych z wartością odchylenia standardowego. Zakres granic klas może być zwiększony (lub zmniejszony) przez zmianę krotności odchylenia standardowego, która w praktyce najczęściej nie przekracza wartości 3. Zastosowanie wąskich przedziałów klas powoduje wystąpienie dużej liczby pikseli niesklasyfikowanych, natomiast rozszerzenie ich powoduje „nakładanie się” klas; piksel może należeć do kilku klas równocześnie. W takich sytuacjach jest on przyporządkowywany do klasy, która została zdefiniowana jako pierwsza. Metoda równoległoboków jest prosta pod względem założeń oraz wykonywanych obliczeń, jednakże z uwagi na problemy związane z nakładaniem się klas nie pozwala na uzyskanie w pełni zadowalających wyników.

W metodzie najmniejszej odległości (Minimum Distance) miarą klasyfikacji pikseli obrazu jest ich odległość spektralna od środka klas, które określone są przez wartości średnie definiujących je grup pikseli. Najczęściej stosowane są dwa sposoby określania tej odległości (Jensen, 1996): odległość euklidesowa oraz suma wartości bezwzględnych różnic.

$$d_e = \sqrt{\sum_{k=1}^n (x_k - s_k)^2} \quad d_r = \sum_{k=1}^n |x_k - s_k| \quad (4, 5)$$

gdzie:

d_e – odległość euklidesowa,

d_r – suma wartości bezwzględnych różnic,

x_k – wartość jaskrawości piksela w kanale k ,

s_k – średnia jaskrawość klasy w kanale k .

Piksel zostaje przyporządkowany do „najbliższej” klasy oraz jeżeli jego odległość do środka tej klasy jest mniejsza od zadanej wartości progowej. Metoda ta jest bardzo często stosowana, gdyż stosunkowo prosty algorytm pozwala na uzyskanie dobrych wyników.

W przeciwieństwie do dwóch poprzednich sposobów klasyfikacji w metodzie klasyfikacji największego prawdopodobieństwa (Maximum Likelihood) piksele obrazu są klasyfikowane bez stosowania kryteriów odległości, lecz na podstawie rachunku prawdopodobieństwa. Dla każdego piksela obrazu obliczane jest prawdopodobieństwo jego przynależności do poszczególnych klas zdefiniowanych na podstawie pól treningowych lub klastrów. Piksel zostaje przydzielony do klasy, w której jego wystąpienie jest najbardziej prawdopodobne. Jeżeli w n -wymiarowej przestrzeni spektralnej występuje piksel x , którego położenie określone jest przez wektor X , to prawdopodobieństwo p_a jego wystąpienia w klasie a jest następujące (Jensen, 1996):

$$p_a = \{-0.5 \ln[\det(V_a)]\} - \left[0.5(X - M_a)^T (V_a^{-1})(X - M_a)\right] \quad (6)$$

gdzie:

V_a – macierz kowariancji jaskrawości pikseli tworzących klasę a ,

M_a – wektor średnich wartości jaskrawości pikseli tworzących klasę a .

Metoda największego prawdopodobieństwa bazuje na założeniach rozkładu normalnego. Dlatego też definicje klas (pola treningowe, klastry) powinny charakteryzować się histogramami o rozkładzie Gaussa. Bezsporną zaletą tej metody jest możliwość podania *a priori* wagi prawdopodobieństwa przyporządkowania pikseli do danej klasy. Zazwyczaj wagi są określane na podstawie oceny powierzchni zajmowanej przez poszczególne klasy na analizowanym zdjęciu. Obecnie jest to najczęściej stosowana metoda klasyfikacji.

W ostatnich latach popularną techniką klasyfikacyjną są tzw. sieci neuronowe. Jest to technika obliczeniowa związana z modelem matematycznym, składającym się z warstw posiadających węzły, którymi są tzw. neurony.

Wszystkie neurony z danej warstwy posiadają połączenia ze wszystkimi neuronami warstw sąsiednich. Połączenia tworzą sieć, której topologia jest utożsamiana z zasadami funkcjonowania ludzkiego mózgu. Zmiany wartości neuronów lub też ich wag związane są z koniecznością wykonania wyjątkowo złożonych obliczeń realizowanych w seriach równoległe przebiegających procesów. Jak podają Tso i Mather (2001) historia sieci neuronowych związana jest z pracami badawczymi prowadzonymi już w latach 40. XX w. W algorytmach klasyfikacji zdjęć satelitarnych sieci neuronowe wykorzystują ogólne założenia klasyfikacji nadzorowanej i nienadzorowanej. Ich popularność w ostatnich latach związana jest przede wszystkim z pojawieniem się algorytmów stosujących uproszczone metody obliczeniowe. Dzięki nim czas wykonywania obliczeń uległ skróceniu, ale i tak czasochłonność metody jest istotnym ograniczeniem jeśli idzie o praktyczne zastosowania. Unikalną cechą sieci jest zdolność samouczenia się. Iwaniak i inni (2004), stosując sieci neuronowe, uzyskali bardzo wysoką dokładność rozpoznania terenów zabudowanych, których poprawna klasyfikacja jest szczególnie trudna w przypadku stosowania tradycyjnych algorytmów klasyfikacji.

Chcąc sprawdzić możliwości klasyfikacji treści zdjęcia satelitarnego z zastosowaniem tradycyjnych metod, a także w celu porównania ich z wynikami przeprowadzonej następnie klasyfikacji obiektowej, wybrano poligon badawczy zobrazowany na zdjęciu satelitarnym wykonanym z pokładu satelity Landsat.

3.1. Charakterystyka terenu badań oraz danych satelitarnych Landsat ETM+

Poligonem tym jest teren o powierzchni 423 km² położony w środkowej części Polski na Nizinie Mazowieckiej w pobliżu Warszawy. W jego centrum, między Wisłą i Narwią, znajduje się miasto Legionowo (49 000 mieszkańców). Na poligonie badawczym występują lasy iglaste, liściaste, tereny rolnicze, łąki oraz zabudowa z przewagą zabudowy rozproszonej. Tereny rolnicze charakteryzują się dużym stopniem rozdrobnienia. Pola o małej powierzchni, często poniżej 1 ha, sąsiadują z użytkami zielonymi. Na Narwi znajduje się sztuczny zbiornik Zalew Zegrzyński o powierzchni ponad 30 km². Obraz satelitarny terenu badań przedstawiony jest na rysunku 2.



Rys. 2. Teren badań. Kompozycja RGB (4, 5, 3) zdjęcia satelitarnego zarejestrowanego skanerem ETM+ z pokładu satelity Landsat

Analiza pokrycia i użytkowania ziemi została wykonana na podstawie zdjęcia satelitarnego zarejestrowanego 7 maja 2000 r. skanerem ETM+ satelity Landsat 7. Wiosenny termin rejestracji zdjęcia nie jest optymalny jeśli idzie o rozpoznanie klas pokrycia i użytkowania ziemi. Lepsze wyniki można uzyskać na podstawie zdjęć z sierpnia i września, jednak ze względu na ograniczoną dostępność bezchmurnych zdjęć w tym czasie, wiosenne zdjęcia często muszą być wykorzystywane do prac interpretacyjnych, co zostało potwierdzone w toku realizacji programu CORINE Land Cover (Ciołkosz i Bielecka, 2005).


Na zdjęciach wykonanych przez satelitę Landsat skanerem ETM+ obraz powierzchni Ziemi rejestrowany jest w 6 zakresach widma z rozdzielczością przestrzenną 30 m, natomiast w zakresie termalnym (kanał 6) z rozdzielczością 60 m. Skaner ETM+ wykonuje dodatkowo zdjęcia w tzw. kanale panchromatycznym obejmującym zakres fal 0,5 – 0,9 μm . Ich rozdzielczość przestrzenna wynosi 15 m. Podstawowe parametry skanera ETM+ przedstawione są w tabeli 1.

Tabela 1. Podstawowe parametry skanera ETM+ satelity Landsat

kanał	zakres spektralny (μm)	rozdzielczość	
		przestrzenna (m)	radiometryczna (bity)
1	0,45 – 0,52	30	8
2	0,52 – 0,60	30	8
3	0,63 – 0,69	30	8
4	0,76 – 0,90	30	8
5	1,55 – 1,75	30	8
6	10,4 – 12,5	60	8
7	2,08 – 2,35	30	8
PAN	0,50 – 0,90	15	8
wysokość orbity: 705 km			
czas rewizyty: 16 dni			

Zdjęcie wykonane skanerem ETM+ charakteryzowało się wzajemnym położeniem danych wielospektralnych i panchromatycznych zgodnym ze standardem LPGA (Level 1 Product Generation System), w którym środki pikseli wielospektralnych pokrywają się ze środkiem co drugiego piksela panchromatycznego. Graficzny schemat wzajemnego położenia pikseli przedstawia rysunek 3. Zamieszczono na nim również drugi stosowany standard wzajemnego położenia danych, NLAPS (National Land Archive Production System). Odmienne sposoby orientacji pikseli wynikają z różnych metod przetwarzania danych satelitarnych w naziemnych stacjach odbiorczych (http://landsat.usgs.gov/technical_details/image_processing/lpgs_vs_NLAPS.php). Informacje te są najczęściej zaniędywane, jednakże w prezentowanej klasyfikacji były analizowane ze względu na sposób traktowania danych o różnej rozdzielczości przez oprogramowanie klasyfikacji obiektowej eCognition (wersja 3), zastosowane w dalszej części pracy. Oprogramowanie to dopuszcza stosowanie danych o różnej rozdzielczości, jednakże są one „zgrywane” względem lewych górnych narożników zdjęć – dane obrazowe zostają przesunięte względem siebie tak, aby rozpoczynały się w tym samym punkcie. Chcąc uniknąć problemów związanych z przesunięciem treści zdjęć, podjęto decyzję o przepróbkowaniu (*resampling*) danych wielospektralnych do wiel-

kości pikseli zakresu panchromatycznego, stosując do tego celu algorytm najbliższego sąsiada (Nearest Neighbor).



Rys. 3. Schemat wzajemnego położenia pikseli zakresu wielospektralnego (30 m) i panchromatycznego (15 m) zdjęć ETM+ w systemie rejestracji LPGS i NLAPS

3.2. Wstępne przetworzenie danych obrazowych

W ramach wstępnego przetworzenia zdjęcia satelitarnego obrazującego teren badań wykonano korekcję atmosferyczną. Jest ona oparta na zasadach równania przepływu energii i ma na celu eliminację wpływu atmosfery na promieniowanie rejestrowane przez skaner znajdujący się na pokładzie satelity. Powinna ona być stosowana przede wszystkim w przypadku pozyskiwania na podstawie danych satelitarnych informacji ilościowych. Podczas klasyfikacji pojedynczych zdjęć korekcja atmosferyczna najczęściej nie jest wykonywana, jednakże jest to konieczne w przypadku klasyfikacji serii zdjęć, zarejestrowanych w różnych okresach, na podstawie których ma powstać jednorodny obraz klasyfikacyjny. Korekcję wykonano z zastosowaniem oprogramowania ATCOR2 (Richter, 2006), będącego jednym z modułów systemu przetwarzania obrazów PCI Geomatica. Zastosowano standardową definicję atmosfery opracowaną dla wiosennej pory roku i terenów z przewagą rolnictwa. Na podstawie informacji dostarczonych razem z danymi obrazowymi sprawdzono i zmodyfikowano parametry kalibracyjne poszczególnych kanałów spektralnych. Obliczenia zostały wykonane osobno dla kanałów wielospektralnych oraz kanału panchromatycznego.

Następny etap wstępnego przetwarzania zdjęć, związany najczęściej z rektyfikacją, został pominięty. Podjęto decyzję o wykonaniu klasyfikacji na podstawie oryginalnych danych satelitarnych posiadających odwzorowanie UTM. W ten sposób ograniczono zakres przetwarzania zdjęć przed wykonaniem klasyfikacji. Konwersja danych do odwzorowania obowiązującego w kraju jest zawsze możliwa, zarówno w przypadku danych klasyfikacyjnych w postaci rastrowej, jak i w postaci wektorowej bazy danych.

3.3. Połączenie danych wielospektralnych i panchromatycznych

W czasie przeprowadzonych klasyfikacji treści zdjęcia wykonanego przez skaner ETM+ analizowano dane z kanałów wielospektralnych, kanału panchromatycznego oraz uzyskane w wyniku ich połączenia. Idea łączenia kanałów wielospektralnych z panchromatycznym polega na uzyskaniu nowego zestawu danych obrazowych posiadających rozdzielczość przestrzenną kanału panchromatycznego i równocześnie charakteryzujących się wartościami spektralnymi zbliżonymi do oryginalnych kanałów wielospektralnych.

Większość współczesnych satelitarnych systemów rejestracji obrazów powierzchni Ziemi charakteryzuje się możliwością równoczesnej rejestracji zdjęć wielospektralnych (MS) i panchromatycznych (PAN). Ze względu na szerokość rejestrowanego zakresu panchromatycznego ilość energii promieniowania elektromagnetycznego docierającego do skanera jest parokrotnie większa w porównaniu z pojedynczym kanałem wielospektralnym. Większa ilość rejestrowanej energii pozwala na zmniejszenie powierzchni czynnej detektorów, czego wynikiem jest możliwość zwiększenia rozdzielczości przestrzennej rejestrowanego zdjęcia. W tabeli 2 przedstawione są wybrane systemy satelitarne obrazujące powierzchnię Ziemi równocześnie w zakresie panchromatycznym i wielospektralnym. Podany jest zakres spektralny kanału PAN, jego rozdzielczość przestrzenna oraz rozdzielczość kanałów MS. Należy zwrócić uwagę, że zakres spektralny danych PAN nie jest jednakowy, w przypadku zdjęć z satelitów QuickBird, IKONOS oraz wykonanych skanem ETM+ kanał panchromatyczny rozszerzony jest o zakres bliskiej podczerwieni. Stosunek rozdzielczości prezentowanych par zdjęć panchromatycznych i wielospektralnych wynosi od 1:2 do 1:4.


Tabela 2. Porównanie zakresów spektralnych i rozdzielczości przestrzennej systemów satelitarnych rejestrujących równocześnie obraz powierzchni Ziemi na zdjęciach panchromatycznych [PAN] i wielospektralnych [MS] (Lillesand i inni, 2004)

skaner/satelita	PAN		MS
	zakres spektralny (μm)	rozdzielczość (m)	rozdzielczość (m)
QuickBird	0,45 – 0,90	0,6	2,4
IKONOS	0,45 – 0,90	1,0	4,0
HRG/SPOT 5	0,48 – 0,71	5,0 2,5	10,0
PAN, LISS-III/IRS	0,50 – 0,75	5,8	23,0
HRV/SPOT 3	0,51 – 0,73	10,0	20,0
HRVIR/SPOT 4	0,61 – 0,68	10,0	20,0
ETM+/Landsat 7	0,52 – 0,90	15,0	30,0

3.3.1 Metody łączenia danych

Obecnie znanych i stosowanych jest wiele technik przetwarzania zdjęć satelitarnych, których celem jest połączenie danych panchromatycznych z wielospektralnymi w taki sposób, aby uzyskać barwny obraz o stopniu szczegółowości zdjęć panchromatycznych. Proces łączenia danych określany jest terminem *data fusion* (łączenie danych) lub *band sharpening* (wyostrzanie obrazu). Pohl i van Gederen (1998) podają przegląd stosowanych metod. Algorytmy łączenia danych można podzielić na dwie podstawowe grupy: związane z transformacjami między różnymi systemami barw oraz z obliczeniami arytmetyczno-statystycznymi. Istnieją również tzw. algorytmy kombinowane, zawierające elementy przetwarzania zdjęć z pierwszej i drugiej grupy.

Najbardziej znaną metodą łączenia zdjęć panchromatycznych z wielospektralnymi jest metoda IHS (Gillespie i inni, 1986; Carper i inni, 1990), będąca standardową funkcją każdego profesjonalnego systemu przetwarzania zdjęć satelitarnych. Schemat metody IHS przedstawiony jest na rysunku 4. Polega ona na wykonaniu transformacji wielospektralnej kompozycji barwnej z systemu barw RGB (Red, Green, Blue) do systemu IHS (Intensity, Hue, Saturation). Następnie zamiast kanału Intensity podstawiany jest kanał panchromatyczny i wykonywana jest transformacja odwrotna z systemu barw IHS do RGB.



Rys. 4. Schemat łączenia zdjęć panchromatycznych z wielospektralnymi metodą IHS

W procesie łączenia danych często stosowana jest także metoda oparta na zasadach analizy składowych głównych, określana skrótem PCA (Principle Component Analysis) (Chavez i inni, 1991). Natomiast biorąc pod uwagę wykonywane obliczenia, jedną z najprostszych metod jest transformacja Brovey (ER Mapper, 2005), związana z prostymi działaniami arytmetycznymi na danych obrazowych. Natomiast w metodzie HP (High-Pass filter) łączone dane są przetwarzane z zastosowaniem filtrów wysokich i niskich częstotliwości (Vrabel, 1996). Przykładem metody bardziej złożonej pod względem

obliczeniowym jest zastosowanie w procesie łączenia transformacji Wavelet (Garguet-Duport i inni, 1996; Zhou i inni, 1998; de Jond i van der Meer, 2004) oraz transformacji Fouriera (Gonzalez i Woods, 1993; Richards i Xiuping, 1999), jak to ma miejsce w przypadku metody FZG, która łączy w sobie elementy algorytmu IHS i transformacji Fouriera (Ehlers, 2005).

Jak widać, metody łączenia danych opierają się na niejednakowych założeniach i zależnie od przyjętego sposobu postępowania i zastosowanych danych satelitarnych można uzyskać różne wyniki. Z tego też względu równolegle rozwijane są prace mające na celu określenie kryteriów oceny jakości połączonych danych (Wald i inni, 1997; Wald, 2002; Cornet i Binard, 2005; Thomas i Wald, 2005). Oceniana jest przede wszystkim geometria oraz radiometria danych wynikowych. Geometrię można ocenić w sposób jednoznaczny metodami fotogrametrycznymi, natomiast w przypadku radiometrii ocena jest bardziej złożona. Kanał wynikowy powinien być skorelowany z wejściowym kanałem wielospektralnym, a zarazem zawierać odpowiednią część informacji związanej z zakresem panchromatycznym. W prawie każdej publikacji poruszającej zagadnienia łączenia danych porównywane są parametry statystyczne oryginalnych danych i wynikowych (Cliche i inni, 1985; Vrabel, 1996; Zhang, 1999; Ray, 2004) w celu określenia zachodzących między nimi związków.

3.3.2. Połączenie danych z zastosowaniem algorytmu PanSharp

Algorytmy, które opracowano z myślą o określonych danych satelitarnych, najczęściej nie pozwalają na uzyskiwanie równie dobrych rezultatów na podstawie zdjęć rejestrowanych przez inne skanery. Jest to związane przede wszystkim z zakresami spektralnymi oraz ze stosunkiem rozdzielczości łączonych zdjęć, które nie zawsze są jednakowe (tab. 2). Równocześnie wszystkie metody przetwarzania zdjęć satelitarnych, które wymagają podjęcia decyzji o wielkości parametrów wejściowych, są zależne od umiejętności i doświadczenia operatora. Jest to szczególnie dobrze widoczne w przypadku metody IHS, stosowanej na potrzeby opracowywania map satelitarnych (Lewiński, 2000; 2001; Lewiński i Zagajewski, 2002) oraz kompozycji barwnych dla interpretacji wizualnej (Lewiński i Poławski, 2004; 2005).

W prezentowanej pracy dane wielospektralne zdjęcia wykonanego skanem ETM+ zostały połączone z kanałem panchromatycznym z zastosowaniem algorytmu PanSharp oprogramowania PCI Geomatica. Jest to algorytm prawie całkowicie zautomatyzowany, jego autor dr Y. Zhang (Zhang, 2002a), opracowując metodę, wyszedł z założenia, że wyniki łączenia danych nie mogą być zależne od rodzaju zdjęć oraz od umiejętności i doświadczenia operatora. Algorytm PanSharp przeznaczony jest do łączenia różnego rodzaju zdjęć satelitarnych o różnej rozdzielczości przestrzennej, spektralnej i radiometrycznej. Może on być wykorzystywany w przypadku zdjęć, w których

zakres kanału panchromatycznego związany jest tylko z zakresem promieniowania widzialnego (np. dane z satelity SPOT) lub jest szerszy i uwzględnia też bliską podczerwień (np. Landsat ETM+, IKONOS). Istotną cechą algorytmu jest również automatyczne wykonanie przepróbkowania, czyli dopasowanie wielkości pikseli obrazu wielospektralnego do panchromatycznego. W przypadku większości innych algorytmów zmiana wielkości pikseli musi być wykonana przez operatora przed rozpoczęciem procesu łączenia danych.

Dokumentacja oprogramowania PCI Geomatica nie zawiera pełnego opisu algorytmu PanSharp. W publikacjach zasygnalizowane są jedynie główne założenia. Wiadomo, że zastosowano metodę najmniejszych kwadratów do określania relacji między wartościami pikseli danych wielospektralnych, panchromatycznych i wynikowych oraz że stosowane są założenia statystyczne w celu standaryzacji i automatyzacji procesu łączenia (Zhang, 2002a; 2002b; 2004). Rezultaty prac Zhanga (2004) oraz Nikolakopoulou (2004a; 2004b) wskazują, że dane wynikowe są dobrze skorelowane z wejściowymi danymi wielospektralnymi, lepiej niż w przypadku innych stosowanych metod. Mając na uwadze cechy algorytmu PanSharp, jego wybór wydaje się być w pełni uzasadniony, zwłaszcza jeżeli planowane jest operacyjne wykonywanie łączenia danych wielospektralnych z panchromatycznymi.

Stosując algorytm PanSharp, wykonano połączenie zdjęć wielospektralnych i panchromatycznego, będących już po korekcji atmosferycznej. Do połączenia wybrano trzy kanały wielospektralne 2, 3 i 4, które pod względem spektralnym odpowiadają zakresowi kanału panchromatycznego (tab. 1). W tabelach 3 i 4 przedstawione są wartości średnie, minimalne, maksymalne, odchylenia standardowe oraz współczynniki korelacji danych przed i po połączeniu.

W celu porównania i obliczenia współczynników korelacji wykonano przepróbkowanie oryginalnych danych wielospektralnych do wielkości pikseli kanału panchromatycznego, wielkość piksela została zmniejszona z 30 m do 15 m. W tym celu posłużono się algorytmem najbliższego sąsiada. W tabelach zamieszczono również wyniki uzyskane dla kanałów 2, 3 i 4 po przepróbkowaniu z zastosowaniem metody splotu sześciennego (Cubic Convolution, CC). Na prezentację wyników związanych z tymi danymi miała wpływ informacja uzyskana od dr. Zhanga o zastosowaniu w algorytmie PanSharp metody przepróbkowania opartej na tych właśnie zasadach.

W przypadku łączonych danych wielospektralnych (kanały 2, 3 i 4) wartości średnie jaskrawości pikseli przed i po połączeniu uległy bardzo małym zmianom. Zachowane zostały również prawie niezmienione wartości odchylenia standardowego. Współczynnik korelacji kanału PAN z kanałami 2, 3 i 4 wynosi 0,69, 0,60 i 0,86 natomiast po przetworzeniu jest większy i wynosi odpowiednio 0,76, 0,67 i 0,90. Wzrost korelacji świadczy o zawartości w przetworzonych kanałach danych pozyskanych w zakresie panchromatycznym. Współczynnik korelacji między kanałami 2, 3 i 4 oraz danymi K2PAN, K3PAN i K4PAN uzyskanymi po połączeniu z kanałem panchromatycznym

jest stosunkowo wysoki i wynosi odpowiednio 0,89, 0,89 i 0,94. W przypadku kanałów po przepróbkowaniu metodą CC zaobserwowano nieznaczne zmniejszenie korelacji z kanałem panchromatycznym oraz wzrost korelacji w stosunku do danych połączonych. Potwierdza to informację, że algorytm wykorzystuje tę właśnie metodę przepróbkowania.

Podane w tabelach parametry nie dają pełnego obrazu zmian, jakie nastąpiły po zastosowaniu algorytmu PanSharp. Dodatkowo, na rysunku 5 przedstawione jest graficzne porównanie histogramów. W przypadku wszystkich trzech kanałów wielospektralnych zachowany jest kształt ich oryginalnych histogramów, równocześnie widoczny jest wpływ danych panchromatycznych, które wyraźnie podkreślają występowanie lokalnych wartości maksymalnych.

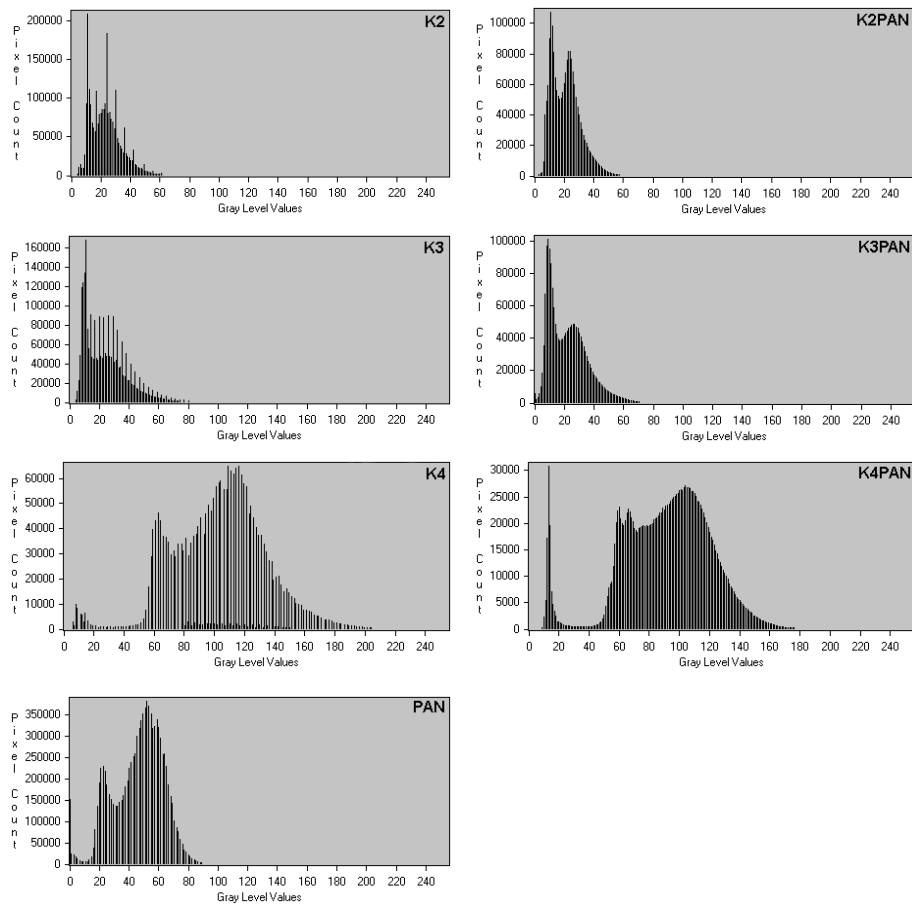
Uzyskane wyniki świadczą o wysokiej zgodności spektralnej oryginalnych danych i połączonych z kanałem panchromatycznym. Równocześnie należy zauważyć, że pod względem wizualnym nastąpiła poprawa stopnia szczegółowości kanałów wielospektralnych. Na rysunku 6 przedstawione jest porównanie kompozycji RGB (4, 5, 3) i kompozycji z udziałem kanałów przetworzonych algorytmem PanSharp (K4PAN, 5, K3PAN).

Tabela 3. Wartości średnie, minimalne, maksymalne oraz odchylenie standardowe oryginalnych i przetworzonych danych pozyskanych za pomocą skanera ETM+ satelity Landsat


kanał	wartości jaskrawości pikseli			
	średnia	minimum	maksimum	odchyl. stand.
PAN	40,00	0	255	16,70
1	10,29	0	156	7,48
2	21,12	2	192	10,11
3	22,36	2	174	13,67
4	90,47	3	255	30,44
5	67,38	0	239	28,71
6	117,79	74	198	20,08
7	43,99	0	246	25,51
K2PAN	21,17	0	233	10,21
K3PAN	22,41	0	239	13,85
K4PAN	90,83	0	255	30,62
2CC	20,77	2	201	9,97
3CC	22,01	1	184	13,50
4CC	90,21	3	255	30,24
K2PAN, K3PAN, K4PAN – dane połączone algorytmem PanSharp CC – cubic convolution				

Tabela 4. Współczynniki korelacji między oryginalnymi i przetworzonymi kanałami zdjęcia pozyskanego za pomocą skanera ETM+ z satelity Landsat

kanal	PAN	1	2	3	4	5	6	7	K2 PAN	K3 PAN	K4 PAN	2CC	3CC	4CC
PAN	1													
1	0,57	1												
2	0,69	0,93	1											
3	0,60	0,93	0,97	1										
4	0,86	0,30	0,43	0,31	1									
5	0,78	0,75	0,81	0,79	0,64	1								
6	0,59	0,73	0,75	0,77	0,39	0,81	1							
7	0,65	0,86	0,87	0,88	0,42	0,93	0,82	1						
K2PAN	0,76	0,83	0,89	0,87	0,43	0,75	0,71	0,79	1					
K3PAN	0,67	0,83	0,87	0,89	0,30	0,73	0,72	0,80	0,97	1				
K4PAN	0,90	0,29	0,41	0,29	0,94	0,62	0,38	0,41	0,49	0,37	1			
2CC	0,72	0,90	0,97	0,94	0,45	0,80	0,75	0,86	0,94	0,91	0,43	1		
3CC	0,63	0,90	0,94	0,97	0,32	0,78	0,77	0,87	0,91	0,94	0,30	0,97	1	
4CC	0,87	0,30	0,44	0,31	0,98	0,65	0,40	0,43	0,43	0,30	0,95	0,45	0,32	1
K2PAN, K3PAN, K4PAN – dane połączone algorytmem PanSharp														
CC – cubic convolution														



Rys. 5. Histogramy kanałów 2, 3, 4 i PAN (po korekcji atmosferycznej) zdjęcia zarejestrowanego skanerem ETM+ oraz histogramy kanałów 2, 3 i 4 po połączeniu z kanałem PAN z zastosowaniem algorytmu PanSharp



Rys. 6. Porównanie kompozycji barwnej RGB uzyskanej na podstawie kanałów 4, 5, 3 skanera ETM+ z kompozycją utworzoną z zastosowaniem połączonych kanałów wielospektralnych z panchromatycznym (K4PAN, 5, K3PAN)

3.4. Klasyfikacja hybrydowa

Do przeprowadzenia tradycyjnej klasyfikacji pikselowej treści zdjęcia obrazującego teren poligonu badawczego zastosowano algorytm tzw. klasyfikacji hybrydowej, polegający na równoczesnym wykorzystaniu klasyfikacji nadzorowanej i nienadzorowanej. Zgodnie z zasadami klasyfikacji nadzorowanej najpierw zdefiniowano pola treningowe, ale tylko dla klas reprezentowanych przez duże i jednorodne obiekty, co do identyfikacji których nie ma jakichkolwiek wątpliwości. Następnie przeprowadzono klasyfikację. Konsekwencją takiego podejścia jest pozostawienie pewnej liczby pikseli niesklasyfikowanych, które później zostały sklasyfikowane z zastosowaniem metody nienadzorowanej. Ten sposób postępowania przyjęto ze względu na specyfikę terenu badań, który charakteryzuje się dużym rozdrobnieniem form pokrycia i użytkowania ziemi, co w wielu przypadkach utrudnia, a nawet uniemożliwia zdefiniowanie reprezentatywnych pól treningowych.

Przed przystąpieniem do klasyfikacji określono zestaw kanałów pozwalający na najlepsze rozpoznanie klas. Analizie poddano kanały wielospektralne, kanał panchromatyczny (wszystkie po korekcji atmosferycznej) oraz kanały uzyskane w wyniku połączenia danych wielospektralnych z kanałem panchromatycznym. W klasyfikacji nienadzorowanej charakterystyki klas spektralnych określono z zastosowaniem algorytmu Competitive Training (Hung, 1993). Obie klasyfikacje wykonano metodą największego prawdopodobieństwa.

3.4.1. Pola treningowe

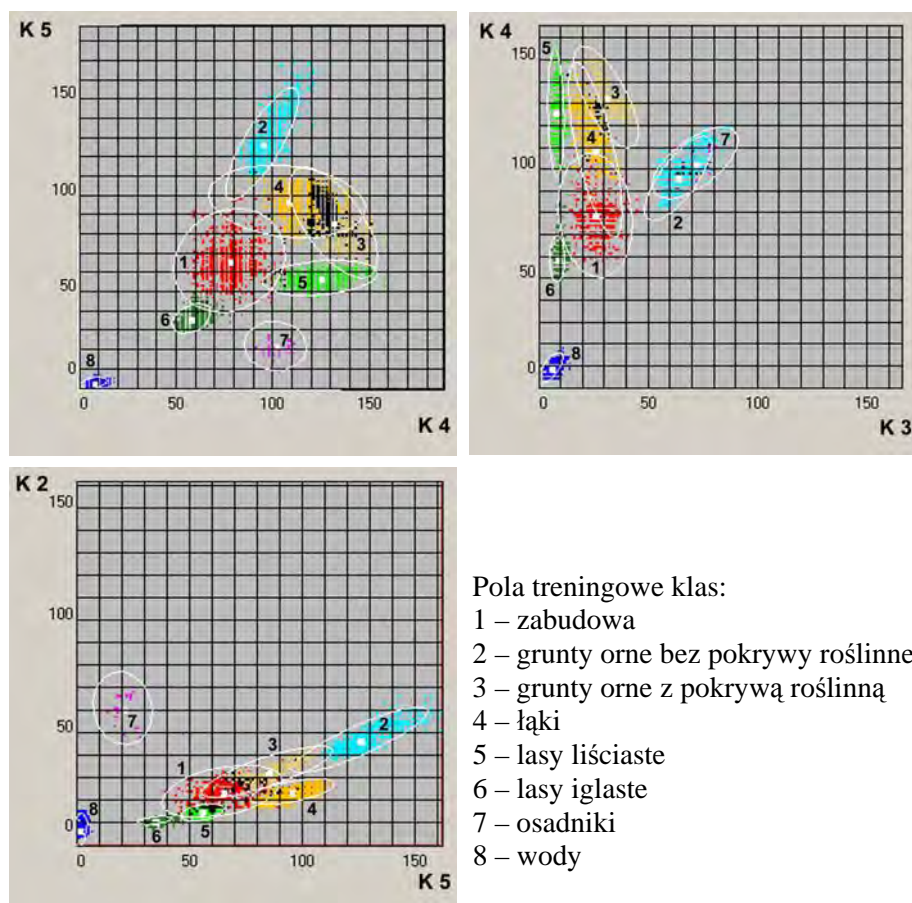
Klasyfikację nadzorowaną rozpoczęto od wyboru pól treningowych. Ten etap klasyfikacji zawsze jest procesem interaktywnym, związanym z definio-

waniem klas, lokalizacją reprezentatywnych wydzieleń, analizą opisujących je parametrów statystycznych oraz relacji zachodzącymi między poszczególnymi klasami.

Na podstawie przeprowadzonych analiz określono pola treningowe dla 8 klas; są nimi: zabudowa, grunty orne z pokrywą roślinną, grunty orne bez pokrywy roślinnej, łąki, lasy liściaste, lasy iglaste, osadniki oraz wody. Wartości spektralne analizowanych pól treningowych nie pozwoliły na podział ogólnej klasy „zabudowa” na podklasy związane z zabudową wiejską, miejską czy też przemysłową.

Klasa „grunty orne z pokrywą roślinną” reprezentuje uprawy ozime, natomiast klasa „grunty orne bez pokrywy roślinnej” związana jest głównie z uprawami jarymi, które w maju jeszcze nie zasłaniają powierzchni gruntu. Po wykonaniu klasyfikacji obie te klasy zostały połączone, tworząc jedną klasę gruntów ornych. Zrezygnowano z określenia pól treningowych dla klasy lasów mieszanych. Postąpiono tak, gdyż nawet od strony interpretacji klasa ta nie jest jednoznacznie zdefiniowana, co w istotny sposób utrudnia określenie na zdjęciu reprezentatywnych dla niej wydzieleń i może prowadzić do błędów klasyfikacyjnych. Ze względu na możliwości rozpoznania określono pola treningowe dla nielicznej klasy „osadniki”.

Podjęwając decyzje o wyborze pól treningowych dla poszczególnych klas, zwracano uwagę, aby rozkład wartości jaskrawości tworzących je pikseli był zbliżony do rozkładu normalnego oraz aby ich liczba była większa od 50 (Jensen, 1996). Na rysunku 7 przedstawiono wykresy rozproszenia wartości jaskrawości pikseli pól treningowych (*scatter plot*) dla par kanałów spektralnych: 5 i 4, 4 i 3 oraz 2 i 5. W przypadku zdjęć zarejestrowanych skanerem ETM+ kanały te są najczęściej wykorzystywane do wstępnej oceny pól treningowych ze względu na stosunkowo mały stopień występującej między nimi korelacji. Na wykresach zaznaczono elipsy reprezentujące zasięgi wartości oraz ich środki reprezentujące średnie wartości jaskrawości pikseli tworzących pola treningowe. Na ich podstawie można stwierdzić, że najlepiej odseparowanymi od innych klasami są „wody”, „las iglaste” oraz „osadniki”. Wyraźnie widoczna jest bliskość spektralna łąk i gruntów ornych z pokrywą roślinną, które są najlepiej rozróżnialne na podstawie pary kanałów 2 i 5. Na wszystkich wykresach klasą najmniej odseparowaną od pozostałych jest „zabudowa”.



Rys. 7. Wykresy rozproszenia wartości jaskrawości pikseli pól treningowych dla par kanałów spektralnych 5 i 4, 4 i 3 oraz 2 i 5

3.4.2. Dobór optymalnego zestawu kanałów w klasyfikacji

Ocenę przydatności poszczególnych kanałów w procesie klasyfikacji rozpoczęto od analizy odległości między klasami w przestrzeni spektralnej. Na podstawie pól treningowych poszczególnych klas, obliczono, oddzielnie dla poszczególnych kanałów, odległość euklidesową (4) oraz tzw. odległość J–M (Jeffreys–Matusita). Tę drugą miarę odległości spektralnej obliczono z zastosowaniem wzoru (Jensen, 1996):

$$JM_{ab} = \sqrt{2(1 - e^{-Bhat_{ab}})} \quad (7)$$

gdzie:

JM_{ab} – odległość J–M między klasami a i b ,

$Bhat_{ab}$ – odległość Bhattacharyya między klasami a i b .

Odległości spektralna, tzw. $Bhat$, między dwoma klasami zdefiniowana jest w następujący sposób (Jensen, 1996):

$$Bhat_{ab} = \frac{1}{8}(M_a - M_b)' \frac{(V_a + V_b)}{2} (M_a - M_b) + \frac{1}{2} \log_e \frac{\det \frac{V_a + V_b}{2}}{\sqrt{\det(V_a)} \sqrt{\det(V_b)}} \quad (8)$$

gdzie:

M_a, M_b – średnia wartość klasy a i b ,

V_a, V_b – macierz kowariancji klasy a i b .

Odległość J–M zdefiniowana wzorem (7) przyjmuje wartości z przedziału $\langle 0, 2 \rangle$. Wartość maksymalna 2 świadczy o całkowitej rozdzielności klas. Wartości poniżej 1,4 świadczą o braku rozdzielności klas (Image Analyst..., 2002). W przeciwieństwie do odległości euklidesowej, odległość J–M nie jest informacją jedynie o relacji między środkami klas, lecz uwzględnia również stopień ich rozproszenia. Ze względu na ustalone wartości, świadczące o rozdzielności klas, odległość J–M jest powszechnie stosowana w czasie podejmowania decyzji o wyborze odpowiednich pól treningowych. W ocenie możliwości klasyfikacyjnych wybranych kanałów posłużono się również wynikami klasyfikacji pól treningowych. Wykorzystano w tym celu metodę największego prawdopodobieństwa. Średnie wartości odległości spektralnych między polami treningowymi klas w poszczególnych kanałach oraz dokładność ich klasyfikacji przedstawiono w tabeli 5.

Tabela 5. Zestawienie średnich odległości euklidesowych i J–M między polami treningowymi oraz dokładności ich klasyfikacji uzyskane na podstawie poszczególnych kanałów skanera ETM+

kanał	średnia 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
K2PAN	28,26	1,51	56,99	66,55
K3PAN	21,62	1,65	73,90	79,25
K4PAN	45,61	1,42	63,15	61,56

W pierwszej kolejności oceniono wyniki uzyskane na podstawie kanałów K2PAN, K3PAN i K4PAN w porównaniu z odpowiadającymi im kanałami 2, 3 i 4. Zastosowanie kanałów K2PAN i K4PAN nie spowodowało uzyskania lepszych rezultatów w porównaniu z kanałami 2 i 4, natomiast stosując kanał K3PAN, można uzyskać lepszą rozróżnialność klas w porównaniu z kanałem 3. Największe zróżnicowanie między klasami występuje w kanałach 2, 5 i 7. Natomiast na podstawie kanału panchromatycznego uzyskano rezultaty zbliżone do wyników z zastosowaniem kanałów 2 i 4.

Do dalszych analiz związanych z optymalizacją liczby kanałów wykorzystanych w klasyfikacji wybrano wszystkie kanały wielospektralne oraz kanał K3PAN i panchromatyczny. Na ich podstawie wyłoniono najlepszą kombinację kanałów, stosując w tym celu jako miarę wartość średniej transformowanej dywergencji. Wartości transformowanej dywergencji zostały obliczone dla wszystkich kombinacji klas, dla których określono pola treningowe, na podstawie następującego wzoru (Jensen, 1996):

$$TDiver_{ab} = 2000 \left[1 - \exp\left(\frac{-Diver_{ab}}{8}\right) \right] \quad (9)$$

gdzie:

$Tdiver_{ab}$ – transformowana dywergencja klas a i b ,

$Diver_{ab}$ – dywergencja klas a i b .

Transformowana dywergencja obliczona na podstawie równania (9) może osiągnąć wartości z przedziału $\langle 0, 2000 \rangle$. Największa wartość wynosząca 2000 sugeruje całkowite odseparowanie dwóch klas. Wartości powyżej 1900 świadczą o dobrym odseparowaniu, natomiast wartości poniżej 1700 informują o braku rozdzielności klas (Jensen 1996).

Największą wartość TDiver wynoszącą 2000, świadczącą o maksymalnej rozróżnialności klas, uzyskano dla kombinacji kanałów: 2, 3, 4, 5 i 7. Tworzą one optymalny zestaw kanałów w aspekcie klasyfikacji klas pokrycia i użytkowania ziemi zdefiniowanych przez pola treningowe na analizowanym zdjęciu.

W tabelach 6, 7, i 8 przedstawiono wybrane parametry statystyczne pól treningowych, uzyskane na podstawie optymalnego zestawu kanałów. Na podstawie danych zamieszczonych w tabeli 6 można stwierdzić, że klasy „wody”, „lasy iglaste” oraz „lasy liściaste” charakteryzują się najmniej zróżnicowanymi polami treningowymi. Największe wartości odchyleń standardowych (przede wszystkim w 7 kanale) związane są z klasami gruntów ornych. Klasą stosunkowo mocno zróżnicowaną we wszystkich kanałach spektralnych jest „zabudowa”. W kolejnych dwóch tabelach podano wartości odległości euklidesowej oraz odległości J–M między poszczególnymi klasami. Najmniejsza odległość euklidesowa, zdecydowanie niższa w porównaniu z pozostałymi, występuje między klasami „łaki” i „grunty orne z pokrywą roślinną”. Sytuacja ta jest całkowicie zrozumiała ze względu na podobieństwo spektralne roślinności łąk i upraw ozimych w początkowej fazie rozwoju. Równocześnie jednak wartość odległości J–M wskazuje na bardzo dobrą rozróżnialność tych klas, co świadczy, że odległość między tymi klasami w funkcji ich rozproszenia jest wystarczająco duża. Dla wszystkich kombinacji klas uzyskano maksymalne wartości odległości J–M bądź bardzo wysokie, wynoszące ponad 1,97 (tab. 8). Sprawdzono również dokładność klasyfikacji pól treningowych, która została wykonana na podstawie optymalnego zestawu kanałów. Dla wszystkich klas uzyskano dokładność powyżej 98%, którą można uznać za wystarczająco wysoką.

Analizując wartości odległości spektralnych (tab. 7 i 8) występujące między poszczególnymi klasami, można zauważyć, że jedynie dla klasy „zabudowa” uzyskiwane są nieznacznie gorsze wyniki. Na tym etapie analizy klasa ta spełniała jednak wszystkie warunki odseparowania od innych klas.

Tabela 6. Wybrane parametry statystyczne pól treningowych obliczone na podstawie wartości jaskrawości tworzących je pikseli

kanal skanera ETM+	minimum	maksimum	mediana	moda	średnia	odchylenie standardowe
ZABUDOWA						
2	14	40	24	24	23,59	4,16
3	14	45	26	23	26,38	5,59
4	56	114	78	79	78,08	9,57
5	39	98	64	61	65,24	8,97
7	27	84	49	52	49,23	9,86
GRUNTY ORNE BEZ POKRYWY ROŚLINNEJ						
2	22	43	31	30	32,49	3,88
3	19	46	31	29	31,37	4,99
4	116	158	131	129	132,50	7,77
5	52	108	86	94	85,46	9,74
7	25	85	56	50	55,88	12,38
GRUNTY ORNE Z POKRYWĄ ROŚLINNĄ						
2	37	66	45	42	46,36	4,95
3	53	91	64	62	64,48	5,36
4	83	124	94	94	95,94	6,55
5	109	168	124	122	126,32	10,02
7	91	170	116	113	119,41	12,33
ŁĄKI						
2	17	31	24	24	23,41	2,10
3	13	39	26	29	26,32	4,37
4	71	151	109	109	108,81	13,49
5	66	115	97	94	96,22	6,33
7	31	82	56	57	55,86	8,09
LASY LIŚCIASTE						
2	11	19	15	14	14,97	1,53
3	5	14	9	8	8,74	1,43
4	88	158	124	119	125,16	9,90
5	41	67	57	56	56,65	3,16
7	19	35	24	24	24,15	2,12
LASY IGLASTE						
2	7	14	10	10	10,43	0,87
3	6	14	10	10	9,88	1,22
4	49	84	58	58	58,55	3,50
5	29	49	36	35	35,91	2,73
7	13	32	20	19	19,70	2,26
OSADNIKI						
2	47	70	61	66	60,97	5,69
3	53	81	72	78	72,12	6,71
4	90	111	103	98	102,57	5,62
5	8	47	20	20	21,03	4,38
7	7	26	13	14	12,18	2,69
WODY						
2	3	15	6	5	6,90	2,59
3	2	14	6	5	6,60	1,95
4	4	19	8	8	8,07	2,50
5	0	7	2	2	2,18	0,96
7	0	7	2	2	2,19	1,24

Tabela 7. Wartości odległości euklidesowej między poszczególnymi klasami, obliczone dla pól treningowych na podstawie kanałów 2, 3, 4, 5 i 7 zarejestrowanych skanerem ETM+

klasa		1	2	3	4	5	6	7	8
1	zabudowa	0,00	59,35	104,62	44,13	57,48	50,58	86,12	108,44
2	grunty orne 1 ^{a)}	59,35	0,00	91,15	28,08	52,20	100,97	96,95	163,05
3	grunty orne 2 ^{b)}	104,62	91,15	0,00	84,22	137,38	154,23	151,33	204,39
4	łąki	44,13	28,08	84,22	0,00	56,73	88,93	105,40	150,10
5	lasy liściaste	57,48	52,20	137,38	56,73	0,00	70,06	89,75	131,26
6	lasy iglaste	50,58	100,97	154,23	88,93	70,06	0,00	92,97	63,37
7	osadniki	86,12	96,95	151,33	105,40	89,75	92,97	0,00	128,84
8	woda	108,44	163,05	204,39	150,10	131,26	63,37	128,84	0,00

^{a)} grunty orne z pokrywą roślinną

średnia odległość euklidesowa = 98,29

^{b)} grunty orne bez pokrywy roślinnej

Tabela 8. Wartości odległości J–M między poszczególnymi klasami obliczone dla pól treningowych na podstawie kanałów 2, 3, 4, 5 i 7 zarejestrowanych skanerem ETM+

klasa		1	2	3	4	5	6	7	8
1	zabudowa	0,0000	1,9994	1,9998	1,9786	1,9964	1,9937	2,0000	2,0000
2	grunty orne 1 ^{a)}	1,9994	0,0000	2,0000	1,9986	1,9996	2,0000	2,0000	2,0000
3	grunty orne 2 ^{b)}	1,9998	2,0000	0,0000	2,0000	2,0000	2,0000	2,0000	2,0000
4	łąki	1,9786	1,9986	2,0000	0,0000	1,9998	2,0000	2,0000	2,0000
5	lasy liściaste	1,9964	1,9996	2,0000	1,9998	0,0000	2,0000	2,0000	2,0000
6	lasy iglaste	1,9937	2,0000	2,0000	2,0000	2,0000	0,0000	2,0000	2,0000
7	osadniki	2,0000	2,0000	2,0000	2,0000	2,0000	2,0000	0,0000	2,0000
8	woda	2,0000	2,0000	2,0000	2,0000	2,0000	2,0000	2,0000	0,0000

^{a)} grunty orne z pokrywą roślinną

średnia odległość J–M = 1,9988

^{b)} grunty orne bez pokrywy roślinnej

3.4.3. Klasyfikacja nadzorowana treści zdjęcia

Pierwszy etap klasyfikacji hybrydowej, czyli klasyfikacja nadzorowana, został wykonany z zastosowaniem metody największego prawdopodobieństwa. Wykorzystano w tym celu optymalny zestaw kanałów spektralnych (2, 3, 4, 5 i 7) oraz pola treningowe 8 klas określonych w czasie wstępnych analiz.

Wykonane próby wykazały występowanie na obrazie klasyfikacyjnym zdecydowanie za dużej liczby pikseli zaliczonych do klasy „zabudowa”. Modyfikacja pól treningowych oraz zastosowanie bardzo niskiego współczynnika wagowego dla tej klasy nie wpłynęło na zadowalającą poprawę wyników.

Dlatego też podjęto decyzję o rezygnacji na tym etapie klasyfikacji z rozpoznania zabudowy.

Uzyskane wyniki klasyfikacji nadzorowanej w postaci powierzchni poszczególnych klas przedstawione są w tabeli 9. W tabeli tej dwie klasy związane z gruntami ornymi „grunty orne z pokrywą roślinną” oraz „grunty orne bez pokrywy roślinnej” zostały połączone w jedną, zbiorczą klasę „grunty orne”. W sumie sklasyfikowano 14 852 ha, co stanowi 35% powierzchni terenu badań, pozostałą część poddano analizie na następnym etapie klasyfikacji.

3.4.4. Klasyfikacja nierozpoznanych pikseli metodą nienadzorowaną

Drugi etap klasyfikacji hybrydowej polegał na wykonaniu klasyfikacji nienadzorowanej tych pikseli, które nie zostały sklasyfikowane metodą nadzorowaną. W tym celu na podstawie wyników pierwszej klasyfikacji wykonano maskę ograniczającą zakres działania obliczeń tylko do pikseli jeszcze niesklasyfikowanych. Parametry klas spektralnych zostały określone z zastosowaniem algorytmu Competitive Training (Hung, 1993). Automatycznie zostało zdefiniowanych 15 klas spektralnych, następnie wykonano klasyfikację metodą największego prawdopodobieństwa.

Po klasyfikacji, na podstawie 15 klas spektralnych, utworzono 6 klas tematycznych. Wykonano to, porównując wynik klasyfikacji z obrazem terenu badań oraz posługując się mapą topograficzną w skali 1:50 000. Cztery z wydzielonych klas uzupełniły już istniejące klasy rozpoznane w trakcie klasyfikacji nadzorowanej. Były to „grunty orne”, „łąki”, „lasy liściaste” oraz „wody”. Dwie pozostałe są nowymi klasami tematycznymi. Pierwsza: „zabudowa” reprezentuje wszystkie typy zabudowy, gdyż nie było możliwe wydzielenie z niej zabudowy przemysłowej lub wykonanie podziału na zabudowę miejską i wiejską. Drugą klasą są „lasy mieszane”, którego jednoznaczne rozpoznanie jest zawsze utrudnione ze względu na występowanie różnego stopnia zmieszania drzew iglastych i liściastych. W czasie grupowania klas spektralnych zwracano uwagę, aby obraz lasu mieszanego posiadał cechy pośrednie między jednorodnym lasem iglastym i liściastym.


Końcowym etapem klasyfikacji hybrydowej było połączenie wyników uzyskanych w toku obu klasyfikacji. Zostało to wykonane w taki sposób, aby wynik klasyfikacji nienadzorowanej zastąpił piksele niesklasyfikowane metodą nadzorowaną. Powstał tym samym obraz klasyfikacyjny przedstawiający na terenie badań 8 klas pokrycia i użytkowania ziemi. Jest on zamieszczony na rysunku 8.

Zestawienie powierzchni poszczególnych klas uzyskanych w czasie kolejnych etapów klasyfikacji hybrydowej przedstawione jest w tabeli 9. Dla końcowego wyniku klasyfikacji podano również procentowy udział poszczególnych klas w powierzchni terenu badań. W obrazie klasyfikacji hybrydowej występują także piksele niesklasyfikowane, czyli takie, które nie zostały skla-

syfikowane metodą nadzorowaną ani metodą nienadzorowaną. Stanowią one 2,3% powierzchni terenu badań. Podjęto próbę przyporządkowania niesklasyfikowanych pikseli do jednej z klas tematycznych lub utworzenie na ich podstawie nowej klasy. Ze względu na duże zróżnicowanie ich wartości nie znaleziono jednak odpowiedniego rozwiązania i podjęto decyzję o pozostawieniu grupy pikseli niesklasyfikowanych.

Tabela 9. Wyniki klasyfikacji hybrydowej wykonanej na terenie badań

		KLASYFIKACJA			
		nadzorowana	nienadzorowana	HYBRYDOWA	
klasa		ha	ha	ha	% terenu badań
1	zabudowa	–	2494,91	2494,91	5,89
2	grunty orne	982,26	7043,76	8026,02	18,94
3	łąki	5873,51	6055,86	11929,37	28,15
4	lasy liściaste	1912,50	1520,98	3433,48	8,10
5	lasy iglaste	4330,24	–	4330,24	10,22
6	lasy mieszane	–	8748,41	8748,41	20,64
7	osadniki	3,46	–	3,46	0,01
8	wody	1 750,07	696,09	2446,16	5,77
9	niesklasyfikowane	27533,00	973,01	973,01	2,30
SUMA		42385,04	27533,02	42385,06	100,00



Rys. 8. Wynik klasyfikacji hybrydowej zdjęcia wykonanego skanerem ETM+

3.4.5. Generalizacja i ocena wyników klasyfikacji hybrydowej

W przypadku baz danych opracowywanych na podstawie zdjęć satelitarnych wielkość przyjętej jednostki odniesienia jest zależna od rozdzielczości przestrzennej zdjęcia, od skali opracowania oraz celu, jakiemu ma służyć baza. W klasyfikacji wykonanej z zastosowaniem tradycyjnych metod rozpatrywane są pojedyncze piksele bez analizy ich otoczenia. Można przyjąć, że

bezpośrednio po klasyfikacji jednostką odniesienia jest jeden piksel zdjęcia. W celu uzyskania wydzielen o wielkości nie mniejszej od założonej jednostki odniesienia obraz klasyfikacyjny musi zostać przetworzony z zastosowaniem funkcji generalizacyjnych. W praktyce klasyfikacyjnej zagadnienie jednostki odniesienia jest najczęściej zaniechane, stosowane są jedynie filtry służące przede wszystkim do eliminacji pojedynczych pikseli o wartościach innych niż ich otoczenie.

W wykonanej klasyfikacji jako jednostkę odniesienia przyjęto 4 ha dla wszystkich klas oraz 1 ha dla klas związanych z zabudową i wodą. Wielkość przyjętych jednostek odniesienia wynika z założeń interpretacyjnych, według których w czasie interpretacji wizualnej można zdefiniować i rozpoznać obiekty o wymiarach 2x2 mm w skali mapy. Oznacza to, że w skali 1:100 000 (w skali interpretacji zdjęcia satelitarnego) można praktycznie rozpoznać powierzchnię o wielkości 4 ha. Natomiast zmniejszenie jednostki odniesienia w przypadku zabudowy i wody do 1 ha wynika z ważności tych klas, biorąc pod uwagę bazy danych o pokryciu i użytkowaniu ziemi. Pod względem liczby pikseli powierzchnie 4 ha i 1 ha odpowiadają 178 i 44 pikselom zdjęcia panchromatycznego zarejestrowanego skanerem ETM+.

Generalizację wykonano z zastosowaniem funkcji oprogramowania PCI Geomatica. Grupy jednakowych pikseli zajmujących powierzchnię mniejszą od jednostki odniesienia zostały dołączone do klasy o największej powierzchni, z którą posiadają wspólną granicę. Uzyskane wyniki przedstawiono w tabeli 10. Zamieszczono w niej powierzchnie poszczególnych klas po generalizacji, ich procentowy udział w całkowitej powierzchni terenu badań oraz procentowy wskaźnik zmian ich powierzchni w porównaniu z danymi przed generalizacją.


Tabela 10. Wyniki klasyfikacji hybrydowej przed i po generalizacji

klasa		KLASYFIKACJA HYBRYDOWA		GENERALIZACJA klasyfikacji hybrydowej		ZMIANY ^{a)}	
		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	lasy liściaste	3433,48	8,10	3160,67	7,46	-272,81	-7,95
5	lasy iglaste	4330,24	10,22	4326,86	10,21	-3,38	-0,08
6	lasy mieszane	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		

^{a)} różnica w powierzchni klas przed i po generalizacji

Uzyskane wyniki generalizacji świadczą o dużym rozdrobieniu rozpoznanych klas w porównaniu z przyjętymi jednostkami odniesienia. Powierzchnia zabudowy zmalała aż o 32%, gdyż małe grupy pikseli tej klasy, mniejsze od 1 ha, zostały przyłączone do sąsiednich klas. Powierzchnia łąk wzrosła o ponad 19%, klasa „grunty orne” uległa zmniejszeniu o 7%, podobnie stało się w przypadku klasy „lasy liściaste”, natomiast powierzchnia wód zwiększyła się o 5,8%. Najbardziej stabilnymi klasami okazały się „lasy iglaste” i „lasy mieszane”. Zmiany ich powierzchni na poziomie 0,1% świadczą o występowaniu dużych skupisk pikseli tych klas o powierzchni powyżej 4 ha. W wyniku generalizacji przestała istnieć najmniej liczna klasa „osadniki”. Jednym z pozytywnych rezultatów generalizacji jest zmniejszenie liczby terenów niesklasyfikowanych o 80%, po generalizacji zajmują one jedynie 0,46% powierzchni obszaru badań.

Wynik klasyfikacji hybrydowej po generalizacji przedstawiony jest na rysunku 9. Wyraźnie widoczne są zmiany w porównaniu z obrazem klasyfikacji (rys. 8). Wizualna ocena zmian jest jedynie potwierdzeniem przedstawionych danych liczbowych. Przeprowadzona generalizacja w niektórych przypadkach uwydatniła również błędy klasyfikacji. Jest to szczególnie dobrze widoczne na przykładzie zabudowy, błędnie rozpoznanej wzdłuż ciągów komunikacyjnych oraz na granicach obszarów leśnych i rolniczych.



Rys. 9. Wynik klasyfikacji hybrydowej zdjęcia wykonanego skanerem ETM+
– po generalizacji



Rys. 10. Fragment obrazu klasyfikacji hybrydowej przed (górny) i po generalizacji (dolny)

Na rysunku 10 przedstawiony jest fragment klasyfikacji pikselowej przed i po generalizacji, na którym widoczne są zmiany struktur powierzchniowych i liniowych. Oba obrazy różnią się w sposób zasadniczy pod względem stopnia szczegółowości oraz przebiegu niektórych granic klas. Jest to dobrze widoczne na przykładzie terenów związanych z rolnictwem. Występują również sytuacje generalizacji obiektów, które pozornie wydają się być większe od przyjętych jednostek odniesienia (1 ha – wody i zabudowa, 4 ha – pozostałe klasy). Sytuacje takie mają miejsce w przypadkach, gdy pojedyncze lub bardzo małe grupy pikseli, sklasyfikowane inaczej niż ich najbliższe otoczenie, układają się w struktury przerywające ciągłość większego obiektu. W ten

sposób mogą powstać obiekty o powierzchni mniejszej od jednostki odniesienia, które są przyłączane do sąsiednich klas w trakcie generalizacji. Niejednokrotnie przerwanie ciągłości klas jest wynikiem błędnego rozpoznania. Na uwagę zasługuje zgeneralizowanie części kanału (Kanał Zegrzyński) przecinającego obraz. Jest to spowodowane pojedynczymi pikselami, które nie będą sklasyfikowane jako „wody”, przerwały ciągłość liniowej struktury i spowodowały przyłączenie fragmentu kanału do sąsiednich klas. Podobne sytuacje są widoczne w przypadku powierzchni leśnych. Niektóre z nich zostały przyłączone do sąsiednich terenów rolniczych wskutek przerwania ich ciągłości przez widoczne na zdjęciu granice obrębów sklasyfikowane inaczej niż otaczający je las.

Zastosowanie generalizacji doprowadziło do powstania znaczących zmian w obrazie klasyfikacyjnym, które z całą pewnością rzutują na wiarygodność końcowych danych. Wykonane porównanie wykazało, że zmiany wyników klasyfikacji dotyczą aż 26% terenu badań (dane zawarte w tab. 10 przedstawiają jedynie informacje ilościowe). Jest to związane z zastosowaniem jednostki odniesienia wielokrotnie większej od powierzchni reprezentowanej przez pojedynczy piksel obrazu. Z tego też względu w większości przypadków wyniki tradycyjnej klasyfikacji są opracowywane z zastosowaniem jedynie filtrów wygładzających o wielkości okna 3x3 lub 5x5 pikseli. W ten sposób usuwane jest zjawisko tzw. pieprzu i soli – zmieniana jest wartość pojedynczych pikseli sklasyfikowanych inaczej niż ich najbliższe otoczenie. Taki sposób postępowania „wygładza” obraz, nie pozwala jednak na ujednoczenie stopnia jego szczegółowości przestrzennej, co jest bardzo istotne w przypadku wykorzystywania obrazu klasyfikacyjnego jako źródła informacji zasilającego bazę danych o zdefiniowanej wielkości jednostki odniesienia.

4. WYKORZYSTANIE METODY OBIEKTOWEJ KLASYFIKACJI TREŚCI ZDJĘĆ SATELITARNYCH DO ROZPOZNIANIA FORM POKRACIA I UŻYTKOWANIA ZIEMI

W odróżnieniu od tradycyjnych metod klasyfikacji pikselowej w klasyfikacji obiektowej nie są analizowane pojedyncze piksele obrazu, lecz ich grupy spełniające ustalone warunki jednorodności. Grupy pikseli nazywamy obiektami. Są one tworzone w czasie procesu segmentacji, który poprzedza klasyfikację.

Segmentacja nie jest nową koncepcją przetwarzania zdjęć satelitarnych. Jest to jeden z fundamentalnych procesów analizy danych obrazowych, który początkowo związany był przede wszystkim z rozpoznawaniem kształtów (*pattern recognition*). Gonzalez i Wintz (1977) podają, że celem segmentacji jest podział treści zdjęcia na tzw. regiony, będące grupami pikseli o podobnych wartościach jaskrawości. Można wyróżnić dwa równoważne kierunki rozwoju segmentacji.


Pierwszy związany jest z poszukiwaniem granic regionu, natomiast drugi koncentruje się na poszukiwaniu grup pikseli spełniających zadane kryterium podobieństwa (Gonzalez i Woods, 1993; Haralick i Shapiro, 1985). Metody wykrywania krawędzi związane są z filtrami krawędziowymi (np. gradientowy, laplacian) oraz z algorytmami wykrywającymi nieciągłości granic. Natomiast jednym z podstawowych sposobów podziału treści zdjęcia na grupy podobnych pikseli jest tzw. progowanie, czyli podział histogramu na przedziały zawierające lokalne maksima. Stosowane są również algorytmy tzw. rosnących regionów. Działanie ich polega na określeniu wokół punktów początkowych, którymi są wybrane piksele obrazu, grup pikseli spełniających zdefiniowaną miarę jednorodności. Najprostszą miarą jednorodności może być odległość euklidesowa między wartościami jaskrawości pikseli lub odchylenie standardowe obliczone na podstawie najbliższego otoczenia punktu początkowego. W kryteriach jednorodności uwzględniana jest również wielkość grup pikseli, w celu ograniczenia powstawania zbyt dużych regionów. Stosowane są też algorytmy działające na zasadzie „dzielenia i łączenia” (*split and merge*). W pierwszej fazie iteracyjnych obliczeń cały obraz jest traktowany jako jeden region, który jest dzielony na mniejsze regiony aż do momentu spełnienia zadanego warunku jednorodności. Równocześnie wykonywane są połączenia regionów, jeżeli pozwala na to kryterium jednorodności. Narzędziem segmentacji mogą być również funkcje obliczające teksturę obrazu (Cross i inni, 1988; Hofmann i inni, 1998; Haralick i inni, 1973).

Obecnie segmentacja nie jest utożsamiana z regionami, lecz z tzw. obiektami. Schneider i Steinwender (1999) definiują obiekt w sposób bardzo ogólny, jako grupę pikseli o określonym znaczeniu dla analizowanego zjawiska. Definicja ta w pewnym stopniu odpowiada definicji regionu. Mając jednak na uwadze wykorzystywane później w klasyfikacji cechy obiektu, można zaproponować rozszerzoną definicję: obiektem jest grupa pikseli spełniająca zadane kryterium jednorodności, posiadająca zdefiniowane cechy geometryczne i topologiczne.

Od roku 2000 można zaobserwować gwałtowny wzrost zainteresowania klasyfikacją obiektową. Powstała wielka liczba różnorodnych opracowań, zarówno pod względem rodzajów klasyfikowanych zdjęć, jak i ich zakresu tematycznego. Jest to ściśle związane z pojawieniem się na rynku oprogramowania eCognition, które jako pierwsze umożliwiło użytkownikom kompleksowe rozwiązania. W środowisku oprogramowania eCognition w wyniku segmentacji powstaje baza danych obiektów, zawierająca wszystkie związane z nimi informacje, następnie obiekty są klasyfikowane na zasadzie zapytań adresowanych do bazy danych (de Kok i inni, 2000a).

4.1. Klasyfikacja obiektowa w środowisku oprogramowania eCognition

W oprogramowaniu eCognition stosowana jest procedura segmentacji zwana „fractal Net Evolution”, opracowana przez firmę Delphi2 Creative Technologies (Baatz i Schäpe, 1999). Opatentowany algorytm wykorzystuje w procesie segmentacji elementy teorii fraktali i sieci neuronowych oraz tworzy hierarchiczną strukturę obiektów posiadających semantyczne powiązania. Schemat takiej struktury pokazany jest na rysunku 11.



Rys. 11. Hierarchiczna struktura obiektów powstających na podstawie pojedynczych pikseli zdjęcia w wyniku segmentacji (Baatz i inni, 2001)

Baatz i Schäpe (2000) opisują podstawowe założenia wielopoziomowej metody segmentacji zastosowanej w oprogramowaniu eCognition. Metoda ta charakteryzuje się dużym stopniem uniwersalności jeśli idzie o dane i zastosowania. Opracowując ją, położono nacisk na rozwiązanie problemu skali analizowanego zjawiska i powtarzalności wyników oraz zwrócono uwagę na optymalizację wykonywanych obliczeń, co jest istotne w przypadku opracowywania dużych zbiorów obrazowych. Zastosowano kryteria ilościowe związane z minimalizacją stopnia niejednorodności w funkcji wielkości obiektów. Wykorzystywane jest również kryterium oceny jakościowej w postaci miary lokalnego kontrastu jako substytutu najlepszej oceny, którą jest ocena wizualna.

Segmentacja rozpoczyna się od analizy pojedynczych pikseli, których grupy tworzą następnie większe obiekty. Decyzje o połączeniu podejmowane są z zastosowaniem kryterium jednorodności. Dla poszczególnych obiektów analizowane są wszystkie możliwe połączenia, a następnie wybierane jest połączenie charakteryzujące się najmniejszą zmianą jednorodności. Taki sposób postępowania można porównać do analizy „kosztów” połączenia. Proces ten kończy się z chwilą braku możliwości wykonania kolejnych operacji.

Decyduje o tym tzw. parametr skali, będący wartością progową stopnia jednorodności.

Baatz i Schäpe (2000) podają definicję niejednorodności, nazywaną przez nich również stopniem dopasowania (*degree of fitting*), dwóch stykających się obiektów w n -wymiarowej przestrzeni cech. Jest to pierwiastek z sumy kwadratów różnicy cech obiektów:

$$h = \sqrt{\sum_n (f_{1n} - f_{2n})^2} \quad (10)$$

gdzie:

h – stopień niejednorodności,

n – liczba wymiarów przestrzeni cech, w której analizowana jest jednorodność,

f_1, f_2 – wartości cech pierwszego i drugiego obiektu.

Dodatkowo miara niejednorodności standaryzowana jest przez odchylenie standardowe cech:

$$h = \sqrt{\sum_n \left(\frac{f_{1n} - f_{2n}}{\sigma_{fn}} \right)^2} \quad (11)$$

gdzie:

σ_{fn} – odchylenie standardowe cechy f obliczone na podstawie obu obiektów.

Decyzja o połączeniu obiektów podejmowana jest na podstawie różnicy niejednorodności zdefiniowanej jako różnica między hipotetyczną (wirtualną) niejednorodnością połączonych obiektów i średnią ich niejednorodności:

$$h_{diff} = h_m - \frac{h_1 + h_2}{2} \quad (12)$$

gdzie:

h_{diff} – różnica niejednorodności,

h_m – stopień niejednorodności po hipotetycznym połączeniu,

h_1, h_2 – stopień niejednorodności pierwszego i drugiego obiektu.

Jak widać, nie jest istotny stopień niejednorodności łączonych obiektów, lecz ocena zmiany po połączeniu. Taki sposób postępowania zapobiega przypadkowemu połączeniu obiektów, które – oceniane jedynie na podstawie średnich wartości cech – mogą być uznane jako względnie jednorodne (Burnett i Blaschke, 2003).

Rozpoczynając pracę w środowisku oprogramowania eCognition, użytkownik definiuje zestaw kanałów spektralnych, na podstawie których wykonywana jest segmentacja. Każdemu kanałowi można przyporządkować wagę, zwiększając w ten sposób jego istotność w procesie segmentacji; istnieje również możliwość uwzględnienia warstw tematycznych. Następnie definiowany jest parametr skali oraz kryterium jednorodności.

Parametr skali ma wpływ na wielkość obiektów. Zwiększenie jego wartości powoduje generowanie większych obiektów, ale nie jest to zależność wprost proporcjonalna, gdyż jest to miara maksymalnej dopuszczalnej różnicy niejednorodności, która jest akceptowana po połączeniu dwóch obiektów.

Kryterium jednorodności definiowane jest przez parametr *kolor* i *kształt*, które są związane z wartościami spektralnymi oraz kształtem obiektu. Mogą one przybierać wartości odpowiednio z przedziałów $\langle 0, 1 \rangle$ i $\langle 0, 1 \rangle$. Parametry są współzależne i ich suma zawsze wynosi 1. Dodatkowo kryterium kształtu dzieli się na dwa dodatkowe kryteria, z którymi związane są parametry *gładkość* i *zwartość* przybierające wartości z przedziału $\langle 0, 1 \rangle$. Ich suma, podobnie jak dla poprzednich parametrów, zawsze równa jest jedności (oprogramowanie eCognition, wersja 3).

Mając na uwadze współzależność parametrów *kolor* i *kształt*, łączny stopień niejednorodności obiektu obliczany jest jako suma ważona niejednorodności spektralnej i kształtu (Baatz i inni, 2001):

$$h = w * h_{kol} + (1 - w) * h_{ksz} \quad (13)$$

gdzie:

h – stopień niejednorodności,
 h_{kol} – niejednorodność spektralna,
 h_{ksz} – niejednorodność kształtu,
 w – waga parametru *kolor*

oraz

$$h_{kol} = \sum_i^n w_i \sigma_i \quad (14)$$

gdzie:

w_i – waga i -tego kanału spektralnego,
 σ_i – odchylenie standardowe wartości pikseli tworzących obiekt.

Kryterium niejednorodności *kształtu* h_{ksz} jest sumą ważoną niejednorodności h_{zwar} i h_{glad} , których wagi związane są z parametrami *zwartość* i *gładkość*:

$$h_{ksz} = w_{zwar} h_{zwar} + (1 - w_{zwar}) h_{glad} \quad (15)$$

gdzie:

w_{zwar} – waga parametru *zwartość*

oraz

$$h_{zwar} = \frac{l}{\sqrt{n}} \qquad h_{glad} = \frac{l}{b} \qquad (16, 17)$$

gdzie:

l – długość granicy obiektu,

n – liczba pikseli tworzących obiekt,

b – obwód prostokąta opisującego obiekt (boki prostokąta są równoległe do krawędzi pikseli).

Dodatkowo uwzględniana jest standaryzacja z zastosowaniem odchylenia standardowego w funkcji wielkości obiektu. Decyzje o połączeniu poszczególnych obiektów podejmowane są na podstawie różnicy niejednorodności przedstawionej w równaniu (12).

Algorytm zastosowany w oprogramowaniu eCognition pozwala na wykonanie wielopoziomowej segmentacji. Polega to na tworzeniu nie jednego, lecz kilku poziomów segmentacji. Wyższe poziomy zawierają większe obiekty, które utworzone są na podstawie obiektów niższego poziomu. Granice ich biegną wzdłuż granic obiektów niższego poziomu (nie przecinają się). Możliwe jest również tworzenie nowej segmentacji między warstwami już istniejącymi. Dopuszczalne jest stosowanie danych obrazowych o różnej rozdzielczości bez konieczności wykonania przepróbkowania w celu ujednoczenia wymiarów pikseli. Dodatkowo, generując kolejne poziomy segmentacji, można zmieniać analizowane kanały spektralne, ich wagi, współczynniki skalowe oraz kryteria jednorodności. Pozwala to na opracowywanie różnych strategii tworzenia obiektów, zależnie od celu, który jest do osiągnięcia.

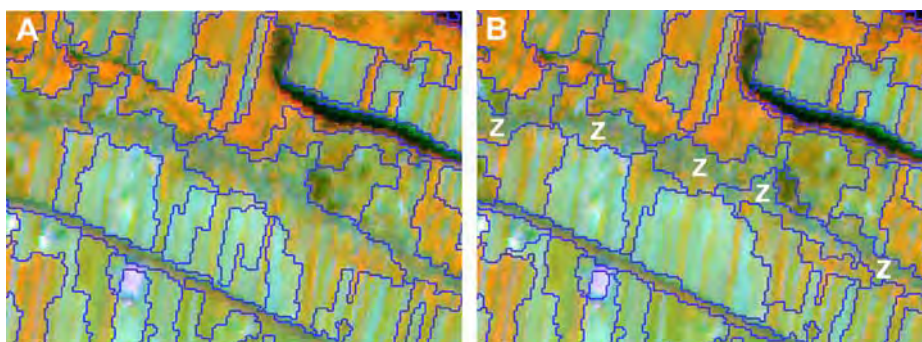
Istotnym i jak dotąd nierozwiązanym jednoznacznie zagadnieniem klasyfikacji obiektowej jest wybór odpowiednich parametrów segmentacji. W dostępnej literaturze znajdujemy różne sposoby wstępnego przetwarzania zdjęć oraz ich segmentacji, świadczące o ciągłym poszukiwaniu optymalnych rozwiązań. Dążąc do unifikacji, należy pamiętać, że prawidłowe zdefiniowanie obiektów zależy również od skali opracowania (Blaschke i inni, 2000) oraz od przyjętego stopnia szczegółowości rozpoznania. Obecnie ocena wyniku segmentacji jest z reguły subiektywną oceną wizualną. Ze względu na duże zainteresowanie klasyfikacją obiektową pojawiają się już pierwsze publikacje proponujące metody optymalizacji procesu segmentacji (Zhang i Maxwell, 2006).

Na rysunku 12 przedstawiona jest segmentacja wysokorozdzielczego zdjęcia satelitarnego QuickBird. Odpowiednio wykonana segmentacja po-

zwoliła na klasyfikację wysokich budynków (zaznaczonych czerwonym kolorem na prawym zdjęciu). Drugi przykład segmentacji zamieszczony na rysunku 13 jest związany ze zdjęciem o średniej rozdzielczości zarejestrowanym przez skaner ASTER satelity Terra. Przedstawia on błędną i poprawną strukturę obiektów, biorąc pod uwagę późniejszą klasyfikację zabudowy. Na zdjęciu widoczna jest rozproszona zabudowa, która na kompozycji barwnej odwzorowuje się w sposób zbliżony do otaczających ją terenów rolniczych. Na lewym zdjęciu granice obiektów nie odzwierciedlają kształtu zabudowy, przez co nie jest możliwe wykonanie jej klasyfikacji. Natomiast na drugim zdjęciu segmentacja wykonana z zastosowaniem innych parametrów oddaje jej kształt, dzięki czemu istnieje możliwość rozpoznania obiektów reprezentujących zabudowę.



Rys. 12. Przykład segmentacji i klasyfikacji wysokiej zabudowy wykonanej na podstawie wysokorozdzielczego zdjęcia satelitarnego QuickBird (Lewiński i Zaremski, 2004)



Rys. 13. Przykład błędnej (A) i poprawnej (B) segmentacji biorąc pod uwagę klasyfikację zabudowy (Z). Kompozycja barwna zdjęcia wykonanego skanerem ASTER z satelity Terra

Oprogramowanie eCognition pozwala na zastosowanie w procesie klasyfikacji obiektowej wielu parametrów definiujących klasy. Można je podzielić na trzy podstawowe grupy związane z bezpośrednim opisem obiektów, zachodzącymi między nimi relacjami oraz warunkami logicznymi.

Parametry bezpośrednio opisujące obiekty dzielą się z kolei na parametry związane z wartościami w poszczególnych kanałach spektralnych, kształtem i teksturą. Zgodnie z zasadami klasyfikacji obiektowej są one związane z obiektami, a nie z pojedynczymi pikselami obrazu, które służą jedynie do obliczenia wartości charakteryzujących cały obiekt. Podstawowym przykładem jest wartość jaskrawości obiektu obliczana jako średnia jaskrawości pikseli tworzących ten obiekt. Parametry kształtu obiektu związane są z jego powierzchnią, obwodem, symetrią, usytuowaniem na zdjęciu. Tekstura obiektów definiowana jest na podstawie obiektów niższego poziomu segmentacji oraz tzw. funkcji Haralick (Baatz i inni, 2001; Hall-Beyer, 2005), które pozwalają na obliczenie wskaźników tekstury na podstawie wartości pikseli tworzących obiekt na danym poziomie segmentacji. Proces ich obliczania jest stosunkowo czasochłonny, są one jednak wyjątkowo przydatne do rozpoznawania klas pokrycia terenu, zwłaszcza na podstawie wysokorozdzielczych zdjęć satelitarnych. Dostępne są również informacje związane z atrybutami warstw tematycznych, o ile są one wykorzystywane w procesie klasyfikacji.

Parametry relacji między obiektami opisują ich wzajemne położenie w ramach poszczególnych poziomów segmentacji oraz między poziomami niższego i wyższego stopnia. Przykładami mogą być: definicja warunku określającego długość granicy z sąsiednim obiektem związanym z określoną klasą, liczba obiektów niższego poziomu zawartych w danym obiekcie lub odwołanie się do wyników klasyfikacji obiektów wyższego poziomu.

W grupie parametrów warunkowych znajdują się operatory logiczne pozwalające m.in. na budowę konstrukcji uwzględniających stopień przynależności obiektu do poszczególnych klas.

Niezwykle cenną cechą oprogramowania eCognition jest możliwość definiowania tzw. funkcji użytkownika, które w procesie klasyfikacji traktowane są na równi z parametrami standardowymi. Funkcje te mogą odwoływać się bezpośrednio do właściwości obiektów oraz do relacji zachodzących między nimi, dzięki czemu istnieje możliwość posługiwania się złożonymi funkcjami klasyfikacyjnymi. Prosty przykładem funkcji użytkownika może być wskaźnik NDVI, powszechnie stosowany w teledetekcji satelitarnej. Zdefiniowanie wzoru wskaźnika pozwala na obliczenie jego wartości na podstawie oryginalnych danych bez konieczności obciążania systemu dodatkową warstwą obrazową zawierającą wyniki obliczeń NDVI, które zostały wykonane poza środowiskiem oprogramowania klasyfikującego.

W klasyfikacji obiektowej oprogramowania eCognition zastosowano teorię zbiorów rozmytych, która w przeciwieństwie do operacji logicznych nie posłu-

guje się tylko wartościami „tak” i „nie”. Zakres możliwych wyników rozciąga się na przedział wartości $\langle 0, 1 \rangle$. Wartość 0 jest równoważna z odpowiedzią „nie”, natomiast 1 – „tak”. Wartości między 0 i 1 związane są z odpowiedziami pośrednimi, których wartość obliczana jest na podstawie wartości funkcji przynależności (Baatz i inni, 2001; Jensen, 1996). Taki sposób postępowania standaryzuje wartości różnych cech obiektów, pozwala na ich bezpośrednie porównywanie oraz ułatwia tworzenie hierarchicznego opisu klas.

Każdy obiekt zdefiniowany w czasie segmentacji może zostać sklasyfikowany parametrycznie, czyli na podstawie ustalonych kryteriów wartości parametrów lub z zastosowaniem metody najbliższego sąsiada (Nearest Neighbour, N.N.). Klasyfikacja metodą najbliższego sąsiada jest odpowiednikiem klasyfikacji nadzorowanej. Obiekty są klasyfikowane poprzez porównanie ich cech z wybranymi obiektami wzorcowymi (samples), będącymi odpowiednikami pól treningowych. Rolę kryterium klasyfikacyjnego pełni odległość w n -wymiarowej przestrzeni cech między danym obiektem a obiektami wzorcowymi. Jest ona obliczana na podstawie następującego wzoru (Baatz i inni, 2001);

$$d = \sqrt{\sum_f \left(\frac{v_f^{(s)} - v_f^{(o)}}{\sigma_f} \right)^2} \quad (18)$$

gdzie:

d – odległość między polem treningowym (s) a obiektem (o) w przestrzeni cech f ,

$v_f^{(s)}$ – wartość cechy f obiektu pełniącego rolę pola treningowego,

$v_f^{(o)}$ – wartość cechy f obiektu,

σ_f – odchylenie standardowe cechy f obiektu.

Jak wynika ze wzoru (18), odległość d jest standaryzowana przez odchylenie standardowe. Następnie, stosując funkcje przynależności zbiorów rozmytych, odległość zamieniana jest na wartość z przedziału $\langle 0, 1 \rangle$ (Baatz i inni, 2001). Metoda najbliższego sąsiada pozwala na uzyskanie bardzo dobrych rezultatów, jednak w przypadku możliwości zdefiniowania klasy jedynie za pomocą paru parametrów należy stosować podejście parametryczne, co powoduje uproszczenie procesu klasyfikacji (Ivits i Koch, 2003).

Kolejną istotną cechą oprogramowania eCognition jest hierarchiczna struktura definicji klas, pozwalająca na dziedziczenie cech klasyfikacyjnych, dzięki czemu opis klas przybiera postać wzajemnych, logicznie uporządkowanych relacji. Klasy znajdujące się na ostatnim poziomie hierarchii automatycznie dziedziczą cechy klas wyższych, od których są zależne w procesie klasyfikacji. Dodatkowo, niezależnie od mechanizmów dziedziczenia, można utworzyć grupy klas, które od strony definicji nie są jednakowe. Prostem

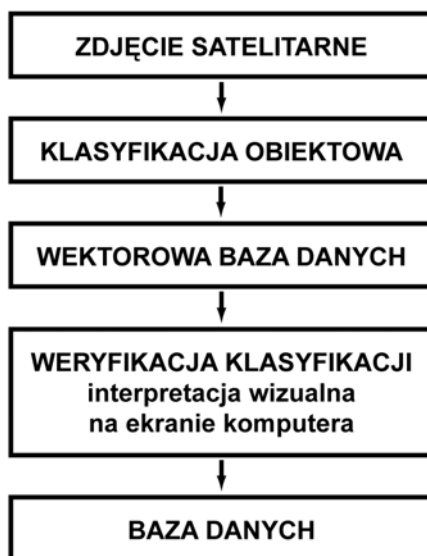
przykładem grupy mogą być „tereny antropogeniczne”, składające się ze wszystkich klas spełniających semantyczne kryterium antropogeniczności. Grupy znajdują również zastosowanie w przypadku analizowania relacji między obiektami. Jeżeli warunkiem istnienia klasy A jest graniczenie z klasą B1, B2 lub B3, to zdefiniowana grupa klas B pozwoli wykonać analizę graniczenia, odwołując się tylko do klasy B, a nie do poszczególnych jej komponentów. Oprogramowanie eCognition dostarcza również narzędzi do tworzenia tzw. struktur klas, które pozwalają między innymi na przenoszenie obiektów między poszczególnymi poziomami segmentacji.

4.2. Algorytm opracowania wektorowej bazy danych na podstawie klasyfikacji obiektowej

Bazy danych CORINE CLC90 i CLC2000 są cenionym i praktycznie wykorzystywanym źródłem informacji o pokryciu terenu, charakteryzują się jednak stosunkowo niskim stopniem szczegółowości wydzieleń (25 ha). Dodatkowo ich wykonanie związane jest z wielką czasochłonnością (Baranowski i Ciołkosz, 1997). Równocześnie obserwujemy wzrost zapotrzebowania na informację o większym stopniu szczegółowości, rzędu 5–1 ha, aktualizowaną zależnie od zakresu tematycznego co 5 lub 3 lata w skali całej Europy. Jest to związane między innymi z wymogami polityki zrównoważonego rozwoju, realizowanej w ramach europejskiego programu GMES (GMES, 2004; 2006).

Opracowanie europejskiej lub krajowej bazy danych o pokryciu i użytkowaniu ziemi o stopniu szczegółowości kilku hektarów, metodą interpretacji wizualnej zdjęć satelitarnych, jest możliwe. Biorąc pod uwagę czasochłonność opracowania, jego koszty i dodatkowo wymaganą częstotliwość aktualizacji informacji, interpretacja wizualna nie jest jednak rozwiązaniem optymalnym. Dlatego też dążenie do opracowania nowej technologii sporządzania baz danych jest w pełni uzasadnione. Nowa technologia musi opierać się na klasyfikacji automatycznej; w chwili obecnej klasyfikacja obiektowa wydaje się być najbardziej odpowiednim narzędziem. Stosowanie jej musi być jednak poprzedzone określeniem zasad postępowania związanych z wykonaniem segmentacji i rozpoznaniem obiektów. Istotny jest również sposób opracowania wyników klasyfikacji, tak aby mogły one w sposób bezpośredni zasilić bazę danych o pokryciu i użytkowaniu ziemi.

Propozycja nowego sposobu tworzenia baz danych, z zastosowaniem klasyfikacji obiektowej, przedstawiona jest w postaci uproszczonego schematu na rysunku 14.

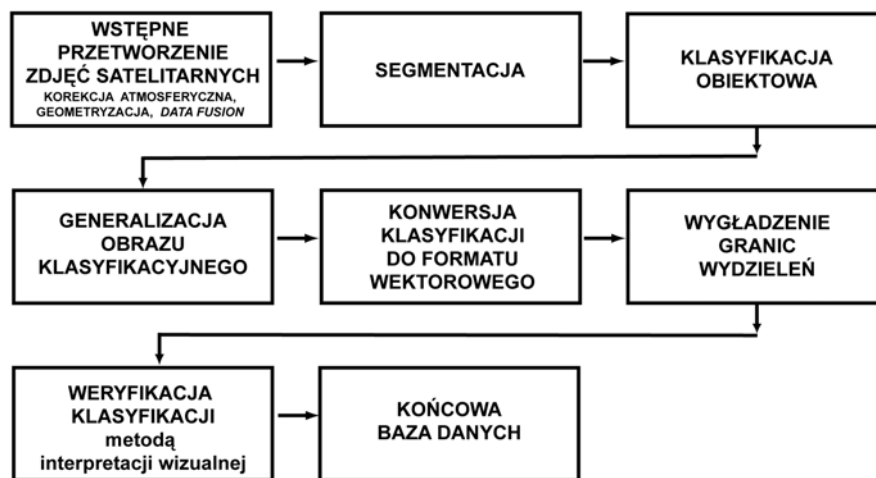


Rys. 14. Uproszczony schemat opracowania baz danych o pokryciu i użytkowaniu ziemi z zastosowaniem klasyfikacji obiektowej

Wynika z niego, że w odróżnieniu od technologii opracowania baz danych CLC90 i CLC2000 (rys. 1) treść zdjęcia satelitarnego nie jest interpretowana, lecz klasyfikowana metodą obiektową. Następnie na podstawie klasyfikacji tworzona jest wektorowa baza danych, weryfikowana przez interpretera. Szczegółową propozycję nowego algorytmu postępowania zamieszczono na rysunku 15.

Proces opracowania bazy danych rozpoczyna się od wstępnego przetworzenia zdjęcia satelitarnego. Jest to związane z korekcją atmosferyczną, której nie należy pomijać podczas klasyfikacji serii zdjęć pochodzących z różnych terminów oraz z wykonaniem rektyfikacji, czyli z przekształceniem zdjęcia do ustalonego odwzorowania. W przypadku stosowania zdjęć satelitarnych składających się z danych wielospektralnych i zdjęcia panchromatycznego w ramach wstępnego przetworzenia powinno być wykonane ich połączenie (data fusion) w sposób umożliwiający uzyskanie danych zbliżonych do wielospektralnych, charakteryzujących się rozdzielczością przestrzenną zdjęcia wykonanego w zakresie panchromatycznym. Następnie wykonywana jest segmentacja obrazu satelitarnego. Jest ona integralną częścią klasyfikacji obiektowej, jednakże została wyodrębniona ze względu na ważną rolę, jaką odgrywa. Od sposobu przeprowadzenia segmentacji zależy jakość klasyfikacji, gdyż nie jest możliwe wykonanie poprawnej klasyfikacji na podstawie niepoprawnie zdefiniowanych obiektów. W prezentowanej metodzie granice obiektów są dodatkowo wykorzystane do utworzenia wektorowej bazy danych. W ten

sposób automatycznie wykonywana jest najbardziej czasochłonna część interpretacji wizualnej, polegająca na wyznaczaniu granic wydzielen. Jeżeli granice są poprawnie wyznaczone, to w przypadku błędnej klasyfikacji obiektu interpretator sprawdzający wyniki klasyfikacji musi jedynie ustalić znaczenie obiektu i zmodyfikować kod wydzielenia, a nie zmieniać przebieg granic.



Rys. 15. Schemat opracowania bazy danych o pokryciu i użytkowaniu ziemi, z zastosowaniem klasyfikacji obiektowej.

Obiekty powstałe w czasie segmentacji są najpierw klasyfikowane, a następnie uzyskany obraz klasyfikacyjny jest generalizowany. W przypadku większości klasyfikacji zdjęć satelitarnych, wykonywanych metodami tradycyjnymi, generalizacja jest pomijana lub zastępowana przez prostą filtrację. W proponowanym w tej pracy algorytmie postępowania obraz jest generalizowany z zastosowaniem jednostki odniesienia. Znaczenie jej jest takie samo jak w przypadku interpretacji wizualnej – decyduje ona o stopniu szczególności opracowania. Wielkość jednostki odniesienia związana jest bezpośrednio z założeniami tworzonej bazy danych; powinna ona uwzględniać docelową skalę opracowania oraz rozdzielczość przestrzenną analizowanego zdjęcia satelitarnego. Generalizacja wykonywana jest na danych zapisanych w formacie rastrowym. Zaletą takiego sposobu postępowania jest uzyskanie „oczyszczonych” danych (bez małych wydzielen), co ułatwia utworzenie wektorowej bazy danych w następnym etapie algorytmu.

Po generalizacji wykonywana jest zmiana formatu danych rastrowych na wektorowy, co powoduje utworzenie wektorowych granic wydzielen. Następnie w celu otrzymania granic maksymalnie zbliżonych do rzeczywistych, jakie ustalane są w toku interpretacji wizualnej, stosowane są funkcje wygładzające. Zadaniem tych funkcji jest zminimalizowanie wyraźnie widocznego

wplywu prostokątnych krawędzi pikseli zdjęcia, wzdłuż których bieżą podziały klas.

Ostatnim etapem jest weryfikacja danych klasyfikacyjnych, którą przeprowadza się metodą interpretacji wizualnej, gdyż tylko interpretator może ocenić i poprawić wyniki klasyfikacji, zmieniając przebieg granic wydzielen lub ich kody. W ten sposób uzyskujemy kompleksową ocenę klasyfikacji oraz poprawioną (teoretycznie bezbłędną) wektorową bazę danych o pokryciu terenu.

Prezentując poszczególne etapy algorytmu, pominięto techniczne aspekty tworzenia wektorowej bazy danych, związane m.in. z tzw. czyszczeniem warstwy wektorowej, które zawsze muszą być wykonane. Równocześnie jednak są one w dużym stopniu wyeliminowane w wyniku przyjętej kolejności przetwarzania danych.

4.3. Utworzenie wektorowej bazy danych o pokryciu i użytkowaniu ziemi z zastosowaniem klasyfikacji obiektowej treści zdjęcia satelitarnego LANDSAT ETM+

Nowa technologia służąca do opracowania baz danych o pokryciu i użytkowaniu ziemi (rys. 14 i 15), w której interpretacja wizualna jest zastąpiona przez klasyfikację obiektową, została praktycznie zastosowana na przykładzie zdjęcia zarejestrowanego przez skaner ETM+ satelity Landsat. Wykonano to na przykładzie tego samego terenu badań oraz tego samego zdjęcia satelitarnego, zarejestrowanego 7 maja 2000 r., na podstawie którego przedstawiono wyniki tradycyjnej klasyfikacji pikselowej.

Pierwszy etap zaproponowanego algorytmu postępowania (rys. 15), związany ze wstępnym przetworzeniem zdjęcia, został przeprowadzony w identyczny sposób jak w przypadku prezentowanej tradycyjnej klasyfikacji nadzorowanej i nienadzorowanej. Zastosowane algorytmy i uzyskane wyniki, związane z wykonaniem korekcji atmosferycznej i z łączeniem kanałów wielospektralnych z kanałem panchromatycznym, przedstawione są w podrozdziałach 3.2 i 3.3. Na podstawie wstępnie przetworzonych danych wykonano segmentację zdjęcia i następnie klasyfikację obiektową.

4.3.1. Segmentacja treści zdjęcia

Segmentacja treści zdjęcia satelitarnego, podobnie jak w przypadku klasyfikacji tradycyjnej, została poprzedzona analizą informacji o poszczególnych kanałach. Analizowano wartości jaskrawości pikseli oraz stopień korelacji danych pochodzących z poszczególnych kanałów spektralnych (tab. 3 i 4). Następnie wykonano szereg prób podziału treści zdjęcia na obiekty. Przeprowadzone próby wykazały, że najlepsze efekty segmentacji można uzyskać, stosując dwupoziomą segmentację, tworząc pierwszy poziom obiektów na podstawie danych panchromatycznych, a następnie drugi z wykorzystaniem

kanałów 2, 3 i 4 połączonych z danymi panchromatycznymi (kanały: K2PAN, K3PAN, K4PAN).

Zastosowanie w segmentacji połączonych kanałów wydaje się być w pełni uzasadnione, gdyż zawierają one sumę informacji związanych z zakresami wielospektralnymi i kanałem panchromatycznym. Spośród trzech wybranych kanałów największą zmiennością informacji charakteryzuje się kanał K4PAN, w którym odchylenie standardowe wartości jaskrawości pikseli wynosi 30,62 i jest największe spośród wszystkich dostępnych danych. Powoduje to generowanie dużej liczby obiektów w porównaniu z danymi charakteryzującymi się małą zmiennością jaskrawości pikseli. Z kanałami K2PAN i K3PAN związane są znacznie mniejsze wartości odchylenia standardowego wynoszące odpowiednio 10,21 i 13,85. Podobnie jak w przypadku danych oryginalnych kanały K2PAN i K3PAN są skorelowane ze sobą na stosunkowo wysokim poziomie: 0,97. Równocześnie jednak ich współczynniki korelacji z kanałem K4PAN są bardzo niskie: 0,49, 0,37, co oznacza, że nie zawierają one takich samych informacji spektralnych jak kanał K4PAN.

Przeprowadzone próby wykazały, że połączone dane zwiększają precyzję wyznaczania obiektów. W większości przypadków granice ich są poprawnie zdefiniowane oraz dodatkowo są prowadzone wzdłuż krawędzi pikseli zdjęcia panchromatycznego, a nie wzdłuż krawędzi dwa razy większych pikseli zdjęć wykonanych w kanałach wielospektralnych. Wykonano również próby zastosowania w procesie segmentacji kanałów wielospektralnych przepróbkowanych do wymiaru piksela panchromatycznego metodą splotu sześciennego. Jednakże na ich podstawie nie zdołano uzyskać lepszych wyników. Zaobserwowano nawet, w niektórych przypadkach, zmniejszenie precyzji wyznaczenia granic obiektów. Najprawdopodobniej jest to spowodowane sposobem obliczania nowych wartości jaskrawości pikseli, które są określane na podstawie wartości występujących w ich najbliższym otoczeniu.


Segmentacja została wykonana z założeniem klasyfikacyjnym rozpoznania obiektów o minimalnej wielkości 4 ha oraz 1 ha dla wód i obszarów zabudowanych. Parametry segmentacji zastosowane w oprogramowaniu eCognition przedstawione są w tabeli 11.

Tabela 11. Parametry segmentacji zdjęcia wykonanego skanerem ETM+


poziom segmentacji	parametr			zastosowana waga kanału				obiekty	
	skala	kolor	zwartość	PAN	K2 PAN	K3 PAN	K4 PAN	liczba	średnia pow. (ha)
1	5	0,9	1	1				84183	0,50
2	23	0,8	0,8		1	2	1	4269	9,93

Obiekty pierwszego poziomu segmentacji powstały w wyniku analizy jedynie danych panchromatycznych. Zastosowano mały parametr *skali* oraz wysokie wartości współczynników *kolor* i *zwartość*. Przyjmując te założenia,

obraz terenu badań został podzielony na 84 183 obiektów o zwartych kształtach. Drugi poziom segmentacji został utworzony na podstawie połączonych kanałów wielospektralnych z kanałem panchromatycznym. Zastosowano dużo większą wartość parametru skali wynoszącą 23 oraz zmienione parametry *kolor* i *zwartość* o jednakowej wartości 0,8, dzięki czemu możliwe było uzyskanie, na bazie obiektów pierwszego poziomu, obiektów o zdecydowanie większej powierzchni. Dodatkowo, dla kanału K3PAN zastosowano wagę 2, która w tym zestawie kanałów spełnia rolę uśredniającą wobec kanału K4PAN, charakteryzującego się wysoką wartością odchylenia standardowego. Na drugim poziomie powstało 4269 obiektów. Przykłady segmentacji pierwszego i drugiego poziomu przedstawione są na rysunkach 16 i 17. Zastosowane parametry pozwoliły na poprawne wydzielenie klasyfikowanych później obiektów, w tym również o charakterze liniowym.



Rys. 16. Przykład segmentacji pierwszego poziomu na tle klasyfikowanego zdjęcia satelitarnego



Rys. 17. Przykład segmentacji drugiego poziomu na tle klasyfikowanego zdjęcia satelitarnego

4.3.2. Klasyfikacja obiektowa

Klasyfikację obiektową zdjęcia satelitarnego wykonano, wykorzystując podział treści zdjęcia na obiekty otrzymany w toku segmentacji drugiego poziomu (tab. 11, rys. 17). Do rozpoznania klas pokrycia i użytkowania ziemi zastosowano

funkcje oprogramowania eCognition: standardową metodę najbliższego sąsiada STD.N.N. (Standard Nearest Neighbor) oraz kryteria parametryczne.

Zastosowanie metody klasyfikacyjnej STD.N.N. poprzedzone było analizą rozróżnialności poszczególnych klas. W tym celu spośród obiektów utworzonych na drugim poziomie segmentacji wybrano obiekty wzorcowe. Przeprowadzone testy pozwoliły na zdefiniowanie wzorców dla następujących 12 klas: lasy iglaste, lasy liściaste, zabudowa, łąki, grunty orne wielkoblokowe bez pokrywy roślinnej, grunty orne wielkoblokowe z pokrywą roślinną, grunty orne drobnoblokowe, tereny z dużym udziałem roślinności naturalnej, las w stanie zmian, osadniki, szklarnie oraz tereny pozbawione roślinności. Na tym etapie klasyfikacji kierowano się przede wszystkim właściwościami spektralnymi obiektów. W czasie późniejszej klasyfikacji niektóre z tych klas zostały podzielone na podklasy z zastosowaniem dodatkowych kryteriów parametrycznych lub zostały połączone, tworząc jedną klasę tematyczną.


Po rozpatrzeniu wstępnych wyników klasyfikacji podjęto decyzję o wyborze wzorców klasy „zabudowa” w taki sposób, aby reprezentowały one wszystkie później rozpoznane typy zabudowy.

Dwie klasy związane z gruntami ornymi wielkoblokowymi bez pokrywy i z pokrywą roślinną (różnice w pokrywie roślinnej wynikają przede wszystkim z majowego terminu rejestracji zdjęcia, w którym uprawy ozime charakteryzują się już zaawansowaną vegetacją i tworzą zwartą pokrywą roślinną) na późniejszym etapie klasyfikacji zostały połączone w jedną klasę „grunty orne wielkoblokowe”. Druga klasa gruntów ornych to „grunty orne drobnoblokowe” związane z tzw. mozaikową formą użytkowania ziemi, utworzoną przez rozdrobnioną strukturę sąsiadujących ze sobą pól i łąk. „Tereny z dużym udziałem roślinności naturalnej” reprezentują obszary niewielkich pól ornich, występujących na przemian z niewielkimi łąkami oraz terenami zadrzewionymi. Tereny pozbawione roślinności reprezentują na tym etapie klasyfikacji dwie klasy bardzo zbliżone do siebie pod względem spektralnym: „płace budów” i „tereny piaszczyste” (położone wzdłuż brzegów Wisły i Narwi). Późniejsze ich rozróżnienie było możliwe na podstawie dodatkowo zastosowanych parametrów.

Równocześnie z określeniem klas i ich wzorców wykonano analizę klasyfikatorów pozwalających na ich rozróżnienie z zastosowaniem metody STD.N.N. W tym celu wykorzystano funkcję Feature Space Optimization oprogramowania eCognition, która jako miarę rozróżnialności podaje odległość w przestrzeni wielospektralnej standaryzowaną odchyleniem standardowym [wzór (18)]. Przeanalizowano następujące parametry obiektów: wartości jaskrawości obiektów, wartości odchylenia standardowego jaskrawości pikseli tworzących obiekty w poszczególnych kanałach oraz tzw. funkcje Haralick obliczające teksturę obiektów (m.in. entropię, kontrast i homogeniczność obiektów). Uwzględniono również parametr *ratio*, który w oprogramowaniu eCognition jest definiowany jako iloraz wartości jaskrawości obiek-

tu w danym kanale do sumy jaskrawości w pozostałych analizowanych kanałach. W sumie testowano 14 parametrów związanych z kanałem panchromatycznym, kanałami wielospektralnymi oraz kanałami K2PAN, K3PAN i K4PAN.

Wykonane analizy wykazały, że kanał panchromatyczny oraz kanały K2PAN, K3PAN i K4PAN, które zostały wykorzystane w procesie segmentacji, nie mają znaczącego wpływu na rozróżnialność zdefiniowanych klas pokrycia i użytkowania ziemi. Należy jednak zaznaczyć, że stosunkowo najlepsze wyniki uzyskano dla kanału K4PAN, charakteryzującego się największą wartością odchylenia standardowego. Ostatecznie wybrano 6 parametrów zdefiniowanych na podstawie wartości jaskrawości pikseli tworzących obiekty, które następnie zostały zastosowane w klasyfikacji metodą najbliższego sąsiada: jaskrawość obiektów w kanałach 4, 5 i 7, *ratio* kanału 3 i 7 oraz entropia GLCM kanału 2 (GLCM – Grey Level Co-occurrence Matrix). Graficzna prezentacja zmienności minimalnej odległości między klasami (minimalna odległość spośród wszystkich dostępnych kombinacji klas) w funkcji liczby najlepszych klasyfikatorów przedstawiona jest na rysunku 18. Dodawanie kolejnych klasyfikatorów (ponad 6 wybranych) powoduje dalszy wzrost rozróżnialności klas, jest on jednak relatywnie mały.



Liczba klasyfikatorów (dimension)

1– *ratio* K3

2– *ratio* K3; średnia K4

3– *ratio* K7; średnia K4, entropia GLCM K2

4– *ratio* K3, średnia K4, K7; entropia GLCM K2

5– *ratio* K3, K7; średnia K4, K5; entropia GLCM K2

6– *ratio* K3, K7; średnia K4, K5, K7; entropia GLCM K2

(K – kanał spektralny)

Rys. 18. Minimalna odległości między wzorcami klas (spośród wszystkich dostępnych kombinacji) w funkcji liczby klasyfikatorów. Wykres funkcji Feature Space Optimization oprogramowania eCognition

Macierz rozróżnialności między obiektami wzorcowymi poszczególnych klas określona z zastosowaniem sześciu wybranych klasyfikatorów przedsta-

wiona jest w tabeli 12. Zróżnicowanie między poszczególnymi klasami, wyrażone przez odległość między nimi [wzór (18)], jest bardzo duże i wynosi od 1,12 do 20,38. Najmniejsze wartości uzyskano w przypadku klasy „grunty orne wielkoblokowe bez pokrywy roślinnej” i „tereny pozbawione roślinności”, czyli dla klas reprezentujących powierzchnię ziemi bez pokrywy roślinnej. Stosunkowo niska rozróżnialność związana jest również z klasą „łąki” i klasami „grunty orne wielkoblokowe z pokrywą roślinną” oraz „grunty orne drobnoblokowe”, co jest związane przede wszystkim z wiosennym terminem rejestracji zdjęcia satelitarnego, w którym tzw. zielone klasy nie są silnie zróżnicowane. Pewnym zaskoczeniem może być brak wysokiej rozróżnialności między klasą „zabudowa” i klasami „tereny z dużym udziałem roślinności naturalnej” oraz „grunty orne drobnoblokowe”. Wynika to z połączenia na tym etapie klasyfikacji wszystkich klas zabudowy, w tym zabudowy o charakterze wiejskim. Wykonane porównania wykazały jednak, że ten sposób postępowania pozwala na uzyskanie dobrych rezultatów końcowych. Kolejną parą klas o stosunkowo niskim stopniu rozróżnialności jest „las w stanie zmian” i „grunty orne drobnoblokowe”; wykazują one podobieństwo spektralne jednakże zastosowanie w czasie późniejszej klasyfikacji dodatkowych kryteriów pozwoliło na ich rozróżnienie.

Tabela 12. Macierz odległości między polami wzorcowymi klas. Obliczenia wykonano dla klasyfikatorów: *ratio* kanału 3, 7; jaskrawość obiektu w kanale 4, 5, 7; entropia GLCM kanału 2

klasa	1	2	3	4	5	6	7	8	9	10	11	12	
1	0,00												
2	4,27	0,00											
3	3,01	8,15	0,00										
4	3,88	4,17	1,42	0,00									
5	16,25	15,24	4,26	4,25	0,00								
6	5,07	12,37	2,15	3,58	10,62	0,00							
7	8,19	13,27	1,83	6,38	13,94	5,82	0,00						
8	5,67	8,16	1,17	2,25	9,61	1,80	5,18	0,00					
9	7,89	6,79	1,22	1,34	2,43	4,67	6,05	2,16	0,00				
10	13,03	15,59	2,40	4,22	3,95	3,68	9,63	2,35	1,34	0,00			
11	20,38	15,83	5,99	6,51	1,14	15,38	17,71	14,13	4,21	8,18	0,00		
12	7,01	2,17	4,28	1,36	6,98	6,38	9,36	3,62	1,93	6,24	8,95	0,00	
1 – lasy iglaste							7 – osadniki						
2 – lasy liściaste							8 – tereny z dużym udziałem roślinności naturalnej						
3 – zabudowa							9 – grunty orne drobnoblokowe						
4 – łąki							10 – lasy w stanie zmian						
5 – grunty orne wielkoblokowe bez pokrywy roślinnej							11 – tereny pozbawione roślinności						
6 – szklarnie							12 – grunty orne wielkoblokowe z pokrywą roślinną						

W procesie klasyfikacji zastosowano również kryteria parametryczne występujące samodzielnie lub razem z STD.N.N. Wykorzystano w tym celu: kryterium wielkości obiektów, odległości między nimi oraz ich kształtu, kryteria graniczenia z obiektem sklasyfikowanym jako inna określona klasa oraz długości wspólnej granicy. Analizowano również stopień przynależności obiektu do innej klasy, jeżeli jest on zaliczany przez system do kilku klas równocześnie, oraz średnie wartości i odchylenia standardowe jaskrawości pikseli zawartych w granicach obiektu. W czasie klasyfikacji zastosowano autorski parametr ZABUD1. Został on specjalnie opracowany w celu identyfikacji klas związanych z zabudową.

Oprogramowanie eCognition pozwala na zdefiniowanie minimalnej wartości funkcji przynależności, która musi zostać przekroczona, aby obiekt został sklasyfikowany. Funkcja przynależności może przybierać wartości z przedziału $\langle 0, 1 \rangle$, wartość 0 oznacza brak możliwości przyporządkowania obiektu do danej klasy, natomiast 1 oznacza całkowite spełnienie wszystkich warunków klasyfikacyjnych. W prezentowanym opracowaniu, w celu zwiększenia poprawności klasyfikacji, zastosowano stosunkowo dużą wartość funkcji przynależności: 0,55. Ze względu na zastosowane w opisie klas relacje między obiektami obliczenia wykonywane były nie w jednym, lecz w kilku cyklach obliczeniowych.

Na zdjęciu obrazującym teren badań wyróżniono w toku klasyfikacji obiektowej 18 form pokrycia i użytkowania ziemi. Są one przedstawione w tabeli 13 zawierającej ich nazwy oraz kody zgodne z nomenklaturą programu CORINE. Połowa klas związana jest z trzecim poziomem legendy CORINE, jedna klasa (wody) z drugim, natomiast pozostałe przyjmują kolejny, czwarty poziom hierarchicznie zbudowanej legendy projektu CLC.

Niektóre z klas, ze względu na podobieństwo spektralne, są nierozpoznawalne tradycyjnymi metodami klasyfikacyjnymi, bazującymi tylko na analizie wartości jaskrawości pikseli zdjęcia satelitarnego.

Tabela 13. Klasy pokrycia i użytkowania ziemi sklasyfikowane metodą obiektową na zdjęciu Landsat ETM+

lp.	kod CORINE	nazwa klasy
1	1121	zabudowa luźna wielorodzinna miejska typu blokowego
2	1122	zabudowa luźna wielorodzinna typu miejskiego
3	1123	zabudowa luźna jednorodzinna typu wiejskiego
4	121	tereny przemysłowe i handlowe
5	1322	zwałowiska odpadów płynnych – osadniki
6	133	plac budów
7	141	miejskie tereny zielone
8	2111	grunty orne wieloblokowe
9	2112	grunty orne drobnoblokowe
10	2113	uprawy szklarniowe
11	231	łąki
12	243	tereny z dużym udziałem roślinności naturalnej
13	311	lasy liściaste
14	312	lasy iglaste
15	313	lasy mieszane
16	324	las w stanie zmian
17	3311	tereny piaszczyste
18	51	cieki i zbiorniki wodne

4.3.3. Zasady klasyfikacji poszczególnych klas

W celu rozpoznania na zdjęciu satelitarnym wspomnianych uprzednio 18 klas pokrycia i użytkowania ziemi zastosowano metodę klasyfikacji STD.N.N. oraz kryteria parametryczne. Przyjęte założenia klasyfikacyjne nie były jednakowe dla wszystkich klas.

Klasy związane z zabudową zostały rozpoznane dwustopniowo. Najpierw, stosując metodę STD.N.N. na podstawie wybranych pól wzorcowych, określono ogólną klasę zabudowy reprezentującą wszystkie jej typy. W czasie analizy zdjęć stwierdzono, że niektóre obiekty zlokalizowane wzdłuż brzegów rzek charakteryzują się cechami, które upodobniają je do terenów zabudowanych. Aby możliwe było ich odróżnienie, w definicji klasy „zabudowa” zastosowano dodatkowo kryterium ograniczające długość występowania wspólnej granicy z klasą „woda”. Uwzględniono również warunek minimalnej szerokości, tak aby nie klasyfikować obiektów o charakterze liniowym, związanych najczęściej z ciągami komunikacyjnymi. Następnie przystąpiono do podziału ogólnej klasy zabudowy na podklasy. W sumie rozpoznano cztery klasy zabudowy: tereny przemysłowe, zabudowa luźna wielorodzinna typu miejskiego, zabudowa luźna wielorodzinna typu wiejskiego oraz zabudowa luźna

wielorodzinna miejska typu blokowego (kody CORINE: 1121, 1122, 1123, 121). Trzy pierwsze klasy zostały wyodrębnione z ogólnej klasy zabudowy z zastosowaniem, opracowanego na potrzeby niniejszej pracy, oryginalnego kryterium ZABUD1.

Kryterium ZABUD1 nie jest standardową funkcją oprogramowania eCognition. Zostało ono specjalnie opracowane w celu rozpoznania zabudowy na zdjęciu wykonanym skanerem ETM+. Na podstawie analizy wartości spektralnych obiektów reprezentujących różne typy zabudowy zdefiniowałem zależność wyrażoną następującym wzorem:

$$ZABUD1 = ((K2 - K3)^2 + (K3 - K4)^2 + (K4 - K5)^2 + (K5 - K7)^2 + (K7 - PAN)^2)^{0.5} \quad (19)$$

gdzie:


K2, K3, K4, K5, K7, PAN – jaskrawość obiektu w poszczególnych kanałach zdjęcia wykonanego skanerem ETM+.

Na rysunku 19 przedstawione są wartości jaskrawości (w postaci krzywych) przykładowych obiektów związanych z zabudową miejską, wiejską oraz z terenami przemysłowymi. Wykresy wartości spektralnych reprezentujących obiekty zabudowy miejskiej oraz przemysłowej są bardzo zbliżone do siebie. Pewne różnice, na poziomie kilku jednostek jaskrawości pikseli, występują jedynie w kanałach 4 i 7. Na rysunku wyróżnia się przede wszystkim krzywa oznaczająca zabudowę wiejską, która różni się od zabudowy miejskiej i przemysłowej w zakresie panchromatycznym (około 10 jednostek) oraz zdecydowanie w zakresie bliskiej podczerwieni – kanały 4 i 5, co jest związane z różnicami w intensywności występowania roślinności w granicach poszczególnych typów zabudowy. Przeprowadzone próby rozróżnienia zabudowy na podstawie wartości kanałów PAN, 4, 5 i 7 nie przyniosły zadowalających wyników. Również zastosowanie współczynnika NDVI oraz miar tekstury obiektów nie wpłynęło na zdecydowaną poprawę ich rozróżnialności. Trudności wynikały przede wszystkim z występowania małych różnic między terenami przemysłowymi i zabudową miejską.

Zastosowanie kryterium ZABUD1, którego wzór uwzględnia różnice w jaskrawości pikseli między kolejnymi kanałami spektralnymi, pozwoliło na rozróżnienie trzech klas zabudowy. Kryterium ZABUD1, obliczone dla poszczególnych klas zabudowy na podstawie wartości z rysunku 19, przedstawione jest w postaci poziomych linii. Teoretycznie, w przypadku braku różnic w odbiciu spektralnym między kolejnymi kanałami, minimalna wartość kryterium wynosi 0. Duże wartości otrzymujemy w przypadku występowania zróżnicowania wartości obiektów w poszczególnych kanałach spektralnych.

Kryterium ZABUD1 w prezentowanej klasyfikacji zostało zastosowane tylko w celu rozróżnienia klas zabudowy. Przeprowadzone próby wskazały,

że może być ono stosowane również w celu rozróżnienia klas niezwiązanych z zabudową. Istnieje też możliwość jego wykorzystania (po adaptacji) do klasyfikacji treści innych zdjęć satelitarnych.



Rys. 19. Wartości jaskrawości (DN) przykładowych obiektów zabudowy wiejskiej, miejskiej i przemysłowej oraz wartości kryterium ZABUD1 obliczonego na ich podstawie

Po wyróżnieniu obiektów związanych z zabudową luźną miejską wyłoniło się z niej zabudowę typu blokowego. Do klasy zabudowy blokowej zostały zaliczone obiekty zabudowy miejskiej, w których granicach na niższym poziomie segmentacji (na pierwszym poziomie) rozpoznano cienie budynków. Jako cienie klasyfikowano obiekty o niskich wartościach jaskrawości pikseli w kanale panchromatycznym i równocześnie o małej powierzchni. Dodatkowo uwzględniono warunki niegraniczenia ich z innymi „cieniami” (klasyfikowano bloki wolnostojące) oraz kryterium odległości między sąsiadującymi „cieniami”.

Klasa **zwałowiska odpadów płynnych – osadniki** (kod CORINE: 1322) została rozpoznana metodą STD.N.N. z równoczesnym zastosowaniem warunku niegraniczenia z klasą „woda” oraz z warunkiem ograniczającym wielkość obiektu.

Place budów i tereny piaszczyste (kod CORINE: 133, 3311) na zdjęciu wykonanym skanerem ETM+ są bardzo zbliżone do siebie pod względem spektralnym. Dlatego też najpierw sklasyfikowano je jako jedną klasę, o nazwie „tereny pozbawione roślinności”, stosując w tym celu jedynie metodę STD.N.N. Następnie podzielono ją na „place budów” i „tereny piaszczyste” (plaże), stosując kryterium odległości od zabudowy oraz kryterium granicze-

nia z obiektami klasy „woda”. Dodatkowo „place budów” i „tereny piaszczyste” wyłoniono również z podklasy „gruntów ornyc bez roślinności”, stosując w tym celu kryterium powierzchni (małe obiekty) oraz warunek graniczenia z wodą i zabudową.

Klasa **miejskich terenów zielonych** (kod CORINE: 141) została zdefiniowana na podstawie dwóch klas „tereny z dużym udziałem roślinności naturalnej” i „lasy mieszane”. Znalazły się w niej obiekty, które spełniły dodatkowo warunek posiadania relatywnie długiej granicy z zabudową (ponad 75%) oraz występowały w określonej odległości od środka miasta Legionowo (jedyne duże miasto na terenie badań, gdzie może występować ta klasa).

Grunty orne wielkoblokowe (kod CORINE: 2111) są klasą składającą się z dwóch podklas, które zostały oddzielnie rozpoznane. Tworzą je: grunty orne wielkoblokowe bez pokrywy roślinnej oraz z pokrywą roślinną (uprawy ozime). Pierwsza klasa została rozpoznana w toku analizy zdjęć metodą STD.N.N. W rozpoznaniu drugiej klasy, ze względu na podobieństwo spektralne do innych terenów pokrytych roślinnością, obok STD.N.N. zastosowano warunek podobieństwa obiektów tej klasy do klasy „tereny z dużym udziałem roślinności naturalnej”.

W klasyfikacji klasy **grunty orne drobnoblokowe** (kod CORINE: 2112) zastosowano jedynie metodę STD.N.N.

Uprawy szklarniowe (kod CORINE: 2113) rozpoznano metodą STD.N.N. oraz zastosowano dodatkowy warunek wynikający z kształtu konstrukcji szklarni. Obiekty tej klasy musiały posiadać kształt, którego geometria jest zbliżona do prostokąta.


Łąki (kod CORINE: 231) sklasyfikowano metodą STD.N.N. bez dodatkowych warunków parametrycznych.

Tereny z dużym udziałem roślinności naturalnej (kod CORINE: 243) zostały rozpoznane metodą STD.N.N. Zastosowane w niej klasyfikatory pozwoliły na skuteczne rozpoznanie klasy, mimo występowania w jej granicach obiektów o różnych charakterystykach spektralnych.

Trzy podstawowe typy lasów (kod CORINE: 311, 312, 313): **lasy iglaste, lasy liściaste i mieszane** zostały sklasyfikowane z zastosowaniem dwustopniowej klasyfikacji. Najpierw do rozpoznania obiektów reprezentujących lasy iglaste i liściaste wykorzystano metodę STD.N.N. Następnie z tych klas zostały wyłonione obiekty spełniające kryterium przynależności do klasy „lasy mieszane”. Założono, że lasem mieszanym może być las iglasty lub liściasty niespełniający warunku jednorodności w ramach wyznaczonych granic obiektu. Warunek ten określono na podstawie przeprowadzonej analizy wartości jaskrawości obiektów w kanale panchromatycznym, w którym drzewostany iglaste charakteryzują się mniejszymi wartościami odbicia spektralnego w porównaniu z drzewami liściastymi. Ilustracja zastosowanego kryterium przedstawiona jest na rysunku 20. Obiekty klasy „lasy mieszane” wyłonione z lasu iglastego charakteryzują się wartościami w kanale panchromatycznym

większymi od 28, jest to „jasny” las iglasty. Natomiast obiekty oddzielone od klasy „lasy liściaste” posiadają wartości w kanale panchromatycznym mniejsze od 45, czyli jest to „ciemny” las liściasty.

Podobne podejście do klasyfikacji lasu mieszanego zastosowano w klasyfikacji zdjęcia wykonanego skanerem ASTER (Lewiński 2006); do rozróżnienia lasu mieszanego zastosowano wartości odchylenia standardowego w trzecim kanale spektralnym. Natomiast de Kok wykorzystał kanał panchromatyczny jako jeden z kilku parametrów pozwalających na rozpoznanie różnych rodzajów drzewostanów (de Kok i inni, 2000a).

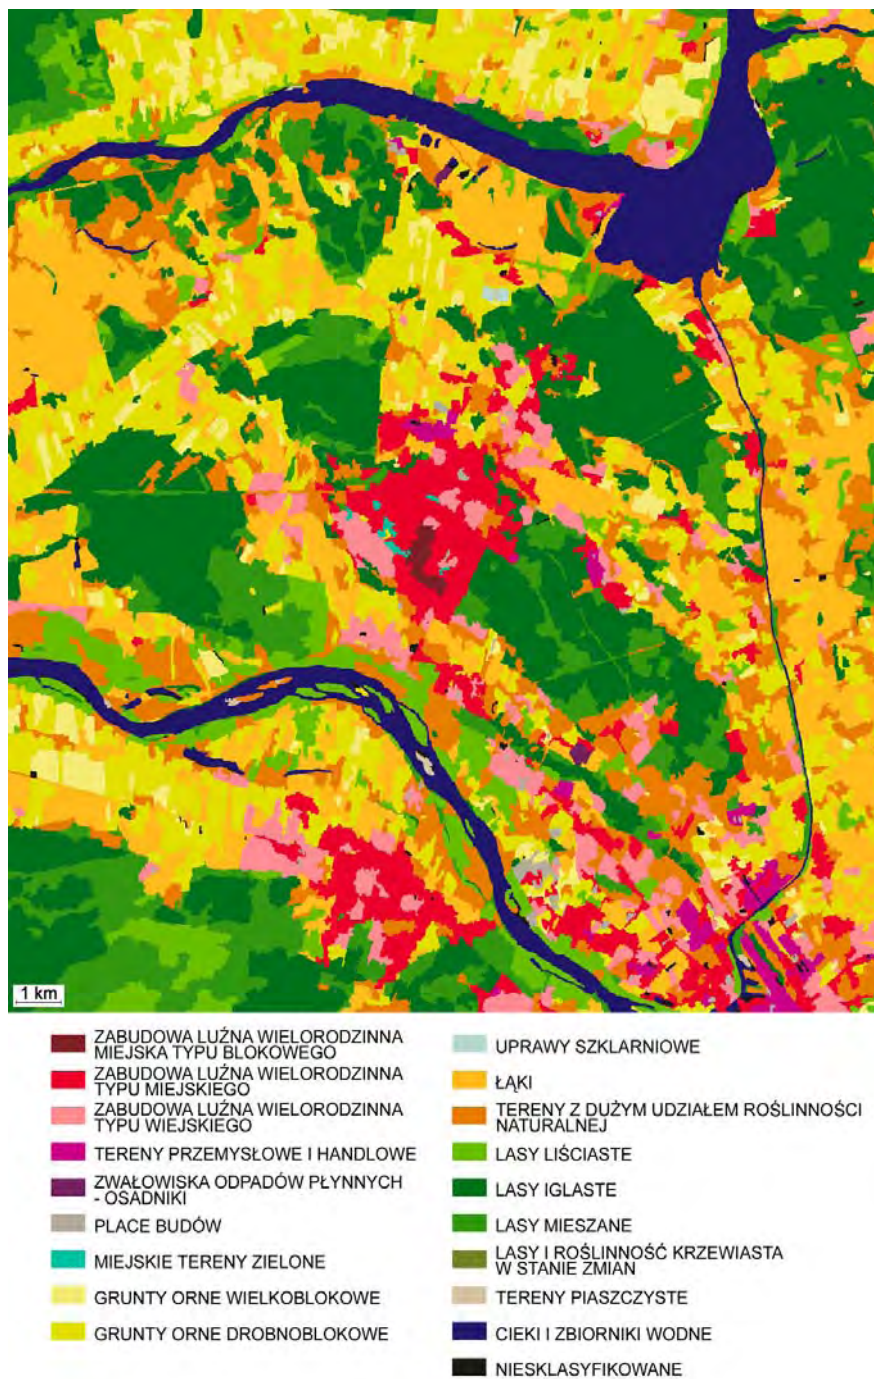


Rys. 20. Zasada klasyfikacji lasu mieszanego na podstawie klas lasy iglaste i lasy liściaste. Oś x – wartość jaskrawości obiektu w kanale panchromatycznym, y – wartość funkcji przynależności

W ramach klasy **lasy i roślinność krzewiasta w stanie zmian** (kod CORINE: 324) rozpoznano jedynie obszary leśne, na których nastąpił wyrąb drzew lub wykonano nowe nasadzenia. W tym celu zastosowano metodę STD.N.N. uzupełnioną warunkiem posiadania przez obiekty tej klasy relatywnie długiej granicy z obiektami sklasyfikowanymi jako las liściasty, iglasty lub mieszany (ponad 75%).

Klasa **cieki i zbiorniki wodne** (kod CORINE: 51) w czasie procesu klasyfikacji została podzielona na trzy podklasy: duże rzeki, małe płytkie zbiorniki oraz kanały. Podklasy rozpoznano z zastosowaniem podejścia parametrycznego, rozpatrując wartości obiektów w kanale 4 i 6 (termalny) oraz dodatkowo w przypadku identyfikacji liniowej struktury kanału uwzględniono parametr szerokości i długości obiektu. Cieki i zbiorniki wodne są jedyną klasą, która została rozpoznana tylko i wyłącznie na podstawie kryteriów parametrycznych.

Na rysunku 21 przedstawiony jest końcowy obraz klasyfikacji obiektowej, na którym rozpoznano 18 klas. Występują na nim również pojedyncze, nierozpoznane obiekty o bardzo małej powierzchni — „niesklasyfikowane”. Klasa ta przestała istnieć w wyniku kolejnych przetworzeń obrazu klasyfikacyjnego.



Rys. 21. Obraz klasyfikacji obiektowej zdjęcia wykonanego skanerem ETM+

4.3.4. Generalizacja wyników klasyfikacji

W celu uzyskania obrazu spełniającego założone warunki szczegółowości przestrzennej bazy danych o pokryciu i użytkowaniu ziemi wykonano generalizację wyników klasyfikacji obiektowej. Podobnie jak w przypadku tradycyjnej klasyfikacji pikselowej, przyjęto wielkość jednostki odniesienia 1 ha dla klas zabudowy i wody oraz 4 ha dla wszystkich pozostałych klas. Oznacza to, że na obrazie klasyfikacyjnym mogą występować jedynie grupy pikseli zajmujące powierzchnię równą lub większą od odpowiadającej danej klasie jednostce odniesienia. W przeliczeniu na piksele kanału panchromatycznego skanera ETM+ (15x15 m) ich minimalna wielkość może wynosić 44 piksele (1 ha) lub 178 pikseli (4 ha).

Przeprowadzenie generalizacji wyników klasyfikacji pikselowej (podrozdz. 3.4.5) spowodowało bardzo duże zmiany w obrazie klasyfikacyjnym, na którym licznie występowały małe grupy pikseli, jak również pojedyncze piksele sklasyfikowane inaczej niż ich otoczenie. W klasyfikacji obiektowej sytuacja jest odmienna, gdyż nie są klasyfikowane piksele, lecz obiekty. Bezpośrednio po procesie segmentacji dysponujemy informacją o powierzchni każdego obiektu, jednak na tym etapie opracowania nie jest wskazane dążenie do uzyskania grup pikseli o powierzchni większej lub równej jednostce odniesienia. Trudno jest bowiem przewidzieć wszystkie okoliczności związane z definiowaniem ich kształtu. Dodatkowo występują sytuacje, w których sąsiadujące małe obiekty są sklasyfikowane jednakowo i dopiero suma ich powierzchni spełnia warunki jednostki odniesienia. Rozpatrując wielkości obiektów, należy mieć również na uwadze stosowane kryteria klasyfikacyjne, związane z obliczaniem wariancji oraz tekstury. Obliczenia zostaną wykonane prawidłowo, jeżeli liczba pikseli tworzących obiekt będzie wystarczająco duża. Jak podaje de Kok (2000b), należy przyjąć, że pojedynczy obiekt ze względu na obliczenia parametrów statystycznych powinien składać się z co najmniej 30 pikseli.

Generalizację wyników klasyfikacji obiektowej wykonano poza środowiskiem oprogramowania eCognition. W tym celu obraz klasyfikacyjny zapisano w zewnętrznym formacie rastrowym. Kody klas zostały przekazane jako wartości pikseli obrazu klasyfikacyjnego, równocześnie wszystkie sąsiadujące ze sobą i jednakowo sklasyfikowane obiekty zostały automatycznie połączone, gdyż przestały istnieć dzielące je wektorowe granice. Generalizację wykonano z zastosowaniem funkcji oprogramowania PCI Geomatica, takich samych jak w przypadku opracowania wyniku tradycyjnej klasyfikacji (podrozdz. 3.4.5) Uzyskany obraz przedstawiony jest na rysunku 22, natomiast dane liczbowe w postaci powierzchni i liczby obiektów związanych z poszczególnymi klasami przed i po generalizacji zamieszczono w tabeli 14.


Po generalizacji wyników klasyfikacji obiektowej największe zmiany pod względem zajmowanej powierzchni nastąpiły dla klas: łąki (+170 ha) i grunty

orne wielkoblokowe (-186 ha). W przypadku łąk zmiany stanowiły jedynie 2.6 % powierzchni klasy. Natomiast powierzchnia wielkoblokowych gruntów ornych zmieniła się o ponad 13%. Tak duże zmiany występujące w ramach jednej klasy wynikają w sposób bezpośredni z liczby obiektów mniejszych od 4 ha oraz z faktu, że klasa ta jest sumą dwóch podklas związanych z polami z odkrytą glebą oraz z polami z pokrywą roślinną. Zmiany powierzchni na poziomie 100 ha dotyczą trzech klas: lasy iglaste, lasy mieszane, grunty orne drobnoblokowe. Pod względem liczby obiektów największe zmiany nastąpiły w klasie „place budów”, ich początkowa liczba wynosząca 56 została zredukowana do 9 spełniających warunek jednostki odniesienia. Klasy „lasy w stanie zmian” oraz „tereny piaszczyste” zostały zredukowane do pojedynczych obiektów. Największa liczba obiektów o powierzchni mniejszej od 4 ha to „tereny z dużym udziałem roślinności naturalnej”. Obiekty te były jednak na tyle małe, że zmiany tej klasy są nieznaczne, wyniosły jedynie 18.3 ha co odpowiada jedynie 0.36% całkowitej powierzchni klasy. Powierzchnie klas związanych z zabudową i wodą, generalizowane z zastosowaniem jednostki odniesienia 1 ha, uległy stosunkowo małym zmianom. Z tabeli 14 wynika, że obraz klasyfikacyjny zawierał 85 bardzo małych niesklasyfikowanych obiektów, które po generalizacji zostały włączone do sąsiednich klas.

Tabela 14. Porównanie wyników klasyfikacji obiektowej treści zdjęcia satelitarnego przed i po generalizacji

kod klasy	KLASA	KLASYFIKACJA		GENERALIZACJA		ZMIANY	
		ha	liczba obiektów	ha	obiekty	%	ha
1121	zabudowa luźna wielorodzinna miejska typu blokowego	63,3	1	63,3	1	0,0	0,0
1122	zabudowa luźna wielorodzinna typu miejskiego	2627,0	85	2668,5	85	1,58	41,5
1123	zabudowa luźna jednorodzinna typu wiejskiego	1884,6	109	1900,5	109	0,84	15,9
121	tereny przemysłowe i handlowe	358,3	21	364,2	20	1,66	5,9
1322	zwałowiska odpadów płynnych – osadniki	24,9	2	24,9	2	0,0	0,0
133	plac budów	137,7	56	82,0	9	-40,48	-55,7
141	miejskie tereny zielone	27,6	6	19,5	2	-29,45	-8,1
2111	grunty orne wieloblokowe	1396,8	171	1210,8	81	-13,32	-186,0
2112	grunty orne drobnoblokowe	6602,2	287	6692,7	185	1,37	90,5
2113	uprawy szklarniowe	15,3	2	15,3	2	0,0	0,0
231	łąki	6477,5	239	6647,5	195	2,62	170,0
243	tereny z dużym udziałem roślinności naturalnej	5125,7	322	5144,0	232	0,36	18,3
111	lasy liściaste	2524,5	124	2548,6	97	0,96	24,1
312	lasy iglaste	8238,7	139	8344,0	97	1,28	105,3
313	lasy mieszane	4131,1	192	4030,6	120	-2,43	-100,5
324	las i roślinność krzewiasta w stanie zmian	6,9	2	4,8	1	-29,69	-2,1
3311	tereny piaszczyste	23,7	8	11,3	1	-52,21	-12,4
51	cieki i zbiorniki wodne	2609,7	28	2612,5	27	0,11	2,8
0	obiekty niesklasyfikowane	109,6	85	0,0	0	-100	-109,6
	SUMA	42385,0	1879	42385,0	1266	474,4 ha = 1,1% terenu badań	

W sumie zmiany w wyniku generalizacji wystąpiły na powierzchni 474,4 ha, co stanowi jedynie 1,1% obrazu całego terenu badań. Podobny rezultat (1,4%) uzyskano w przypadku generalizacji wyników klasyfikacji obiektowej zdjęcia wykonanego skanerem ASTER z satelity Terra (Lewiński, 2006), wykonanej według podobnego algorytmu postępowania. Całkowita liczba obiektów utworzonych na drugim poziomie segmentacji zdjęcia wykonanego skanerem ETM+, wynosząca początkowo 1879, została zredukowana do 1266 (o 33%). Małe zmiany powierzchniowe świadczą o prawidłowo wykonanej segmentacji obrazu. Zbyt duży parametr skali, zdefiniowany w czasie segmentacji, mógłby spowodować wygenerowanie wyłącznie obiektów większych od zdefiniowanej jednostki odniesienia. Na ich podstawie byłoby niemożliwe uzyskanie zakładanego poziomu szczegółowości przestrzennej. Natomiast zbyt mały parametr skali, generujący wielką liczbę relatywnie małych obiektów, może spowodować niepotrzebne podziały dobrze zdefiniowanych obiektów.




	ZABUDOWA LUŻNA WIELORODZINNA MIEJSKA TYPU BLOKOWEGO		UPRAWY SZKLARNIOWE
	ZABUDOWA LUŻNA WIELORODZINNA TYPU MIEJSKIEGO		ŁĄKI
	ZABUDOWA LUŻNA WIELORODZINNA TYPU WIEJSKIEGO		TERENY Z DUŻYM UDZIAŁEM ROŚLINNOŚCI NATURALNEJ
	TERENY PRZEMYSŁOWE I HANDLOWE		LASY LIŚCIASTE
	ZWAŁOWISKA ODPADÓW PŁYNNYCH - OSADNIKI		LASY IGLASTE
	PLACE BUDÓW		LASY MIESZANE
	MIEJSKIE TERENY ZIELONE		LASY I ROŚLINNOŚĆ KRZEWIASTA W STANIE ZMIAN
	GRUNTY ORNE WIELKOBLOKOWE		TERENY PIASZCZYSTE
	GRUNTY ORNE DROBNOBLOKOWE		CIEKI I ZBIORNIKI WODNE

Rys. 22. Obraz klasyfikacji obiektowej zdjęcia wykonanego skanerem ETM+ – po generalizacji

4.3.5. *Utworzenie wektorowej bazy danych*

Obraz klasyfikacyjny po generalizacji można uznać za końcowy wynik przeprowadzonej klasyfikacji, pozwalający na utworzenie rastrowej bazy danych o pokryciu i użytkowaniu ziemi. Tego rodzaju dane zasadniczo różnią się jednak od wektorowych baz danych uzyskiwanych na podstawie interpretacji wizualnej. Pomijając techniczne aspekty różnych sposobów zapisu informacji, w rastrowej bazie danych granice wydzieleni biegają wzdłuż prostokątnych krawędzi pikseli obrazu klasyfikacyjnego.

W celu doprowadzenia wyniku klasyfikacji do przyjętego w opracowaniach kartograficznych obrazu o ciągłym rysunku granic obiektów zastosowano funkcje oprogramowania PCI Geomatica. Najpierw wykonano zamianę formatu rastrowego klasyfikacji na wektorowy, po której powstały poligony o granicach pokrywających się z krawędziami pikseli. Następnie granice zostały wygładzone w taki sposób, aby automatycznie uzyskane linie przypominały wyniki interpretacji wizualnej. Na rysunku 23 przedstawione są „wygładzone” granice wektorowych poligonów na tle obrazu rastrowego.



Rys. 23. Wektorowe granice poligonów na tle rastrowego obrazu klasyfikacyjnego

Atrybuty warstwy wektorowej związane z klasami pokrycia i użytkowania ziemi zostały pozyskane automatycznie na podstawie atrybutów obrazu klasyfikacyjnego.

4.3.6. *Analiza wyników klasyfikacji obiektowej*

Ocena klasyfikacji obiektowej zdjęcia Landsat ETM+ została wykonana metodą interpretacji wizualnej. Przyjęto sposób postępowania zastosowany w programie CORINE mający na celu identyfikację zmian między bazą danych

CLC90 a nowym zdjęciem satelitarnym z roku 2000 (Nunes de Lima, 2005). Osoba wykonująca interpretację obserwowała na monitorze komputera równocześnie wektorową bazę danych uzyskaną w wyniku klasyfikacji obiektowej oraz kompozycję barwną klasyfikowanego zdjęcia. Sprawdzona została poprawność kodów klas poszczególnych wydzieleń oraz równocześnie przebieg ich granic. Na podstawie zaznaczonych różnic między klasyfikacją i interpretacją utworzono tzw. warstwę zmian, której analiza pozwoliła na ocenę poprawności klasyfikacji. Następnie, uwzględniając zmiany wprowadzone przez interpretatora, utworzono końcowy „poprawny” obraz klasyfikacyjny.

Tabela 15 przedstawia macierz błędów uzyskaną dzięki porównaniu bazy danych powstałej w wyniku klasyfikacji treści zdjęcia z bazą poprawioną przez interpretatora. Podane są powierzchnie poszczególnych klas (w ha) oraz tzw. dokładność producenta i użytkownika związana, odpowiednio z błędami niedoszacowania i przeszacowania. Teoretycznie znacząca część błędów klasyfikacyjnych może być związana z majowym terminem rejestracji zdjęcia ETM+, gdyż w wiosennym okresie wegetacyjnym roślinność charakteryzuje się wysokim poziomem chlorofilu. Zjawisko to wpływa na zmniejszenie zróżnicowania spektralnego między tzw. zielonymi klasami. Problem ten występuje również w przypadku interpretacji wizualnej.

Całkowita dokładność klasyfikacji wyniosła 94,5%. Biorąc pod uwagę dokładność producenta, z najmniejszą dokładnością zostały sklasyfikowane „tereny z dużym udziałem roślinności naturalnej” (243), „zabudowa luźna jednorodzinna typu wiejskiego” (1123) oraz „łąki” (231). Dokładność rozpoznania tych klas wyniosła odpowiednio: 78,5%, 87,4% i 93,3%. Stosunkowo niska dokładność 86,9% związana jest również z klasą „płace budów” (133), jednak ze względu na zajmowaną powierzchnię nie odgrywa ona znaczącej roli w całkowitej ocenie.

Stosunkowo niska dokładność użytkownika związana jest z klasą „lasy liściaste” (311) 81,4%, „tereny z dużym udziałem roślinności naturalnej” (243) 89,8%, „łąki” (231) 89,8% oraz „grunty orne drobnoblokowe” (2112) 92,1%. Jako las liściasty (311) zostały błędnie sklasyfikowane tereny z dużym udziałem roślinności naturalnej (243) – 327 ha oraz łąki (231) – 136 ha. W przypadku łąk (231) 569 ha tej klasy w ocenie interpretatora należy do klasy „tereny z dużym udziałem roślinności naturalnej” (243) i równocześnie w ramach tej klasy wykryto 190 ha nieprawidłowo sklasyfikowanych łąk oraz 109 ha zabudowy luźnej jednorodzinnej typu wiejskiego (1123). Błędy klasyfikacji luźnej zabudowy wiejskiej związane są przede wszystkim ze stopniem rozproszenia zabudowy. Natomiast w przypadku zabudowy miejskiej, charakteryzującej się większym stopniem zwarcia, uzyskano dużo wyższą dokładność. Na uwagę zasługuje wysoka poprawność klasyfikacji nielicznej klasy związanej z zabudową blokową (1121), wody (51) oraz lasów mieszanych (313), które zostały wyłonię z klasy „lasy iglaste” i „lasy liściaste” z zastosowaniem ustalonego kryterium jednorodności. W przypadku klasy

gruntów ornych drobnoblokowych (2112) błędnie sklasyfikowano 368 ha związanych z terenami o dużym udziale roślinności naturalnej (243). Spośród 18 automatycznie rozpoznanych klas 7 zostało sklasyfikowanych bezbłędnie.

W celu całościowej oceny klasyfikacji na podstawie macierzy błędów obliczono statystykę K_{hat} , która uwzględnia nie tylko wartości z przekątnej macierzy, lecz również sumy kolumn i wierszy związane z dokładnością producenta i użytkownika. Wartość statystyki K_{hat} obliczono na podstawie wzoru stosowanego do oceny klasyfikacji (Congalton i Mead, 1983; Congalton, 1991):

$$K_{hat} = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})} \quad (20)$$

gdzie:

N – suma obserwacji (powierzchni) w macierzy błędów,

r – liczba wierszy/kolumn macierzy,


x_{ii} – wartości głównej przekątnej macierzy,

x_{i+} – suma i -tej kolumny,

x_{+i} – suma i -tego wiersza.

Uzyskano wartość K_{hat} równą 93,76%. Mając na uwadze wysoką wartość statystyki K_{hat} oraz całkowitą dokładność klasyfikacji wynoszącą 94,54%, wynik klasyfikacji można uznać za co najmniej zadowalający. Należy również pamiętać, że analizowana macierz błędów została uzyskana na podstawie sprawdzenia klasyfikacji całego terenu badań.

Na rysunku 24 przedstawiony jest obraz wektorowej bazy danych, utworzonej po uwzględnieniu zmian uzyskanych w wyniku weryfikacji przeprowadzonej metodą interpretacji wizualnej.



- | | | | |
|---|---|---|--|
|  | ZABUDOWA LUŻNA WIELORODZINNA MIEJSKA TYPU BLOKOWEGO |  | UPRAWY SZKLARNIOWE |
|  | ZABUDOWA LUŻNA WIELORODZINNA TYPU MIEJSKIEGO |  | ŁĄKI |
|  | ZABUDOWA LUŻNA WIELORODZINNA TYPU WIEJSKIEGO |  | TERENY Z DUŻYM UDZIAŁEM ROŚLINNOŚCI NATURALNEJ |
|  | TERENY PRZEMYSŁOWE I HANDLOWE |  | LASY LIŚCIASTE |
|  | ZWAŁOWISKA ODPADÓW PŁYNNYCH - OSADNIKI |  | LASY IGLASTE |
|  | PLACE BUDÓW |  | LASY MIESZANE |
|  | MIEJSKIE TERENY ZIELONE |  | LASY I ROŚLINNOŚĆ KRZEWIASTA W STANIE ZMIAN |
|  | GRUNTY ORNE WIELKOBLOKOWE |  | TERENY PIASZCZYSTE |
|  | GRUNTY ORNE DROBNOBLOKOWE |  | CIEKI I ZBIORNIKI WODNE |

Rys. 24. Obraz wektorowej bazy danych utworzonej po weryfikacji klasyfikacji obiektowej metodą interpretacji wizualnej

5. PORÓWNANIE KLASYFIKACJI TREŚCI ZDJĘCIA WYKONANEJ METODĄ PIKSELOWĄ I OBIEKTOWĄ

Klasyfikacje wykonane na przykładzie tego samego terenu badań oraz tego samego zdjęcia satelitarnego zarejestrowanego skanerem ETM+ pozwalają na przeprowadzenie porównania zastosowanych metod klasyfikacyjnych w aspekcie możliwości rozpoznania klas pokrycia i użytkowania ziemi.

Tradycyjna pikselowa klasyfikacja wykonana z zastosowaniem połączonych metod klasyfikacji nadzorowanej i nienadzorowanej pozwoliła na rozpoznanie na terenie badań jedynie 8 klas. Dodatkowo, w czasie generalizacji mającej na celu uzyskanie założonej szczegółowości przestrzennej wydzieleń (1 i 4 ha) liczba klas została zredukowana do 7, zmianie uległo ponad 26% powierzchni sklasyfikowanego obszaru. W wielu przypadkach powstały deformacje obrazu klasyfikacyjnego wynikające z dużego rozdrobnienia obrazu większości klas.

Klasyfikacja obiektowa tego samego zdjęcia w połączeniu z zaproponowanym algorytmem opracowania wyników pozwoliła na rozpoznanie 18 klas pokrycia i użytkowania ziemi. Należy zwrócić uwagę, że połowa z tych klas jest niemożliwa do rozpoznania z zastosowaniem tradycyjnych metod, bazujących tylko na analizie spektralnej pojedynczo rozpatrywanych pikseli zdjęcia satelitarnego. Odpowiednio dobrane parametry segmentacji już na wstępnym etapie klasyfikacji pozwoliły na uzyskanie dużej liczby obiektów o wielkości spełniającej kryteria jednostek odniesienia. Dzięki temu w trakcie generalizacji klasyfikacji obiektowej zmiany wynikające z istnienia grup pikseli mniejszych od jednostek odniesienia wystąpiły jedynie na obszarze 1,1% terenu badań. W ramach przedstawionego algorytmu postępowania klasyfikacja obiektowa została poddana weryfikacji z zastosowaniem interpretacji wizualnej, w wyniku której uzyskano końcową bazę danych oraz oceniono dokładność klasyfikacji na poziomie 94,54%.

Porównanie wyników otrzymanych w trakcie klasyfikacji treści zdjęcia satelitarnego dwoma metodami wykonano w sposób automatyczny z założeniem, że klasyfikacja obiektowa po wykonanej weryfikacji będzie materiałem referencyjnym dla klasyfikacji pikselowej. Przed przystąpieniem do porównania należało rozwiązać problem różnej liczebności klas rozpoznanych na obu klasyfikacjach. Podjęto decyzję o wykonaniu 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 zabudowy (1121, 1122, 1223 i 121) i klasy „uprawy szklarniowe (2113), występujących w klasyfikacji obiektowej, utworzono jedną klasę, która tematycznie odpowiada klasie „zabudowa”, rozpoznanej w klasyfikacji pikselowej. Następnie, kierując się podobieństwem spektralnym, klasy „grunty orne wielkoblokowe” (2111), klasy zajmujące małe po-

wierzchnie „place budów” (133) oraz „tereny piaszczyste” (3311) zostały zagregowane do klasy „grunty orne”. Nieliczne klasy obiektowe „miejskie tereny zielone” (141) oraz „lasy i roślinność krzewiasta w stanie zmian” (324) po dodaniu do klasy „łąki” (231) utworzyły jedną klasę łąk. Natomiast „osadniki” (1322) dodano do klasy „woda” (51). Klasy związane z lasami „lasy liściaste” (311), „lasy iglaste” (312) oraz „lasy mieszane” (313) występujące w przypadku obu klasyfikacji i niewymagające agregacji pozostały niezmiennione. Dwie ostatnie klasy klasyfikacji obiektowej: „grunty orne drobnoblokowe” (2112) oraz „tereny z dużym udziałem roślinności naturalnej” (243) ze względu na swój charakter nie mają odpowiadających im klas w klasyfikacji pikselowej, gdyż żadna z nich nie jest jednorodna spektralnie. Pierwsza reprezentuje tzw. mozaikową strukturę upraw, w której granicach występują dodatkowo drobne struktury gruntów orných oraz łąk. Druga związana jest głównie z łąkami, jednakże w jej granicach występują również niewielkie pola, lasy oraz wody. W obu przypadkach wydzielenie z nich podklas jest niemożliwe, równocześnie klasy te zajmują znaczącą powierzchnię terenu badań i mają istotny wpływ na wyniki porównania klasyfikacji. W celu rozwiązania tego problemu przyjęto dwa sposoby postępowania. W pierwszym założono, że wszystkie klasy klasyfikacji pikselowej rozpoznane na obszarze klas obiektowych 2112 i 243 są rozpoznane prawidłowo. Taki sposób postępowania z oczywistych względów powoduje wzrost dokładności ocenianej klasyfikacji. Natomiast drugi sposób postępowania polegał na pominięciu obszarów reprezentowanych przez klasy 2112 i 243 w czasie wykonywania analizy porównawczej. Uzyskane wyniki przedstawione są w tabeli 16.

Tabela 16. Ocena klasyfikacji pikselowej, porównanie z klasyfikacją obiektową po agregacji klas

klasa klasyfikacji pikselowej	METODA 1 ^{a)}		METODA 2 ^{b)}	
	dokładność %			
	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_{nat}	0,66		0,54	

^{a)} Założenie prawidłowej klasyfikacji pikselowej na obszarze klas obiektowych 2112 i 243

^{b)} Pominięcie w ocenie obszarów zajmowanych przez klasy obiektowe 2112 i 243

Zgodnie z przewidywaniami większą dokładność klasyfikacji pikselowej, wynoszącą nieco ponad 72%, uzyskano w przypadku oceny wykonanej pierwszą metodą, zakładającą poprawne rozpoznania obszarów związanych z klasami o kodach 2112 i 243 wyróżnionymi w toku klasyfikacji obiektowej. Stosując drugą metodę oceny, nieuwzględniającą tych klas, otrzymano znacznie mniejszą dokładność całkowitą na poziomie 61%. Obliczone wartości statystyki K_{hat} są bardzo niskie i wynoszą odpowiednio 0,66 i 0,54. Bez względu na przyjęty sposób oceny najniższe dokładności związane są z klasą „zabudowa” oraz „lasy mieszane”. W przypadku obu sposobów oceny klasyfikacji wyniki uzyskane dla klasy „lasy iglaste” są prawie jednakowe. W ocenie drugą metodą z punktu widzenia producenta stosunkowo najlepiej wypadły klasy „grunty orne” i „łąki”, równocześnie jednak osiągnięto znacznie gorsze wyniki dokładności użytkownika, związane z przeszacowaniem. Jedyne dokładność klasyfikacji klasy „wody” nie może budzić zastrzeżeń. Podsumowując: uzyskano wyniki świadczące o stosunkowo niskiej dokładności klasyfikacji pikselowej w porównaniu z klasyfikacją obiektową.

6. PROPOZYCJA AUTOMATYZACJI PROCESU POZYSKIWANIA INFORMACJI O POKRYCIU I UŻYTKOWANIU ZIEMI

Podstawową wadą interpretacji wizualnej jest jej wielka czasochłonność, wynikająca z dużej liczby ręcznych operacji związanych przede wszystkim z zaznaczeniem przebiegu granic wydzieleń oraz z nadaniem im kodów klasyfikacyjnych. Wpływa to nie tylko na czas wykonania opracowania, ale również na jego koszt, który jest proporcjonalny do stopnia szczegółowości opracowania. Dlatego też należy poszukiwać metod automatycznych, które mogłyby wspomagać albo nawet zastąpić ręczną pracę interpretatora.

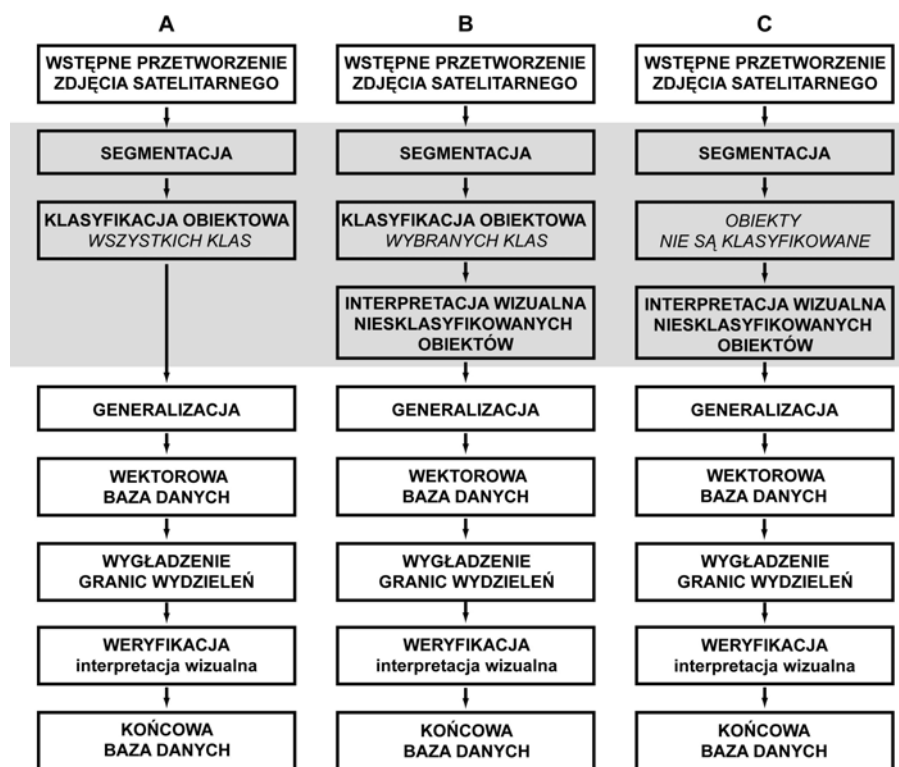
Wyniki uzyskane na podstawie klasyfikacji treści zdjęcia satelitarnego wykonanego skanerem ETM+ wykazały, że nowa technika klasyfikacji obiektowej, w przeciwieństwie do dotychczas stosowanych metod, może wspomagać proces tworzenia baz danych o pokryciu i użytkowaniu ziemi. Jest to możliwe w przypadku rozpoznania wszystkich lub tylko części klas, a nawet wtedy, gdy klasyfikacja obiektowa jest ograniczona jedynie do wykonania segmentacji.

Na rysunku 25 przedstawione są trzy schematy tworzenia bazy danych z zastosowaniem klasyfikacji obiektowej, będące modyfikacją zastosowanego sposobu postępowania w prezentowanej klasyfikacji treści zdjęcia wykonanego skanerem ETM+. Różnice między nimi występują jedynie w części związanej z klasyfikacją. Każdy schemat rozpoczyna się od wstępnego przetwarzania zdjęcia satelitarnego, które jest związane z wykonaniem korekcji at-

mosferycznej, rektyfikacji oraz złączeniem kanałów wielospektralnych z kanałem panchromatycznym.

Wariant „A” przedstawia sytuację optymalną, w której narzędzia klasyfikacji obiektowej pozwalają na rozpoznanie wszystkich założonych klas pokrycia i użytkowania ziemi. Wariant „B” znajduje zastosowanie wówczas, gdy możemy rozpoznać automatycznie jedynie część klas. Takie sytuacje występują najczęściej, gdyż w przypadku opracowania wykonywanego zgodnie z ustaloną legendą, która nie uwzględnia automatycznych możliwości klasyfikacyjnych, zawsze należy spodziewać się niesklasyfikowanych obiektów. Może to wynikać z właściwości spektralnych klas oraz z cech reprezentujących je obiektów, które nie pozwalają na prawidłowe rozróżnienie ich od pozostałych klas. Przykładem takich klas na zdjęciach o średniej rozdzielczości są sady oraz cmentarze, które w większości przypadków, w czasie interpretacji wizualnej, są rozpoznawane na podstawie materiałów pomocniczych. Wobec braku możliwości zastosowania metod automatycznego rozpoznania zachodzi konieczność wykonania ręcznej klasyfikacji, czyli interpretacji wizualnej. Jeżeli przebieg utworzonych automatycznie granic obiektów jest prawidłowy, to rozpoznanie przez interpretatora niesklasyfikowanych obiektów jest zadaniem stosunkowo prostym, nawet w przypadku dużej ich liczby. W ostatnim wariantcie postępowania „C” rola klasyfikacji obiektowej ograniczona jest jedynie do segmentacji. Klasyfikacja automatyczna nie jest wykonywana, obiekty zdefiniowane w czasie segmentacji są klasyfikowane metodą interpretacji wizualnej.

W przypadku wszystkich trzech wariantów sposób przetwarzania wyników klasyfikacji, mający na celu utworzenie bazy danych, jest jednakowy i składa się z omawianych już etapów: generalizacji, stworzenia wektorowej bazy danych, wygładzenia granic wydzielen oraz weryfikacji i opracowania końcowej bazy danych.



Rys. 25. Warianty zastosowania klasyfikacji obiektowej w procesie tworzenia bazy danych o pokryciu i użytkowaniu ziemi

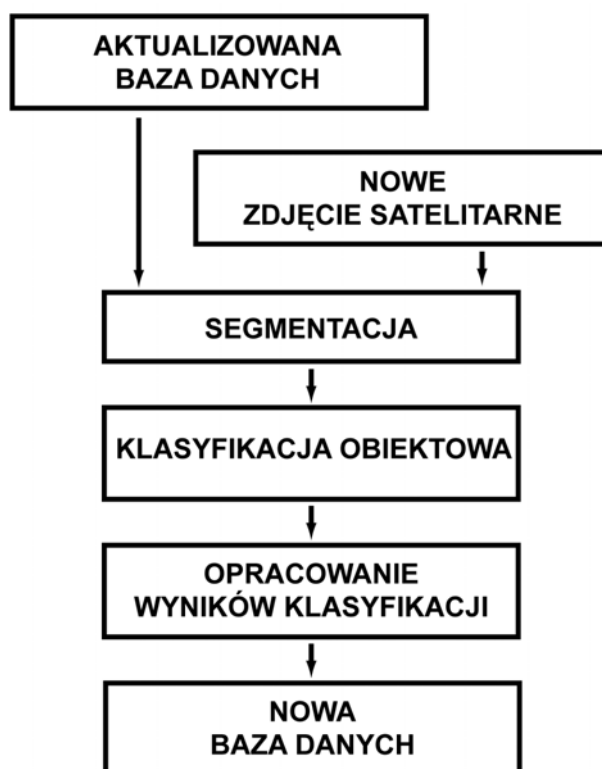
Zastosowanie klasyfikacji obiektowej powoduje znaczące zwiększenie szybkości wykonania opracowania w porównaniu z tradycyjną interpretacją wizualną. Jest to możliwe nawet w przypadku wykorzystania tylko granic wydzieleń powstałych w czasie segmentacji, gdyż dzięki temu najbardziej czasochłonna część interpretacji wizualnej wykonywana jest automatycznie. Trudno jest jednoznacznie określić stopień zmniejszenia czasochłonności opracowania. Można jednak podjąć próbę jego oszacowania na przykładzie jednej sceny zdjęcia zarejestrowanego skanerem TM lub ETM+ z pokładu satelity Landsat. Na zdjęciu zobrazowany jest obszar o wymiarach 180x180 km, którego powierzchnia jest przedstawiona na około 25 mapach w skali 1:100 000. Wykonanie interpretacji wizualnej jednego arkusza mapy zgodnie z zasadami programu CORINE zajmuje średnio 40 godzin, czyli 1000 godzin w przypadku 25 map. Jeżeli przyjmiemy, że 90% czasu interpretacji przypada na czynności związane z określaniem granic, to uzyskamy 900 godzin pracy. Natomiast czas wykonania segmentacji jednej sceny uzależniony jest przede wszystkim od szybkości systemu przetwarzającego ob-

raz. Można jednak przyjąć, że segmentacja spełniająca warunki programu CORINE zostanie wykonana w ciągu 40 minut, czyli aż ponad 1300 razy szybciej niż w przypadku pracy interpretatora. Równocześnie jednak należy pamiętać, że mogą wystąpić błędy segmentacji, które należy zlokalizować i skorygować w trakcie ręcznej klasyfikacji lub weryfikacji. Czas wykonania tych czynności zależy od ilości i złożoności wprowadzanych zmian. Dodatkowo istotne są również możliwości edycyjne oprogramowania, którym dysponujemy. Szybkość przeprowadzenia samej klasyfikacji jest związana z przyjętym sposobem rozpoznania klas. W przypadku zastosowania metody najbliższego sąsiada wprawny operator powinien określić obiekty wzorcowe i wykonać klasyfikację całej sceny w ciągu około 8 godzin. Natomiast stosując już ustalone kryteria parametryczne, czas klasyfikacji uzależniony jest tylko od szybkości systemu komputerowego – powinna być ona wykonana w ciągu kilkunastu lub kilkudziesięciu minut. Na podstawie doświadczeń związanych z prezentowaną klasyfikacją można ocenić, że klasyfikacja obiektowa (z uwzględnieniem weryfikacji) powinna przyspieszyć opracowanie bazy danych przynajmniej o 50%.


Obecnie istotnym zagadnieniem jest aktualizacja istniejących już baz danych, które zostały opracowane w poprzednich latach z zastosowaniem interpretacji wizualnej. W tym celu nie mogą być wykorzystane przedstawione schematy postępowania (rysunek 25), gdyż ich działanie związane jest z opracowaniem od początku nowej bazy danych. W trakcie jej tworzenia nie są uwzględniane dodatkowe informacje pochodzące z innych źródeł (np. z bazy danych w postaci warstwy tematycznej).

Klasyfikacja obiektowa może znaleźć zastosowanie również w przypadku aktualizacji baz danych. Propozycja postępowania przedstawiona jest na rysunku 26. Danymi wejściowymi jest już istniejąca baza danych (w postaci warstwy tematycznej) oraz nowe zdjęcie satelitarne, będące źródłem aktualnych informacji o pokryciu terenu. W czasie segmentacji najpierw tworzone są obiekty odpowiadające wydzieleniom bazy danych, a następnie, na podstawie zdjęcia satelitarnego, wykonywane są segmentacje niższego poziomu. Tworzone są obiekty o wielkości zapewniającej aktualizację informacji z założonym stopniem szczegółowości przestrzennej. Zaletą takiego sposobu postępowania jest zgodność granic. Oznacza to, że w procesie segmentacji nowo powstające obiekty korzystają z granic już istniejącej bazy danych (wyższy poziom segmentacji). Ilustracją takiego sposobu postępowania jest rysunek 27. Górna część rysunku przedstawia, na tle zdjęcia wykonanego skanerem ETM+ w roku 2000, granice obiektów odpowiadających wydzieleniom bazy CORINE CLC90. Na dolnym rysunku widoczne są obiekty utworzone na podstawie parametrów segmentacji podanych w tabeli 11. Wyraźnie widać różnicę w wielkości obiektów, wynikającą ze stopnia szczegółowości bazy CORINE (25 ha) oraz segmentacji wykorzystanej do wykonania bardziej szczegółowego opracowania (4 ha). Następnie nowe (mniejsze) obiekty są

klasyfikowane z zastosowaniem relacji z obiektami z wyższego poziomu oraz informacją o ich wielkości. Dzięki temu klasyfikacja wspomagana jest informacją z istniejącej bazy, a decyzja o klasyfikacji obiektu jako zmiany w pokryciu terenu może być podejmowana z uwzględnieniem jego wielkości. Podobnie jak w przypadku schematów przedstawionych na rysunku 25 obraz klasyfikacyjny jest następnie opracowywany z zastosowaniem generalizacji i edycji kształtu granic wydzieleń. W wyniku wykonanych operacji (rysunek 26) powstaje nowa, aktualna baza danych.



Rys. 26. Schemat zastosowania klasyfikacji obiektowej w aktualizacji istniejącej bazy danych



Rys. 27. Segmentacja uzyskana na podstawie bazy CLC90 (górze) oraz segmentacja o większym stopniu szczegółowości zdjęcia Landsat ETM+ z roku 2000 (dół)

Ważnym zagadnieniem każdej technologii jest określenie możliwości standaryzacji wykonywanych operacji w celu zapewnienia powtarzalności wyników. W interpretacji wizualnej zdjęć satelitarnych standaryzacja związana jest przede wszystkim z definicjami wyróżnionych klas. Przykładem może być ponownie program CORINE, w ramach którego opracowano precyzyjne definicje klas ilustrowane wieloma przykładami interpretacji. Przeprowadzono także szkolenia osób biorących udział w programie. Mimo to końcowy wynik uzależniony jest zawsze od indywidualnej wiedzy i doświadczenia interpretatora, który podejmuje ostateczne decyzje. Również w przypadku tradycyjnych automatycznych klasyfikacji pikselowych, przez ponad 30 lat ich stosowania, nie zdołano wprowadzić do powszechnego użytku zasad postępowania gwarantujących powtarzalność uzyskiwanych wyników. W klasyfikacji nadzorowanej osoba z wiedzą interpretacyjną pełniącą rolę operatora podejmuje decyzje o wyborze pól treningowych, od których całkowicie za-

leżnione są wyniki klasyfikacji. Natomiast w klasyfikacji nienadzorowanej początkowe wartości klas spektralnych najczęściej są definiowane losowo. Standaryzacja może jedynie dotyczyć doboru parametrów początkowych stosowanych algorytmów, a i tak na następnym etapie klasyfikacji operator podejmuje subiektywne decyzje związane z tworzeniem klas tematycznych na podstawie klas spektralnych.

W klasyfikacji obiektowej zagadnienie standaryzacji należy rozpatrywać z podziałem na dwa etapy związane z segmentacją obrazu oraz rozpoznaniem klas. Z całą pewnością parametry segmentacji mogą zostać jednoznacznie zdefiniowane dla określonego typu zdjęć satelitarnych. Należy się spodziewać, że na wynik segmentacji może mieć również wpływ pora rejestracji zdjęć (okres wegetacji) oraz charakterystyka geograficzna i fizjograficzna zobrazowanego terenu. Jak dotąd nie jest to poparte wynikami kompleksowych badań.

Ocena możliwości standaryzacji klasyfikacji obiektowej na etapie klasyfikacji obiektów jest zagadnieniem bardziej złożonym. Przystępując do klasyfikacji, mamy do dyspozycji metodę najbliższego sąsiada oraz funkcje parametryczne odwołujące się do określonych wartości wybranych cech obiektów. W przypadku stosowania metody najbliższego sąsiada, podobnie jak w klasyfikacji nadzorowanej, uzyskiwane wyniki są uzależnione od wiedzy operatora, który podejmuje decyzje o wyborze pól testowych. Jego działania mogą zostać zdefiniowane jedynie na podstawie opisowych zasad postępowania, tak jak w przypadku interpretacji wizualnej. Stosując natomiast klasyfikację parametryczną, możliwe jest zdefiniowanie ściśle określonych zasad postępowania, które podobnie jak w segmentacji muszą uwzględniać specyfikę zdjęcia i zobrazowanego terenu. Jest to możliwe przede wszystkim w przypadku wybranych klas pokrycia i użytkowania ziemi, charakteryzujących się stosunkowo małą zmiennością parametrów zastosowanych do ich rozpoznania.

W przedstawionej metodzie opracowania bazy danych na podstawie klasyfikacji obiektowej zdjęcia zarejestrowanego skanerem ETM+ standaryzacja wykonanych przetworzeń jest możliwa, lecz nie jest jednakowa dla wszystkich etapów zaproponowanego algorytmu. W ramach wstępnych prac związanych z przygotowaniem danych satelitarnych do klasyfikacji wykonano korektę atmosferyczną oraz połączenie danych wielospektralnych i panchromatycznych. W obu przypadkach zastosowano sprawdzone narzędzia, pozwalające na uzyskiwanie powtarzalnych wyników. Jest to szczególnie dobrze widoczne w przypadku algorytmu PanSharp oprogramowania PCI Geomatica, w którym rola operatora ograniczona jest do minimum (podanie nazw zbiorów). Następnie na podstawie kanału panchromatycznego oraz danych połączonych wykonywana jest segmentacja, zgodnie z ustalonymi parametrami. Przyjęty sposób postępowania zapewnił utworzenie obiektów reprezentatywnych dla zobrazowanych form pokrycia i użytkowania ziemi oraz pozwolił na wykonanie klasyfikacji na założonym poziomie szczegółowości przestrzennej. Można przyjąć, że w przypadku zdjęć po-

chodzących ze skanera ETM+, zarejestrowanych w wiosennym okresie wegetacji, zastosowany sposób segmentacji zapewnia uzyskanie porównywalnych wyników niezależnie od umiejętności operatora. Na kolejnym etapie zaproponowanej metody klasyfikacja obiektów została wykonana z równoczesnym zastosowaniem metody najbliższego sąsiada oraz funkcji parametrycznych, w związku z tym uzyskane wyniki, podobnie jak w przypadku interpretacji wizualnej, są uzależnione od doświadczenia osoby wykonującej klasyfikację. Jedynie klasa „wody” została sklasyfikowana z zastosowaniem tylko kryteriów parametrycznych. Następnie obraz klasyfikacyjny został przetworzony. Najpierw wykonano generalizację, stosując w tym celu standardowe funkcje oprogramowania PCI Geomatica. Narzędzia tego oprogramowania wykorzystano również do konwersji danych z formatu rastrowego do wektorowego oraz do zmiany kształtu granic wydzielen. Wymienione trzy etapy opracowania wyników klasyfikacji obiektowej mogą podlegać całkowitej standaryzacji, gdyż są one wykonywane z zastosowaniem określonych procedur działających według zdefiniowanych parametrów. Proces tworzenia bazy danych został zakończony weryfikacją wizualną uzyskanych wyników, na podstawie której powstała następnie ostateczna wersja bazy. Ten etap opracowania jest taki sam jak w przypadku weryfikacji tradycyjnej interpretacji wykonanej przez osobę nadzorującą pracę zespołu interpretatorów i nie może podlegać jednoznacznym regułom standaryzacji.

Mając na uwadze wszystkie aspekty zaproponowanej metody automatycznego tworzenia bazy danych o pokryciu i użytkowaniu ziemi, można stwierdzić, że zapewnia ona powtarzalność wyników w większym stopniu niż w przypadku tradycyjnej ręcznej interpretacji.

7. ZASTOSOWANIE PROPONOWANEJ METODY TWORZENIA BAZY DANYCH O POKRYCIU I UŻYTKOWANIU ZIEMI NA PRZYKŁADZIE ARKUSZA MAPY TOPOGRAFICZNEJ M-34-20-D „PUŁAWY”


Przedstawione dotychczas wyniki, związane z automatyzacją procesu tworzenia bazy danych na podstawie informacji zobrazowanych na zdjęciu satelitarnym, zostały uzyskane na przykładzie terenu badań zlokalizowanego wokół miasta Legionowo. Aby móc potwierdzić słuszność przyjętych założeń i sposobu postępowania w zaproponowanym algorytmie opracowania danych klasyfikacyjnych, podjęto próbę utworzenia nowej bazy danych o pokryciu i użytkowaniu ziemi dla innego terenu badań. W tym celu wybrano obszar testowy, odpowiadający arkuszowi mapy topograficznej „Puławy” w skali 1:50 000, oznaczonej godłem M-34-20-D. Obejmuje on teren o powierzchni około 320 km², ograniczony współrzędnymi 21°45' i 22°00' długości geograficznej oraz 51°20' i 51°30' szerokości geograficznej.

Obraz satelitarny nowego terenu badań jest przedstawiony na rysunku 28. Podstawowymi formami pokrycia terenu są tutaj grunty orne, lasy, wody (Wisła), łąki oraz tereny zabudowane. Grunty orne reprezentowane są przede wszystkim przez niewielkie pola, tworzące mozaikową strukturę upraw. Występują tu również większe pola, o powierzchni kilkunastu hektarów, nie są one jednak dominującą formą pokrycia terenu. Duże kompleksy leśne, lasów iglastych, liściastych i mieszanych widoczne są na zdjęciu przede wszystkim wzdłuż wschodniego brzegu Wisły oraz na południu. Nad Wisłą położone jest miasto Puławy (52 000 mieszkańców). Granice administracyjne miasta obejmują powierzchnię 50 km², z której jedynie około 16% to zabudowa, dominują tereny leśne i zadrzewione (<http://www.um.pulawy.pl>). Na północ od Puław zlokalizowane są Zakłady Azotowe. Na ich terenie znajdują się instalacje przemysłowe, zbiorniki wodne, osadniki oraz składowiska suchych odpadów przemysłowych. Wzdłuż brzegów Wisły oraz małych cieków położone są łąki, obok których występują zazwyczaj skupiska roślinności naturalnej, tzw. zakrzaczenia.

Próbie utworzenia bazy danych podjęto na podstawie zdjęcia satelitarnego zarejestrowanego 16 maja 2000 r. skanerem ETM+. Wykorzystano w tym celu zdjęcie satelitarne, na podstawie którego opracowano w IGiK bazę CORINE CLC2000. Nie były to oryginalne dane satelitarne, lecz wstępnie przetworzone w ramach programu CORINE. Przetworzenie to polegało na wykonaniu rektyfikacji, w trakcie której nowe wartości jaskrawości pikseli obrazu obliczono z zastosowaniem metody splotu sześciennego. W czasie tej operacji dodatkowo został zmniejszony wymiar pikseli kanałów wielospektralnych z 30 m na 25 m oraz kanału panchromatycznego z 15 m na 12,5 m. Taki sposób postępowania miał na celu uzyskanie kompozycji barwnych o podwyższonym stopniu szczegółowości, z których korzystano w toku interpretacji wizualnej. Mając na względzie tradycyjną klasyfikację treści zdjęcia, tak przetworzone dane nie są odpowiednim materiałem klasyfikacyjnym, ponieważ oryginalne wartości jaskrawości pikseli są zniekształcone. Równocześnie jednak w najbliższym czasie można spodziewać się, że w ramach europejskich projektów będą podejmowane próby automatycznych klasyfikacji tego rodzaju danych. Świadczą o tym materiały przetargowe dotyczące wykonania klasyfikacji zabudowy w ramach programu GMES Fast Track Service on Land Monitoring (Land FTS), które zostały opublikowane na początku 2007 r. przez Europejską Agencję Środowiska (Tender specifications, 2007). Z opisu warunków przetargu wynika, że klasyfikacja ma być wykonana na podstawie zdjęć zarejestrowanych przez satelitę SPOT, przygotowanych tak samo jak dla celów tradycyjnej interpretacji wizualnej (przepróbkowanie metodą splotu sześciennego).

Ze względu na wykorzystanie danych satelitarnych po rektyfikacji, w trakcie której dodatkowo zmienione zostały wielkości pikseli, zakres przygotowania zdjęć do klasyfikacji został ograniczony do połączenia danych

wielospektralnych z kanałem panchromatycznym. Wykorzystano w tym celu omówiony już algorytm PanSharp.



Rys. 28. Obraz satelitarny arkusza mapy M-34-20-D „Puławy”. Kompozycja RGB (4, 5, 3) zdjęcia satelitarnego zarejestrowanego skanerem ETM+ z pokładu satelity Landsat, 16 maja 2000 r.

Segmentację treści zdjęcia satelitarnego wykonano, stosując zasady postępowania, które zostały ustalone w czasie klasyfikacji terenu badań wokół miasta Legionowo (tab. 11). Treść zdjęcia została podzielona na obiekty na podstawie jaskrawości pikseli kanału panchromatycznego oraz na podstawie danych uzyskanych w wyniku połączenia tego kanału z 2, 3 i 4 kanałem wielospektralnym. Przeprowadzona po segmentacji analiza wizualna wykazała

dużą zgodność przebiegu granic powstałych obiektów z kształtami form pokrycia terenu zobrazowanymi na zdjęciu.

Klasyfikacja obiektowa została wykonana z założeniem rozpoznania klas występujących w bazie danych CORINE CLC2000. W granicach arkusza mapy „Puławy” w bazie CLC2000 występuje 17 klas. Zastosowane metody klasyfikacji obiektowej pozwoliły na zdefiniowanie 13 klas odpowiadających klasom z bazy CLC2000, w tym 2 z nich rozpoznano z podziałem na podklasy, w sumie uzyskano 15 klas. Zrezygnowano z rozpoznania 3 klas występujących w bazie CLC2000. Pierwsza z nich, „miejskie tereny zielone”, nie została sklasyfikowana mimo rozpoznania jej w czasie klasyfikacji wykonanej dla terenu badań wokół Legionowa. Wynika to z faktu zastosowania w definicji tej klasy m.in. warunku graniczenia jej obiektów z obiektami rozpoznanyymi jako zabudowa. W przypadku Puław taka sytuacja nie wystąpiła, gdyż tereny, które mogłyby należeć do tej klasy, nie są otoczone wyłącznie zabudową i posiadają relatywnie długie granice również z innymi klasami. Dwie pozostałe klasy, „sady i plantacje” oraz „tereny komunikacyjne”, na obrazie satelitarnym o średniej rozdzielczości nie są jednoznacznie rozróżnialne od innych klas. W przypadku interpretacji wizualnej są one rozpoznawane głównie z zastosowaniem materiałów pomocniczych, którymi są najczęściej mapy topograficzne. Wszystkie nierozpoznane klasy występują na niewielkich powierzchniach. W klasyfikacji automatycznej nie wykonano też podziału wód na rzeki i zbiorniki wodne, utworzono tylko jedną klasę „wody”. Równocześnie klasy występujące w bazie CORINE: „zwałowiska i hałdy” oraz „grunty orne”, zostały rozpoznane z podziałem na dwie podklasy. W pierwszym przypadku rozpoznano oddzielnie miejsca składowania mokrych i suchych odpadów przemysłowych; klasy te nazwano odpowiednio „osadniki” i „tereny zdegradowane”. Natomiast „grunty orne” zostały rozpoznane z podziałem na „grunty orne drobnoblokowe” i „grunty orne wielkoblokowe”. Z kolei „grunty orne wielkoblokowe” zostały utworzone jako suma gruntów ornych bez pokrywy roślinnej i gruntów ornych z pokrywą roślinną. Zestawienie rozpoznanych klas przedstawione jest w tabeli 17.

Ze względu na różnice między oryginalnymi i sklasyfikowanymi danymi niektóre parametry zastosowane w rozpoznaniu klas na terenie badań wokół Legionowa musiały zostać zmodyfikowane. Nie dotyczyło to klasy „wody”, które zostały sklasyfikowane w podobny sposób, z zastosowaniem wartości progowych jaskrawości pikseli w 4 i 6 kanale spektralnym. Zmianie uległ natomiast sposób klasyfikacji „terenów piaszczystych”, rozpoznanych poprzednio wspólnie z klasą „place budowy”. Tym razem zostały one rozpoznane samodzielnie na podstawie wartości jaskrawości pikseli w drugim kanale spektralnym, z zastosowaniem dodatkowego warunku graniczenia tej klasy z obiektami sklasyfikowanymi jako „wody”. Postąpiono tak, gdyż na nowym zdjęciu nie występowały jednoznacznie zdefiniowane place budów.

Pozostałe klasy rozpoznano, podobnie jak w przypadku „Legionowa”, stosując standardową metodę najbliższego sąsiada oraz w niektórych przypadkach dodatkowe warunki. W celu określenia nowych parametrów metody STD.N.N., podobnie jak w czasie poprzedniej klasyfikacji, posłużono się funkcją Feature Space Optimization oprogramowania eCognition. Na jej podstawie określono 6 parametrów: wartości jaskrawości obiektów w kanałach 4, PAN i K4PAN oraz entropia GLCM obiektów w kanale 4, 7 i PAN. W porównaniu z parametrami zastosowanymi w czasie klasyfikacji oryginalnych danych satelitarnych (podrozdz. 4.3.2) zdecydowanie wzrosło znaczenie miar tekstury obiektów, co wynika ze sposobu wstępnego przetworzenia zdjęć, którego celem było zwiększenie stopnia szczegółowości interpretowanych obrazów.

W przypadku klasy związanej z zabudową (zabudowa i tereny przemysłowe) oraz terenów zdegradowanych występujących w pobliżu obiektów przemysłowych zastosowano odmienne parametry metody STD.N.N. oraz zmieniono wartość funkcji przynależności, zwiększając ją z 0,55 do 0,90. Postąpiono tak ze względu na występowanie w granicach Puław zabudowy w otoczeniu dużej ilości drzew, rozproszonego charakteru instalacji chemicznych na terenie Zakładów Azotowych oraz z powodu dużego podobieństwa spektralnego terenów zdegradowanych do niektórych obszarów o charakterze rolniczym. W celu prawidłowego rozpoznania tych trzech klas sklasyfikowano je oddzielnie, stosując następujące parametry metody STD.N.N.: wartości jaskrawości obiektów w kanałach 2, 4, 7 i PAN oraz entropię GLCM obiektów w kanale K3PAN. Dodatkowo, w klasyfikacji terenów zdegradowanych zastosowano warunek występowania tej klasy w pobliżu terenów przemysłowych.

Podobnie jak w przypadku klasyfikacji wykonanej na terenie wokół Legionowa zastosowano kryterium ZABUD1 w celu rozróżnienia zabudowy od terenów przemysłowych oraz na podstawie kryterium związanego z wartościami jaskrawości pikseli w kanale panchromatycznym wyłoniono klasę „lasy mieszane” z klas „lasy liściaste” i „lasy iglaste”.

Wynik klasyfikacji obiektowej, zgodnie z opracowanym algorytmem postępowania (rysunek 15), został poddany generalizacji. W przypadku wszystkich rozpoznanych klas zastosowano tym razem jednakową wielkość jednostki odniesienia, wynoszącą 4 ha, co jest równoważne powierzchni reprezentowanej przez 256 pikseli kanału panchromatycznego, przepróbkowanych do wielkości 12,5x12,5 m. Następnie, stosując funkcje wygładzające granice wydzieleni, utworzono wektorową bazę danych. Obraz bazy danych po generalizacji przedstawiony jest na rysunku 29. Dla porównania rysunek 30 przedstawia bazę CORINE CLC2000.

Obrazy baz CLC2000 i powstałej w wyniku zastosowania automatycznych algorytmów różnią się przede wszystkim stopniem szczegółowości przestrzennej będącej wynikiem zastosowania różnych jednostek odniesienia przestrzennego: 25 i 4 ha. W obu przypadkach dominującą formą są grunty

orne oraz widoczny jest prawie jednakowy układ powierzchni lasów liściastych, iglastych oraz mieszanych. Również podobnie zlokalizowane są łąki. Różnice można zauważyć przede wszystkim w przypadku terenów związanych z przemysłem i z zabudową w rejonie Zakładów Azotowych i Puław. Analiza obrazu satelitarnego wykazała, że stosując automatyczną klasyfikację, część obiektów reprezentujących te klasy nie zostało rozpoznane prawidłowo (mimo zastosowania „ostrych” kryteriów rozpoznania). Dlatego też podjęto decyzję o ponownej klasyfikacji tych klas metodą wizualną (wskazując ręcznie obiekty, które powinny reprezentować te klasy). Zmiany w klasyfikacji wykonano jedynie na podstawie zdjęcia satelitarnego, a następnie ponownie przeprowadzono generalizację i utworzono nową wektorową bazę danych (rysunek 31).

Ocena utworzonych automatycznie baz danych o pokryciu i użytkowaniu ziemi arkusza mapy M-34-20-D została wykonana poprzez porównanie powierzchni poszczególnych klas z informacjami zawartymi w bazie CLC2000. Uzyskane wyniki przedstawiono w tabeli 17. Podane są w niej nazwy klas, ich kody (zgodnie z nomenklaturą programu CORINE) oraz powierzchnie rozpoznanych klas. Wyniki uzyskane automatycznie podzielone są na dwie kolumny. Pierwsza (I) związana jest z klasyfikacją bez poprawy jej wyników metodą wizualną, natomiast druga (II) uwzględnia wizualną klasyfikację (poprawę) zabudowy i terenów przemysłowych.

Tabela 17. Porównanie powierzchni klas na arkuszu mapy M-34-20-D „Puławy” występujących w bazie danych CORINE CLC2000 oraz w bazie opracowanej automatycznie z zastosowaniem klasyfikacji obiektowej

klasy pokrycia i użytkowania ziemi			powierzchnia (ha)			zgodność powierzchni klas z CLC2000 (%)	
kod klasy	CLC2000	klasyfikacja obiektowa	CLC 2000	klasyfikacja obiektowa		I	II
				I ^{a)}	II ^{b)}		
112	zabudowa		720,4	475,3	650,9	66,0	90,3
121	tereny przemysłowe		455,3	113,0	323,8	24,8	71,1
122	tereny komunikacyjne		28,7	–	–	0,0	0,0
132	zwałowiska i hałdy	osadniki	283,4	26,7	33,8	97,5	93,3
		ter. zdegradowane		249,4	230,7		
141	miejskie tereny zielone		35,6	–	–	0,0	0,0
211	grunty orne	wielkoblokowe	14191,1	2593,5	2466,3	106,4	105,7
		drobnoblokowe		12500,3	12529,3		
222	sady i plantacje		78,8	–	–	0,0	0,0
231	łąki		1583,3	1645,1	1645,1	103,9	103,9
242	złożone systemy upraw i działek		3696,6	2096,8	1865,4	56,7	50,5
243	tereny z dużym udziałem roślinności naturalnej		1630,2	3825,8	3816,3	234,7	234,1
311	lasy liściaste		2723,7	2252,4	2252,5	82,7	82,7
312	lasy iglaste		3901,5	3656,3	3652,9	93,7	93,6
313	lasy mieszane		1596,1	2272,8	2238,8	142,4	140,3
324	lasy i roślinność krzewiasta w stanie zmian		960,0	86,9	86,9	9,1	9,1
324	tereny piaszczyste		26,7	46,7	46,7	175,1	175,1
511	rzeki	wody	943,6	1040,3	1 041,9	107,3	107,3
512	zbiorniki wodne		26,3				
suma			32881,4	32881,4	32881,4	–	–
suma klas 311, 312 i 313			8221,3	8181,5	8144,2	99,5	99,1
suma klas 242, 243 i 324			6286,8	6009,5	5768,6	95,6	91,7

^{a)} Wyniki uzyskane bez zastosowania dodatkowej klasyfikacji wizualnej

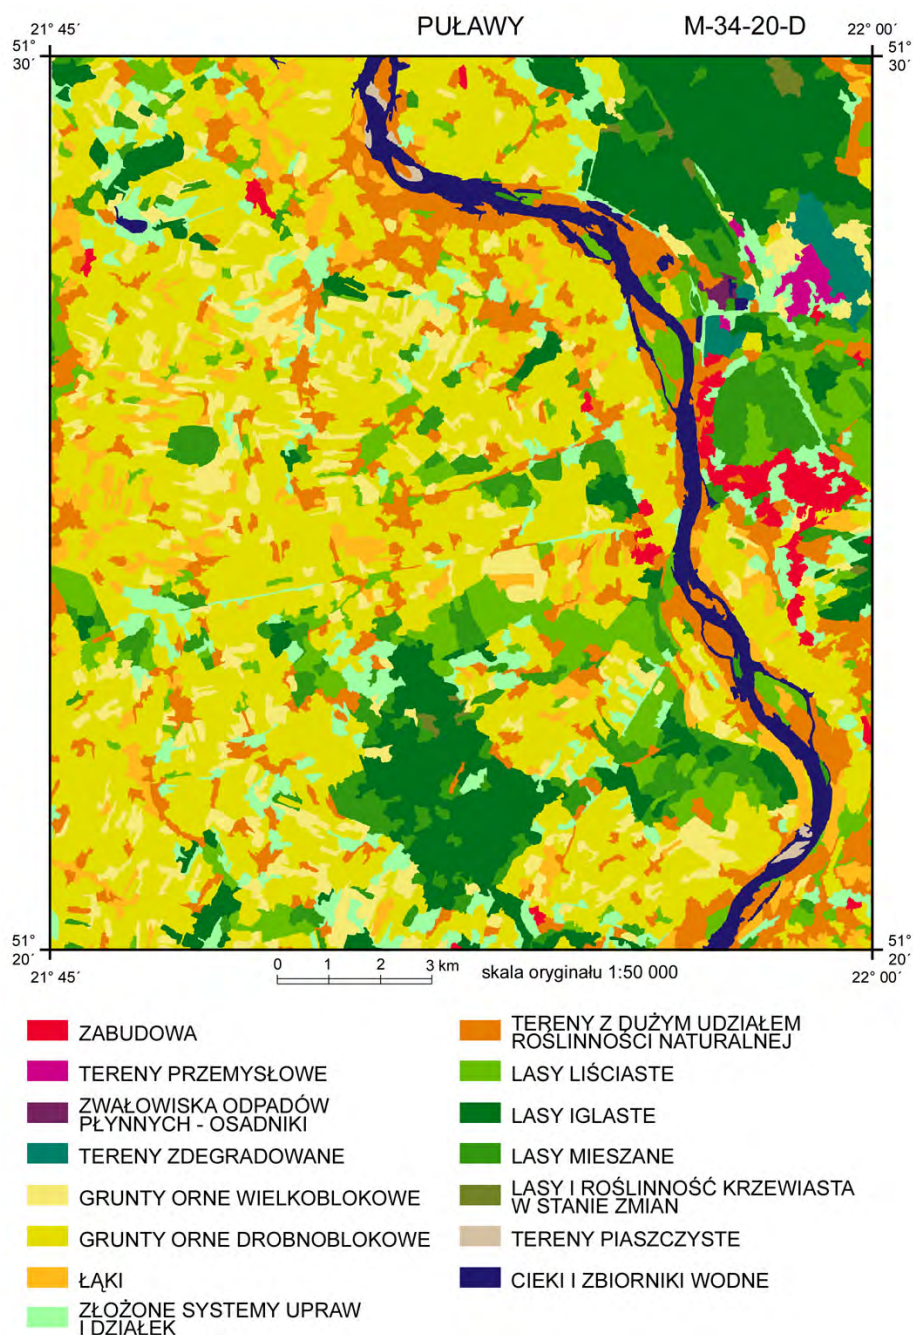
^{b)} Po klasyfikacji obiektowej wykonano dodatkową klasyfikację wizualną obiektów związanych z zabudową i terenami przemysłowymi

Najmniejsze różnice w powierzchniach klas (nieprzekraczające 10%) uzyskano dla gruntów ornych, łąk, lasów iglastych oraz wód. Stosunkowo zbliżone powierzchnie uzyskano również dla lasów liściastych. W przypadku klas „lasy mieszane”, „złożone systemy upraw i działek” i „tereny z dużym udziałem roślinności naturalnej” różnice w powierzchniach są większe. Należy jednak pamiętać, że są to klasy niejednorodne pod względem spektralnym, w związku z czym są one wyjątkowo podatne nie tylko na błędy klasyfikacyjne, ale również interpretacyjne. Na uwagę zasługuje klasa „lasy i roślinność krzewiasta w stanie zmian”, której jedynie 9,1% powierzchni zostało rozpoznanych automatycznie. Tak duże różnice w powierzchni tej klasy są wy-

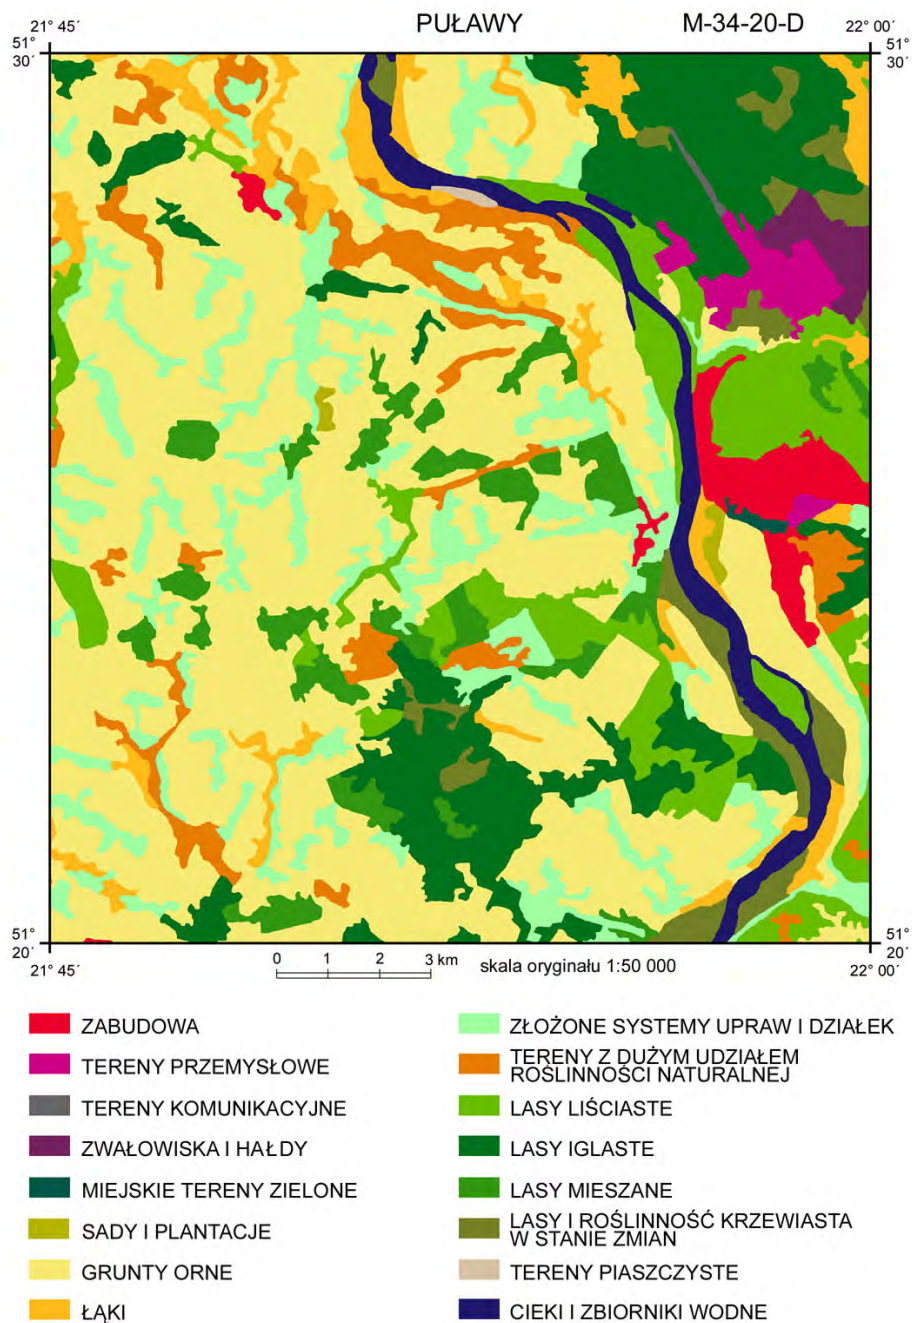
kiem rozpoznania w toku klasyfikacji obiektowej wyłącznie tzw. zmian występujących w granicach kompleksów leśnych. Nie rozpoznano roślinności krzewiastej w stanie zmian, która według bazy CLC2000 występuje głównie wzdłuż brzegów południowego odcinka Wisły; w tych miejscach klasa ta została sklasyfikowana jako „tereny z dużym udziałem roślinności naturalnej”, co równocześnie spowodowało wystąpienie „nadmiaru” tej klasy. W bazie danych utworzonej automatycznie występuje również stosunkowo duża liczba terenów piaszczystych – o 75% więcej w porównaniu z bazą CLC2000. Wynika to głównie z różnego stopnia szczegółowości przestrzennej porównywanych baz danych, gdyż wzdłuż brzegów Wisły występują głównie małe obiekty tej klasy (o powierzchni kilku hektarów). Obiekt o powierzchni ponad 25 ha może powstać przede wszystkim w wyniku generalizacji (połączenia) mniejszych wydzieleń, co miało miejsce w przypadku interpretacji wizualnej. Jak było do przewidzenia, dla zabudowy i terenów przemysłowych znacznie lepsze wyniki pod względem zajmowanej powierzchni związane są z poprawioną klasyfikacją (II). Zgodność ich powierzchni wynosi odpowiednio: 90% i 71%.

W tabeli 17 przedstawione jest dodatkowo porównanie połączonych powierzchni wybranych klas. Wykonano je dla klas lasów (liściaste, iglaste i mieszane) i dla połączonych klas: „złożone systemy upraw i działek”, „tereny z dużym udziałem roślinności naturalnej” oraz „lasy i roślinność krzewiasta w stanie zmian” (ostatnia z nich została sklasyfikowana głównie jako tereny z dużym udziałem roślinności naturalnej). W ocenie zgodności powierzchni połączonych klas został w pewnym stopniu zmniejszony efekt generalizacji bazy CLC2000 oraz efekt błędnego rozpoznania, który mógł wystąpić zarówno w toku klasyfikacji automatycznej, jak i podczas interpretacji wizualnej. W obu przypadkach uzyskano bardzo wysoką zgodność. Wyniosła ona ponad 99% dla lasów, natomiast w drugim przypadku dla klasyfikacji I i II uzyskano różne wyniki: 95% i 91%. Różnice te wynikają z ręcznej klasyfikacji obiektów zabudowy i terenów przemysłowych w miejscach, w których występowały klasy biorące udział w porównaniu zsumowanych powierzchni.

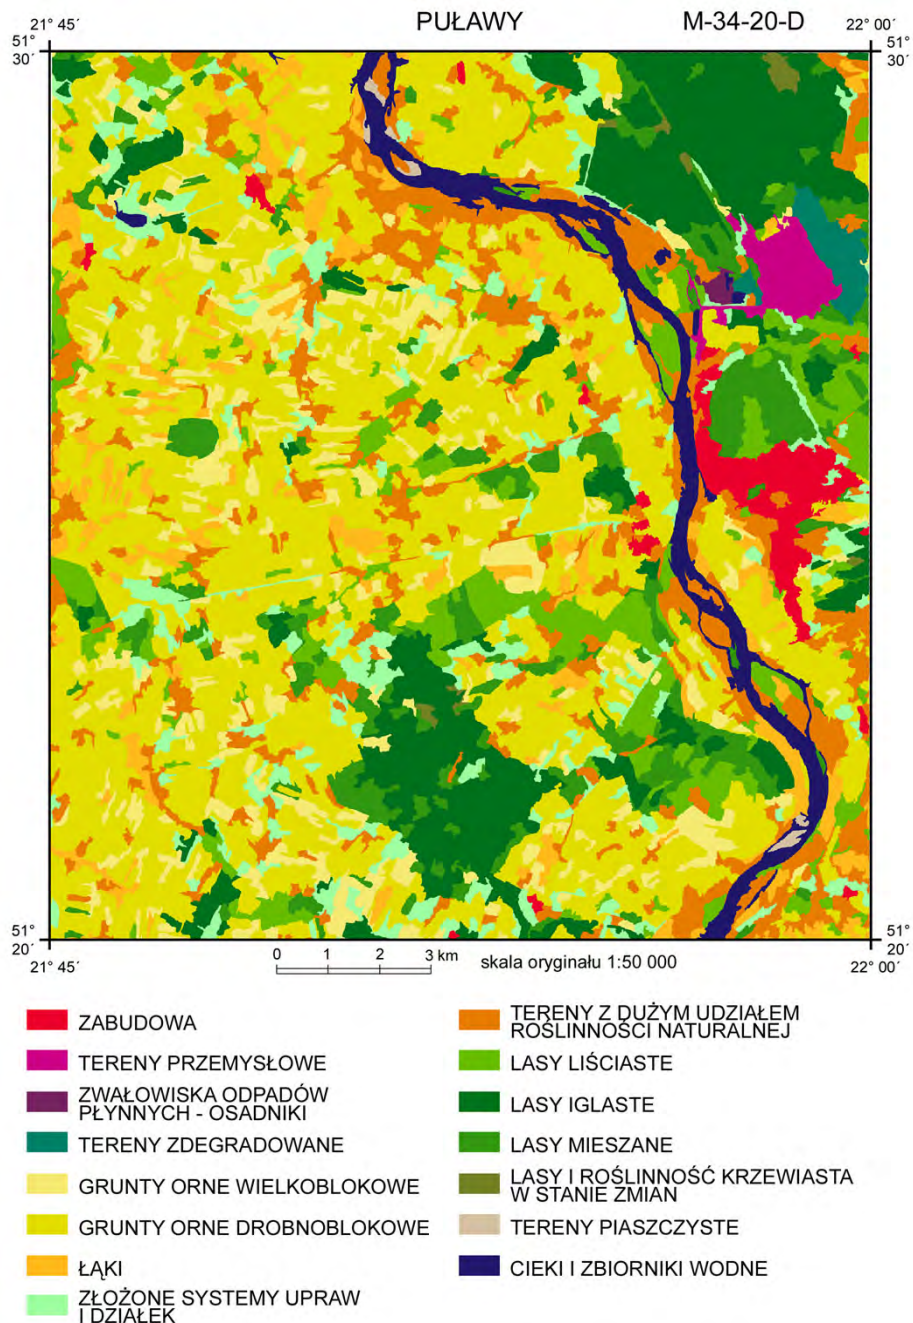
Na podstawie przeprowadzonych analiz powierzchni klas można uznać, że automatycznie utworzona baza danych o pokryciu i użytkowaniu ziemi jest porównywalna z bazą danych CORINE CLC2000 pod względem tematycznym, równocześnie charakteryzuje się ona dużo większym stopniem szczegółowości przestrzennej (prawie ośmiokrotnym). Wykonanie bazy danych o pokryciu i użytkowaniu ziemi na przykładzie arkusza mapy „Puławy” potwierdziło skuteczność zaproponowanego sposobu automatyzacji procesu tworzenia bazy danych.



Rys. 29. Obraz wektorowej bazy danych utworzonej automatycznie na podstawie klasyfikacji obiektowej



Rys. 30. Obraz bazy danych CORINE CLC2000



Rys. 31. Obraz wektorowej bazy danych utworzonej automatycznie na podstawie klasyfikacji obiektowej z zastosowaniem dodatkowej klasyfikacji wizualnej obiektów związanych z zabudową i terenami przemysłowymi

8. PODSUMOWANIE

- 1) Zaproponowana metoda opracowania baz danych o pokryciu i użytkowaniu ziemi na podstawie zdjęć satelitarnych z zastosowaniem klasyfikacji obiektowej pozwala na automatyzację procesu tworzenia bazy wektorowej. Powstała baza danych charakteryzuje się granicami wydziełów, których kształt zbliżony jest do granic uzyskiwanych w toku interpretacji wizualnej, oraz stopniem szczegółowości zdefiniowanym przez jednostkę odniesienia.
- 2) Poprawność przyjętych założeń została praktycznie sprawdzona na podstawie zdjęć satelitarnych zarejestrowanych skanerem ETM+. Wykonano klasyfikację obiektową oryginalnych danych satelitarnych oraz przetworzonych metodą splotu sześciennego dla celów interpretacji wizualnej. W obu przypadkach utworzono wektorowe bazy danych charakteryzujące się dużą liczbą rozpoznanych klas o ustalonym stopniu szczegółowości przestrzennej.
 - a) Klasyfikacja obiektowa zdjęcia satelitarnego ETM+ obrazującego teren badań wokół miasta Legionowo pozwoliła na rozpoznanie 18 klas pokrycia i użytkowania ziemi. Następnie opracowano wektorową bazę danych o stopniu szczegółowości przestrzennej wynoszącym 1 ha dla klas związanych z wodami i zabudową oraz 4 ha dla pozostałych klas. Poprawność utworzonej automatycznie bazy oceniono metodą interpretacji wizualnej, wyniosła ona 94,6%.
 - b) Te same dane satelitarne sklasyfikowano, stosując tradycyjne „pikselowe” metody klasyfikacji nadzorowanej i nienadzorowanej, które pozwoliły na rozpoznanie tylko 8 klas. Następnie obraz klasyfikacyjny został doprowadzony do stopnia szczegółowości przestrzennej klas obiektowych i porównany z bazą danych utworzoną na podstawie klasyfikacji obiektowej, która została sprawdzona metodą interpretacji wizualnej. Porównanie wykazało wyjątkowo małą zgodność wyników tradycyjnej klasyfikacji oraz małą ich przydatność w aspekcie tworzenia bazy danych o pokryciu i użytkowaniu ziemi.
 - c) Na podstawie zdjęcia satelitarnego ETM+, wstępnie przetworzonego z myślą o interpretacji wizualnej, opracowano bazę danych o pokryciu i użytkowaniu ziemi arkusza mapy M-34-20-D „Puławy”. Klasyfikację obiektową wykonano, mając na celu rozpoznanie klas występujących w bazie CORINE CLC90. Zastosowane metody klasyfikacji pozwoliły na rozpoznanie 13 klas (w tym 2 z podziałem na podklasy); nie rozpoznano klas, które w czasie interpretacji wizualnej są identyfikowane z zastosowaniem materiałów pomocniczych. Następnie utworzono wektorową bazę danych o rozdzielczości przestrzennej 4 ha. Uzyskane wyniki porównano z bazą danych CORINE CLC2000. Mimo dużej różnicy w rozdzielczości

przestrzennej obu baz (4 i 25 ha) stwierdzono wysoką zgodność wielkości powierzchni poszczególnych klas.

- 3) Segmentacja treści zdjęcia satelitarnego ETM+ została wykonana na podstawie kanału panchromatycznego oraz danych uzyskanych w wyniku połączenia kanału panchromatycznego z 2, 3 i 4 kanałem zakresu wielospektralnego. Do połączenia zdjęć zastosowano algorytm PanSharp. Przyjęty sposób postępowania pozwolił na uzyskanie dobrych wyników zarówno w przypadku segmentacji oryginalnych danych satelitarnych, jak i przetworzonych metodą splotu sześciennego.
- 4) W trakcie klasyfikacji obiektowej, poszczególne klasy pokrycia i użytkowania ziemi rozpoznano z zastosowaniem metody najbliższego sąsiada, funkcji parametrycznych oraz za pomocą relacji zachodzących między obiektami. W klasyfikacji danych przepróbkowanych do mniejszej wielkości piksela metodą splotu sześciennego zdecydowanie wzrosło znaczenie klasyfikatorów związanych z teksturą obiektów.
- 5) Opracowane kryterium ZABUD1 pozwala na efektywne rozróżnienie różnych typów zabudowy. Może ono być stosowane także w rozpoznaniu innych klas pokrycia terenu oraz mieć zastosowanie nie tylko w przypadku klasyfikacji zdjęć satelitarnych ETM+ (po modyfikacji formuły obliczeniowej).
- 6) Zaproponowana metoda postępowania może w istotny sposób przyspieszyć, wspomagać lub nawet zastąpić interpretację wizualną. Automatyczne algorytmy, w porównaniu z metodami tradycyjnymi, pozwalają na skrócenie czasu opracowania bazy danych o pokryciu i użytkowaniu ziemi o podobnym zakresie tematycznym jak w przypadku interpretacji wizualnej i równocześnie charakteryzującej się dużo większym stopniem szczegółowości przestrzennej.
- 7) W klasyfikacji obiektowej warunki standaryzacji rozpoznania klas spełniają przede wszystkim kryteria parametryczne (ustalone wartości progowe). Określenie ich, zależnie od typu i okresu rejestracji zdjęć satelitarnych, wydaje się być możliwe, wymaga jednak przeprowadzenia testów na wielu zestawach danych satelitarnych. Wykonanie takich prac jest niezbędne w celu całkowitej automatyzacji procesu klasyfikacji obiektowej.
- 8) Przedstawiona metoda opracowania wyników klasyfikacji obiektowej jest stosowana zgodnie ze ściśle określonymi zasadami postępowania, co zapewnia powtarzalność uzyskiwanych wyników.

Rozwój klasyfikacji obiektowej jest bezpośrednio związany z pojawieniem się na rynku oprogramowania eCognition firmy Definiens Imaging GmbH. Prezentowane opracowanie wykonano, posługując się wersją 3.0 oprogramowania eCognition Professional. Obecnie jest już dostępna wersja 5.0, która charakteryzuje się udoskonalonymi metodami segmentacji, klasyfikacji, analiz danych oraz narzędziami pozwalającymi na automatyczne wykonywanie serii wielu klasyfikacji. Bez wątpienia są to rozwiązania bardzo zaawansowane technologicznie, określające nowe standardy i kierunki klasyfikacji zdjęć satelitarnych oraz lotniczych. Nie jest to jednak jedyne narzędzie pozwalające na utworzenie i analizę obiektów. Dostępne są również mniej popularne oprogramowania (Meinel i Neubert, 2004), takie jak InfoPACK i SPRING, czy też oprogramowanie dedykowane tylko do wykonania segmentacji – Minimum Entropy Approach. Na uwagę zasługuje Feature Analyst, produkt firmy Visual Learning Systems pracujący w środowisku oprogramowania ArcGIS oraz Erdas Imagine. Można oczekiwać, że w najbliższym czasie również inne firmy specjalizujące się w profesjonalnych systemach przetwarzania obrazów i GIS zaproponują swoim użytkownikom funkcje klasyfikacji obiektowej.

Równoległe z rozwojem rozwiązań programistycznych, dostarczających nowych narzędzi analizy danych obrazowych, muszą być prowadzone prace, czego przykładem jest prezentowana monografia, których celem jest doskonalenie istniejących oraz opracowywanie nowych algorytmów postępowania. Dzięki nim możliwe będzie dostosowanie metod klasyfikacji obiektowej do specyfiki klasyfikowanych terenów. Dla polskich warunków użytkowania ziemi trudności klasyfikacji treści zdjęć satelitarnych o średniej rozdzielczości przestrzennej wynikają przede wszystkim z dużej bioróżnorodności oraz dużego rozdrobnienia form pokrycia terenu. Jednym z przykładów złożoności problematyki klasyfikacji treści zdjęć satelitarnych jest analiza terenów rolniczych. Klasyfikacja ta wymaga wprowadzenia podziału klasyfikowanych pól nie tylko w aspekcie występowania pokrywy roślinnej, lecz również ze względu na ich wielkość. W przypadku licznie występujących mozaikowych struktur upraw nie można wyodrębnić pojedynczych pól i należy je rozpoznawać jako jedną klasę (grunty orne małoblokowe). Podobna sytuacja ma miejsce w przypadku klasyfikacji rozproszonej zabudowy o charakterze wielkomiejskim i wiejskim. Istotnym zagadnieniem wymagającym uwzględnienia w procesie klasyfikacji obiektowej jest również sposób przygotowania zdjęć satelitarnych do klasyfikacji oraz opracowania jej wyników, na podstawie których powstaje końcowy produkt klasyfikacji w postaci bazy danych. Wykonana w toku zrelacjonowanych badań praca pozwoliła na sprecyzowanie zasad pozyskiwania i opracowywania informacji o pokryciu i użytkowaniu ziemi na podstawie zdjęć satelitarnych oraz na automatyzację wykonywanych procesów, dzięki czemu będzie możliwe uzyskiwanie bardziej wiarygodnych i równocześnie powtarzalnych wyników.

Obecnie w dziedzinie przetwarzania obrazów satelitarnych mamy z całą pewnością dekadę klasyfikacji obiektowej. Obiektowa technika analizy zdjęć satelitarnych powinna w najbliższym czasie zdominować tradycyjne „pikselowe” metody klasyfikacji oraz sukcesywnie zastępować interpretację wizualną. Umożliwi to zwiększenie częstotliwości automatycznego pozyskiwania aktualnych informacji o otaczającym nas środowisku, których źródłem są zdjęcia satelitarne.

LITERATURA

- [1] Baatz M., Banz U., Dehghani S., Heynen M., Holtje A., Hofmann P., Lingenfelder I., Mimler M., Sohlbach M., Weber M., Willhauck G., 2001. eCognition user guide. Definiens Imaging GmbH.
- [2] Baatz M., Schäpe A., 1999. Object-oriented and multi-scale image analysis in semantic networks. Proceedings of 2nd International Symposium: Operationalization of Remote Sensing, 16-20 Aug., ITC, Netherlands.
- [3] Baatz M., Schäpe A., 2000. Multiresolution segmentation – an optimization approach for high quality multi-scale image segmentation. *Angewandte Geographische Informationsverarbeitung XII, Beiträge zum AGIT – Symposium*, Salzburg.
- [4] Baranowski M., 2004. Baza danych ogólnogeograficznych. *Biuletyn Informacyjny Głównego Geodety Kraju*, nr 2, s. 3–5.
- [5] Baranowski M., Ciołkosz A., 1997. Opracowanie bazy danych pokrycia terenu Polski. *Prace Instytutu Geodezji i Kartografii*, t. XLIV, z. 95, s. 7–28.
- [6] Bartholome E., Belward A.S., 2005. GLC 2000: a new approach to global land cover mapping from Earth observation data. *International Journal of Remote Sensing*, Vol. 26, no. 9, pp. 1959–1977.
- [7] Bartholome E., Belward A.S., Achard F., Bartalev S., Carmona-Moreno C., Eva H., Fritz S., Gregoire J-M., Mayaux P., Stibig H-J., 2002. GLC 2000 Global land cover mapping for the year 2000, project status. European Commission, Joint Research Centre, EUR 20524 EN.
- [8] Benz U. C., 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 & Remote Sensing*, Vol. 54, pp. 239–258.
- [9] Białousz S., 2004. Pokrycie terenu jako jeden z elementów ułatwiających modelowanie pokrywy glebowej. Referat wygłoszony na seminarium „Realizacja projektu CORINE Land Cover 2000 i wykorzystanie

- baz danych CORINE Land Cover 1990 w Polsce”, zorganizowanym przez GIOŚ i IGiK w dniu 19 maja 2004 w Warszawie.
- [10] Białousz S., Osińska-Skotak K., Fijałkowska A., Pluto-Kossakowska J., Lady-Drużycka K., Różycki S., 2004, System Baz Danych Przestrzennych dla Województwa Mazowieckiego. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa, s. 174.
- [11] Bielecka, Ciołkosz, 1998. Powódź w dolinie Odry w świetle interpretacji zdjęć satelitarnych. *Prace Instytut Geodezji i Kartografii*, t. XLV, z. 97, s. 81–95.
- [12] Bielecka, Ciołkosz, 2000. Mapy użytkowania ziemi w skalach przeglądowych. *Polski Przegląd Kartograficzny*, t. 31, nr 2, s. 129–132.
- [13] Bielecka, Ciołkosz, 2004. Land cover structure in Poland and its changes in the last decade of 20th century. *Annals of Geomatics*, Vol. 2, nr 1, s. 82–88.
- [14] Blaschke T., Lang S., Lorup E., Strobl J., Zeil P., 2000. Object-oriented image processing in an integrated GIS/Remote Sensing environment and perspectives for environmental applications. *Environmental Information for Planning, Politics and the public*. Metropolis Verlag, Marburg, Vol. 2, pp. 555–570.
- [15] Blaschke T., 2005. Towards a framework for change detection based on image objects. In: Erasmí, S., Cyffka, B., Kappas, M. (Eds.) *Göttinger Geographische Abhandlungen*, Vol. 113, Göttingen, pp. 1–9.
- [16] Brooks C.N., Schaub D.L., Powell R.B., French N.H., Shuchman R., 2006. Multi-temporal and multi-platform agricultural land cover classification in Southeastern Michigan. *Proceedings of ASPRS 2006 Annual Conference*, Reno, Nevada; 1–5 May.
- [17] Burnett C., Blaschke T., 2003. A multi-scale segmentation / object relationship modelling methodology for landscape analysis. *Ecological Modelling*, Vol. 168, pp. 233–249.
- [18] Buttner G., Maucha G., Taracsak G., 2003. Inter-Change: a software for interpreting land cover changes. *Geoinformation for European-wide integration*, Benes (ed.). *Proceedings of the 22nd Symposium of European Association of Remote Sensing Laboratories*, Prague, Czech Republic, 4-6 June 2002, pp. 93–98.
- [19] Cabral A., de Vasconcelos M. J. P., Pereira J. M. C., Bartholome E., Mayaux P., 2003. Multi-temporal compositing approaches for SPOT-4 VEGETATION. *International Journal of Remote Sensing*, Vol. 24, No. 16, pp. 3343–3350.
- [20] Campbell J.B., 2002. *Introduction to remote sensing*. Third edition. Taylor & Francis.
- [21] Carper W.J., Lillesand M.T., Kiefer R.W., 1990. The use of intensity-hue-saturation transformations for merging SPOT panchromatic and

- multispectral image data. *Photogrammetric Engineering & Remote Sensing*, Vol. 56, No. 4, pp. 459–467.
- [22] Chavez P.S., Jr., Stuart C.S., Anderson J.A., 1991. Comparison of three different methods to merge multiresolution and multispectral data: Landsat TM and SPOT panchromatic. *Photogrammetric Engineering & Remote Sensing*, Vol. 57, No. 3, pp. 295–303.
- [23] Ciołkosz A., Miszański J., Ołędzki J.R., 1986. Interpretacja zdjęć lotniczych. Wyd. drugie poszerzone. PWN, Warszawa.
- [24] Ciołkosz A., Bielecka E., 2005. Pokrycie terenu w Polsce, baza danych CORINE Land Cover. Inspekcja Ochrony Środowiska. Biblioteka Monitoringu Środowiska.
- [25] Civco D.L., Hurd J.D., Wilson E.H., Song M., Zhang Z, 2002. A comparison of land use and land cover change detection methods. *Proceedings of 2002 ASPRS Annual Convention*, Washington, D.C. 12 p.
- [26] Cliche G., Bonn F., Teiller P., 1985. Integration of the SPOT panchromatic channel into its multispectral mode for image sharpness enhancement. *Photogrammetric Engineering & Remote Sensing*, Vol. 51, No. 3, pp. 311–316.
- [27] 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.
- [28] Congalton R.G., Mead R.A., 1983. A quantitative method to test for consistency and correctness in photointerpretation. *Photogrammetric Engineering & Remote Sensing*, Vol. 49, No. 1, pp. 69–74.
- [29] Cornet Y., Binard M., 2005. Which metrics to assess and compare the quality of image fusion products. *New Strategies for European Remote Sensing*, Oluic M. (ed), *Proceedings of the 24th Symposium of European Association of Remote Sensing Laboratories*, Croatia, 25–27 May 2004. pp. 385–392.
- [30] CORINE Land Cover. Technical guide. 1993.
- [31] Cross A.M., Mason D.C., Dury S.J., 1988. Segmentation of remotely-sensed images by split-and-merge process. *International Journal of Remote Sensing*, Vol. 9, No. 8, pp. 1329–1345.
- [32] Ehlers M., 2005. Beyond pansharpening: advances in data fusion for very high resolution remote sensing data. *Proceedings of the ISPRS Hannover workshop 2005 “High-resolution earth imaging for geospatial information”*.
- [33] Ehlers M., Michel U., Bohmann G., Tomowski D., 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.
- [34] ER Mapper, 2005. ER Mapper 7.01 User Guide. Earth Resource Mapping Ltd.

-
- [35] Ferenc J., Otahel J., Pravda J., 1995. Proposal for a methodology and nomenclature scale 1:50000 CORINE Land Cover Project. Final Report. Institute of Geography, Slovak Academy of Sciences, Bratislava.
- [36] Friedl M.A., McIver, D.K. Hodges J.C.F., Zhang X., Muchoney D., Strahler A.H., Woodcock C.E., Gopal S., Schmieder A., Coope A., Baccini A., Gao F., Schaaf C., 2002, Global land cover from MODIS: Algorithms and early results, *Remote Sensing of Environment*, Vol. 83, pp. 135–148.
- [37] Garguet-Duport B., Girel J., Chassery J.M., Pautou G., 1996. The use of Multiresolution analysis and wavelets transform for merging SPOT panchromatic and multispectral image data. *Photogrammetric Engineering & Remote Sensing*, Vol. 62 No. 9, pp. 1057–1066.
- [38] Giada S., De Groeve T., Ehrlich D., 2003. Information extraction from very high resolution satellite imagery over Lukole refugee camp, Tanzania. *International Journal of Remote Sensing*, Vol.24, No. 22, pp. 4251–4266.
- [39] Gillespie A.R., Kahle A.B., Walker R.E., 1986. Colour enhancement of highly correlated image, decorrelation and HIS contrast stretches. *Remote Sensing and Environment*, Vol. 20, pp. 209–235.
- [40] GMES, 2004. Global monitoring for environment and security, final report for the GMES initial period (2001–2003).
- [41] GMES – GEOLAND Project, 2005. Core Service Generic Land Cover. <http://www.gmes-geoland.info/CS/CSL/index.php>
- [42] GMES, 2006. GMES Fast Track Service Precursor (FTSP) on European land monitoring, FTSP technical implementation – discussion paper, ver 11.4, 23. 06. 2006.
- [43] Gomes A., Marçal A.R., 2003. Land Cover Revision Through Object Based Supervised Classification of ASTER Data. Proceedings of the ASPRS 2003 Annual Conference, Anchorage, USA. May 5–9.
- [44] Gonzalez R. C., Wintz P., 1977. Digital image processing. Addison-Wesley Publishing Company.
- [45] Gonzalez R.C., Woods R.E., 1993. Digital image processing. Addison-Wesley Publishing Company.
- [46] Greiwe A., Ehlers M., 2005. Combined analysis of hyperspectral and high resolution image data in an object oriented classification approach. Proceedings of the ISPRS WG VII/1 "Human Settlements and Impact Analysis" 3rd International Symposium Remote Sensing and Data Fusion Over Urban Areas (URBAN 2005) and 5th International Symposium Remote Sensing of Urban Areas (URS 2005). Tempe, AZ, USA. March 14–16.
- [47] Hall-Beyer M., 2005. GLCM texture: a tutorial. <http://www.fp.ucalgary.ca/mhallbey/tutorial.htm>

-
- [48] Halounova L., 2005. Textural classification of B & W aerial photos for the forest classification. *New Strategies for European Remote Sensing*, Oluic M. (ed), Proceedings of the 24th Symposium of European Association of Remote Sensing Laboratories, Dubrovnik, Croatia, 25–27 May 2004. pp. 247–252. Millpress, Rotterdam.
- [49] 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. pp. 610–621.
- [50] Haralick R.M., Shapiro L.G., 1985. Image Segmentation Techniques. *Computer vision, graphics and image processing*, Vol. 29, pp. 100–132.
- [51] Hofmann T., Puzicha J., Buhmann J.M., 1998. Unsupervised texture segmentation in a deterministic annealing framework. *IEEE Transactions on pattern analysis and machine intelligence*, Vol. 20, No. 8, pp. 803–818.
- [52] Hofmann P., 2001a. Detecting urban features from IKONOS data using an object-oriented approach. *Remote Sensing & Photogrammetry Society (Editor): Proceedings of the First Annual Conference of the Remote Sensing & Photogrammetry Society 12-14 September*, pp. 28–33.
- [53] Hofmann P., 2001b. Detecting buildings and roads from IKONOS data using additional elevation information. *GeoBIT/GIS 6/01*, pp. 28–33.
- [54] Hung C., 1993. Competitive learning networks for unsupervised training. *International Journal of Remote Sensing*, Vol. 14, No. 12, pp. 2411–2415.
- [55] Image Analyst user's guide, 2002. Z/I Imaging Corporation.
- [56] Iwaniak A., Krówczyńska M., Paluszyński W., 2004. Using neural networks for urban area classification in satellite images. *Remote Sensing in Transition*, Goossens R. (ed.). Proceedings of the 23rd Symposium of European Association of Remote Sensing Laboratories, Ghent, Belgium, 2-5 June 2003. pp. 109–113.
- [57] Ivits E., Koch B., 2003. Object-oriented remote sensing tools for biodiversity assessment: A European approach. *Geoinformation for European-wide integration*, Benes (ed.). Proceedings of the 22nd Symposium of European Association of Remote Sensing Laboratories, Prague, Czech Republic, 4-6 June 2002. pp. 465–472.
- [58] Jensen J.R., 1996. *Introductory digital image processing, a remote sensing perspective*. Second edition. Prentice Hall, Upper Saddle River, New Jersey.
- [59] de Jond S.M., van der Meer F.D., 2004. *Remote sensing image analysis: including the spatial domain*. Kluwer Academic Publishers.
- [60] Kellndorfer J.M., Ulaby F.T., 2003. Forest Biomass Inversion from SAR using Object Oriented Image Analysis Techniques. In: *Proceedings of IGARSS 2003 IEEE*, 21–25 July, Toulouse.

- [61] Kniivila M., 2004. Land Degradation and Land Use/Cover Data Sources. United Nations Statistics Division, Department of Economic and Social Affairs.
<http://unstats.un.org/unsd/ENVIRONMENT/envpdf/landdatafinal.pdf>
- [62] de Kok R., Buck A., Schneider T., Ammer U., 2000a. Analysis of image objects from VHR imagery for forest GIS updating in the Bavarian Alps. Proceedings of the ISPRS, Amsterdam, July 2000, Working Group III/5.
- [63] de Kok R., Buck A., Schneider T., Ammer U., Baatz M., 2000b. Data fusion with Landsat 7 imagery. STROBL, J. et al. (Hrsg), *Angewandte Geographische Informationsverarbeitung XII, Beiträge zum AGIT-Symposium Salzburg 1999*, Karlsruhe, Herbert Wichmann Verlag, pp. 90–97.
- [64] de Kok R., Wever T., Fockelmann R., 2003. Analysis of urban structure and development applying procedures for automatic mapping of large area data. Jürgens, Carstens, J. (Ed.): *Remote Sensing of Urban Areas*. Regensburg.
- [65] de Kok R., Koziół K., Wężyk P., 2005. Zastosowanie klasyfikacji obiektowej wysokorozdzielczych obrazów teledetekcyjnych oraz analiz przestrzennych GIS w kartowaniu drzewostanów. *Roczniki Geomatyki*, t. 3, z. 4, s. 99–108.
- [66] Kressler, F.P., Steinnocher K., Franzen M., 2005. Object-Oriented Classification of Orthophotos to support update of Spatial Databases. Proceedings of the IGARSS 2005 Symposium. Seoul, Korea. July 25–29, 2005.
- [67] Lewiński St., 2000. The satellite maps of Poland elaborated on the basis of Landsat MSS, TM and IRS-1C images. Proceedings of 28 th International Symposium on Remote Sensing of Environment, Cape Town, RPA, 27–30 March.
- [68] Lewiński St., 2001. Zastosowanie transformacji RGB->HIS w przetwarzaniu zdjęć satelitarnych. *Teledetekcja Środowiska*, nr 32, s. 138–142.
- [69] Lewiński St., B. Zagajewski B., 2002. The map of the Narew River National Park on the scale of 1:25000 elaborated on the basis of the merger of the satellite and aerial imagery. *Miscellanea Geographica Vol 10*, pp. 307–318.
- [70] Lewiński St., Zaremski K., 2004. Examples of object-oriented classification performed on high-resolution satellite images. *Miscellanea Geographica*, Vol. 11, pp. 349–358.
- [71] Lewiński St., Poławski Z.F., 2004. Interpretation of LISS-III images obtained by fusion with panchromatic data. *Remote Sensing in Transition*, Goossens R. (ed.). Proceedings of the 23rd Symposium of European Association of Remote Sensing Laboratories, Ghent, Belgium, 2–5 June 2003. pp. 97–101.

-
- [72] Lewiński St., 2005. Klasyfikacja obiektowa narzędziem wspomagającym process interpretacji zdjęć satelitarnych. *Polskie Towarzystwo Informatyki Przestrzennej, Roczniki Geomatyki*, t. 3, z. 2, s. 97–106.
- [73] Lewiński St., Poławski Z.F., 2005. The comparison of interpretation possibility of RGB composite of LISS-III and ETM+ scanner. *New Strategies for European Remote Sensing*, Oluic M. (ed), Proceedings of the 24th ERSeL Symposium, Dubrovnik, Croatia, 25-27 May 2004. pp. 327–333.
- [74] Lewiński St., 2006. Land use classification of ASTER image – Legionowo test site. *Global Developments in Environmental Earth Observation from Space*, Marçal (ed). Proceedings of the 25th Symposium of the European Association of Remote Sensing Laboratories, Porto, Portugal, 6-9 June 2005. pp. 441–447.
- [75] Lillesand M.T., Kiefer R.W., Chipman J.W., 2004. *Remote sensing and image interpretation*, fifth edition. Wiley.
- [76] Liu Z.J., Wang J., Liu W.P., 2005: Building Extraction from High Resolution Imagery based on Multi-scale Object Oriented Classification and Probabilistic Hough Transform. Proceedings of the IGARSS 2005 Symposium. Seoul, Korea. July 25–29.
- [77] Loveland T. R., Zhu Z., Ohlen D. O., Brown J.F., Reed B. C., Yang L., 1999. An analysis of the IGBP global land-cover characterization process. *Photogrammetric Engineering & remote Sensing*, Vol. 65, No. 9, pp. 1021–1032.
- [78] Loveland T. R., Reed B. C., Brown J.F., Ohlen D. O., Zhu Z., Yang L., Merchant J. W., 2000. Development of a global land cover characteristics database and IGBP DISCover from 1 km AVHRR data. *International Journal of Remote Sensing*, Vol. 21, No. 6, pp. 1303–1330.
- [79] Meinel G., Neubert M., 2004. A comparison of segmentation programs for high resolution remote sensing data. Proceedings of ASPRS 2004 Annual Conference, Istanbul, Turkey. 19–23 July.
- [80] Mitri G.H., Gitas I.Z., 2002. The development of an object-oriented classification model for operational burned area mapping on the Mediterranean island of Thasos using Landsat TM images. *Forest Fire Research & Wildland Fire Safety*, Vieges (ed). Proceedings of the IV International Conference on Forest Fire Research, Luso – Coimbra, Portugal, 18–23 November, 2002.
- [81] Mücher C. A., Steinnocher K. T., Kressler F. P. Heunks C., 2000. Land cover characterization and change detection for environmental monitoring of Pan-Europe. *International Journal of Remote Sensing*, Vol. 21, No. 6, pp. 1159–1181.
- [82] Naumann S., Siegmund A., 2006. Modelling of settlements-dynamics by object-oriented image and change detection analysis on Tenerife. *Global Developments in Environmental Earth Observation from Space*,

- Marçal (ed). Proceedings of the 25th Symposium of the European Association of Remote Sensing Laboratories, Porto, Portugal, 6–9 June 2005. pp. 241–249.
- [83] Neubert M., 2001. Segment-based analysis of high resolution satellite and laser scanning data. In: Hilty, L. M., Gilgen, P. W. (Eds.): Sustainability in the Information Society. Proceedings of the 15th International Symposium Informatics for Environmental Protection, Zurich, October 10-12, 2001. Marburg: pp. 379–386.
- [84] Nikolakopoulos K. G., 2004a. Comparative study of fusing ETM data with five different techniques for the broader area of Pyrgos, Greece. Optics in Atmospheric Propagation and Adaptive Systems VI. Edited by Gonglewski J. D., Stein K.. Proceedings of the SPIE, Vol. 5238, pp. 84–95.
- [85] Nikolakopoulos K. G., 2004b. Pansharp vs. wavelet vs. PCA fusion technique for use with Landsat ETM panchromatic and multispectral data. Optics in Atmospheric Propagation and Adaptive Systems VII. Edited by Gonglewski J. D., Stein K.. Proceedings of the SPIE, Vol. 5573, pp. 30–40.
- [86] NLC2000 Management Committee, 2005. South African National Land-Cover 2000 Database Project. Raster Map. Pretoria. CSIR Environmentek/ARC Institute for Soil, Climate and Water.
- [87] Nunes de Lima M. V., 2005. CORINE Land Cover updating for the year 2000. IMAGE2000 and CLC2000, products and methods. JRC–IES.
- [88] Ołędzki J.R., 2001. Regiony fotomorficzne Polski. Klub Teledetekcji Środowiska Polskiego Towarzystwa Geograficznego, Warszawa.
- [89] 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.
- [90] Pirog S., 2004. Możliwości wykorzystania bazy CORINE na potrzeby zarządzania regionem na przykładzie województwa małopolskiego. Referat wygłoszony na seminarium „Realizacja projektu CORINE Land Cover 2000 i wykorzystanie baz danych CORINE Land Cover 1990 w Polsce”, zorganizowanym przez GIOŚ i IGiK w dniu 19 maja 2004 w Warszawie.
- [91] Pohl C., Van Gederen J.L., 1998. Multisensor image fusion in remote sensing: concepts, methods and applications. International Journal of Remote sensing, Vol. 19, pp. 823–854.
- [92] Ray S.S., 2004. Merging of IRS LISS III and PAN data – evaluation of various methods for a predominantly agricultural area. International Journal of Remote Sensing, Vol. 25, No. 13, pp. 2657–2664.

-
- [93] Rego F.L., Koch B., 2003. Automatic classification of land cover with high resolution data of the Rio de Janeiro city Brazil comparison between pixel and object classification. Carstens, J. (Ed.): Remote Sensing of Urban Areas 2003, pp. 153–157.
- [94] Richards J.A., Xiuping J., 1999. Remote Sensing Digital Image Analysis, an introduction, third, revised and enlarged edition. Springer.
- [95] Richter R., 2006. ATCOR-2/3 user guide, ver 6.2. DLR-German Aerospace Center. http://www.rese.ch/pdf/atcor23_manual.pdf
- [96] Rossner G., Bock M., 2005. The aptness of landcover classifications for regional environmental planning: new orientation through objects?. New Strategies for European Remote Sensing, Oluic M. (ed), Proceedings of the 24th Symposium of European Association of Remote Sensing Laboratories, Dubrovnik, Croatia, 25-27 May 2004. pp. 663–670.
- [97] Sabins F. F., 1978. Remote sensing, principles and interpretation. W. H. Freeman and Company, San Francisco.
- [98] Schneider W., Steinwendner J., 1999. Landcover mapping by interrelated segmentation and classification of satellite images. International Archives of Photogrammetry and Remote Sensing (IAPRS), Vol. 32, part 7-4-3 W6.
- [99] Syed S., Dare P., Jones S., 2005. Automatic classification of land cover features with high resolution imagery and lidar data: an objectoriented approach. Proceedings of SSC2005 Spatial Intelligence, Innovation and Praxis: The national biennial Conference of the Spatial Sciences Institute, September, 2005. Melbourne: Spatial Sciences Institute. pp. 512-522.
- [100] System baz danych przestrzennych dla województwa mazowieckiego, 2004. Oficyna Wydawnicza Politechniki Warszawskiej.
- [101] 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. 10–14 November, 2003. Honolulu, Hawaii.
- [102] Tender Specifications, 2007. GMES fast track service on land monitoring, high resolution core land cover data for built-up areas, including degree of soil sealing, 2006. EEA/IDS/07/001.
- [103] Thomas C., Wald L., 2005. Assessment of the quality of fused products. New strategies for European remote sensing. New Strategies for European Remote Sensing, Oluic M. (ed), Proceedings of the 24th Symposium of European Association of Remote Sensing Laboratories, Dubrovnik, Croatia, 25-27 May 2004. pp. 317–325.
- [104] Tiede D., Heurich M., Blaschke T., 2004. Object-based semi automatic mapping of forest stands with Laser scanner and Multi-spectral data. In-

- ternational Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. XXXVI-8W2, Freiburg, pp. 328–333.
- [105] Tomlin C.D., 1990. Geographic Information Systems and cartographic modeling. Prentice Hall, Englewood Cliffs, N.J. 07632.
- [106] Tso B., Mather P.M., 2001. Classification Methods for Remotely Sensed Data. Taylor & Francis, New York.
- [107] Wald L., Ranchin T., Mangolini M., 1997. Fusion of satellite images of different spatial resolution: assessing the quality of resulting images. Photogrammetric Engineering & Remote Sensing, Vol. 63, No. 6, pp. 691–699.
- [108] Wald L., 2002. Data fusion, definitions and architectures, fusion of images of different spatial resolution. Ecole des Mines de Paris.
- [109] Wężyk P., de Kok R., Zajaczkowski G., 2004. The role of statistical and structural texture analysis in VHR image analysis for forest applications - A case study on Quickbird data in Niepolomice Forest. Strobl, J., Blaschke T. & Griesebner, G. (Hrsg.): Angewandte Geoinformatik 2004. Beiträge zum 16. AGIT-Symposium Salzburg 2004, H. Wichmann Verlag, Heidelberg, s. 770–775.
- [110] Wężyk P., Bednarczyk P., 2005. Testowanie metod i algorytmów klasyfikacji wysokorozdzielczych zobrazowań satelitarnych Puszczy Niepolomickiej. Roczniki Geomatyki, t. 3, z. 2, s. 163–172.
- [111] Wężyk P., de Kok R., Koziół K., 2006. Application of the object based image analysis of the VHR satellite images in the land-use classification. Polskie Towarzystwo Informatyki Przestrzennej, Roczniki Geomatyki, t. 4, z. 3, s. 227–238.
- [112] 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. pp. 1225–1231.
- [113] Vrabel J., 1996. Multispectral Imagery band sharpening study. Photogrammetric Engineering & Remote Sensing, Vol. 62, No. 9, pp. 1075–1083.
- [114] Zhou J., Civco D.L., Silander J.A., 1998. A wavelet transform method to merge Landsat TM and SPOT panchromatic data. International Journal of Remote Sensing, Vol. 19, No. 4, pp. 743–757.
- [115] Zhan, X., Sohlberg, R., Townshend, J.R.G., DiMiceli, C.M., Carroll, M.L., Eastman, J.C., Hansen, M.C., Defries, R.S. 2002, Detection of land cover changes using MODIS 250 meter data. Remote Sensing of Environment, Vol. 83, No. 1, pp. 336–350.

- [116] 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.
- [117] Zhang Y., 2002a. 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.
- [118] Zhang Y., 2002b. A new automatic approach for effectively fusing Landsat 7 as well as IKONOS images. *Proceedings of IEEE/IGARSS 2002*, June 24–28, Toronto, Canada.
- [119] Zhang Y., 2004. Understanding image fusion. *Photogrammetric Engineering & Remote Sensing*, Vol 70, No. 6, pp. 657–661.
- [120] Zhang Y., Maxwell T., 2006. A fuzzy logic approach to supervised segmentation for object-oriented classification. *Proceedings of ASPRS 2006 Annual Conference*, Reno, Nevada, 1–5 May.

STANISŁAW LEWIŃSKI

**OBJECT-ORIENTED CLASSIFICATION OF SATELLITE IMAGES
AS A METHOD FOR DERIVING INFORMATION
ON LAND COVER AND LAND USE**

Summary

Increase of application of satellite images for environmental monitoring can be observed recently. This is particularly evident while analyzing tasks undertaken within European GMES initiative, which assumes collection of information on land cover and land use on the basis of satellite images more frequently and with higher level of spatial detail. In order to fulfill these tasks new methods of creating spatial databases should be commonly implemented, with the aim to replace conventional method of visual interpretation.

The presented work includes proposal of methodology for creating land cover/land use database on the basis of object-oriented classification of medium-resolution satellite images. The proposed methods enable to create vector database automatically, with defined minimum mapping unit and with class boundaries similar to those obtained with the use of conventional methods of visual interpretation.

Object-oriented classification of Landsat ETM+ satellite image was done for the study area of 423 km², comprising city of Legionowo. The results of classification were next processed with the use of specially designed algo-

rithm. The whole approach consists of 8 stages: preparation of satellite data for classification, segmentation, object-oriented classification, generalization of classification results, preparation of vector database, smoothing of class boundaries, verification of classification, preparation of final database.

In the phase of preparation of Landsat ETM+ satellite image for classification multispectral and panchromatic data were fused, applying PANSHARP algorithm. Segmentation of image content was done on the basis of panchromatic channel and data obtained after fusing. In the course of object-oriented classification various classification methods were applied, including self-prepared ZABUD1 criterion, which was used for discriminating built-up land classes. Generalization of classification was done, using minimum mapping unit of 1 ha for built-up land and 4 ha for the remaining classes. It caused changes reaching only 1.1 % of the study area. Next raster classified image was converted to vector one, forming vektor data base, and smoothing of class boundaries was performed to make them resembling map obtained as a result of visual interpretation. Vector database was next verified by visual interpretation; in the course of this process interpreter could change class codes and location of class boundaries. In the last stage of the work final database was prepared, which included changes entered in verification process. As a result of the applied object-oriented classification and further processing of classification image the database, comprising 18 land cover/land use classes was created; its accuracy was assessed as reaching 94 %.

In order to make comparison of the methods, land cover/land use classification was done, using conventional classification approach. So-called hybrid method was used, which combines supervised classification and next unsupervised approach for non-classified pixels. Pixel-based classification allowed to recognize only 8 classes. The resultant image was generalized using the same rules as in case of object-oriented classification; this process caused changes in classification image reaching over 26 % of the study area. Next results of classification were compared with database obtained in the course of object-oriented classification, which served as a reference material. Low consistency of both classifications was achieved – 72 % and 61 %, depending on the applied method of comparison.

In order to confirm the applied assumptions and approach for object-oriented classification, the action was done to prepare land cover/land use database for a new region. Study area covering sheet of topographic map at a scale of 1:50000, called “Pulawy” (M-34-20-D sheet designation), was selected for this purpose. Landsat ETM+ image, used previously at IGiK for preparing CORINE CLC2000 database, was utilized for this work. The satellite data were not original, but already pre-processed within CORINE project. This pre-processing included image rectification, in which cubic convolution resampling method was applied, as well as change of pixel size was done (for multispectral data from 30 m to 25 m, for panchromatic data from 15 m to 12.5 m). Such an approach was aimed at obtaining colour composites with

higher level of detail, to be used later for visual interpretation. Application of object-oriented classification enabled to recognize 15 land cover/land use classes. Automatically prepared vector database was compared with CORINE CLC2000 database. Despite big difference in spatial resolution of two compared databases (4 ha and 25 ha, respectively) high consistency of areas for particular classes was achieved.

The proposed approach, aimed at automatic preparation of land cover/land use databases, can significantly support, or even replace visual interpretation. It allows to prepare database with similar information content as in case of visual interpretation in a shorter time, giving much more detail.

The presented method of preparing results of object-oriented classification is applied according to the strictly defined rules; it assures repeatability of the results.

Translation: Zbigniew Bochenek