

Klasyfikacja drzewostanów na obrazie hiperspektralnym Hyperion (EO-1)

Forest Classification Using The Hyperspectral Scanner Hyperion Image (EO-1)

Maciej BARTOLD

The hyperspectral images have been a valuable source of information, as well as helpful in recognizing forest stands on examined territories. People improve the techniques, digital tools which use the the hyperspectral image abilities. In recent years the studies have been created, which talk about examining the usefulness of these images. This is a component of one of the steps of these researches, which are researched in the world, including Poland.

The author's goal was to conduct a classification based on the scanner Hyperion image, as well as examining the usefulness of this source in recognizing forest stands on particular area. Spectral Angle Mapper was used to researches – a specific tool, which classifies hyperspectral images.

Overcoming difficulties with the inability to perform on atmospheric correction and selecting the channels, the author was successful in using this image to perform the examination. The original image was divided spectral into two ones. As the effect, each picture was classified separately. The first one consisted of 47 channels in range of the electromagnetic spectrum from 457 to 925 nm. The second image consisted of 74 channels in range of spectrum 426–447 nm and 932–1780 nm. The channel selection was dictated by the technical conditions and the usefulness of the Near- nad Mid-Infrared.

Used materials and methods allowed to recognize dominating forest stands with grouping them by kind and age. The results were created with the reliability of 74% for the first image and 91% for the second image.

More pattern data used in classifying was received from the first image. It would seem that the valuable pattern data to classify, the better recognized forest stands by the program.

Nevertheless, it was the amount and quality of informations (channels) in both images that decided of the final effect. Based on the classification results it is clear that infrared channels are the best material to recognize forest stands.

An important chapter of this study was the selection of the right classification method. The Spectral Angle Mapper was chosen. This method based on spectral profiles comparing and it worked very well in the researches. An important element of this method was the classification parameters choice, which greatly influenced the received results. And that's why data patterns choice, classification settings were up to the user and it was the deciding factor on received results.

The image was registered by the Hyperion scanner on 25 June, during summer, time of the years, when forest classifying based on aerial photos and satellite images is most difficult. In case of hypespectral images is possible to recognize forest stands by kind and age a whole year. When using the spectral properties of the single objects, the classification program shows different forms of land cover.

The results of these tests may be a valuable material to actualize the condition of the trees for the forest inspectorate. An additional advantage of the hyperspectral images is actuality of ones and a fast classification process. In this case, the results will illustrate only the general condition of the forests, in view of the 30 m spatial resolution image.

To summarize, the Hyperion scanner image and classification Spectral Angle Mapper based on that, confirmed to be useful in recognizing forest stands. They can be serve as a very good examples to forest areas researches and be helpful in making forest maps.

Wstęp

Techniki satelitarne, szeroko stosowane w łączności, obserwacji Ziemi i nawigacji, są obecnie jednym z najintensywniej rozwijających się sektorów nauki i gospodarki. Satelity służące obserwacji globalnej znajdują obecnie zastosowania w wielu dziedzinach naukowych: geodezji i gospodarce przestrzennej, geologii, rolnictwie, leśnictwie, hydrologii i meteorologii.

Postępujący rozwój technologiczny prowadzi do zwiększania dokładności zobrazowań satelitarnych oraz bogactwa uzyskiwanych informacji. Satelity dostarczają obrazy, których rozdzielczość przestrzenna schodzi poniżej 1 metra. Na ich podstawie można dokonać m. in. analiz na temat zagrożeń przyrodniczych oraz prognozowania upraw i roślin. Obecnie tworzy się trójwymiarowe modele terenu a także ocenia dynamikę rozwoju poszczególnych zjawisk geograficznych.

Przeznaczenie obrazów teledetekcyjnych jest bardzo zróżnicowane. Wykonuje się na ich podstawie, na przykład, mapy pokrycia terenu dla celów planowania przestrzennego. Dzięki powtarzalności uzyskiwania obrazów tego samego obszaru monitoruje się środowisko i jego zagrożenia. Ocenia się skutki klęsk żywiołowych, prognozuje uprawy i wzrost roślin. Istnieją satelity meteorologiczne, które służą specjalnie monitorowaniu zjawisk atmosferycznych i obserwacji globalnych zmian klimatu.

Przykładów zastosowań systemów satelitarnych jest wiele i ich liczba stale się zwiększa. Obecnie, już nie tylko wojsko czy instytucje publiczne sięgają po materiały, ale także liczne firmy czy osoby prywatne coraz

chętniej korzystają z pomocy zobrazowań satelitarnych. Ich wzrost popularności najlepiej przedstawia zjawisko wykorzystania ich w aplikacjach internetowych (GoogleEarth, Zumi), które bazują na zobrazowaniach satelitów wysokorozdzielczych.

Cel i przedmiot badań

Odkąd pojawiły się pierwsze obrazy satelitarne, lasy są stałym punktem obserwacji badań. Prowadzi się ciągle monitoring lasów. Wraz z postępem technologicznym obrazów teledetekcyjnych potrafiąo bardziej szczegółowo analizować drzewostany i wydzielić drzewostany wg różnych klas. Nowoczesne zobrazowania hiperspektralne są również skutecznym narzędziem do monitorowania lasów. Niniejsza praca jest kontynuacją badań obszarów leśnych z wykorzystaniem takich zobrazowań.


Celem badań jest ocena przydatności obrazu hiperspektralnego skanera Hyperion (umieszczonego na satelicie EO-1) do rozpoznania drzewostanów Poniżnia. Przeprowadzono klasyfikację obszarów leśnych Poniżnia metodą SAM (*Spectral Angle Mapper*), wykorzystującą właściwości odbicia spektralnego drzew. W efekcie uzyskano mapy cyfrowe, na których wydzielono różne drzewostany.

Badaniami objęto obszar położony między Chęcina i Jędrzejowem, przedstawiony na obrazie wykonanym skanerem Hyperion (Ryc. 1).

Poglądy na wyróżnianie drzewostanów

Wyznaczenie klas drzewostanów metodami teledetekcyjnymi zawsze stanowiło duży problem badawczy. Różnice w definiowaniu obszarów leśnych przyczyniają się do trudności klasyfikowania drzewostanów na podstawie obrazów teledetekcyjnych.

Od początku rozwoju badań nad zastosowaniem interpretacji obrazów teledetekcyjnych napotymano problemy w opracowaniu liczby i znaczenia klas. W artykule *Klasyfikacja treści leśnej zdjęć satelitarnych* E. Wiśniewska i T. Zawila-Niedźwiecki (1998) omawiają metodyczną ewolucję podejścia do teledetekcyjnej interpretacji lasów w ciągu ostatnich 30-stu lat. Autorzy pokazali zmiany w klasyfikowaniu obszarów leśnych wraz z postępem uzyskania coraz dokładniejszych zdjęć satelitarnych. Zestawili klasy leśne, opracowane w ramach dwóch projektów europejskich. W międzynarodowym projekcie CORINE Land Cover tereny leśne zakwalifikowano do kilku kategorii użytkowania ziemi – lasów i ekosystemów seminaturalnych (3): lasów (3.1.), zespołów roślinności drzewiastej i krzewiastej (3.2.)



Ryc. 1 Mapa sytuacyjna – zasięg analizowanego obrazu uzyskanego ze skanera Hyperion 25 czerwca 2006. Według: mapa.szukacz.pl

Fig. 1 Situation map – The reach of analyzed scanner Hyperion image (registered 25 June 2006).

i terenów otwartych, pozbawionych roślinności lub o rzadkim pokryciu roślinnym (3.3.). W obrębie każdego podzespołu wydzielono kilka dodatkowo mniejszych klas (3.1.1. lasy liściaste, 3.1.2., lasy iglaste i 3.1.3. lasy mieszane). Z kolei w projekcie monitorowania lasów Europy (FMERS – *Forest Monitoring in Europe by Remote Sensing*) wydzielono cztery klasy lasów i cztery klasy zadrzewień. Dodatkowo do każdej z klas lasów przyporządkowano jedną z siedmiu klas opisujących skład gatunkowy. Podział ten oparto o nomenklaturę stosowaną do oceny zasobów leśnych świata (FRA-2000).

Klasyfikacja lasów na zdjęciach lotniczych i satelitarnych

W Polsce przez długi czas zdjęcia lotnicze nie odgrywały istotnej roli w badaniach dotyczących lasów. Przyczyniły się do tego między innymi brak dostępu do sprzętu fotogrametrycznego, koszty wykonywania zdjęć lotniczych i brak specjalistów. Początkowo do analizy drzewostanów wykorzystywano technikę polegającą na obrysowywaniu konturów obszarów leśnych, charakteryzujących się podobnym fototonem i strukturą obrazu. W następnych latach potrafiło już na podstawie modelu stereoskopowego określić zwarcie, stopień zmieszania gatunkowego, wysokość drzew a także wyznaczyć obszary drzewostanów zamierających, zaatakowanych przez różne szkodniki (Mozgawa i in., 2001).

Jak zauważono, B. Królak (2006) wykonując klasyfikację obszarów leśnych, wywnioskował niemożność wykorzystania teledetekcji w przypadku młodych drzew o silnym zwarcie. Zaznaczono, że teledetekcja jest użyteczna jedynie dla dojrzałych drzewostanów, których luźne zwarcie i wielkość koron pozwalają na bezproblemowe kartowanie pojedynczych drzew. Szersze zastosowanie do badań lasów znalazły obrazy satelitarne a później hiperspektralne.

Pierwsze prace nad klasyfikacją lasów na podstawie obrazów satelitarnych – zarejestrowanych skanerem MSS satelity Landsat, umożliwiły jedynie wydzielenie drzewostanów iglastych, liściastych i mieszanych (Ciołkosz, Poławski, 1980). Proces analizy polegał pierwotnie na wizualnej ocenie a następnie sprawdzaniu wyników na obszarze badań. Nie posługiwano się żadnymi narzędziami, jedynie intuicyjnie przypisywano je do poszczególnych kategorii. Tymi samymi metodami opracowywano pierwsze mapy obejmujące obszary leśne dotknięte klęską ekologiczną w Górach Izerskich i Karkonoszach. Wyróżniono zdrowe i martwe drzewostany świerkowe oraz liściaste i mieszane, a także wylesienia.

Wraz z postępowaniem technologicznym satelitów Landsat i tym samym wzrostem dokładności obrazowania powierzchni Ziemi, możliwe były bardziej precyzyjne wydzielenia leśne. Na podstawie obrazów Landsata TM zidentyfikowano na obszarze jednogatunkowe drzewa z podziałem na klasy wieku a także wyznaczono stopnie zmieszania gatunkowego (Baubien, 1979).

W połowie lat 80. XX wieku porównywano barwy lasów Sudetów Zachodnich na obrazie satelitarnym z wynikami interpretacji spektrostrefowych zdjęć lotniczych i na ich podstawie wyznaczono drzewostany według kategorii udziału drzew martwych i umierających, ubytku aparatu asymilacyjnego oraz ich wieku (Bochenek i in., 1987). Autorzy dokonali analizy dokładności klasyfikacji, która wykazała duże zróżnicowanie w rozpoznaniu.

Na początku lat 90. ubiegłego wieku wprowadzono Systemy Informacji Lasów Państwowych (SILP). Celem było katalogowanie na bieżąco informacji o stanie lasów. Dzięki temu można było mieć dostęp do aktualnej bazy danych o wybranym kompleksie leśnym. Służyły one przede wszystkim jako materiały uzupełniające lub też do weryfikacji poprawności wykonywanej interpretacji obrazu.

Wykorzystanie nowoczesnych systemów przetwarzania obrazów pozwoliło na bardziej szczegółowe klasyfikowanie drzewostanów. Oceniano możliwości programów, które mogłyby służyć do interpretacji treści leśnej. W artykule Wykorzystanie systemu przetwarzania obrazów ERDAS IMAGINE do klasyfikacji obszarów leśnych Z. Bochenek i M. Iracka (1996) przedstawili prace nad analizą treści leśnej pięciu zdjęć satelitarnych Landsat TM, obejmujących kompleksy leśne w różnych regionach Polski. Wykazano, że system umożliwił sprawne wykonanie wszystkich etapów analizy. Jednakże zauważono, że do wykonania klasyfikacji nieodzowne jest wykorzystanie informacji specjalistycznych w postaci map drzewostanowych i siedliskowych, zinterpretowanych zdjęć lotniczych, danych terenowych oraz informacji z SILP.

Rozwój technologiczny specjalistycznych programów komputerowych pociągnął za sobą wzrost zastosowania nowych metod do klasyfikacji treści leśnej. Pojedyncze drzewostany zidentyfikowano na podstawie wyznaczania na obrazach pól treningowych i jednorodnych spektralnie klas, reprezentujących daną kategorię leśną. Zauważono, że wybrane zakresy Thematic Mapper'a (TM3, TM4, TM5) są użyteczne poprzez ich wagowanie przy ocenie uszkodzeń drzewostanów. Powstawało coraz więcej opracowań na temat klasyfikacji lasów różnych obszarów na podstawie wykonanych zdjęć skanerami TM, HRV (High Resolution Visible) a także obrazów radarowych. Powtarzalność zobrazowań z określonego obszaru umożliwiała ocenę dynamiki zmian stanu lasu na analizowanym obszarze. Opracowania takie wykonywane były również i w Polsce – dla obszarów Sudetów i Lasów Raciborskich (Zawiła-Niedźwiecki, 1994).

Kolejny etap rozwoju badań nad klasyfikacją lasów na podstawie zdjęć satelitarnych to udoskonalanie i wynajdywanie nowych narzędzi w systemach przetwarzania obrazów. Miały one służyć do coraz bardziej szczegółowego wydzielenia lasów, w oparciu o dodatkowe parametry takie jak tekstura obrazu (Kushwaha, i in., 1994) i stosowaniu zaawansowanych metod klasyfikacji – np. klasyfikacji kontekstualnej i największego prawdopodobieństwa (Magnussen i in., 2004). Autorzy w swoich pracach nad tymi metodami oprócz pomiarów

dokonywali oceny dokładności uzyskanych wyników – wahały się one dla poszczególnych kategorii wydzielen od 50 do 90%.

Do wykonywania map pokrycia terenu wykorzystywano coraz częściej metody „uczenia systemów”, klasyfikacji największego prawdopodobieństwa (Bayesa), najbliższego sąsiedztwa (KNN) czy też metody wektorów nośnych. Autorzy badali te techniki i starali się ocenić ich skuteczność w rozpoznaniu poszczególnych drzewostanów. Jedną z takich prac, oceniającą przydatność wybranej techniki jest *Random forest classifier for remote sensing classification* (Pal, 2005). Wykazano efektywność stosowania metody wektorów nośnych (*Support Vector Machine*) – jednej z technik, za pomocą której można przewidywać przynależność obiektów do klas i wartości zmiennych liczbowych. Coraz powszechniej jest stosowana metoda sztucznych sieci neuronowych (SNN), która pozwalała uzyskać bardzo dobre wyniki w klasyfikacji obszarów leśnych na podstawie danych teledetekcyjnych (Gopal i Woodcock, 1996).

Zastosowanie technik hyperspektralnych w badaniach obszarów leśnych

Obrazy hyperspektralne wnoszą zupełnie nową jakość do zdalnego rozpoznania różnych typów obiektów w terenie. Można dostrzec dwuetapowy przebieg badań. Początkowo zajmowano się porównywaniem wyników jednej klasyfikacji na różnych materiałach źródłowych. Z upływem czasu zaczęto koncentrować się na szukaniu i sprawdzeniu algorytmów służących skutecznemu rozpoznaniu drzew na obrazach hyperspektralnych.

W artykule *Processing Hyperion and ALI for Forest Classification* (Goodenough i in., 2003) zaprezentowano klasyfikację lasów na podstawie trzech różnych danych: hyperspektralnych (skaner Hyperion satelity EO-1) oraz wielospektralnych (skaner ALI, także satelita EO-1, oraz skaner ETM+ Landsat 7). Klasyfikacja polegała na identyfikowaniu poszczególnych gatunków drzew, jakie występują na badanych obszarach Kanady i USA. W pracy wykazano, że dokładność klasyfikacji wynosi odpowiednio: 90% dla obrazu pozyskanego z Hyperiona, 84,8% z ALI i 75% z ETM+.

Obecnie badania polegają na jak najbardziej pełnym wykorzystaniu zasobów informacji, jakie niosą w sobie obrazy hyperspektralne. W opracowaniu J. Lumme (2005) oceniano skuteczność różnych metod klasyfikacji drzewostanów na obrazie uzyskanym ze skanera AISA. Autor ten zastosował dwie klasyfikacje hybrydowe – Bayes’a z innymi miarami oraz sztuczną sieć neuronową z dodatkowymi miarami. Wywnioskował, że najlepsze wyniki daje klasyfikacja hybrydowa – Bayes’a z wykorzystaniem miar tekstury, wskaźnika NDVI i analizy składowych głównych.

Podobne badania wykonali B. Buddenbaum i inni (2005), którzy stosując klasyfikacje *Spectral Angle Mapper* i Bayes’a na obrazie hyperspektralnym ze skanera HyMap nie uzyskali zadowalających efektów i wywnio-

skowali, że potrzeba głębszej analizy by uzyskać poprawne wyniki.

W Polsce również zajmowano się możliwościami zastosowania danych hyperspektralnych. P. Wężyk i B. Wertz (2005) dokonali aktualizacji mapy leśnej Puszczy Niepołomickiej na podstawie zobrazowania hyperspektralnego uzyskanego przez skaner AISA.

Charakterystyka kompleksów leśnych badanego obszaru

Na badanym obszarze występuje kilka kompleksów leśnych. Większość z nich znajduje się w jego północnej i środkowej części. Jedynie na południowym krańcu sceny występuje pojedynczy kompleks lasów iglastych. Nazwy poszczególnych kompleksów leśnych pochodzą od nazw sąsiadujących z nimi miejscowości. W niektórych przypadkach mniejszym kompleksom leśnym nadano własne nazwy.

W północnej części terenu, występuje zwarty kompleks leśny Podzamcze, porastający wzniesienie Grzywy Korzeckowskie. Jego nazwa pochodzi od znajdującej się w pobliżu miejscowości. Lasy te wchodziły w skład Chęcińsko-Kieleckiego Parku Krajobrazowego. Zajmują powierzchnię ponad 1100 ha i są nadzorowane przez Nadleśnictwo Kieleckie z siedzibą w Kielcach. Jest to jedyny kompleks leśny, znajdujący się w granicach powiatu kieleckiego. Pozostałe występują na terenach powiatu jędrzejowskiego i są pod nadzorem Nadleśnictwa Jędrzejowskiego.

Natomiast na południe od Podzamcza występują lasy należące do Włoszczowsko-Jędrzejowskiego Obszaru Chronionego Krajobrazu. Są to kolejno od północy: kompleks leśny Wilkomija (ponad 500 ha) występujący między dopływem a głównym nurtem Białej Nidy; kompleks rozciągający się wzdłuż torów kolejowych między Wolicą a Sokołowem Dolnym (około 300 ha); pojedyncze lasy Wrzosowa (około 30 ha) oraz zajmujący największą powierzchnię Las Jędrzejowski. Ten ostatni rozciąga się od wschodnich okolic Jędrzejowa aż do gminy Oksa i zajmuje powierzchnię ponad 2 000 ha.

Scena obejmuje również niewielki skrawek lasu prywatnego. Znajduje się on na zachód od kompleksu leśnego Wilkomija, po drugiej stronie rzeki Biała Nida. Ostatni fragment lasu, położony na południe od Jędrzejowa, zajmuje powierzchnię ponad 250 ha.

Niestety brakuje szczegółowych danych statystycznych o składzie gatunkowym i wieku drzewostanów. Informacje na stronach internetowych nadleśnictwa (<http://www.radom.lasy.gov.pl/jedrzejew>, <http://www.radom.lasy.gov.pl/kielce>) dotyczą lasów ogółem dla całego powiatu a nie każdego pojedynczego kompleksu. Jednakże na podstawie leśnych map przeglądowo-gospodarczych oraz map drzewostanowych można wizualnie interpretować przestrzenne zróżnicowanie lasu.

W obszarach leśnych dominują dwa gatunki drzew: sosna i dąb. Ich rozmieszczenie jest zróżnicowane. Są pojedyncze kompleksy, gdzie występuje jedynie monokul-

tura sosnowa albo w mniejszym stopniu zmieszana z dębami. Miejscami występują również inne gatunki drzew takie jak: olsza, modrzew czy brzoza. Pod względem wiekowym zróżnicowanie jest mniejsze. Są to lasy z klasą wiekową od 21 lat do wieku rębności. W bardzo nielicznych miejscach występują niewielkie powierzchnie młodników czy drzew w wieku rębnym. Poniżej znajduje się zestawienie gatunków drzewostanów (tab. 1) występują-

Analiza obrazu uzyskanego ze skanera hyperion Metodyka badań

Pierwszy etap badań polegał na odpowiednim przygotowaniu obrazu hiperspektralnego oraz zebraniu materiałów (mapa topograficzna i mapy przeglądowo-gospodarcze). Wykorzystany obraz był po pierwotnej korekcji radiometrycznej i geometrycznej i wymagał

Tabela 1. Występowanie drzewostanów na badanym obszarze (z podziałem na gatunek i wiek).

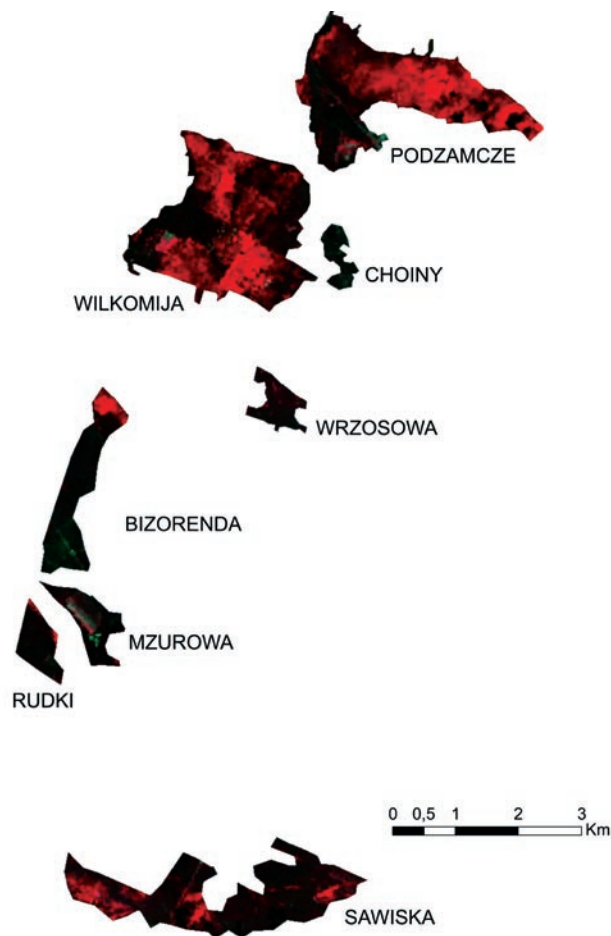
Table 1. Forest stands in the study area (kind and age)

Gatunek (Species) Wiek (Age)	I klasa wieku [do 21 lat] (Less than 21 years old)	Od 21 lat do wieku rębności (Between 21 years old and rotation age)	Rębne i starsze (After rotation age)	Wiek rębności (The Rotation Age)
Sosna (Pine)	TAK/yes	TAK/yes	NIE/no	100
Dąb (Oak)	TAK/yes	TAK/yes	NIE/no	140
Buk (Beech)	NIE/no	TAK/yes	NIE/no	120
Olsza (Alder)	NIE/no	TAK/yes	NIE/no	80
Brzoza (Birch-tree)	NIE/no	TAK/yes	NIE/no	80

cych na badanym obszarze oraz ich wiek wraz z uwzględnionym zróżnicowanym wiekiem rębności.

Badania dotyczą rozpoznania drzewostanów Podzamcza, Wilkomiji, Wrzosowy i fragmentu Lasu Jędrzejowskiego. O takim wyborze zdecydowały trzy czynniki. Pierwszy to brak materiałów, map leśnych niektórych fragmentów. Drugi powód to taki, że zdecydowano się badać obszary znajdujące się w bliskim sąsiedztwie, czyli znajdujące się w północnej i środkowej części sceny. Ostatni, i w znacznej mierze ograniczający pole badań to wydzielenie na obrazie obszarów leśnych nie znajdujących się pod chmurami.

Zaprezentowano ryc. 2 z wyodrębnionymi obszarami leśnymi. Jest to wydruk kompozycji barwnych utworzonych z trzech kanałów: R: 750 nm G: 650 nm B: 550 nm. Kompozycje te powstały poprzez rzutowanie odpowiednich kanałów spektralnych zdjęć satelitarnych podstawowymi barwami światła (Ciołkosz, Miszalski, Olędzki, 1999). Nazwy przypisano im na podstawie map leśnych lub dla orientacji zaczerpnięto od nazwy najbliższej położonej wsi. Na podstawie tych kompozycji można wstępnie rozpoznać poszczególne gatunki drzewostanów oraz spróbować określić ich zasięg występowania. Interpretacja wizualna pozwalała rozróżnić nie tylko gatunek, ale i wiek. Jednakże rozpoznanie wieku ograniczało się do określenia drzewostanu młodego lub starego. Sosna różni się od dębu ciemniejszą tonacją czerwieni oraz czarnym kolorem. Natomiast obszary o coraz jaśniejszej czerwonej tonacji przedstawiają dęby coraz młodsze. Na obszarze Wilkomiji jest niewielki fragment o tonacji różowej, który przedstawia drzewostan młodych dębów. Na obszarze leśnym Sawiska jest możliwe lokalizowanie olszy na tle sosny, a w lasach Mzurowa można rozpoznać młodniki sosny. Na drodze dedukcji można stworzyć pierworys rozpoznania drzewostanów z wykorzystaniem kompozycji barwnych.



Ryc. 2 Kompozycje barwne RGB (R: 750 nm G: 650 nm B: 550 nm) z obrazu hiperspektralnego ze skanera Hyperion.

Fig. 2 A RGB (R: 750 nm G: 650 nm B: 550 nm) color compositions made from hyperspectral scanner Hyperion image.

dalszego przetworzenia. Część kanałów pozostawiono bez zmian a na pozostałych przeprowadzono transformację redukcji szumów tzw. *Minimal Noise Fraction* (MNF). Skutkiem segregacji kanałów było utworzenie dwóch obrazów: pierwszego z kanałów skorelowanych, drugiego z kanałów po transformacji MNF. Kolejne etapy pracy przebiegały na dwóch obrazach. Dodatkowo przeprowadzono zmianę układu współrzędnych. Do sprawdzenia wstępnej identyfikacji lasów na obrazie satelitarnym wykorzystano mapę topograficzną w skali 1: 50 000. Arkusz mapy zeskanowano a następnie otrzymany cyfrowy produkt poddano geometryzacji do układu 92. Natomiast fragmenty mapy przeglądowo-gospodarczej połączono i pokolorowano.

Następnie wyznaczono granice obszarów leśnych na obrazie satelitarnym. Pomocne było tu wyznaczenie wskaźnika NDVI dla całego badanego obszaru. Tam gdzie występowały chmury lub ich cienie, wartości NDVI były ujemne. Natomiast wszystkie tereny nieleśne – grunty orne, miasta charakteryzowały wartości wskaźnika do 0.3. Dzięki temu można było dokładnie odróżnić tereny leśne od sąsiadujących z nimi obszarów nieleśnych.

Następnie przystąpiono do analizy obrazów i rozpoznania drzewostanów. Polegały one na sklasyfikowaniu obszarów leśnych, wykorzystując krzywe odbicia spektralnego, na poszczególne gatunki i klasy wieku drzewostanu. Różnice odbicia spektralnego w bardzo wąskich przedziałach spektralnych (10 nm) pozwoliły na lepsze rozpoznanie drzewostanów. Krzywe odbicia najlepiej odczytać z pikseli homogenicznych reprezentujących jedną klasę. W celu znalezienia takich pikseli zastosowano algorytm *Pixel Purity Index* (PPI). Wynikiem tego procesu był nowy obraz z wyszukаныmi pikselami. Obraz PPI nałożono na obraz hiperspektralny. Tym samym wyznaczono grupy pikseli reprezentujących dany gatunek drzewostanu i jego wiek. Zbiór takich pikseli stanowił wzorzec do klasyfikacji. Krzywe odczytane z pikseli jednego zbioru są uśredniane i w efekcie otrzymuje się jedną krzywą odbicia, reprezentującą konkretny gatunek i wiek drzewostanu.

W badaniu wykorzystano klasyfikację *Spectral Angle Mapper* (SAM). Polega ona na klasyfikowaniu pikseli w oparciu o kąt nachylenia krzywej odbicia spektralnego do osi poziomej X. Każdy piksel odpowiada wartości odbicia i zostaje przyrównany do zebranych wcześniej wzorców. Im mniejsza różnica kątów między krzywą testowaną (odczytaną z każdego piksela) a referencyjną, tym większe prawdopodobieństwo, że dany punkt reprezentuje poszczególną klasę.

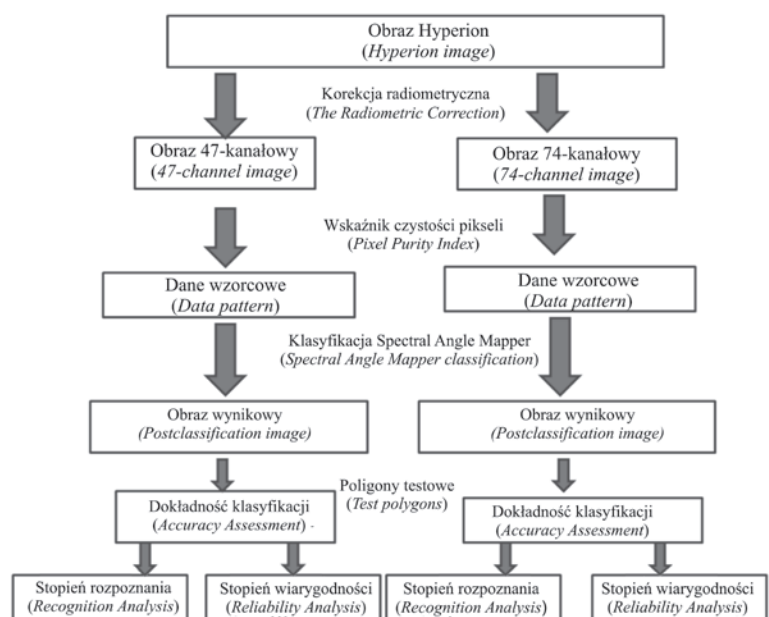
Ostatnim etapem pracy było określenie dokładności wyników klasyfikacji. Przeprowadzono dwie oceny. Pierwsza, dotycząca stopnia rozpoznania, pozwoliła na uzyskanie informacji jaki procent pikseli został rozpoznany przez program poprawnie. Druga,

dotycząca stopnia wiarygodności, pokazała poprawność interpretacji obrazu konkretnych obiektów i zaklasyfikowania ich do wydzielonych klas. W przypadku analizy rozpoznania, utworzono kilka poligonów referencyjnych, reprezentujących klasy drzewostanów. Natomiast przy ocenie wiarygodności sprawdzano poprawność identyfikacji 260 punktów kontrolnych generowanych losowo przez program.

Na koniec podsumowano wyniki i oceniono czy obraz ze skanera Hyperiona był skutecznym źródłem do rozpoznania lasów, a także czy sama metoda badań – klasyfikacja SAM – stanowiła efektywne narzędzie do omawianej pracy badawczej.

Cały etap przygotowania obrazu do klasyfikacji jak i sam jej proces wykonano w oprogramowaniu ENVI 4.3. Także w tym programie dokonano analizy stopnia rozpoznania drzewostanów. ENVI jest specjalistycznym oprogramowaniem do wykonywania operacji na obrazach wielokanałowych i radarowych. W programie tym można wykonywać zaawansowane procedury klasyfikacyjne na danych hiperspektralnych. Pakiet oprogramowania ArcGIS 9.0 służył do wstępnego opracowania rozpoznania drzewostanów na podstawie kompozycji barwnych oraz do przeprowadzenia generalizacji obrazów wynikowych. Natomiast ocenę wiarygodności uzyskanych wyników oraz przygotowanie mapy do wydruku wykonano w oprogramowaniu Erdas IMAGINE 8.3.

Schemat badań przedstawiono na ryc. 3. Przedstawia on w uproszczeniu kolejne etapy postępowania. Przy każdym z dwóch obrazów ze skanera Hyperion wykonywano te same czynności. Pomiędzy kolumnami podawano wspólne schematy postępowania. Są to kolejno: obliczanie *Pixel Purity Index*, klasyfikacja *Spectral Angle Mapper*, wyznaczenie poligonów testowych.



Ryc. 3 Schemat postępowania.

Fig.3 The process scheme of researches.

Materiały źródłowe

Analizowany obraz hiperspektralny zarejestrowany został przez skaner Hyperion, umieszczony na satelicie Earth Observing-1, 25 czerwca 2006. Jest to skaner o wysokiej rozdzielczości spektralnej, umożliwiający rejestrację danych w 242 zakresach spektralnych z rozdzielczością terenową 30 x 30 m. Dane rejestrowane są w zakresie fal o długości od 356 nm do 2577 nm a szerokość pojedynczego kanału spektralnego wynosi 10 nm. Rozdzielczość radiometryczna równa się 12 bitów. Oznacza to, że na obrazie można wydzielić 4096 stopni w skali szarości. Instrument pozyskuje dane w pasie skanowania o szerokości 7,7 km i długości do 185 km. Dzięki tak dużej ilości zakresów spektralnych możliwe jest wykonywanie szczegółowych i kompleksowych badań środowiskowych¹.

Analizowany obraz był wstępnie przetworzony do postaci Level 1R². Był on zgeometryzowany do międzynarodowego układu Universal Transverse Mercator. Zmieniony był również rozmiar sceny, tak że jej długość w skali rzeczywistej wynosiła 30 km.

Niestety, obraz ten nie został poddany korekcji atmosferycznej. Głównym powodem był brak licencji do oprogramowania FLAASH, działającego pod programem ENVI. Mimo braku korekcji atmosferycznej, dokonano próby klasyfikacji obszarów leśnych wykorzystując cechy spektralne poszczególnych gatunków drzew. Na danym obrazie każdy piksel przedstawia wartość radiancji promieniowania elektromagnetycznego³. Wartość ta wyrażona jest w jednostkach DN (*Digital Number*). Wielkości radiancji, wyrażone na obrazie jaskrawością pikseli (DN) w poszczególnych zakresach spektrum, prezentują charakterystyki spektralne. W tym przypadku, cechy spektralne obiektów mogą być porównywane jedynie w obrębie jednej sceny i tylko wykonanej w ciągu jednego dnia. Dlatego też otrzymanych wyników nie można utożsamiać z uzyskanymi na innych obrazach hiperspektralnych. Tak samo wyznaczonych charakterystyk spektralnych nie można porównywać z uzyskanymi z innego źródła.

Na początek przeprowadzono zmianę układu współrzędnych z międzynarodowego UTM do układu PUVG-92. Umotywowane jest to dostępnością do cyfrowej mapy topograficznej, opracowanej w tym samym układzie współrzędnych. Mapa ta stanowiła podkład do lokalizacji wybranych wydziałów drzewostanów.

¹ Hyperion ma szerokie zastosowanie w górnictwie, geologii, leśnictwie, rolnictwie i zarządzaniu środowiskiem. Pełny opis jego charakterystyki znajduje się na oficjalnej stronie platformy EO-1 <http://eo1.usgs.gov>.

² Obrazy skanera Hyperion są gromadzone i przechowywane w Centrum United States Geological Survey. Produkty można otrzymać zarówno w stanie surowym lub już po wstępnym przetwarzaniu radiometrycznym – sygnowane jako Level1R. Te drugie cechują się między innymi korekcją rozmieszczenia pikseli, przeskalowaniem wartości radiancji do jednostek DN (*Digital Number*). Zapisywane są one w formacie HDF (*Hierarchical Data Format*).

³ <http://eo1.usgs.gov>

Materiały pomocnicze

Dla potrzeb lokalizacji poszczególnych drzewostanów wykorzystano mapę topograficzną w skali 1: 50 000, arkusz M-34-41 D Chęciny, wykonaną w układzie 92, z aktualizacją na rok 1998.

Korzystano również z map przeglądowo-gospodarczych w skali 1: 10 000 – dla kompleksu leśnego *Podzamcze*, ze stanem aktualizacji na rok 1999. Dzięki uprzejmości Regionalnej Dyrekcji Lasów Państwowych w Jędrzejowie otrzymano dostęp do *Systemu Informacji Leśnej* – map drzewostanowych dla poszczególnych kompleksów leśnych w skali 1: 50 000 (stan aktualizacji na rok 2006). Do generacji tych wydruków wykorzystano oprogramowanie eLas Server 1.0.

Pozyskane materiały pomocnicze zostały poddane przetworzeniom. Pierwszą czynnością było połączenie kilku arkuszy mapy kompleksu leśnego *Podzamcze* w całość. Następnie dokonano „aktualizacji” tej mapy – na rok 2006. Uzyskane mapy pokolorowano i zaktualizowano wiek drzewostanów (do każdej klasy wydzielenia dodano 7 lat, tak by pokazano stan aktualizacji na rok 2006).

Drugim etapem było zeskanowanie mapy topograficznej arkusza *Chęciny* a następnie zgeometryzowanie go.

Przygotowanie obrazu hiperspektralnego do klasyfikacji

Redukcja kanałów – transformacja MNF

Transformacja MNF (*Minimum Noise Fraction*) służy do analizy wzajemnej korelacji kanałów oraz usuwania zakłóceń i szumów. Jest ona zbliżona do Analizy Składowych Głównych (PCA). Transformacja MNF pozwala efektywnie usunąć szumy z danych wielospektralnych, gdy zmienność szumów różni się pomiędzy kanałami spektralnymi. Jest to ekwiwalent PCA, kiedy zmienność szumów jest taka sama we wszystkich kanałach spektralnych. Procedura ta pozwala na klasyfikację kanałów od bogatych w informacje do silnie zakłóconych przez szumy. Po transformacji uzyskano obraz złożony z czystych, nieskorelowanych ze sobą kanałów oraz tych, zawierających różne zakłócenia. Do dalszych etapów badań zostały wykorzystane tylko czyste kanały.

Obraz Hyperion pierwotnie składał się z 242 kanałów. Jednakże na wstępie trzeba odrzucić czterdzieści cztery kanały, gdyż nie były one skalibrowane. Są to kanały o przedziałach spektralnych w zakresie widzialnym i bliskiej podczerwieni (VNIR): 356–417 nm, 936–1058 nm oraz zakresie krótkofalowej podczerwieni (SWIR): 852–902 nm, 2406–2578 nm. Na oficjalnej stronie internetowej platformy EO-1 podano że przyczyną odrzucenia tych kanałów jest brak czułości detektorów na rejestrowanie w tych zakresach fal, stąd przy każdym wstępnym przetworzeniu cyfrowym obrazu Hyperiona odrzuca się te kanały do dalszych badań. Dodatkowo usunięto jeszcze dwa kanały ze względu na

nałożenie się ich w zakresie VNIR i SWIR. W dalszym etapie przetworzenia cyfrowego analizowano pozostałe 196 kanałów.

Najpierw wizualnie szukano zakłóconych kanałów i odnotowywano je. Finalnie wykorzystano do badań 121 kanałów. Jednakże podzielono je na dwa obrazy z segregowanymi kanałami. Pierwszy zawiera czterdzieści siedem czystych, skorelowanych kanałów. Drugi, z 74-ma kanałami, został poddany transformacji MNF w oprogramowaniu ENVI. W wyniku tego postępowania po odwrotnej transformacji uzyskano tę samą liczbę kanałów, ale nie skorelowanych ze sobą. Każde kolejne etapy pracy zostały wykonywane na dwóch obrazach. W tabelach 2 i 3 zestawiono szczegółowe długości fal dla kanałów, uwzględnionych w tych badaniach.

Tworzenie wzorców do klasyfikacji. Algorytm PPI

Aby przeprowadzić klasyfikację treści obrazu, należy programowi wskazać wzorce klas, według których będzie on analizował prawdopodobieństwo przynależ-

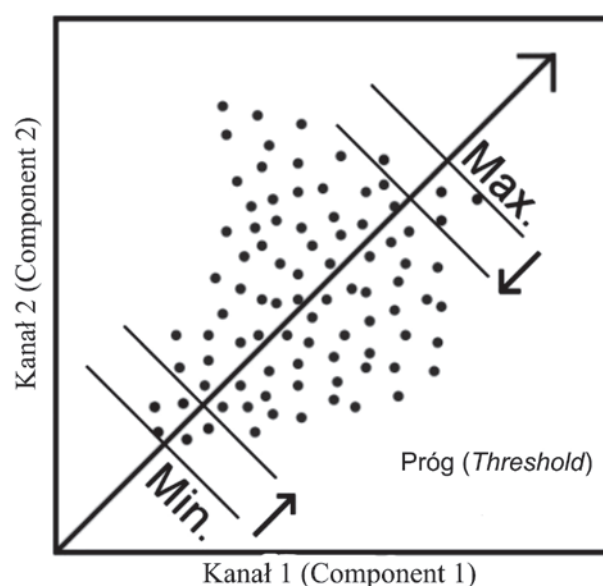
Tabela 2. Zestawienie 47-miu kanałów pierwszego obrazu.
Table 2. The list of 47-channels (first image).

Kanał (Channel)	Długość fali (Wavelength)	Kanał (Channel)	Długość fali (Wavelength)
11	457.3417	35	701.5486
12	467.5172	36	711.7238
13	477.6923	37	721.8995
14	487.8678	38	732.0746
15	498.0428	39	742.2499
16	508.2185	40	752.4251
17	518.3937	41	762.6005
18	528.5690	42	772.7761
19	538.7442	43	782.9514
20	548.9193	44	793.1268
21	559.0944	45	803.3020
22	569.2698	46	813.4772
23	579.4454	47	823.6525
24	589.6204	48	833.8278
25	599.7959	49	844.0031
26	609.9713	50	854.1783
27	620.1464	51	864.3533
28	630.3320	52	874.5286
29	640.4974	53	884.7043
30	650.6727	54	894.8795
31	660.8477	55	905.0546
32	671.0228	56	915.2299
33	681.1983	57	925.4054
34	691.3736		

ności piksela do danej grupy. Wzorcami do klasyfikacji były zbiory pikseli odpowiadające konkretnemu gatunkowi i wiekowi drzewostanu. Złożoność problemu wyszukiwania wzorców polegała na odnalezieniu pikseli czystych spektralnie.

Algorytm *Pixel Purity Index* (PPI) służy wyszukiwaniu ze zbioru wszystkich pikseli tylko czystych spektralnie tzw. *endmembers*. Piksele homogeniczne reprezentują jednorodne obiekty. Zasada PPI polega na tworzeniu określonej liczby n -wymiarowych wektorów (gdzie n – liczba kanałów spektralnych), na które zostają odwzorowywane wszystkie piksele zobrazowania wielospektralnego. Algorytm określa krotność, z jaką dany zarejestrowany piksel został uznany za ekstremalny. Ostateczna liczba wyszukanych pikseli zależy od progu wartości, dla którego piksele są uważane za ekstremalnie położone. Im większa wartość progu, tym więcej pikseli oddalonych od końców wektora może zostać zaliczonych jako *endmembers*. Standardowa wartość progu wynosi 2–3 dla obrazów wielospektralnych niezasmuconych. W przypadku obrazów zakłóconych różnymi szumami, zaleca się podwyższenie wartości progu. Aby uzyskać dokładne wyniki, przeprowadza się iterację tej operacji. Te piksele, które znajdują się na krańcu wektora są uznawane za homogeniczne. Liczbę takich pikseli decyduje wartość progu. Proces wyszukiwania przez PPI ilustruje ryc. 4.

W wyniku selekcji kanałów do dalszych badań wykorzystano dwa obrazy: pierwszy 47-kanałowy i drugi 74-kanałowy. Na każdym z nich wykonano operacje według algorytmu PPI. Liczba prób wynosiła 10 000 a próg pikseli ustawiono na 2. Okazało się, że na pierwszym obrazie algorytm znalazł niecałe 6 000 pikseli co najmniej raz uznanych za czyste spektralnie. W przypadku drugiego było ich prawie 2 000. Tabela (4) przed-



Ryc. 4 Schemat wyszukiwania pikseli czystych spektralnie (*endmembers*). Według: www.microimages.com/documentation/cplates/61Ppi.pdf.

Fig. 4 The search for spectrally pure pixels scheme.

Tabela 3. Zestawienie 74-ech kanałów drugiego obrazu.

Table 3. The list of 74-channels (second image).

Kanał (Channel)	Długość fali (Wavelength)	Kanał (Channel)	Długość fali (Wavelength)	Kanał (Channel)	Długość fali (Wavelength)
8	426.8158	101	1154.5768	140	1548.0214
9	436.9910	102	1164.6759	141	1558.1202
10	447.1665	103	1174.7749	142	1568.2188
79	932.6393	104	1184.8738	143	1578.3171
80	942.7279	105	1194.9725	144	1588.4156
81	952.8165	106	1205.0708	145	1598.5142
82	962.9050	107	1215.1689	146	1608.6133
83	972.9934	108	1225.1672	147	1618.7119
84	983.0817	109	1235.2657	148	1628.8103
85	993.1704	110	1245.3643	149	1638.8082
86	1003.2994	111	1255.4633	150	1648.9065
87	1013.2982	112	1265.5621	151	1659.0056
88	1023.3965	113	1275.6610	152	1669.1045
89	1033.4954	114	1285.7594	153	1679.2030
90	1043.5931	115	1295.8575	154	1689.3018
91	1053.6919	116	1305.9563	155	1699.3997
92	1063.7906	117	1316.0546	156	1709.4987
93	1073.8888	118	1326.0529	157	1719.5972
94	1083.9879	119	1336.1514	158	1729.6958
95	1094.0864	134	1487.5308	159	1739.6945
96	1104.1851	135	1497.6292	160	1749.7928
97	1114.1838	136	1507.7271	161	1759.8912
98	1124.2826	137	1517.8258	162	1769.9897
99	1134.3802	138	1527.9241	163	1780.0880
100	1144.4789	139	1537.9227		

stawia liczbę pikseli uznanych z odpowiednią krotnością za *endmembers* dla obu obrazów.

Zwraca na uwagę fakt, że zdecydowanie większą liczbę pikseli, minimum raz uznanych za czyste, algorytm odnalazł na obrazie zawierającym 47-kanałów, tj.

Tabela 4. Piksele czyste spektralnie na obu obrazach.

Table 4. Purity pixels of analyzed images.

Obraz (Image)	Obraz 47-kanałowy (47-channel image)	Obraz 74-kanałowy (74-channel image)
Krotność (multiplicity)		
Piksele min. 1x	5987	1978
Piksele min. 100x	203	147
Piksele min. 1000x	36	27

tym prawie dwa razy mniej kanałów niż drugim. Wydawałoby się, że obraz zawierający więcej kanałów, a tym samym więcej informacji, będzie również zawierał więcej pikseli czystych spektralnie. Okazało się jednak, że na pierwszym obrazie można wyszukać ponad 3 razy więcej punktów wzorcowych niż na drugim. Należy

również zauważyć, że im większy pułap uznania pikseli *endmembers*, tym liczby wyszukanych takich przypadków maleją. Również wraz ze wzrostem pułapu, proporcje wyników dwóch obrazów względem siebie równoważą się. Największe wartości krotności uznania za poprawne piksele wynosiły odpowiednio 4216 w obrazie 47-kanałowym i 6096 w obrazie 74-kanałowym. W obu przypadkach liczba tych pikseli wynosiła dziewięć. Po zlokalizowaniu i rozpoznaniu omawianych pikseli okazało się, że reprezentują one cienie chmur. Dlatego też nie mogły zostać wykorzystane do dalszego etapu pracy, czyli tworzenia wzorców.

Jeśli chodzi o ogólną lokalizację wyszukanych pikseli, duża część z nich znajduje się w tych samych pozycjach na dwóch obrazach. Odzwierciedlenie tego zjawiska można znaleźć w dalszym etapie pracy podczas przypisania ich do konkretnych klas. Jedyne różnice występowania takich pikseli to ich liczba oraz krotność z jaką zostały zaklasyfikowane jako homogenicznie. W kilku przypadkach powtarzał się przypadek pikseli reprezentujących obiekty nieleśne (w tym chmury).

Następnym etapem było selekcjonowanie pikseli *endmembers*, identyfikowanie i tworzenie na ich podstawie wzorców. Najistotniejszym momentem badań było ustalenie, jakie drzewostany i o jakim wieku reprezentują pojedyncze grupy pikseli. Były dwa kryteria, jakimi się posługiwano przy wyznaczaniu wzorców. Pierwsze to takie, że piksel musiał być przynajmniej raz zaklasyfikowany jako czysty spektralnie. Drugie, że każde zbiorowisko sąsiadujących blisko ze sobą pikseli reprezentowało konkretną klasę gatunkową i wiekową. Przy tworzeniu ROI (*Region of Interest*) nie wzorowano się na liczbie klas z map leśnych, lecz starano się jak najdokładniej podać dane reprezentatywne dla rozpoznanego drzewostanu. Ważnym elementem tego procesu było zebranie jak największej liczby wzorców, żeby po pierwszej wstępnej próbie klasyfikacji można edytować liczbę wykorzystanych danych wzorcowych.

Proces zbierania wzorców przeprowadzono analogicznie na dwóch badanych obrazach. Tabele 5 i 6 przedstawiają zebrane dane wzorcowe. Na obu obrazach wyznaczono po 24 zbiorowiska pikseli (ROI). Każdą grupę pikseli oznaczono nazwą gatunku, kompleksu w którym się znajdują oraz wiekiem (w przybliżeniu do 5 lat). Oddzielną klasę stanowiły bagna, które zlokalizowano

wewnątrz kompleksów leśnych. Z pierwszego obrazu rozpoznano 2444 piksele, a na drugim 1128.

Na podstawie wyznaczonych danych z algorytmu PPI rozpoznano następujące drzewostany: sosnę, dąb oraz olszę. Natomiast w kategorii wiekowej można było zidentyfikować zarówno sosny należące do pierwszej klasy wiekowej od 21 lat do wieku rębności (odpowiednio sosny do lat 21, sosny 50-letnie i 80-letnie). Analogicznie jest z dębami, które również zidentyfikowano jako najmłodsze do lat 21 oraz te należące do klasy od 21 lat do wieku rębności (40-letnie oraz ponad 70-letnie). Pojedynczą grupę gatunkową i wiekową stanowiła olsza w wieku 50 lat. Pod względem gatunkowym rozpoznano bez problemów te, które dominują na badanym obszarze, to jest sosnę i dąb. Z rzadziej występujących można było zebrać dane tylko o olszy, natomiast niemożliwe było wskazanie wzorców dla buku oraz brzozy. W przypadku kategorii wiekowych, uzyskano pełny zakres danych, dla drzewostanów najmłodszych oraz dla poszczególnych klas wiekowych, nie przekraczających wieku rębności.

Analizując dane ROI z pierwszego obrazu (tab. 5), nietrudno dostrzec, że najwięcej informacji zebrano o dębie (ponad 1300 pikseli) oraz dla sosny (ponad 950 pikseli). Zdecydowanie najmniej zebrano danych o olszy. Gdyby podzielić dane wg kompleksów, okazałoby się że

Tabela 5. Dane wzorcowe – obraz 47-kanalowy.

Table 5. Data patterns – 47-channel image.

Lp. (Nr.)	Nazwa poligonu [ROI] (Region of Interest name)	Piksele (Pixels)
1	Dąb(Oak) Podzamcze 110 lat / years	181
2	Dąb (Oak) Podzamcze 45 lat years	33
3	Dąb(Oak) Podzamcze 35–50 lat / years	129
4	Dąb(Oak) Podzamcze 50–75 lat / years	84
5	Dąb (Oak) Podzamcze 110 lat / years	78
6	Dąb (Oak) Podzamcze 95 lat / years	39
7	Sosna (Pine) Podzamcze 45 lat / years	66
8	Dąb (Oak) Wilkomija 50 lat / years	427
9	Dąb (Oak) Wilkomija 40 lat / years	102
10	Dąb (Oak) Wilkomija 50 lat / years	63
11	Bagna (Swamps) Wilkomija	63
12	Dąb (Oak) Wilkomija do 21 lat / years	90
13	Sosna (Pine) Wilkomija 75 lat / years	27
14	Sosna(Pine) Wilkomija 40 lat / years	120
15	Dąb (Oak) Wilkomija 120 lat / years	81
16	Sosna (Pine) Wilkomija 80 lat / years	36
17	Sosna (Pine) Choiny 50 lat / years	95
18	Sosna (Pine) Mzurowa do 21 lat / years	99
19	Bagna (Swamps) Mzurowa	81
20	Sosna (Pine) Mzurowa 45 lat / years	355
21	Olsza Sawiska 50 lat / years	30
22	Sosna (Pine) Podzamcze 80–90 lat / years	36
23	Sosna (Pine) Podzamcze 80 lat / years	21
24	Sosna (Pine) Wilkomija do 21 lat / years	108

Tabela 6. Dane wzorcowe – obraz 74-kanalowy.

Table 6. Data patterns – 74-channel image.

Lp. (Nr.)	Nazwa poligonu [ROI] (Region of Interest name)	Piksele (Pixels)
1	Dąb (Oak) Podzamcze 110 lat / years	72
2	Dąb (Oak) Podzamcze 110 lat / years	9
3	Dąb (Oak) Podzamcze 45 lat / years	37
4	Dąb(Oak) Podzamcze 35–50 lat / years	98
5	Dąb (Oak) Podzamcze 50–75 lat / years	18
6	Dąb (Oak) Wilkomija 50 lat / years	81
7	Dąb (Oak) Wilkomija 40 lat / years	64
8	Dąb (Oak) Wilkomija 50 lat / years	37
9	Sosna (Pine) Wilkomija 75 lat / years	36
10	Dąb (Oak) Wilkomija do 21 lat / years	39
11	Sosna (Pine) Wilkomija 80 lat / years	37
12	Sosna (Pine) Wilkomija 80 lat / years	46
13	Dąb Wilkomija 50 lat / years	9
14	Sosna (Pine) Wilkomija 70 lat / years	57
15	Dąb (Oak) Wilkomija 120 lat / years	49
16	Sosna (Pine) Wrzosowa 40 lat / years	39
17	Sosna (Pine) Mzurowa do 21 lat / years	36
18	Bagna (Swamps) Mzurowa	45
19	Olsza (Adler) Mzurowa 45 lat / years	30
20	Sosna (Pine) Mzurowa 45 lat / years	111
21	Olsza S(Adler) awiska 50 lat / years	42
22	Dąb (Oak) Sawiska 80 lat / years	109
23	Sosna (Pine) Podzamcze 80 lat / years	18
24	Sosna (Pine) Podzamcze 75 lat / years	9

najwięcej próbek zebrano z obszaru leśnego Wilkomija (ponad 1000 pikseli), podczas gdy z obrębu Podzamcze niecałe 800.


Patrząc na tabelę (6) danych ROI z drugiego obrazu łatwo dostrzec zdecydowanie mniejszą liczbę pikseli przypadającą na dany wzorzec. W porównaniu z pierwszym obrazem różnice te uwidaczniają się przy tych samych wydzieleniach leśnych. Na przykład, dla tego samego obszaru dębu 35–50-letniego na Podzamczu rozpoznano na pierwszym obrazie 129 pikseli, na drugim niecałe 100.

Interesująco przedstawiają się przebiegi krzywych spektralnych poszczególnych drzewostanów. Ryc. 5 ilustruje krzywe dla wybranych wzorców. Oś pozioma reprezentuje zakres długości fal promieniowania elektromagnetycznego. Uwzględniano tu wszystkie kanały z dwóch obrazów rejestrujących promieniowanie od 450 do 1780 nm. Oś pionowa odpowiada wartościom jaskrawości piksela, wyrażonych w jednostkach DN (*Digital Number*). Natomiast w legendzie podano gatunek drzewostanu, nazwę kompleksu leśnego skąd pobrano próbkę oraz wiek drzewostanu.

Wykres na ryc. 5 wskazuje pewne prawidłowości w rozpoznaniu drzewostanów na obrazach ze skanera Hyperion. Różnice pomiędzy poszczególnymi krzywymi uwidaczniają się w konkretnych przedziałach fal: 750–950, 1000–1100 i 1200–1300 nm. Na charakter spektralny poszczególnych drzewostanów wpływ mają różne czynniki (Ciołkosz, Miszalski, Olędzki, 1999). Krzywe mogą się różnić w zależności od fazy fenologicznej rozwoju drzew, stopnia ich wilgotności. Zależą również od budowy liścia oraz składu i koncentracji barwników naturalnych. Na podstawie przebiegu krzywych można wyciągnąć pierwsze wnioski na temat rozpoznania drzewostanów.


Największe różnice w przebiegu krzywych, a tym samym najłatwiejsze rozpoznanie dotyczyło różnic gatunkowych. Cechy spektralne drzewostanów liściastych (dębu, olszy) i iglastych (sosny) różnią się całkowicie i to w każdym z podanych wyżej przedziałów fal promieniowania. Piksele reprezentujące te dwa gatunki na obrazach różnią się wartościami jaskrawości rzędu 3000 DN. W przypadku rozróżnienia wewnątrz gatunkowego, dębu i olszy, sytuacja komplikuje się. Ich wartości jaskrawości pikseli na całej długości podanych fal są zbliżone.

Podczas identyfikowania drzewostanów pod względem wieku, sytuacja jest trudniejsza. Na przykład, na badanym obszarze w obrębie dwóch kompleksów Pod-



Ryc. 5 Profile spektralne wybranych drzewostanów. Legenda: 1. Dąb Podzamcze 110 lat; 2. Sosna Podzamcze 80 lat; 3. Dąb Wilkomija 21 lat; 4. Dąb Wilkomija 90 lat; 5. Sosna Wilkomija 80 lat; 6. Olsza Sawiska 50 lat.

Fig. 5 Spectral profiles of different types of forest stands. Legend: 1. Oak Podzamcze 110 years old; 2. Pine Podzamcze 80 years old; 3. Oak Wilkomija 21 years old; 4. Dąb Wilkomija 90 years old; 5. Pine Wilkomija 80 years old; 6. Alder Sawiska 50 years old.



Ryc. 6 Profile spektralne dębu. Legenda: 1. Dąb Podzamcze 50 lat; 2. Dąb Wilkomija 50 lat.

Fig. 6 Spectral profiles of oak. Legend: 1. Oak Podzamcze 50 years old; 2. Oak Wilkomija 50 years old.

zamcza i Wilkomiji występuje dąb 50-letni. Na ryc. 6 przedstawiono profile krzywych tego samego obiektu ze wskazanych dwóch źródeł. Krzywe te wykazują w niektórych przedziałach długości fal różnice rzędu 1000 DN. Mimo że ten obiekt o tych samych cechach jest prawidłowo rozpoznany w dwóch różnych kompleksach

leśnych, to należy zebrać jak najwięcej danych by program na podstawie kilkunastu lub kilkudziesięciu wzorców mógł poprawnie identyfikować dane drzewostany.

Na podstawie omawianych profili wysunięto pierwsze wnioski. Bardzo istotnym elementem przygotowania obrazów do klasyfikacji jest zebranie jak największej liczby poprawnie przygotowanych danych wzorcowych. Najlepiej jest zbierać dane tego samego obiektu gatunkowego i wiekowego z kilku różnych obrębów leśnych, tak by program mógł je rozpoznać na każdym z nich. Profile krzywych na ryc. 6 wskazują, że rozpoznany dąb z jednego kompleksu leśnego może nie być jednoznacznie identyfikowany z tym samym dębem występującym gdzie indziej. Taka sama sytuacja dzieje się w przypadku sosny i olszy.

Podsumowanie zebranych danych ROI zestawiono w tabeli 7. W porównaniu ze stanem rzeczywistym (tabela 1) nie udało się rozpoznać gatunków występujących w mniejszości na danym obszarze – buku i brzozy.

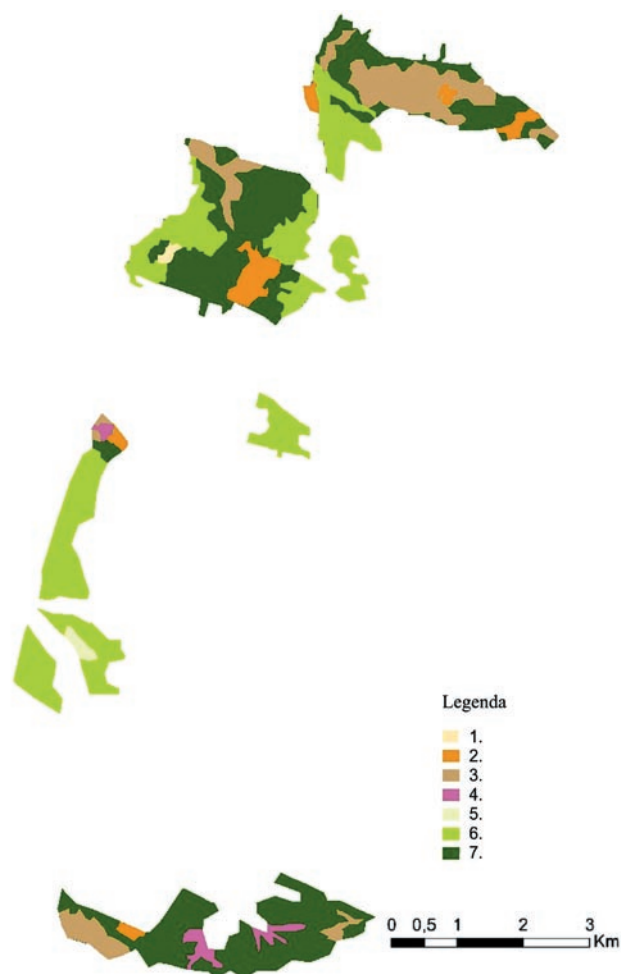
Zanim przystąpiono do wykonania klasyfikacji, dokonano próby interpretacji wizualnej obszarów leśnych. Starano się rozpoznać poszczególne gatunki drzew i określić skalę wiekową. Proces interpretacji wykonano w oprogramowaniu ArcGIS 9.0. Najważniejszym zadaniem podczas interpretacji było ustalenie zasięgów pojedynczych wydzieli. Interpretację wykonano na podstawie dwóch źródeł. Pierwsze stanowiły własne obserwacje i notatki wykonane podczas badań terenowych w lipcu 2007 roku. Drugim źródłem były kompozycje barwne ze skanera Hyperion (R: 750 nm, G: 650 nm, B: 550 nm). Ryc. 7 pokazuje rozmieszczenie rozpoznanych drzewostanów. Uzyskane wyniki interpretacji nie będą stanowić materiału referencyjnego do wyników klasyfikacji, lecz jedynie mają na celu zbadanie możliwości wizualnego rozpoznania konkretnych drzewostanów. Na ich podstawie, tak jak w przypadku profili krzywych spektralnych, można wnioskować o trudnościach w identyfikowaniu oraz określaniu zasięgu występowania poszczególnych gatunków.

W tym procesie widać przewagę wykorzystywania obrazów wielokanałowych nad zdjęciami lotniczymi. A. Ciołkosz, J. Miszałski, J. R. Olędzki (1999) wykazali, że lato nie jest najlepszą porą do wykonywania zdjęć przeznaczonych do interpretacji lasów. Natomiast, tak jak

Tabela 7. Rozpoznanie gatunkowe i wiekowe drzewostanów na obrazach.

Table 7. Recognition of forest stands (species and age) based on analyzed images.

Gatunek (Species) / Wiek (Age)	I klasa wieku [do 21 lat] (Less than 21 years old)	Od 21 lat do wieku rębności (Between 21 years old and rotation age)
Sosna (Pine)	TAK/yes	TAK/yes
Dąb (Oak)	TAK/yes	TAK/yes
Buk (Beech)	NIE/no	NIE/no
Olsza (Alder)	NIE/no	TAK/yes
Brzoza (Birch-tree)	NIE/no	NIE/no



Ryc. 7 Rozpoznane drzewostany na podstawie interpretacji wizualnej obrazu ze skanera Hyperion. Legenda: 1. Dąb do 21 lat; 2. Dąb młodszy; 3. Dąb starszy; 4. Olsza; 5. Sosna do 21 lat; 6. Sosna młodsza; 7. Sosna starsza.

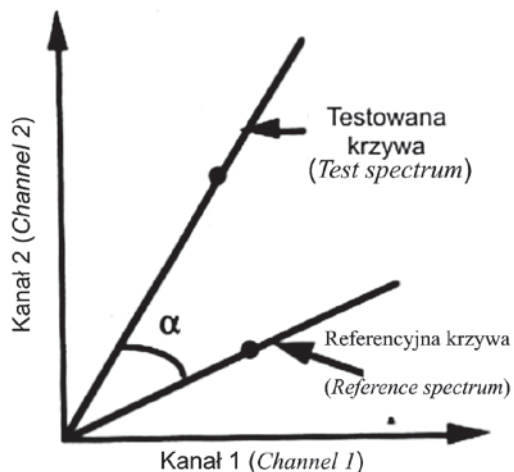
Fig. 7 Visual interpretation of scanner Hyperion image. Legend: 1. Oak less than 21 years old; 2. Oak (young); 3. Oak (old); 4. Alder; 5. Pine less than 21 years old; 6. Pine (young); 7. Pine (old).

w przypadku obrazu ze skanera Hyperion, można odróżnić gatunki liściaste i iglaste. Na podstawie różnic w tonacji barw można też w przybliżeniu ocenić wewnątrz gatunku czy jest młodszy czy starszy od sąsiadującego.

Należy zaznaczyć, że powstałe obrazy interpretacyjne nie mogą stanowić materiału referencyjnego do otrzymanych wyników klasyfikacji. Owszem, własne obserwacje i znajomość terenu pozwoliły na zebranie informacji o lokalizacji określonych drzewostanów, lecz wyznaczenie zasięgu ich występowania opierało się o kompozycje barwne. Wiedza zdobyta podczas badań terenowych okazała się przydatna do oceny wiarygodności klasyfikacji.

Klasyfikacja Spectral Angle Mapper (SAM)

Mechanizm działania klasyfikacji SAM (Spectral Angle Mapper) jest bardzo dobrze opisany w zakładce

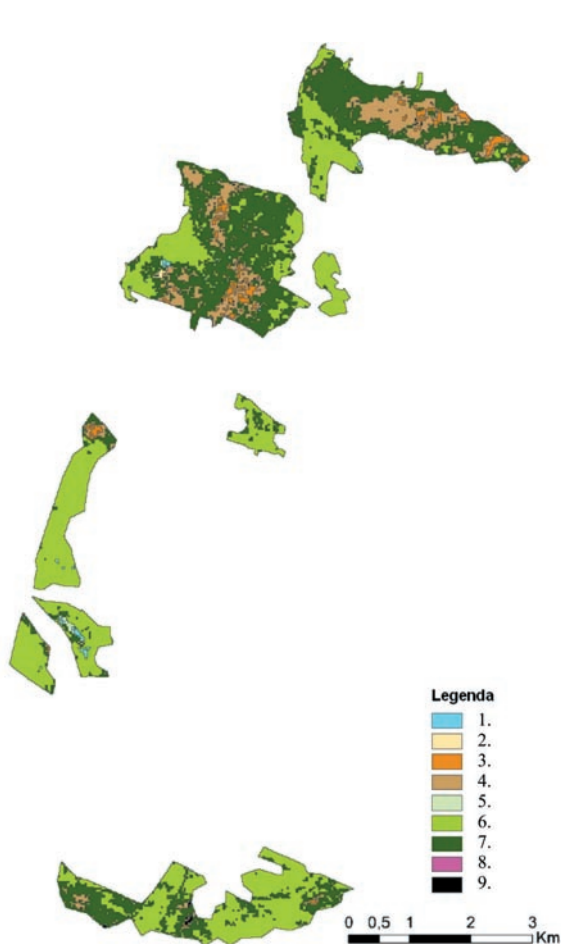


Ryc. 8 Obliczanie kąta spektralnego (odległości spektralnej). Według: ENVI Application Help.

Fig. 8 Calculating the angle between the spectra. (ENVI Application Help)

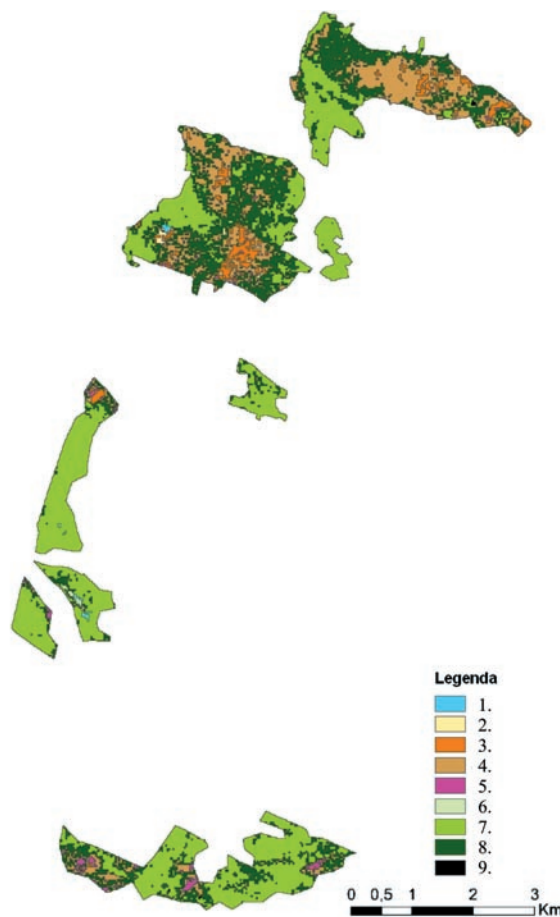
„pomoc” programu ENVI oraz przez Beate Hejmanowską (2004). Według niej jest to „(...) automatyczna metoda przyrównująca wektory spektralne każdego piksela, powstałe z analizy krzywej odbicia spektralnego pozyskanej z każdego piksela obrazu oddzielnie do wzorcowej krzywej obiektu czystego spektralnie (...)”. Każda krzywa referencyjna reprezentuje konkretną klasę drzewostanu. Ryc. 8 przedstawia najprostszyschemat porównania krzywych z dwóch kanałów. Wyznaczony kąt między nimi decyduje o przynależności do danej krzywej referencyjnej. Jednostką miary kąta jest radian.

Po obliczeniu kąta spektralnego, zwanego też odległością spektralną, powstają obrazy dla każdej klasy oddzielnie. Na tych obrazach każdy piksel prezentuje wartość tej odległości. W skali szarości przedstawione są piksele prawdopodobnie reprezentujące obszar badanej klasy. Piksele czarne (o najniższych wartościach) oznaczają największe, bliskie pewności obszary zalicza-



Ryc. 9 Pierwsza próba klasyfikacji drzewostanów na obrazie 47-kanałowym. Legenda: 1. Bagna; 2. Dąb do 21 lat; 3. Dąb 40–50 lat; 4. Dąb 90–120 lat; 5. Sosna do 21 lat; 6. Sosna 30–50 lat; 7. Sosna 70–90 lat; 8. Olsza 50 lat; 9. Niesklasyfikowane.

Fig. 9 First forest classification on 47-channel image. Legend: 1. Marshes; 2. Oak less than 21 years old; 3. Oak 40–50 years old; 4. Oak 90–120 years old; 5. Pine less than 21 years old; 6. Pine 30–50 years old; 7. Pine 70–90 years old; 8. Alder 50 years old; 9. Unclassified.



Ryc. 10 Pierwsza próba klasyfikacji drzewostanów na obrazie 74-kanałowym. Legenda: 1. Bagna; 2. Dąb do 21 lat; 3. Dąb 40–50 lat; 4. Dąb 90–120 lat; 5. Olsza 50 lat; 6. Sosna do 21 lat; 7. Sosna 30–50 lat; 8. Sosna 70–90 lat; 9. Niesklasyfikowane.

Fig. 10 First forest classification on 74-channel image. Legend: 1. Marshes; 2. Oak less than 21 years old; 3. Oak 40–50 years old; 4. Oak 90–120 years old; 5. Alder 50 years old; 6. Pine less than 21 years old; 7. Pine 30–50 years old; 8. Pine 70–90 years old; 9. Unclassified.

ne do danego wzorca. Natomiast białe, o wartościach najwyższych, oznaczają brak przynależności do wskazanego źródła.

Powstaje również jeden łączny obraz z pikselami przydzielonymi do danej klasy. Program klasyfikuje piksele do wybranej granicy kąta spektralnego. W ENVI domyślna wartość kąta do każdego ROI wynosi 0,1 radiana. Oznacza to, że przy porównywaniu kątów spektralnych wszystkich wzorców z testowanym, program wybiera tę krzywą, która najbliższą odpowiada krzywej z piksela i spełnia warunek wartości kąta spektralnego poniżej 0,1 radiana.

W pracy, program oblicza kąty na podstawie porównania tego samego piksela z 47-kanalów pierwszego obrazu oraz 74-kanalów drugiego obrazu z danymi wzorcowymi. W efekcie uzyskano dwa razy po 24 obrazu informujące o przynależności pikseli do pojedynczej klasy.

Na ryc. 9 i 10 przedstawiono wyniki klasyfikacji z dwóch obrazów, z obszaru Podzamcza, Wilkomiji i Sawiska.


Pierwsze wyniki niestety nie były obiecujące. Okazało się, że w wielu przypadkach błędnie rozpoznano poszczególne klasy. Porównując wizualnie efekty klasyfikacji, lepsze rezultaty uzyskano na obrazie 74-kanalowym. Dotyczy to całego badanego obszaru, a w szczególności tych fragmentów gdzie występują różne gatunki drzewostanów. Potwierdziły się przypuszczenia, że program może błędnie rozpoznać dąb i olszę oraz mieć trudności w klasyfikowaniu drzewostanu z uwzględnieniem wieku.

Na podstawie uzyskanych wyników przeprowadzono korektę danych wzorcowych. Okazało się, że w niektórych przypadkach przynależność pikseli do dwóch różnych klas jest taka sama. Dla przykładu podano sytuację z dębem stuletnim i pięćdziesięcioletnim, wyznaczonym na obrazie 47-kanalowym.

Na ryc. 11 pokazano prawdopodobieństwo występowania dębów różniących się wiekowo. Obszary o barwie czarnej reprezentują najniższe wartości odległości spektralnej, czyli tym samym o największym prawdopodobieństwie przynależności do wskazanej klasy. Natomiast biała barwa przedstawia najwyższe wartości, co oznacza, że nie przynależną one do danego wzorca.

Przypadek dębu nie jest jedynym, w którym obliczone odległości spektralne nie pozwalają na rozróżnianie. Ta sama sytuacja występuje przy porównaniu wartości odległości dębu i olszy. Dlatego też pierwsze wyniki klasyfikacji nie odzwierciedlają rzeczywistego rozmieszczenia drzewostanów. Ilustracje wskazują wyraźnie, że do procesu klasyfikacji należy wprowadzić korekty. Zmiany dotyczyć muszą zarówno poprawienia doboru danych wzorcowych ROI a także właściwemu ustawieniu wartości kąta spektralnego.

Proces analizowania błędów klasyfikacji przebiegał dwutorowo. Na każdym z dwóch obrazów ze skanera Hyperion sprawdzano jeszcze raz obszary ROI, wykonywano klasyfikację SAM oraz ponownie analizowano wyniki. Pierwszą czynnością była poprawa danych wzorcowych. Na podstawie wyników pierwszej klasyfikacji sprawdzano odległości spektralne dla poszczególnych klas. Badano, które wzorce drzewostanów zostały



Ryc. 11 Rozmieszczenie odległości spektralnych A – dąb 100-letni B – dąb 50-letni.

Fig. 11 Rule images with the spectra angle from the reference spectrum for two classes: A – Oak 100 years old, B – Oak 50 years old.

błędnie rozpoznane. Droga eliminacji pojedynczych błędnych wzorców uzyskiwano coraz lepsze wyniki. Okazało się, że niektóre dane, przygotowane do klasyfikacji, wzajemnie się wykluczały. Reprezentowały one tę samą cechę drzewostanu (gatunek i wiek), lecz program klasyfikował je zupełnie inaczej. Do skutecznej analizy wzorców wykorzystywano kompozycję barwną obrazów z trzech kanałów (ryc. 2). Na tej podstawie oraz własnych badań terenowych sprawdzono, gdzie prawidłowo powinny przebiegać granice drzewostanów.

Drugim etapem było ustalenie granicy odległości spektralnej każdego wzorca, do którego ma przynależeć testowany piksel. Na każdym z czterdziestu ośmiu obrazów rozkładu odległości spektralnej danego wzorca wyznaczono przedziały i sprawdzono do której wartości kąta program poprawnie rozpoznaje wzorec drzewostanu. Po wielu próbach testowania i sprawdzeniu otrzymanych obrazów odległości spektralnej zweryfikowano i ustalono najlepsze wg autora parametry do poprawnej klasyfikacji.

W efekcie do ponownej klasyfikacji SAM na obrazie 47-kanałowym wykorzystano siedemnaście wzorców, a na 74-kanałowym osiemnaście wzorców (tabele 8 i 9). Łączna ilość pikseli czystych spektralnie z danych wzorcowych zmniejszyła się z pierwotnych 2444 do 2084.

We wzorcach dla drugiego obrazu wprowadzono drobne zmiany. Trzy poligony reprezentujące 50-letni dąb na obszarze Wilkomiji połączono w jeden. W wyniku łączenia, uśrednianie zostały wartości wzorców. Stwierdzono, na podstawie wcześniejszych analiz, że w przypadku uśrednienia wartości z wzorców, lepsze są wyniki rozpoznania danego drzewostanu. Dodatkowo zrezygnowano z dwóch wzorców sosny: 75-letniej z Pod-

Tabela 9. Poprawione dane wzorcowe – obraz 74-kanałowy.
Table 9. Corrected data patterns – 74-channel image.

Lp. (Nr.)	Nazwa poligonu [ROI] (Region of Interest name)	Piksele (Pixels)
1	Dąb (<i>Oak</i>) Podzamcze 110 lat / years	72
2	Dąb(<i>Oak</i>) Podzamcze 35–50 lat / years	98
3	Dąb (<i>Oak</i>) Podzamcze 50–75 lat / years	18
4	Dąb (<i>Oak</i>) Wilkomija 50 lat / years	182
5	Sosna (<i>Pine</i>) Wilkomija 75 lat / years	36
6	Dąb (<i>Oak</i>) Wilkomija do 21 lat / years	39
7	Sosna (<i>Pine</i>) Wilkomija 80 lat / years	46
8	Dąb (<i>Oak</i>) Wilkomija 50 lat / years	9
9	Sosna Wilkomija 70 lat / years	57
10	Dąb (<i>Oak</i>) Wilkomija 90 lat / years	49
11	Sosna (<i>Pine</i>) Wrzosowa 40 lat / years	39
12	Sosna (<i>Pine</i>) Mzurowa do 21 lat / years	36
13	Bagna Mzurowa	45
14	Olsza Mzurowa 45 lat	30
15	Sosna (<i>Pine</i>) Mzurowa 45 lat / years	111
16	Olsza (<i>Adler</i>) Sawiska 50 lat / years	42
17	Dąb (<i>Oak</i>) Sawiska 80 lat / years	109
18	Sosna (<i>Pine</i>) Podzamcze 80 lat / years	18

zamcza oraz 80-letniej z Wilkomiji. Powodowały one to, że program klasyfikował je na niekorzyść innych wzorców. Liczba pikseli czystych spektralnie, wykorzystywanych do wzorców nieznacznie zmalała w stosunku do pierwotnego (z 1128 do 1036).

Po ustaleniu wzorców przystąpiono do określenia progów odległości spektralnych dla każdego z nich. Program przy procesie klasyfikacji wprowadza domyślną wartość 0,1 radiana dla każdego ROI. W ostateczności do klasyfikacji obu obrazów ze skanera Hyperion wprowadzono nowy próg 0,04 radiana. Jedynie w kilku przypadkach zmieniono wartości progów. W tabeli 10 przedstawiono progi dla wybranych klas. W przypadku poprawnego rozpoznania olszy na pierwszym obrazie parametr progowania musiał być ustawiony na 0,015 radiana, podczas gdy na drugim wynosi on niecałe 0,04. W pozostałych przypadkach wartości progów dla obu obrazów są zbliżone.

Po przeprowadzeniu klasyfikacji uzyskano mapy z klasami drzewostanów. Na pierwszej wyróżniono osiemnaście klas; na drugiej siedemnaście. Liczba powstałych klas wynikała z liczby przygotowanych wzorców. Następnie połączono obszary o tych samych cechach drzewostanów. W efekcie na poprawionych mapach zostało osiem klas: siedem klas drzewostanu oraz oddzielną klasę bagna. Poniżej podano zestawienie klas drzewostanów, które udało się rozpoznać: 1. Sosna do 21 lat; 2. Sosna 30–50 lat, 3. Sosna 70–90 lat, 4. Olsza 50 lat, 5. Dąb do 21 lat, 6. Dąb 40–50 lat, 7. Dąb 90–120 lat.

Ostatnim etapem przed przystąpieniem do analizy dokładności klasyfikacji była generalizacja wyników. Mapy wynikowe opracowano w skali 1: 25 000. Dlatego

Tabela 8. Poprawione dane wzorcowe – obraz 47-kanałowy.
Table 8. Corrected data patterns – 47-channel image.

Lp. (Nr.)	Nazwa poligonu [ROI] (Region of Interest name)	Piksele (Pixels)
1	Dąb (<i>Oak</i>) Podzamcze 110 lat / years	181
2	Dąb (<i>Oak</i>) Podzamcze 45 lat / years	33
3	Dąb (<i>Oak</i>) Podzamcze 35–50 lat / years	129
4	Dąb (<i>Oak</i>) Podzamcze 110 lat / years	78
5	Dąb (<i>Oak</i>) Podzamcze 95 lat / years	39
6	Sosna (<i>Pine</i>) Podzamcze 45 lat / years	66
7	Dąb (<i>Oak</i>) Wilkomija 40 lat / years	592
8	Bagna (<i>Swamps</i>) Wilkomija	63
9	Dąb (<i>Oak</i>) Wilkomija do 21 lat / years	90
10	Dąb (<i>Oak</i>) Wilkomija 120 lat / years	81
11	Sosna (<i>Pine</i>) Wilkomija 80 lat / years	36
12	Sosna (<i>Pine</i>) Choiny 45 lat / years	95
13	Sosna (<i>Pine</i>) Mzurowa do 21 lat / years	99
14	Bagna (<i>Swamps</i>) Mzurowa	81
15	Sosna (<i>Pine</i>) Mzurowa 45 lat / years	355
16	Olsza (<i>Adler</i>) Sawiska 50 lat / years	30
17	Sosna (<i>Pine</i>) Podzamcze 80–90 lat / years	36

Tabela 10. Progi odległości spektralnej do poprawnego klasyfikowania drzewostanu (w rad)
 Table 10. Spectral angle thresholds (rad)

Obraz (Image) Drzewostan (Forest stand)	Olsza (Sawiska) 50-lat (Alder 50 years old)	Dąb (Wilkomija) do 21 lat (Oak less than 21 years old)	Sosna (Mzurowa) do 21 lat (Pine less than 21 years old)
Obraz 47-kanalowy (47-channel image)	0,015	0,026	0,039
Obraz 74-kanalowy (74-channel image)	0,035	0,022	0,031

też istotnym był proces generalizacji, czyli zmniejszenia szczegółowości obrazów. Wychodząc z założeń metodycznych programu CORINE Land Cover, w którym najmniejszą powierzchnię określono na 25 ha przy skali 1: 100 000 (CORINE Land Cover Technical Guide, 1993), przyjęto na opracowaniach map za najmniejszą powierzchnię obszar 6, 25 ha.

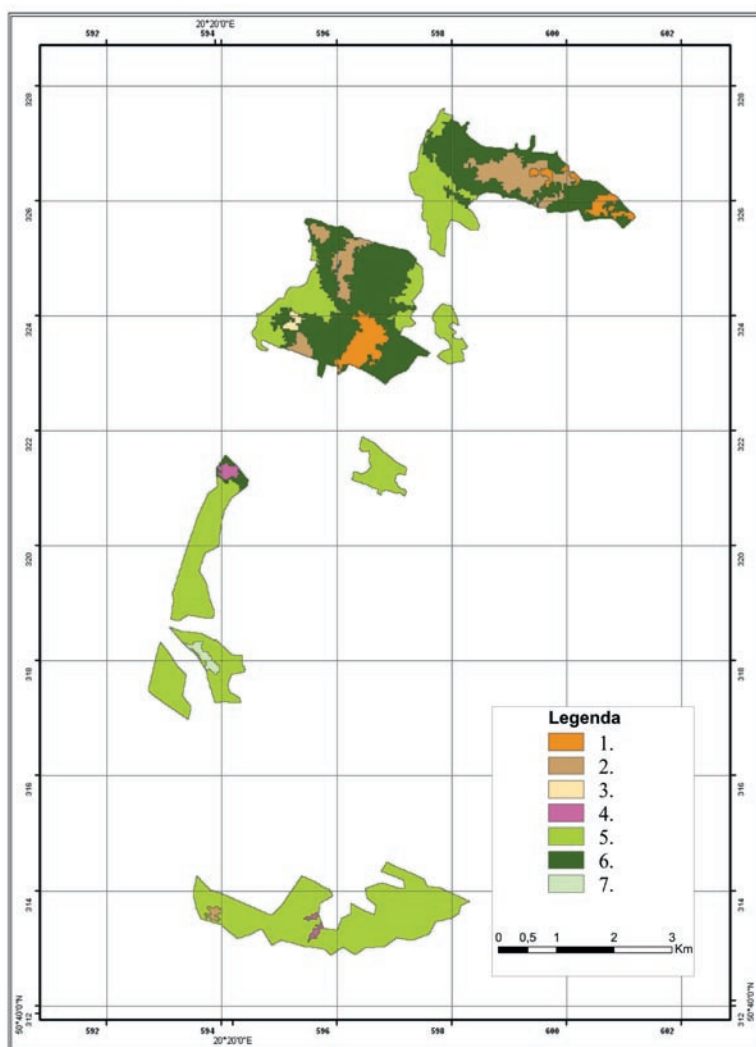
Proces generalizacji przeprowadzono w oprogramowaniu ArcGIS. Zlokalizowano wszystkie powierzchnie o mniejszej niż w założeniu powierzchni wydzielenia i następnie automatycznie zostały one poddane generalizacji. W efekcie klasa bagien została wyeliminowana, gdyż zajmowały one powierzchnię około 5 ha. Na ryc. 12 i 13 przedstawiono ostateczne wersje wyników klasyfikacji, zmniejszone do skali 1: 50 000. Po procesie generalizacji przystąpiono do analiz dokładności wyników klasyfikacji.

Ocena dokładności klasyfikacji

Stopień rozpoznania

A. Ciołkosz, J. Miszański, J. R. Olędzki (1999) podając metodykę oceny dokładności interpretacji obrazów stwierdzają, że wartość osiągniętych rezultatów interpretacji określają stopień rozpoznania, wiarygodność i dokładność interpretacji. W niniejszym opracowaniu zastosowano dwie pierwsze metody oceny. Analizę rozpoznania wykonano w programie ENVI 4.3, natomiast ocenę wiarygodności w oprogramowaniu Erdas IMAGE 8.3.

Stopień rozpoznania przedstawia procent rozpoznanych obiektów w stosunku do ogólnej liczby obiektów odtworzonych na obrazie. W przypadku tej pracy, wyznaczono pola testowe do oceny poprawnego rozpoznania drzewostanów na obu obrazach wynikowych. Na podstawie klasyfikacji SAM na obrazach rozpoznano siedem klas drzewostanów (po trzy klasy sosny i dębu oraz olszę). Sprawdzano poprawność rozpoznania dla każdej klasy oddzielnie. Etap przygotowania pól treningowych polegał na wyznaczeniu kilku obszarów reprezentujących daną klasę. Kryterium, regulującym wyznaczenie klas referencyjnych było szukanie reprezentatywnego obszaru lasów dla danej klasy drzewostanów. W efekcie powstał zbiór danych, zidentyfikowanych jako właściwe dane odpowiadające rzeczywistej lokalizacji poszczególnych drzew. Etap rozpoznania wykonano analogicznie na dwóch obrazach wynikowych.



Ryc. 12 Ostateczna klasyfikacja drzewostanów na obrazie 47-kanalowym. Legenda: 1. Dąb do 21 lat; 2. Dąb 40–50 lat; 3. Dąb 90–120 lat; 4. Olsza 50 lat; 5. Sosna do 21 lat; 6. Sosna 30–50 lat; 7. Sosna 70–90 lat.

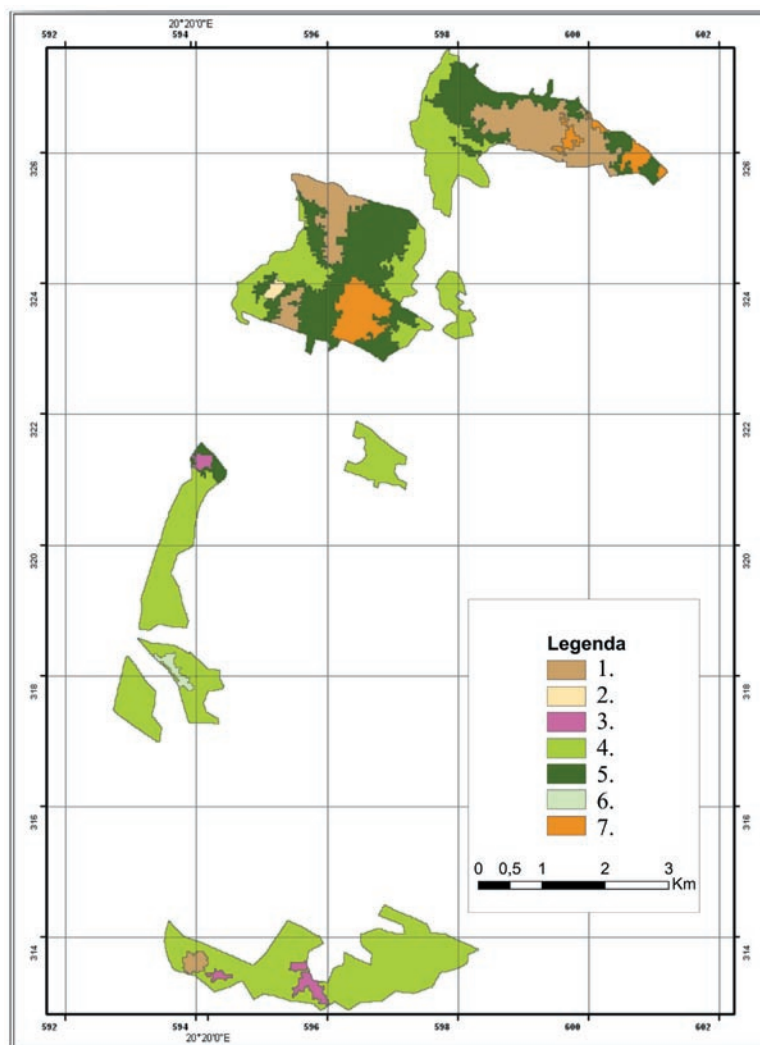
Fig. 12 Final forest classification on 47-channel image. Legend: 1. Oak less than 21 years old; 2. Oak 40–50 years old; 3. Oak 90–120 years old; 4. Alder 50 years old; 5. Pine less than 21 years old; 6. Pine 30–50 years old; 7. Pine 70–90 years old.

W tabelach (11, 12) podano raporty stopnia rozpoznania. Pierwsze części raportów przedstawiają dokładności rozpoznania oraz wartości współczynnika kappa. Dokładność rozpoznania (tzw. producenta) mówi o tym, jaki procent wszystkich pikseli klas referencyjnych (pól testowych) zostało poprawnie rozpoznanych na sklasyfikowanym obrazie. Z kolei współczynnik kappa wyraża proporcjonalną redukcję błędów powstających w czasie procesu klasyfikacyjnego, w porównaniu z błędem klasyfikacji realizowanej przypadkowo (ERDAS Field Guide, 1998).

W tabelach *Poprawność rozpoznanych klas (w pikselach oraz w %)* kolumny przedstawiają wyznaczone klasy referencyjne a wiersze klasy drzewostanów z obrazów klasyfikowanych. Rozpoznanie polega na zlokalizowaniu i sprawdzeniu czy dany piksel z pola testowego klasy referencyjnej jest tak samo zidentyfikowany na obrazie sklasyfikowanym. Wyniki tego procesu przedstawiają dokładności producenta. Wyrażone są w ilościach pikseli oraz stosunku procentowym. Jeśli piksel nie został poprawnie zlokalizowany, to raporty podają również do jakiej innej klasy został on przypisany – tzw. dokładność użytkownika. Ta statystyka pokazuje wartość pikseli poprawnie rozpoznanych do ogólnej liczby pikseli uznanych za tę klasę na obrazie wynikowym (ERDAS Field Guide, 1998).

Lepsze wyniki uzyskano z obrazu 74-kanalowego. Dokładność rozpoznania drzewostanów na pierwszym obrazie wynosiła 76,6%, podczas gdy na drugim 88,8%. Natomiast współczynniki kappa wynosiły odpowiednio 0.70 i 0.85. Oznacza to, że w przypadku pierwszego obrazu proces klasyfikacji pominął 70% błędów, które mogłaby generować klasyfikacja całkowicie przypadkowa. W przypadku drugiego obrazu sklasyfikowanego, proces pominął 85%.

Analizując pierwszy wykaz, nietrudno dostrzec że najlepsze wyniki uzyskano przy rozpoznaniu sosny do lat 21 (100%), sosna 70–90 lat (96.4%), dębu 40–50 lat (88.1%) i dębu 90–120 lat (83.3%). Natomiast pozostałe klasy identyfikowano poprawnie na obrazie sklasyfikowanym w granicach 60–70%. Najgorszy rezultat dała sosna 30–50 lat (jedynie 31% pikseli referencyjnych poprawnie zaklasyfikowanych na obrazie). Podane wyżej dane procentowe przedstawiają wartości dokładności producenta. Rozbieżności pomiędzy rezultatami zlokalizowania klas wynikają z kilku powodów. Pierwszy: uzyskane wyniki zależą od wskazanych pól referencyjnych. Im mniejsze obszary tym, lepsze rezultaty identyfikacji. W przypadku drzewostanów występujących w mniejszości, procenty rozpoznania będą dużo wyższe



Ryc. 13 Ostateczna klasyfikacja drzewostanów na obrazie 74-kanalowym. Legenda: 1. Dąb do 21 lat; 2. Dąb 40–50 lat; 3. Dąb 90–120 lat; 4. Olsza 50 lat; 5. Sosna do 21 lat; 6. Sosna 30–50 lat; 7. Sosna 70–90 lat.

Fig. 13 Final forest classification on 74-channel image. Legend: 1. Oak less than 21 years old; 2. Oak 40–50 years old; 3. Oak 90–120 years old; 4. Alder 50 years old; 5. Pine less than 21 years old; 6. Pine 30–50 years old; 7. Pine 70–90 years old.

niż tych zajmujących największe powierzchnie. Drugi: reprezentatywność poligonów testowych. Jeśli wskaźnik obszar (np. olszy), w którym rzeczywiście występuje ten gatunek, lecz na obrazie jest często mylony z innym gatunkiem, to wyniki dokładności będą niższe. Potwierdzenie znajduje się w tabeli 11, gdzie w przypadku dębu do 21 lat i sosny 30–50 lat, znaczna część pikseli referencyjnych została błędnie sklasyfikowana na obrazie hiperspektralnym. Natomiast obserwując wyniki dokładności użytkownika, łatwo dostrzec że cztery klasy drzewostanów zostały w 100% zaklasyfikowane, a najgorsze wyniki prezentuje sosna w wieku 30–50 lat i 70–90 lat.

Z kolei drugi raport (tabela 12) przedstawia bardzo dobre wyniki. Na siedem klas sześć zostało poprawnie rozpoznanych z dokładnością w granicach 80–100%. Jedynie klasa sosny 30–50-letniej dała najgorsze wyniki

Tabela 11.cd (continued)

Klasa z obrazu (Image class)	Dokładności (<i>Producent and User</i>)		i użytkownika (<i>Accuracies</i>)	
	Dokładność producenta (<i>Prod. Acc.</i>) [%]	Dokładność użytkownika (<i>User Acc.</i>) [%]	Dokładność producenta (<i>Prod. Acc.</i>) [Nr. of pixels]	Dokładność użytkownika (<i>User Acc.</i>) [Nr. of pixels]
Sosna do 21 lat (<i>Pine < 21</i>)	100.00	100.00	244/244	244/244
Dąb do lat 21 (<i>Oak < 21</i>)	61.66	100.00	238/386	238/238
Dąb 40–50 lat (<i>Oak 40–50</i>)	88.06	100.00	686/779	686/686
Dąb 90–120 lat (<i>Oak 90–120</i>)	83.29	98.52	2856/3429	2856/2899
Olsza 50 lat (<i>Adler 50</i>)	66.83	100.00	802/1200	802/802
Sosna 30–50 lat (<i>Pine 30–50</i>)	31.31	60.55	350/1118	350/578
Sosna 70–90 lat (<i>Pine 70–90</i>)	96.42	48.86	1480/1535	1480/3029

Całkowita dokładność=(6656/8691) 76,59%

(*Overall Accuracy*)

Współczynnik Kappa = 0,6984

(*Kappa Coefficient*)

ki. Sytuacja powtarza się analogicznie jak na pierwszym sklasyfikowanym obrazie. Mimo, że ta sama klasa ponownie została najbliżej rozpoznana, to jednak widać duże różnice w lokalizowaniu pikseli referencyjnych tego drzewostanu. Na pierwszym obrazie, poprawność wynosiła 30%, na drugim prawie 70%. Oznacza to, że osiągnięto prawie dwukrotnie lepszy rezultat w stosunku do poprzedniego, choć nie zadowalający do końca. W podsumowaniu, w końcowej części raportu zestawiono wyniki dokładności producenta i użytkownika. Są one poprawne i pozwalają stwierdzić, że rozpoznanie drzewostanów było bardziej poprawne na obrazie 74-kanalowym.

Stopień wiarygodności

Do oceny wiarygodności obrazów sklasyfikowanych użyto opcję *Accuracy Assessment* (AA) w programie Erdas IMAGINE 8.3. Opcja ta służy oszacowaniu dokładności klasyfikacji, lecz w tym przypadku będzie wykorzystywana również do oceny stopnia wiarygodności uzyskanych wyników. *Accuracy Assessment* polega na porównaniu klasyfikacji z danymi geograficznymi np. mapami lub też danymi sprawdzonymi w terenie (Erdas Field Guide, 1998)

W przewodniku Erdas Field Guide podano, że na ogół nie praktykuje się terenowego sprawdzania lub jakiegokolwiek innego testowania każdego piksela sklasyfikowanego obrazu. R. Congalton (1991) wskazał zastosowanie zbioru pikseli odniesienia do oszacowania dokładności opracowania interpretacyjnego. Piksele te są punktami obrazu sklasyfikowanego, dla których zna-

ne są (lub będą) aktualne dane. Są one wybierane losowo. Autor zwrócił uwagę również na wyznaczanie liczby pikseli odniesienia. Wykazał, że w celu oszacowania średniej dokładności z dokładnością $\pm 5\%$ potrzebnych jest ponad 250 pikseli odniesienia. W pracy do każdego obrazu sklasyfikowanego wygenerowano po 260 wybranych losowo punktów kontrolnych.

Raporty oceny wiarygodności załączono na końcu pracy (tabele 13, 14). Każdy raport składa się z trzech części: macierzy błędów, dokładności klasyfikacji oraz statystyki kappi. Pierwszy służy do przyrównania punktów odniesienia (czyli odpowiadających rzeczywistości) względem punktów klasyfikowanych na obrazie. Natomiast dwa następne zostały omówione przy ocenie stopnia rozpoznania.

W tabeli 15 zestawiono liczby punktów kontrolnych przedstawiające konkretną klasę (dla obu oszacowań dokładności). Na obrazach wyznaczono losowo najwięcej punktów referencyjnych dla sosny 30–50-letniej. W przypadku losowego wyboru pikseli odniesienia zachodzi proporcja, że im większe powierzchnie danej klasy tym więcej punktów referencyjnych zostaje dla niej wybranych. Z kolei najmniejszym wydzieleniom drzewostanów przypada najmniej punktów kontrolnych. Automatem losowy wybór tych pikseli nie był kierowany żadnymi zasadami, stąd widoczne zbliżone rozkłady danych referencyjnych dla obu obrazów sklasyfikowanych

Analizując macierz błędów w tabeli 13, można dostrzec że klasa dębu 90–120-letniego była poprawnie identyfikowana jedynie w 23 przypadkach (na 51 punktów referencyjnych). Natomiast pozostałe klasy drzewostanów zostały poprawnie identyfikowane.

Tabela 12.cd (continued)

(Klasa z obrazu (Image class))	Dokładności (<i>Producer</i> i <i>User</i>)		użytkownika (<i>Accuracies</i>)	
	Dokładność producenta (<i>Prod. Acc.</i>) [%]	Dokładność użytkownika (<i>User Acc.</i>) [%]	Dokładność producenta (<i>Prod. Acc.</i>) [Nr. of pixels]	Dokładność użytkownika (<i>User Acc.</i>) [Nr. of pixels]
Sosna do 21 lat (<i>Pine < 21</i>)	96.31	100.00	235/244	235/235
Dąb do lat 21 (<i>Oak < 21</i>)	98.19	100.00	379/386	379/379
Olsza 50 lat (<i>Adler 50</i>)	79.58	100.00	955/1200	955/955
Sosna 30–50 lat (<i>Pine 30–50</i>)	69.41	94.75	776/1118	776/819
Dąb 90–120lat (<i>Oak 90–120</i>)	94.23	98.57	3231/3429	3231/3278
Sosna 70–90 lat (<i>Pine 70–90</i>)	96.48	68.85	1481/1535	1481/2151
Dąb 40–50 lat (<i>Oak 40–50</i>)	84.60	100.00	659/779	659/659

Całkowita dokładność = (7716/8691) 88.78%
(*Overall Accuracy*)

Współczynnik Kappa = 0.8544
(*Kappa Coefficient*)

W drugiej części raportu (tabela 13) przy dokładności klasyfikacji podano wartości producenta i użytkownika. Wyniki te pozwalają na głębsze analizowanie wiarygodności klasyfikacji. Dokładność producenta pokazuje, że liczba wybranych losowo pikseli odniesienia zaklasyfikowanych prawie do każdej klasy odpowiada zbliżonej liczbie poprawnie zidentyfikowanych pikseli. Najlepsze wyniki uzyskano dla dębu 90–120-letniego (45%). Oznacza to, że przy losowym generowaniu punktów kontrolnych program wyznaczył 51 punktów zaklasyfikowanych na obrazie jako dąb 90–120-letni, lecz tylko 23 z 51 odpowiadało rzeczywistości. Pozostałe zostały zaliczone do innej klasy drzewostanu.

Dokładność użytkownika wskazuje ile pikseli jest zidentyfikowanych poprawnie w stosunku do liczby pikseli odpowiadających tej klasie na obrazie wynikowym. Ta dokładność, w zasadzie ma najważniejsze znaczenie do oceny wiarygodności uzyskanych wyników. Ma ona to do siebie, że w stosunku do dokładności producenta, zachodzą tu zależności odwrotnie proporcjonalne. W przypadku pierwszego obrazu, najlepsze rezultaty uzyskano dla trzech klasach drzewostanów: dębu do 21 lat i olszy 50 lat – 100% oraz sosny 30–50 lat i dębu 90–120 lat (odpowiednio 93,6% i 88,5%). Odnosnie najstarszej klasy dębu, mimo że dokładność producenta wynosiła 45%, to użytkownika osiągnęła 88,5%. Całkowita dokładność klasyfikacji wynosiła 73,85%.

Statystyki kappa pokazują, że najmniej poprawnie zaklasyfikowano sosnę do 21 lat – współczynnik kappa wyniósł 0,32. Oznacza to, że jedynie w 30% uniknięto błędu, gdyby program wykonywał klasyfikację zupełnie

losową. Niskie wartości uzyskano także dla sosny 70–90 lat i dębu 40–50 lat; odpowiednio 0,41 i 0,59. Całkowity współczynnik kappa wyniósł 0,62.

Raport (tabela 14) wskazuje zdecydowaną poprawę wyników wiarygodności drugiego obrazu w stosunku do pierwszego. Całkowita dokładność klasyfikacji wynosi prawie 91% (podczas gdy dla pierwszego niecałe 74%). Natomiast wartość kappa w stosunku do poprzedniego wzrosła do 0,871.

Macierz błędów wskazuje na bardzo dobre wyniki w poprawnym identyfikowaniu wszystkich pikseli odniesienia w stosunku do liczby pikseli referencyjnych. Najwięcej błędów było dla sosny 30–50-letniej, jednakże liczba 7 niepoprawnie przypisanych pikseli w stosunku do 114 referencyjnych jest marginalnym błędem klasyfikacji w tej klasie. W pozostałych klasach liczba błędów nie przekroczyła 5 pikseli.

Statystyki dokładności producenta i użytkownika pokazują prawidłowe sklasyfikowanie drzewostanów na obrazie 74-kanalowym. Według programu, najgorsze wyniki uzyskano dla dębu do 21 lat, a stuprocentową skuteczność wykazano dla sosny do 21 lat. Natomiast od strony użytkownika, dwie klasy osiągnęły wynik 100%: olsza 50-letnia, dąb 90–120-letni. Ogółem dla każdej klasy uzyskano zadowalające wyniki. Prawie każdy punkt kontrolny i przypisana jemu klasa drzewostanu była zgodna.

Statystyki kappa potwierdzają wcześniejsze wyniki w raporcie. Uniknięto 87% błędów w procesie klasyfikacji względem błędów klasyfikacji losowej. Na końcu analizy w celu porównania osiągniętych wyników zestawiono je w tabelach 15 i 16.

Tabela 13. Raport z oszacowania dokładności klasyfikacji – stopnia wiarygodności – obraz 47-kanalowy.

Table 13. Accuracy Assessment Report – Reliability Analysis – 47-channel image

MACIERZ BŁĘDÓW (ERROR MATRIX)

Klasa z obrazu (Image class)	Punkty kontrolne (Control Points)						
	Sosna 30–50 lat (Pine 30–50)	Dąb 90–120 lat (Oak 90–120)	Dąb do lat 21 (Oak < 21)	Sosna 70–90 lat (Pine 70–90)	Dąb 40–50 lat (Oak 40–50)	Olsza 50 lat (Adler 50)	Sosna do 21 lat (Pine < 21)
	0	0	0	0	0	0	0
Sosna 30–50 lat (Pine 30–50)	88	2	0	3	0	1	0
Dąb 90–120lat (Oak 90–120)	0	23	0	2	1	0	0
Dąb do lat 21 (Oak < 21)	0	0	2	0	0	0	0
Sosna 70–90 lat (Pine 70–90)	16	25	1	62	3	1	0
Dąb 40–50 lat (Oak 40–50)	1	1	0	5	11	0	0
Olsza 50 lat (Adler 50)	0	0	0	0	0	3	0
Sosna do 21 lat (Pine < 21)	6	0	0	0	0	0	3
Ogółem (Overall)	111	51	3	72	15	5	3

OSZACOWANIE DOKŁADNOŚCI
(ACCURACY ASSESSMENT)STATYSTYKI KAPPA
(OVERALL KAPPA STATISTICS)

Klasa (Image class)	Referencyj- ne ogółem (Control P.)	Zaklasyfiko- wane ogółem (Classified)	Poprawnie zidentyfiko- wane (Correctly)	Dokładność Producenta (Prod.Acc.)	Dokładność Użytkow- nika (User Acc.)	Klasa (Image class)	Kappa
Sosna 30–50 lat (Pine 30–50)	111	94	88	79.28%	93.62%	Sosna 30–50 lat (Pine 30–50)	0.8886
Dąb 90–120lat (Oak 90–120)	51	26	23	45.10%	88.46%	Dąb 90–120 lat (Oak 90–120)	0.8565
Dąb do lat 21 (Oak < 21)	3	2	2	66.67%	100.00%	Dąb do lat 21 (Oak < 21)	1.0000
Sosna 70–90 lat (Pine 70–90)	72	108	62	86.11%	57.41%	Sosna 70–90 lat (Pine 70–90)	0.4110
Dąb 40–50 lat (Oak 40–50)	15	18	11	73.33%	61.11%	Dąb 40–50 lat (Oak 40–50)	0.5873
Olsza 50 lat (Adler 50)	5	3	3	60.00%	100.00%	Olsza 50 lat (Adler 50)	1.0000
Sosna do 21 lat (Pine < 21)	3	9	3	100.00%	33.33%	Sosna do 21 lat (Pine < 21)	0.3256
Ogółem (Overall)	260	260	192				

Całkowita dokładność klasyfikacji (Overall Accuracy)
= 73.85%

Całk. współ. Kappa (Overall Kappa Coefficient)
= 0.6297

Tabela 14.: Raport z oszacowania dokładności klasyfikacji – stopnia wiarygodności – obraz 74-kanalowy.
 Table 14. Accuracy Assessment Report – Reliability Analysis –74-channel image

MACIERZ BŁĘDÓW (ERROR MATRIX)							
Klasa z obrazu (Image class)	Punkty kontrolne (Control Points)						
	Dąb 40–50 lat (Oak 40–50),	Olsza 50 lat (Adler 50)	Sosna 30–50 lat (Pine 30–50)	Dąb 90–120 lat (Oak 90–120)	Dąb do 21 lat (Oak < 21)	Sosna 70–90 lat (Pine 70–90)	Sosna do 21 lat (Pine < 21)
Dąb 40–50 lat (Oak 40–50)	14	0	0	0	0	4	0
Olsza 50 lat (Adler 50)	0	12	0	0	0	0	0
Sosna 30–50 lat (Pine 30–50)	0	1	106	1	0	1	0
Dąb 90–120 lat (Oak 90–120)	0	0	0	45	0	0	0
Dąb do 21 lat (Oak < 21)	0	0	0	0	6	1	0
Sosna 70–90 lat (Pine 70–90)	3	0	7	4	1	46	0
Sosna do 21 lat (Pine < 21 years)	0	0	1	0	0	0	7
Ogółem (Overall)	17	13	114	50	7	52	7

OSZACOWANIE DOKŁADNOŚCI
(ACCURACY ASSESSMENT)

STATYSTYKI KAPPA
(OVERALL KAPPA STATISTICS)

Klasa (Image class)	Referencyjne Ogółem (Control P.)	Zaklasyfikowane Ogółem (Classified)	Poprawnie zidentyfikowane (Correctly)	Dokładność Producenta (Prod. Acc.)	Dokładność Użytkownika (User Acc.)	Klasa (Class image)	Kappa
Dąb 40–50 lat (Oak 40–50)	17	18	14	82.35%	77.78%	Dąb 40–50 lat (Oak 40–50)	0.7622
Olsza 50 lat (Adler 50)	13	12	12	92.31%	100.00%	Olsza 50 lat (Adler 50)	1.0000
Sosna 30–50 lat (Pine 30–50)	114	109	106	92.98%	97.25%	Sosna 30–50 lat (Pine 30–50)	0.9510
Dąb 90–120lat (Oak 90–120)	50	45	45	90.00%	100.00%	Dąb 90–120lat (Oak 90–120)	1.0000
Dąb do 21 lat (Oak < 21)	7	7	6	85.71%	85.71%	Dąb do 21 lat (Oak < 21)	0.8532
Sosna 70–90 lat (Pine 70–90)	52	61	46	88.46%	75.41%	Sosna 70–90 lat (Pine 70–90)	0.6926
Sosna do 21 lat (Pine < 21 years)	7	8	7	100.00%	87.50%	Sosna do 21 lat (Pine < 21 years)	0.8715
Ogółem (Overall)	260	260	236				

Całkowita dokładność dokładności (Overall Accuracy) = 90.77%

Całk. współ. Kappa (Overall Kappa Coefficient) = 0.8731

Tabela 15. Liczba pikseli odniesienia zaklasyfikowanych na obrazach wynikowych.

Table 15. Number of Control Points based on both images.

Ogółem

Obraz (Image) / Drzewostan (Forest stand)	Sosna (Pine) < 21 lat / years	Sosna (Pine) 30–50 lat / years	Sosna (Pine) 70–90 lat / years	Olsza (Adler) 50 lat / years	Dąb (Oak) < 21 lat / years	Dąb (Oak) 40–50 lat / years	Dąb (Oak) 90–120 lat / years	Ogółem (Overall).
Obraz 47-k.	9	94	108	3	2	18	26	260
Obraz 74-k.	8	109	61	12	7	18	45	260

Tabela 16. Zestawienie dokładności wiarygodności.

Table 16. Comparison of Recognition Analysis.

Obraz (Image)	Dokładność (Accuracy)	
	Dokładność całkowita (Overall Accuracy) [%]	Współczynnik kappi (Kappa Coefficient)
Obraz 47-k.	73,85%	0,63
Obraz 74-k.	90,77%	0,87

Literatura:

- Beaubien J., 1979, *Forest Type Mapping from Landsat Digital Data*, Photogrammetric Engineering Remote Sensing, t. 45, z. 8.
- Bochenek Z., Iracka M., 1996, *Wykorzystanie systemu przetwarzania obrazów ERDAS IMAGINE do klasyfikacji obrazów leśnych* (w:) SIP VI Konferencja Naukowo-Techniczna, Warszawa.
- Bochenek Z., Polawski Z., Zawila-Niedźwiecki T., 1987, *Wykorzystanie zdjęć Landsat Thematic Mapper do badania zdegradowanych obszarów leśnych na przykładzie Sudetów Zachodnich*, Prace IGIK, t. 34, z. 2, s. 59.68.
- Buddenbaum B., Schlerf M., Hill J., 2005, *Classification of coniferous tree species and age classes using hyperspectral data and geostatistical methods*, International Journal of Remote Sensing, t. 26, z. 20, s. 5453–5465.
- Coburn C. A., Roberts A. C. B., 2004, *A multiscale texture analysis procedure for improved forest stand classification*, International Journal of Remote Sensing, t. 25, z. 20, s. 4287–4308.
- Congalton R., 1991, *A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data*, Remote Sensing of Environment, t. 37, s. 35–46.
- ENVI Application Help. Pomoc w programie ENVI wersja 4.3
- ERDAS Field Guide. Przewodnik geoinformatyczny, 1998, GEOSYSTEMS Polska, Warszawa.
- Goodenough D. G., Dyk A., Niemann O., 2003, *Processing Hyperion and ALI for Forest Classification*, IEEE Transactions on Geoscience and Remote Sensing, t. 41, z. 6, s. 1321–1331.
- Gopal, S., Woodcock, C., 1996, *Remote sensing of forest change using artificial neural networks*, IEEE Transactions on Geoscience and Remote Sensing, t. 34, z. 2, s. 398–404.
- Hejmanowska B., 2004, *Wykorzystanie naziemnych pomiarów spektrometrycznych do kalibracji hiperspektralnych zobrażeń lotniczych i satelitarnych na przykładzie reliktywanego obszaru Tarnobrzeskiego Zagłębia Siarkowego*, Projekt badawczy, AGH.
- Iracka M., Wiśniewska E., Zawila-Niedźwiecki T., 1999, *Tematyka leśna w aktualnych pracach badawczych*, Biul. Inf. BOINTE Geod. i Kart., z. 3–4, s. 25–34.
- Królak B., 2006, *Możliwość zastosowania teledetekcji oraz GIS w celu określenia wybranych cech drzewostanu*, Sylwan, z. 8, s. 3–10.
- Kushwaha S. P. S., Kuntz S., Oesten, 1994, *Application of image texture in forest classification*, International Journal of Remote Sensing, t. 15, z. 11, s. 2273–2284.
- Lumme J., 2005, *Forest Classification Using High Spectral and Spatial Resolution Data*, 4th EARSeL Workshop on Imaging Spectroscopy. New quality in environmental studies, s. 611–616.
- Magnussen S., Boudewyn P., Wulder M., 2004, *Contextual classification of Landsat TM images to forest inventory cover types*, International Journal of Remote Sensing, t. 25, z. 12, z. 2421–2440.
- Mozgawa J., Piekarski E., Olenderek H., Będkowski K., 2000, *Fotogrametria i teledetekcja w leśnictwie w Polsce* (w:) Fotogrametria, teledetekcja i GIS u progu trzeciego tysiąclecia, Archiwum Fotogrametrii, Kartografii i Teledetekcji, t. 10, Kraków.
- Pal M., 2005, *Random forest classifier for remote sensing classification*, International Journal of Remote Sensing, t. 26, z. 1, s. 217–222.
- Wężyk P., Wertz B., 2005, *Forest Map Revision Using The Hyperspectral Scanner AISA Images*, 4th EARSeL Workshop on Imaging Spectroscopy. New quality in environmental studies, s. 617–629.
- Wiśniewska E., Zawila-Niedźwiecki T., 1998, *Klasyfikacja treści leśnej zdjęć satelitarnych*, Prace IGIK, t. XLV, z. 97, s. 157–167.
- Wolter P. T., Mladenoff D. J., Host G. E., Crow. T. R., 1995, *Improved forest classification in the northern lake states using multi-temporal Landsat imagery*, Photogrammetric Engineering & Remote Sensing, t. 61, s. 1129–1143.
- Zawila-Niedźwiecki T., 1994, *Ocena stanu lasu w ekosystemach zagrożonych z wykorzystaniem zdjęć satelitarnych i systemu informacji przestrzennej*, Prace IGIK, t. XLI, z. 90.

<http://eo1.usgs.gov> – oficjalna strona satelity EO-1 oraz charakterystyka skanera Hyperion

<http://www.mapa.szukacz.pl> – interaktywna mapa Polski

<http://www.radom.lasy.gov.pl> – strona o lasach Nadleśnictwa Jędrzejów

<http://www.radom.lasy.gov.pl> – strona o lasach Nadleśnictwa Kielce

<http://www.microimages.com/documentation/cplates/61Ppi.pdf>



Mgr Maciej Bartold, absolwent Wydziału Geografii i Studiów Regionalnych Uniwersytetu Warszawskiego, ze specjalnością geoinformatyka-teledetekcja. Zainteresowania naukowe: satelitarne badania roślinności, techniki klasyfikacyjne obrazów. e-mail: maksb@wp.pl