

MARTYNA WIETECZA, ANETA MODZELEWSKA, KRZYSZTOF STEREŃCZAK

Wykorzystanie lotniczej teledetekcji hiperspektralnej w klasyfikacji gatunkowej lasów strefy umiarkowanej*

Airborne hyperspectral data for the classification of tree species
a temperate forests

ABSTRACT

Wietecha M., Modzelewska A., Stereńczak K. 2017. Wykorzystanie lotniczej teledetekcji hiperspektralnej w klasyfikacji gatunkowej lasów strefy umiarkowanej. Sylwan 161 (1): 3-17.

The review focuses on use of airborne hyperspectral imagery in forest species classification. Studies mentioned in the review concern hyperspectral image classification with use of various methods. Only research, where study area is located in Europe or North America were selected. Articles were reviewed with respect to used pre-processing methods, methods of feature selection or feature extraction, algorithms of image classification and trees species which were classified. The whole process of acquiring and working with hyperspectral data is described. Different approaches (e.g. use or skip atmospheric corrections) were compared. In each article, various deciduous and conifer species were classified. Studies comparing several classification algorithms (Spectral Angle Mapper, Support Vector Machine, Random Forest) were mentioned. In most cases SVM gives the best results. Species, which are classified with the highest accuracy, include Scots pine (*Pinus sylvestris*) and Norway spruce (*Picea abies*). Broadleaved species are, in general, classified with lower accuracy than conifer ones. Within broadleaved trees, European beech (*Fagus sylvatica*) and oaks (*Quercus* sp.) are classified with the highest accuracy.

KEY WORDS

remote sensing, hyperspectral data, tree species classification

ADDRESSES

Martyna Wietecha – e-mail: m.wietecha@ibles.waw.pl

Aneta Modzelewska – e-mail: a.modzelewska@ibles.waw.pl

Krzysztof Stereńczak – e-mail: k.sterenczak@ibles.waw.pl

Instytut Badawczy Leśnictwa; Sękocin Stary, ul. Braci Leśnej 3, 05-090 Raszyn

Wstęp

Teledetekcja jest nauką zajmującą się przetwarzaniem i interpretacją informacji jakościowych pozyskanych zdalnie, najczęściej z pułapu lotniczego lub satelitarnego. W badaniach obszarów leśnych teledetekcja powszechnie wykorzystywana jest do monitorowania zmian ich powierzchni [Adams i in. 1995] oraz analizy składu gatunkowego [Martin i in. 1998] i zdrowotności [Wulder i in. 2006]. Współczesnymi przykładami wykorzystania danych teledetekcyjnych w polskim leśnictwie mogą być analizy wizualne i pomiary wykonywane na ortofotomapach, analizy wizualne zdjęć

*Publikacja powstała w ramach projektu REMBIOFOR „Teledetekcyjne określanie biomasy drzewnej i zasobów węgla w lasach” współfinansowanego ze środków Narodowego Centrum Badań i Rozwoju w ramach programu „Środowisko naturalne, rolnictwo i leśnictwo” BIOSTRATEG na podstawie umowy nr BIOSTRATEG1/267755/4/NCBR/2015.

lotniczych i satelitarnych, przetworzenia danych (korekcje radiometryczne, zmiany kontrastu i jasności, filtracja, wagowanie), cyfrowe klasyfikacje pikselowe i obiektowe, analizy teledetekcyjnych wskaźników roślinności oraz skanowanie laserowe. W ostatnim czasie obok sensorów satelitarnych i terenowych pojawiły się platformy lotnicze umożliwiające pozyskiwanie zobrażeń hiperspektralnych.

W teledetekcji hiperspektralnej wykorzystywane są dane powstałe w efekcie rejestracji odbicia promieniowania elektromagnetycznego od badanego obiektu w bardzo wąskich zakresach spektralnych. Ich szerokość (rozdzielczość spektralna) wynosi najczęściej od kilku do kilkunastu nanometrów [Vane, Goetz 1993; Zagajewski 2010]. Dane hiperspektralne, w odróżnieniu od wielospektralnych, umożliwiają pozyskanie nieprzerwanej charakterystyki spektralnej badanego obiektu zapisanej w kilkuset zakresach spektralnych. Zaletą hiperspektralnych skanerów lotniczych jest także możliwość pozyskiwania danych o stosunkowo wysokiej rozdzielczości przestrzennej. Umożliwia to analizę drzewostanów na poziomie pojedynczych koron drzew. Takie parametry rozdzielcze pozwalają na zastosowanie obrazów hiperspektralnych przy tworzeniu map gatunkowych i wykorzystywanie obrazów hiperspektralnych do dokładniejszego określania (szacowania) wybranych cech drzew i drzewostanów, w szczególności zasobności [Tompalski i in. 2014]. Ponadto integracja danych z lotniczego skanowania laserowego i mapy reprezentującej gatunki drzew (przy odpowiednio niskich kosztach) może stanowić efektywne uzupełnienie Leśnej Mapy Numerycznej (LMN), szczególnie w zakresie taksacji i inwentaryzacji drzewostanów [Stereńczak i in. 2014].

W pracy przedstawiono przegląd obecnie stosowanych metod klasyfikacji drzewostanów z wykorzystaniem teledetekcji hiperspektralnej. Uwzględnione zostały badania, w których wykorzystano dane pozyskane przy pomocy skanerów lotniczych w strefie umiarkowanych szerokości geograficznych.

Wstępne przetwarzanie obrazu

Wyróżnia się kilka etapów przetwarzania zobrażeń hiperspektralnych zmierzających do sporządzenia mapy gatunkowej. Przed wykonaniem klasyfikacji obrazu konieczne jest wyeliminowanie zakłóceń wynikających m.in. z błędów detektora, ruchu i wychyleń samolotu podczas lotu oraz wpływu warunków atmosferycznych. Następuje to podczas wstępnego przetwarzania danych. Składają się na nie, wykonywane w różnej kolejności, kalibracja radiometryczna, korekcja geometryczna oraz korekcja atmosferyczna.

Kalibracja radiometryczna skanera i obrazów polega na usunięciu szumów i zakłóceń generowanych przez sam detektor. Procedury te wykonywane są najczęściej przez dostawcę danych. W przypadku hiperspektralnych zobrażeń lotniczych bardzo ważnym elementem przetworzeń wstępnych jest korekcja geometryczna, czyli eliminacja błędów topologicznych obrazu oraz jego dowiązanie do określonego układu współrzędnych [Kurczyński, Wolniewicz 2002]. Dzięki temu możliwe jest jego właściwe wykorzystanie w systemach GIS. W większości przypadków korekcja geometryczna odbywa się w specjalistycznym oprogramowaniu, którego przykładem jest program PARGE (ang. Parametric Geocoding & Orthorectification for Airborne Optical Scanner Data) [Schlöpfer i in. 1998]. Program ten służy do przeprowadzania parametrycznej geometryzacji każdego piksela na obrazie. Spośród analizowanych w niniejszej pracy badań nad klasyfikacją gatunkową drzewostanów program ten wykorzystali Boschetti i in. [2007], klasyfikując drzewostany w Parku Krajobrazowym Ticino we Włoszech, oraz Forzieri i in. [2012], klasyfikując różne formy pokrycia terenu, w tym obszary leśne. Innym przykładem podejścia do korekcji geometrycznej są także metody oparte na Numerycznym Modelu Terenu (NMT)

wykorzystane m.in. przez zespoły Dalponte'a i in. [2014] w klasyfikacji drzewostanów borealnych w Norwegii oraz Ghosha i in. [2014], którzy przeprowadzili klasyfikację dla lasu miejskiego w Niemczech. Do korekcji geometrycznej służy również ortofotomapa, co zaprezentowane zostało w pracy analizującej możliwości wyodrębnienia trzech gatunków sosny w lasach stanu Wirginia w Stanach Zjednoczonych [van Aardt, Wynne 2007].

Zobrazowania lotnicze, podobnie jak satelitarne, mogą wymagać korekcji atmosferycznej. Jest ona potrzebna, gdyż każdy szereg nalogu wykonywany jest przy innych warunkach oświetleniowych i zmiennych warunkach atmosferycznych (przezroczystość atmosfery, obecność chmur). Jest szczególnie ważna, gdy wykonywane są analizy wieloczasowe bądź porównywane są dane z różnych obszarów lub sensorów. W przypadku danych hiperspektralnych możliwe jest zastosowanie względnych lub bezwzględnych metod korekcji. Pierwsza grupa metod charakteryzuje się obliczaniem parametrów statystycznych pozyskanych z obrazu lub z terenowych pomiarów spektrometrycznych (empiryczne techniki korekcji atmosferycznej). Przykładem metody wykorzystującej informacje zawarte w obrazie może być korekcja QUAC (ang. Quick Atmospheric Correction) [Bernstein i in. 2005] zastosowana m.in. przez Dalponte'a i in. [2014]. Autorzy zaznaczyli jednak, że jej przeprowadzenie nie polepszyło istotnie wyników klasyfikacji i ostatecznie zalecili stosowanie danych bez korekcji QUAC.

Druga grupa metod korekcji atmosferycznej opiera się na fizycznej charakterystyce rzeczywistych warunków atmosferycznych i wykorzystuje modele transferu promieniowania [Głowienka 2008]. W badaniach nad klasyfikacją drzewostanów na gatunki można spotkać się z wykorzystaniem programu ATCOR (ang. Atmospheric & Topographic Correction) [Richter 1996] lub narzędzia FLAASH (ang. Fast Line-of-sight Atmospheric Analysis of Hypercubes) [Adler-Golden i in. 1999]. Program ATCOR-4 (ang. Atmospheric & Topographic Correction for wide FOV airborne optical scanner data), przeznaczony dla danych lotniczych, z wykorzystaniem kodu radiacyjnego MODTRAN-4, zastosowali m.in. Ghosh i in. [2014]. Korekcję atmosferyczną za pomocą algorytmu FLAASH, który dostępny jest jako moduł oprogramowania ENVI, przeprowadzili natomiast Dalponte i in. [2012], analizując drzewostany w południowych Alpach, a także Jones i in. [2010], przeprowadzając klasyfikację gatunkową drzewostanów Parku Narodowego Gulf Islands w Kanadzie. Drugi z wymienionych zespołów badawczych w ramach eliminacji wpływu atmosfery na zobrazowaniach zaproponował usunięcie kanałów odpowiedzialnych za absorpcję pary wodnej, tj. 1350-1450 nm i 1796-1970 nm. Buddenbaum i in. [2005], prowadząc klasyfikację gatunków iglastych na terenie górskiego lasu w południowo-zachodniej części Niemiec, do usunięcia wpływu atmosfery zastosowali natomiast zmodyfikowany kod radiacyjny 5S-Code [Tanre' i in. 1990; Hill i in. 1995; Hill, Mehl 2003]. Niektórzy badacze wykonują z powodzeniem klasyfikację na zobrazowaniach bez korekcji atmosferycznej [van Aardt, Wynne 2007; Alonso i in. 2011; Forzieri i in. 2012; Raczko i in. 2015].

Redukcja wymiaru przestrzeni spektralnej

Ze względu na specyfikę danych hiperspektralnych (dużą liczbę kanałów spektralnych) wymagane jest przeprowadzenie redukcji zakresów promieniowania elektromagnetycznego posiadających najmniej przydatnych informacji i wykorzystanie do klasyfikacji skompresowanego zestawu danych. Umożliwia to także znaczące skrócenie czasu wykonywania przetworzeń. Do tego celu stosowane są dwie alternatywne procedury [Serpico, Moser 2007]: selekcja kanałów oryginalnych (ang. feature selection) oraz transformacja danych prowadząca do utworzenia jakościowo nowych kanałów (ang. feature extraction).

Dalponte i in. [2014] zastosowali wszystkie dostępne kanały skanera HySpex VNIR-1600 (160 kanałów z zakresu 410-990 nm). Metodę tę testowali również Ghosh i in. [2014], klasyfikując drzewostany na podstawie danych pozyskanych m.in. z lotniczego skanera hiperspektralnego HyMap (125 kanałów z zakresu 450-2480 nm, rozdzielczość przestrzenna 4 i 8 m). Porównywano ją jednocześnie z pięcioma innymi kombinacjami zestawów danych z wykorzystaniem kanałów po transformacji Minimum Noise Fraction (MNF) ze skanera HyMap i hiperspektralnego skanera satelitarnego Hyperion (146 kanałów z zakresu 400-2500 nm, rozdzielczość przestrzenna 30 m), kanałów utworzonych z obliczonych wskaźników roślinności oraz z informacjami pochodzącymi z lotniczego skanowania laserowego (ang. ALS – Airborne Laser Scanning). Każdorazowo kryterium oceny klasyfikacji jest jej dokładność całkowita, czyli iloraz sumy pikseli sklasyfikowanych poprawnie oraz całkowitej liczby pikseli weryfikacyjnych, a także współczynnik kappa, który wyraża błąd klasyfikacji (im wyższa wartość, tym błąd jest mniejszy). Wyniki pokazały, że zastosowanie wszystkich oryginalnych kanałów najlepsze rezultaty przyniosło tylko w przypadku danych o rozdzielczości 30 m (dokładność całkowita ~87%). Najlepszą dokładność klasyfikacji otrzymano natomiast dla kanałów po transformacji MNF o rozdzielczości 4 i 8 m (dokładność całkowita ~95,5%). Porównanie wyników klasyfikacji przy zastosowaniu wszystkich kanałów z zastosowaniem kanałów po selekcji przeprowadzili także Dalponte i in. [2012] (skaner AISA Eagle, 126 kanałów z zakresu 402,9-989,1 nm). W badaniach porównywano jednocześnie dwa różne klasyfikatory – algorytm maszyn wektorów wspierających (ang. SVM – Support Vector Machines) oraz algorytm losowych drzew decyzyjnych (ang. RF – Random Forest). W przypadku pierwszego klasyfikatora dokładności klasyfikacji z wykorzystaniem wszystkich kanałów i kanałów po selekcji były takie same (74,1%). Dla drugiego lepsze wyniki uzyskano przy zastosowaniu wszystkich kanałów (70,8%, przy selekcji 69,4%). Wszystkie kanały hiperspektralnego skanera HyMap (125 kanałów z zakresu 450-2480 nm) wzięto też pod uwagę, klasyfikując drzewostany w południowo-zachodnich Niemczech [Heinzel, Koch 2012]. Dokładność całkowita wyniosła w tym przypadku 64,67%.

Selekcję kanałów zastosowano do klasyfikacji gatunkowej lasów Góry Chojnik w Karkonoskim Parku Narodowym [Raczko i in. 2015]. Zaproponowano zastosowanie każdorazowo innego zestawu istniejących kanałów, z wyłączeniem kolejno jednego kanału (skaner Apex, 288 kanałów z zakresu 380-2500 nm). Klasyfikację przeprowadzono tym samym 288 razy, po czym wybrany został zestaw 40 kanałów niosących największą ilość informacji. Uzyskano dokładność klasyfikacji rzędu 78,63%. Boschetti i in. [2007], w badaniach których dokładność klasyfikacji wyniosła 75%, posłużyli się kanałami wchodzącymi w zakres promieniowania tzw. krawędzi czerwieni (ang. red edge), tj. 650-670, 690-710 i 730-750 nm (skaner MIVIS, 92 kanały z zakresu 430-2500 nm). Zakres red edge wykorzystali także Dalponte i in. [2012], stosując algorytm sekwencyjnej pływającej selekcji postępującej (ang. SFFS – Sequential Forward Floating System). Dodatkowo w wyniku selekcji wybrano również kanały spektralne z zakresu zielonego i kilka z zakresu powyżej 800 nm. Otrzymana dokładność uzależniona była od liczby klas oraz obranego klasyfikatora (43 kanały dla 6 gatunków drzew, klasy innych gatunków liściastych i klasy obiektów innych niż las – 74,1 i 70,8%, 21 kanałów dla 5 typów lasów i klasy obiektów innych niż las – 79,3 i 75,5%, 20 kanałów dla trzech klas, tj. gatunki liściaste, iglaste i obiekty inne niż las – 95,8 i 94,4% oraz 21 kanałów dla dwóch klas, tj. lasy i obiekty inne niż las – 95,5 i 98,8%). Ten sam algorytm selekcji (SFFS) wykorzystali także Dalponte i in. [2009], wybierając 32 zakresy spektralne dla klasyfikacji dwóch różnych obszarów leśnych we Włoszech z zakresu 400-970 nm (skaner AISA Eagle, 244 kanały z zakresu 400-970 nm). Forzieri i in. [2012] posłużyli się podobnym algorytmem selekcji, tj. sekwencyjnej selekcji postępującej (ang. SFS – Sequential Forward Selection). Wykorzystano

na tej podstawie 24 kanały z zakresu 441-1319 nm (skaner MIVIS, 9102 kanały z zakresu 430-12 700 nm). Podczas badań nad identyfikacją gatunkową lasów północno-wschodniego wybrzeża Kanady (Gulf Islands) Jones i in. [2010] do selekcji kanałów wykorzystali pomiary spektrometryczne wykonane w kontrolowanych warunkach laboratoryjnych (spektrometr ASD, 350-2500 nm). Ponadto ze względu na wysoki stopień zakłóceń usunięte zostały kanały z zakresów 395-429 oraz 2401-2500 nm. Na podstawie przeprowadzonych procedur liczba zastosowanych kanałów została zmniejszona z 492 (AISA Dual, 492 kanały z zakresu 396-2503 nm) do 40.

W teledetekcji hiperspektralnej najpowszechniej stosowaną metodą transformacji przestrzeni spektralnej, mającej na celu utworzenie jakościowo nowych kanałów i ograniczenie objętości danych, jest wspomniana wcześniej transformacja Minimum Noise Fraction [Green i in. 1988; Dadon i in. 2010]. Składa się ona z dwóch kaskadowych analiz głównych składowych (ang. PCA – Principal Components Analysis). W pierwszym etapie transformacji identyfikowane i odłączane są od obrazu szumy, następnie przeprowadzana jest standardowa transformacja PCA. Efektem transformacji MNF jest nowy zestaw kanałów uporządkowanych względem wariancji: od największej do najmniejszej. W kolejnych etapach pracy wykorzystywane są pierwsze kanały MNF, które pozbawione są zakłóceń i zawierają najmniej skorelowane informacje. Spośród analizowanych publikacji metodę tę do klasyfikacji gatunkowej drzewostanów zastosowali Ghosh i in. [2014], wykorzystując pierwsze 25 kanałów MNF (skaner HyMap, 126 kanałów z zakresu 450-2480 nm), a także Buddenbaum i in. [2005], wykorzystując pierwsze 10 kanałów MNF (skaner HyMap, 128 kanałów z zakresu 400-2500 nm).

Metody klasyfikacji

Klasyfikacja zobrazowań teledetekcyjnych polega na określeniu przynależności każdego piksela na obrazie do zdefiniowanej grupy obiektów – klasy. Danym hiperspektralnym poświęcone są metody nadzorowane, pikselowe, nieparametryczne oraz miękkie. W literaturze bardzo często można się też spotkać z próbami poprawienia dokładności klasyfikacji poprzez połączenie danych hiperspektralnych z danymi pozyskanymi w ramach lotniczego skanowania laserowego – ALS [Jones i in. 2010; Dalponte i in. 2012, 2014; Heinzl, Koch 2012; Latifi i in. 2012; Ghosh i in. 2014], z wykorzystaniem ortofotomapy [Heinzl, Koch 2012] bądź zobrazowań wielospektralnych [Dalponte i in. 2012].

W przypadku obszarów leśnych najczęściej stosowaną metodą klasyfikacji lotniczych zobrazowań hiperspektralnych są maszyny wektorów wspierających (SVM) [Vapnick 1998]. Jest to jedna z metod wykorzystujących tzw. systemy uczące się (ang. Machine Learning). SVM jest metodą pikselową, nieparametryczną, miękką lub twardą i nadzorowaną. Jej bardzo istotnym elementem jest proces uczenia, który obejmuje wskazanie wzorców do klasyfikacji. Przyczyną wyboru tej metody przez wielu badaczy jest przede wszystkim to, że nie odnotowuje się w jej przypadku znaczącego wpływu zjawiska Hughesa – spadku dokładności klasyfikacji po przekroczeniu pewnej liczby stosowanych kanałów [Hughes 1968]. W porównaniu z innymi metodami zastosowanie klasyfikacji SVM umożliwia uzyskanie wyższej dokładności klasyfikacji danych hiperspektralnych [Melgani, Bruzzone 2004; Dalponte i in. 2009; Alonso i in. 2011].

Przy identyfikacji gatunków drzew metoda SVM była porównywana z innymi klasyfikatorami m.in. przez Dalponte'a i in. [2012] oraz Ghosha i in. [2014]. W swoich badaniach zestawili oni ze sobą wyniki klasyfikacji SVM z efektami klasyfikacji metodą RF, która także wykorzystuje systemy uczące się i polega na stworzeniu wielu tzw. drzew decyzyjnych na podstawie losowego zestawu danych. W pierwszej pracy, dla wybranych kanałów, wyższą dokładność całkowitą klasyfikacji uzyskano, stosując metodę SVM przy identyfikacji 7 gatunków drzew i klasy

obiektów innych niż las (SVM 74,1%, RF 69,4%), 5 gatunków drzew i klasy obiektów innych niż las (SVM 79,3%, RF 75,5%) oraz 3 klasy, które stanowiły lasy iglaste, lasy liściaste i obiekty inne niż las (SVM 95,8%, RF 94,4%). Klasyfikator RF wyższą dokładność wykazał tylko w przypadku podziału obrazu na dwie klasy, którymi były obszary leśne i obiekty inne niż las (SVM 95,5%, RF 98,8%). Badania Ghosha i in. [2014] wykazały natomiast większą przydatność klasyfikatora SVM przy zastosowaniu wszystkich dostępnych kanałów, przy wszystkich testowanych wariantach rozdzielczości przestrzennej, tj. 4, 8 i 30 m (4 m – SVM 81,0%, RF 78,0%; 8 m – SVM 92,5%, RF 79,5%; 30 m – SVM 92,7%, RF 81,5%). W przypadku kanałów MNF dokładności klasyfikacji obu klasyfikatorów były porównywalne (4 m – SVM 96,5%, RF 96,0%; 8 m – SVM 96,5%, RF 94,5%, 30 m – SVM 73,0%, RF 71,0%). Dalponte i in. [2009] przedstawili wyniki klasyfikacji na 23 klasy (w tym 19 klas gatunków drzew) dla obszaru Bosco della Fontana oraz na 8 klas (w tym 6 klas gatunków drzew) dla obszaru Val di Sella w północnych Włoszech. W badaniach porównywano trzy metody: najprostszy klasyfikator wykorzystujący metodę największego prawdopodobieństwa (ang. ML – Maximum Likelihood), średnio zaawansowany klasyfikator metodą liniowej analizy dyskryminacyjnej (ang. LDA – Linear Discriminant Analysis) oraz najbardziej złożony klasyfikator SVM. Testowano przy tym różne rozdzielczości spektralne danych (4,6, 9,2, 13,8, 18,4, 23, 27,6, 32,2 i 36,8 nm). W metodzie ML na podstawie statystyk określone jest prawdopodobieństwo przynależności każdego piksela do danej klasy. Metoda LDA polega natomiast na wyszukiwaniu funkcji będącej liniową kombinacją cech i parametrów, które najlepiej odróżniają od siebie poszczególne klasy obiektów – wykorzystywane są w niej systemy uczące się. Na podstawie przeprowadzonych badań stwierdzono, że klasyfikator SVM jest najbardziej efektywny przy klasyfikacji dużej ilości klas (23), zastosowaniu dużej liczby kanałów (126) i wysokiej rozdzielczości spektralnej danych (4,6 nm). Współczynnik kappa wyniósł w tym przypadku 0,82 dla klasyfikatora ML, 0,77 dla klasyfikatora LDA oraz 0,88 dla klasyfikatora SVM. Metodę SVM zastosowali Dalponte i in. [2014] z wykorzystaniem różnych metod segmentacji koron drzew. Wyznaczono 3 klasy, w tym 2 klasy gatunków iglastych i jedną klasę gatunków liściastych. Uzyskano najwyższą dokładność całkowitą 93,5% przy segmentacji manualnej. Raczko i in. [2015] wykorzystali metodę SVM do wyznaczenia 5 gatunków drzew, w tym 2 gatunków liściastych i 3 iglastych. Uzyskano dokładność całkowitą równą 78,66%. Jones i in. [2010], wyznaczając 11 gatunków drzew, w tym 6 liściastych i 5 iglastych, stosując 40 wybranych kanałów spektralnych, za pomocą klasyfikatora SVM uzyskali dokładność całkowitą 72,3%.

Innymi metodami stosowanymi obecnie w klasyfikacji gatunkowej drzewostanów leśnych z wykorzystaniem danych hiperspektralnych są algorytmy Spectral Angle Mapper (SAM) oraz Spectral Information Divergence (SID). Metoda SAM jest dedykowana danym hiperspektralnym i polega na porównywaniu profili spektralnych (wektorów spektralnych) każdego piksela na obrazie z dowolnym wzorcem (pochodzącym np. z pomiarów laboratoryjnych, naziemnych lub z tzw. pikselami czystymi spektralnie). Obliczany jest kąt spektralny między każdą parą wektorów i na tej podstawie tworzone są obrazy wynikowe. Jest to metoda pikselowa, nieparametryczna, miękka i półautomatyczna. Metoda SID również polega na porównaniu wektorów spektralnych dwóch pikseli, ale bazuje na pomiarze rozbieżności ich rozkładów prawdopodobieństwa. Klasyfikator SAM wykorzystali m.in. Buddenbaum i in. [2005], porównując go z klasyfikatorem ML. W badaniach wyróżniono 4 klasy dla świerka pospolitego w różnych przedziałach wiekowych (10-30, 31-50, 51-80 i ponad 80 lat) oraz 2 klasy dla daglezi zielonej (10-30 i 31-50 lat). Testowano przy tym różne rozdzielczości spektralne danych oraz różne metody geostatystyczne. Większą dokładność całkowitą klasyfikacji wykazał klasyfikator ML (SAM 42,1-65,7%, ML 58,5-76,9%). Metody SAM, SID oraz ML testowali także Forzieri i in. [2012], przeprowadzając

klasyfikację na czterech obszarach o różnych typach pokrycia terenu (las mieszany, tereny zalewowe, tereny zabudowane i użytki rolne). Na obszarze leśnym wyznaczono 4 klasy gatunków drzew. Najwyższą dokładność całkowitą (~85%) otrzymano przy zastosowaniu 24 oryginalnych kanałów z wykorzystaniem klasyfikatora ML. Ghiyamat i in. [2013] porównywali natomiast wyniki otrzymane metodą SAM i SID przy testowaniu zastosowania pojedynczych oraz wielu pikseli czystych spektralnie dla klasy. Przeprowadzono trzy klasyfikacje: pierwszą z podziałem na drzewa liściaste i sosnę, drugą z podziałem na drzewa liściaste, sosnę czarną i sosnę zwyczajną oraz trzecią z podziałem na 6 klas, w tym na różne klasy wieku sosny czarnej i sosny zwyczajnej. W badaniach wykazano, że przy bardziej zaawansowanych klasyfikacjach należy stosować wiele pikseli czystych spektralnie dla klasy. Zwiększyło to dokładność klasyfikacji o około 8,3 do 14,3 punkta procentowego. W pierwszej klasyfikacji z wykorzystaniem oryginalnych kanałów spektralnych otrzymano dokładność całkowitą 92,6% dla SAM i 91,3% dla SID, w drugiej klasyfikacji 74,6% dla SAM i 73,0% dla SID oraz dla trzeciej klasyfikacji 66,7% dla SAM i 64,2% dla SID.

Zintegrowanie danych hiperspektralnych z innymi rodzajami danych

Optyczne dane teledetekcyjne, szczególnie hiperspektralne, niosą ze sobą znaczną ilość informacji przydatnej w rozróżnieniu gatunków drzew. Informacja dotyczy jednak jedynie refleksyjności. Inne cechy drzewostanu, takie jak wysokość drzew czy kształt koron, możemy uzyskać dzięki aktywnym technikom teledetekcyjnym, do których należy LiDAR (ang. Light Detection and Ranging).

Wśród analizowanych opracowań znalazły się badania, w których wykorzystywano informację pozyskaną przez ALS do klasyfikacji gatunkowej w połączeniu ze zobrazeniami hiperspektralnymi. Analizę przydatności informacji pozyskanych w ramach ALS przeprowadzono m.in. w badaniach Jonesa i in. [2010]. Klasyfikowano 11 gatunków drzew. Klasyfikacja danych hiperspektralnych została wzbogacona informacją o wysokości i miąższości drzewostanów. Porównano przy tym wyniki klasyfikacji algorytmem SVM przy wykorzystaniu wyłącznie danych hiperspektralnych oraz w połączeniu z informacją o wysokości lub miąższości. Po dodaniu do informacji spektralnej informacji o wysokości drzewostanów dokładność klasyfikacji wzrosła z 72,3 do 72,9%. Przy wzbogaceniu danych hiperspektralnych informacją o miąższości dokładność całkowita wzrosła z 72,3 do 73,5%. W przypadku większości gatunków informacja pozyskana z danych ALS podwyższyła ich rozróżnialność.

W badaniach prowadzonych przez Heinzela i Koch [2012] wzbogacono dane hiperspektralne m.in. o dane LiDAR (full-waveform), informację o wysokości pozyskaną metodą ALS, obraz tekstury oraz wysokorozdzielcze zdjęcia spektrostrefowe. Dokładność klasyfikacji w przypadku pojedynczych zestawów danych wynosiła: dane LiDAR (full-waveform) 79,22%, dane wysokościowe 47,27%, tekstura 46,75%, dane hiperspektralne 64,67%, zdjęcia spektrostrefowe (CIR) 50,71%. Połączenie informacji ze wszystkich zestawów danych pozwoliło na klasyfikację z dokładnością całkowitą 88,03%.

Informację pozyskaną z danych ALS wprowadzili do analizy także Dalponte i in. [2012]. Porównano klasyfikację na podstawie danych hiperspektralnych z klasyfikacją po dołączeniu dodatkowego parametru – maksymalnej wysokości lub wysokości drzew pozyskanej z ALS. Wprowadzenie dodatkowych parametrów podwyższyło dokładność klasyfikacji z 71,1% do 78,6%. W badaniach skoncentrowano się na porównaniu efektywności wykorzystania danych hiperspektralnych w połączeniu z ALS o wysokiej gęstości oraz danych wielospektralnych w połączeniu z ALS o mniejszej gęstości. W przypadku danych hiperspektralnych całkowita dokładność w każdym z przypadków wynosiła od ponad 80 do ponad 90%. W przypadku danych o gorszej rozdzielczości spektralnej wyniki były niższe o około 10 punktów procentowych.

Zestawy danych hiperspektralnych o różnej rozdzielczości terenowej HyMap 4 i 8 m oraz Hyperion 30 m porównano w pracy Ghosha i in. [2014]. By ocenić wpływ danych ALS na jakość klasyfikacji, klasyfikację wzbogacono informacją o wysokości drzew. W tym przypadku dodanie parametru wysokościowego nie miało istotnego statystycznie wpływu na podwyższenie dokładności klasyfikacji. Według autorów niniejszego opracowania wynik ten jest logicznie uzasadniony, ponieważ wysokość nie stanowi szczególnej cechy wybranych gatunków drzew lasotwórczych w naszej strefie klimatycznej i jej wykorzystywanie nie powinno wpłynąć znacząco na wyniki analiz.

Dane hiperspektralne były również integrowane z wynikami analiz geostatystycznych. W badaniach Buddenbauma i in. [2005] w wyniku analiz geostatystycznych i wykorzystania wielowymiarowych miar korelacji przestrzennej (semiwariancji, semiwariancji krzyżowej, pseudo-semiwariancji krzyżowej, madogramów, pseudokrzyżowych madogramów, macierzy współwystępowania) pozyskano informację o teksturze. Po połączeniu jej z informacją spektralną oraz przeprowadzeniu procesów poklasyfikacyjnych (sieve i clump) dokładność klasyfikacji wzrosła z 70 do 77,8%.

Klasyfikacja gatunków iglastych

Zastosowanie danych hiperspektralnych pozwala na rozróżnienie poszczególnych gatunków drzew. Wśród gatunków iglastych w badaniach najczęściej podejmowano się klasyfikowania świerka pospolitego (*Picea abies*) i sosny zwyczajnej (*Pinus sylvestris*), a także jodły pospolitej (*Abies alba*) oraz daglezi zielonej (*Pseudotsuga menziesii*). Możliwość rozróżnienia świerka i sosny na terenie południowych Niemiec podjęto w pracy Heinzela i Koch [2012], otrzymując odpowiednio dokładność 88,7 i 89,7%. Na obszarze lasu miejskiego w Karlsruhe (Niemcy) podjęto temat klasyfikacji 5 gatunków, w tym sosny i daglezi. Wykorzystanie danych lotniczych po transformacji MNF i klasyfikatora SVM dało najwyższą dokładność całkowitą – 96,5% [Ghosh i in. 2014].

Klasyfikację 6 gatunków, w tym: świerka pospolitego, sosny zwyczajnej oraz jodły pospolitej, przeprowadzono na obszarze Val di Sella (Alpy). Najwyższą dokładność otrzymano, stosując transformację MNF oraz klasyfikator SVM (74,1%) [Dalponte i in. 2009]. W kolejnych badaniach prowadzonych przez Dalponte'a i in. [2012] klasyfikowano 5 gatunków iglastych: jodłę pospolitą, modrzew europejski (*Larix decidua*), świerk pospolity, sosnę zwyczajną i sosnę górską (*Pinus mugo*). Dla poszczególnych gatunków przy zastosowaniu metody SVM otrzymano dokładność producenta: 66,2% (jodła pospolita), 81,1% (buk zwyczajny), 56,6% (modrzew europejski), 81,4% (świerk pospolity), 96,6% (sosna górską), 84,3% (sosna zwyczajna) i 88,9% (pozostałe liściaste) oraz użytkownika: 86,4% (jodła pospolita), 83,9% (buk zwyczajny), 57,6% (modrzew europejski), 66,6% (świerk pospolity), 53,5% (sosna górską), 80,2% (sosna zwyczajna) i 58,6% (pozostałe liściaste).

W pracy Jonesa i in. [2010] klasyfikowano 5 gatunków iglastych: jodłę olbrzymią (*Abies grandis*), żywotnik olbrzymi (*Thuja plicata*), dagleżę zieloną (*Pseudotsuga menziesii*), choinę zachodnią (*Tsuga heterophylla*) i sosnę wydmową (*Pinus contorta*). Z wykorzystaniem algorytmu SVM poszczególne gatunki zostały sklasyfikowane z dokładnością producenta: 6,9% (jodła olbrzymia), 85,8% (daglezja zielona), 42,7% (żywotnik olbrzymi), 64,3% (choina zachodnia) i 77,5% (sosna wydmowa). Dokładność użytkownika osiągała: 66,7% (jodła olbrzymia), 79,7% (daglezja zielona), 47% (żywotnik olbrzymi), 84,9% (choina zachodnia) i 61,5% (sosna wydmowa).

W południowo-wschodnich Niemczech klasyfikowano 2 gatunki drzew iglastych, dzieląc je jednocześnie na różne klasy wieku. W efekcie wyróżniono 6 klas: świerk pospolity w wieku

10-30, 30-50, 50-80 i powyżej 80 lat oraz daglezję zieloną w wieku 10-30 i 30-50 lat. Uzyskano współczynnik kappa o wysokości 0,66 przy użyciu wyłącznie danych hiperspektralnych. Wskaźnik wzrósł do 0,74, gdy do klasyfikacji dodano informację o teksturze obliczoną na podstawie analiz geostatystycznych [Buddenbaum i in. 2005]. Dokładność całkowita klasyfikacji wyniosła 77,8% w przypadku zastosowania klasyfikatora Spectral Angle Mapper na danych hiperspektralnych i informacji o teksturze.

Klasyfikacja gatunków liściastych

Wśród klasyfikowanych gatunków liściastych najczęściej wyróżniane są różne gatunki dębu, szczególnie bezszypułkowy, czerwony i szypułkowy, a także buk zwyczajny (*Fagus sylvatica*). W swoich badaniach Ghosh i in. [2014] podjęli zagadnienie klasyfikacji buka zwyczajnego, dębu bezszypułkowego (*Quercus petraea*) oraz dębu czerwonego (*Quercus rubra*). Najwyższą dokładność całkowitą klasyfikacji (96,5%) otrzymano przy wykorzystaniu klasyfikatora SVM na danych lotniczych po transformacji MNF. W pracy Forzieriego i in. [2012] przeprowadzono klasyfikację, wyróżniając 4 klasy: dąb, wierzba, topola i oliwka. Przy użyciu klasyfikatora Maximum Likelihood otrzymano dokładność całkowitą 85%.

Na obszarze rezerwatu Bosco della Fontana w południowych Alpach przeprowadzono klasyfikację następujących gatunków liściastych: klon polny (*Acer campestre*), klon jesionolistny (*Acer negundo*), olsza czarna (*Alnus glutinosa*), grab pospolity (*Carpinus betulus*), leszczyna pospolita (*Coryllus avellana*), jesion wąskolistny (*Fraxinus angustifolia*), orzech czarny (*Juglans nigra*), orzech włoski (*Juglans regia*), platan (*Platanus hybrida*), topola szara (*Populus canescens*), czereśnia (*Prunus avium*), dąb burgundzki (*Quercus cerris*), dąb szypułkowy (*Quercus robur*), dąb czerwony (*Quercus rubra*), lipa drobnolistna (*Tilia cordata*), wiąz pospolity (*Ulmus minor*) oraz robinia akacja (*Robinia psuedoacacia*). Dla większości gatunków przy wykorzystaniu algorytmu SVM osiągnięto dokładność producenta powyżej 80%, z wyjątkiem wiazu pospolitego i platanu, które sklasyfikowano z dokładnością powyżej 70%, oraz leszczyny, dla której dokładność producenta wyniosła powyżej 50% [Dalponte i in. 2009]. W pracy Jonesa i in. [2010] sklasyfikowano: topolę balsamiczną (*Populus balsamifera*), topolę osikową (*Populus tremuloides*), olszę czerwoną (*Alnus rubra*), klon wielkolistny (*Acer macrophyllum*), *Quercus garryana* i chróściń (*Arbutus menziesii*). Wykorzystano algorytm klasyfikacyjny SVM. Dla poszczególnych gatunków osiągnięto następujące dokładności producenta (P) i użytkownika (U): topola kalifornijska – 97,5% (P), 73,8% (U), topola osikowa – 22,9% (P), 26,8% (U), olsza czerwona – 66,5% (P), 74,5% (U), klon wielkolistny – 54,3% (P), 73,7 % (U), *Quercus garryana* – 81,8% (P), 79,3% (U), chróścina – 57,4% (P), 68,1% (U). W badaniach prowadzonych przez Heinzela i Koch [2012] sklasyfikowano buk zwyczajny i dąb bezszypułkowy z dokładnością odpowiednio 90,7 oraz 83,1%. Jako problem w trakcie klasyfikacji przedstawiono mieszanie się klas w obrębie gatunków, tj. błędne klasyfikowanie buka jako dębu bądź odwrotnie.

Klasyfikację sześciu gatunków liściastych przeprowadzono w badaniach Boschettiego i in. [2007]. Wyróżniano pojedyncze gatunki (olsza czarna, kasztan jadalny), a także grupy gatunków (topole i topole osiki, obce gatunki inwazyjne) oraz zespoły leśne (grądy, bory sosnowe, łągi wierzbowe). Wykorzystano algorytm klasyfikacji Maximum Likelihood. Całkowita dokładność klasyfikacji wyniosła 75%, a współczynnik kappa osiągnął wysokość 0,67.

Dyskusja

Przeprowadzony przegląd stosowanych obecnie metod klasyfikacji gatunkowej drzewostanów opartych na przetworzeniu i analizie lotniczych zobrażeń hiperspektralnych wykazuje, że dane mogą być wykorzystywane do identyfikacji gatunków zarówno drzewostanów liściastych, jak

i iglastych lasów strefy umiarkowanych szerokości geograficznych. Przegląd ten pozwolił ponadto na wyodrębnienie najczęściej stosowanych i najbardziej efektywnych algorytmów.

Na etapie wstępnego przetwarzania danych stosowane są różne algorytmy dedykowane obrazowaniom hiperspektralnym. Konieczne jest przeprowadzenie korekcji radiometrycznej oraz geometrycznej. Na podstawie wykonanego przeglądu metod nie stwierdzono jednak, które z metod są najbardziej efektywne. Metodę przetworzeń należy bowiem dopasować do pozyskanych danych zarówno hiperspektralnych, jak i referencyjnych (np. ortofotomapa, NMT). Decyzję o przeprowadzeniu bądź pominięciu korekcji atmosferycznej należy podjąć po wnikliwej analizie warunków atmosferycznych panujących w czasie wykonania nalotu oraz ich wpływu na jakość pozyskanych danych hiperspektralnych. Dodatkowo stwierdza się, że w przypadku obrazowań hiperspektralnych przeznaczonych do klasyfikacji gatunkowej drzewostanów częściej wykorzystywane są bezwzględne metody korekcji, tj. oparte na modelach transferu promieniowania.

W przypadku redukcji wymiarów przestrzeni spektralnej pojawia się w literaturze możliwość wykorzystania wszystkich dostępnych kanałów, selekcja zakresów najbardziej informacyjnych bądź transformacja danych, w wyniku której powstają jakościowo nowe kanały (tab. 1). Wybór zakresów spektrum może się odbywać na podstawie różnych algorytmów selekcji. Najczęściej pojawiają się algorytmy oparte na metodach sekwencyjnego dodawania cech w procesie przeszukiwania (metoda SFFS i SFS). W analizowanych opracowaniach wykorzystywano również do klasyfikacji zakres red edge, zakresy wybrane na podstawie pomiarów spektrometrycznych lub testowania różnych zestawów kanałów, a także kanały otrzymane w wyniku transformacji MNE. Wyniki przeglądu literatury wskazują, że wyższą dokładność całkowitą klasyfikacji gatunkowej drzewostanów uzyskuje się po ograniczeniu wykorzystywanych zakresów promieniowania niż przy wykorzystaniu całego zakresu spektrum.

Wśród stosowanych obecnie klasyfikatorów najlepsze efekty uzyskuje się z wykorzystaniem algorytmu maszyn wektorów wspierających (SVM), ze względu na brak występowania w tej metodzie zjawiska Hughesa. Wzbogacenie zestawu danych wejściowych o informacje uzyskane ze skanowania laserowego, głównie wysokość drzew, pozwala natomiast na bardziej efektywne rozpoznanie gatunkowe i niejednokrotnie podwyższa dokładność klasyfikacji.

Przeanalizowane prace wskazują, że przy zastosowaniu optymalnej metody klasyfikacji możliwe jest wyróżnienie znacznej liczby gatunków ze stosunkowo wysoką dokładnością (tab. 2). Wysoką rozróżnialnością cechują się zwłaszcza gatunki iglaste, świerk pospolity i sosna zwyczajna, które są klasyfikowane z dokładnością powyżej 80%. Wśród gatunków liściastych dobrze rozróżnialne są dęby i buk zwyczajny. Gatunki trudne do klasyfikowania to m.in. leszczyna oraz topola osikowa, dla których klasyfikacja osiąga znacznie niższą dokładność. Przy klasyfikacji gatunków drzew na podstawie lotniczych danych hiperspektralnych napotkać można problemy, takie jak niedostateczna rozdzielczość przestrzenna obrazowań, występowanie zjawiska Hughesa, dobór odpowiedniej próby do klasyfikacji oraz przeszacowanie klasyfikacji gatunków o podobnych charakterystykach spektralnych w obrębie grupy gatunków liściastych i grupy gatunków iglastych.

Przeprowadzony przegląd literatury wskazał także pewne ograniczenia wykorzystania danych hiperspektralnych w gospodarce leśnej. Do najważniejszych należą koszt danych i automatyzacja przetwarzania kilku szeregów danych. Aktualna cena danych (w Polsce koszt wynosi od około sześciu do kilkunastu złotych za hektar) oznacza, że praktyczne wdrożenie danych hiperspektralnych do praktyki urzędzeniowej może być bardzo trudne. Wynika to przede wszystkim z faktu, że brakuje opracowań, które wykażą zysk netto generowany dzięki zastosowaniu danych hiper-

Tabela 1.

Najczęściej wykorzystywane metody redukcji wymiarów przestrzeni (Metoda) i klasyfikacji gatunków (Klasyfikator) oraz używane do tego zakresy spektralne (Zakres [nm]) i liczba wykorzystanych kanałów (n) w odniesieniu do liczby kanałów skanera (N; liczba klas w nawiasie)

The most frequently applied feature reduction (Metoda) and classification (Klasyfikator) methods as well as selected spectral bands (Zakres [nm]) and number of selected bands (n) per number of all bands in the scanner (N; number of classes in parentheses)

	Metoda	Zakres	n/N	Klasyfikator
Boschetti i in. [2007]	Red edge	VIS: 450-550, 650-700 NIR: 700-750	4/92 (7)	ML
Buddenbaum i in. [2005]	MNF	–	10/128 (6)	SAM, ML
Dalponte i in. [2009]	SFFS	VIS: 400-700 NIR: 700-1050	32/126 (8), 32/126 (23)	SVM, GML, LDA
	Wszystkie kanały All bands	VIS: 400-700 NIR: 700-1050	126/126 (7)	SVM, RF
Dalponce i in. [2012]	SFFS	VIS: 400-700 NIR: 700-800, 850-950	43/126 (8), 21/126 (5), 20/126 (3), 21/126 (2)	SVM, RF
Dalponte i in. [2014]	Wszystkie kanały All bands	VIS: 400-70 NIR: 700-1050	160/160 (3)	SVM
Forzieri i in. [2012]	SFS	VIS: 450-700 NIR: 700-1350	24/102 (17)	ML, SAM, SID
Gosh i in. [2014]	Wszystkie kanały All bands	VIS: 450-700 NIR: 700-1350 SWIR: 1350-2450	126/126 (5)	SVM, RF
	MNF	–	25/126 (5)	SVM, RF
Heinzel i Koch [2012]	Wszystkie kanały All bands	VIS: 450-700 NIR: 700-1350 SWIR: 1350-2450	125/125 (4)	SVM
Jones i in. [2010]	Laboratoryjne pomiary spektrometryczne Ground based spectrometer measurements	VIS: 500-700 NIR: 700-850, 950-1100, 1300-1350 SWIR: 1400-1500, 1650-1850, 2050-2150, 2200-2350	40/492 (11)	SVM
Raczko i in. [2015]	Wybór każdorazowo innego zestawu danych Different sets of features	–	40/288 (5 kl.)	SVM

MNF – minimum noise fraction, SFFS – sequential forward floating selection, SFS – sequential floating selection

spektralnych w gospodarce leśnej. Mała konkurencja na rynku powoduje również dodatkowe utrudnienia. Ponieważ jednak rynek skanerów hiperspektralnych intensywnie się rozwija, można spodziewać się, że w niedalekiej przyszłości liczba tych urządzeń wzrośnie i cena danych spadnie.

Automatyzacja procesu jest kolejnym utrudnieniem. Większość prezentowanych prac naukowych to opracowania na niewielkiej liczbie szeregów. Zastosowanie większej liczby szeregów generuje potrzebę ich integracji, czyli uwzględnienia wielu czynników warunkujących informację spektralną zawartą w pikselu. Jest to złożone i często pomijane w opracowaniach zagadnienie, bez rozwiązania którego operacyjne wdrożenie jest trudne.

Tabela 2.

Dokładność [%] klasyfikacji (PA – producenta, UA – użytkownika, OA – całkowita) oraz współczynnik kappa (κ) dla wyznaczonych klas w obrębie drzewostanów liściastych (Liściaste) i iglastych (Iglaste)

Classification accuracy [%] (PA – producer's, UA – user's, OA – overall) and kappa coefficient (κ) for distinguished broadleaved (Liściaste) or coniferous (Iglaste) stand classes

	Liściaste	PA	UA	Iglaste	PA	UA	OA	κ
Boschetti i in. [2007] 4 m*	<i>Alnus</i> sp.	71	55	<i>Pinus</i> sp.	90	95	75,00	0,67
	<i>Castanea sativa</i>	79	80					
	<i>Quercus carpinetum</i>	70	77					
	<i>Populus</i> sp.	64	62					
	<i>Salix</i> sp.	79	71					
	obce gatunki inwazyjne alien invasive species	77	77					
Buddenbaum i in. [2005] 5 m	b.d.						77,80	0,74
	<i>Acer campestre</i>	75,6		–			b.d.	0,88
	<i>Acer negundo</i>	87,5						
	<i>Alnus glutinosa</i>	91,0						
	<i>Carpinus betulus</i>	92,3						
	<i>Fraxinus angustifolia</i>	90,2						
	<i>Juglans nigra</i>	88,3						
	<i>Juglans regia</i>	90,7						
Dalponte i in. [2009] 1 m	<i>Platanus hybrida</i>	90,2						
	<i>Populus canescens</i>	89,0						
	<i>Populus hybrida</i>	89,9						
	<i>Prunus avium</i>	80,7						
	<i>Quercus cerris</i>	93,4						
	<i>Quercus robur</i>	88,2						
	<i>Quercus rubra</i>	91,6						
	<i>Robinia pseudoacacia</i>	88,2						
	<i>Tilia cordata</i>	89,3						
	<i>Ulmus minor</i>	71,7						
Dalponte i in. [2012] 1 m	<i>Fagus sylvatica</i>	81,1	83,9	<i>Abies alba</i>	66,2	86,4	91,70	0,88
	Inne			<i>Picea abies</i>	81,4	66,6		
	other	88,9	58,6	<i>Pinus sylvestris</i>	84,3	80,2		
				<i>Pinus mugo</i>	96,6	53,5		
				<i>Larix decidua</i>	56,5	57,6		
Dalponte i in. [2014] b.d.	<i>Betula</i> sp.+			<i>Picea abies</i>	94,8	96,6		
	<i>Populus tremula</i>	73,2	92,3	<i>Pinus sylvestris</i>	97,5	90,3	93,50	0,89
Forzieri i in. [2012] 3 m	<i>Populus</i> sp.	38,8		<i>Picea</i> sp.	82,0		83,40	b.d.
	<i>Quercus</i> sp.	94,6		<i>Pinus</i> sp.	61,8			
	<i>Salix</i> sp.	67,8						
	<i>Olea</i> sp.	33,0						
Ghosh i in. [2014] 4 m	b.d.						81,00	0,77
Ghosh i in. [2014] 8 m	b.d.						96,50	0,83
Heinzel i Koch [2012] 4 m	<i>Fagus sylvatica</i>	90,7		<i>Picea abies</i>	88,7		88,03	b.d.
	<i>Quercus petraea</i>	83,1		<i>Pinus sylvestris</i>	89,0			

Tabela 2. ciąg dalszy

	Liściaste	PA	UA	Iglaste	PA	UA	OA	κ
	<i>Acer macrophyllum</i>	54,3	73,7	<i>Abies grandis</i>	6,9	66,7	73,50	0,60
Jones i in.	<i>Alnus rubra</i>	66,5	74,5	<i>Pinus contorta</i>	77,5	61,5		
[2010]	<i>Populus balsamifera</i>	97,5	73,8	<i>Pseudotsuga manziesii</i>	85,8	79,7		
2 m	<i>Populus tremuloides</i>	22,9	26,8	<i>Thuja plicata</i>	6,9	66,7		
	<i>Quercus garryana</i>	81,8	79,3	<i>Tsuga heterophylla</i>	64,3	84,9		
				<i>Arbutus menziesii</i>	57,4	68,1		
Raczko	<i>Alnus glutinosa</i>	74	82	<i>Larix decidua</i>	60	82	78,66	0,71
i in. [2015]	<i>Fagus sylvatica</i>	88	86	<i>Picea abies</i>	84	77		
3,5 m				<i>Pinus sylvestris</i>	69	53		

b.d. – no info

* rozdzielczość danych; spatial resolution

Wnioski

- ✦ Teledetekcja hiperspektralna może być wykorzystywana do klasyfikacji gatunkowej drzewostanów.
- ✦ Przeprowadzenie korekcji atmosferycznej dla danych hiperspektralnych nie jest konieczne.
- ✦ Wyższą dokładność całkowitą klasyfikacji uzyskuje się po ograniczeniu liczby wykorzystywanych zakresów spektralnych.
- ✦ Najwyższą dokładność klasyfikacji gatunkowej drzewostanów uzyskuje się, stosując klasyfikator SVM (Support Vector Machines).
- ✦ Zintegrowanie danych hiperspektralnych z danymi ALS może przyczynić się do poprawienia dokładności klasyfikacji. Najczęściej wykorzystywaną w tym celu informacją jest wysokość drzew.
- ✦ Wyższą rozróżnialnością charakteryzują się gatunki iglaste.
- ✦ Praktyczne używanie danych hiperspektralnych w działalności gospodarczej firm leśnych wymaga dalszego rozwoju technologii, znacznego spadku cen i/lub wnikliwej analizy ekonomicznej zysków płynących z użycia danych hiperspektralnych w gospodarce leśnej.

Literatura

- van Aardt J. A. N., Wynne R. H. 2007. Examining pine spectral separability using hyperspectral data from an airborne sensor: An extension of field-based results. *International Journal of Remote Sensing* 28 (2): 431-436.
- Adams J. B., Sabol D. E., Kapos V., Filho R. A., Roberts D. A., Smith M. O., Gillespie A. R. 1995. Classification of multispectral images based on fractions of endmembers: Application to land-cover change in the Brazilian Amazon. *Remote Sensing of Environment* 52 (2): 137-154.
- Adler-Golden S. M., Matthew M. W., Bernstein L. S., Levine R. Y., Berk A., Richtsmeier S. C., Acharya P. K., Anderson G. P., Felde G., Gardner J., Hike M., Jeong L. S., Pukall B., Mello J., Ratkowski A., Burke H. H. 1999. Atmospheric correction for short-wave spectral imagery based on MODTRAN4. *SPIE Proc. Imaging Spectrometry* 3753: 61-69.
- Alonso M. C., Malpica J. A., de Aguirre A. M. 2011. Consequences of the Hughes phenomenon on some classification techniques. *ASPRS 2011 Annual Conference*. Milwaukee, Wisconsin May 1-5, 2011.
- Bernstein L. S., Sundberg R. L., Levine R. Y., Perkins T. C., Berk A. 2005. A new method for atmospheric correction and aerosol optical property retrieval for VIS-SWIR multi- and hyperspectral imaging sensors: QUAC (QUick Atmospheric Correction). *IEEE IGARSS 00*: 3549-3552.
- Boschetti M., Boschetti L., Oliveri S., Casati L., Canova I. 2007. Tree species mapping with airborne hyper-spectral MIVIS data: the Ticino Park study case. *International Journal of Remote Sensing* 28 (6): 1251-1261.
- Buddenbaum H., Schlerf M., Hill J. 2005. Classification of coniferous tree species and age classes using hyper-spectral data and geostatistical methods. *International Journal of Remote Sensing* 26 (24): 5453-5465.

- Dadon A., Ben-Dor E., Karnieli A. 2010. Use of derivative calculations and minimum noise fraction transform for detecting and correcting the spectral curvature effect (smile) in Hyperion images. *IEEE Transactions on Geoscience and Remote Sensing* 48 (6): 2603-2612.
- Dalponte M., Bruzzone L., Gianelle D. 2012. Tree species classification in the Southern Alps based on the fusion of very high geometrical resolution multispectral/hyperspectral images and LiDAR data. *Remote Sensing of Environment* 123: 258-270.
- Dalponte M., Bruzzone L., Vescovo L., Gianelle D. 2009. The role of spectral resolution and classifier complexity in the analysis of hyperspectral images of forest areas. *Remote Sensing of Environment* 113: 2345-2355.
- Dalponte M., Orka H. O., Ene L. T., Gobakken T., Naesset E. 2014. Tree crown delineation and tree species classification in boreal forests using hyperspectral and ALS data. *Remote Sensing of Environment* 140: 306-317.
- Forzieri G., Moser G., Catani F. 2012. Assessment of hyperspectral MIVIS sensor capability for heterogeneous landscape classification. *ISPRS Journal of Photogrammetry and Remote Sensing* 74: 175-184.
- Ghiyamati A., Shafri H. Z. M., Mahdirajic G. A., Shariff A. R. M., Mansor S. 2013. Hyperspectral discrimination of tree species with different classifications using single- and multiple-endmember. *International Journal of Applied Earth Observation and Geoinformation* 23: 177-191.
- Ghosh A., Fassnacht F. E., Joshia P. K., Koch B. 2014. A framework for mapping tree species combining hyperspectral and LiDAR data: Role of selected classifiers and sensor across three spatial scales. *International Journal of Applied Earth Observation and Geoinformation* 26: 49-63.
- Głowienka E. 2008. Porównanie metod korekcji atmosferycznej dla danych z sensorów hiperspektralnych. *Archiwum Fotogrametrii, Kartografii i Teledetekcji* 18: 121-130.
- Green A., Berman M., Switzer B., Craig M. 1988. A transformation for ordering multispectral data in terms of image quality with implications for noise removal. *IEEE Transactions on Geoscience and Remote Sensing* 26 (1): 65-74.
- Heinzel J., Koch B. 2012. Investigating multiple data sources for tree species classification in temperate forest and use for single tree delineation. *International Journal of Applied Earth Observation and Geoinformation* 18: 101-110.
- Hill J., Mehl W. 2003. Geo- und radiometrische Aufbereitung multi- und hyperspektraler Daten zur Erzeugung langjähriger kalibrierter Zeitreihen. *Photogrammetrie, Fernerkundung, Geoinformation* 1: 7-14.
- Hill J., Mehl W., Radeloff V. 1995. Improved forest mapping by combining corrections of atmospheric and topographic effects. W: Asken J. [red.]. *Sensors and environmental applications of remote sensing, Proceedings 14th EARSeL Symposium*. Göteborg, Sweden, 6-8 June 1994. 143-151.
- Hughes G. F. 1968. On the mean accuracy of statistical pattern recognizers. *IEEE Transactions on Information Theory* IT-14: 55-63.
- Jones T. G., Coops N. C., Sharma T. 2010. Assessing the utility of airborne hyperspectral and LiDAR data for species distribution mapping in the coastal Pacific Northwest, Canada. *Remote Sensing of Environment* 114: 2841-2852.
- Kurezyński Z., Wolniewicz W. 2002. Korekcja geometryczna wysokorozdzielczych obrazów satelitarnych. *Geodeta* 11: 90.
- Latifi H., Fassnacht F., Koch B. 2012. Forest structure modeling with combined airborne hyperspectral and LiDAR data. *Remote Sensing of Environment* 121: 10-25.
- Martin M. E., Newman S. D., Aber J. D., Congalton R. G. 1998. Determining Forest Species Composition Using High Spectral Resolution Remote Sensing Data. *Remote Sensing of Environment* 65 (3): 249-254.
- Melgani F., Bruzzone L. 2004. Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing* 42 (8): 1778-1790.
- Raczko E., Zagajewski B., Ochtyra A., Jarościńska A., Marcinkowska-Ochtyra A., Dobrowolski M. 2015. Określenie składu gatunkowego lasów Góry Chojnik (Karkonoski Park Narodowy) z wykorzystaniem lotniczych danych hiperspektralnych APEX. *Sylwan* 159 (7): 593-599.
- Richter R. 1996. Atmospheric correction of DAIS hyperspectral image data. *Computers & Geosciences* 22: 785-793.
- Schlöpfer D., Schaepman M., Itten K. I. 1998. Level II pre-processing concept for the AIRBORNE PRISM Experiment (APEX). *Proceeding of 1st EARSEL Workshop on Imaging Spectroscopy EARSeL/RSL*. Zurich.
- Serpico S., Moser G. 2007. Extraction of Spectral Channels from Hyperspectral Images for Classification Purposes. *IEEE Transactions On Geoscience And Remote Sensing* 45 (2): 484-495.
- Stereńczak K., Hycza T., Ciesielski M., Bałazy R., Sławik Ł. 2014. Jednoczesna rejestracja lotnicza zobrazowań hiperspektralnych i ALS – możliwości wykorzystania w leśnictwie. VII Konferencja Geomatyka w Lasach Państwowych. Rogów, 16-18 września 2014.
- Tanre´ D., Deroo C., Duhaut O., Herman M., Morcrette J. J., Perbos J., Deschamps P. Y. 1990. Description of a computer code to simulate the satellite signal in the solar spectrum: the 5S code. *International Journal of Remote Sensing* 11: 659-668.
- Tompalski P., Coops N. C., White J. C., Wulder M. A. 2014. Simulating the impacts of error in species and height upon tree volume derived from airborne laser scanning data. *Forest Ecology and Management* 327: 167-177.

- Vane G., Goetz A. F. H. 1993.** Terrestrial imaging spectrometry: Current status, future trends. *Remote Sensing of Environment* 44: 117-126.
- Vapnick V. N. 1998.** *Statistical learning theory*. John Wiley and Sons Inc.
- Wulder M. A., Dymond C. C., White J. C., Leckie D. G., Carroll A. L. 2006.** Surveying mountain pine beetle damage of forests: A review of remote sensing opportunities. *For. Ecol. Manage.* 221: 27-41.
- Zagajewski B. 2010.** Ocena przydatności sieci neuronowych i danych hiperspektralnych do klasyfikacji roślinności Tatr Wysokich. *Teledetekcja Środowiska* 43: 38-44.